

การใช้แพร่โวลต์อัลกอริทึมแบบใช้เทรสโวลต์สองระดับในการทำนายการร้องขอ
เว็บเพจ

AN EFFICIENT TWO-LEVEL THRESHOLDS PAIRWISE ALGORITHM
FOR PREDICTING REQUEST TO WEB SERVER

วิศิษฐ์ พัฒน์ชู
WISIT PHATCHOO

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาเทคโนโลยีสารสนเทศ

บัณฑิตวิทยาลัย

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2547

ISBN 974-9709-72-1

การใช้แพรวัวส์อัลกอริทึมแบบใช้เทอร์สโหลสองระดับในการทำนายการร้องขอ
เว็บเพจ

AN EFFICIENT TWO-LEVEL THRESHOLDS PAIRWISE ALGORITHM
FOR PREDICTING REQUEST TO WEB SERVER



วิศิษฐ์ พัฒน์ชู

WISIT PHATCHOO

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาเทคโนโลยีสารสนเทศ
บัณฑิตวิทยาลัย

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เลขหมู่.....
เลขทะเบียน.....51616
วัน,เดือน,ปี2.6...ค.ศ...2547

พ.ศ. 2547

ISBN 974-9709-72-1



**AN EFFICIENT TWO-LEVEL THRESHOLDS PAIRWISE ALGORITHM
FOR PREDICTING REQUEST TO WEB SERVER.**

WISIT PHATCHOO

**A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF SCIENCE IN INFORMATION TECHNOLOGY
SCHOOL OF GRADUATE STUDIES
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

2004

ISBN 974-9709-72-1

COPYRIGHT 2004

SCHOOL OF GRADUATE STUDIEDS

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

บัณฑิตวิทยาลัย
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ใบรับรองวิทยานิพนธ์

หัวข้อวิทยานิพนธ์ การใช้แพร่ไวรัสอัลกอริทึมแบบใช้เทรชโวลสองระดับในการทำนายการร้องขอเว็บเพจ
AN EFFICIENT TWO-LEVEL THRESHOLDS PAIRWISE ALGORITHM FOR PREDICTION REQUEST TO WEB SERVER


ชื่อนักศึกษา นายวิศิษฎ์ พัฒน์ชู

รหัสประจำตัว 43067004

ปริญญา วิทยาศาสตรมหาบัณฑิต

สาขาวิชา เทคโนโลยีสารสนเทศ

อาจารย์ผู้ควบคุมวิทยานิพนธ์ ผศ.ดร.โชติพัชร ภรณ์วลัย

คณะกรรมการสอบวิทยานิพนธ์		ลายมือชื่อ
ผศ.ดร.โชติพัชร	ภรณ์วลัย	
รศ.ดร.รัตติกกร	วรากุลศิริพันธ์ุ	
ผศ.ดร.จันทร์บูรณ์	สถิตวิริยวงศ์	
ผศ.ดร.วรพจน์	กรีสุระเดช	
ผศ.อักรินทร์	คุณกิตติ	

วัน/เดือน/ปี ที่สอบ 18 พฤษภาคม 2547 เวลา 11.00 น. เป็นต้นไป
สถานที่สอบ ณ ห้อง M 23 (ชั้นลอย) อาคารเรียนรวมและปฏิบัติการคณะเทคโนโลยีสารสนเทศ


บัณฑิตวิทยาลัยรับรองแล้ว

(ผศ.ดร.ภาณุวัตร เจริญสุข)
คณบดีบัณฑิตวิทยาลัย

วันที่.....๒๘.....เดือน.....พฤษภาคม.....พ.ศ. ๒๕๔๗

หัวข้อวิทยานิพนธ์	การใช้แพร่โวลต์อัลกอริทึมแบบใช้เทรสโวลสองระดับในการ ทำนายการร้องขอเว็บเพจ
นักศึกษา	นาย วิศิษฎ์ พัฒน์ชู
รหัสประจำตัว	43067004
ปริญญา	วิทยาศาสตรมหาบัณฑิต
สาขาวิชา	วิทยาการสารสนเทศ
พ.ศ.	2547
อาจารย์ผู้ควบคุมวิทยานิพนธ์	ผศ.ดร. โชติพัชร ภรณ์วลัย

บทคัดย่อ

พรีเฟรชซิง (Pre-fetching) เป็นเทคนิคที่ใช้ในการลดเวลาในการเข้าถึงเว็บเพจ (webpage) หรือรีซอร์ส (resource) ต่างๆบนเครือข่ายอินเทอร์เน็ต โดยจะทำการทำนายเว็บเพจหรือรีซอร์สที่ผู้ใช้จะเข้าถึงในอนาคต และจะทำการดึงเว็บเพจหรือรีซอร์สที่ทำนายมาเก็บไว้ที่พรีอ็อกซีเซิร์ฟเวอร์ (Proxy server) หรือแคช (Cache) ก่อนที่ผู้ใช้จะเข้าถึง และแพร่โวลต์อัลกอริทึม (Pairwise Algorithm) ก็เป็นหนึ่งในพรีเฟรชซิงเทคนิคที่จะใช้ข้อมูลในการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆของผู้ใช้มาทำการสร้างเป็นฮินท์ (Hint) ที่จะใช้ในการบอกว่าเว็บเพจหรือรีซอร์สที่ผู้ใช้จะเข้าถึงในอนาคต เพื่อทำการดึงมาเก็บไว้ก่อน

ในวิทยานิพนธ์นี้แนะนำเสนอเทคนิคที่ใช้ในการปรับปรุงประสิทธิภาพของแพร่โวลต์อัลกอริทึม โดยเทคนิคที่แนะนำนี้เรียกว่าแพร่โวลต์อัลกอริทึมแบบใช้เทรสโวล 2 ระดับ ซึ่งจะมีการรวมเอาฮินท์ที่จะจากข้อมูลการเข้าถึงเว็บเพจหรือรีซอร์สของผู้ใช้เฉพาะคนและจากข้อมูลการเข้าถึงเว็บเพจหรือรีซอร์สของผู้ใช้ทั้งหมด ซึ่งผลจากการนำฮินท์ทั้งสองมารวมกันจะทำให้ได้ฮินท์ที่มีอัตราความถูกต้อง (Precision) และอัตราการนำฮินท์กลับมาใช้ (Recall) ที่สูงกว่าแพร่โวลต์อัลกอริทึมเดิม

Thesis Title	An Efficient Two-Level Thresholds Pairwise Algorithm for Predicting Request to Web Server.
Student	Mr. Wisit Phatchoo
Student ID.	43067004
Degree	Master of Science
Programme	Information Science
Year	2004
Thesis Advisor	Asst. Prof. Dr. Chotipat Pornavalai

ABSTRACT

Prefetching is the technique to reduce time or latency of users resource access on internet network. The prefetching will predict the webpages or resources that user will access in future and then it pull predicted webpages or resources and keep them on proxy server or cache. Pairwise algorithm is one of prefetching technique that use resource access information of clients to construct hint volumes. The hint volumes are predicted webpage or resource.

This thesis represents the extend technique that improve the efficiency of pairwise algorithm. Our extend technique, we call two-level thresholds pairwise algorithm. It will construct hint volume from the combination of hint volumes that use resource access of specific clients and hint volumes that use resource access information of all clients. After that, we will get more efficiency hint volumes from both resource access information. The performance of hint volumes from our extend technique has high normalized precision rate and high normalized recall rate than original pairwise algorithm.

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จได้ด้วยความกรุณาจากอาจารย์ ที่ปรึกษา ผศ.ดร. โชติพัชร ภรณ์วัลย์ ที่ให้ความช่วยเหลือให้คำชี้แนะช่วยแก้ปัญหาตลอดจนให้ความรู้และประสบการณ์ที่ดีแก่ข้าพเจ้า

ขอขอบพระคุณ รศ.ดร.รัตติกกร วรากุลศิริพันธุ์, ผศ.ดร. จันทร์บุรณ์ สถิตวิริยวงศ์, ผศ.ดร. วรพจน์ กรีสระเดช, ผศ. อัครินทร์ คุณกิตติ กรรมการสอบหัวข้อและโครงร่างวิทยานิพนธ์ที่ได้กรุณาให้คำแนะนำตลอดจนข้อชี้แนะจนในที่สุดทำให้วิทยานิพนธ์ฉบับนี้สำเร็จลงได้

ขอขอบคุณเพื่อนๆ และน้อง ๆ ของข้าพเจ้าที่ได้ช่วยเหลือในการหาข้อมูลเกี่ยวกับสื่อไฟล์และเนื้อหาต่างๆ

สุดท้ายต้องขอขอบคุณพ่อและแม่ของข้าพเจ้า นายวิรัตน์และนางสาตี พัฒน์ชู ที่เป็นกำลังให้ตลอดเวลาที่ทำวิทยานิพนธ์ฉบับนี้

สำหรับคุณงามความดีอันใดที่เกิดจากวิทยานิพนธ์ฉบับนี้ ข้าพเจ้าขอมอบให้กับบิดามารดาซึ่งเป็นที่รักและเคารพยิ่ง ตลอดจนครูอาจารย์ที่เคารพทุกท่านที่ได้ประสิทธิ์ประสาทวิชาความรู้และถ่ายทอดประสบการณ์ที่ดีให้แก่ข้าพเจ้า

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญรูป.....	VI
สารบัญตาราง.....	XIII
บทที่ 1 บทนำ.....	1
1.1 ที่มาและเหตุจูงใจในการทำวิจัย.....	1
1.2 อธิบายถึงปัญหาที่กำลังศึกษาอยู่ของวิทยานิพนธ์.....	1
1.3 ทำไมปัญหานี้ถึงน่าสนใจ.....	1
1.4 หลักการใหม่อะไรที่น่าสนใจ.....	2
1.5 เปรียบเทียบกับหลักการที่มีอยู่เดิม.....	2
1.6 รายละเอียดในวิทยานิพนธ์.....	3
บทที่ 2 ความรู้พื้นฐานของการเข้าถึงเว็บเพจบนเครือข่ายอินเทอร์เน็ต.....	4
2.1 องค์ประกอบของอินเทอร์เน็ต.....	4
2.2 องค์ประกอบพื้นฐานของเว็ลด์ไวด์เว็บ.....	10
2.3 ขั้นตอนการเข้าถึงเว็บเพจ.....	22
บทที่ 3 ระบบการทำงานของพีเอฟซีและแพร์ไวส์อัลกอริทึม.....	47
3.1 กล่าวนำ.....	47
3.2 รูปแบบการทำงานแบบต่างๆของการพีเอฟซี.....	47
3.3 รูปแบบต่างๆ ของลือกไฟล์.....	50
3.4 รูปแบบต่างๆของระบบพีเอฟซี.....	54
บทที่ 4 ทฤษฎีและการทำงานของแพร์ไวส์อัลกอริทึม.....	57
4.1 ทฤษฎีของแพร์ไวส์อัลกอริทึม.....	57
4.2 การทำงานของแพร์ไวส์อัลกอริทึม.....	58
4.3 ประสิทธิภาพของแพร์ไวส์อัลกอริทึม.....	62
4.4 วิเคราะห์ประสิทธิภาพของแพร์ไวส์อัลกอริทึม.....	67

บทที่ 5	การทดลองและวิเคราะห์หาประสิทธิภาพของแพร์ไวส์อัลกอริทึมแบบใช้ทรสโฮล 2 ระดับ.....	70
5.1	ทฤษฎีของแพร์ไวส์อัลกอริทึมแบบใช้ทรสโฮล 2 ระดับ.....	70
5.2	การวัดประสิทธิภาพของแพร์ไวส์อัลกอริทึมแบบใช้ทรสโฮล 2 ระดับ.....	75
5.3	เปรียบเทียบประสิทธิภาพของแพร์ไวส์อัลกอริทึมแบบใช้ทรสโฮล 2 ระดับ กับแพร์ไวส์อัลกอริทึมแบบเดิม.....	76
5.4	การปรับปรุงแพร์ไวส์อัลกอริทึมแบบใช้ทรสโฮล 2 ระดับ.....	84
บทที่ 6	บทสรุปและวิจารณ์ผลการทดลอง.....	100
6.1	สรุปและวิเคราะห์ผลการทดลอง	100
6.2	ทรัพยากรที่ใช้ในการทำงานของแพร์ไวส์อัลกอริทึมแบบใช้ทรสโฮล 2 ระดับ ...	101
6.3	การเลือกใช้ทรสโฮลในส่วนการทำงานแต่ละส่วน	103
6.4	ข้อเสนอแนะ	104
6.5	การนำแพร์ไวส์อัลกอริทึมแบบใช้ 2 ทรสโฮลไปใช้งานจริง	104
	เอกสารอ้างอิง.....	106
	ภาคผนวก ก	107
	ภาคผนวก ข	108
	ประวัติผู้เขียน.....	116

สารบัญรูป

รูปที่	หน้า
2.1 แสดงลักษณะทำงานของโปรโตคอลของมนุษย์เมื่อเปรียบเทียบกับโปรโตคอลบนคอมพิวเตอร์	4
2.2 แสดงลำดับชั้นต่างๆของอินเทอร์เน็ตโปรโตคอล	5
2.3 แสดงกระบวนการร้องขอและการส่งกลับของเว็บเพจระหว่างเว็บไคลเอนต์และเว็บเซิร์ฟเวอร์	11
2.4 ลักษณะทั่วไปของข้อมูลการร้องขอแบบ HTTP (HTTP Request Message)	14
2.5 โครงสร้างของ HTTP Request Message	15
2.6 ลักษณะทั่วไปของการตอบกลับแบบ HTTP HTTP Response Message	16
2.7 โครงสร้างของข้อมูลการตอบกลับแบบ HTTP (HTTP response message)	17
2.8 ตัวอย่างของข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) ทั่วไป	20
2.9 ตัวอย่างของข้อมูลการตอบกลับแบบ HTTP (HTTP Response Message) ทั่วไป	21
2.10 ข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) ที่มีการใช้ CONDITIONAL GET	21
2.11 ข้อมูลการตอบกลับแบบ HTTP (HTTP Response Message) ที่มีตอบกลับด้วย CONDITIONAL GET	22
2.12 โครงสร้างในการเข้าถึงเว็บเพจในเวิร์ลด์ไวด์เว็บ	23
2.13 ตัวอย่างที่พรีอ็อกซ์มีการทำงานเป็นประตูสู่เครือข่ายภายนอก (Gateway) ไปยัง FTP, HTTP และ Mail	30
2.14 ขั้นตอนที่เกิดขึ้นในกระบวนการร้องขอและตอบกลับแบบ HTTP ที่มีการใช้งาน เว็บพรีอ็อกซ์	31
2.15 แสดงรูปแบบการทำงานอย่างง่ายๆ เป็นลำดับของพรีอ็อกซ์	34
2.16 แสดงตัวอย่างของการส่งตัวแปร (Parameter) ผ่านแท็ก <FORM> ในเว็บเพจ	40
2.17 รูปแบบการ Hosting แบบต่างๆ	45
3.1 แสดงตัวอย่างของล็อกไฟล์	52
4.1 รูปแบบการทำนายของแพร์ไวส์อัลกอริทึม	57
4.2 ขั้นตอนอ่านและประมวลผลเรคคอร์ดในล็อกไฟล์	59
4.3 สรุปลักษณะของแพร์ไวส์อัลกอริทึม	59
4.4 ขั้นตอนการนับของแพร์ไวส์อัลกอริทึม	61

สารบัญรูป(ต่อ)

รูปที่	หน้า
4.5	ขั้นตอนการหาความน่าจะเป็นของการขึ้นต่อกันของแพร์ไวส์อัลกอริทึม60
4.6	ขั้นตอนการสร้างอินโวลลุ่มของแพร์ไวส์อัลกอริทึม61
4.7	อัตราanomัลไลซ์รีคอลของแพร์ไวส์อัลกอริทึมเมื่อมีการใช้ P_i จาก 0.1 – 1 และใช้ $t=0, T=30$64
4.8	อัตราanomัลไลซ์พีริซิชั่นของแพร์ไวส์อัลกอริทึมเมื่อมีการใช้ P_i จาก 0.1 – 1 และใช้ $t=0, T=30$65
4.9	ขนาดเฉลี่ยของอินของแพร์ไวส์อัลกอริทึมเมื่อมีการใช้ P_i จาก 0.1 – 1 และใช้ $t=0, T=30$66
4.10	อัตราanomัลไลซ์รีคอลของแพร์ไวส์อัลกอริทึมเมื่อมีการใช้ P_i จาก 0.1 – 1 และใช้ $t=0, T=30$ ของผู้ใช้ที่มีการร้องขอ 3 อันดับแรก68
4.11	อัตราพีริซิชั่นของแพร์ไวส์อัลกอริทึมเมื่อมีการใช้ P_i จาก 0.1 – 1 และใช้ $t=0, T=30$ ของผู้ใช้ที่มีการร้องขอ 3 อันดับแรก69
5.1	ขั้นตอนทั้งหมดของแพร์ไวส์อัลกอริทึมแบบใช้ 2 เทรสโสล71
5.2	การรวมอินของแพร์ไวส์อัลกอริทึมแบบใช้ 2 เทรสโสล72
5.3	แสดงอัตราanomัลไลซ์รีคอลที่ได้จากแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 203.107.128.24977
5.4	แสดงอัตราanomัลไลซ์รีคอลที่ได้จากแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 203.148.232.25477
5.5	แสดงอัตราanomัลไลซ์รีคอลที่ได้จากแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 202.44.10.8078
5.6	แสดงอัตราanomัลไลซ์พีริซิชั่นจากแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 203.107.128.24979
5.7	แสดงอัตราanomัลไลซ์พีริซิชั่นที่ได้จากแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 202.28.22.25479
5.8	แสดงอัตราanomัลไลซ์พีริซิชั่นที่ได้จากแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 202.44.10.8080
5.9	แสดงขนาดอินเฉลี่ยจากแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 203.107.128.24981

สารบัญรูป(ต่อ)

รูปที่	หน้า
5.10 แสดงขนาดอินพุตจากแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 202.28.22.254	81
5.11 แสดงขนาดอินพุตจากแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 202.44.10.80	82
5.12 แสดงอัตราอัมพลไลซ์รีคอลลีของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสล ของผู้ใช้ทั้งหมด	82
5.13 แสดงอัตราอัมพลไลซ์พรีซิชั่นรีคอลลีของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสล ของผู้ใช้ทั้งหมด	83
5.14 แสดงอัตราขนาดของอินพุตของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสล ของผู้ใช้ทั้งหมด	83
5.15 แสดงอัตราอัมพลไลซ์รีคอลลีของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการ ทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 0.1$	85
5.16 แสดงอัตราอัมพลไลซ์รีคอลลีของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการ ทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 0.4$	85
5.17 แสดงอัตราอัมพลไลซ์รีคอลลีของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการ ทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 0.7$	86
5.18 แสดงอัตราอัมพลไลซ์รีคอลลีของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการ ทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 1.0$	86

สารบัญญรูป(ต่อ)

รูปที่	หน้า
5.25	แสดงขนาดชิ้นเฉลี่ยของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้งและมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 0.7$90
5.26	แสดงขนาดชิ้นเฉลี่ยของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้งและมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 1.0$90
5.27	แสดงกระจายตัวของจำนวนครั้งของการร้องขอที่มาจากไคลเอนท์ของลือกไฟล์ฝั่งเซิร์ฟเวอร์.....91
5.28	แสดงอัตราณอัมลไลซ์รีคอลลของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้งและมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 0.1$92
5.29	แสดงอัตราณอัมลไลซ์รีคอลลของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้งและมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 0.4$92
5.30	แสดงอัตราณอัมลไลซ์รีคอลลของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้งและมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 0.7$93
5.31	แสดงอัตราณอัมลไลซ์รีคอลลของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้งและมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 1.0$93

สารบัญรูป(ต่อ)

รูปที่	หน้า
5.38	แสดงขนาดอินทรีย์ของแพรวัวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้งและมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 0.7$97
5.39	แสดงขนาดอินทรีย์ของแพรวัวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้งและมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 1.0$97
5.40	แสดงกระจายตัวของจำนวนครั้งของการร้องขอที่มาจากไคลเอนท์.....98
6.1	แสดงเวลาการทำงานที่ใช้ของแพรวัวส์อัลกอริทึม, แพรวัวส์อัลกอริทึมแบบใช้เทรสโสล 2 ระดับและแพรวัวส์อัลกอริทึมแบบใช้เทรสโสล 2 ระดับที่ได้รับการปรับปรุงของข้อมูลที่ได้จากทางด้านเซิร์ฟเวอร์102
6.2	แสดงเวลาการทำงานที่ใช้ของแพรวัวส์อัลกอริทึม, แพรวัวส์อัลกอริทึมแบบใช้เทรสโสล 2 ระดับและแพรวัวส์อัลกอริทึมแบบใช้เทรสโสล 2 ระดับที่ได้รับการปรับปรุงของข้อมูลที่ได้จากทางด้านไคลเอนต์102

สารบัญตาราง

ตารางที่	หน้า
2.1 แสดง MIME Type ต่างๆ	25
3.1 แสดงข้อมูลทั่วไปของที่มีอยู่ในล็อกไฟล์	51
3.2 แสดงข้อมูลเพิ่มเติมที่อาจมีในล็อกไฟล์	53
4.1 ตัวอย่างของแพร์ไวส์อัลกอริทึม	61
5.1 ตัวอย่างของแพร์ไวส์อัลกอริทึมที่มีการใช้เทรสโสด 2 ระดับ	73

บทที่ 1

บทนำ

1.1 ที่มาเหตุจูงใจในการทำวิจัย

ความแพร่หลายของอินเทอร์เน็ตและเว็ลด์ไวด์เว็บมีการเติบโตอย่างมาก เว็ลด์ไวด์เว็บเป็นแหล่งข้อมูลขนาดมหาศาล ผู้คนสามารถหาข้อมูลได้เกือบทุกประเภทบนเว็ลด์ไวด์เว็บไม่ว่าจะเป็นข้อมูลทางด้านการศึกษา การสื่อสาร ข้อมูลส่วนตัว ข้อมูลข่าว ฯลฯ มีเว็บไซต์หลายร้อยเว็บไซต์เกิดขึ้นทุกวัน เว็บไซต์ชื่อดังต่างๆ สามารถดึงดูดให้มีผู้คนเข้ามาดูได้เป็นจำนวนมาก ซึ่งมีผลทำให้เกิดปริมาณข้อมูลที่อยู่บนเครือข่ายอินเทอร์เน็ตมีปริมาณที่สูงมากอีกทั้งจำนวนผู้ใช้เครือข่ายอินเทอร์เน็ตก็เพิ่มสูงขึ้นกว่าเมื่อก่อน ด้วยปัจจัยข้างต้นที่ได้กล่าวมาแล้ว เป็นผลให้การเข้าถึงเว็บไซต์ต่างๆ ในปัจจุบันใช้เวลานานขึ้นกว่าเดิม แม้จะมีการพัฒนาและเพิ่มประสิทธิภาพของอินเทอร์เน็ตให้ดีขึ้น ไม่ว่าจะเป็นการเพิ่มความเร็วของเครือข่าย การเพิ่มประสิทธิภาพของเซิร์ฟเวอร์ ผู้ให้บริการ แต่ก็ยังไม่เพียงพอกับการเติบโตที่รวดเร็วของเว็ลด์ไวด์เว็บ

1.2 อธิบายถึงปัญหาที่กำลังศึกษาและวิจัย

แพร่ไวรัสอัลกอริทึมเป็นหนึ่งในวิธีการเฟิร์มแวร์ซึ่งที่ใช้ในการช่วยลดเวลาในการเข้าถึงเว็บไซต์หรือรีซอร์สต่างๆ บนเครือข่ายอินเทอร์เน็ต โดยจะอาศัยข้อมูลในการเข้าถึงของผู้ใช้ในอดีตเพื่อทำนายเว็บไซต์หรือรีซอร์สถัดไปในช่วงเวลาหนึ่งจากเว็บไซต์หรือรีซอร์สปัจจุบันที่ผู้ใช้เข้าถึงอยู่ ซึ่งวิธีการแพร่ไวรัสอัลกอริทึมนี้จะมีอัตราความถูกต้อง (precision) และอัตราการนำอันกลับมาใช้ (recall) ยังไม่ดีเท่าที่ควร ซึ่งทำให้เกิดการเสียประโยชน์และช่องสัญญาณในการเฟิร์มแวร์ซึ่งวิทยานิพนธ์ฉบับนี้จึงได้ทำการวิเคราะห์วิธีการแพร่ไวรัสอัลกอริทึมที่มีการใช้งานอยู่ และนำเสนอเทคนิคเพิ่มเติมที่นำไปใช้ในการช่วยทำให้วิธีการแพร่ไวรัสอัลกอริทึมมีความถูกต้องและมีประสิทธิภาพเพิ่มมากขึ้น ซึ่งได้ทำการวิเคราะห์และผลลัพธ์ที่แสดงถึงความถูกต้องและประสิทธิภาพที่เพิ่มขึ้นเมื่อเปรียบเทียบกับวิธีการแพร่ไวรัสอัลกอริทึมเดิมกับวิธีการแพร่ไวรัสอัลกอริทึมที่ถูกปรับปรุงด้วยการนำเอาเทคนิคที่วิทยานิพนธ์นี้เสนอ

1.3 ทำไมปัญหานี้ถึงน่าสนใจ

เมื่อไม่กี่ปีที่ผ่านมาได้มีการนำเสนอวิธีการหลายวิธีในการช่วยลดเวลาในการเข้าถึงเว็บไซต์หรือรีซอร์สต่างๆ บนเครือข่ายอินเทอร์เน็ต เช่น พร็อกซี-แคช (proxy-cache) ที่มีการเก็บเอาเว็บไซต์หรือรีซอร์สที่ผู้ใช้คนหนึ่งเคยดูแล้วไว้เมื่อผู้ใช้คนอื่นต้องการเข้าถึงหรือดูเว็บไซต์เดียวกันนี้ก็สามารถนำจาก พร็อกซี-แคชได้โดยไม่ต้องมีการดึงจากเซิร์ฟเวอร์ต้นทางใหม่ วัตต์เน็ช(What-

next) ที่มีการใช้เอ็นแกรม (n-gram) อัลกอริทึมในการทำนายหาเว็บเพจหรือริชอร์สที่ผู้ใช้ต้องการเข้าถึงล่วงหน้า 프리เฟรชซิง (Pre-fetching) จะทำการทำนายและดึงเอาเว็บเพจหรือริชอร์สที่ผู้ใช้จะเข้าถึงในอนาคตมาเก็บไว้ที่ฟร็อกซ์หรือแคชก่อนเพื่อที่เมื่อผู้ใช้ต้องการเข้าถึงเว็บเพจหรือริชอร์สนั้นก็สามารถเอาจากฟร็อกซ์หรือแคชได้เลย

สำหรับเทคนิคการฟรีเฟรชซิง (Pre-fetching) ได้มีการนำเสนอวิธีการปรับปรุงให้มีประสิทธิภาพมากขึ้น เช่นการนำเอาโครงข่ายประสาทเทียม (neural net) ที่จะใช้การทำงานแบบ context-specific แทนการใช้ url-specific ในการทำนายเว็บเพจหรือริชอร์สที่จะถูกเข้าถึง Dns-Tcp connection prefetching ที่มีการเพิ่มกระบวนการ pre-resolving, pre-connecting และ pre-warming http ที่จะช่วยลดเวลาของฟรีเฟรชซิง การทำงานร่วมกันของ coherence-prefetching ที่จะใช้การทำงานร่วมกันระหว่าง cache coherence และ pre-fetching ในการปรับปรุงประสิทธิภาพของ pre-fetching และการควบคุมการฟรีเฟรชซิงที่มีการเพิ่มกลไกในการควบคุมการฟรีเฟรชซิง

1.4 มีการนำเสนอหลักการใหม่อย่างไร

เทคนิคที่นำมาใช้ในวิทยานิพนธ์นี้คือ วิธีการแพร่ไวรัสอัลกอริทึมแบบใช้เทรสโธล 2 ระดับ (Two-Level Thesholds Pairwise Algorithmh) ที่จะนำไปใช้ปรับปรุงประสิทธิภาพของแพร่ไวรัสอัลกอริทึม โดยในแพร่ไวรัสอัลกอริทึมจะมีการนำข้อมูลการเข้าถึงเว็บเพจหรือริชอร์สต่างในอดีตของผู้ใช้ทั้งหมดนำมาใช้เป็นฮินท์ (Hint) ที่ใช้บอกเว็บเพจหรือริชอร์สใดที่จะถูกเข้าถึงในอนาคต แต่วิธีการแพร่ไวรัสอัลกอริทึมแบบใช้เทรสโธล 2 ระดับจะเพิ่มเติมจากแพร่ไวรัสอัลกอริทึม โดยจะเพิ่มการเก็บข้อมูลการเข้าถึงเว็บเพจหรือริชอร์สต่างๆ ของผู้ใช้เป็นคณๆ ไป จากนั้นจะนำข้อมูลการเข้าถึงเว็บเพจหรือริชอร์สของผู้ใช้ที่เก็บเป็นคณๆ นั้นนำมาสร้างเป็นฮินท์ที่เหมาะสมกับผู้ใช้แต่ละคน และก็จะนำฮินท์ได้จากแพร่ไวรัสอัลกอริทึมเดิมมาเพิ่มเข้าไปด้วย ดังนั้นฮินท์ที่ส่งไปให้ผู้ใช้ใช้ในการฟรีเฟรชซิงจากประกอบด้วยฮินท์ที่สร้างจากข้อมูลการเข้าถึงเว็บเพจหรือริชอร์สต่างๆ ในอดีตของผู้ใช้เฉพาะคนนั้นๆ กับฮินท์ที่เกิดจากข้อมูลการเข้าถึงเว็บเพจหรือริชอร์สของผู้ใช้ทั้งหมด ซึ่งผลจากการรวมฮินท์จากสร้างจากข้อมูลทั้งสองแหล่งทำให้ได้ฮินท์ที่มีอัตราความถูกต้อง (precision) และการนำฮินท์กลับมาใช้ (recall) ที่สูงขึ้น

1.5 เปรียบเทียบกับหลักการเดิมที่มีอยู่

ประสิทธิภาพของการฟรีเฟรชซิงนั้นจากวัดในรูปของอัตราความถูกต้อง (precision), อัตราการนำฮินท์กลับมาใช้ใหม่ (recall), ขนาดของฮินท์เฉลี่ย (average hintsize) ซึ่งวิธีการแพร่ไวรัสอัลกอริทึมเดิมเมื่อมีการใช้ค่าพารามิเตอร์เทรสโธลด์ (Probabilities Threshold , p_t) ที่สูงแล้ว อัตราการนำฮินท์กลับมาใช้จะเริ่มลดลงอย่างรวดเร็วในขณะที่อัตราความถูกต้องยังคงเพิ่มขึ้นเล็กน้อย

จนถึงค่าพารามิเตอร์ไฮดรอลิกค่าหนึ่งจากนั้นอัตราความถูกต้องจะเริ่มลดลงในขณะที่อัตราการนำอินกลับมาใช้จะต่ำมาก ซึ่งในวิทยานิพนธ์นี้ที่การนำวิธีการแพร่ไวรัสอัลกอริทึมแบบใช้เทรซไฮล 2 ระดับมาปรับปรุงประสิทธิภาพของแพร่ไวรัสอัลกอริทึม ทำให้ได้อินที่มีประสิทธิภาพมากขึ้น มีอัตราความถูกต้องและอัตราการนำอินกลับมาใช้ที่สูงขึ้นเมื่อเพิ่มค่าพารามิเตอร์ไฮดรอลิก และเมื่อค่าพารามิเตอร์ไฮดรอลิกสูงๆ อัตราความถูกต้องและอัตราการนำอินกลับมาใช้ก็ยังคงอยู่ในระดับสูงอยู่ ในขณะที่ขนาดของอินเฉลี่ยที่สูงขึ้นจากวิธีการแพร่ไวรัสเดิมเล็กน้อย

1.6 รายละเอียดของวิทยานิพนธ์

ในวิทยานิพนธ์นี้ประกอบด้วย 6 บทด้วยกัน กล่าวคือ

บทที่ 1 จะกล่าวถึงเหตุจูงใจในการทำวิจัยนี้ วัตถุประสงค์ของการทำวิจัย ตลอดจนถึงปัญหาที่น่าสนใจที่ศึกษาในวิทยานิพนธ์นี้ ขอบเขตของการทำวิจัย นอกจากนี้ยังเสนอหลักการใหม่เมื่อเปรียบเทียบกับหลักการเดิม

บทที่ 2 จะกล่าวถึงความรู้พื้นฐานของการเข้าถึงเว็บเพจบนเครือข่ายอินเทอร์เน็ต ซึ่งจะอธิบายองค์ประกอบต่างของการเข้าถึงเว็บเพจในปัจจุบัน การทำงานที่จะเกิดขึ้นเมื่อมีการร้องขอหรือเข้าถึงเว็บเพจ

บทที่ 3 จะกล่าวถึงระบบการทำงานของการฟรีเฟรชซึ่ง องค์ประกอบ รูปแบบการทำงานที่มีการใช้หรือวิจัยอยู่ในปัจจุบัน ข้อดีและข้อด้อยของการฟรีเฟรชซึ่ง

บทที่ 4 ในบทนี้จะกล่าวถึงวิธีการแพร่ไวรัสอัลกอริทึมที่เป็นหนึ่งในวิธีการที่ใช้ในการฟรีเฟรชซึ่ง องค์ประกอบและการทำงานของแพร่ไวรัสอัลกอริทึม และจะกล่าวถึงแพร่ไวรัสอัลกอริทึมที่มีการใช้เทรซไฮล 2 ระดับที่เป็นแพร่ไวรัสแบบปรับปรุงให้มีประสิทธิภาพที่ได้ดีกว่าแพร่ไวรัสอัลกอริทึมเดิม

บทที่ 5 จะกล่าวถึงวิธีการทดลองหาประสิทธิภาพของแพร่ไวรัสอัลกอริทึมแบบเดิมและแพร่ไวรัสอัลกอริทึมแบบใช้เทรซไฮล 2 ระดับ และทำการวิเคราะห์ผลการทดลองของวิธีทั้งสอง

บทที่ 6 ในบทนี้จะทำการสรุปผลและวิจารณ์การทดลองที่เกิดขึ้นรวมถึงข้อเสนอแนะและปัญหาที่เกิดขึ้นในการทดลอง

บทที่ 2

ความรู้พื้นฐานของการเข้าถึงเว็บเพจบนเครือข่ายอินเทอร์เน็ต

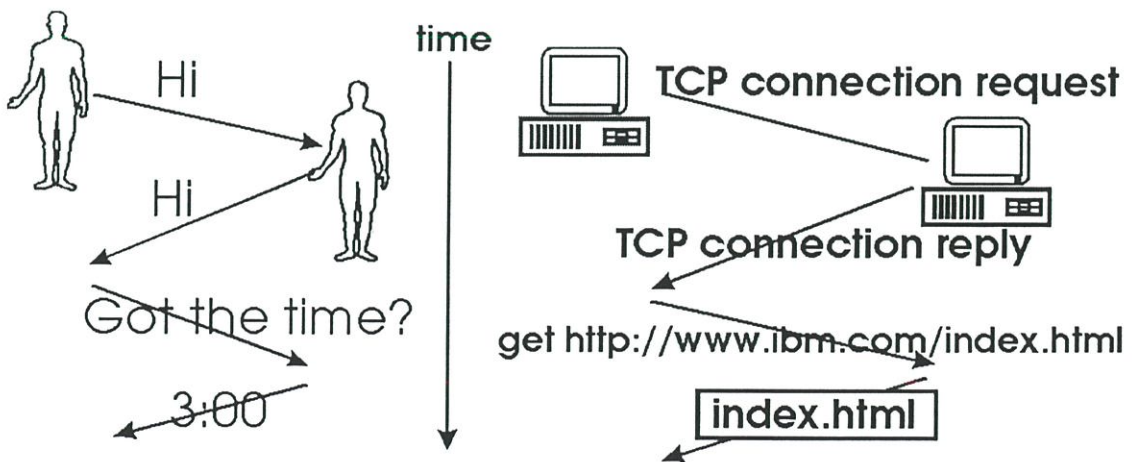
เวิลด์ไวด์เว็บเกิดขึ้นครั้งแรกในปี 1989 โดยการนำเสนอของ ทิม เบอร์เนอร์ลี (Tim Berners-Lee) และต่อมาก็กลายเป็นแหล่งข้อมูลขนาดมหาศาลบนเครือข่ายคอมพิวเตอร์ การทำงานที่มีส่วนการติดต่อกับผู้ใช้งานแบบกราฟฟิกทำให้ผู้ใช้งานสามารถที่จะดูหรือท่องไปตามกลุ่มของเว็บเพจด้วยการคลิกที่ลิงก์ที่อยู่ในเว็บเพจ โดยที่ผู้ใช้ไม่จำเป็นต้องสนใจรูปแบบหรือตำแหน่งของเว็บเพจเลย และในเวิลด์ไวด์เว็บนั้นผู้ใช้งานไม่เพียงแต่จะสามารถดูเว็บเพจได้เท่านั้น ยังสามารถที่จะค้นหาข้อมูล รับและส่งอิเลคทรอนิกส์เมล และสามารถที่จะทำธุรกรรมโดยผ่านทางเวิลด์ไวด์เว็บได้

เวิลด์ไวด์เว็บนั้นทำงานบนเครือข่ายอินเทอร์เน็ต โดยใช้โปรโตคอล HTTP ในการสื่อสารระหว่างเว็บเบราว์เซอร์และเว็บเซิร์ฟเวอร์ และข้อมูลของเว็บเพจนั้นจะอยู่ในรูปของภาษา HTML ที่จะใช้ในการบอกทำให้เว็บเบราว์เซอร์ให้แสดงเว็บเพจอย่างไร ในบทนี้จะอธิบายถึงการทำงานของอินเทอร์เน็ต องค์ประกอบต่างๆ และการทำงานของเวิลด์ไวด์เว็บ และองค์ประกอบต่างๆ ของเวิลด์ไวด์เว็บ

2.1 องค์ประกอบของอินเทอร์เน็ต

2.1.1 โปรโตคอล

โดยเริ่มต้นจากการอธิบายโปรโตคอลของมนุษย์ก่อน โดยพิจารณาจากรูปที่ 2.1



รูปที่ 2.1 แสดงลักษณะทำงานของโปรโตคอลของมนุษย์เมื่อเปรียบเทียบกับโปรโตคอลบนคอมพิวเตอร์

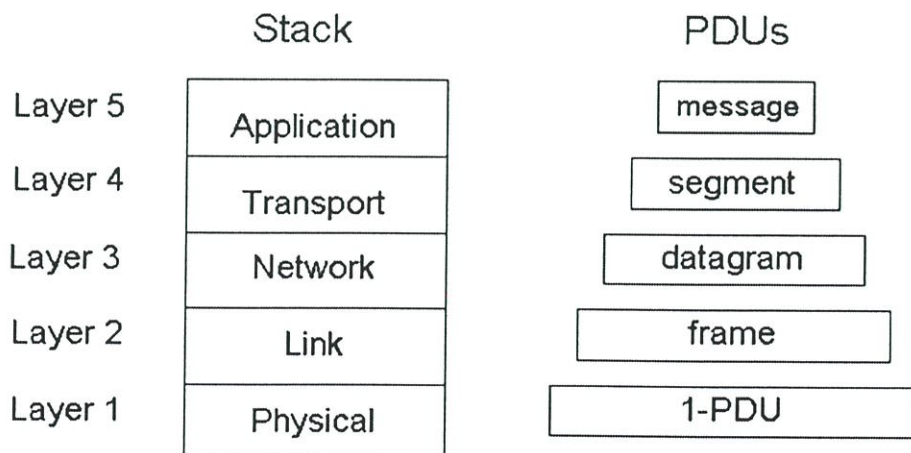
จากรูปที่ 2.1 นั้นเริ่มต้นคนทั่วไปจะเริ่มทักทายด้วยการ “สวัสดี” จากนั้นคนที่สองก็จาก “สวัสดี” ตอบ การตอบของคนที่สองเป็นการบอกเป็นนัยว่าคนที่สองนั้นได้รับรู้การ “สวัสดี” ของคนแรกแล้ว จากนั้นคนแรกก็ถามว่า “ตอนนี้เวลาอะไร” ไปยังคนที่สอง คนที่สองก็ตอบกลับไปที่ว่า “ตอนนี้เวลา 15.00” ซึ่งในความเป็นจริงนั้นคนที่สองอาจจะไม่ตอบอะไรเลยก็ได้ หรืออาจจะตอบอย่างอื่นกลับมาก็ได้ ดังนั้นสำหรับโปรโตคอลของมนุษย์นั้นคือ “ข้อความบางอย่างใดอย่างหนึ่งที่มีการส่งเมื่อเกิดกระทำอย่างใดอย่างหนึ่งเกิดขึ้น และการตอบรับอย่างใดอย่างหนึ่งที่รองรับข้อความหรือการกระทำที่มีการส่งมา”

และสำหรับโปรโตคอลของระบบเครือข่ายนั้นจะคล้ายกับ โปรโตคอลของมนุษย์ยกเว้นเพียงข้อความที่แลกเปลี่ยนกันนั้นจะถูกทำโดยฮาร์ดแวร์หรือซอฟต์แวร์แทน การติดต่อสื่อสารต่างๆอาจจะเกี่ยวข้องกับสองส่วนประกอบของระบบเครือข่ายหรือมากกว่านั้นก็ได้ ดังนั้นนิยามของโปรโตคอลของระบบเครือข่ายคือ

“รูปแบบและลำดับของข้อความหรือการกระทำที่มีการแลกเปลี่ยนระหว่างสองหรือมากกว่าส่วนประกอบที่มีการติดต่อกัน”

2.1.2 อินเทอร์เน็ตโปรโตคอล

อินเทอร์เน็ตโปรโตคอลประกอบด้วย 5 เลเยอร์ (layers) นั่นคือ ฟิสิกส์คอลเลเยอร์, เดต้าลิงก์เลเยอร์, เน็ตเวิร์คเลเยอร์, ทรานสปอร์ตเลเยอร์, แอปพลิเคชันเลเยอร์ การแลกเปลี่ยนข้อมูลระหว่างเลเยอร์จะอยู่ในรูปของ PDU-n โดยจะมีชื่อเรียกเฉพาะสำหรับ 4 เลเยอร์บน นั่นคือ Frame, Datagram, Segment, Message สำหรับในส่วนของฟิสิกส์คอลเลเยอร์นั้นจะไม่มีชื่อเรียกเฉพาะ เพราะข้อมูลจะถูกส่งไปเป็นบิตๆ(bit) ลักษณะของข้อมูลในชั้นเลเยอร์ต่างเป็นดังรูปที่ 2.2



รูปที่ 2.2 แสดงลำดับชั้นต่างๆของอินเทอร์เน็ตโปรโตคอล

โปรโตคอลเลเยอร์ต่างๆ จะถูกใส่เข้าไปให้ทำงานที่ทั้งซอฟต์แวร์, ฮาร์ดแวร์ หรือทำงานในส่วนทั้งฮาร์ดแวร์และซอฟต์แวร์ก็ได้ ตัวอย่างแอปพลิเคชันเลเยอร์เช่น HTTP ซึ่งจะทำงานในซอฟต์แวร์ที่เครื่องคอมพิวเตอร์ที่เรียกว่าเว็บไคลเอนต์ (Web Client) หรือเครื่องเซิร์ฟเวอร์ต่างๆที่เรียกว่าเว็บเซิร์ฟเวอร์ และเช่นเดียวกับทรานสปอร์ตเลเยอร์ แต่สำหรับเคต่าลิงก์เลเยอร์และฟิสิกส์คอลเลเยอร์นั้นใช้ในการติดต่อสื่อสารระหว่างลิงก์ใดๆ โดยทั้งสองเลเยอร์นั้นจะถูกใส่เข้าไปทำงานในเน็ตเวิร์กการ์ดเลย สำหรับเน็ตเวิร์กเลเยอร์จะทำงานในส่วนร่วมกันระหว่างซอฟต์แวร์และฮาร์ดแวร์

สำหรับหน้าที่ต่างๆของเลเยอร์แต่ละเลเยอร์ของอินเทอร์เน็ตโปรโตคอลนั้นสามารถสรุปได้ดังนี้

- แอปพลิเคชันเลเยอร์ (Application Layer) : มีหน้าที่ในการให้การสนับสนุนเน็ตเวิร์กแอปพลิเคชันต่างๆ โดยแอปพลิเคชันเลเยอร์นั้นจะรวมทั้งโปรโตคอลต่างๆเช่น HTTP ที่มีหน้าที่ในการเข้าถึงเว็บเพจ SMTP ที่มีหน้าที่ในการส่งอีเมลล์ และ FTP ที่มีหน้าที่ในการรับส่งไฟล์ต่างๆ
- ทรานสปอร์ตเลเยอร์ (Transport Layer) : มีหน้าที่ในการส่งข้อมูลจากแอปพลิเคชันเลเยอร์หรือแอสเสจ (Message) จากแอปพลิเคชันเลเยอร์ระหว่างแอปพลิเคชันของเครื่องไคลเอนต์และแอปพลิเคชันของเซิร์ฟเวอร์ ในอินเทอร์เน็ตนั้นจะมี 2 ทรานสปอร์ตโปรโตคอลนั่นก็คือ TCP และ UDP โดย TCP จะให้บริการแบบรับการประกันการถึงข้อมูล (Connection-Oriented) และ TCP จะทำการแบ่งข้อมูลจากแอปพลิเคชันเลเยอร์ (Message) ออกเป็นเซกเมนต์ (Segment) ย่อยๆ ก่อนที่จะส่งข้อมูล สำหรับ UDP จะเป็นโปรโตคอลแบบไม่รับประกันการถึงของข้อมูล (Connectionless) ซึ่งจะกล่าวในรายละเอียดต่อไป การทำงานของทรานสปอร์ตเลเยอร์มีส่วนสำคัญอย่างมากในการควบคุมการส่งข้อมูลให้ถึงเป้าหมายไม่ให้เกิดความผิดพลาด ไม่ให้มีการส่งข้อมูลที่ส่งไปแล้วซ้ำ
- เน็ตเวิร์กเลเยอร์ (Network Layer) : มีหน้าที่ในการค้นหาเส้นทางที่จะใช้ในการส่งข้อมูลของทรานสปอร์ตเลเยอร์หรือเคต่าแกรม (Datagram) จากเครื่องโฮสต์หรือคอมพิวเตอร์เครื่องหนึ่งไปยังเครื่องโฮสต์อีกเครื่องหนึ่ง โดยส่วนประกอบหลักๆของเน็ตเวิร์กเลเยอร์มี 2 ส่วนคือ ส่วนแรกเป็นส่วนในการนิยามฟิลด์ต่างในเคต่าแกรม (Datagram) ที่จะใช้ในการจำแนกเครื่องคอมพิวเตอร์เครื่องต่างๆในเครือข่ายอินเทอร์เน็ต และส่วนที่สองคือส่วนที่จะใช้ในการค้นและรักษาข้อมูลที่จะใช้ในการพิจารณาว่าจะส่งข้อมูลไปทางใดเพื่อให้ถึงปลายทาง ซึ่งส่วนประกอบทั้งสองจะอยู่ในโปรโตคอลที่ใช้ในชั้นเน็ตเวิร์กเลเยอร์นั่นก็คือ ไอพี(IP) โปรโตคอล ในอินเทอร์เน็ตนั้นเครื่องทุกเครื่องและอุปกรณ์ทุกชนิดต่างต้องมีการทำงานของไอพีโปรโตคอลเพื่อให้ติดต่อสื่อสารได้
- เคต่าลิงก์เลเยอร์ (Datalink Layer) : สำหรับเน็ตเวิร์กเลเยอร์นั้นจะใช้ในการส่งข้อมูลไปตามเส้นทางที่จะประกอบอุปกรณ์ต่างๆในอินเทอร์เน็ตระหว่างเครื่องต้นทางและเครื่อง

ปลายทาง ซึ่งในการเคลื่อนย้ายหรือส่งข้อมูลในเครือข่ายอินเทอร์เน็ตนั้นจะต้องส่งข้อมูลไปเป็นฮอป (Hop) หรือเป็นลิงก์ไป ในแต่ละฮอป (hop) นั้นก็คือเครื่องคอมพิวเตอร์หรืออุปกรณ์เน็ตเวิร์คที่อยู่ระหว่างเครื่องต้นทางและเครื่องปลายทาง โดยระหว่างเครื่องต้นทางและเครื่องปลายทางนั้นก็จะประกอบด้วยหลายๆ ฮอปหรือหลายๆลิงก์ ซึ่งเดต้าลิงก์เลเยอร์จะทำหน้าที่ในส่วนนี้ โดยเครื่องคอมพิวเตอร์หรืออุปกรณ์เน็ตเวิร์คในแต่ละฮอปจะส่งเดต้าแกรมไปยังเดต้าลิงก์เลเยอร์ของเครื่องคอมพิวเตอร์หรืออุปกรณ์เน็ตเวิร์คนั้น จากนั้นเดต้าลิงก์เลเยอร์จะทำการเพิ่มส่วนหัว (Header) และส่วนหาง (Trailer) เข้าไปในเดต้าแกรมที่มาจากเน็ตเวิร์กเลเยอร์ซึ่งจะเรียกข้อมูลในส่วนนี้ว่าเป็นเฟรม (Frame) ก่อนส่งให้ฟิสิกส์คอลเลเยอร์ต่อไป

- ฟิสิกส์คอลเลเยอร์ (Physical Layer) : มีหน้าที่ในการส่งข้อมูลที่เป็นบิตๆจากเฟรมของข้อมูลที่ถูกส่งมาจากเดต้าลิงก์เลเยอร์จากฮอป (hop) หนึ่งไปยังอีกฮอปหนึ่ง โดยสำหรับการทำงานของเลเยอร์นี้จะต้องเกี่ยวข้องกับสื่อหรือสายสัญญาณที่ใช้ด้วยเช่นถ้าใช้สายสัญญาณเป็นสายสัญญาณแบบเส้นใยแก้วนำแสง (Fiber Optic) ก็ต้องมีการแปลงข้อมูลที่เป็นบิตๆให้อยู่ในรูปของแสงก่อนจะส่งไปยังสายใยแก้วนำแสงนั้น

2.1.3 อินเทอร์เน็ต

ถ้าจะนิยามอินเทอร์เน็ต[5] นั้นก็สามารถนิยามได้ว่าเป็นระบบเครือข่ายของระบบเครือข่าย นั่นคืออินเทอร์เน็ตเป็นการเชื่อมต่อกันของระบบเครือข่ายต่างๆทั่วโลก ที่ประกอบด้วยเครือข่ายแบบปิดและเครือข่ายแบบเปิด ซึ่งทุกๆระบบเครือข่ายที่เชื่อมต่อกับอินเทอร์เน็ตจะต้องมีการทำงานบนโปรโตคอลไอพี

อินเทอร์เน็ตเกิดขึ้นมาเมื่อ 20 ปีก่อน ด้วยความพยายามของกองทัพสหรัฐอเมริกา (Department of defense) ในงานวิจัยทางการทหารเพื่อต่อต้านศัตรู โดยได้ทำการทดลองเครือข่ายคอมพิวเตอร์ซึ่งเรียกว่าอาร์ปาเน็ต (ARPAnet) เป็นการออกแบบตามความต้องการในขั้นต้น ที่จะใช้ในการรับส่งข้อความระหว่างเครื่องคอมพิวเตอร์ โดยใช้ไอพี (IP) โปรโตคอล

จากอดีตที่คิดว่าไม่น่าจะเป็นไปได้แต่ก็ได้พิสูจน์แล้วว่าเป็นความจริง จากการติดต่อสื่อสารในการรับส่งข้อความระหว่างเครื่องคอมพิวเตอร์หนึ่งกับเครื่องคอมพิวเตอร์หนึ่ง กลายเป็นเครื่องคอมพิวเตอร์หนึ่งกับเครื่องคอมพิวเตอร์อื่นอีกหลายๆเครื่องได้ อินเทอร์เน็ตได้ถูกพัฒนาขึ้นในสหรัฐอเมริกา อังกฤษ และสแกนดิเนเวีย ซึ่งภายหลังรัฐบาล, มหาวิทยาลัยและประชาชนทั่วไปได้ให้ความสนใจมากขึ้น มีการผลิตซอฟต์แวร์หรือแอปพลิเคชันเพื่อรองรับการใช้งานบนเครือข่ายอินเทอร์เน็ตแตกต่างกันไป และทุกคนสามารถหาซื้อเครื่องคอมพิวเตอร์ที่สามารถสื่อสารกับเครื่องคอมพิวเตอร์อื่นบนเครือข่ายได้ตามความต้องการ

ในขณะเดียวกัน ประมาณพ.ศ.2526 ระบบเครือข่ายแบบท้องถิ่น (Local Area Network:LAN) ได้ถูกพัฒนาขึ้นอย่างรวดเร็วซึ่งสามารถใช้ได้บนเครื่องคอมพิวเตอร์เวิร์คสเตชันซึ่งนิยมใช้ระบบยูนิกซ์(Unix) ของ Berkeley ซึ่งในยูนิกซ์นี้ได้รวมโปรแกรมในส่วนการทำงานของไอพีที่มีรูปแบบการใช้งานใกล้เคียงกับระบบยูนิกซ์หน่วยงานอื่นๆ ทำให้สามารถทำงานร่วมกันได้ จึงได้มีการเริ่มสร้างระบบเครือข่ายของตนเองโดยเชื่อว่าถ้าติดต่อภายในระบบของตนเองได้ ก็ย่อมสามารถติดต่อกับเครือข่ายอื่นๆ ที่นอกเหนือภายในระบบตนเองได้เช่นกัน ระบบเครือข่ายที่สำคัญอีกเครือข่ายหนึ่งคือ NSFnet หรือมูลนิธิวิทยาศาสตร์แห่งชาติของสหรัฐอเมริกา (National Science Foundation) NSF ได้จัดตั้งศูนย์ซูเปอร์คอมพิวเตอร์ (Supercomputer) 5 แห่งเพื่อสนับสนุนงานวิจัย ครั้งแรก NSF ได้พยายามที่จะใช้อาร์ปาเน็ต (ARPAnet) ในการติดต่อสื่อสารซึ่งกันและกัน แต่ไม่ประสบความสำเร็จเพราะเป็นการทำงานของระบบราชการ ดังนั้น NSF จึงตัดสินใจสร้างระบบเครือข่ายของตนเองบนพื้นฐานของเครือข่ายอาร์ปาเน็ตที่ใช้โปรโตคอลทีซีพี-ไอพีซึ่งสามารถติดต่อศูนย์ต่างๆ ได้ด้วยความเร็ว 56 กิโลบิต/วินาที (56 Kbps) และได้พัฒนาโดยการขยายเครือข่ายออกสู่ภูมิภาคของประเทศ ในปี พ.ศ.2530 NSF ได้พัฒนาระบบเพื่อรองรับการใช้งานที่เพิ่มขึ้นความหวังที่สำคัญของการพัฒนาเครือข่าย NSF ก็คือเพื่อให้ทุกคนได้ใช้ระบบเครือข่ายได้ในระดับหนึ่งไม่จำกัดเฉพาะหน่วยงานของรัฐบาล หรือนักวิจัยของสถาบันเท่านั้น NSF ยังได้พัฒนาและสนับสนุนทางด้านการศึกษาโดยการให้ทุนแก่มหาวิทยาลัยในการติดตั้งระบบเครือข่าย เพื่อให้ทุกคนสามารถใช้ได้ทั่วถึงกัน การใช้อินเทอร์เน็ตได้แพร่หลายมากขึ้นเรื่อยๆ มีการพัฒนาปรับปรุงเทคโนโลยีต่างๆ ภายในระบบงานของแต่ละเครือข่ายของหน่วยงานต่างๆ โดยชื่อที่ใช้เรียกเครือข่ายมีการปรับเปลี่ยนไปเรื่อยตั้งแต่ชื่อ อาร์ปาเน็ต (ARPAnet) เป็นเฟเดอรัลรีเสิร์ชอินเทอร์เน็ต (Federal Research Internet) บ้างหรือทีซีพี/ไอพี บ้างจนในที่สุดกลายเป็นที่รู้จักกันในปัจจุบันคือ อินเทอร์เน็ต (Internet)

ลักษณะเครือข่ายของอินเทอร์เน็ตจะอยู่ในรูปลำดับชั้นที่ไม่มีโครงสร้างที่แน่นอน แต่จะอยู่รูปล่างไปข้างบน (Hierarchical) ที่ประกอบด้วยระบบที่เป็นปลายสุด(เครื่องคอมพิวเตอร์ที่ใช้งานตามบ้านหรือระบบเครือข่ายขององค์กรใดๆ) ที่จะเชื่อมต่อไปยังผู้ให้บริการอินเทอร์เน็ตท้องถิ่นจากนั้นผู้ให้บริการท้องถิ่นก็จะเชื่อมต่อไปยังผู้ให้บริการภูมิภาค และผู้ให้บริการส่วนภูมิภาคก็จะเชื่อมต่อไปยังผู้ให้บริการระดับประเทศและผู้ให้บริการระดับประเทศก็จะเชื่อมต่อกันเป็นระบบเครือข่ายขนาดมหึมา

สำหรับรูปแบบของแอปพลิเคชันที่ใช้งานบนเครือข่ายอินเทอร์เน็ตนั้นส่วนใหญ่มักจะมีการทำงานที่เรียกว่า “ไคลเอนต์ – เซิร์ฟเวอร์” โดยไคลเอนต์จะเป็นเครื่องที่ต้องการร้องขอการให้บริการจากเครื่องเซิร์ฟเวอร์ และเครื่องเซิร์ฟเวอร์เป็นเครื่องใช้ในการให้บริการกับเครื่องไคลเอนต์ โดยการทำงานของแอปพลิเคชันบนเครือข่ายอินเทอร์เน็ตจะมีสองแบบคือการทำงานแบบรับประกันการถึง

ของข้อมูล (CONNECTION-ORIENTED) และการทำงานแบบไม่รับประกันการถึงของข้อมูล (CONNECTIONLESS)

2.1.4 รูปแบบการให้บริการของอินเทอร์เน็ต

การให้บริการบนอินเทอร์เน็ตมี 2 แบบคือ

2.1.4.1 การให้บริการแบบรับประกันการถึงของข้อมูล (CONNECTION-ORIENTED)

การให้บริการแบบรับประกันการถึงของข้อมูล (CONNECTION-ORIENTED) นั้นเป็นการติดต่อกับระหว่างเครื่องไคลเอนต์และเครื่องเซิร์ฟเวอร์จะต้องมีการสร้างการเชื่อมต่อระหว่างกันก่อนที่จะมีการส่งข้อมูลระหว่างกัน และอย่างที่กล่าวแล้วว่าอินเทอร์เน็ตจะใช้โปรโตคอลที่ซีพี/ไอพี (TCP/IP) ในการทำงาน ดังนั้นจะเรียกกระบวนการสร้างการเชื่อมต่อก่อนการส่งของข้อมูลนี้ว่า “การตกลงการเชื่อมต่อสามทาง (Three-way Handshake)”

โดยโปรโตคอลที่ซีพี (TCP) ที่เป็นโปรโตคอลในส่วนทรานสปอร์ตโน้เลเยอร์ในการให้บริการแบบรับประกันการถึงของข้อมูล (CONNECTION-ORIENTED) และการให้บริการแบบนี้ยังสามารถให้บริการแบบอื่นเพิ่มเติมได้อีกเช่น

- ความถูกต้องของข้อมูล (Reliable Data Transfer) จะมีการให้บริการที่ทำให้แน่ใจได้ว่าข้อมูลที่มีการส่งระหว่าง ไคลเอนต์และเซิร์ฟเวอร์นั้นจะไม่มีสูญหาย จะใช้กระบวนการที่เรียกว่า Acknowledgment และ Retransmission ในการให้บริการแบบนี้
- การควบคุมการส่งข้อมูล (Flow control) จะมีการให้บริการที่ใช้ในการควบคุมการส่งข้อมูลระหว่างไคลเอนต์และเซิร์ฟเวอร์ให้แต่ละฝั่งสามารถรับข้อมูลได้ทัน ป้องกันไม่ให้ฝั่งหนึ่งส่งข้อมูลเร็วกว่าอีกฝั่งที่จะรับได้ทัน
- การควบคุมความคับคั่งของข้อมูล (Congestion control) จะมีการให้บริการที่ใช้ในการควบคุมไม่ให้ระบบเครือข่ายเกิดความคับคั่งของข้อมูล เพราะเมื่อมีการเกิดความคับคั่งของข้อมูลแล้ว การควบคุมความคับคั่งของข้อมูลจะทำการลดความเร็วในการส่งลงเพื่อไม่ให้ไปเพิ่มความคับคั่งของระบบเครือข่ายอีก

2.1.4.2 การให้บริการแบบไม่รับประกันการถึงของข้อมูล (CONNECTIONLESS)

การให้บริการแบบไม่รับประกันการถึงของข้อมูล (CONNECTIONLESS) นั้นจะไม่มีการสร้างการเชื่อมต่อก่อนที่จะเริ่มส่งข้อมูลระหว่างไคลเอนต์และเซิร์ฟเวอร์ การส่งข้อมูลระหว่างกันนั้นไม่ว่าจะเป็นฝั่งไคลเอนต์หรือฝั่งเซิร์ฟเวอร์จะเพียงเมื่อต้องการจะส่งข้อมูลก็ทำการสร้างแพคเกจ (Message) ที่จะส่งแล้วก็ส่งออกไปเลย จะไม่มีกระบวนการตรวจสอบว่าข้อมูลที่ส่งไปนี้ทางอีกฝั่งได้รับหรือไม่ และไม่มีกระบวนการควบคุมการส่งใดๆเลย

การให้บริการแบบ CONNECTIONLESS นั้นจะใช้โปรโตคอลในชั้นทรานสปอร์ตเนลเลอร์คือ UDP

2.2 องค์ประกอบพื้นฐานของเว็ลด์ไวด์เว็บ

2.2.1 UNIFORM RESOURCE IDENTIFIER (URI)

การเข้าถึงและการจัดการรีซอร์สต่างๆ ที่กระจายอยู่บนเว็ลด์ไวด์เว็บจะต้องมีวิธีการที่ใช้ในการบ่งบอกหรือแสดงตำแหน่งของรีซอร์สนั้นๆ ซึ่งในเว็ลด์ไวด์เว็บจะใช้ UNIFORM RESOURCE IDENTIFIER(URI) [6] ในการบ่งบอกหรือแสดงตำแหน่งของรีซอร์ส โดย URI จะทำงานคล้ายกับตัวชี้ตำแหน่งไปยังรีซอร์สนั้นๆ URI จะประกอบด้วย 3 ส่วน คือ โปรโตคอลที่ใช้ในการติดต่อกับเครื่องเซิร์ฟเวอร์หรือเว็บเซิร์ฟเวอร์, UNIFORM RESOURCE LOCALTOR (URL) คือชื่อของเครื่องเซิร์ฟเวอร์หรือเว็บเซิร์ฟเวอร์หรือตำแหน่งของรีซอร์สและ UNIFORM RESOURCE NAME (URN) คือชื่อของรีซอร์สนั้นๆ เช่น <http://www.foo.com/coolpic.gif> ในตัวอย่างนี้โปรโตคอลที่ใช้ในการติดต่อกับเครื่องแม่ข่าย (http), ชื่อของเครื่องเซิร์ฟเวอร์(www.foo.com), และชื่อของรีซอร์สนั้นๆบนเครื่องแม่ข่าย (coolpic.gif)

2.2.2 HYPERTEXT MARKUP LANGUAGE (HTML)

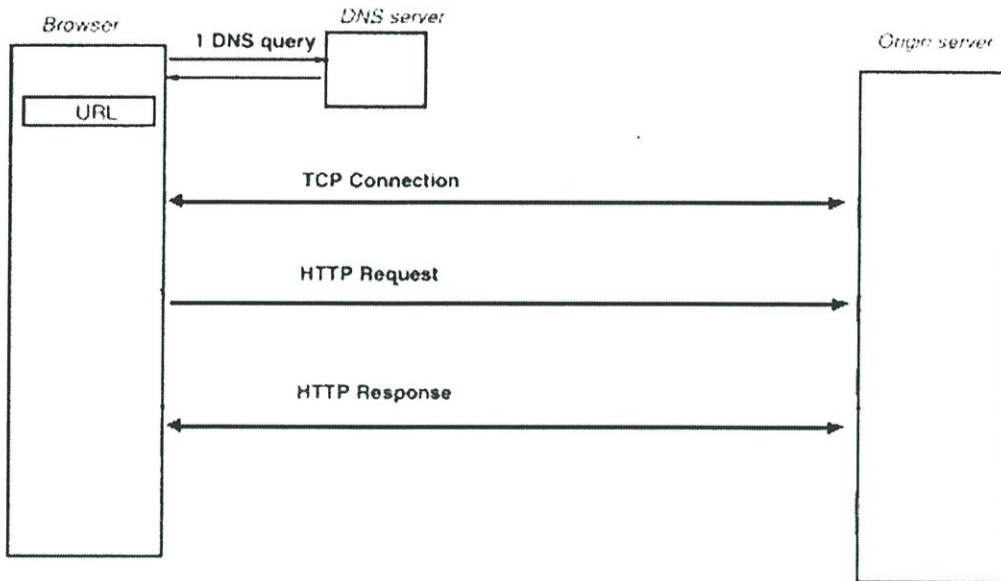
Hypertext Markup Language [7] คือภาษามาตรฐานในการแสดงตัวอักษรหรือรูปแบบของตัวอักษรบนเว็บเพจ ซึ่ง HTML เป็นภาษาที่ได้รับการสืบทอดจาก Standard Generalized Markup Language (SGML) โดย HTML สามารถให้ผู้สร้างเว็บเพจสามารถที่จะจัดรูปแบบของข้อความแสดงรูปภาพ การสร้างลิงก์ต่างๆบนเว็บเพจ โครงสร้างของ HTML เป็นรูปแบบง่ายๆในการทำ ความเข้าใจและการเรียนรู้ ปัจจุบันมีการพัฒนา HTML ไปถึงเวอร์ชันที่ 4 แล้ว

การทำงานของ HTML ก็คือเมื่อผู้ใช้ร้องขอเว็บเพจจากเครื่องเซิร์ฟเวอร์แล้วทางเครื่องเซิร์ฟเวอร์จะส่งเว็บเพจนั้นกลับมาให้ผู้ใช้ โดยเว็บเพจนั้นจะอยู่ในรูปของโครงสร้าง HTML เมื่อเครื่องของผู้ใช้ได้รับแล้วตัวโปรแกรมที่ทำหน้าที่ในการแปลความหมายและแสดงผลเว็บเพจหรือเว็บไคลเอนต์ก็คือ โปรแกรมเว็บเบราว์เซอร์ ก็จะทำงานเพื่อแสดงเว็บเพจนั้นๆออกมาตามโครงสร้าง HTML

2.2.3 HYPERTEXT TRANSFER PROTOCOL (HTTP)

Hypertext Transfer Protocol เป็นโปรโตคอลระดับแอปพลิเคชันเลเยอร์ที่เป็นส่วนสำคัญมากในเครือข่ายเว็ลด์ไวด์เว็บ โดย HTTP จะทำงานเป็น 2 ฝั่งคือฝั่งเครื่องไคลเอนต์และฝั่งเครื่องเซิร์ฟเวอร์ การติดต่อกันระหว่าง 2 ฝั่งจะใช้ HTTP ในการติดต่อสื่อสารกัน

HTTP จะนิยามว่าทางโปรแกรมฝั่งไคลเอนต์นั่นก็คือเว็บไคลเอนต์หรือเว็บเบราว์เซอร์จะร้องขอเว็บเพจจากเครื่องเซิร์ฟเวอร์อย่างไร และทางโปรแกรมฝั่งเครื่องเซิร์ฟเวอร์หรือเว็บเซิร์ฟเวอร์จะส่งเว็บเพจกลับไปอย่างไร การทำงานของการจะเป็นรูปแบบดังรูป



รูปที่ 2.3 แสดงกระบวนการร้องขอและการส่งกลับของเว็บเพจระหว่างเว็บไคลเอนต์และเว็บเซิร์ฟเวอร์

ก่อนอื่นต้องขออธิบายก่อนว่าในเว็บเพจหนึ่งจะประกอบด้วยส่วนประกอบย่อย (objects) เช่นตัวเว็บเพจหรือตัวโครงสร้าง HTML, รูปภาพที่มีในเว็บเพจนั้น หรือส่วนประกอบอื่นๆ ไม่ว่าจะเป็นแฟ้มข้อมูลแบบเสียงที่มีในเว็บเพจ เมื่อผู้ใช้ทางฝั่งเครื่องไคลเอนต์ร้องขอเว็บเพจ โปรแกรมเว็บไคลเอนต์หรือเว็บเบราว์เซอร์จะส่ง การร้องขอข้อมูลแบบ HTTP (HTTP Request) สำหรับส่วนประกอบต่างๆ (objects) แต่ละอันในเว็บเพจไปยังเว็บเซิร์ฟเวอร์ เมื่อเครื่องเว็บเซิร์ฟเวอร์ได้รับการร้องขอจากผู้ใช้ทางฝั่งเครื่องไคลเอนต์ก็จะตอบกลับด้วยการตอบกลับของการร้องขอข้อมูล HTTP (HTTP Response) ที่ประกอบด้วยส่วนประกอบที่ร้องขอมาอยู่ในเนื้อหา (body) ของการตอบกลับนั้นด้วย ในช่วงปีตั้งแต่ 1997 เว็บเซิร์ฟเวอร์หรือเว็บเบราว์เซอร์จะทำงาน โดยใช้ HTTP เวอร์ชัน 1.0 [8] และตั้งแต่ปี 1998 เป็นต้นมาเว็บเซิร์ฟเวอร์และเว็บเบราว์เซอร์ก็เริ่มทำงานโดยใช้ HTTP เวอร์ชัน 1.1 [9] โดย HTTP เวอร์ชัน 1.1 จะยังคงสนับสนุน HTTP เวอร์ชัน 1.0 อยู่เว็บเซิร์ฟเวอร์ที่ทำงานด้วย HTTP เวอร์ชัน 1.0 สามารถที่จะติดต่อกับเว็บเบราว์เซอร์ที่ทำงานด้วย HTTP

เวอร์ชัน 1.1 ได้และเว็บเบราว์เซอร์ที่ทำงานด้วย HTTP เวอร์ชัน 1.0 ก็สามารถติดต่อสื่อสารกับเว็บเซิร์ฟเวอร์ที่ทำงานด้วย HTTP เวอร์ชัน 1.1 ได้

ทั้ง HTTP/1.1 และ HTTP/1.0 จะใช้ทีซีพี (TCP) เป็นโพรโทคอลในชั้นทรานสปอร์ตเลเยอร์ ในการทำงานทางฝั่งของเครื่องไคลเอนต์ที่มีโปรแกรมเว็บไคลเอนต์หรือเว็บเบราว์เซอร์ทำงานอยู่ เริ่มต้นจะทำการสร้างการเชื่อมต่อแบบทีซีพี (TCP Connection) กับเว็บเซิร์ฟเวอร์และเมื่อการเชื่อมต่อเรียบร้อยแล้ว เว็บเบราว์เซอร์และเว็บเซิร์ฟเวอร์ก็จะทำการติดต่อกัน โดยผ่าน Socket Interface ทางเว็บเบราว์เซอร์ก็จะส่งข้อมูลการร้องแบบ HTTP ไปยัง Socket Interface และขณะเดียวกันก็จะรับข้อมูลการตอบกลับแบบ HTTP ผ่านทาง Socket Interface เช่นกัน และทางเว็บเซิร์ฟเวอร์ก็เช่นเดียวกัน เมื่อมีการส่งข้อมูลการร้องขอแบบ HTTP จากเว็บเบราว์เซอร์ไปยังเว็บเซิร์ฟเวอร์หรือการส่งข้อมูลการตอบกลับแบบ HTTP จากเว็บเซิร์ฟเวอร์ไปยังเว็บเบราว์เซอร์แล้วจะส่งต่อไปเป็นหน้าที่ของทีซีพีในชั้นทรานสปอร์ตเลเยอร์ในการที่จะรับผิดชอบในการทำให้ข้อมูลการร้องแบบ HTTP ส่งถึงเว็บเซิร์ฟเวอร์ หรือข้อมูลการตอบกลับแบบ HTTP ให้ถึงเว็บเบราว์เซอร์

เว็บเซิร์ฟเวอร์จะส่งเว็บเพจที่ทางเว็บเบราว์เซอร์ของเครื่องไคลเอนต์ร้องขอ โดยไม่มีการเก็บข้อมูลหรือสถานะใดๆเกี่ยวกับทางเครื่องไคลเอนต์ ดังนั้นถ้าทางฝั่งเครื่องไคลเอนต์ร้องขอเว็บเพจที่เคยร้องขอมาแล้ว ทางเว็บเซิร์ฟเวอร์ก็จะไม่มีการบอกว่าเว็บเพจนี้ได้ส่งมาแล้ว แต่เว็บเซิร์ฟเวอร์ก็จะส่งเว็บเพจเดิมกลับมาให้ทางเครื่องไคลเอนต์ นั่นคือจะไม่มีจดหรือเก็บสถานะใดๆเลยในเว็บเซิร์ฟเวอร์ ซึ่งการทำงานแบบนี้จะเรียก HTTP ว่าเป็นโพรโทคอลที่มีการทำงานเป็น Stateless Protocol

2.2.3.1 การเชื่อมต่อแบบ NON-PERSISTENT และ PERSISTENT

HTTP สามารถใช้ทั้งการเชื่อมต่อแบบไม่คงตัว (Non-Persistent) และการเชื่อมต่อแบบคงตัว (Persistent) โดย การเชื่อมต่อแบบไม่คงตัว (Non-Persistent) เป็นโหมคมาตรฐานของ HTTP/1.0 และการเชื่อมต่อแบบคงตัว (Persistent) นั้นเป็น โหมคเริ่มต้นของ HTTP/1.1

การเชื่อมต่อแบบไม่คงตัว (Non-Persistent)

การทำงานในการสื่อสารระหว่างเว็บเบราว์เซอร์กับเว็บเซิร์ฟเวอร์ในกรณีที่มีการทำงานแบบไม่คงตัว (Non-Persistent) จะมีขั้นตอนดังนี้

สมมติว่ามีการร้องขอเว็บเพจ "www.someschool.edu/somedepartment/home.index" ที่ประกอบด้วยรูป 10 รูปในเว็บเพจนี้

- เว็บเบราว์เซอร์ที่ทางเครื่องไคลเอนต์จะทำการเริ่มต้นการสร้างการเชื่อมต่อแบบทีซีพี ไปยังเว็บเซิร์ฟเวอร์ของ "www.someschool.edu" ที่ port หมายเลข 80 ที่เป็น port มาตรฐานของเว็บเซิร์ฟเวอร์ที่ใช้ในการรอรับการร้องขอจากทางเครื่องไคลเอนต์

- เว็บเบราว์เซอร์ที่เครื่องไคลเอนต์ส่งข้อมูลการร้องขอแบบ HTTP เข้าไปใน Socket ที่มีการเชื่อมต่อกับทางเว็บเซิร์ฟเวอร์ที่ได้มีการสร้างการเชื่อมต่อแล้วในขั้นตอนแรก ภายในข้อมูลการร้องขอแบบ HTTP จะประกอบด้วยพาท “/somedepartment/home.index” ที่ทำการร้องขอ
- เว็บเซิร์ฟเวอร์ได้รับการร้องขอแบบ HTTP จาก Socket ที่มีการเชื่อมต่อกับเครื่องไคลเอนต์แล้ว จากนั้นเว็บเซิร์ฟเวอร์ก็จะทำการดึงเอา “/somedepartment/home.index” จากเนื้อที่ในดิสก์ของเว็บเซิร์ฟเวอร์ที่เก็บอยู่ เอามาแล้วใส่เข้าไปในส่วนเนื้อหาของเนื้อหา(body) ในข้อมูลการตอบกลับแบบ HTTP แล้วส่งกลับไปให้ทางเครื่องไคลเอนต์
- จากนั้นเว็บเซิร์ฟเวอร์จะทำการปิดหรือยกเลิกการเชื่อมต่อกับเว็บเบราว์เซอร์ของเครื่องไคลเอนต์
- เว็บเบราว์เซอร์ของเครื่องลูกข่ายได้รับการตอบกลับแบบ HTTP จากเว็บเซิร์ฟเวอร์แล้วทำการแปลข้อมูลของเว็บเพจที่ได้รับจากข้อมูลการตอบกลับแบบ HTTP และทำการหาว่าในเว็บเพจมีส่วนประกอบ (Object) อื่นๆอีกหรือไม่
- จากนั้นเว็บเบราว์เซอร์ก็จะเริ่มกระบวนการข้างต้นอีกครั้งเพื่อทำการร้องขอไฟล์รูปภาพหรือส่วนประกอบอื่นๆ ที่มีอยู่ในเว็บเพจนี้

กระบวนการทั้งหมดข้างต้นเป็นการทำงานการเชื่อมต่อแบบไม่คงตัว (NON-PERSISTENT) เพราะว่าแต่ละ การเชื่อมต่อนั้นจะถูกปิดหรือยกเลิกภายหลังที่เว็บเซิร์ฟเวอร์ส่งส่วนประกอบอันนั้นๆ กลับมาแล้ว การเชื่อมต่อที่สร้างขึ้นจะไม่ถูกใช้สำหรับส่วนประกอบอื่นๆ ดังนั้นจากตัวอย่างข้างต้นจะต้องมีการสร้างการเชื่อมต่อทั้งหมด 11 การเชื่อมต่อในการดูเว็บเพจนี้ (1 การเชื่อมต่อสำหรับโครงสร้าง HTML และ 10 การเชื่อมต่อสำหรับรูปภาพทั้ง 10 ภาพ)

การเชื่อมต่อแบบคงตัว (PERSISTENT)

การเชื่อมต่อแบบคงตัว (PERSISTENT) นั้น เว็บเซิร์ฟเวอร์จะทำการคงการเชื่อมต่อแบบที่ซีพีไอไว้หลังจากที่ได้มีการส่งส่วนประกอบ (Objects) ใดๆ กลับไปให้ทางเครื่องไคลเอนต์แล้ว และการร้องขอส่วนประกอบอื่นๆจากเครื่องไคลเอนต์เครื่องเดียวกันสามารถที่จะถูกส่งผ่านทางการเชื่อมต่อเดิมได้ ซึ่งการเชื่อมต่อแบบคงตัวนี้จะช่วยลดเวลาที่ใช้ในการสร้างการเชื่อมต่อที่ซีพีไอ และในการเชื่อมต่อแบบคงตัวนี้ (PERSISTENT) นั้นยังแบ่งเป็นการเชื่อมต่อแบบคงตัวที่มีการส่งข้อมูลแบบตามลำดับซึ่งมีการทำงานที่ทางเครื่องไคลเอนต์จะรอให้ได้รับการตอบกลับแบบ HTTP จากทางเว็บเซิร์ฟเวอร์ก่อนถึงจะทำการร้องขอส่วนประกอบถัดไปและการเชื่อมต่อแบบคงตัวที่มีการส่งข้อมูลแบบขนานที่จะทำการสร้างการเชื่อมต่อที่ซีพีไอหลายๆอันแล้วทำการร้องขอแต่ละส่วนประกอบพร้อมๆกัน ซึ่งจำนวนการเชื่อมต่อแบบที่ซีพีไอที่จะทำการสร้างก็ขึ้นอยู่กับเว็บ

บราวเซอร์ที่กำหนดให้สร้างได้ก็การเชื่อมต่อในคราวเดียว การเชื่อมต่อแบบคงตัว(PERSISTENT) จะถูกกำหนดเป็นโหมคมาตรฐานของ HTTP/1.1

2.2.3.2 โครงสร้างรูปแบบของ HTTP (HTTP Message Format)

HTTP/1.0 และ HTTP/1.1 จะแบ่งเป็น HTTP Request Message และ Response Message

ข้อมูลการร้องขอแบบ (HTTP Request Message)

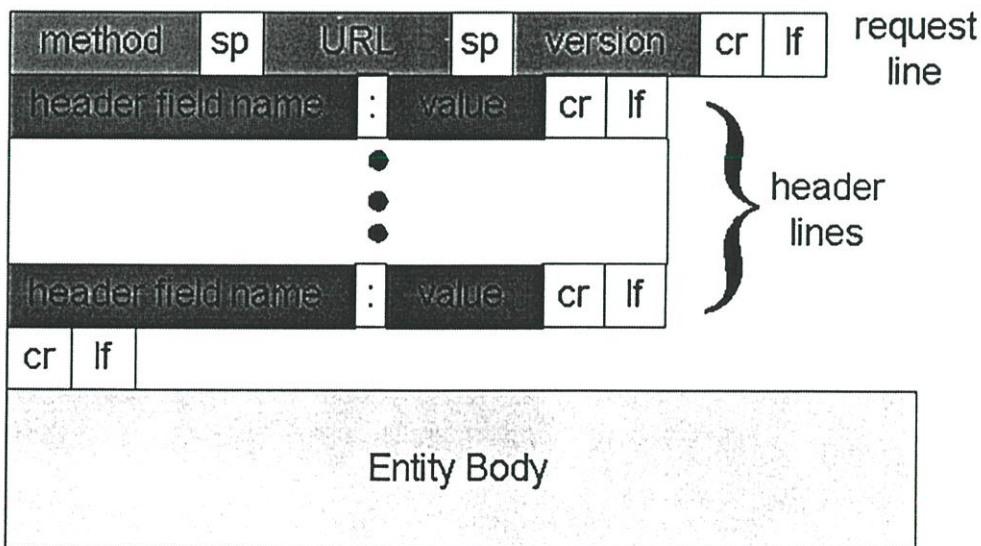
ข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) มีรูปแบบดังนี้

```
GET /somefir/page.html HTTP/1.1
Connection: close
User-agent: Mozilla/4.0
Accept: text/html, image/gif, image/jpeg
Accept-language: fr
```

รูปที่ 2.4 ลักษณะทั่วไปของข้อมูลการร้องขอแบบ HTTP (HTTP Request Message)

รูปแบบของข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) จะอยู่ในรูปของรหัสแอสกี (ASCII code) ธรรมดา ดังนั้นคนทั่วไปสามารถที่จะอ่านได้ ในข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) ตามรูปที่ 2.4 นั้นตัวอย่างจะประกอบด้วย 5 บรรทัด แต่ละบรรทัดจะต้องจบด้วยอักษรจบบรรทัด (Carriage Return) และอักษรเริ่มต้นบรรทัดใหม่ (Line Feed) และในบรรทัดสุดท้ายจะมีการเพิ่มอักษรจบบรรทัด (Carriage Return) และอักษรเริ่มต้นบรรทัดใหม่ (Line Feed) ไปอีกหนึ่งครั้งเป็น 2 ครั้งเฉพาะในบรรทัดสุดท้าย ในบรรทัดแรกของข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) จะเรียกว่า “Request Line” ซึ่งบรรทัดหลังจากนี้จะเรียกว่า “Header Line” ใน Request Line จะประกอบด้วย 3 ฟิลด์คือ ฟิลด์ Method, ฟิลด์ URL และ ฟิลด์ HTTP Version ที่ใช้และใน ฟิลด์ Method จะสามารถมีได้หลายค่าคือ GET, POST หรือ HEAD การใช้งานส่วนใหญ่ของข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) จะใช้ GET Method ซึ่งการใช้ GET Method จะเป็นการที่บราวเซอร์หรือเว็บไคลเอนต์ที่เครื่องถูกข่ายร้องขอส่วนประกอบใดๆในเว็บเพจ (ซึ่งจะระบุในฟิลด์ URL และในตัวอย่างคือ “/somedir/page.html”) จากเว็บเซิร์ฟเวอร์และจะบอกเวอร์ชันของ HTTP ที่ใช้ในฟิลด์ HTTP version (ซึ่งในตัวอย่างคือเวอร์ชัน 1.1)

สำหรับในส่วนของ Header Line ในตัวอย่างจะประกอบด้วย *Connection: close* Header Line เป็นการที่บราวเซอร์หรือเว็บไคลเอนต์บอกทางเว็บเซิร์ฟเวอร์ว่าไม่ต้องการใช้การเชื่อมต่อแบบคงตัว (PERSISTENT) นั่นก็คือต้องการให้ทางเว็บเซิร์ฟเวอร์ปิดการเชื่อมต่อหลังจากที่ได้มีการส่งส่วนประกอบใดๆ (Object) ของเว็บเพจที่ร้องขอแล้ว ที่ต้องบอกเพราะว่าใน Request Line ทางบราวเซอร์บอกทางเว็บเซิร์ฟเวอร์ว่าใช้ HTTP/1.1 ซึ่งถ้าไม่บอกใน *Connection: close* ใน Header Line แล้วทางเว็บเซิร์ฟเวอร์จะใช้การเชื่อมต่อแบบคงตัว PERSISTENT (เพราะเป็นโหมคมาตรฐานของ HTTP เวอร์ชัน 1.1) สำหรับบรรทัดถัดไป *User-agent: Header Line* จะเป็นการบอกว่าบราวเซอร์ที่ทำการร้องขอนั้นเป็นบราวเซอร์อะไร (ในตัวอย่างคือ *Mozilla/4.0* นั่นก็คือ NETSCAPE บราวเซอร์) และ *Accept: Header Line* จะเป็นการบอกเว็บเซิร์ฟเวอร์ว่าทางบราวเซอร์สามารถรองรับส่วนประกอบของเว็บเพจแบบไหนบ้าง (ซึ่งในตัวอย่างคือ html ไฟล์, รูปภาพแบบ jpeg, gif) ถ้าใน “/somedir/page.html” มีไฟล์ประเภทอื่นเช่น จาวา แล้วทางเว็บเซิร์ฟเวอร์ก็จะไม่ส่งไฟล์นั้นให้ทางบราวเซอร์ที่เครื่องไคลเอนต์และสุดท้าย *Accept-language: Header Line* นั้นเป็นการบอกว่าทางผู้ใช้ที่เครื่องไคลเอนต์นั้นอยากที่จะรับส่วนประกอบต่างๆ (Objects) ของเว็บเพจที่เป็นภาษาฝรั่งเศส ซึ่งถ้าทางเว็บเซิร์ฟเวอร์มีส่วนประกอบต่างๆ (Objects) ที่เป็นแบบฝรั่งเศสก็ให้ส่งกลับมา แต่ถ้าไม่มีการจะส่งในแบบที่เป็นมาตรฐานกลับมา



รูปที่ 2.5 โครงสร้างของ HTTP Request Message

จากรูปหลังจากข้อมูลในส่วน Header Line จะเป็นส่วนที่เรียกว่า “Entity Body” ซึ่ง Entity Body จะไม่ใช้กับ GET Method แต่จะใช้กับ POST Method การใช้ POST Method ทางบราวเซอร์ จะใช้ในการส่งข้อมูลบางอย่างไปให้กับเว็บเซิร์ฟเวอร์ เช่นการค้นหาค้นหาเว็บ ทางผู้ใช้ที่เครื่อง ไคลเอนต์ก็ต้องส่งข้อความที่ต้องการค้นหาไปให้เว็บเซิร์ฟเวอร์ และข้อมูลส่วน Entity Method จะส่งถูกส่งผ่านฟอร์มบนเว็บเพจ และสุดท้ายคือ HEAD Method จะใช้ในการตรวจสอบ แก้ไขความผิดพลาดของ HTTP Request Message

ข้อมูลการตอบกลับแบบ HTTP (HTTP Response Message)

รูปแบบทั่วไปของข้อมูลการตอบกลับแบบ HTTP (HTTP response message) เป็นดังรูปที่ 2.6


```
HTTP/1.1 200 OK
Connection: close
Date: Thu, 06 Aug 1998 12:00:15 GMT
Server: Apache/1.3.0 (Unix)
Last-Modified: Mon, 22 Jun 1998 09:23:24 GMT
Content-Length: 6821
Content-Type: text/html
Data data data data data ...
```

รูปที่ 2.6 ลักษณะทั่วไปของการตอบกลับแบบ HTTP Response Message

ในข้อมูลการตอบกลับแบบ HTTP (HTTP response message) ตามตัวอย่างประกอบด้วย 3 ส่วนคือ Status Line, 6 Header Line และ Entity Body ในส่วนของ Entity Body จะเป็นข้อมูลของ Object ที่ทางผู้ใช้อ้างอิงจากเว็บเซิร์ฟเวอร์(ส่วนของ *Data data data data data ...* ในรูป 2.4) ใน Status Line จะประกอบด้วย 3 필ด์คือ 필ด์ Protocol Version, 필ด์ Status Code และ 필ด์ Corresponding Status Code ในตัวอย่าง Protocol version คือ HTTP/1.1 และ Status Code แสดงการส่งข้อมูล ถูกต้อง (200 OK)

สำหรับในส่วนของ Header Line ทางเว็บเซิร์ฟเวอร์จะใช้ *Connection: close* Header Line ที่จะบอกกับทางเว็บบราวเซอร์ของผู้ใช้ว่าจะมีการปิดการเชื่อมต่อหลังจากที่ได้ส่งข้อมูลของ ส่วนประกอบใดๆ (Objects) ของเว็บเพจกลับมาให้แล้ว ส่วน *Date: Header Line* เป็นการบอกวัน และเวลาที่ข้อมูลการตอบกลับแบบ HTTP (HTTP response message) ได้ถูกสร้างขึ้นแล้วส่งกลับไปให้ทางเว็บบราวเซอร์ของผู้ใช้ ส่วน *Server: Header Line* จะใช้บอกว่าข้อมูลการตอบกลับแบบ

HTTP (HTTP response message) นี้ถูกสร้างจากเว็บเซิร์ฟเวอร์อะไร (ซึ่งในตัวอย่างคือ APACHE WEB SEVER) สำหรับ *Last-Modified: Header Line* จะเป็นการบอกว่าส่วนประกอบใดๆ (Objects) ของเว็บเพจที่ได้ส่งกลับมาให้เราได้มีการแก้ไขครั้งล่าสุดเมื่อไหร่ สำหรับ *Content-Length: Header Line* คือขนาดเป็นไบนารีของส่วนประกอบของเว็บเพจที่ส่งกลับมา และสุดท้าย *Content-Type: Header Line* เป็นการบอกว่าใน Entity Body นั้นเป็นส่วนประกอบของเว็บเพจแบบใด(จากในตัวอย่างก็เป็นการบอกว่าใน Entity Body เป็นข้อมูลแบบไฟล์ HTML)



รูปที่ 2.7 โครงสร้างของข้อมูลการตอบกลับแบบ HTTP (HTTP response message)

รูปที่ 2.7 เป็นรูปแบบมาตรฐานของข้อมูลการตอบกลับแบบ HTTP (HTTP response message) และในส่วนของ Status Code จะมีได้หลายค่าตามการเชื่อมต่อของการตอบกลับแบบ HTTP สำหรับตัวอย่างและความหมายของบาง Status Code และ Corresponding Status Code คือ

- 200 OK : แสดงว่า Request ของผู้ใช้ถูกต้อง และได้ส่งข้อมูลกลับมาให้แล้ว
- 301 Moved Permanently : บ่งบอกว่าส่วนประกอบของเว็บเพจที่ทางผู้ร้องขอได้มีการเปลี่ยนที่อยู่แล้วและตำแหน่งที่อยู่ใหม่ของส่วนประกอบของเว็บเพจ (Objects) จะระบุใน *Location: Header* แล้วบราวเซอร์ของทางผู้ร้องขอจะไปที่ URL ตาม *Location: Header* โดยอัตโนมัติ

- 401 Bad Request เป็นการบอกว่าการร้องขอแบบ HTTP ที่ทางผู้ใช้ส่งมามีรูปแบบไม่ถูกต้อง
- 404 Not Found เป็นการบอกวา Object ที่ทางผู้ใช้ร้องขอไม่มีอยู่บนเว็บเซิร์ฟเวอร์
- 505 HTTP Version Not Supported เป็นการบอกวาเว็บเซิร์ฟเวอร์ไม่รองรับ HTTP Version ที่ระบุมาใน Request Message การติดต่อกันระหว่างเครื่องไคลเอนต์และเครื่องเซิร์ฟเวอร์

2.2.3.3 การติดต่อกันระหว่างเครื่องไคลเอนต์และเครื่องเซิร์ฟเวอร์ที่มีการใช้การยืนยันตัวตน (AUTHENTICATION) และการใช้คุกกี้ (COOKIES)

HTTP มีการทำงานแบบไม่เก็บสถานะ (Stateless) เกี่ยวกับผู้ใช้งานไว้ แต่อย่างไรก็ดีเว็บไซต์ต่างๆ อาจจำเป็นต้องมีการจดจำหรือต้องการจำแนกผู้ใช้เพราะจุดประสงค์เกี่ยวกับการจำกัดการเข้าถึงเว็บไซต์หรือต้องการที่จะเก็บข้อมูลบางอย่างที่ใช้กับแต่ละคน ซึ่งใน HTTP ก็ได้มีกลไกที่จะใช้ช่วยในการทำงานลักษณะนี้คือ การยืนยันตัวตน (AUTHENTICATION) และการใช้คุกกี้ (COOKIES)

การยืนยันตัวตน (AUTHENTICATION)

บางเว็บไซต์อาจต้องการให้ผู้ใช้งานใส่ชื่อบัญชีผู้ใช้ (Username) และรหัสลับ (Password) ในการที่เข้าถึงเอกสารหรือเว็บเพจของเว็บไซต์นั้นๆ ซึ่งทำให้ต้องการกลไกที่เรียกว่า กระบวนการยืนยันตัวตน (AUTHENTICATION) โดย HTTP จะมีการกำหนด Status Code และ Header แบบพิเศษที่จะช่วยให้เว็บไซต์สามารถที่จะทำการกระบวนการยืนยันตัวตนได้ ตัวอย่างในการทำงานของกระบวนการยืนยันตัวตนมีดังนี้

- ผู้ใช้งานที่เครื่องลูกข่ายส่งข้อมูลการร้องขอเว็บเพจแบบ HTTP (HTTP Request Message) ไปยังเว็บเซิร์ฟเวอร์
- ทางเว็บเซิร์ฟเวอร์จะตอบกลับด้วยข้อมูลการตอบกลับแบบ HTTP (HTTP Response Message) ที่จะไม่มีส่วนประกอบใดๆของเว็บเพจใน Entity Body ส่งกลับมาด้วยและจะตอบด้วย Status Code ว่า 401 Authorization Required และในส่วนของ Header จะมีค่าเป็น WWW-Authentication Header เพื่อที่จะบ่งบอกว่าทางเว็บเซิร์ฟเวอร์กำหนดให้มีการยืนยันตัวตน (AUTHENTICATION) ในการเข้าถึงเว็บเพจนั้นๆ
- ทางเว็บเบราว์เซอร์ของผู้ใช้งานที่เครื่องไคลเอนต์ได้รับการตอบกลับแบบ HTTP ที่ตอบกลับมา ก็จะมีการเตือนให้ใส่ชื่อบัญชีผู้ใช้ (Username) และรหัสลับ (Password) หลังจากทีผู้ใช้งานใส่ชื่อบัญชีผู้ใช้และรหัสลับแล้ว เว็บเบราว์เซอร์หรือเว็บไคลเอนต์ก็จะส่งข้อมูลการร้องขอแบบ HTTP ไปยังเว็บเซิร์ฟเวอร์อีกครั้งซึ่งในการร้องขอแบบ HTTP ครั้งนี้จะมีส่วน

ของ Header เป็น Authorization: Header และมีชื่อบัญชีผู้ใช้ (Username) และรหัสลับ (Password) อยู่ในภายในส่วนของ Header ด้วย

หลังจากที่ได้รับส่วนประกอบของเว็บเพจ(Objects) แรกแล้วทางเว็บเบราว์เซอร์หรือเว็บไคลเอนต์ที่เครื่องไคลเอนต์ก็จะส่งการร้องขอแบบ HTTP ของส่วนประกอบของเว็บ (Objects) ที่เหลือซึ่งในการร้องขอครั้งนี้และครั้งต่อไป นั่นก็จะส่งชื่อบัญชีผู้ใช้ (Username) และรหัสลับ (Password) อยู่ในในการร้องขอแบบ HTTP นั้นๆ ด้วย ซึ่งชื่อบัญชีผู้ใช้และรหัสลับนั้นจะถูกเก็บไว้ในแคช (Cache) ทำให้ผู้ใช้งานไม่จำเป็นต้องใส่ชื่อบัญชีผู้ใช้และรหัสลับทุกครั้ง ชื่อบัญชีผู้ใช้และรหัสลับจะยังคงอยู่ในแคช (Cache) ภายในช่วงระยะเวลาหนึ่งเท่านั้น

คุกกี้ (COOKIES)

คุกกี้ (COOKIES) เป็นกลไกอีกอย่างหนึ่งสำหรับเว็บเบราว์เซอร์ในการที่เก็บข้อมูลบางอย่างของผู้ใช้ไว้ โดยจะถูกกำหนดไว้ใน RFC 2101 [10] ตัวอย่างในการใช้งานคุกกี้มีดังนี้ สมมติผู้ใช้งานต้องการเข้าถึงเว็บไซต์หนึ่งและในเว็บไซต์นี้มีการใช้งานคุกกี้จากนั้นทางเว็บเบราว์เซอร์ก็จะตอบกลับด้วยข้อมูลการตอบกลับแบบ HTTP ที่มี *Set-Cookie:* อยู่ใน Header ซึ่ง Header นี้จะประกอบด้วยหมายเลขที่ใช้ในการจำแนกผู้ใช้โดยหมายเลขนี้จะถูกสร้างจากทางเว็บเบราว์เซอร์สมมติให้เป็น

Set-cookie: 1678453

เมื่อทางผู้ใช้งานได้รับการตอบกลับนี้แล้วเว็บเบราว์เซอร์ของเครื่องไคลเอนต์ก็จะพบว่า มี *Set-Cookie:* Header และมีหมายเลขของคุกกี้ในส่วนของ Header จากนั้นเว็บเบราว์เซอร์ก็จะเพิ่มข้อมูลของคุกกี้ในไฟล์ที่เว็บเบราว์เซอร์ใช้ในการเก็บข้อมูลของคุกกี้ไว้บนเครื่องไคลเอนต์โดยในไฟล์นั้นก็จะเก็บชื่อเครื่องเซิร์ฟเวอร์ (HOSTNAME) ของเว็บเซิร์ฟเวอร์และหมายเลขที่ทางเว็บเซิร์ฟเวอร์ส่งมาไว้ ดังนั้นการร้องขอในครั้งถัดๆไปในส่วนของ Header ของข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) ที่ทางเว็บเบราว์เซอร์ของผู้ใช้จะส่งให้ทางเว็บเซิร์ฟเวอร์ก็จะมี *Cookies:* Header และก็จะบอกหมายเลขนั้นกับทางเว็บเซิร์ฟเวอร์ด้วยดังเช่น

Cookie: 1678453

ซึ่งในกรณีนี้ทางเว็บเซิร์ฟเวอร์จะไม่รู้ชื่อผู้ใช้และรหัสลับของผู้ใช้งานแต่ทางเว็บเซิร์ฟเวอร์จะสามารถรู้ได้ว่าผู้ใช้งานคนนี้เป็นคนเดียวกับผู้ใช้งานที่เคยเข้ามาแล้ว นอกจากนี้เว็บเซิร์ฟเวอร์สามารถใช้คุกกี้ในการทำงานหลายๆอย่างเช่น

- ถ้าทางเว็บเซิร์ฟเวอร์ต้องการการยืนยันตัวตน (AUTHENTICATION) ของผู้ใช้แต่ไม่ต้องการให้ทางผู้ใช้ใส่ชื่อผู้ใช้และรหัสลับทุกครั้งก็สามารถใช้คุกกี้ได้
- ถ้าทางเว็บเซิร์ฟเวอร์ต้องการจำข้อมูลที่ใช้กับผู้ใช้แต่ละคน ก็สามารถใช้คุกกี้ได้
- ถ้าผู้ใช้มีการซื้อสินค้าผ่านทางเว็บไซต์ เว็บเซิร์ฟเวอร์ก็สามารถใช้คุกกี้ในการเก็บข้อมูลสินค้าที่ผู้ใช้ซื้อไว้ เพื่อใช้ในการสร้าง Shopping Cart ได้

แต่อย่างไรก็ตามคุกกี้ (Cookie) ก็ยังมีปัญหาในกรณีที่ผู้ใช้งานคนเดิมแต่ใช้เครื่องโคลนเอ็นต์คนละเครื่องกับที่เคยเข้าถึงเว็บไซต์ เว็บเซิร์ฟเวอร์จะไม่สามารถจำแนกหรือจดจำข้อมูลผู้ใช้คนนี้ได้

2.2.3.4 CONDITIONAL GET

เว็บแคช (Web Cache) นั้นเป็นการเก็บส่วนประกอบต่างๆของเว็บเพจ (Objects) ที่เคยมีการเข้าถึงแล้วนั้นไว้เพื่อใช้ในการลดเวลาในการเข้าถึงส่วนประกอบต่างๆของเว็บเพจเดิม นั้น โดยเว็บแคช (Web Cache) สามารถทำที่เครื่องโคลนเอ็นต์หรือเครื่องใดๆ ที่ทำหน้าที่แคชส่วนประกอบนั้นๆ (Object) เฉพาะก็ได้ (Proxy Server or Cache Server)

แม้ว่าเว็บแคช (Web Cache) จะสามารถช่วยลดเวลาในการเข้าถึงส่วนประกอบต่างๆของเว็บเพจใดๆ ที่อยู่บนเว็บเซิร์ฟเวอร์ได้ แต่ก็จะมีปัญหาที่เกิดขึ้นมาอีกก็คือ จะรู้ได้อย่างไรว่าส่วนประกอบของเว็บเพจนั้นที่ได้มีการเก็บหรือแคชไว้ในเครื่องโคลนเอ็นต์หรือที่พร็อกซีเซิร์ฟเวอร์ (Proxy Server) นั้นเก่าไปหรือได้มีการแก้ไขแล้วที่เว็บเซิร์ฟเวอร์แล้วหรือยัง ดังนั้น HTTP จึงมีกลไกที่ใช้ในการตรวจสอบกับทางเว็บเซิร์ฟเวอร์ว่าส่วนประกอบของเว็บเพจใดๆ ที่ได้มีการเก็บหรือแคชไว้ได้มีการแก้ไขแล้วหรือไม่ โดยกลไกนี้จะเรียกว่า CONDITIONAL GET ซึ่งการร้องขอแบบ HTTP แบบนี้จะถูกเรียกว่า “การร้องขอแบบ CONDITIONAL GET (CONDITIONAL GET Message)” ซึ่งในการร้องขอแบบ HTTP นี้จะมีการใช้ GET Method และใน Header มีการระบุ *If-Modified-Since*: Header ไว้

```
GET /fruit/kiwi.gif HTTP/1.0
```

```
User-agent: Mozilla/4.0
```

```
Accept: text/html, image/gif, image/jpeg
```

รูปที่ 2.8 ตัวอย่างของข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) ทั่วไป

และทางเว็บเซิร์ฟเวอร์ก็จะตอบกลับด้วยข้อมูลการตอบกลับแบบ HTTP (HTTP Response Message) นี้

```
HTTP/1.0 200 OK
Date: Wed, 12 Aug 1998 15:39:29
Server: Apache/1.3.0 (Unix)
Last-Modified: Mon, 22 Jun 1998 09:23:24
Content-Type: image/gif
data data data data data .....
```

รูปที่ 2.9 ตัวอย่างของข้อมูลการตอบกลับแบบ HTTP (HTTP Response Message) ทั่วไป

จากนั้นทางเว็บเบราว์เซอร์ของเครื่องไคลเอนต์ก็จะแสดงผลส่วนประกอบของเว็บเพจนั้นและก็จะทำการเก็บส่วนประกอบของเว็บเพจนี้ไว้ในแคชและจะเก็บ Last-Modified ของส่วนประกอบนี้ไว้ด้วย สมมติหลังจากนี้ 3 อาทิตย์ผ่านไปผู้ใช้ที่เครื่องไคลเอนต์เดียวกันนี้ต้องการร้องขอเว็บเพจเดียวกันนี้และส่วนประกอบของเว็บเพจนี้ยังอยู่ในแคชและด้วยเหตุที่ว่าส่วนประกอบนี้อาจมีการเปลี่ยนแปลงเกิดขึ้นที่เว็บเซิร์ฟเวอร์ ดังนั้นเว็บเบราว์เซอร์ก็จะทำการตรวจสอบว่าเกิดการแก้ไขส่วนประกอบของเว็บเพจนี้ที่เว็บเซิร์ฟเวอร์หรือไม่ด้วย CONDITIONAL GET โดยจะส่งการร้องขอที่มีการข้อมูลการร้องขอแบบ HTTP ดังนี้

```
GET /fruit/kiwi.gif HTTP/1.0
User-agent: Mozilla/4.0
Accept: text/html, image/gif, image/jpeg
If-modified-since: Mon, 22 Jun 1998 09:23:24
```

รูปที่ 2.10 ข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) ที่มีการใช้ CONDITIONAL GET

โดยค่าของ *If-modified-since*: header จะเป็นค่าที่ได้จาก *Last-Modified*: header ที่ได้รับจากเว็บเซิร์ฟเวอร์เมื่อตอนที่ได้มีการเก็บหรือแคชส่วนประกอบของเว็บเพจหรือตัวเว็บเพจนี้ไว้ *CONDITIONAL GET* นี้จะบอกกับทางเว็บเซิร์ฟเวอร์ว่าให้ส่งส่วนประกอบที่ร้องขอของเว็บเพจนี้กลับมาถ้าส่วนประกอบนี้ได้มีการแก้ไขเกิดขึ้นหลังจากวันที่ระบุใน *If-modified-since* : Header แล้ว ถ้าไม่มีการแก้ไขเกิดขึ้นหลังจากวันที่ระบุ ทางเว็บเซิร์ฟเวอร์ก็จะตอบกลับด้วยการตอบกลับที่มีข้อมูลการตอบกลับดังนี้

HTTP/1.0 304 Not Modified

Date: Wed, 19 Aug 1998 15:39:29

Server: Apache/1.3.0 (Unix)

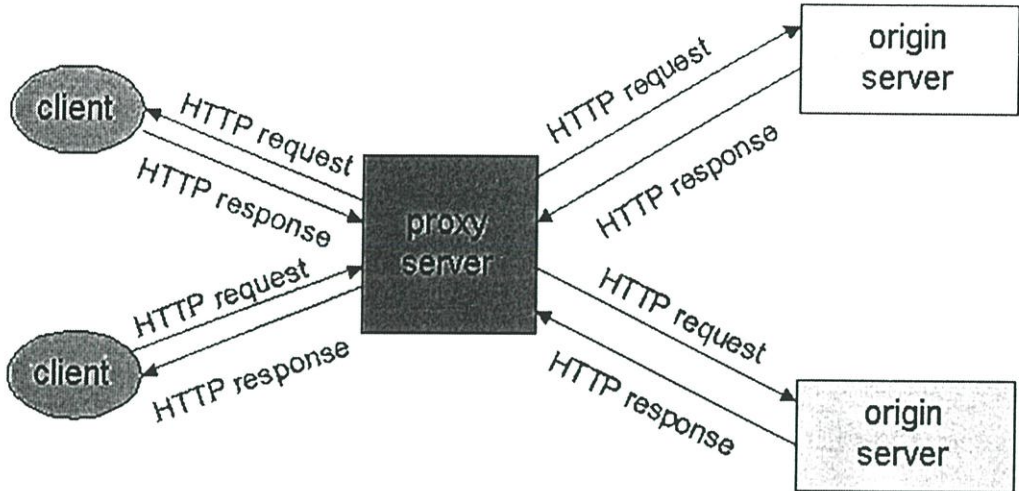
(empty entity body)

รูปที่ 2.11 ข้อมูลการตอบกลับแบบ HTTP (HTTP Response Message) ที่มีตอบกลับด้วย *CONDITIONAL GET*

จากรูปที่ 2.11 ทางเว็บเซิร์ฟเวอร์จะยังคงส่งข้อมูลการตอบกลับแบบ HTTP (HTTP Response Message) กลับมา แต่จะไม่ได้ส่งส่วนประกอบนั้นกลับมา เพื่อแต่ส่งข้อมูลการตอบกลับแบบ HTTP ที่มี Status Code 304 Not Modified เพื่อบอกว่าส่วนประกอบ (Objects) นั้นไม่ได้รับการแก้ไขหลังจากวันที่ระบุใน *If-modified-since* header ในข้อมูลการร้องขอแบบ HTTP ที่ร้องขอไป ดังนั้นทางเว็บเบราว์เซอร์ก็สามารถใช้ส่วนประกอบชิ้นนั้นของเว็บเพจนั้นที่ได้เก็บหรือแคชไว้แสดงผลได้เลย

2.3 ขั้นตอนการเข้าถึงเว็บเพจ

การเข้าถึงเว็บเพจบนเว็ลด์ไวด์เว็บ โดยทั่วไปที่มีการใช้งานอยู่ในปัจจุบันจากเป็นดังรูปที่ 2.12 ซึ่งการทำงานในการเข้าถึงเว็บเพจบางที่ของผู้ใช้อาจจะประกอบด้วยส่วน โครงสร้างต่างๆที่แตกต่างจากรูปที่ 2.12 ก็ได้



รูปที่ 2.12 โครงสร้างในการเข้าถึงเว็บเพจในเว็ลด์ไวด์เว็บ

สำหรับรูปที่ 2.12 นั้นจะอธิบายได้ดังนี้

2.3.1 เว็บไคลเอนต์

เว็บไคลเอนต์จะเป็นส่วนของโปรแกรมที่ทำงานที่เครื่องไคลเอนต์ซึ่งก็คือเว็บเบราว์เซอร์นั่นเอง เว็บเบราว์เซอร์เป็นโปรแกรมที่ผู้ใช้ใช้ในการดูเว็บเพจบนเว็ลด์ไวด์เว็บจะทำงานในระดับแอปพลิเคชันเลเยอร์ (Application Layer) หน้าที่หลักของเว็บเบราว์เซอร์มีดังนี้

2.3.1.1 ส่งการร้องขอเว็บเพจ

เว็บเบราว์เซอร์จะทำการสร้างข้อมูลการร้องขอแบบ HTTP (HTTP Request Message) แล้วส่งไปยังเว็บเซิร์ฟเวอร์เมื่อผู้ใช้คลิกที่ลิงค์บนเว็บเพจหรือเมื่อมีการพิมพ์ URL โดยตรง นอกจากนี้เว็บเบราว์เซอร์จะทำการสร้างและส่งการร้องขอแบบ HTTP เพื่อร้องขอส่วนประกอบต่างๆ ที่มีในเว็บเพจด้วย

2.3.1.2 จัดการกับการตอบกลับของเว็บเซิร์ฟเวอร์

เว็บเบราว์เซอร์จะทำหน้าที่ในการจัดการกับการตอบกลับด้วยข้อมูลการตอบกลับแบบ HTTP (HTTP Response Message) ที่ได้รับเว็บเซิร์ฟเวอร์โดยเว็บเบราว์เซอร์จะทำการแปลหรือเรียกว่า “Parse” ข้อมูลของเว็บเพจที่อยู่ในข้อมูลการตอบกลับแบบ HTTP แล้วก็จะแสดงผลเว็บเพจนั้น จากนั้นก็จะทำการร้องขอส่วนประกอบต่างๆ ที่อยู่ภายในเว็บเพจนั้นเพื่อใช้ในการแสดงผลเว็บเพจนี้ให้ครบถ้วน นอกจากนี้ ถ้ามีส่วนของโปรแกรมที่ทำงานที่ฝ่ายเครื่องไคลเอนต์ที่ต้องใช้ในการ

แสดงผลเว็บเพจด้วย เว็บเบราว์เซอร์ก็จะทำงานในส่วนของ โปรแกรมนั้นด้วย ตัวอย่างของ โปรแกรมที่ทำงานที่ฝ่ายเครื่องลูกข่ายเช่น การใช้ Javascript ในเว็บเพจ

2.3.1.3 จัดการเกี่ยวกับการแคชชิ่ง (Caching)

การแคชชิ่งจะเป็นการเก็บส่วนประกอบของเว็บเพจ (Object) หรือเอกสารที่เคยร้องขอมาแล้ว จากเว็บเซิร์ฟเวอร์ไว้ในเนื้อที่ส่วนหนึ่งในเครื่อง โคลเอนต์ของผู้ใช้ ในการเข้าถึงส่วนประกอบของ เว็บเพจหรือตัวเว็บเพจนั้นอีกครั้งภายหลังก็สามารถดึงจากแคชได้เลย การแคชชิ่งจะช่วยลดเวลาใน การเข้าถึงเว็บเพจต่างและยังช่วยในการลดความคับคั่งที่เกิดบนเว็ลด์ไวด์เว็บอีกด้วย แต่อย่างไรก็ตาม การแคชชิ่งจะต้องมีการใช้กลไกบางอย่างในการทำงานเพื่อใช้ในการตรวจสอบว่า ส่วนประกอบใดๆของเว็บเพจที่ได้มีการแคชไว้ได้มีการแก้ไขที่เว็บเซิร์ฟเวอร์หรือไม่ ซึ่งกลไกตรง นี้เรียกว่า “การตรวจสอบข้อมูลที่แคชไว้ (Cache Revalidation)” และทำงานร่วมกับโปรโตคอล HTTP ด้วย ดังที่กล่าวในหัวข้อ HTTP (CONDITIONAL GET)

2.3.1.4 การจัดเก็บการตั้งค่าต่างๆ

เว็บเบราว์เซอร์นั้นจะมีการทำงานเป็นแบบที่มีส่วนตอบโต้กับผู้ใช้งาน (Interactive Software) ดังนั้นจึงสามารถที่จะปรับแต่งการทำงานของเว็บเบราว์เซอร์ได้ การปรับแต่งนั้นจะแบ่งเป็น

2.3.1.4.1 การแสดงผลทางกายภาพ

ผู้ใช้งานสามารถที่จะปรับแต่งการแสดงผลเว็บเพจได้ตามความต้องการของผู้ใช้เอง ขอบเขตใน การปรับแต่งนั้นก็ขึ้นกับเว็บเบราว์เซอร์เองว่ามีความสามารถในการปรับแต่งได้มากน้อยเพียง ซึ่งจะ จำแนกได้เป็น

- การแสดงผลภายนอก : การปรับแต่งในส่วนนี้จะเป็นการปรับแต่งการรูปแบบของเว็บเบราว์เซอร์เอง ไม่ว่าจะเป็นขนาดของเว็บเบราว์เซอร์ รูปแบบของปุ่มหรือแถบเลื่อนต่างๆ
- แสดงผลรูปภาพต่างๆที่มีในเว็บเพจ : ในเว็บเพจนั้นสามารถมีได้ทั้งตัวอักษรแล้วรูปภาพต่างๆ ดังนั้นเว็บเบราว์เซอร์ก็อาจจะสามารถที่ปรับแต่งให้มีการดึงและแสดงผลรูปภาพที่มีในเว็บเพจด้วยหรือไม่แสดงก็ได้ เพราะในกรณีที่มีรูปขนาดใหญ่อยู่ในเว็บเพจอาจจะทำให้ใช้เวลาในการดึงรูปนั้นนานได้
- ลักษณะตัวอักษร: เว็บเบราว์เซอร์สามารถที่จะปรับเปลี่ยนรูปแบบตัวอักษรที่จะใช้แสดงผลได้ ไม่ว่าจะเป็นขนาดรูปแบบของตัวอักษร ขนาดของตัวอักษร
- สีต่างๆ : การปรับแต่งในส่วนนี้เป็นการปรับแต่งในส่วนหลังของสีพื้นหลังของเว็บเบราว์เซอร์เอง หรือจะเป็นสีของตัวอักษรต่างๆในเว็บเพจเช่น ข้อความที่เป็นลิงค์ไปยังเว็บเพจอื่นที่ยังไม่เคยดูเป็นสีแดง ขณะที่ส่วนของข้อความที่เป็นลิงค์ไปยังเว็บเพจอื่นที่เคยดูมาแล้วเป็นสีเขียว

2.3.1.4.2 การจัดการส่วนที่ไม่นิยามในโปรโตคอล HTTP

เว็บเพจในปัจจุบันไม่ได้มีเพียงลิงค์ไปยังเว็บเพจต่างๆเท่านั้น ยังมีการลิงค์ไปยังเอกสารที่เป็นรูปแบบต่างๆ เช่น PDF, PS, DOC ซึ่งถ้าเป็นเว็บเพจหรือรูปภาพแล้วเว็บเบราว์เซอร์สามารถที่จะจัดการในการแสดงผลได้ แต่ถ้าเป็นไฟล์รูปแบบอื่นๆแล้วเว็บเบราว์เซอร์จะต้องอาศัยโปรแกรมภายนอก (Helper Application) ในการช่วยแสดงผล เช่นถ้าผู้ใช้งานต้องการร้องขอไฟล์ PDF บนเว็บเพจ เว็บเบราว์เซอร์จะต้องดึงข้อมูลของไฟล์ PDF นั้นจากเว็บเบราว์เซอร์แล้วทำการเรียกให้โปรแกรมที่สามารถแสดงผลไฟล์นั้นขึ้นมาทำงานและแสดงผลไฟล์นั้น การที่เว็บเบราว์เซอร์สามารถรู้ได้ว่าจะต้องเรียกใช้โปรแกรมภายนอก (Helper Application) อะไรโดยดูจาก MIME Type ในข้อมูลการตอบกลับแบบ HTTP ที่ได้รับจากเว็บเซิร์ฟเวอร์ ตัวอย่างของ MIME Type และโปรแกรมภายนอกที่ใช้เป็นดังตาราง

ตารางที่ 2.1 แสดง MIME Type ต่างๆ

Content type	MIME type	Helper application
Zip compressed data	application/x-zip-compressed	<i>gunzip</i> /WINZIP32
PostScript document	application/postscript	<i>ghostview</i> /GSVIEW32
Word document	application/msword	<i>catdoc</i> /WINWORD
PDF document	application/pdf	<i>acroread</i> /ACRORD32
audio/video	video/x-mpeg-2	<i>raplayer</i> /MPLAYER2

ในตารางแสดงว่าถ้า Object มี MIME Type เป็น application/postscript ให้ทำการเรียกใช้โปรแกรมภายนอกคือ ghostview

แต่อย่างไรก็ดีเว็บเบราว์เซอร์สามารถที่จะเรียกในงานโปรแกรมภายนอกบางอย่างโดยอัตโนมัติโดยที่ผู้ใช้ไม่สามารถรู้ได้เลยเพราะก็แสดงผลจะอยู่เว็บเบราว์เซอร์เลย เช่น เว็บเบราว์เซอร์ สามารถเรียกใช้ Acroread ในการแสดงผลไฟล์ PDF format และแสดงผลในตัวเว็บเบราว์เซอร์ได้เลย ซึ่งโปรแกรมภายนอกที่มีความสามารถแบบนี้จะเรียกว่า Plug-in ซึ่งการเรียกใช้งาน Plug-in ใดก็อาจดูที่ MIME Type หรือผู้ที่แท็กพิเศษใช้ข้อมูลของเว็บเพจ

2.3.1.5 การจัดการด้านการรักษาความปลอดภัย

เนื่องจากในปัจจุบันมีเว็บไซต์เกิดขึ้นมากมาย ในแต่ละเว็บไซต์ก็ประกอบด้วยเว็บเพจแบบต่างๆ ทั้งแบบไม่เปลี่ยนแปลง(static) หรือแบบมีการเปลี่ยนแปลงได้(dynamic) นอกจากนี้ยังสามารถที่จะประกอบด้วยส่วนการทำงานที่ทำให้เกิดความเสียดังต่อพวกไวรัสหรือการลักลอบเข้าถึงเครื่องของผู้ใช้ได้ เช่น Javascript, ActiveX, Perl Script ทำให้เว็บเบราว์เซอร์เองนั้นจะต้องมีการกลไกที่ใช้ในการป้องกันการเข้าถึงเครื่องของผู้ใช้และรวมถึงป้องกันการทำงานของพวกไวรัสได้ด้วย ซึ่งส่วนการทำงานที่ทำให้เกิดปัญหาได้นี้ส่วนใหญ่จะมาจาก

- JAVA : JAVA เป็นภาษาโปรแกรมที่จะใช้ในการเขียน โปรแกรมที่ทำงานบนเว็บเพจ เรียกว่า Java Applet โดยเว็บเบราว์เซอร์จะทำการดึงส่วนประกอบของเว็บเพจที่เป็น Java Applet มาจากเว็บเซิร์ฟเวอร์ก่อนถึงทำการประมวลผลเพื่อแสดงผล Java Applet นั้น การประมวลผล Java Applet นั้นจะต้องมีการเรียกใช้งาน ตัวแปลภาษา Java ขึ้นมาแปลแล้วถึงจะสามารถแสดงผลได้ แม้ว่า Java Applet นั้นไม่สามารถที่จะลบข้อมูลบนเครื่องของผู้ใช้ได้ แต่ Java Applet ก็มีความสามารถในการที่จะเขียน Java Applet ให้มีการสื่อสารบนเครือข่ายได้ ดังนั้นก็เป็นช่องทางหนึ่งในการที่ทำให้การความเสี่ยงในด้านความปลอดภัยได้
- JAVASCRIPT : JAVASCRIPT จะไม่เหมือน Java เพราะสามารถเขียนขึ้นมาได้ง่ายกว่าและ Javascript เป็นส่วนเพิ่มเติมของ HTML ดังนั้นเว็บเบราว์เซอร์สามารถที่จะประมวลผล Javascript ได้โดยตรง ปัญหาของ Javascript คือ Javascript สามารถที่จะเรียกใช้งานคำสั่งบางอย่างโดยที่ผู้ใช้อาจจะไม่รู้เลยก็ได้ว่ามีการเรียกใช้ เช่น Javascript สามารถที่จะใช้ในการส่งอีเมลได้ และ Javascript สามารถที่จะเข้าถึงไฟล์ข้อมูลในเครื่องของผู้ใช้ได้ ดังนั้นก็สามารถเป็นช่องทางในการเกิดความเสียด้านความปลอดภัยได้
- ACTIVEX : ACTIVEX Control จะมีการทำงานคล้ายกับ Java Applet แต่การทำงานของ ActiveX นั้นจะแสดงหน้าต่างแสดงข้อมูลของ ActiveX นั้น ซึ่งเรียกว่ากลไก Certificate โดยการ Certificate นั้นจะมีข้อมูลส่วนของผู้ใช้เขียน ActiveX นั้นแสดงขึ้นมาแสดงด้วย แต่เพราะ ActiveX มีความสามารถที่เหมือนกัน Java applet ดังนั้นก็ทำให้เกิดปัญหาในรูปแบบเดียวกัน

จากปัญหาในด้านความปลอดภัยที่เกิดขึ้นกับเว็บเบราว์เซอร์ดังนั้นทางผู้พัฒนาเว็บเบราว์เซอร์จึงต้องมีการแก้ไขและปรับปรุงการทำงานของเว็บเบราว์เซอร์ให้มีความปลอดภัยมากยิ่งขึ้น

2.3.1.6 จัดการเกี่ยวกับคุกกี้ (COOKIES)

เว็บเบราว์เซอร์จะมีหน้าที่ในการเก็บคุกกี้ที่ได้รับจากเว็บไซต์แต่ละแห่ง ซึ่งรายละเอียดเกี่ยวกับคุกกี้ได้อธิบายโดยละเอียดในส่วน โพรโตคอล HTTP แล้วการเก็บคุกกี้ที่เว็บเบราว์เซอร์ต่างๆ ก็มี

การเก็บที่แตกต่างกัน เช่น อาจมีการเก็บคุกกี้ทั้งหมดไว้ในไฟล์ข้อมูลเพียงไฟล์เดียวเลย หรือ อาจจะเก็บแยกเป็นไฟล์ๆสำหรับแต่ละเว็บไซต์ ผู้ใช้สามารถที่จะลบคุกกี้ที่มีอยู่ในเครื่องได้

2.3.1.7 สรุป

เว็บไคลเอนต์จะมีโปรแกรมเว็บเบราว์เซอร์ทำงานอยู่ โดยเว็บเบราว์เซอร์จะใช้ในการสร้างและส่งการร้องขอแบบ HTTP (HTTP Request Message) ของเว็บเพจที่ผู้ใช้งานต้องการดูไปยังเว็บเซิร์ฟเวอร์ ต่อจากนั้นก็ทำหน้าที่ในการแปลและแสดงผลข้อมูลเว็บเพจที่ได้รับจากข้อมูลการตอบกลับแบบ HTTP (HTTP Response Message) ที่ส่งกลับมาจากเว็บเซิร์ฟเวอร์ซึ่งในการแสดงผลนั้นอาจจะต้องมีการเรียกใช้งานโปรแกรมภายนอก (Helper Application) เพื่อประมวลผลในส่วนที่เว็บเบราว์เซอร์ไม่สามารถทำงานได้ การเข้าถึงเว็บไซต์ต่างๆ อาจเกิดปัญหาเกี่ยวกับความปลอดภัยของเครื่องที่ผู้ใช้ใช้งานอยู่หรือปัญหาเกี่ยวกับไวรัส ซึ่งปัญหานี้ส่วนมากอาจเกิดจาก Java Applet, ActiveX, Javascript ที่มีอยู่ในเว็บเพจได้

2.3.2 เว็บพร็อกซี (Web Proxy)

การทำงานรูปแบบไคลเอนต์-เซิร์ฟเวอร์นั้นจะมีการเชื่อมต่อระหว่างไคลเอนต์กับเซิร์ฟเวอร์โดยตรงจะไม่มีกล่าวถึงเครื่องเซิร์ฟเวอร์ใดๆระหว่างไคลเอนต์และเซิร์ฟเวอร์เช่นเดียวกับการเข้าถึงเว็บเพจต่าง การร้องขอของผู้ใช้จะถูกส่งไปยังเว็บเซิร์ฟเวอร์โดยตรงและการตอบกลับจากเว็บเซิร์ฟเวอร์ก็จะถูกส่งกลับไปยังเครื่องของผู้ใช้โดยตรง ต่อในระยะเวลาต่อมาได้มีการนำเครื่องเซิร์ฟเวอร์ที่ทำงานเป็นตัวกลางในการเชื่อมต่อระหว่างเครื่องของผู้ใช้และเว็บเซิร์ฟเวอร์ ซึ่งเรียกเครื่องเซิร์ฟเวอร์นี้ว่า “PROXY” และสำหรับการใช้พร็อกซีในเว็ลด์ไวด์เว็บนั้นจะเรียกว่า “WEB PROXY”

เว็บพร็อกซีนั่นจะเป็นเครื่องหรืออุปกรณ์ที่มีการทำงานอยู่ระหว่างเว็บไคลเอนต์และเว็บเซิร์ฟเวอร์โดยจะมีการทำงานคล้ายกับเป็นเว็บเซิร์ฟเวอร์เสมือน (Virtual Web Server) ให้กับเว็บไคลเอนต์ต้นทางเพราะจะทำหน้าที่ในการรับการร้องขอจากเว็บไคลเอนต์ต้นทางและในทางตรงข้ามก็จะทำงานคล้ายกับเป็นเว็บไคลเอนต์เสมือน (Virtual Web Client) ให้กับเว็บเซิร์ฟเวอร์ปลายทางด้วยเพราะจะทำการรับการตอบรับของเว็บเซิร์ฟเวอร์ปลายทางด้วย

จุดประสงค์ของการนำเว็บพร็อกซีมาใช้ก็เพราะว่าเพื่อลดการเชื่อมต่อที่ไม่จำเป็นระหว่างเครื่องไคลเอนต์และเว็บเซิร์ฟเวอร์ อย่างเช่น นำมาทำงานเกี่ยวกับแคชซึ่งเว็บเพจต่างและส่งเว็บเพจนั้นกลับไปให้ผู้ใช้งานโดยที่อาจจะไม่ต้องมีการติดต่อกับเครื่องเว็บเซิร์ฟเวอร์เลยก็ได้ อีกทั้งยังช่วยลดระยะเวลาในการร้องขอเว็บเพจจากเว็บเซิร์ฟเวอร์ด้วย และยังลดความคับคั่งของเครือข่ายภายในที่เชื่อมต่อไปยังเครือข่ายภายนอกด้วย

2.3.2.1 เว็บพร็อกซีชนิดต่างๆ

รูปแบบการทำงานของพร็อกซีแบบเป็น 4 แบบ คือ

- Regular Proxy : เป็นพร็อกซีที่มีการทำงานเพียงแค่ว่า การร้องขอจากเว็บไคลเอนต์ที่เครื่องผู้ใช้และทำการส่งการร้องขอนั้นไปยังเว็บเซิร์ฟเวอร์ และในทางกลับกันการทำการรับการตอบกลับจากเว็บเซิร์ฟเวอร์ และส่งการตอบกลับนั้นกลับไปยังผู้ใช้
- Caching Proxy : ความแตกต่างระหว่าง Regular Proxy และ Caching proxy คือ Caching proxy จะทำการเก็บข้อมูลการตอบกลับต่างๆที่ได้รับจากเว็บเซิร์ฟเวอร์ไว้ด้วย และเมื่อ Caching proxy ได้รับการร้องขอเว็บเพจหรือรีซอร์สที่มีอยู่ในพร็อกซีเองก็สามารถทำการเอาเว็บเพจหรือรีซอร์สที่แคชซึ่งไว้ส่งกลับไปให้ผู้ใช้ได้เลย
- Transparent Proxy : การทำงานที่โดยจะไม่มีมีการแก้ไขข้อมูลต่างๆที่ผ่าน อีกทั้งยังสามารถทำงานแบบ Caching Proxy ได้ด้วย
- Non-transparent Proxy : จะมีการทำงานคล้ายกับ Transparent Proxy แต่ Non-Transparent Proxy จะสามารถแก้ไขข้อมูลที่วิ่งผ่านได้ โดยอาจจะมีการเพิ่มหรือนำข้อมูลบางอย่างออกจากการร้องขอของเว็บไคลเอนต์หรือการตอบกลับจากเว็บเซิร์ฟเวอร์ได้

2.3.2.2 การทำงานของเว็บพร็อกซี

ในหัวข้อนี้จะกล่าวถึงฟังก์ชันการทำงานที่มีใน proxy

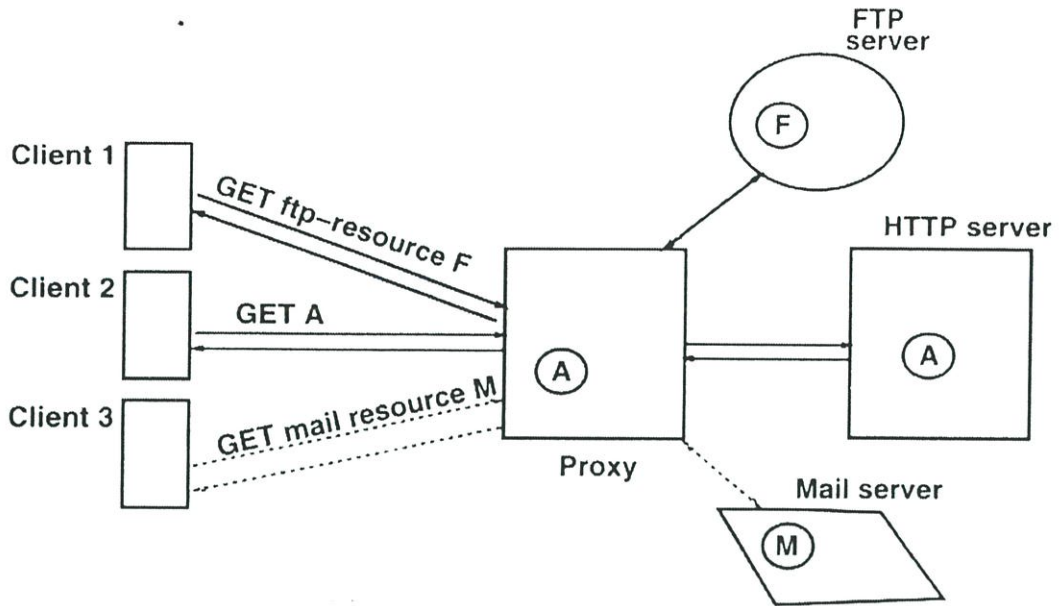
2.3.2.2.1 ความสามารถในการใช้การเชื่อมต่อไปยังเว็ลด์ไวด์เว็บร่วมกัน

เว็บพร็อกซีนั้นจะทำงานเสมือนเป็นเครื่องที่แทนเครื่องในเครือข่ายทั้งหมด และจะทำให้เครื่องต่างๆในเครือข่ายสามารถที่จะเข้าถึงเครือข่ายเว็ลด์ไวด์เว็บได้ เว็บพร็อกซีสามารถที่จะสร้างการเชื่อมต่อเพียงการเชื่อมต่อเดียวไปยังเว็บเซิร์ฟเวอร์เพื่อจัดการการร้องขอจากหลายๆผู้ใช้ได้ เพราะการร้องขอและการตอบรับต่างๆจะต้องผ่านที่เว็บพร็อกซีก่อน จากนั้นเว็บพร็อกซีค่อยทำการร้องขอไปยังเว็บเซิร์ฟเวอร์ต่อไป

2.3.2.2.2 แคชซึ่งข้อมูลการตอบกลับจากเว็บเซิร์ฟเวอร์

หนึ่งในการทำงานที่สำคัญของเว็บพร็อกซีก็คือการแคชซึ่งเว็บเพจหรือรีซอร์สที่ได้รับจากเว็บเซิร์ฟเวอร์ แล้วเว็บเพจหรือรีซอร์สนั้นกลับมาใช้กับผู้ใช้คนอื่นได้ เว็บพร็อกซีจะทำการเว็บเพจหรือรีซอร์สที่ได้ทำการแคชไว้กลับไปให้ผู้ใช้เมื่อเว็บพร็อกซีพิจารณาแล้วว่าเว็บเพจหรือรีซอร์สนั้นยังไม่ได้รับการแก้ไข(การทำงานตรงนี้ เว็บพร็อกซีจะต้องมีการส่งการร้องเพื่อทำการ Cache Revalidation ที่มี Header เป็น If-Modified-Since ไปยังเว็บเซิร์ฟเวอร์ (ตามที่ได้อธิบายไว้ในหัวข้อ HTTP Protocol) นอกเหนือจากนั้นยังมีหน้าที่คือ

- ซ่อนข้อมูลของเว็บไคลเอนต์ในเครือข่าย (Anonymizing Clients) : เว็บพร็อกซีจะทำหน้าที่อีกอย่างที่สำคัญคือ จะทำการปิดบังหรือซ่อนผู้ใช้ต่างๆของเครือข่ายภายในไม่ให้เครือข่ายภายนอกสามารถเห็นได้ เพราะการร้องขอและการตอบรับต่างๆจะต้องผ่านเว็บพร็อกซีอย่างเดียวเท่านั้นถึงจะถูกส่งต่อไปยังผู้ใช้หรือเว็บเซิร์ฟเวอร์อีกที ดังนั้นเครื่องต่างๆในเครือข่ายภายนอกจะไม่ได้รู้ได้ว่าเครื่องที่อยู่ในเครือข่ายนั้นมีกี่เครื่อง มีไอพีอะไรบ้าง
- แปลงหรือทำการแก้ไขการร้องขอหรือการตอบกลับบน โพรโตคอล HTTP (Transforming Requests and Responses) : เว็บพร็อกซีอาจจะทำการแก้ไขข้อมูลการร้องขอแบบ HTTP หรือข้อมูลการตอบกลับแบบ HTTP ได้ในหลายๆกรณี เช่น เว็บ พร็อกซีกับเว็บเซิร์ฟเวอร์อาจจะมีการทำงานที่ HTTP เวอร์ชันใหม่กว่าเว็บเบราว์เซอร์ของผู้ใช้ดังนั้นเว็บพร็อกซีสามารถที่จะแปลงการร้องขอแบบ HTTP ของผู้ใช้ให้เป็นเวอร์ชันที่ใหม่ที่เว็บเซิร์ฟเวอร์รองรับแล้วส่งการร้องขอไปยังเว็บเซิร์ฟเวอร์แล้วเมื่อเว็บเซิร์ฟเวอร์ตอบกลับก็ทำการแปลงเป็น HTTP เวอร์ชันที่เว็บเบราว์เซอร์ของผู้ใช้รองรับอีกทีหนึ่ง ที่ต้องมีการแปลงเพราะการร้องขอหรือการตอบกลับอาจจะใช้ประโยชน์จาก HTTP เวอร์ชันที่ใหม่กว่าได้เช่นการใช้ Header “If-Modified-Since” เป็นต้น หรือ เว็บพร็อกซีกับเว็บเซิร์ฟเวอร์อาจจะมี การบีบอัดข้อมูลระหว่างกัน ซึ่งการทำงานตรงนี้ผู้ใช้จะไม่เกี่ยวข้องเลยเพราะเมื่อเว็บพร็อกซีได้รับการร้องขอจากเว็บเซิร์ฟเวอร์แล้วเว็บพร็อกซีก็จะทำการขยายข้อมูลที่บีบอัดและส่งเป็นการตอบกลับแล้วส่งกลับไปให้ผู้ใช้ได้ โดยที่ผู้ใช้ไม่รู้เลยว่ามีการบีบอัดข้อมูลเกิดขึ้น
- เป็นประตูสู่เครือข่ายภายนอก (Gateway to non-HTTP system) : เว็บพร็อกซีสามารถที่จะมีบทบาทในการเชื่อมต่อระหว่างระบบอื่นๆที่ไม่ได้มีการติดต่อกันโดยใช้ โพรโตคอล HTTP เช่น เว็บพร็อกซีอาจจะเป็นตัวกลางระหว่างเว็บไคลเอนต์และเอฟทีพีเซิร์ฟเวอร์ (FTP Server) ซึ่งการร้องขอของผู้ใช้จะถูกส่งไปยังเอฟทีพีเซิร์ฟเวอร์ (FTP Server) และการตอบกลับจากเอฟทีพีเซิร์ฟเวอร์ (FTP Server) ก็จะถูกส่งกลับไปยังผู้ใช้ แต่เพราะเว็บไคลเอนต์และเอฟทีพีเซิร์ฟเวอร์ใช้โพรโตคอลที่แตกต่างกันในการติดต่อ ดังนั้นเว็บพร็อกซีต้องทำการแปลงการร้องขอแบบ HTTP ที่มาจากเว็บไคลเอนต์ให้เป็นการร้องขอแบบ FTP ก่อน และจะต้องแปลงการตอบกลับแบบ FTP ให้เป็นการตอบกลับแบบ HTTP ก่อนส่งกลับไปยังเว็บไคลเอนต์ดังกรณีนี้ เว็บพร็อกซีจะทำหน้าที่เหมือนกับเป็น “ประตูสู่เครือข่ายภายนอก (Gateway)” ค่ะ



รูปที่ 2.13 ตัวอย่างที่พร็อกซีมีการทำงานเป็นประตูสู่เครือข่ายภายนอก (Gateway) ไปยัง FTP, HTTP และ Mail

ตัวอย่างของการที่เว็บพร็อกซีทำหน้าที่เป็นประตูสู่เครือข่ายภายนอก (Gateway) เช่น สมมติเว็บไคลเอนต์มีการร้องขอไปยังเอฟทีพีเซิร์ฟเวอร์ (FTP Server) โดยร้องขอ ftp://ftp.kmitl.ac.th/F ไปยังเว็บพร็อกซีเมื่อเว็บพร็อกซีได้รับการร้องขอแล้ว เว็บพร็อกซีก็จะทำการแปลงการร้องขอแบบ HTTP ของเว็บไคลเอนต์ไปเป็นการร้องขอแบบ FTP แล้วจึงทำการร้องขอไปยังเอฟทีพีเซิร์ฟเวอร์ (FTP Server) ต่อไป แต่อย่างไรก็ดีในกรณีนี้เว็บพร็อกซีจะต้องทำการสร้างการเชื่อมต่อไปยังเอฟทีพีเซิร์ฟเวอร์ (FTP Server) และเว็บพร็อกซีจะทำงานกลายเป็นเอฟทีพีเซิร์ฟเวอร์ (FTP Client) เลขนอกเหนือจากนั้นการทำงานของโปรโตคอล FTP จะมีการส่งข้อมูลกับการร้องขอจะส่งโดยใช้การเชื่อมต่อที่แตกต่างกัน(ข้อมูลทาง port 20, การร้องขอทาง port 21) ดังนั้นเว็บพร็อกซีต้องทำการดึงข้อมูลจากช่องการเชื่อมต่อของข้อมูลในการตอบกลับของเอฟทีพีเซิร์ฟเวอร์ (FTP Server) แล้วทำการแปลงเป็นการตอบกลับแบบ HTTP ส่งกลับไปเว็บไคลเอนต์ต่อไป

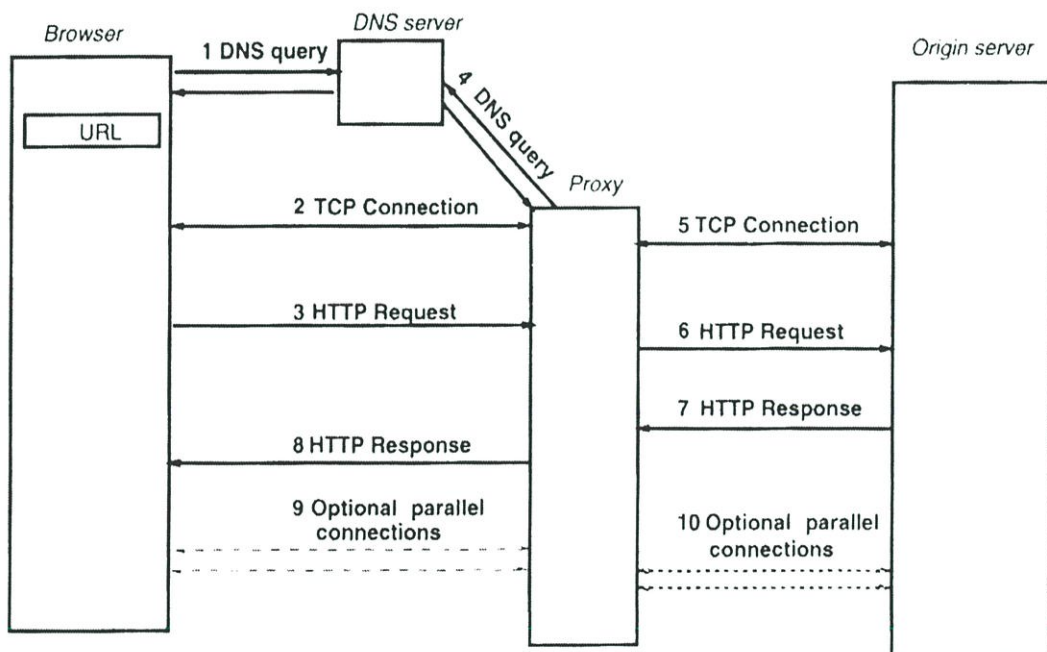
2.3.2.2.3 กรองและตรวจสอบการร้องขอจากเว็บไคลเอนต์หรือการตอบกลับจากเว็บเซิร์ฟเวอร์

เว็บพร็อกซีสามารถทำหน้าที่ในการกรองหรือป้องกันการร้องขอแบบ HTTP หรือการตอบกลับแบบ HTTP ที่ไม่ถูกต้อง โดยการกรอง (Filter) ของเว็บพร็อกซีนี้อาจจะกรองโดยการดูจากเว็บไซต์ปลายทางว่าถ้าเป็นเว็บไซต์นี้จะไม่ให้มีการร้องขอเกิดขึ้น หรือจะเป็นการกรองในกรณีของการตอบกลับแบบ HTTP ว่าถ้ามีขนาดหรือมีรูปแบบของข้อมูลเป็นตามเงื่อนไขใดเงื่อนไขหนึ่งก็ไม่ให้ทำการส่งการตอบกลับแบบ HTTP นั้นกลับไปให้ผู้ใช้ได้ นอกเหนือจากนี้การกรองของเว็บ

พร็อกซียังรวมไปถึงการนำหรือการใส่ข้อมูลเพิ่มลงไป ในข้อมูลของการร้องขอแบบ HTTP หรือ – ข้อมูลการตอบกลับแบบ HTTP ได้ด้วย

2.3.2.3 บทบาทของเว็บพร็อกซีเกี่ยวกับการจัดการการร้องขอและการตอบรับการร้องขอ ในหัวข้อนี้จะกล่าวถึงการทำงาน โดยรายละเอียดในการที่เว็บพร็อกซีจะจัดการกับการร้องขอแบบ HTTP ที่ส่งมาจากผู้ใช้และการตอบกลับแบบ HTTP ที่ส่งมาจากเว็บเซิร์ฟเวอร์

2.3.2.3.1 ขั้นตอนในการแลกเปลี่ยนของข้อมูลการร้องขอแบบ HTTP และข้อมูลการตอบกลับแบบ HTTP ของเว็บพร็อกซี



รูปที่ 2.14 ขั้นตอนที่เกิดขึ้นในกระบวนการร้องขอและตอบกลับแบบ HTTP ที่มีการใช้งานเว็บพร็อกซี

ในรูปที่ 2.14 จะแสดงขั้นตอนที่เกี่ยวข้องทั้งหมดเมื่อมีการใช้งานเว็บพร็อกซีในการเป็นตัวกลางระหว่างเว็บไคลเอนต์และเว็บเซิร์ฟเวอร์

เมื่อผู้ใช้ทำการร้องขอเว็บเพจหรือรีซอร์สใดๆ เว็บเบราว์เซอร์ของผู้ใช้จะมีการสร้างการเชื่อมต่อ (TCP Connection) ไปยังเว็บพร็อกซีนั้นก็เพราะมีการกำหนดให้เว็บเบราว์เซอร์ของผู้ใช้มีการสร้างการเชื่อมต่อผ่านเว็บพร็อกซี ซึ่งเว็บเบราว์เซอร์อาจจะต้องทำการค้นหาไอพีของเว็บพร็อกซีด้วย

ดังนั้นเว็บเบราว์เซอร์ต้องทำการส่งข้อมูลเพื่อสอบถามไอพีของพร็อกซี (DNS Query) ไปยังดีเอ็นเอสเซิร์ฟเวอร์ (DNS Server) ของผู้ใช้ด้วย (ขั้นตอนที่ 1 และ 2) จากนั้นเมื่อรู้ไอพีของเว็บพร็อกซีแล้ว เว็บเบราว์เซอร์ก็จะทำการส่งการร้องขอแบบ HTTP ไปยังเว็บพร็อกซี (ขั้นตอนที่ 3) เมื่อเว็บพร็อกซีได้รับการร้องขอแบบ HTTP จากผู้ใช้แล้ว เว็บพร็อกซีก็จะต้องทำการเชื่อมต่อกับเว็บเซิร์ฟเวอร์ปลายทางโดยเว็บพร็อกซีจะต้องทำการค้นหาไอพีของเว็บเซิร์ฟเวอร์ปลายทางเช่นกัน โดยจะทำการส่งข้อมูลเพื่อสอบถามไอพีของพร็อกซี (DNS Query) ไปยังดีเอ็นเอสเซิร์ฟเวอร์ (DNS Server) (ขั้นตอนที่ 4) ซึ่งดีเอ็นเอสเซิร์ฟเวอร์ของเว็บพร็อกซีอาจจะต้องตัวเดียวหรือคนละตัวกับผู้ใช้ก็ได้ เมื่อรู้ไอพีของเว็บเซิร์ฟเวอร์ปลายทางแล้วเว็บพร็อกซีก็จะทำการสร้างการเชื่อมต่อ (TCP Connection) ไปยังเว็บเซิร์ฟเวอร์ปลายทางและทำการส่งการร้องขอแบบ HTTP ไปยังเว็บเซิร์ฟเวอร์ (ขั้นตอนที่ 5 และ 6) จากนั้นเมื่อเว็บเซิร์ฟเวอร์ส่งการตอบกลับแบบ HTTP กลับมายังเว็บพร็อกซี เว็บพร็อกซีก็จะทำการส่งต่อข้อมูลการตอบกลับแบบ HTTP นั้นกลับไปให้เว็บเบราว์เซอร์ของผู้ใช้ต่อไป ซึ่งระหว่างกระบวนการทั้งหมดนี้เว็บเบราว์เซอร์อาจจะมีการสร้างการร้องขอเพิ่มเติมไปยังเว็บพร็อกซีก็ได้ และเว็บพร็อกซีก็ต้องการร้องขอเว็บเพจหรือรีซอร์สต่างๆเพิ่มเติมตามที่ได้รับ การร้องขอจากผู้ใช้ด้วย (ขั้นตอนที่ 9 และ 10)

2.3.2.3.2 การจัดการข้อมูลของการร้องขอแบบ HTTP และการตอบกลับแบบ HTTP

ตามที่ได้กล่าวมาแล้วว่าเว็บพร็อกซีอาจจะมีการเพิ่มหรือลบข้อมูลบางอย่างไปในข้อมูลของการร้องขอแบบ HTTP หรือข้อมูลการตอบกลับแบบ HTTP ได้ซึ่งการเพิ่มหรือการลบต่างๆที่เกิดขึ้นอาจจะเป็นเกิดเพราะกรณีดังนี้

- แสดงตัวเองของเว็บพร็อกซี (Identification) : เว็บพร็อกซีสามารถที่จะแสดงตัวเองใน HTTP Header ได้เพื่อให้เซิร์ฟเวอร์หรือส่วนประกอบอื่นๆเช่น เราเตอร์สามารถที่จะรู้ได้ว่าการร้องขอแบบ HTTP หรือการตอบกลับแบบ HTTP นี้ถูกส่งมาจากเว็บพร็อกซีนี้ หนึ่งในจุดประสงค์ที่ทำการเพิ่ม Header นี้ก็เพราะใช้ในการแสดงว่ามีการเกิดลูปในการส่งการร้องขอแบบ HTTP หรือการตอบกลับแบบ HTTP หรือไม่
- แปลงเวอร์ชันของ HTTP (Version number change) : เว็บพร็อกซีสามารถที่จะเปลี่ยน Request Line ในข้อมูลการร้องขอแบบ HTTP ได้เช่น HTTP Request Line ที่ถูกส่งมาจากผู้ใช้อาจจะเป็น

GET /foo/bar.html HTTP/1.0

อาจจะถูกแก้ไขเป็น

GET /foo/bar.html HTTP/1.1


ก่อนที่จะถูกส่งไปยังเว็บเซิร์ฟเวอร์ เพราะเว็บพรีอ็อกชันนั้นอาจจะต้องการทำงานหรือใช้ความสามารถของ HTTP ในเวอร์ชันที่ใหม่กว่า ซึ่งเว็บเบราว์เซอร์ของผู้ใช้ไม่สนับสนุนได้ และในกรณีที่เว็บเบราว์เซอร์ของผู้ใช้ทำงานด้วย HTTP เวอร์ชันใหม่กว่าและก็เช่นเดียวกันเว็บพรีอ็อกชันก็สามารถแปลงเป็น HTTP เวอร์ชันที่เว็บเซิร์ฟเวอร์สนับสนุนได้

- เพิ่มข้อมูลบางอย่างเกี่ยวกับการตอบกลับที่ส่งกลับ (Adding obligatory information about the resource) : ในการส่งการตอบกลับแบบ HTTP กลับไปยังผู้ใช้โดยใช้เว็บเพจหรือรีซอร์สที่ทำการแคชไว้ นั้น เว็บพรีอ็อกชันอาจจะต้องการเพิ่มข้อมูลบางอย่างเกี่ยวกับเว็บเพจหรือรีซอร์สนั้นเข้าไป เช่น มีการเพิ่มข้อมูลบอกช่วงระยะเวลาที่เว็บเพจหรือรีซอร์สนั้นมีการตรวจสอบการแก้ไขกับเว็บเซิร์ฟเวอร์
- จัดการเกี่ยวกับความล่าช้าและการสำรองข้อมูล (Handling delay and Buffering) : เว็บพรีอ็อกชันนั้นจะทำงาน โดยเป็นตัวกลางระหว่างเว็บไคลเอนต์และเว็บเซิร์ฟเวอร์ นอกจากนั้นยังจัดเก็บเว็บเพจหรือรีซอร์สต่างๆที่ได้มีการร้องขอไว้ในแคชแล้วยังทำให้หน้าที่ในการส่งเว็บเพจหรือรีซอร์สที่ได้มีการแคชไว้ส่งกลับไปที่ทางผู้ใช้อย่างรวดเร็ว
- รักษาสถานะและข้อกำหนดต่างของการเชื่อมต่อ (State maintenance and policy issue) : เว็บพรีอ็อกชันจะต้องมีการรักษาและดูแลสถานะของแต่ละการเชื่อมต่อที่เข้ามาที่เว็บ พรีอ็อกชัน และการเชื่อมต่อที่เว็บพรีอ็อกชันทำการเชื่อมต่อกับเว็บเซิร์ฟเวอร์ด้วยเช่น การปิดการเชื่อมต่อกับเบราว์เซอร์ของผู้ใช้ในกรณีที่มีการยกเลิกการร้องขอเว็บเพจจากเว็บเซิร์ฟเวอร์ แต่สำหรับการเชื่อมต่อกับเว็บเซิร์ฟเวอร์นั้นเว็บพรีอ็อกชันอาจจะไม่ทำการยกเลิกการเชื่อมต่อถ้าผู้ใช้ยกเลิกการเชื่อมต่อ เพราะเว็บพรีอ็อกชันอาจจะต้องการแคชเว็บเพจหรือรีซอร์สนั้นไว้ก่อน ซึ่งก็ขึ้นอยู่กับนโยบายที่กำหนดไว้ให้กับเว็บพรีอ็อกชันด้วย
- จัดการเกี่ยวกับคุกกี้ (Handling cookies) : อย่างที่ได้กล่าวไปแล้วว่าเว็บไคลเอนต์จะต้องมีการใช้งาน คุกกี้ (Cookies) ด้วย ซึ่งคุกกี้ก็จะถูกส่งมาจากเว็บเซิร์ฟเวอร์และเพราะเว็บพรีอ็อกชันนั้นจะทำงานคล้ายกับเป็นทั้งเว็บไคลเอนต์และเว็บเซิร์ฟเวอร์เพราะเว็บพรีอ็อกชันนั้นจะได้รับทั้งคุกกี้ที่อยู่ในข้อมูลการร้องขอแบบ HTTP และคุกกี้ที่ได้รับจากการตอบกลับแบบ HTTP ซึ่งเว็บพรีอ็อกชันจะต้องทำการส่งต่อไปยังเว็บเซิร์ฟเวอร์หรือเว็บไคลเอนต์ต่อไป ตัวอย่างเช่นเว็บไคลเอนต์ทำการร้องขอแบบ HTTP ไปยังเว็บเซิร์ฟเวอร์ S โดยผ่านเว็บพรีอ็อกชัน P จากนั้นเว็บเซิร์ฟเวอร์ S ก็ได้ส่งคุกกี้ โดยการ ใช้ Set-Cookie Header ในการตอบกลับแบบ HTTP กลับไปที่เว็บพรีอ็อกชันเพราะเว็บ พรีอ็อกชันจะถูกมองว่าเป็นไคลเอนต์ เมื่อเว็บพรีอ็อกชันได้รับข้อมูลการตอบกลับแบบ HTTP ที่มี Set-Cookie แล้วก็จะทำการส่งการตอบกลับแบบ HTTP นี้กลับไปที่เว็บไคลเอนต์ต่อไป และครั้งต่อไปที่เว็บไคลเอนต์ค้นหาทำการร้องขอเว็บเพจ

หรือรีซอร์ส จากเว็บเซิร์ฟเวอร์ S อีกก็จะทำการส่งคุกกี้ที่ได้เก็บไว้เว็บเซิร์ฟเวอร์ S โดยผ่านเว็บพร็อกซี P และเว็บพร็อกซี P ก็ทำการส่งการร้องขอแบบ HTTP ที่มีคุกกี้นี้ต่อไปให้เว็บเซิร์ฟเวอร์ต่อไป ซึ่งเว็บพร็อกซี P อาจจะมีการเพิ่มเอาคุกกี้ของตัวเองเข้าไปได้ด้วย ไม่ว่าจะเป็นการกำหนดให้เว็บไคลเอนต์เก็บคุกกี้ของตัวเอง(คุกกี้ของพร็อกซี)หรือส่ง คุกกี้ที่ตัวเองเก็บไว้ส่งให้กับเว็บเซิร์ฟเวอร์

2.3.2.4 ลำดับชั้นและการเชื่อมต่อเป็นลูกโซ่ของเว็บพร็อกซี

ในการทำงานจริงๆของเว็บพร็อกซีนั้นอาจจะมีการทำงานของเว็บพร็อกซีหลายตัวระหว่างเว็บไคลเอนต์ และเว็บเซิร์ฟเวอร์ ตัวอย่างเช่นสมมติว่า มหาวิทยาลัยหนึ่งมีเว็บพร็อกซีทำงานอยู่หนึ่งตัว และแต่ละคณะก็สามารถที่จะมีเว็บพร็อกซีเป็นของตัวเองในเครือข่ายของแต่ละคณะได้อีก และมหาวิทยาลัยนี้อาจจะเชื่อมต่อกับไอเอสพี (ISP: Internet Service Provide) ซึ่งอาจจะมีเว็บพร็อกซีของไอเอสพีอีก และท้ายที่สุดที่เว็บเซิร์ฟเวอร์ปลายทางอาจจะมีเว็บพร็อกซีอยู่อีกได้เช่นกัน ดังนั้นการทำงานจะเป็นดังรูป



รูปที่ 2.15 แสดงรูปแบบการทำงานอย่างง่าย ๆ เป็นลำดับของพร็อกซี

ดังนั้นโดยสรุปการร้องขอแบบ HTTP ของเว็บไคลเอนต์นั้นอาจจะผ่านเว็บพร็อกซีหลายๆ ตัวกว่าจะถึงเว็บเซิร์ฟเวอร์ปลายทางและในความเป็นจริงอาจจะไม่ทำงานเป็นเส้นตรงดังรูปก็เป็นได้ โดยอาจจะมีมีการติดต่อของเว็บพร็อกซีเป็นลำดับชั้นได้เช่นกัน เช่น เว็บพร็อกซีของมหาวิทยาลัยหลายแห่งอาจจะเชื่อมต่อกับเว็บพร็อกซีของไอเอสพีและเว็บพร็อกซีของไอเอสพีทั้งหมดของประเทศหนึ่งอาจจะเชื่อมต่อกับเว็บพร็อกซีของทวีปอีกชั้นหนึ่งก็ได้

2.3.2.5 สรุป

เว็บพร็อกซีเป็นเครื่องหรืออุปกรณ์ที่มีการทำงานระหว่างเว็บไคลเอนต์และเว็บเซิร์ฟเวอร์ ซึ่งเว็บพร็อกซีมีความสามารถในการทำให้ผู้ใช้ต่างๆ ในเครือข่ายขององค์กรหนึ่งสามารถที่เข้าถึงเครือข่ายเว็ลด์ไวด์เว็บร่วมกันได้ เว็บพร็อกซีสามารถทำหน้าที่ในการกรองการร้องขอแบบ HTTP

หรือการตอบกลับแบบ HTTP ที่ผ่านได้ และเว็บพรีอ็อกซียังทำหน้าที่ในการแคชเว็บเพจหรือรีซอร์สไว้ให้กับผู้ใช้งานคนอื่นๆได้ การนำเว็บพรีอ็อกซีมาใช้ยังมีประโยชน์ในการช่วยลดระยะเวลาในการเข้าถึงเว็บเพจหรือรีซอร์สต่างด้วย

2.3.3 เว็บเซิร์ฟเวอร์ (Web server)

เว็บเซิร์ฟเวอร์เป็นโปรแกรมที่จะใช้ในการสร้างและส่งการตอบกลับแบบ HTTP กลับไปยังผู้ใช้ที่มีการร้องขอเว็บเพจหรือรีซอร์สใดบนเว็บเซิร์ฟเวอร์

2.3.3.1 ความแตกต่างระหว่างเว็บไซต์และเว็บเซิร์ฟเวอร์

เว็บไซต์จะประกอบด้วยกลุ่มของเว็บเพจที่อยู่ภายใต้ชื่อเฉพาะชื่อหนึ่ง แต่เว็บเซิร์ฟเวอร์จะเป็นโปรแกรมที่จะใช้ในการติดต่อสื่อสารกับเว็บไคลเอนต์ที่เครื่องของผู้ใช้ที่มีการร้องขอเว็บเพจหรือรีซอร์สใดบนเว็บไซต์ ซึ่งในหัวข้อนี้จะอธิบายลักษณะการทำงานแบบต่างๆของเว็บไซต์ รูปแบบการทำงานของเว็บเซิร์ฟเวอร์ และการจำแนกรูปแบบของเว็บเซิร์ฟเวอร์ แบบต่างๆ

2.3.3.1.1 เว็บไซต์

รูปแบบต่างของเว็บไซต์ในปัจจุบันสามารถแบ่งง่ายๆเป็น

- เว็บไซต์สถาบันการศึกษา (University) : เว็บไซต์แบบนี้ส่วนใหญ่จะเป็นเว็บไซต์ที่มีการให้ข้อมูลเกี่ยวกับหลักสูตรการศึกษาหรือข้อมูลการวิจัยรวมถึงรูปและข้อมูลที่ใช้ในการติดต่อกับทางสถาบันการศึกษา ในเว็บไซต์อาจจะมีลิงค์ไปยังเว็บไซต์ของแต่ละส่วนการศึกษาที่แสดงรายชื่อของนักศึกษาและอาจารย์ผู้สอนรวมถึงโฮมเพจในแต่ละส่วนการศึกษานั้นๆด้วย
- เว็บไซต์ในรูปแบบการให้ข้อมูลจากธุรกิจถึงผู้บริโภค (Business-to-consumer) : บริษัททั่วไปอาจจะมีการสร้างเว็บไซต์ที่ใช้ในการให้ข้อมูลเกี่ยวกับผลิตภัณฑ์ที่ขายหรือจะบอกตำแหน่งงานที่ว่างอยู่ ภายในเว็บไซต์อาจจะให้ลูกค้าสามารถที่จะดูข้อมูลรายละเอียดของผลิตภัณฑ์ ราคา ข้อมูลการสั่งซื้อ อาจรวมถึงสามารถดูข้อมูลสินค้าที่มีอยู่ในคลังสินค้าได้ด้วย ลูกค้าอาจจะสามารถค้นหาข้อมูลได้ด้วย ลักษณะของเว็บไซต์ที่มีการทำงานอย่างนี้จะเรียกว่าเว็บไซต์แบบ “B2C”
- เว็บไซต์ภายในขององค์กร (Corporate intranet) : บริษัทในปัจจุบันหลายบริษัทได้มีการสร้างเว็บไซต์ที่ใช้เฉพาะภายในองค์กรเท่านั้นที่เรียกว่า “อินทราเน็ตเว็บไซต์” โดยเว็บไซต์นี้จะให้ข้อมูลต่างๆที่จำเป็นต้องใช้ในการทำงานกับพนักงานในองค์กร อีกทั้งยังใช้ในการติดต่อระหว่างพนักงานในองค์กรเอง การเข้าถึงเว็บไซต์นี้จะต้องมีการใส่ บัญชีรายชื่อ (Username) และรหัสผ่าน (Password) ก่อน
- เว็บไซต์จากกลุ่มธุรกิจหนึ่งไปยังอีกกลุ่มธุรกิจหนึ่ง (Business-to-business) : การทำงานในบริษัทหนึ่งอาจจะต้องมีการขึ้นกับอีกบริษัทหนึ่ง ดังนั้นบริษัทหนึ่งอาจจะมีการสร้างเว็บไซต์

ที่ใช้ในการแลกเปลี่ยนข้อมูลระหว่างทั้งสองบริษัทขึ้นมาเพื่อให้อีกบริษัทหนึ่งสามารถที่จะดึงหรือค้นหาข้อมูลของอีกบริษัทหนึ่งได้ ลักษณะของเว็บไซต์ที่มีการทำงานอย่างนี้จะเรียกว่าเว็บไซต์แบบ “B2B”

- เว็บไซต์เหตุการณ์เฉพาะ (Special Event) : บางเว็บไซต์ประเภทนี้จะเป็นเว็บไซต์แบบที่มีการตั้งขึ้นชั่วคราวเฉพาะในเวลาหนึ่งๆ เช่นเว็บไซต์มหกรรมกีฬาต่างๆ ภายในไซต์จะแสดงข้อมูลการรายงานต่างๆของเหตุการณ์นั้น โดยข้อมูลจะมีการเปลี่ยนแปลงอย่างรวดเร็วตามเหตุการณ์นั้นๆ เว็บไซต์แบบนี้จะมีผู้ใช้เข้าถึงเป็นจำนวนมากในช่วงระยะเวลาหนึ่ง
- เว็บท่า (Portal) : เว็บไซต์ท่าจะถูกสร้างขึ้นเพื่อใช้ในการสร้างความสัมพันธ์กับผู้ใช้งานที่จะเป็นศูนย์กลางข้อมูลทุกอย่างที่ผู้ใช้ต้องการจะเข้าถึง เช่น เว็บไซต์แบบ Portal อาจมีการแสดงข้อมูลภูมิอากาศ รายการโทรทัศน์ ข่าว ซึ่งเว็บไซต์แบบนี้จะสามารถให้ผู้ใช้งานสามารถที่ปรับเปลี่ยนข้อมูลที่จะแสดงได้ เช่นผู้ใช้อาจจะต้องการดูข้อมูลเกี่ยวกับภาพยนต์ที่เข้าฉายอยู่ เป็นต้น ในเว็บไซต์จะมีการจัดการให้มีลิงค์ไปยังเว็บไซต์ต่างๆที่ผู้ใช้งานใจเพื่อให้่ายในการเข้าถึงของผู้ใช้งาน
- เว็บไซต์ที่ใช้ค้นหาข้อมูลในเครือข่ายอินเทอร์เน็ต (Search) : เว็บไซต์แบบนี้จะเป็นเว็บไซต์ที่จะให้ผู้ใช้งานสามารถที่จะค้นหาข้อมูลที่ผู้ใช้งานใจจากเว็บไซต์ๆ โดยผู้ใช้งานจะต้องใส่คำที่ต้องการจะหา (Keyword) หรือข้อมูลที่ต้องการค้นหาแล้วทางเว็บไซต์จะทำการค้นหาให้แสดงรายการเว็บไซต์ที่มีข้อมูลที่อาจจะตรงหรือใกล้เคียงกับข้อมูลที่ผู้ใช้งานต้องการจะค้นหาซึ่งความถูกต้องของการค้นหานั้นก็ขึ้นการรูปแบบหรือเทคโนโลยีที่เว็บไซต์ที่ให้บริการค้นหาข้อมูลใช้
- เว็บไซต์ที่เป็นประตูสู่บริการด้านอื่น (Gateway to other services) : เว็บไซต์หลายๆแห่งจะให้บริการอื่นเช่น กลุ่มข่าว (Newsgroups), จดหมายอิเล็กทรอนิกส์ (Email), ห้องสนทนา (Chatroom) เช่นเว็บไซต์สำหรับกลุ่มข่าวเกี่ยวกับระบบเครือข่ายก็อาจจะให้ผู้ใช้งานสามารถที่จะลงทะเบียนเป็นสมาชิกเพื่อรับข้อมูลข่าวสารเกี่ยวกับระบบเครือข่ายได้

2.3.3.1.2 เว็บเซิร์ฟเวอร์

เว็บเซิร์ฟเวอร์เป็นโปรแกรมที่ใช้ในการจัดการการร้องขอแบบ HTTP ที่ถูกส่งมาจากผู้ร้องขอเว็บเพจหรือรีซอร์สบนเว็บไซต์ โดยเว็บเซิร์ฟเวอร์จะต้องมีการเชื่อมต่อกับระบบเครือข่ายและจะต้องมี Memory, Harddisk, I/O Device รวมถึงโปรแกรมที่ใช้ในการจัดการการร้องขอแบบ HTTP ซึ่งเว็บเซิร์ฟเวอร์จะต้องมีความสามารถในการรองรับการร้องขอแบบ HTTP จำนวนมากจากผู้ใช้ต่างๆได้ ซึ่งจะรองรับได้เพียงใดก็ขึ้นกับโปรแกรมและเครื่องที่ใช้ ภายในเว็บเซิร์ฟเวอร์อาจจะมีการทำงานบริการอื่นๆได้เช่น Email, FTP

2.3.3.2 การจัดการการร้องขอจากผู้ใช้

2.3.3.2.1 การจัดการกับการร้องขอของผู้ใช้งาน

- อ่านและแปลงข้อมูลการร้องขอแบบ HTTP : เว็บเซิร์ฟเวอร์จะอ่านข้อมูลการร้องขอในการร้องขอแบบ HTTP ที่ส่งมา โดย Header Control จะประกอบด้วย Request LINE เช่น GET และ URL ที่ทำการร้องขอเช่น www.it.kmitl.ac.th อีกทั้งจะทำการดึงเอาข้อมูลของการร้องขออื่นๆออกมาจากข้อมูลการร้องขอแบบ HTTP ที่ส่งมาด้วย เช่น Cookies, If-Modified-Since เป็นต้น
- ทำการแปลง URL ให้เป็นในรูปของชื่อของไฟล์ : เว็บเซิร์ฟเวอร์จะทำการแปลง URL ให้เป็นชื่อของไฟล์ที่มีอยู่ในเครื่องเว็บเซิร์ฟเวอร์โดยการแปลงอาจจะทำการแปลงแบบตรงๆเลย เช่น Directory เริ่มต้นของเว็บไซต์ www.it.kmitl.ac.th คือ C:\IT ถ้ามีการร้องขอ www.it.kmitl.ac.th/index.html ก็จะทำให้การแปลงเป็นการร้องขอของ C:\IT\index.html
- พิจารณาว่าการร้องขอนั้นจำเป็นต้องมีการตรวจสอบสิทธิของผู้ใช้หรือไม่ (authorized): ก่อนที่จะทำการส่งการตอบกลับแบบ HTTP กลับไปให้ผู้ใช้งาน เว็บเซิร์ฟเวอร์จะต้องมีการตรวจสอบก่อนว่าผู้ใช้งานนั้นมีสิทธิในการเข้าถึงหรือร้องขอเว็บเพจหรือรีซอร์สนั้นๆหรือไม่ ถ้ามีเว็บเซิร์ฟเวอร์จะต้องมีการส่งการตอบกลับแบบ HTTP ที่มี Header บอกทางเว็บไคลเอนต์เพื่อให้มีการแสดงกล่องข้อความว่าให้ผู้ใช้งานแสดงชื่อผู้ใช้งาน (Username) และรหัสผ่านก่อน (Password) ของผู้ที่มีสิทธิใช้งานก่อน
- ส่งข้อมูลของเว็บเพจหรือรีซอร์สนั้นๆกลับไปให้ผู้ใช้งาน : เว็บเซิร์ฟเวอร์จะทำการสร้าง -ข้อมูลการตอบกลับแบบ HTTP ที่จะมีข้อมูล Status Code ของการตอบกลับแบบ HTTP รวมถึงข้อมูลของเว็บเพจหรือรีซอร์สนั้นๆส่งกลับไปให้ผู้ใช้งาน

ในการจัดการการร้องขอบางครั้งเว็บเซิร์ฟเวอร์อาจจะต้องมีการเก็บบันทึกข้อมูลของการร้องขอแบบ HTTP หรือการตอบกลับแบบ HTTP ไว้ด้วย เช่น เว็บเซิร์ฟเวอร์อาจจะมีเก็บไอพีแอดเดรสของผู้ใช้, URL ที่ผู้ใช้งานร้องขอ, เวลาที่มีการร้องขอไว้ใช้ไฟล์ไฟล์หนึ่งที่เรียกว่า “ล็อกไฟล์ (Log File)”

ในข้อมูลการตอบกลับแบบ HTTP ที่ถูกส่งจากเว็บเซิร์ฟเวอร์นั้นไม่จำเป็นจะต้องมีข้อมูลของเว็บเพจหรือรีซอร์สเสมอไปอย่างเช่นในกรณีที่มีการร้องขอแบบ HTTP ของผู้ใช้งานส่งมาเป็น If-Modified-Since Header ถ้าเว็บเพจหรือรีซอร์สที่ทำการร้องขอไม่ได้มีการเปลี่ยนแปลงในเวลาของ If-Modified-Since Header แล้วเว็บเซิร์ฟเวอร์ก็จะตอบกลับด้วย Not-Modified Header ในข้อมูลการตอบกลับแบบ HTTP เท่านั้น

2.3.3.2.2 การควบคุมการเข้าถึงเว็บเซิร์ฟเวอร์

เว็บเซิร์ฟเวอร์อาจจะต้องมีการจำกัดการเข้าถึงของผู้ใช้ที่เข้ามาใช้งานแต่ละคน กระบวนการควบคุมการเข้าถึง (Access Control) จะเป็นการรวมกระบวนการ “การยืนยันตัวตนของผู้ใช้ (Authentication)” ที่ใช้ในการบ่งบอกว่าใครเป็นผู้ร้องขอเว็บเพจหรือรีซอร์สนั้นและ “การบอกสิทธิของผู้ใช้ (Authorization)” ซึ่งใช้ในการตรวจสอบว่าผู้ใช้มีสิทธิในการเข้าถึงเว็บเพจหรือรีซอร์สนั้นหรือไม่

การยืนยันตัวตน (AUTHENTICATION)

การทำงานแบบไคลเอนต์-เซิร์ฟเวอร์นั้นการยืนยันตัวตนจะเป็นการถามชื่อผู้เข้าใช้ (Username) และรหัสผ่าน (Password) ของผู้ใช้งาน ในการทำงานแบบนี้เว็บเซิร์ฟเวอร์จะทำการเก็บรักษารหัสผ่านของผู้ใช้งานไว้โดยจะประกอบด้วยชื่อผู้เข้าใช้ (Username) และรหัสผ่าน (Password) ของผู้ใช้ที่ต้องการยืนยันตัวตน การเก็บรหัสผ่านอาจจะเก็บในรูปแบบที่มีการเข้ารหัสหรือไม่ก็ได้ ในการสร้างเซสชัน (Session) เพื่อร้องขอเว็บเพจหรือรีซอร์สใดของผู้ใช้งานจะต้องมีการให้ทางผู้ส่งชื่อผู้เข้าใช้และรหัสผ่านมาด้วยแล้วทางเว็บเซิร์ฟเวอร์จะตรวจสอบว่าชื่อผู้เข้าใช้และรหัสผ่านถูกต้องหรือไม่ ถ้าถูกต้องเซสชันระหว่างเว็บเบราว์เซอร์ผู้ใช้งานและเว็บเซิร์ฟเวอร์ก็จะถูกสร้างขึ้น ถ้ามีการยกเลิกเซสชันแล้ว ผู้ใช้งานจะต้องมีการส่งชื่อผู้เข้าใช้และรหัสผ่านอีกครั้งในการสร้างเซสชันใหม่

เซสชัน (Session) ก็คือการเชื่อมต่อในการส่งเว็บเพจหรือรีซอร์สหนึ่งๆ ดังนั้นเว็บเซิร์ฟเวอร์จะต้องมีการยืนยันตัวตนในทุกๆ เซสชันซึ่งทำให้ผู้ใช้งานจะต้องทำการส่งชื่อผู้เข้าใช้และรหัสผ่านให้ทุกครั้งดังนั้นเว็บเบราว์เซอร์ของผู้ใช้จะมีความสามารถการเก็บชื่อผู้เข้าใช้และรหัสผ่านที่ได้มีการส่งไปให้กับเว็บเซิร์ฟเวอร์ในครั้งแรกไว้ ดังนั้นการร้องขอต่างๆ ที่ถูกส่งภายหลัง ผู้ใช้งานก็ไม่จำเป็นต้องมีการใส่ชื่อผู้เข้าใช้และรหัสผ่านอีกครั้งเพราะเว็บเบราว์เซอร์จะทำการใส่ชื่อผู้เข้าใช้และรหัสผ่านไว้ใน Request Header ให้เอง และเว็บเบราว์เซอร์จะเก็บชื่อผู้เข้าใช้และรหัสผ่านไว้จนกว่าจะมีการปิดเว็บเบราว์เซอร์นั้น

สำหรับรูปแบบในการยืนยันตัวตนนั้นก็มียหลายแบบเช่น Basic Authentication, Digest Access Authentication เป็นต้น

การตรวจสอบสิทธิ (AUTHORIZATION)

การตรวจสอบสิทธิเป็นการที่จะทำให้เว็บเซิร์ฟเวอร์ใช้ในการตรวจสอบว่าการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆ เพราะเว็บเพจหรือรีซอร์สต่างๆ ในเว็บเซิร์ฟเวอร์จะมีการควบคุมการเข้าถึงอยู่ เช่น Admin.asp อาจจะสามารถเข้าถึงได้เฉพาะผู้ใช้งานที่มีสิทธิเป็น Superuser เท่านั้น ผู้ใช้ทั่วไปไม่สามารถเข้าถึงได้ โดยสิทธิในการเข้าถึงรีซอร์สต่างๆ ในเว็บเซิร์ฟเวอร์จะถูกเก็บไว้เรียกว่า

Access Control List ที่จะแสดงว่าผู้ใช้แต่ละคนมีสิทธิในการเข้าถึงรีซอร์สใดบ้าง ซึ่งรายละเอียดเกี่ยวกับการสร้างและการเก็บรักษา Access Control List นั้นจะขึ้นอยู่กับแต่ละโปรแกรมเว็บเซิร์ฟเวอร์

การตรวจสอบสิทธินั้นส่วนมากจะทำเป็น Directory มากกว่าที่จะเป็นรีซอร์สๆหนึ่ง สำหรับการตรวจสอบสิทธินั้นจะทำให้ประสิทธิภาพของเว็บเซิร์ฟเวอร์ลดลงมากเพราะเว็บเซิร์ฟเวอร์จะต้องมีการตรวจสอบผู้เข้าใช้และรหัสผ่านทุกครั้งที่มีการเข้าถึงดังนั้นควรกำหนดให้มีการตรวจสอบสิทธิ เฉพาะรีซอร์สหรือ Directory ที่จำเป็นเท่านั้น

2.3.3.2.3 การสร้างการตอบกลับแบบไม่คงที่ (Dynamically generated responses)

การทำงานโดยทั่วไปของเว็บเซิร์ฟเวอร์จะมีการส่งข้อมูลเว็บเพจที่เป็นแบบคงที่ (Static) แต่ต่อมาก็ได้มีการทำงานของเว็บเพจที่เป็นแบบไม่คงที่ (Dynamic) เกิดขึ้น โดยเว็บเพจแบบไม่คงที่จะมีการทำงานอื่นร่วมอยู่ด้วย ข้อมูลของเว็บเพจแบบไม่คงที่นั้นจะถูกสร้างขึ้นเมื่อมีการร้องขอจากผู้ใช้งาน ดังนั้นผู้ใช้งานที่เข้าถึงเว็บเพจแบบไม่คงที่แต่ละคนอาจจะได้รับข้อมูลของเว็บเพจที่ไม่เหมือนกัน โดยเว็บเพจแบบไม่คงที่สามารถถูกสร้างได้จากหลายรูปแบบ เช่นการใช้ Server-Side Includes/Scripts สำหรับภาษาโปรแกรมที่ใช้ในการสร้าง Server-side ก็เช่น Active Server Page(ASP), Professional Homepage(PHP), Perl, Java Server Page(JSP)

สำหรับ Server-Side Include/Script นั้นเมื่อมีการร้องขอเว็บเพจที่เป็นแบบ Server-Side Include/Script แล้ว เว็บเซิร์ฟเวอร์จะทำการประมวลผล Server-Side Include/Script เว็บเพจนั้นเมื่อได้เป็นผลลัพธ์ออกมาแล้วก็จะทำการส่งเว็บเพจผลลัพธ์นั้นกลับไปให้ผู้ร้องขอ ในการประมวลผลนั้นอาจจะต้องมีการใช้ตัวแปร (Parameter) บางอย่างผ่านทางผู้ร้องขอส่งมาด้วย

การส่งตัวแปร (Parameter) ในการร้องขอ Server-Side Include/Script นั้นสามารถส่งได้ 2 แบบ คือการส่งผ่าน URL ของเว็บเพจที่เป็น Server-Side กับส่งโดยการผ่านแท็ก <FORM> ของเว็บเพจ โดยการส่งผ่าน URL นั้นจะส่งให้รูปที่มี ? เป็นตัวบอกว่าการส่งตัวแปร (Parameter) ให้กับเว็บเพจนั้นๆ และแต่ละตัวแปร (Parameter) จะคั่นด้วย & เช่น มีการร้องขอ

“www.it.kmitl.ac.th/login.asp?cost=10&name=wisit”

จากการร้องขอข้างบนจะเป็นการส่งตัวแปร (Parameter) ที่เรียกว่าเป็นการส่งแบบ GET Method เพราะตัวแปร (Parameter) จะส่งมาใน URL เลขจากตัวอย่างเป็นการส่งตัวแปร (Parameter) ที่ชื่อ Cost ซึ่งมีค่า 10 และส่งตัวแปร (Parameter) ที่ชื่อ Name มีค่า wisit ไปให้กับ เว็บเพจ Login.asp ซึ่งเว็บเซิร์ฟเวอร์ก็จะทำการประมวลผล login.asp โดยใช้ค่าตัวแปร (Parameter) ตามที่ส่งมา

สำหรับการส่ง Parameter อีกแบบจะเรียกว่าส่งแบบ POST Method โดยจะส่งผ่านแท็ก <FORM> ในเว็บเพจที่เป็น Server-Side Include/Script เช่นในเว็บเพจมีฟอร์มดังรูป ซึ่งเมื่อ Submit แล้วส่งจะมีการส่งค่า Parameter ไปยัง Login.asp

The image shows a login form with a light gray background. It contains two input fields: one for 'Username' and one for 'Password'. Below the fields is a button labeled 'Login'.

รูปที่ 2.16 แสดงตัวอย่างของการส่งตัวแปร (Parameter) ผ่านแท็ก <FORM> ในเว็บเพจ

การส่งตัวแปร (Parameter) แบบนี้ข้อมูลตัวแปร (Parameter) จะอยู่ในส่วนของ Entity Body ของข้อมูลการร้องขอแบบ HTTP ที่ส่งไปให้ทางเว็บเซิร์ฟเวอร์ เมื่อเว็บเซิร์ฟเวอร์ได้รับการร้องขอ Login.asp แล้วก็จะทำการดึงค่าตัวแปร (Parameter) ที่อยู่ใน Entity Body ของข้อมูลการร้องขอแบบ HTTP ออกมาเพื่อใช้ในการประมวลผล

การทำงานของเว็บเซิร์ฟเวอร์ที่มีการสร้างเว็บเพจแบบไม่คงที่นั้นจะทำให้เว็บเซิร์ฟเวอร์มีการทำงานมากขึ้น ดังนั้นจึงทำให้ประสิทธิภาพการทำงานของเว็บเซิร์ฟเวอร์ลดลงกว่าเว็บเซิร์ฟเวอร์ที่ให้บริการเฉพาะเว็บเพจแบบคงที่ อีกทั้งยังมีความเสี่ยงเกี่ยวกับด้านความปลอดภัยของเว็บเซิร์ฟเวอร์ด้วยเพราะอาจมีการสร้าง Server-Side Include/Script ที่มีการเข้าถึงไฟล์หรือรีซอร์สต่างๆ บนเว็บเซิร์ฟเวอร์โดยตรงได้ ทำให้ Server-Side Include/Script สามารถลบหรือแก้ไขไฟล์หรือรีซอร์สต่างๆ ได้ ดังนั้นจะต้องมีการตั้งค่าการทำงานเกี่ยวกับการเข้าถึงรีซอร์สต่างๆ อย่างระมัดระวัง

2.3.3.2.4 การสร้างและใช้งานคุกกี้

คุกกี้ (Cookies) นั้นเป็นหนทางหนึ่งที่ทำให้เว็บเซิร์ฟเวอร์สามารถที่จะเก็บข้อมูลบางอย่างเกี่ยวกับผู้ใช้งานได้ ซึ่งเมื่อเว็บเซิร์ฟเวอร์ต้องการที่จะให้เว็บเบราว์เซอร์ของผู้ใช้งานสร้าง Cookie นั้นเว็บเซิร์ฟเวอร์จะมีการส่งการตอบกลับแบบ HTTP ที่มี Header เป็น “Set-Cookie” พร้อมกับชื่อและค่าของคุกกี้ นั้นให้กับเว็บเบราว์เซอร์ จากนั้นเว็บเบราว์เซอร์จะทำการสร้างคุกกี้ นั้นและเก็บไว้ที่เครื่องของผู้ใช้ และการร้องขอครั้งถัดไปของผู้ใช้ก็จะมีคุกกี้ นั้นส่งมาด้วย

2.3.3.3 การใช้ข้อมูลในการสร้างการร้องขอแบบ HTTP ร่วมกัน

แม้ว่าเว็บเซิร์ฟเวอร์จะสามารถจัดการการร้องขอแบบ HTTP ได้โดยอิสระ โดยจะมีการสร้าง โพรเซส (Process) ขึ้นมาจัดการกับการร้องขอแบบ HTTP แต่ละอัน ซึ่งการทำงานอย่างนี้ทำให้เว็บเซิร์ฟเวอร์มีการทำงานที่หนัก ดังนั้นก็มีวิธีที่จะช่วยลดการทำงานนี้

2.3.3.3.1 การใช้การร้องขอแบบ HTTP และการตอบกลับ HTTP ร่วมกัน

ในการที่เว็บเซิร์ฟเวอร์จะสร้างข้อมูลการตอบกลับแบบ HTTP แล้วส่งกลับไปให้ทางผู้ร้องขอ นั้น เว็บเซิร์ฟเวอร์จะต้องมีการอ่านข้อมูลจากแฟ้มข้อมูลบนดิสก์ จากนั้นก็ดึงมาเก็บไว้ในหน่วยความจำ จากนั้นถึงทำการสร้างเป็นการร้องขอแบบ HTTP ได้ ซึ่งการทำงานแบบนี้ก็ทำให้มีความล่าช้าในการทำงานมาก เพราะถ้ามีการร้องขอเป็นจำนวนมากเว็บเซิร์ฟเวอร์ก็ต้องมีการทำงานดังที่กล่าวมาแล้วซ้ำแล้วซ้ำอีกในแต่ละการร้องขอ ทั้งๆที่เป็นเว็บเพจเดียวกัน ดังนั้นจึงมีการนำเสนอการทำงานที่เรียกว่า “แคชซิง(caching)” บนเว็บเซิร์ฟเวอร์ขึ้น

การแคชซิงบนเว็บเซิร์ฟเวอร์จะไม่เหมือนกับการแคชซิงบนเว็บเบราว์เซอร์เพราะการแคชซิงบนเว็บเซิร์ฟเวอร์นั้นสำหรับเว็บเพจแบบคงที่ที่จะทำการเก็บข้อมูลของเว็บเพจนั้นที่ได้มีการส่งไปให้ยังผู้ใช้คนก่อนๆ ไว้ในหน่วยความจำ จากนั้นเมื่อมีผู้ใช้คนอื่นร้องขอเว็บเพจเดียวกันนี้เว็บเซิร์ฟเวอร์ก็สามารถนำข้อมูลของเว็บเพจนั้นจากหน่วยความจำมาสร้างเป็นข้อมูลการตอบกลับแบบ HTTP แล้วส่งกลับไปให้ผู้ใช้ได้เลย แต่การแคชซิงของเว็บเพจแบบคงที่นั้นเว็บเซิร์ฟเวอร์จะต้องมีการตรวจสอบดูว่าเว็บเพจที่ได้มีการแคชไว้ นั้น ได้รับการแก้ไขหรือไม่ ถ้าได้รับการแก้ไขเว็บเซิร์ฟเวอร์ก็ต้องมีการดึงเอาข้อมูลของเว็บเพจล่าสุดมาแคชซิงไว้

สำหรับการแคชเว็บเพจแบบไม่คงที่นั้นก็สามารทำได้ โดยเว็บเซิร์ฟเวอร์จะทำการเก็บผลลัพธ์ของการประมวลผลของเว็บเพจแบบไม่คงที่ที่มีการร้องขอบ่อยไว้ เมื่อมีการร้องขอเว็บเพจแบบไม่คงที่ที่มีตัวแปร (Parameter) แบบเดิมก็สามารถที่จะดึงเอาผลลัพธ์ที่ได้ประมวลผลไว้แล้วส่งกลับไปให้ผู้ใช้ได้เลย แต่การทำงานแคชซิงแบบนี้ก็ต้องมีการตรวจสอบก่อนด้วยว่าผลลัพธ์ของการประมวลผลเว็บเพจแบบไม่คงที่นั้น ได้มีการเปลี่ยนแปลงหรือไม่ เช่นถ้าเว็บเพจแบบไม่คงที่ที่ต้องการติดต่อกับฐานข้อมูล เมื่อข้อมูลในฐานข้อมูลมีการเปลี่ยนแปลงผลลัพธ์ที่มีการแคชซิงไว้ก็ไม่สามารถใช้ได้

2.3.3.3.2 การใช้งาน METADATA ของการร้องขอแบบ HTTP ร่วมกัน

อย่างที่ได้อธิบายมาแล้วว่าเว็บเซิร์ฟเวอร์จะต้องมีการสร้างโพรเซสเพื่อใช้ในการจัดการกับการร้องขอของผู้ใช้ที่ได้รับ ดังนั้นเว็บเซิร์ฟเวอร์สามารถที่จะแคชซิงข้อมูลแบบอย่างของโพรเซสที่ใช้จัดการการร้องขอเว็บเพจหนึ่งไว้ เช่น พอยเตอร์ (Pointer) ที่ชี้ไปยังข้อมูลของเว็บเพจนั้นบนดิสก์, ข้อมูลการแปลงจาก URL ไปเป็นชื่อไฟล์, Header ของการตอบกลับแบบ HTTP ของเว็บเพจนี้ไว้ เมื่อมีการร้องขอเว็บเพจเดียวกันนี้จากผู้ใช้อื่นๆ เว็บเซิร์ฟเวอร์ก็สามารถสร้างโพรเซสที่ใช้ในการ

จัดการการร้องขอโดยนำข้อมูลของโพรเซสก่อนหน้ามาใช้ได้เลย ซึ่งการจะสามารถช่วยลดเวลาในการจัดการการร้องขอผู้ใช้ได้

2.3.3.4 รูปแบบต่างๆ ของเว็บเซิร์ฟเวอร์

ในหัวข้อนี้จะกล่าวถึงรูปแบบโมเดลต่างๆ ที่เว็บเซิร์ฟเวอร์ใช้ในการจัดการกับรีซอร์สของเว็บเซิร์ฟเวอร์เพื่อรองรับการร้องขอของผู้ใช้

2.3.3.4.1 เว็บเซิร์ฟเวอร์แบบ EVENT-DRIVEN

เป็นวิธีการที่ง่ายที่สุดคือจะมี 1 โพรเซสในการจัดการเพียง 1 การร้องขอทั้งหมด ณ เวลาหนึ่งๆ โดยสิ่งที่จะต้องทำก็คือ โพรเซสจะต้องทำขอรับการร้องขอ, สร้างข้อมูลการตอบกลับแบบ HTTP และส่งกลับไปยังผู้ร้องขอ จากนั้นก็จะถึงไปจัดการกับการร้องขอถัดไป EVENT-DRIVEN จะใช้หลักการนี้ในการทำงานแต่ EVENT-DRIVEN จะทำการแบ่งการทำงานออกเป็นงานย่อยๆ คือ การขอรับการร้องขอ, อ่านและแปลการร้องขอแบบ HTTP, ค้างเว็บเพจหรือรีซอร์สที่ร้องขอ, ส่งเป็นการตอบกลับแบบ HTTP กลับไปให้ผู้ร้องขอ ซึ่งทำการที่โพรเซสทำงานส่วนย่อยๆ นี้จะมีช่วงเวลาที่จะต้องรอหรือมีการทำงานเกี่ยวกับ I/O Device เช่น Diskdrive ที่จะใช้เวลาในการจัดการหลังจากที่มีการร้องขอ ดังนั้นช่วงเวลาที่โพรเซส กำลังรอนานเกี่ยวกับ I/O อยู่โพรเซสก็สามารถที่จะปรับเปลี่ยนไปจัดการกับการร้องขออันถัดไปได้ นอกเหนือจากนั้นการทำงานแบบนี้ยังเป็นการควบคุมความเป็นลำดับ (Serializing) ของการร้องขอของแต่ละผู้ร้องขอได้ เช่น 2 ผู้ใช้งานอาจจะต้องการเขียนหรือแก้ไขเว็บเพจหรือรีซอร์สเดียวกัน EVENT-DRIVEN จะสามารถทำให้แน่ใจได้ว่าการแก้ไขนั้นจะเป็นไปตามลำดับที่ถูกต้อง อีกทั้งถ้าเป็นการร้องขอรีซอร์สเดียวกันยังสามารถใช้ประโยชน์จากการแคชซึ่งได้อีกด้วย

แต่การทำงานแบบ EVENT-DRIVEN นั้นจะต้องมีการจัดการเกี่ยวกับ Non-Blocking และ Blocking System เช่น พวกร I/O ต่างตามที่ได้อีกกล่าวมาแล้ว ดังนั้น โปรแกรมเว็บเซิร์ฟเวอร์จะต้องการติดต่อกับระบบปฏิบัติการที่ยุ่งยากมากขึ้นๆ ดังนั้นเว็บเซิร์ฟเวอร์ส่วนใหญ่จะไม่ใช้การทำงานแบบ EVENT-DRIVEN

2.3.3.4.2 เว็บเซิร์ฟเวอร์แบบ PROCESS-DRIVEN

ในการแบบนี้จะใช้โพรเซส 1 โพรเซสในการจัดการ 1 การร้องขอซึ่งจะแตกต่างจาก EVENT-DRIVEN ที่จะใช้เพียง 1 โพรเซสในการจัดการการร้องขอทั้งหมด ดังนั้นถ้าสมมติโพรเซสหนึ่งที่มีการจัดการการร้องขออยู่ก็ต้องมีการรอเกี่ยวกับ I/O Device โปรแกรมเว็บเซิร์ฟเวอร์ก็สามารถที่จะเปลี่ยนไปประมวลผลโพรเซสที่จัดการการร้องขออื่น

เว็บเซิร์ฟเวอร์แบบ PROCESS-DRIVEN นั้นจะมีโพรเซสหนึ่งที่เป็นโพรเซสหลักเมื่อมีการร้องขอจากผู้ใช้ส่งมายังเว็บเซิร์ฟเวอร์แล้ว โพรเซสหลัก จะทำการสร้างโพรเซสย่อยขึ้นมาจัดการการ

ร้องขอนั้น แล้วเมื่อมีการจัดการการร้องขอเรียบร้อยแล้ว โพรเซสย่อยที่ถูกสร้างขึ้นมานั้นก็จะถูกยกเลิก แต่โพรเซสหลักอาจจะต้องการลดการทำงานที่ลดประสิทธิภาพของเว็บเซิร์ฟเวอร์ในการที่จะต้องสร้างโพรเซสขึ้นใหม่ทุกครั้งที่มีการร้องขอเข้ามา โดยโพรเซสหลักอาจจะทำการสร้างโพรเซสย่อยๆไว้ก่อนเลยหลายๆ โพรเซสไว้เลยแต่กำหนดสถานะของโพรเซสย่อยนั้นไว้ว่าอยู่ในภาวะรอการทำงาน จากนั้นเมื่อมีการร้องขอส่งมา โพรเซสหลักก็กำหนดสถานะของโพรเซสย่อยหนึ่งๆที่ได้มีการสร้างไว้แล้วเป็นทำงาน แล้วให้โพรเซสนั้นจัดการกับการร้องขอที่เข้ามา

แต่การทำงานแบบ PROCESS-DRIVEN นั้นก็มีข้อเสียคือ อย่างแรกคือ ประสิทธิภาพที่ลดลงเมื่อมีการต้องสลับเปลี่ยนไปทำงานโพรเซสต่างๆ เพราะอาจจะต้องมีการจัดเก็บข้อมูลของโพรเซสปัจจุบันเช่นเก็บค่า Address ของ Memory ต่างๆ, ค่า Counter ต่างๆ จากนั้นก็ต้องทำการดึงข้อมูลของโพรเซสใหม่ขึ้นมาใช้ประมวลผล ซึ่งใน EVENT-DRIVEN นั้นใช้โพรเซสเดียวกันนั้นค่า Address ต่างๆจึงไม่เปลี่ยนแปลง อีกทั้งยังเกิดปัญหาในการที่โพรเซส 2 โพรเซสต้องมีการใช้รีซอร์สร่วมกัน ดังนั้นต้องเสียการทำงานในการดึงข้อมูลเข้าแล้วออกไปมาในการใช้งาน

2.3.3.4.3 เว็บเซิร์ฟเวอร์แบบ HYBRID

เว็บเซิร์ฟเวอร์แบบ HYBRID นั้นจะเป็นการรวมเอาข้อดีของทั้ง EVENT-DRIVEN และ PROCESS-DRIVEN เข้าด้วยกัน ซึ่งในการรวมการทำงานทั้งสองอย่างนี้โดย Hybrid server ก็มีการทำงานหลายๆแบบ

- แบบแรกจะมีการแบ่งส่วนการทำงานที่อิสระย่อยๆที่เรียกว่า “Thread” แต่ละ Thread จะมีการทำงานที่อิสระในโพรเซสดังนั้นเว็บเซิร์ฟเวอร์สามารถที่จะกำหนดให้แต่ละ Thread ในโพรเซสสามารถที่จะจัดการกับการร้องขอของผู้ใช้ที่แตกต่างกันได้ ซึ่งส่วนนี้เป็นการทำงานที่คล้ายกับ EVENT-DRIVEN แต่เพราะแต่ละ Thread มีการทำงานที่อิสระ ดังนั้นเมื่อ Thread ใด Thread หนึ่งในโพรเซสต้องมีการรอเกี่ยวกับ I/O แล้ว Thread อื่นในโพรเซสเดียวกันก็สามารถที่ทำงานต่อไปได้ แล้วประสิทธิภาพในการเปลี่ยนไปทำงานที่แต่ละ Thread ยังดีกว่าในการปรับเปลี่ยนการทำงานระหว่างโพรเซสเพราะ Thread อยู่ภายใต้โพรเซสเดียวกันทำให้ใช้ Address ของ Memory ร่วมกัน อีกทั้งการใช้การทำงานแบบ Thread ยังช่วยในการแก้ปัญหาในการจัดการเกี่ยวกับรีซอร์สที่มีการใช้งานร่วมกันด้วย
- แบบที่สอง เว็บเซิร์ฟเวอร์นั้นอาจจะจัดการเกี่ยวกับการร้องขอที่ไม่มีการติดต่อกับ I/O เช่นมีความผิดพลาดเช่นการร้องขอเว็บเพจหรือรีซอร์สที่ไม่มีอยู่บนเว็บเซิร์ฟเวอร์ ในกรณีนี้ ถ้าเว็บเซิร์ฟเวอร์มีการทำงานแบบ PROCESS-DRIVEN ก็จะทำให้เกิดการเสียเวลาในการสร้างโพรเซสเพื่อเพียงแค่ตอบกลับเป็นการตอบกลับแบบ HTTP ที่แสดงความผิดพลาดเท่านั้น ดังนั้นในกรณีนี้เว็บเซิร์ฟเวอร์ควรที่จะมีการทำงานแบบ EVENT-DRIVEN เพราะไม่ต้องเสียเวลาในการสร้างโพรเซสใหม่และยังสามารถใช้ประโยชน์จาก Header ของข้อมูลการ

ตอบกลับแบบ HTTP ที่ได้มีการแคชซึ่งไว้ด้วย ดังนั้นเว็บเซิร์ฟเวอร์แบบ HYBRID นี้จะมี โพรเซสหลักที่มีการทำงานแบบ EVENT-DRIVEN แล้วเมื่อมีการร้องขอเข้ามาที่ต่อมีการติดต่อกับ I/O แล้วโพรเซสหลักก็จะทำการสร้างโพรเซสลูกขึ้นมาจัดการ แต่ถ้าการร้องขอนั้น ไม่ต้องการทำงานเกี่ยวกับ I/O โพรเซสก็สามารถจัดการการร้องขอนั้นได้เลย

2.3.3.5 การตั้งเว็บไซต์บนเว็บเซิร์ฟเวอร์ (SERVER HOSTING)

2.3.3.5.1 การตั้งหลายๆเว็บไซต์บนเว็บเซิร์ฟเวอร์เครื่องเดียว (Multiple Website on single web server)

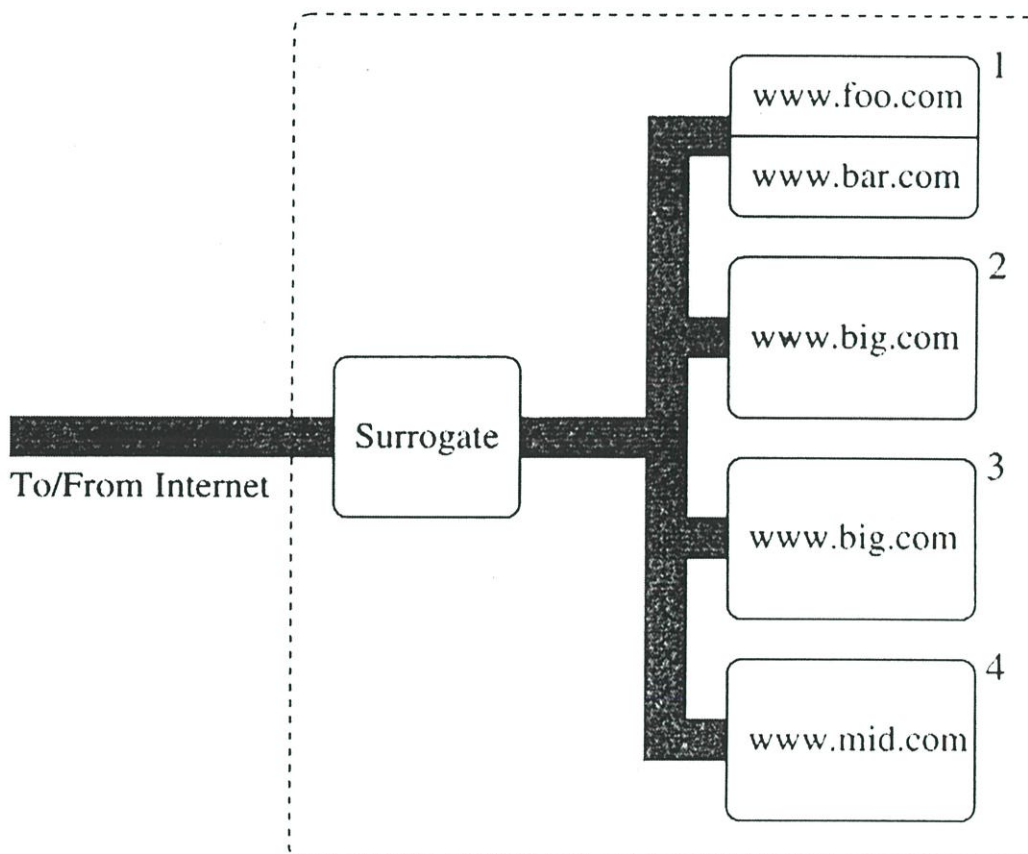
รูปแบบการของเว็บเซิร์ฟเวอร์นี้จะมีการเอาเว็บไซต์หลายๆ เว็บไซต์ลงไปบนเครื่องเว็บเซิร์ฟเวอร์เครื่องเดียวเท่านั้น ดังนั้นเว็บเซิร์ฟเวอร์เครื่องเดียวนี้จะมีหน้าที่ใช้การจัดการการร้องขอของเว็บไซต์ทั้งหมดที่มีอยู่ ซึ่งเว็บเซิร์ฟเวอร์นี้จะให้บริการโดย Hosting Company ที่จะให้บริการเช่าเครื่องเว็บเซิร์ฟเวอร์ในการสร้างเว็บไซต์ขององค์กรต่างๆ ซึ่งการทำงานแบบ Multiple Website นั้นจะมีสองแบบ

- โฮสต์เสมือน(Virtual host) : เว็บเซิร์ฟเวอร์แบบนี้จะใช้ไอพีแอดเดรส (IP Address) เดียวกันในแต่ละ เว็บไซต์แต่ละจะใช้โดเมนเนมในการแยกความแตกต่างระหว่างเว็บไซต์ซึ่งการทำงานแบบนี้โปรแกรมเว็บเซิร์ฟเวอร์จะต้องสนับสนุนการทำงานของโฮสต์เสมือนด้วยและจะใช้บน HTTP/1.1 เท่านั้น
- การใช้ไอพีเดียว(Dedicate IP) : เว็บเซิร์ฟเวอร์แบบนี้แต่ละเว็บไซต์จะมีไอพีแอดเดรส (IP address) เป็นของตนเอง

2.3.3.5.2 การตั้งเว็บไซต์เดียวบนเว็บเซิร์ฟเวอร์หลายๆเครื่อง (Multiple machine for single web site)

สำหรับเว็บไซต์ที่มีจำนวนผู้เข้ามาใช้งานจำนวนมาก การใช้เครื่องเพียงหนึ่งเครื่องเป็นเว็บเซิร์ฟเวอร์ในการจัดการกับการร้องขอจำนวนมากนั้น อาจจะทำให้ใช้เวลาในการจัดการการร้องขอนาน ดังนั้นจึงมีการสร้างหรือจัดกลุ่มของเครื่องเว็บเซิร์ฟเวอร์ให้จัดการเว็บไซต์เดียวกัน โดยจะต้องมีกลไกในการจัดการเกี่ยวกับการแปลงจากโดเมนเนมของเว็บไซต์เป็นไอพีแอดเดรส ถ้าสมมติ www.foo.com มีการใช้ 2 เครื่องเว็บเซิร์ฟเวอร์ที่มีไอพีแอดเดรสเป็น 10.1.1.1 กับ 10.1.1.2 ถ้ามีการร้องขอการแปลงโดเมนเนม “www.foo.com” มาที่โดเมนเนมเซิร์ฟเวอร์แล้วโดเมนเนมเซิร์ฟเวอร์อาจจะส่งไอพีแอดเดรส กลับไปเป็น 10.1.1.1 หรือ 10.1.1.2 ก็ได้ซึ่งอาจจะเป็นแบบสุ่มหรือตั้งค่าไว้ก็ได้

ส่วนสำคัญอีกอย่างหนึ่งคือจะต้องมีการสำเนาข้อมูลในเครื่องทุกเครื่องของเว็บไซต์เดียวกันให้มีข้อมูลที่เหมือนกันๆด้วย ซึ่งตรงนี้อาจจะใช้ Diskdrive ร่วมกันสำหรับเครื่องทุกเครื่องหรือใช้การทำงานของ RAID เข้ามาช่วยได้



รูปที่ 2.17 รูปแบบการ Hosting แบบต่างๆ

2.3.3.6 สรุป

เว็บเซิร์ฟเวอร์มีหน้าที่ในการสร้างและส่งการตอบกลับแบบ HTTP กลับไปที่ไคลเอนต์ เมื่อมีการส่งการร้องขอมาเว็บเซิร์ฟเวอร์จะใช้ URL เพื่อทำการแปลงเป็นชื่อของไฟล์ที่อยู่ในดิสก์ของเครื่องเว็บเซิร์ฟเวอร์เอง และทำการดึงไฟล์นั้นออกมาแล้วส่งกลับไปเป็นการตอบกลับแบบ HTTP เว็บเซิร์ฟเวอร์สามารถมีกลไกในการร้องการยืนยันตัวตนจากผู้ใช้ได้ นอกจากนั้นเว็บเซิร์ฟเวอร์ยังมีกลไกในการตรวจสอบสิทธิในการเข้าถึงเว็บเพจหรือริชอร์สใดๆของผู้ใช้ด้วย เว็บเพจที่เว็บเซิร์ฟเวอร์ส่งกลับไปให้ผู้นั้นมีทั้งเป็นแบบคงและเป็นแบบไม่คงที่ รูปแบบของเว็บเซิร์ฟเวอร์นั้น

มีทั้งเป็นแบบ EVENT-DRIVEN หรือ PROCESS-DRIVEN หรือเป็น HYBRID ที่เป็นการทำงานร่วมกันระหว่าง EVENT-DRIVEN และ PROCESS-DRIVEN ได้

บทที่ 3

ระบบการทำงานของพรีเฟรชชิง

3.1 กล่าวนำ

ความแพร่หลายของเว็ลด์ไวค์เว็บทำให้มีผู้ใช้ในการใช้งานอินเทอร์เน็ตเพิ่มขึ้นมาก ซึ่งทำให้การจราจรบนเครือข่ายอินเทอร์เน็ตมีความคับคั่งของข้อมูลสูงมากขึ้น และเมื่อการจราจรบนเครือข่ายอินเทอร์เน็ตคับคั่งมาก จะทำให้การเข้าถึงเว็บเพจหรือรีซอร์สใดบนอินเทอร์เน็ตมีแนวโน้มว่าจะใช้เวลาเพิ่มหรือว่านานขึ้น เพราะว่าการเข้าถึงเว็บเพจหรือรีซอร์สใดบนอินเทอร์เน็ตจะต้องมีการสร้างการเชื่อมต่อ (TCP Connection) ไปยังเซิร์ฟเวอร์จากนั้นทางแอปพลิเคชันทางด้านไคลเอนต์ (Web Client) หรือเว็บเบราว์เซอร์ ก็จะทำการส่งข้อมูลการร้องขอแบบ HTTP (HTTP Request) ของเว็บเพจหรือรีซอร์สใดที่ต้องการเข้าถึงไปยังเว็บเซิร์ฟเวอร์ (Web Server) เมื่อเว็บเซิร์ฟเวอร์ได้รับข้อมูลการร้องขอแบบ HTTP แล้วก็จะทำการดึงเอาเว็บเพจหรือรีซอร์สนั้นออกมาแล้วส่งกลับไปด้วยข้อมูลการตอบกลับแบบ HTTP (HTTP Response) และส่งกลับไปยังไคลเอนต์ซึ่งเวลาส่วนใหญ่ของกระบวนการร้องขอและการตอบกลับระหว่างเซิร์ฟเวอร์และไคลเอนต์จะเป็นช่วงเวลาที่ยืดออกของการส่งการร้องขอหรือการตอบกลับเดินทางอยู่ในเครือข่ายซึ่งถ้าเครือข่ายมีความคับคั่งแล้วจะทำให้เวลาโดยรวมของการเข้าถึงเว็บเพจหรือรีซอร์สใดเพิ่มสูงขึ้น

มีวิธีการต่างๆ ที่ถูกนำเสนอในการช่วยลดการเข้าถึงรีซอร์สต่างๆ บนอินเทอร์เน็ตเช่น Cache Replacement[1,2] , Speculative Prefetching[3-4] ซึ่งวิธีการต่างๆ เหล่านี้ก็มีประสิทธิภาพต่างกันไป แต่วิธีที่มีการใช้กันอย่างแพร่หลายในปัจจุบันคือการใช้พร็อกซีเซิร์ฟเวอร์ (Proxy Server) นั่นก็คือการใช้พร็อกซีหรือในการเก็บเว็บเพจหรือรีซอร์สต่างๆ ที่ได้มีการเข้าถึงโดยผู้ใช้งานหนึ่งแล้วไว้ เมื่อมีผู้ใช้งานอื่นต้องการเข้าถึงเว็บเพจหรือรีซอร์สเดียวกันนี้ พร็อกซีก็สามารถที่จะส่งเว็บเพจหรือรีซอร์สนั้นกลับไปให้ผู้ใช้งานได้เลย ไม่จำเป็นต้องมีการร้องขอจากเว็บเซิร์ฟเวอร์ปลายทางตามรายละเอียดของพร็อกซีที่ได้กล่าวถึงในบทที่ 2 แล้ว นอกจากนี้ยังสามารถนำพร็อกซีมาใช้ในกระบวนการที่เรียกว่า “พรีเฟรชชิง (PRE-FETCHING)” ซึ่งเป็นกระบวนการที่สามารถช่วยในการลดเวลาในการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆ เช่นเดียวกัน

3.2 ระบบพรีเฟรชชิง

สำหรับคำนิยามของการพรีเฟรชชิงก็คือ เป็นระบบที่จะทำการดึงการทำงานบางอย่างที่จะต้องเกิดขึ้นในข้อมูลการร้องขอแบบ HTTP ของผู้ใช้งานในอนาคต แล้วทำงานส่วนนั้นล่วงหน้าก่อนที่

จะต้องมีการทำงานส่วนนั้นจริง ซึ่งการทำงานอย่างนี้จะทำให้ลดเวลาในการทำงานส่วนนั้นเมื่อต้องใช้งานจริงเพราะได้มีการทำงานส่วนนั้นไว้แล้ว การทำงานที่จะทำล่วงหน้านั้นก็จะมีงานที่จำแนกได้เป็นประเภท ซึ่งจะกล่าวในภายหลัง

ระบบพีเรซซิ่งนั้นจะต้องอาศัยข้อมูลการเข้าถึงของผู้ใช้ในอดีตเพื่อใช้ในการทำนายการเข้าถึงที่จะเกิดขึ้นในอนาคตเพื่อใช้ในการทำงานล่วงหน้าก่อนที่จะเกิดการร้องขอจริง โดยข้อมูลหลักที่จะนำมาใช้เป็นข้อมูลในการทำนายมีดังนี้

3.2.1 เซิร์ฟเวอร์ล็อกไฟล์ (SERVER LOG)

โดยทั่วไปเว็บเซิร์ฟเวอร์จะทำการสร้างบันทึกการร้องขอที่เรียกว่า “ล็อก” ของเว็บเบราว์เซอร์ของผู้ใช้ไว้โดยกระบวนการนี้จะเป็นส่วนหนึ่งในการจัดการกับการร้องขอที่ได้รับจากเว็บไคลเอนต์ แต่ละเรคคอร์ดของล็อกจะแสดงการร้องขอแต่ละครั้งที่เกิดขึ้น เซิร์ฟเวอร์ล็อกไฟล์นั้นสามารถนำมาใช้ในการวิเคราะห์รูปแบบการเข้าถึงของผู้ใช้เพื่อใช้ในการทำนายการเข้าถึงในอนาคตได้ แต่อย่างไรก็ดีการร้องขอที่มีในเซิร์ฟเวอร์นั้นอาจจะไม่ถูกต้องทั้งหมด เพราะเซิร์ฟเวอร์ล็อก จะเก็บข้อมูลจากการร้องขอที่ถูกส่งเข้ามาที่เว็บเซิร์ฟเวอร์เท่านั้นดังนั้นการร้องขอที่เกิดจากผู้ใช้แต่ไม่ได้ถูกส่งมาจากเว็บเซิร์ฟเวอร์เพราะการร้องขอนั้นอาจจะถูกจัดการโดยพร็อกซีหรือแคชของเว็บเบราว์เซอร์ของผู้ใช้เอง

สำหรับข้อมูลในแต่ละเรคคอร์ดในล็อกไฟล์นั้นส่วนใหญ่จะประกอบด้วย IP Address หรือโฮสต์เนมของไคลเอนต์ (Hostname), เวลาที่มีการร้องขอส่งเข้ามา (Access time), ชื่อของเว็บเพจหรือรีซอร์สที่ทำการร้องขอและเวอร์ชันของ HTTP ที่ใช้ในการร้องขอ

3.2.2 พร็อกซีล็อกไฟล์ (PROXY LOG)

พร็อกซีนั้นจะทำงานคล้ายกับเป็นเว็บเซิร์ฟเวอร์ดังนั้นก็จะมีส่วนการทำงานที่ใช้ในการสร้างและบันทึกการร้องขอจากไคลเอนต์เช่นเดียวกับเว็บเซิร์ฟเวอร์ พร็อกซีล็อกนั้นจะให้ข้อมูลที่มีประโยชน์กว่าเซิร์ฟเวอร์ล็อก เพราะการร้องขอต่างๆ จะต้องผ่านที่พร็อกซีก่อนถึงจะมีการส่งการร้องขอนั้นไปยังเว็บเซิร์ฟเวอร์ปลายทาง ดังนั้นการใช้พร็อกซีล็อกในการวิเคราะห์รูปแบบการเข้าถึงของผู้ใช้เพื่อใช้ในการทำนายการร้องขอจึงมีความถูกต้องมากกว่า อีกทั้งพร็อกซีล็อกยังเก็บการร้องขอจากผู้ไปยังเว็บเซิร์ฟเวอร์ต่างๆ มากกว่าหนึ่งแห่ง ทำให้มีข้อมูลมากกว่าในการทำนายเมื่อเปรียบเทียบกับเซิร์ฟเวอร์ล็อกที่มีการบันทึกการร้องขอของเว็บเซิร์ฟเวอร์นั้นเท่านั้น

ยิ่งไปกว่านั้นพร็อกซีล็อกยังรวมไปถึงการร้องขอที่ถูกจัดการโดยพร็อกซีเองด้วย ซึ่งตรงนี้เซิร์ฟเวอร์ล็อกจะไม่ได้มีการบันทึกไว้เพราะไม่มีการร้องขอส่งไปถึง แต่อย่างไรก็ตามยังมีข้อเสียบางอย่างของพร็อกซีล็อกเช่นเดียวกับเซิร์ฟเวอร์ล็อก เช่นการร้องขอที่ได้ถูกจัดการโดยแคชของเว็บเบราว์เซอร์ที่ไคลเอนต์เองนั้น พร็อกซีล็อกจะไม่ได้มีการบันทึกไว้ และจากที่ได้กล่าวไว้แล้วในบท

ที่ 2 ว่าพร็อกซีนั้นสามารถที่การทำงานเป็นลูกโชนได้ดังนั้นพร็อกซีลือกของพร็อกซีที่อยู่ในใกล้ผู้ใช้มากที่สุดจะให้ข้อมูลรูปแบบการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆของผู้ใช้ได้ดีที่สุดเพราะพร็อกซีลือกของพร็อกซีตัวห่างจากผู้ใช้ในลูกโชนั้นจะไม่สามารถจำแนกผู้ใช้ต่างๆได้เพราะจะถูกมองเป็นไคลเอนต์เดียวจากพร็อกซีลำดับก่อนหน้านั้น

3.2.3 ไคลเอนต์ลือกไฟล์ (CLIENT LOG)

ไคลเอนต์ลือกจะเป็นการบันทึกการร้องขอต่างๆที่เกิดขึ้นจากไคลเอนต์ ดังนั้นทุกๆการร้องขอจะถูกบันทึกไว้ในไคลเอนต์ลือกรวมไปถึงการร้องขอที่ถูกจัดการโดยแคชของเว็บเบราว์เซอร์เองด้วย ซึ่งส่วนการบันทึกจะให้ข้อมูลที่ดีกว่าเซิร์ฟเวอร์ลือกและพร็อกซีลือก อีกทั้งไคลเอนต์ลือกยังให้ข้อมูลเกี่ยวกับการร้องขอที่มีการยกเลิกจากผู้ช่วย ซึ่งส่วนตรงนี้เซิร์ฟเวอร์ลือกและพร็อกซีลือกไม่สามารถบันทึกได้ แต่ไคลเอนต์ลือกก็มีข้อเสียในแง่ที่ว่าไม่สามารถให้ข้อมูลรูปแบบการเข้าถึงของผู้ใช้ในกรณีที่ผู้ใช้ไม่เคยเข้าเว็บนั้นๆเลย เพราะจะไม่มีข้อมูลรูปแบบการร้องขอของผู้ใช้อยู่เลย แต่ในพร็อกซีลือกหรือเซิร์ฟเวอร์ลือกจะสามารถพอที่จะทำนายการร้องขอสำหรับเว็บเพจที่ผู้ใช้ไม่เคยเข้าถึงได้โดยดูจากรูปแบบการเข้าถึงเว็บเพจนั้นของผู้ใช้คนอื่นๆ

3.2.4 ข้อมูลจากการเฝ้าดูระบบเครือข่าย (NETWORK MONITORING)

ไคลเอนต์, พร็อกซีและเซิร์ฟเวอร์ลือกนั้นจะต้องมีส่วนการทำงานของซอฟต์แวร์ที่เพิ่มเข้ามาเพื่อใช้ในการสร้างลือกของการร้องขอที่เกิดขึ้น และข้อมูลในลือกนั้นจะเป็นข้อมูลที่เกิดจากระดับแอปพลิเคชันดังนั้นจึงไม่มีข้อมูลเกี่ยวกับการทำงานในระดับเน็ตเวิร์กเช่น TCP และ UDP เลย การเฝ้าดูระบบเครือข่ายเป็นการเก็บ และการติดตามข้อมูลการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆรูปแบบใหม่และเก็บเป็นลือกไฟล์ไว้ โดยจะไม่มีผลกระทบต่อการทำงานของโปรแกรมเว็บเซิร์ฟเวอร์เลย แต่ส่วนการทำงานนี้จะทำงานอยู่ที่อุปกรณ์เครือข่ายเช่น เราเตอร์ แทน

การเฝ้าดูระบบเครือข่ายจะให้ข้อมูลการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆ ได้ถึงในระดับเน็ตเวิร์กคือ ไอพีเลเยอร์ (IP Layer) การเฝ้าดูสามารถดูเวลาของแต่ละแพคเกจของการร้องขอบนแต่ละลิงก์ของระบบเครือข่ายได้เลย ซึ่งเมื่อเปรียบเทียบกับเซิร์ฟเวอร์, พร็อกซีและไคลเอนต์ลือกแล้วเวลาที่สามารถดูได้จะเป็นเวลาที่มีค่าเดียวคือ เวลาที่การร้องถูกส่งมาถึงที่เซิร์ฟเวอร์หรือพร็อกซีหรือที่เกิดจากไคลเอนต์เท่านั้น เวลาที่ได้จากการเฝ้าดูระบบเครือข่ายแต่ละลิงก์สามารถนำมาใช้พิจารณาในแง่ของความล่าช้าที่เกิดขึ้นในแต่ละลิงก์ได้ และด้วยการเฝ้าดูระบบเครือข่ายนั้นจะไม่เกี่ยวข้องกับโปรแกรมของเว็บเซิร์ฟเวอร์ดังนั้นจึงสามารถเก็บข้อมูลของการร้องขอได้อย่างเต็มที่เช่น อาจจะมีเก็บข้อมูลของ HTTP Header ได้ทั้งหมด

แต่อย่างไรก็ตามการเฝ้าดูระบบเครือข่ายนั้นก็ยังมีข้อเสียเช่นเดียวกับ เซิร์ฟเวอร์และพร็อกซีลือกคือไม่สามารถที่จะเก็บข้อมูลการร้องขอที่ถูกจัดการโดยแคชของเว็บเบราว์เซอร์ที่ไคลเอนต์ได้ และ

ยังมีข้อเสียในกรณีที่มีการใช้การเข้ารหัสข้อมูลก่อนส่งระหว่างไคลเอนต์และเซิร์ฟเวอร์ การเฝ้าดูระบบเครือข่ายจะไม่สามารถเก็บข้อมูลได้ และมีข้อจำกัดในเรื่องของความเร็วในการเฝ้าดูข้อมูล เพราะถ้าถึงที่ถูกละเมิดในการเฝ้าดูนั้นมีความเร็วสูง การเฝ้าดูข้อมูลการร้องขอต่างๆจะต้องเร็วตามไปด้วยเพื่อให้สามารถเฝ้าดูได้ทันทำให้ต้องใช้เครื่องและอุปกรณ์ที่มีความเร็วสูงและสามารถรองรับความเร็วในการส่งข้อมูลได้

ทั้งหมดเป็นแหล่งข้อมูลที่จะใช้นามาสร้างเป็นรูปแบบการเข้าถึงของผู้ใช้ที่เครื่องไคลเอนต์ต่างๆ แล้วนำรูปแบบการเข้าถึงนั้นมาใช้ทำนายการร้องขอเว็บเพจหรือรีซอร์สที่จะเกิดขึ้นในอนาคต ซึ่งแต่ละแหล่งข้อมูลก็มีข้อดีข้อเสียแตกต่างกันไป การใช้ไคลเอนต์ลึกลักษณะรูปแบบการเข้าถึงที่ได้ก็จะเหมาะกับไคลเอนต์ใดไคลเอนต์หนึ่งเท่านั้นและในกรณีที่ไคลเอนต์นั้นไม่เคยมีการเข้าถึงเว็บไซต์หนึ่งเลยก็จะไม่สามารถสร้างรูปแบบการเข้าถึงของไคลเอนต์นั้นได้ แต่ถ้ามีการใช้พร็อกซีลึกลักษณะก็จะไม่สามารถบันทึกการร้องขอที่เกิดขึ้นได้ทั้งหมด แต่การใช้พร็อกซีลึกลักษณะก็จะดีในส่วนที่ถ้าไคลเอนต์ใดๆไม่เคยเข้าถึงเว็บไซต์หนึ่งเลยก็สามารถเอารูปแบบการเข้าถึงของไคลเอนต์อื่นมาใช้ในการทำนายได้อีกทั้งพร็อกซีลึกลักษณะก็ได้มาจากไคลเอนต์หลายๆ ไคลเอนต์ดังนั้นดังนั้นจึงมีข้อมูลในการเข้าถึงเว็บเซิร์ฟเวอร์ต่างๆมากกว่าไคลเอนต์ลึกลักษณะ ส่วนเซิร์ฟเวอร์ลึกลักษณะจะมีการบันทึกการร้องขอที่ถูกส่งมาจากไคลเอนต์หรือพร็อกซีเท่านั้น ข้อมูลในเซิร์ฟเวอร์ลึกลักษณะจะเป็นของเซิร์ฟเวอร์เดียวเท่านั้นในการนำมาสร้างเป็นรูปแบบการเข้าถึงของผู้ใช้ที่ไคลเอนต์ต่างๆจึงเหมาะสมสำหรับเว็บเซิร์ฟเวอร์เดียวเท่านั้น ส่วนการใช้ข้อมูลจากการเฝ้าดูระบบเครือข่ายนั้นจะได้เป็นข้อมูลที่มีรายละเอียดมากเพราะสามารถดูได้ทั้งในรูปแบบ TCP หรือ UDP หรือ HTTP ซึ่งการใช้แหล่งข้อมูลนี้ไม่ค่อยนิยมใช้กันเพราะมีความเกี่ยวข้องกับนโยบายความเป็นส่วนตัว และมีความยุ่งยากในการนำมาสร้างรูปแบบการเข้าถึงของไคลเอนต์ด้วย

3.3 รูปแบบต่างๆ ของลึอกไฟล์

3.3.1 รูปแบบทั่วไปของลึอกไฟล์

ในแต่ละเรคคอร์ดของลึอกไฟล์จะแตกต่างกันไปขึ้นอยู่กับแอปพลิเคชันที่ใช้บนเว็บเซิร์ฟเวอร์หรือพร็อกซีเซิร์ฟเวอร์ แต่โดยทั่วไปจะประกอบด้วยข้อมูลหลัก 7 อย่างซึ่งแสดงดังตารางที่อยู่ข้างล่าง

ตารางที่ 3.1 แสดงข้อมูลทั่วไปของที่มีอยู่ในล็อกไฟล์

Field	Meaning
Remote host	Hostname or IP address of requesting client
Remote identity	Account associated with connection on client machine
Authenticated user	Name provided by user for authentication
Time	Date/time associated with the request
Request	Request method, Request-URI, and protocol version
Response code	Three-digit HTTP response code
Content length	Number of bytes associated with the response

- ชื่อโฮสต์ (Remote Host) : จะแสดงไอพีแอดเดรส(IP Address) ของเครื่องไคลเอนต์หรือจะเป็นชื่อของโฮสต์ก็ได้เช่น 10.245.131.2 หรือ Chaokhun.kmitl.ac.th เครื่องเซิร์ฟเวอร์สามารถที่จะหาไอพีแอดเดรสของเครื่องไคลเอนต์ได้โดยตรงจาก Socket ที่ใช้ในการส่งข้อมูลการร้องขอแบบ HTTP (HTTP Request) ได้เลย แต่อย่างไรก็ดีสำหรับการหาชื่อโฮสต์ของเครื่องไคลเอนต์นั้น จะต้องมีการส่งการแปลงจากไอพีแอดเดรสเป็นชื่อโฮสต์ (DNS Lookup) ไปยังดีเอ็นเอสเซิร์ฟเวอร์(DNS Server) เพื่อทำการแปลงจากย้อนกลับจากไอพีแอดเดรสเป็นชื่อโฮสต์(Reverse DNS Lookup) หาชื่อโฮสต์ของเครื่องไคลเอนต์ แต่โดยทั่วไปเว็บเซิร์ฟเวอร์จะไม่มีใช้การล็อกชื่อโฮสต์ เพราะต้องเสียเวลาในการส่งแปลงจากไอพีแอดเดรส เป็นชื่อโฮสต์ต่างๆ เพื่อไม่ทำให้ประสิทธิภาพของเว็บเซิร์ฟเวอร์ลดลง
- บัญชีผู้ใช้(Remote Identity) : จะแสดงชื่อของผู้ใช้ที่กำลังใช้เครื่องไคลเอนต์เชื่อมต่อ TCP เข้ามาที่เซิร์ฟเวอร์ โดยการเชื่อมต่อ TCP นี้จะถูกใช้ในการติดต่อสื่อสารระหว่างแอปพลิเคชันที่ทำงานอยู่ที่เครื่องไคลเอนต์กับเครื่องเซิร์ฟเวอร์ แต่โดยทั่วไปฟิลด์นี้จะไม่มีการบันทึกไว้เพราะเว็บเซิร์ฟเวอร์ส่วนใหญ่ไม่มีความจำเป็นต้องเก็บข้อมูลส่วนนี้ ดังนั้นฟิลด์นี้จะปรากฏเป็น “-“ ในล็อกไฟล์ส่วนใหญ่
- ข้อมูลของผู้ใช้ที่ได้รับสิทธิเข้ามา(Authenticated User) : จะเป็นส่วนที่แสดงชื่อของผู้ใช้ที่ได้มีการยืนยันตัวเองโดยผ่านกระบวนการยืนยันการใช้งานบนโปรโตคอล HTTP ด้วยการให้หัวข้อมการยืนยันตัวเอง(Authentication Header) ในข้อมูลการร้องขอแบบ HTTP ที่จะถูกส่งมาจากเครื่องไคลเอนต์ในกรณีที่ต้องมีการใช้ ชื่อผู้ใช้(User) และ รหัสลับ (Password) ในการเข้าถึงเว็บเพจหรือรีซอร์สใดๆ ในเซิร์ฟเวอร์ โดยทั่วไปฟิลด์นี้จะปรากฏเป็น “-“ ถ้าไม่มีการใช้การแสดงผล หรือกรณีที่เซิร์ฟเวอร์ไม่มีการเก็บข้อมูลส่วนนี้

- เวลา(Time) : ในล็อกไฟล์นั้นจะต้องมีการเก็บเวลาที่ได้รับการร้องขอ โดยจะมีหน่วยเป็นวินาที, นาทีและชั่วโมงตามลำดับ แต่อย่างไรก็ดีในส่วนของฟิลด์นี้จะไม่ได้มีการกำหนดรูปแบบของเวลาที่มีการบันทึกไว้แน่นอน จะขึ้นกับแต่ละเซิร์ฟเวอร์ โดยเวลาที่มีการบันทึกนั้นจะสามารถใช้เป็นเวลา 4 แบบ อาจจะเป็นเวลาที่ได้รับการร้องขอ หรือจะเป็นเวลาที่เริ่มการส่งการตอบกลับไปยังไคลเอนต์ เวลาที่ส่งการตอบกลับเสร็จแล้วหรือจะเป็นเวลาที่มีการเริ่มสร้างข้อมูลการตอบกลับแบบ HTTP (HTTP Response)
- เว็บเพจหรือรีซอร์สที่ร้องขอ (Request) : ส่วนของฟิลด์นี้จะใช้เก็บรีซอร์สที่มีการร้องขอมาจากไคลเอนต์ โดยจะประกอบด้วย URI ของรีซอร์สและโปรโตคอลเวอร์ชันที่มีการส่งมา
- รหัสของข้อมูลการตอบกลับแบบ HTTP (Response Code) : เป็นส่วนที่จะแสดงรหัสในการตอบกลับไปแบบ HTTP ซึ่งจะอยู่ในรูปตัวเลข 3 ตำแหน่งเช่น 200 OK เป็นต้น
- ขนาดของข้อมูล (Content Length) : เป็นฟิลด์ที่ใช้ในการเก็บจำนวนของไบต์ที่ได้มีการส่งไปในข้อมูลการตอบกลับแบบ HTTP และก็ขึ้นกับเว็บเซิร์ฟเวอร์เช่นกันในการเก็บข้อมูลส่วนนี้ โดยอาจจะเป็นขนาดของข้อมูลในส่วนของ Entity body ในข้อมูลการตอบกลับแบบ HTTP หรือจะเป็นขนาดของการตอบกลับแบบ HTTP ทั้งหมดก็ได้ ถ้าเซิร์ฟเวอร์ไม่มีการเก็บหรือไม่รู้ในส่วนนี้ก็จะเก็บเป็น “-“ หรือเป็น 0 สำหรับในส่วนของการตอบกลับที่ไม่มีข้อมูลในส่วนของ Entity Body(304 Not Modified)

```

10.245.131.2 - - [15/Oct/2000:00:00:25 -0400] "GET /img/logo.gif
HTTP/1.0" 304 0
10.245.131.2 - - [15/Oct/2000:00:00:26 -0400] "GET /img/site.gif
HTTP/1.0" 304 0
10.3.2.16 - - [15/Oct/2000:00:00:38 -0400] "GET /est/bybhi.html
HTTP/1.0" 304 0
10.16.202.34 - - [15/Oct/2000:00:00:45 -0400] "GET /img/tday.gif
HTTP/1.0" 200 3699

```

รูปที่ 3.1 แสดงตัวอย่างของล็อกไฟล์

รูปที่ 3.1 แสดง 4 เรคคอร์ดในล็อกไฟล์ที่มีรูปแบบทั่วไป ในแต่ละเรคคอร์ดฟิลด์ที่สองและฟิลด์ที่สามจะเป็น “-“ เพราะเซิร์ฟเวอร์ไม่มีการบันทึกบัญชีผู้ใช้และบัญชีผู้ใช้ที่ได้มีการยืนยันตัวเองมาก ส่วนในฟิลด์เวลา(Time) จะมีรูปแบบเป็น วัน เดือน ปี และตามด้วยเวลาที่ท้องถิ่นของเซิร์ฟเวอร์ ส่วน “-0400” แสดงว่าเวลาที่ท้องถิ่นของเซิร์ฟเวอร์เป็น 4 ชม.หลังจากเวลากลางกรีนนิช (Greenwich Mean Time)

3.3.2 รูปแบบเพิ่มเติมจากรูปแบบทั่วไป (Extended Common Log Format)

การบันทึกล็อกไฟล์ของเซิร์ฟเวอร์นั้นอาจจะมีสามารถเก็บข้อมูลเพิ่มเติมจากรูปแบบทั่วไปได้อีก โดยข้อมูลที่สามารถจัดเก็บได้จะเป็นดังตารางที่ 3.2

ตารางที่ 3.2 แสดงข้อมูลเพิ่มเติมที่อาจมีในล็อกไฟล์

Field	Meaning
User agent	Information on user agent software
Referer	URI from which Request-URI was obtained
Request processing time	Time spent processing the request
Request header size	Number of bytes in the request header
Request body size	Number of bytes in the request body
Remote response code	Response code from the server
Remote content length	Size of the response from server
Remote response header size	Size of the response header sent by server
Proxy request header size	Size of the request header sent to server
Proxy response header size	Size of the response header sent to client

- เว็บแอปพลิเคชันที่ไคลเอนต์ใช้ (User Agent) : ในส่วนนี้จะเก็บบันทึกค่าของ User-Agent ที่อยู่ในหัวข้อของ User-agent ในข้อมูลการร้องขอแบบ HTTP ที่ส่งมาจากไคลเอนต์ โดยจะแสดงชื่อและเวอร์ชันของแอปพลิเคชันที่ได้ทำการส่งข้อมูลการร้องขอแบบ HTTP มา ซึ่งส่วนนี้อาจจะมีข้อมูลเพิ่มเติมได้อีกเช่น ชื่อของระบบปฏิบัติการที่ทำงานอยู่ที่เครื่องไคลเอนต์
- เว็บเพจอ้างอิง(Referer) : ในส่วนนี้จะเก็บค่าของ Referer ที่อยู่ในหัวข้อ Referer ในข้อมูลการร้องขอแบบ HTTP ในกรณีถ้ามีการส่งข้อมูลส่วนนี้มากับการร้องขอแบบ HTTP ที่มาจากไคลเอนต์
- เวลาที่ใช้ในการกระบวนการร้องขอแบบ HTTP (Request Processing Time) : เป็นฟิลด์ที่จะใช้บอกระยะเวลาที่มีการสร้างการตอบกลับแบบ HTTP (HTTP Response) ที่จะส่งกลับไปให้ไคลเอนต์ โดยมีหน่วยเป็นวินาที
- ขนาดของข้อมูลในส่วนหัวข้อที่มีมาในข้อมูลการร้องขอแบบ HTTP (Request Header Size) : ส่วนนี้จะเก็บบันทึกจำนวนไบต์ของหัวข้อของ HTTP ที่ได้รับจากข้อมูลการร้องขอแบบ HTTP (HTTP Request) ที่ส่งมาจากไคลเอนต์
- ขนาดของข้อมูลของที่มีใช้ส่วนเนื้อหา (Request Body Size) : ส่วนนี้จะบันทึกจำนวนไบต์ของส่วนเนื้อหา(Body) ของการร้องขอแบบ HTTP ที่ได้รับจากไคลเอนต์

โดยทั่วไป HTTP Request จะไม่มีข้อมูลในส่วนของ Body ยกเว้นกรณีที่ทางไคลเอนต์มีการส่งแบบ PUT หรือ POST

สำหรับข้อมูลส่วนที่เหลือในตาราง 3.2 จะเกี่ยวข้องกับพรีอ็อกซีเซิร์ฟเวอร์ ซึ่งเป็นส่วนที่อาจจะมีการบันทึกไว้ในพรีอ็อกซีล็อก ประกอบด้วย

- รหัสของการตอบกลับปลายทาง (Remote Response Code) : ส่วนของฟิลด์นี้จะบันทึกในรูปแบบของตัวเลข 3 ตำแหน่งที่จะประกอบด้วยสถานะของการตอบกลับแบบ HTTP (HTTP Response) ที่ได้รับมาจากเว็บเซิร์ฟเวอร์ปลายทางมายังพรีอ็อกซีนี้ ซึ่งรหัสการตอบกลับนี้นี้อาจจะแตกต่างจากรหัสการตอบกลับฟิลด์ (Response Code) ที่มีใช้ข้อมูลการตอบกลับแบบ HTTP ที่ส่งจากพรีอ็อกซีไปยังไคลเอนต์ก็ได้
- ขนาดของข้อมูลปลายทาง(Remote Content Length) : จะเป็นจำนวนของไบต์ในข้อมูลการตอบกลับแบบ HTTP ที่ส่งมาจากเว็บเซิร์ฟเวอร์ปลายทางมายังพรีอ็อกซี ซึ่งขนาดของข้อมูลปลายทางนี้อาจจะแตกต่างจาก Content Length ฟิลด์ของ HTTP Response ที่ส่งจากพรีอ็อกซีไปยังไคลเอนต์ก็ได้
- ขนาดของหัวข้อในข้อมูลการตอบกลับแบบ HTTP ปลายทาง(Remote Response Header Size) : เป็นขนาดที่เป็นจำนวนไบต์ของหัวข้อในข้อมูลการตอบกลับแบบ HTTP ที่ส่งมาจากเว็บเซิร์ฟเวอร์ปลายทางมายังพรีอ็อกซี
- ขนาดของหัวข้อในการร้องขอจากพรีอ็อกซี(Proxy Request Header Size) : เป็นจำนวนไบต์ของในส่วนหัวข้อของการร้องขอแบบ HTTP ที่ส่งจากพรีอ็อกซีไปยังเว็บเซิร์ฟเวอร์ปลายทาง ซึ่งอาจจะแตกต่างจากขนาดของการส่วนหัวข้อในการร้องแบบ HTTP ที่ส่งมาจากไคลเอนต์มายังพรีอ็อกซีก็ได้
- ขนาดของส่วนหัวข้อในการตอบกลับแบบ HTTP ของพรีอ็อกซี(Proxy Response Header Size) : เป็นจำนวนไบต์ของส่วนหัวข้อที่มีในการตอบกลับแบบ HTTP ที่ส่งจากพรีอ็อกซีไปยังไคลเอนต์

3.4 รูปแบบต่างๆของระบบพรีเฟรชชิง

3.4.1 การพรีเฟรชชิงชื่อโฮสต์ (DNS Prefetching)

ก่อนที่จะมีการสร้างการเชื่อมต่อไปยังเว็บเซิร์ฟเวอร์นั้น ทางด้านแอปพลิเคชันของผู้ใช้งานนั้น จะต้องมีการแปลงจากส่วนที่เป็นโฮสต์ของ URL ที่ถูกร้องขอให้ไปเป็นไอพีแอดเดรสก่อน ซึ่งกระบวนการนี้อาจจะต้องมีการติดต่อกับดีเอ็นเอสเซิร์ฟเวอร์ท้องถิ่น (Local DNS Server) หรือ

อาจจะต้องมีการติดต่อกับดีเอ็นเอสเซิร์ฟเวอร์ตัวอื่นในระดับที่สูงขึ้นไป ซึ่งทำให้มีการเสียเวลาในขั้นตอนนี้อาจสมควร

เพื่อหลีกเลี่ยงหรือลดเวลาในกระบวนการแปลงจากชื่อโฮสต์เป็นไอพีแอดเดรสนั้น นั่นก็ โดยจะทำการแปลงจากชื่อโฮสต์เป็นไอพีแอดเดรสล่วงหน้าก่อนที่ผู้ใช้จะมีการร้องขอเว็บเพจหรือรีซอร์สใดๆจากโฮสต์นั้น ซึ่งการทำงานแบบนี้ก็จะช่วยลดเวลาในกระบวนการที่เกี่ยวกับการแปลงชื่อหรือ URL เป็นไอพีแอดเดรส (DNS Service) และการทำงานของระบบพีเพรชชิงแบบนี้จะ ใช้ได้ดีและมีประสิทธิภาพ ถ้าในกระบวนการแปลงชื่อโฮสต์เป็นไอพีแอดเดรสของผู้ใช้ต้องมีการ ติดต่อกับดีเอ็นเอสเซิร์ฟเวอร์ในหลายๆระดับเพราะจะเสียเวลาในการกระบวนการนี้เยอะ ทำให้เกิด ความล่าช้าในการเข้าถึงเว็บเพจหรือรีซอร์สต่างบนเว็ลด์ไวด์เว็บ

3.4.2 การพีเพรชชิงการเชื่อมต่อแบบ TCP (Connection prefetching)

ในกระบวนการจัดการข้อมูลการร้องขอแบบ HTTP นั้นแอปพลิเคชันทางด้านผู้ใช้หรือเว็บ ไคลเอนต์นั้น จะต้องมีการสร้างการเชื่อมต่อแบบ TCP ไปยังเว็บเซิร์ฟเวอร์หรือเซิร์ฟเวอร์ที่ ให้บริการในการเข้าถึงเว็บเพจเช่น พร็อกซีเซิร์ฟเวอร์ การเชื่อมต่อแบบ TCP นี้จะต้องมีการเริ่มต้น ด้วยกระบวนการสร้างการเชื่อมต่อสามทาง (Three-way handshake) ก่อนระหว่างไคลเอนต์กับ เซิร์ฟเวอร์ก่อน ซึ่งกระบวนการนี้การช่วงเวลาที่จะต้องใช้ไปในการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆ การลดช่วงเวลาในการสร้างการเชื่อมต่อแบบ Three-way handshake นี้ก็สามารถทำได้โดยการสร้าง การการเชื่อมต่อแบบ TCP ไว้ก่อนเลขล่วงหน้าเลข ดังนั้นเมื่อผู้ใช้มีการคลิกลิงก์ต่างๆ บนเว็บเพจ แอปพลิเคชันของผู้ใช้ก็สามารถส่งการร้องขอแบบ HTTP ไปได้เลย ไม่ต้องเสียเวลาในการสร้าง การเชื่อมต่อแบบ TCP อีก

ดังที่ได้กล่าวแล้วว่า การพีเพรชชิงการเชื่อมต่อแบบ TCP คือกระบวนการที่จะพีเพรชชิงการ เชื่อมต่อ TCP ล่วงหน้านั้นเองซึ่งสมมติว่าหน้าเว็บเพจหน้าหนึ่งมีลิงก์ไปยังเว็บเซิร์ฟเวอร์ต่างๆ ใน กระบวนการพีเพรชชิงแบบนี้ก็จะเลือกที่จะทำการสร้างการเชื่อมต่อแบบ TCP ไปยังเว็บเซิร์ฟเวอร์ ต่างๆ ไว้ก่อนเมื่อดังนั้นเมื่อเกิดการคลิกที่ลิงก์ขึ้น เว็บแอปพลิเคชันก็สามารถที่จะส่ง HTTP Request ไปยังเว็บเซิร์ฟเวอร์ได้เลย

ข้อจำกัดบางอย่างที่จะต้องพิจารณาด้วยสำหรับการทำงานของระบบพีเพรชชิงการเชื่อมต่อแบบ TCP นั่นก็คือการที่มีการสร้างการเชื่อมต่อแบบ TCP ทิ้งไว้ล่วงหน้านั้น ในกรณีถ้าการเชื่อมต่อนี้ ไม่ได้มีการคลิกเกิดขึ้นแม้ว่าการเชื่อมต่อจะถูกปิดไปเอง แต่ก็จะทำให้สูญเสียทรัพยากรของเว็บ เซิร์ฟเวอร์ไปเปล่าๆ

3.4.3 การพรีเฟรชซึ่งการร้องขอแบบ HTTP (HTTP prefetching)

การดูเว็บเพจหรือรีซอร์สต่างๆ นั้นจะอยู่ในรูปแบบที่ว่าผู้ใช้จะคลิกลิงก์ต่างๆบนเว็บเพจเพื่อใช้ในการดูเว็บเพจหน้าต่อไปหรือเว็บเพจอื่น ดังที่ได้กล่าวไว้ในบทก่อนหน้านี้ว่าเมื่อมีการคลิกลิงก์บนเว็บเพจเว็บแอปพลิเคชันหรือเว็บเบราว์เซอร์จะมีการสร้างการเชื่อมต่อแบบ TCP ไปยังเว็บเซิร์ฟเวอร์ จากนั้นก็จะทำการส่งการร้องขอแบบ HTTP ไปยังเว็บเซิร์ฟเวอร์ ซึ่งระยะเวลาในการที่จะได้รับการตอบกลับแบบ HTTP นั้นก็ขึ้นอยู่กับปัจจัยหลายอย่าง ไม่ว่าจะเป็นความเร็วของการประมวลผลของเซิร์ฟเวอร์ปลายทาง, ปริมาณข้อมูลหรือความคับคั่งของเครือข่าย ณ เวลานั้น, ขนาดของเว็บเพจหรือรีซอร์สที่มีการร้องขอ ซึ่งถึงแม้ในกรณีของรีซอร์สที่มีการแคชไว้แล้วนั้นก็อาจจะยังคงต้องมีการส่งการร้องขอแบบ HTTP ไปยังเว็บเซิร์ฟเวอร์อยู่ดีเพื่อตรวจสอบว่ารีซอร์สที่ได้มีการแคชไว้ นั้นมีการแก้ไขหรือไม่ที่เว็บเซิร์ฟเวอร์

ในช่วงเวลาที่ผู้ใช้กำลังดูหรืออ่านเว็บเพจอยู่นั้นจะเป็นช่วงเวลาที่ต้องสูญเสียของสัญญาณของผู้ใช้นั้นว่าง เพราะไม่ได้มีการส่งการร้องขอแบบ HTTP ออกไป ดังนั้นในช่วงเวลานี้ถ้ามีการส่งการร้องขอแบบ HTTP เว็บเพจหรือรีซอร์สที่ถูกพิจารณาแล้วว่าผู้ใช้ต้องการร้องขอต่อไป เมื่อมีการได้รับการตอบกลับแบบ HTTP ก็จะทำการเก็บเว็บเพจหรือรีซอร์สนั้นไว้ที่แคชก่อน จากนั้นถ้าผู้ใช้มีการเข้าถึงเว็บเพจหรือรีซอร์สนั้นต่อไปจริงๆ เว็บแอปพลิเคชันหรือเว็บเบราว์เซอร์ก็สามารถนำเว็บเพจหรือรีซอร์สนั้นๆมาแสดงจากแคชได้เลย สำหรับการทำงานแบบนี้ยังสามารถใช้กับในกรณีที่ทำการตรวจสอบว่าเว็บเพจหรือรีซอร์สใดที่ได้แคชไว้มีการแก้ไขที่เว็บเซิร์ฟเวอร์ได้อีกด้วย ที่กล่าวมาข้างต้นนั้นก็คือกระบวนการพรีเฟรชซึ่งการร้องขอแบบ HTTP (HTTP prefetching) ที่จะทำการพรีเฟรชซึ่งเว็บเพจหรือรีซอร์สต่างๆล่วงหน้าก่อนที่จะมีการร้องขอจากผู้ใช้งาน

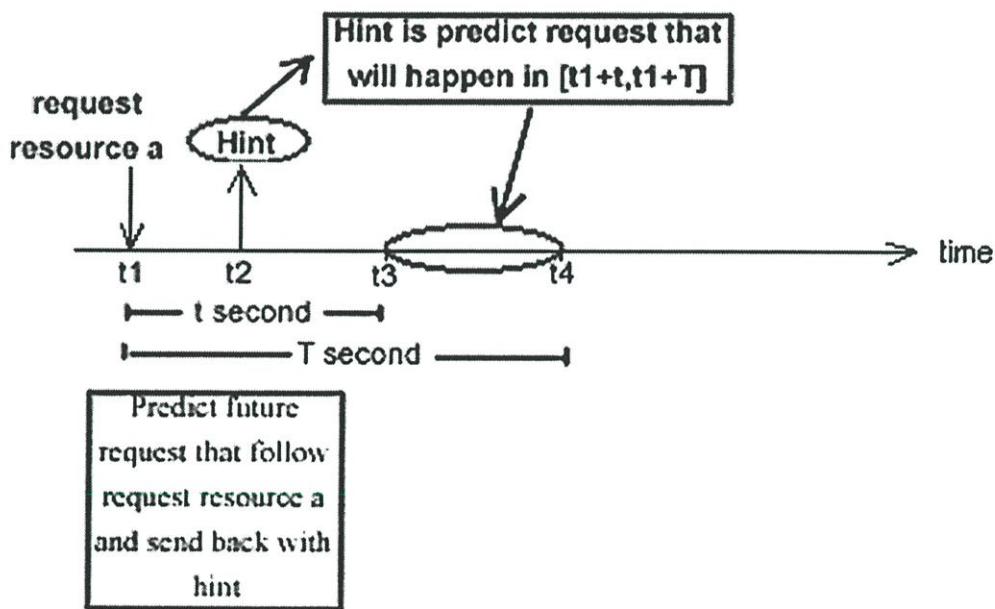
สำหรับวิธีการนี้จุดสำคัญอยู่ที่กระบวนการที่จะใช้ในการพิจารณาว่าเว็บเพจหรือรีซอร์สใดจะถูกเข้าถึงต่อไปหรือล่วงหน้า ซึ่งยังสามารถพิจารณาได้ถูกต้องมากเท่าไรหรือการพรีเฟรชซึ่งแบบนี้ก็จะมีประสิทธิภาพเพิ่มขึ้นตามไปด้วย ซึ่งในวิทยานิพนธ์นี้จะนำเสนอวิธีการที่มีประสิทธิภาพมากวิธีการหนึ่งที่จะนำมาใช้ในการทำนายหรือพิจารณาเว็บเพจหรือรีซอร์สที่จะมีการเข้าถึงจากผู้ใช้งานล่วงหน้า

บทที่ 4

ทฤษฎีและการทำงานของแพร์ไวส์อัลกอริทึม

4.1 ทฤษฎีของแพร์ไวส์อัลกอริทึม

แพร์ไวส์อัลกอริทึมเป็นอัลกอริทึมที่ใช้ในการทำนายการร้องเว็บเพจหรือรีซอร์สใดๆ ที่จะเกิดขึ้นในอนาคตของผู้ใช้ที่เครื่องไคลเอนต์ โดยจะทำการประมวลผลเซิร์ฟเวอร์ล็อกไฟล์เพื่อใช้ในการสร้างรูปแบบการเข้าถึงของผู้ใช้ และนำข้อมูลนั้นมาใช้ในการทำนายการร้องในอนาคตของผู้ใช้ รูปแบบการทำนายของแพร์ไวส์อัลกอริทึมจะเป็นดังรูป



รูปที่ 4.1 รูปแบบการทำนายของแพร์ไวส์อัลกอริทึม

จากรูปที่ 4.1 สามารถอธิบายได้ว่า ถ้าสมมติเมื่อเวลา t_1 เว็บเซิร์ฟเวอร์ได้รับการร้องขอแบบ HTTP (HTTP Request) ที่เป็นการร้องขอรีซอร์ส A จากเว็บเบราว์เซอร์ของผู้ใช้ที่เครื่องไคลเอนต์ ทางเว็บเซิร์ฟเวอร์ใช้เวลาในการดึงข้อมูลรีซอร์ส A และทำการสร้างเป็นข้อมูลการตอบกลับแบบ HTTP (HTTP Response) และทำการดึงเอากลุ่มของ URL ของเว็บเพจหรือรีซอร์สที่เว็บเซิร์ฟเวอร์ทำนายว่าผู้ใช้จะต้องเข้าถึงหลังจากเข้าถึงรีซอร์ส A ภายในช่วงระยะเวลา t_3 ถึง t_4 (นั่นก็คือช่วงเวลา t ถึง T)

วินาทีจากเวลา t) โดยจะเรียกกลุ่มของ URL นี้ว่า “ฮินท์(Hint)” จากนั้นก็ทำการส่งอินทกลับมารวมกับข้อมูลของรีซอร์ส A ไปยังเว็บเบราว์เซอร์ของผู้ใช้ จากนั้นเว็บเบราว์เซอร์ก็จะทำการแสดงผลรีซอร์ส A และระหว่างที่ผู้ใช้กับอ่านหรือดูรีซอร์ส A อยู่ นั้น เว็บเบราว์เซอร์ก็จะทำการพรีเฟรช(Prefetch) เว็บเพจหรือรีซอร์สตาม URL ที่มีในฮินท์ที่ได้รับจากเว็บเซิร์ฟเวอร์ เมื่อพรีเฟรชแล้วจะทำการเก็บไว้ที่แคช ถ้าการทำงานถูกต้องผู้ใช้ต้องการเข้าถึงเว็บเพจหรือรีซอร์สตามที่ได้ทำนายไว้ เว็บเบราว์เซอร์ก็สามารถที่จะนำเว็บเพจหรือรีซอร์สนั้นจากแคชขึ้นมาแสดงผลได้เลย ไม่ต้องเสียเวลาในการร้องขอจากเว็บเซิร์ฟเวอร์

กระบวนการข้างต้นนั้นทางฝั่งไคลเอนต์ไม่จำเป็นต้องเป็นเว็บเบราว์เซอร์เสมอไป การทำงานดังกล่าวสามารถเอามาใช้กับพรีอ็อกซีได้เช่นกัน โดยพรีอ็อกซีจะทำงานเช่นเดียวกับเว็บเบราว์เซอร์แต่ถ้ามีการทำงานที่พรีอ็อกซีนั่นอาจจะได้เปรียบกว่าการทำงานที่เว็บเบราว์เซอร์เพราะถ้ามีการแคชที่พรีอ็อกซีแล้วผู้ใช้คนอื่นของพรีอ็อกซีจะได้รับประโยชน์จากการพรีเฟรชด้วย


4.2 การทำงานของแพร์ไวส์อัลกอริทึม

ส่วนประกอบที่สำคัญต่างๆ ของแพร์ไวส์อัลกอริทึมมีดังนี้

- รีซอร์ส A หมายถึง เว็บเพจหรือรีซอร์สใดๆ ที่มีการเข้าถึง โดยผู้ใช้ที่เครื่องไคลเอนต์
- รีซอร์ส B หมายถึง เว็บเพจหรือรีซอร์สใดๆ ที่มีการเข้าถึง โดยผู้ใช้ที่เครื่องไคลเอนต์ หลังจากเข้าถึงรีซอร์ส A แล้ว ภายในไปเกินช่วง $[t, T]$
- คาเตอร์ C_a เป็นคาเตอร์ที่จะใช้นับจำนวนครั้งที่เกิดการร้องขอรีซอร์ส A ของผู้ใช้ทุกคนที่มีการร้องขอมาที่เว็บเซิร์ฟเวอร์ในลือกไฟล์
- คาเตอร์ $C_{b|a}$ เป็นคาเตอร์ที่จะใช้นับจำนวนครั้งที่เกิดการร้องขอรีซอร์ส B ใดๆของผู้ใช้ทุกคนที่มีการร้องขอมาที่เว็บเซิร์ฟเวอร์ที่เกิดหลังจากเข้าถึงรีซอร์ส A แล้วและถูกร้องขอจากผู้ใช้คนเดียวกันด้วยในลือกไฟล์
- คาเตอร์ $P_{b|a}$ เป็นความน่าจะเป็นที่ผู้ใช้จะมีการร้องขอรีซอร์ส B ภายหลังจากรีซอร์ส A แล้วไม่น้อยกว่า t วินาทีแต่ไม่เกิน T วินาที โดยสามารถหา $P_{b|a} = C_{b|a} / C_a$
- ความน่าจะเป็นทรสโฮส (P_r) เป็นความน่าจะเป็นที่จะใช้เป็นเกณฑ์ในการพิจารณาว่าเว็บเพจหรือรีซอร์ส B ใดบ้างจะถูกใส่เข้าไปใน V_a

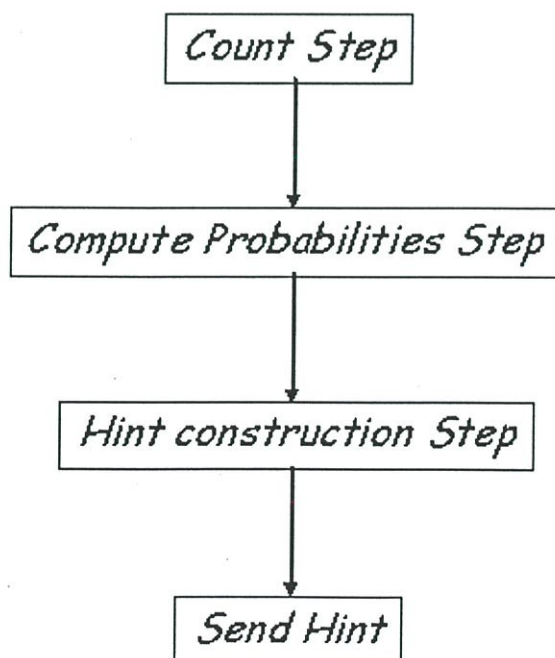
แพร์ไวส์อัลกอริทึมจะทำการประมวลผลลือกไฟล์เพื่อทำงานสร้างความน่าจะเป็นที่รีซอร์ส B ใดๆ ขึ้นกับรีซอร์ส A ใด แต่ก่อนจะเริ่มการทำงานของแพร์ไวส์ต้องมีกระบวนการ “Clean” ลือกไฟล์ก่อนดังนี้

1. จะทำการลบหรือนำเรคคอร์ดภายในล็อกไฟล์ที่เป็นการร้องขอเว็บเพจหรือรีซอร์สที่เป็น CGI, ASP, JSP ออกไปแล้ว
2. จากนั้นก็เอาล็อกไฟล์ที่ผ่านจากขั้นตอนแรกมาอ่านทีละเรคคอร์ด และจะเก็บเฉพาะไอพีแอดเดรส (IP Address) ของไคลเอนต์,รีซอร์สที่มีการร้องขอและเวลาที่มีการร้องขอ แล้วทำการเข้ารหัสไอพีแอดเดรสและชื่อของรีซอร์สที่มีการร้องขอด้วยอัลกอริทึม MD5 ในแต่ละเรคคอร์ด โดยจะได้เป็น $\{T_i, X, Y\}$ เมื่อ T_i เป็นเวลาที่มีการร้องขอ, X เป็นไอพีแอดเดรสของไคลเอนต์และ Y เป็นเว็บเพจหรือรีซอร์สที่มีการร้องขอ ดังรูปที่ 4.2



รูปที่ 4.2 ขั้นตอนอ่านและประมวลผลเรคคอร์ดในล็อกไฟล์

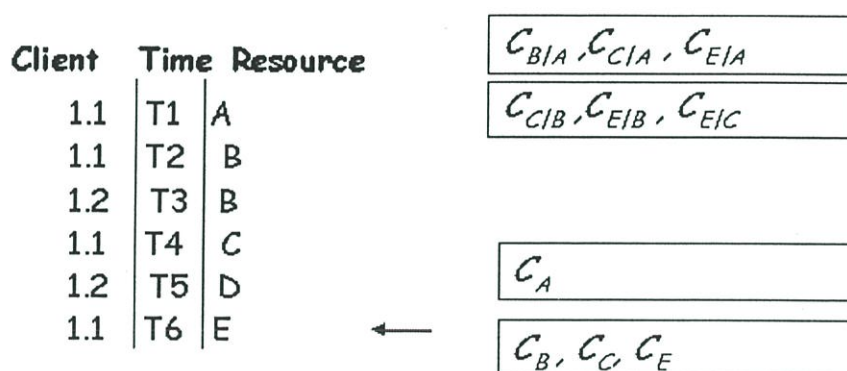
ขั้นตอนการทำงานของแพรวัวส์อัลกอริทึมจะประกอบด้วย 4 ขั้นตอนคือ



รูปที่ 4.3 สรุปขั้นตอนของแพรวัวส์อัลกอริทึม


รายละเอียดของแต่ละขั้นตอนเป็นดังนี้

1. ทำการนับจำนวนการร้องขอเว็บเพจหรือรีซอร์ส A (C_a) และนับจำนวนการร้องขอเว็บเพจหรือรีซอร์ส B ที่หลังจากการร้องขอเว็บหรือรีซอร์ส A ($C_{b|a}$) แล้วในช่วงไม่น้อยกว่า t วินาทีและไม่เกิน T วินาที ((t,T)) หลังจากได้รับการร้องขอเว็บเพจหรือรีซอร์ส A แล้ว (ดู flowchart การทำงานได้ใน ภาคผนวก ข. Flowchart ที่ 1)




รูปที่ 4.4 ขั้นตอนการนับของแพรวัวส์อัลกอริทึม

2. เมื่อทำตามขั้นตอนที่ 1 แล้วก็จะได้กลุ่มของ $C_{b|a}$ และกลุ่มของ C_a จากนั้นก็นำมาทำการหาความน่าจะเป็นของการขึ้นต่อกันของเว็บเพจหรือรีซอร์ส B ใดๆ กับเว็บเพจหรือรีซอร์ส A ใด ($P_{b|a}$) ตามสูตรที่ได้กล่าวมาแล้ว เมื่อเสร็จขั้นตอนนี้แล้วก็จะได้เป็นกลุ่มของ $P_{b|a}$ (ดู flowchart การทำงานได้ใน ภาคผนวก ข. Flowchart ที่ 2)



รูปที่ 4.5 ขั้นตอนการหาความน่าจะเป็นของการขึ้นต่อกันของแพรวัวส์อัลกอริทึม

3. ขั้นตอนนี้ก็จะพิจารณาว่า $P_{b|a}$ ใดที่มีค่ามากกว่าหรือเท่ากับ P_t ก็จะนำเว็บเพจหรือรีซอร์ส B นั้นใส่เข้าไปเป็นโวลุ่มของเว็บเพจหรือรีซอร์ส A (V_a) และทำอย่างนี้กับทุก $P_{b|a}$ ที่ได้จากขั้นตอนที่ 4 (ดู flowchart การทำงานได้ใน ภาคผนวก ข. Flowchart ที่ 3)



รูปที่ 4.6 ขั้นตอนการสร้างอินโวลุ่มของแพร์ไวส์อัลกอริทึม

4. เป็นขั้นตอนสุดท้ายในการใช้งาน คือเมื่อมีการร้องขอเว็บเพจหรือรีซอร์ส A มาที่เว็บเซิร์ฟเวอร์แล้ว ทางเว็บเซิร์ฟเวอร์จะไปดูว่าโวลุ่มของเว็บเพจหรือรีซอร์ส A นี้มีอะไรบ้าง จากนั้นก็ส่งโวลุ่มนั้นกลับไปพร้อมกับเว็บเพจหรือรีซอร์ส A เพื่อให้ทางไคลเอนต์ทำการปริ้นท์ต่อไป (ดู flowchart การทำงานได้ใน ภาคผนวก ข. Flowchart ที่ 4)

สำหรับอัลกอริทึมของแพร์ไวส์อัลกอริทึมจะเขียนได้ดังตารางที่ 4.1

ตารางที่ 4.1 ตัวอย่างของแพร์ไวส์อัลกอริทึม

// ขั้นตอนการลบข้อมูลส่วนที่เป็น CGI, ASP, JSP

สำหรับแต่ละเรคคอร์ดในล็อกไฟล์

ถ้ารูปแบบของไฟล์ไม่เป็น .CGI หรือ .ASP หรือ .JSP หรือ .PHP

ทำการเก็บค่า Ti, ค่า MD5 ของไอพีของผู้ใช้, ค่า MD5 ของเว็บเพจที่ถูกเข้าถึง

ตารางที่ 4.1 (ต่อ)

<p>// นับจำนวนการร้องขอ a แล้วตามด้วย b สำหรับผู้ใช้คนที่ i ของผู้ใช้ที่มีการร้องขอมาทั้งหมด สำหรับเว็บเพจ a ที่ผู้ใช้ i</p> $C_a = C_a + 1$ <p>สำหรับเว็บเพจ b ที่ถูกร้องขอตามหลังเว็บเพจ a ของผู้ใช้คนที่ i</p> $C_{b a} = C_{b a} + 1$ <p>// กำหนดค่า $P_{b a}$ ของเว็บเพจ a สำหรับเว็บเพจ a ที่ถูกร้องขอมา สำหรับเว็บเพจ b ที่ถูกร้องขอตามหลังเว็บเพจ a</p> $P_{b a} = C_{b a} / C_a$ <p>// สร้างอื่น สำหรับเว็บเพจ a ที่ถูกร้องขอมา สำหรับเว็บเพจ b ที่ถูกร้องขอตามหลังเว็บเพจ a ถ้า $P_{b a}$ ใดมีค่ามากกว่า P_i แล้วให้เพิ่มเว็บเพจ b เข้าไปในอื่นของเว็บเพจ a</p> <p>ผลลัพธ์ที่ได้ : กลุ่มของอื่นที่จะใช้กับผู้ใช้ทุกคน</p>

4.3 ประสิทธิภาพของแพรวาส์อัลกอริทึม

ในการวัดประสิทธิภาพของแพรวาส์อัลกอริทึมนั้นจะใช้เซิร์ฟเวอร์ล็อกไฟล์จากเว็บเซิร์ฟเวอร์ที่เป็นที่นิยมแห่งหนึ่งในประเทศไทยในการสร้างรูปแบบการเข้าถึงของผู้ใช้ต่างๆที่มีการร้องขอจากเว็บเซิร์ฟเวอร์นี้เพื่อใช้ในการสร้างอื่น โดยจะแบ่งส่วนของล็อกไฟล์ออกเป็นสองส่วน ส่วนหนึ่งขนาดประมาณ 200,000 เรคคอร์ด และส่วนที่สองขนาดประมาณ 100,000 เรคคอร์ดในการทดสอบประสิทธิภาพของอื่นที่สร้างขึ้นมาได้

จะกำหนดให้ $N_sendhint$ เป็นจำนวนครั้งที่มีการส่งอื่น โวลุ่ม และแต่ละอื่นในอื่น โวลุ่มจะมีการกำหนดค่า $Hint_status$ ที่จะแสดงว่าอื่นนั้นมีการร้องขอจริงจากไคลเอนต์หรือไม่ ส่วน $Hited-$

number เป็นจำนวนครั้งที่มีการร้องขอเว็บเพจที่ตรงกับอื่นในอินโวลกลุ่มที่ส่งไป ส่วน N_{hinturl} เป็นจำนวนอื่นในอินโวลกลุ่ม สำหรับการวัดประสิทธิภาพของแพรวัวส์อัลกอริทึมจะวัดในรูปแบบคือ

- นอมัลไลซ์รีคอล (Normalized Recall) เป็นอัตราที่เว็บเพจหรือริชอร์สที่ผู้กำลังเข้าถึงอยู่ในปัจจุบันถูกทำนายด้วยอื่นหรือไม่ เช่น ถ้าสมมติมีส่งอื่นไปว่าเมื่อผู้มีการเข้าถึงเว็บเพจ A แล้ว ผู้ใช้จะเข้าถึงเว็บเพจ B, C, D ด้วย และการเข้าถึงจริงของผู้ใช้เป็น A, B, E

$$\text{Normalized Recall} = \frac{\sum_{j=1}^{n_{\text{sendhint}}} \left(\frac{\text{Hited} - \text{number of hinturl of } a}{n_{\text{after } a}} \right)}{n_{\text{sendhint}}}$$

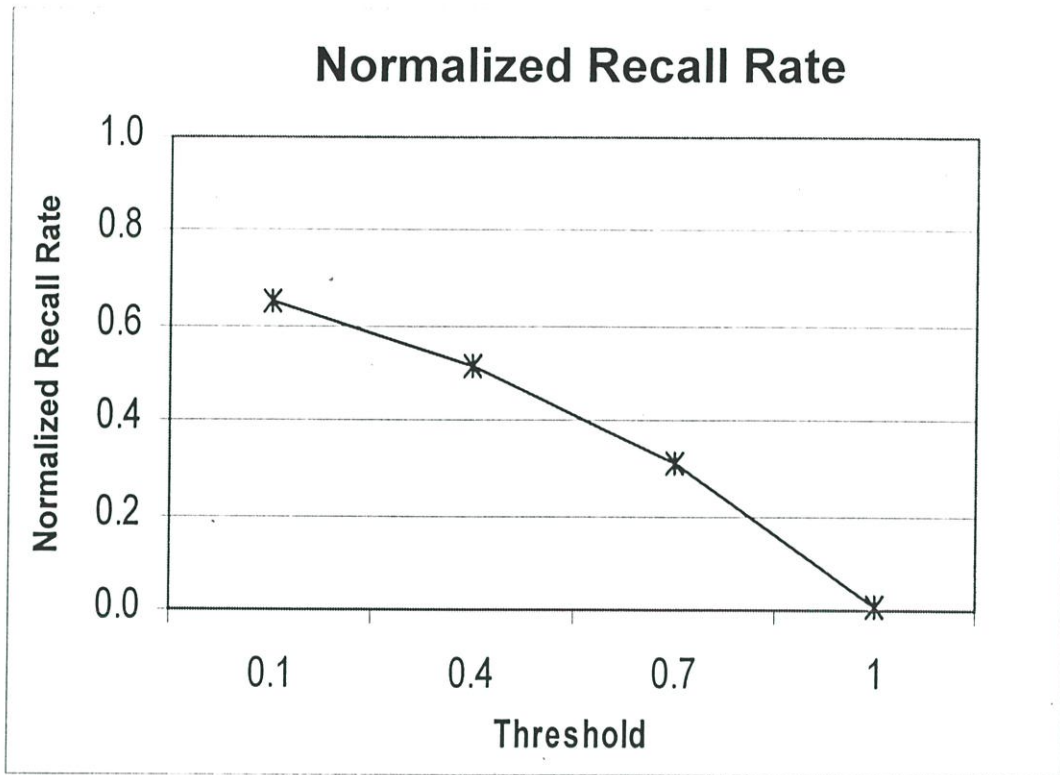
- นอมัลไลซ์พรีซีชัน (Normalized Precision) เป็นอัตราที่เว็บเพจหรือริชอร์สที่ถูกทำนายว่าผู้ใช้จะเข้าถึงในช่วงเวลา $[t, T]$ ข้างหน้าแล้ว ผู้ใช้มีการเข้าถึงเว็บเพจหรือริชอร์สเหล่านั้นถูกต้องเท่าไร

$$\text{Normalized Precision} = \frac{\sum_{j=1}^{n_{\text{sendhint}}} \left(\frac{\sum_{i=1}^{N_{\text{hinturl of } a_i}} \text{Hited} - \text{status of hinturl of } a_i}{n_{\text{hinturl}}} \right)}{n_{\text{sendhint}}}$$

- ขนาดเฉลี่ยของอื่น (Average Hintsize) เป็นขนาดเฉลี่ยของอื่นที่ได้มีการสร้างขึ้นทั้งหมด


$$\text{Average Hintsize} = \frac{\sum_{i=1}^{n_{\text{sendhint}}} n_{\text{hinturl of } a_i}}{n_{\text{sendhint}}}$$

ละในการทดลองหาประสิทธิภาพจะมีการใช้ค่า P_t หลายค่าจากค่า 0.1 ถึง 1.0 และจะมีการใช้ช่วงระยะเวลาที่จะทำนายการเข้าถึงของผู้ใช้นั้นคือค่า t และ T หลายค่าเช่นกัน โดยค่า $t=0$ คงที่แต่ค่า T จะมีค่าเป็น 30 ประสิทธิภาพของแพรวัวส์อัลกอริทึมเป็นดังรูปข้างล่าง



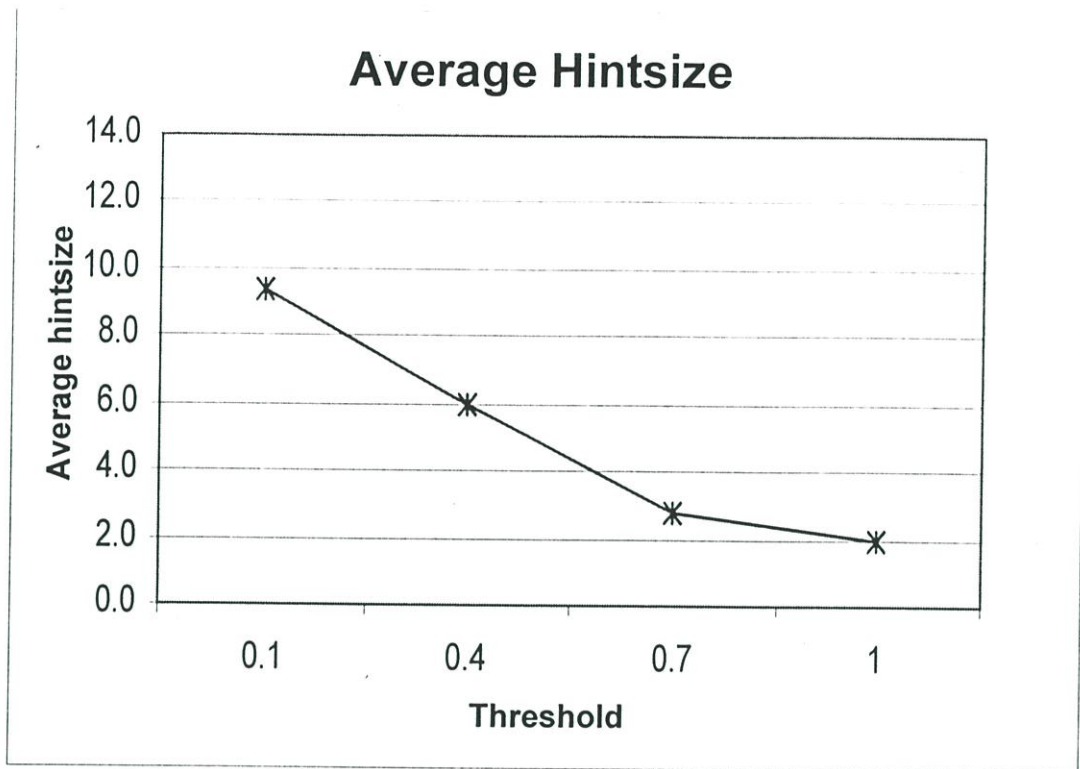
รูปที่ 4.7 อัตรานอ้มัลไลซ์รีคอลของเพอร์ไวส์อัลกอริทึมเมื่อมีการใช้ P_t จาก 0.1 – 1 และใช้ $t=0$, $T=30$

จากรูปที่ 4.7 แสดงอัตรานอ้มัลไลซ์รีคอลจะลดลงตามค่า P_t ที่เพิ่มขึ้นนั่นก็เพราะอื่นที่ได้มีขนาดเล็กลงเมื่อมีการใช้ค่า P_t ที่สูงทำให้อัตรานอ้มัลไลซ์รีคอลลดลงแปรผันตามค่า P_t



รูปที่ 4.8 อัตรานอ้มัลไลซ์พรีซีชันของแพรวัวส์อัลกอริทึมเมื่อมีการใช้ P_t จาก 0.1 – 1 และใช้ $t=0$, $T=30$

ส่วนรูปที่ 4.8 แสดงอัตรานอ้มัลไลซ์พรีซีชันที่จะเพิ่มขึ้นตามค่า P_t ที่เพิ่มขึ้น โดยอัตรานอ้มัลไลซ์พรีซีชันจะเพิ่มขึ้นเรื่อยจนถึงค่าของ P_t ค่าหนึ่ง แล้วอัตรานอ้มัลไลซ์พรีซีชันจะเริ่มลดลง แม้ว่าจะเพิ่มค่า P_t แล้วก็ได้ไม่ได้ทำให้อัตรานอ้มัลไลซ์พรีซีชันเพิ่มขึ้นอีกแล้ว



รูปที่ 4.9 ขนาดเฉลี่ยของฮินของแพรวัวส์อัลกอริทึมเมื่อมีการใช้ P_i จาก 0.1 – 1 และใช้ $t=0, T=30$

จากรูปที่ 4.9 แสดงความสัมพันธ์ของขนาดเฉลี่ยของฮินและค่าความน่าจะเป็นทรสโสลจะเห็นว่าเมื่อมีการใช้ค่าความน่าจะเป็นทรสโสลที่ค่าต่ำ จะได้ขนาดของฮินที่มีขนาดใหญ่ ซึ่งจะทำให้ค่าอัตราอนุมัติไลซ์รีคอลมีอัตราสูงเพราะฮินมีขนาดใหญ่ยิ่งทำให้มีโอกาสที่การร้องถัดไปจะอยู่ในฮินมาก ในขณะที่ถ้ามีการใช้ค่าความน่าจะเป็นทรสโสลที่สูง จะได้ฮินที่มีขนาดเล็กซึ่งทำให้อัตราอนุมัติไลซ์รีคอลมีอัตราลดลงแต่ฮินที่ได้จะมีความถูกต้องมากขึ้นเพราะมาจากข้อมูลจำนวนมากขึ้น ซึ่งจะเห็นว่าอัตราอนุมัติไลซ์รีคอลกับอัตราอนุมัติไลซ์พีริซันค่อนข้างเป็นส่วนกลับกัน ดังนั้นการหาค่าที่เหมาะสมระหว่างค่าความน่าจะเป็นทรสโสลที่ดีที่สุดที่ให้อัตราอนุมัติไลซ์รีคอลและอัตราอนุมัติไลซ์พีริซันที่ดีที่สุดจึงเป็นสิ่งสำคัญมาก และการใช้ค่าช่วงเวลาที่ใช้ในการสร้างฮิน (Time Interval) นั้นจะขึ้นกับว่ามีการใช้กับโปรแกรมประยุกต์ใด ซึ่งโปรแกรมประยุกต์ใดหนึ่งอาจจะต้องใช้ช่วงเวลา 0-300 วินาทีถึงจะดีแต่กับอีกโปรแกรมประยุกต์อีกอันหนึ่งอาจจะใช้แค่ 0-30 วินาทีก็พอแล้ว

4.4 วิเคราะห์ประสิทธิภาพของแพรวัวส์อัลกอริทึม

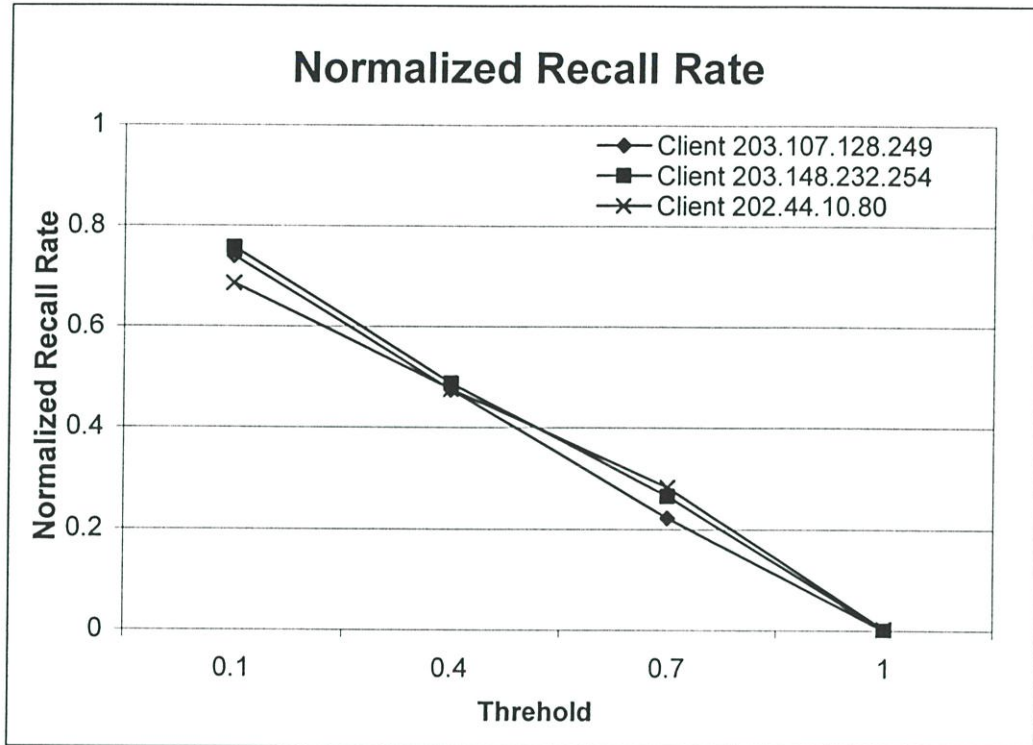
ซึ่งตามที่ได้กล่าวไปแล้วจะทำให้เมื่อมีการใช้ค่า P_i ที่สูงแล้วอัตราanomัลไลซ์รีคอลที่ได้ควรที่จะน่าจะดีขึ้นเรื่อย กลับมีการลดลง จากรูปที่ 4.7 และจะเห็นได้ว่าอัตราanomัลไลซ์พีริซิชั่นจะเพิ่มขึ้นตามค่า P_i ที่เพิ่มขึ้นนั่นก็เพราะว่าเมื่อมีการใช้ค่า P_i ที่สูงนั้น อันที่ได้ก็จะมีค่าความถูกต้องสูงเพราะถ้าค่า P_{ba} สูงแล้วนั้นก็หมายถึงว่ามีจำนวนผู้ใช้จำนวนมากที่ร้องขอเว็บเพจ B ต่อจากเว็บเพจ A แต่เมื่อมีใช้ค่า P_i ที่สูงมากๆ ใกล้ค่า 1 แล้วอันที่ได้นั้นมีขนาดเล็กๆ มากหรือไม่ได้เลย ทำให้ค่าanomัลไลซ์พีริซิชั่นที่ได้จะลดลงอย่างรวดเร็วมากซึ่งแสดงให้เห็นว่าการใช้ค่า P_i ที่สูงๆ มากแล้วไม่ได้ทำให้anomัลไลซ์อัตราพีริซิชั่นดีตามไปด้วย จากรูปที่ 4.8 ซึ่งแสดงให้เห็นถึงว่าอันที่ได้ไม่ค่อยมีประสิทธิภาพนัก

และสำหรับแพรวัวส์อัลกอริทึมนั้นจะใช้ข้อมูลการร้องขอในอดีตมาใช้ในการสร้างรูปแบบการเข้าถึงเว็บเพจหรือรีซอร์สต่างของผู้ใช้ทุกคน ซึ่งตรงนี้นั้นเมื่อมีการใช้ค่า P_i ที่สูงแล้วก็จะให้ได้อันที่มาจากรูปแบบการร้องขอของผู้ใช้ที่มีการร้องขอมากครั้งหรือผู้ใช้ที่มีอัตราการร้องขอต่อเว็บเพจทั้งหมดที่ร้องขอมีค่ามากเท่านั้น เพราะแพรวัวส์อัลกอริทึมเองจะใช้ข้อมูลการเข้าถึงเว็บเพจหรือรีซอร์สต่างบนเครื่องแม่ข่ายของผู้ใช้ทั้งหมดร่วมกันและนำข้อมูลนั้นมาสร้างเป็นกลุ่มของอันที่จะนำมาใช้งานกับผู้ใช้ทุกๆ คน

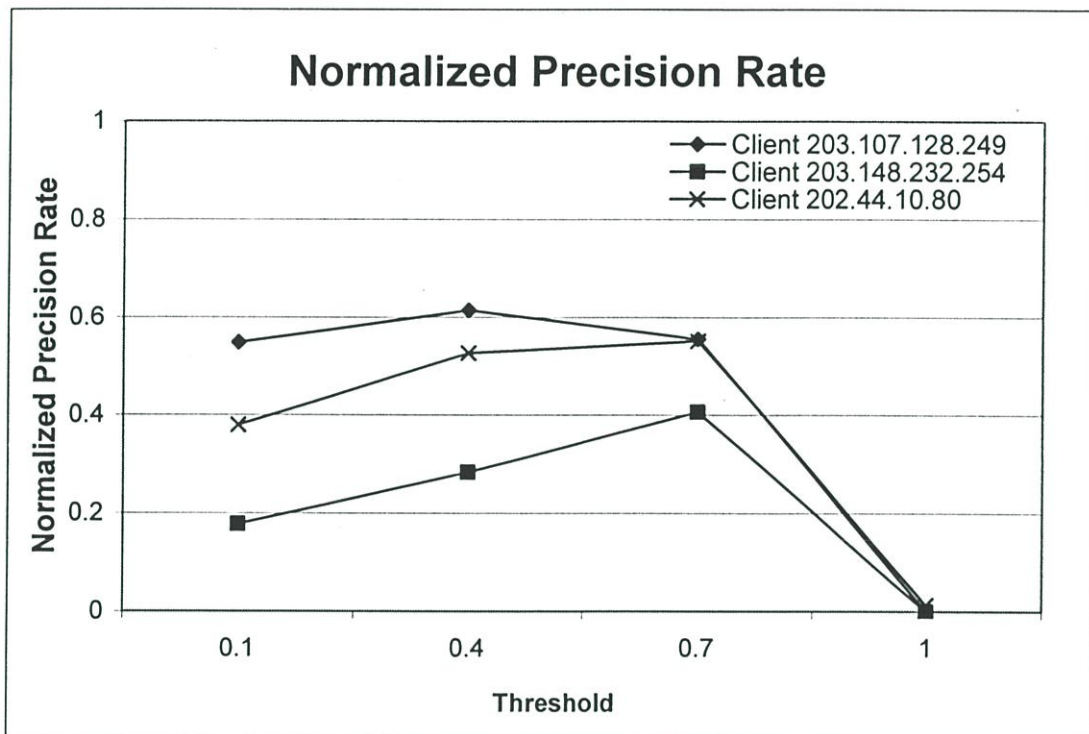
ดังนั้นในวิทยานิพนธ์นี้จึงได้ใช้อันที่ได้จากแพรวัวส์อัลกอริทึมมาจำลองสถานการณ์ตามที่ได้กล่าวไปแล้วแต่จะคำนวณอัตราanomัลไลซ์รีคอล, nomัลไลซ์พีริซิชั่นและขนาดของอันเฉลี่ยเป็นผู้ใช้คนๆ ไป เพื่อให้เห็นว่าเมื่อคิดค่าเฉลี่ยอัตราanomัลไลซ์รีคอล, อัตราanomัลไลซ์พีริซิชั่นของอันที่ได้จากแพรวัวส์อัลกอริทึมเป็นคณา แล้ว อัน ของแพรวัวส์อัลกอริทึมนั้นจะแสดงความไม่มีประสิทธิภาพเท่าที่ควร ความไม่มีประสิทธิภาพของอันที่ได้จากแพรวัวส์อัลกอริทึมนั้นมาจากการใช้ข้อมูลร่วมกันของผู้ใช้ทั้งหมดนำมาสร้างเป็นกลุ่มของอันเพื่อนำมาใช้กับผู้ใช้คนต่างๆ นั่นเอง

จากรูปที่ 4.10 และรูปที่ 4.11 ซึ่งจะแสดงอัตราanomัลไลซ์รีคอลและอัตราanomัลไลซ์พีริซิชั่นของผู้ใช้ที่มีการร้องขอมามากที่สุด 3 อันดับแรก จะเห็นได้ว่าแม้ว่าผู้ใช้ทั้งสามคนจะมีการร้องขอเว็บเพจหรือรีซอร์สต่างๆ มากครั้งที่สุด แต่อัตราanomัลไลซ์พีริซิชั่นและอัตราanomัลไลซ์รีคอลก็ไม่ได้สูงตามไปด้วย ทั้งที่ผู้ใช้ทั้งสามน่าจะมียอดรูดังกล่าวในระดับสูงเพราะมีข้อมูลการร้องขอของผู้ใช้ทั้งสามมาก นั่นก็เพราะอันที่ได้นั้นมีส่วนของข้อมูลที่ได้จากผู้ใช้คนอื่นๆ ด้วยทำให้อันดังกล่าวไม่ได้แสดงถึงรูปแบบหรือลักษณะการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆ ของผู้ใช้ทั้งสามได้ดีพอ

]



รูปที่ 4.10 อัตราอนุมัติไลเซนส์รีคอลของแพร์ไวส์อัลกอริทึมเมื่อมีการใช้ P_i จาก 0.1 – 1 และใช้ $t=0$, $T=30$ ของผู้ใช้ที่มีการร้องขอ 3 อันดับแรก



รูปที่ 4.11 อัตราanomัลไลซ์พีริซึชันของแพรวัวส์อัลกอริทึมเมื่อมีการใช้ P_i จาก 0.1 – 1 และใช้ $t=0$, $T=30$ ของผู้ใช้ที่มีการร้องขอ 3 อันดับแรก

ในบทถัดจะกล่าวถึงการปรับปรุงประสิทธิภาพของแพรวัวส์อัลกอริทึมให้ดีขึ้น และสามารถสร้างอื่นที่มีประสิทธิภาพที่ให้อัตราanomัลไลซ์รีคอดและอัตราanomัลไลซ์พีริซึชันที่ดีขึ้น

บทที่ 5

แพร่ไวรัสอัลกอริทึมแบบใช้ 2 โทรสโสด

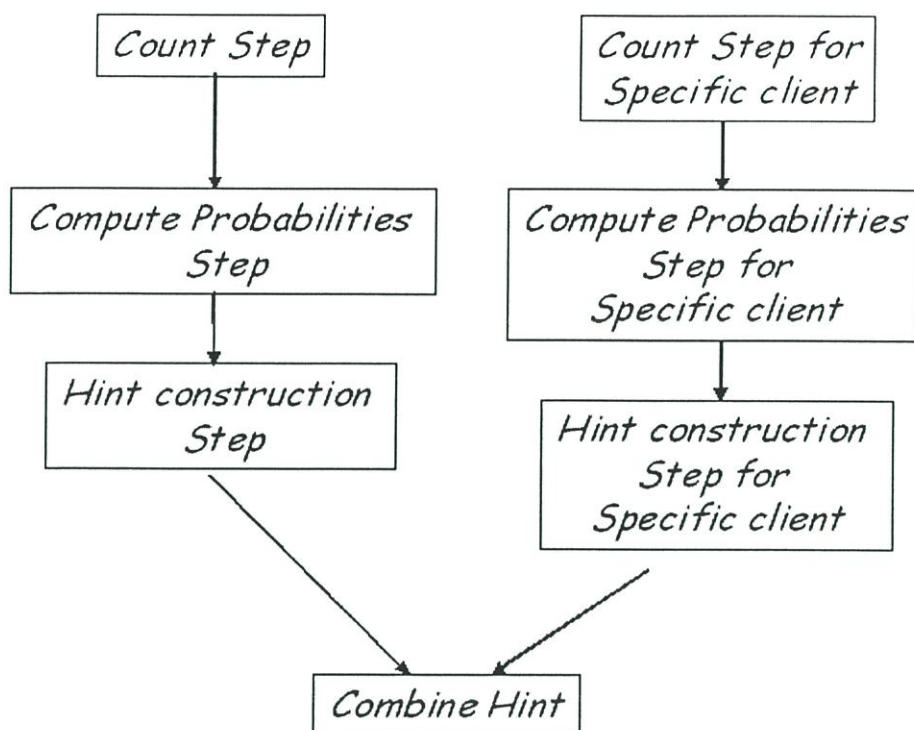
จากบทที่แล้วได้มีการกล่าวถึงข้อดีของแพร่ไวรัสอัลกอริทึมจึงได้มีการนำเสนอแพร่ไวรัสอัลกอริทึมแบบใช้ 2 โทรสโสดเพื่อเพิ่มประสิทธิภาพของแพร่ไวรัสอัลกอริทึมเดิม

5.1 ทฤษฎีของแพร่ไวรัสอัลกอริทึมแบบใช้ 2 โทรสโสด

แพร่ไวรัสอัลกอริทึมแบบใช้ 2 โทรสโสดนั้นจะมีการทำงานแบ่งได้เป็น 2 ส่วนที่ทำงานร่วมกันคือ

1. ส่วนที่มีการสร้างอินจากข้อมูลการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆของผู้ใช้ทั้งหมด การสร้างอินแบบนี้จะไม่มีการสนใจว่าผู้ใช้แต่ละคนเข้าถึงเว็บเพจหรือรีซอร์สอะไรบ้าง เพียงแต่สนใจว่าเซสชันในการเข้าถึงเว็บเพจหรือรีซอร์สของผู้ใช้นั้นเข้าถึงอะไรบ้าง แล้วนำข้อมูลนั้นมาใช้ในการสร้างอิน จะเห็นได้ว่าการทำงานในส่วนนี้ก็คือเป็นแพร่ไวรัสอัลกอริทึมเดิมนั่นเองและในการกล่าวถึงอินในส่วนนี้จะเรียกว่า “Old hint”
2. ส่วนที่มีการสร้างอินจากข้อมูลการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆของผู้ใช้แต่ละคน การสร้างอินแบบนี้คือจะเป็นส่วนที่เพิ่มเติมเข้ามาจากแพร่ไวรัสอัลกอริทึมเดิม โดยจะมีการเก็บด้วยว่าผู้ใช้แต่ละคนนั้นเข้าถึงเว็บเพจหรือรีซอร์สอะไรบ้าง แล้วนำข้อมูลนั้นมาใช้ในการสร้างอินเป็นอินและในการกล่าวถึงอินในส่วนนี้จะเรียกว่า “New hint” ซึ่งอินที่ได้จะมีความเหมาะสมสำหรับผู้ใช้คนหนึ่งๆ

จากส่วนการทำงานทั้งสองส่วนจะเห็นว่าอินที่ได้จากการทำงานส่วนแรกจะเป็นอินที่เหมาะสมกับผู้ใช้ทุกคน เพราะใช้ข้อมูลการเข้าถึงจากผู้ใช้ทั้งหมดในการสร้าง แต่อินในส่วนที่สองนั้นเป็นอินที่เพิ่มจากแพร่ไวรัสอัลกอริทึมเดิมจะเป็นอินที่เหมาะสมกับผู้ใช้เป็นคนๆไปเท่านั้น เพราะสร้างจากข้อมูลการเข้าถึงของผู้ใช้แต่ละคน หลังจากทำงานในทั้งสองส่วนแล้วเมื่อต้องการการทำการส่งอินก็จะทำการรวมเอาอินจากทั้งสองส่วนแล้วจะส่งไปให้ทางไคลเอนต์ต่อไป ขั้นตอนทั้งหมดสามารถสรุปได้ดังรูปที่ 5.1 และจากการที่ส่วนการทำงานแรกจะเหมือนแพร่ไวรัสอัลกอริทึมเดิมตามที่ได้อธิบายไว้ในบทที่ 4 แล้ว ดังนั้นจะอธิบายแต่ส่วนการทำงานที่สองเท่านั้น



รูปที่ 5.1 ขั้นตอนทั้งหมดของแพรวัวส์อัลกอริทึมแบบใช้ 2 เทรสโสด

5.1.1 ส่วนที่มีการสร้างอินจากข้อมูลการเข้าถึงเว็บเพจหรือรีซอร์สต่างๆของผู้ใช้แต่ละคน

ส่วนการทำงานนี้จะขั้นตอนที่คล้ายกับแพรวัวส์อัลกอริทึมเดิม แต่จะแยกเก็บค่าเคาเตอร์ต่างๆของผู้ใช้เป็นคนๆไป รายละเอียดของแต่ละขั้นตอนเป็นดังนี้รูปที่ 5.2 สำหรับคำนิยามต่างๆ จะเป็นเหมือนที่ใช้ในแพรวัวส์อัลกอริทึมเดิมในบทที่ 4 แต่จะขอกำหนดความน่าจะเป็นเทรสโสดของส่วนที่ 1 (แพรวัวส์อัลกอริทึมเดิม) เป็น P_{11} และส่วนความน่าจะเป็นเทรสโสดของส่วนที่ 2 จะให้เป็น P_{12}

5.1.1.1 การเก็บจำนวนครั้งของการขึ้นต่อกันของเว็บเพจ ($C_{b|a}$) ที่ผู้ใช้แต่ละคนเข้าถึง ขั้นตอนนี้จะทำการนับจำนวนครั้งของการขึ้นต่อกันของเว็บเพจเช่นเดียวกับที่ทำในแพรวัวส์อัลกอริทึมเดิม แต่จะมีการทำงานที่เพิ่มเติมก็คือจะแยกเก็บเคาเตอร์ต่างๆ แยกเป็นผู้ใช้คนๆไป ที่ต้อง ทำอย่างนี้ก็เพราะต้องการใช้เคาเตอร์ต่างๆของการขึ้นต่อกันของเว็บเพจต่างๆ ของแต่ละผู้ใช้ ในการคำนวณหาความน่าจะเป็นของการที่ผู้ใช้คนใดคนหนึ่งร้องขอเว็บ A แล้วตามด้วยเว็บเพจ B ($C_{b|a}$) (ดู การทำงานได้ใน ภาคผนวก ข. Flowchart ที่ 5)

5.1.1.2 การคำนวณหาความน่าจะเป็นของการขึ้นต่อกันของเว็บเพจ ($P_{b|a}$) ที่ผู้ใช้แต่ละคนเข้าถึง

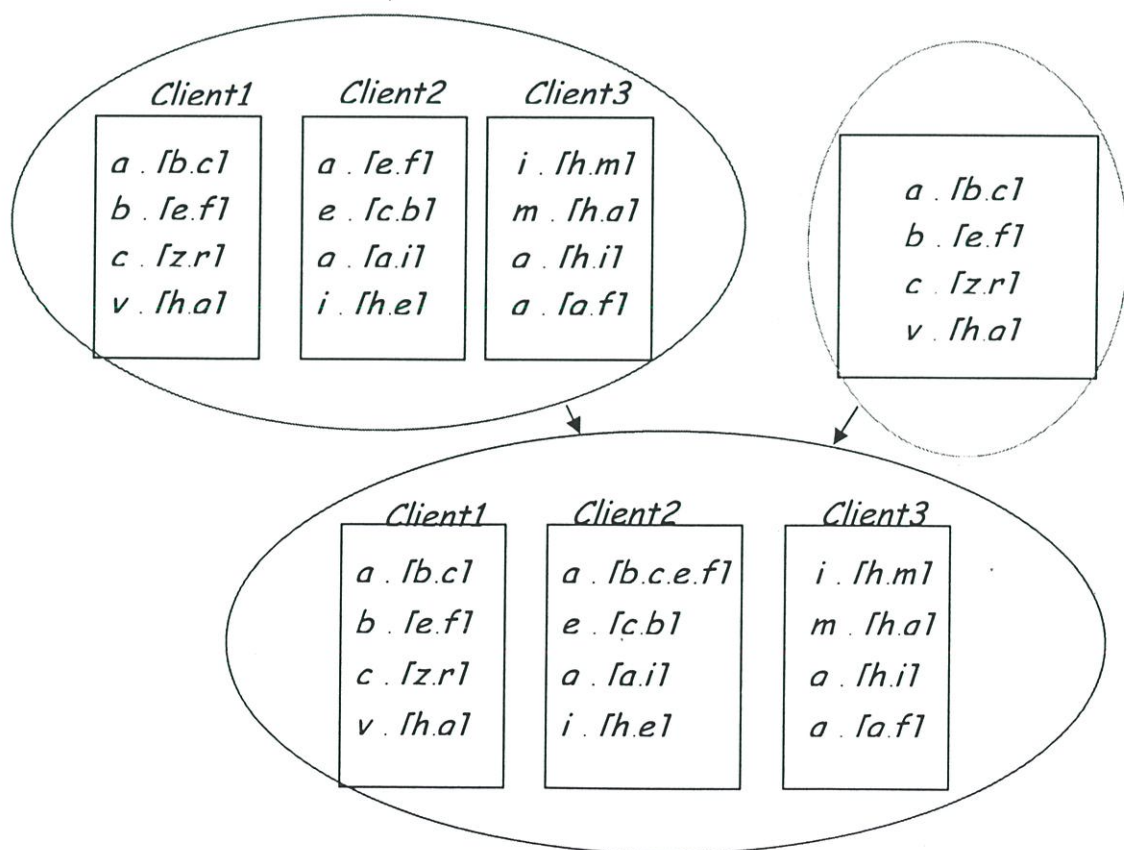
ขั้นตอนนี้จะทำเช่นเดียวกับแพรวัวส์อัลกอริทึมเดิม แต่ที่แตกต่างคือจะแยกเก็บความน่าจะเป็นของการขึ้นต่อกันของเว็บเพจเป็นผู้ใช้คนๆ ไป (ดูการทำงานได้ใน ภาคผนวก ข. Flowchart ที่ 6)

5.1.1.3 สร้างอินสำหรับผู้ใช้แต่ละคน

ขั้นตอนนี้ก็เช่นเดียวกับแพรวัวส์อัลกอริทึมเดิม ก็จะพิจารณาว่าความน่าจะเป็นของการขึ้นต่อกันของเว็บเพจ B ใดๆ ขึ้นต่อ A ใดๆ (P_{ba}) ถ้ามีค่ามากกว่าความน่าจะเป็นทรสโสล (P_{12}) ก็จะนำเอาเว็บเพจ B นั้นใส่เข้าไปเป็นอินของเว็บเพจ A ของผู้ใช้คนหนึ่งๆ โดยที่ค่าความน่าจะเป็นทรสโสลนี้ (P_{12}) อาจจะเป็นค่าเดียวกับค่า P_{11} ของการทำงานในส่วนแรก (แพรวัวส์อัลกอริทึมเดิม) ก็ได้ (ดู การทำงานได้ใน ภาคผนวก ข. Flowchart ที่ 7)

5.1.1.4 การรวมอินที่ได้จะทั้ง 2 ส่วนการทำงาน

ขั้นตอนนี้จะทำการรวมอินที่ได้จากข้อมูลที่การเข้าถึงเว็บเพจของผู้ใช้ทุกคนมาสร้างอินและข้อมูลการเข้าถึงเว็บเพจของผู้ใช้แต่ละคนแยกกันมาสร้างเป็นอิน มารวมกัน โดยจะเลือกเอาอินของทั้งสองส่วนที่ซ้ำจะเอามาแค่หนึ่งรวมเป็นอินสุดท้ายที่จะใช้ในการส่งไปให้เว็บไคลเอนต์เพื่อใช้ในการพรีเฟรชซึ่งต่อไป ดังรูปที่ 5.2 (ดู การทำงานได้ใน ภาคผนวก ข. Flowchart ที่ 8)



รูปที่ 5.2 การรวมอินของแพรวัวส์อัลกอริทึมแบบใช้ 2 ทรสโสล

จากรูปที่ 5.2 สำหรับกลุ่มของอินที่ได้จากแพรวัวส์อัลกอริทึมแบบใช้ 2 เทรสโสลส่วนแรก(แพรวัวส์อัลกอริทึมเดิม) คือกลุ่มที่อยู่วงกลมด้านบนขวา และกลุ่มของอินที่ได้จากแพรวัวส์อัลกอริทึมแบบใช้ 2 เทรสโสลส่วนที่สองจะเป็นส่วนที่อยู่ในวงกลมด้านบนซ้าย จะเห็นได้ว่าจะมีกลุ่มของอินเฉพาะของแต่ละผู้ใช้ไปภายในกลุ่มของอินทั้งหมด และสุดท้ายส่วนของอินที่เป็นที่อยู่ด้านล่างจะเป็นกลุ่มของอินที่ได้จากการรวมอินจากทั้งสองส่วนแล้วจะเห็นได้ว่าในส่วนของผู้ใช้คนที่ 2 จะได้อินเพิ่มเติมจากการทำงานในส่วนแรกเข้าไปด้วย และอินสุดท้ายจะมีสำหรับผู้ใช้แต่ละคนไป เช่นถ้าผู้ใช้มีการร้องเว็บเพจ E มา ทางเว็บเซิร์ฟเวอร์ก็จะส่งอินของเว็บเพจ E ที่อยู่ในส่วนของอินของผู้ใช้คนที่ 2 ในกลุ่มของอินสุดท้ายที่ได้จากการรวมกันของอินกลับไป จากตัวอย่างที่ 5.2 นั้นก็คือ C, B

สำหรับอัลกอริทึมของแพรวัวส์อัลกอริทึมที่มีการใช้เทรสโสล 2 ระดับจะเป็นดังตารางที่ 5.1

ตารางที่ 5.1 ตัวอย่างของแพรวัวส์อัลกอริทึมที่มีการใช้เทรสโสล 2 ระดับ

```
// ขั้นตอนการลบข้อมูลส่วนที่เป็น CGI, ASP, JSP
สำหรับแต่ละเรคคอร์ดในล็อกไฟล์
    ถ้ารูปแบบของไฟล์ไม่เป็น .CGI หรือ .ASP หรือ .JSP หรือ .PHP
        ทำการเก็บค่า Ti,ค่า MD5 ของไอพีของผู้ใช้, ค่า MD5 ของเว็บเพจที่ถูกเข้าถึง

// นับจำนวนการร้องขอ a แล้วตามด้วย b (ส่วนที่หนึ่ง)
สำหรับผู้ใช้คนที่ i ของผู้ใช้ที่มีการร้องขอมาทั้งหมด
    สำหรับเว็บเพจ a ที่ผู้ใช้ i
         $C_a = C_a + 1$ 
        สำหรับเว็บเพจ b ที่ถูกร้องขอตามหลังเว็บเพจ a ของผู้ใช้คนที่ i
             $C_{b|a} = C_{b|a} + 1$ 
```

ตารางที่ 5.1(ต่อ)

// จำนวนค่า $P_{b|a}$ ของแต่เว็บเพจ a

สำหรับเว็บเพจ a ที่ถูกร้องขอมา

สำหรับเว็บเพจ b ที่ถูกร้องขอตามหลังเว็บเพจ a

$$P_{b|a} = C_{b|a} / C_a$$

// สร้างอิน

สำหรับเว็บเพจ a ที่ถูกร้องขอมา

สำหรับเว็บเพจ b ที่ถูกร้องขอตามหลังเว็บเพจ a

ถ้า $P_{b|a}$ ใดมีค่ามากกว่า P_t แล้วให้เพิ่มเว็บเพจ b เข้าไปในอินของเว็บเพจ a

ผลลัพธ์ที่ได้ : กลุ่มของอินที่จะใช้กับผู้ใช้ทุกคน

----- จบส่วนการทำงานที่หนึ่ง -----

// นับจำนวนการร้องขอ a แล้วตามด้วย b ของผู้ใช้แต่ละคน

สำหรับผู้ใช้คนที่ i ของผู้ใช้ที่มีการร้องขอมาทั้งหมด

สำหรับเว็บเพจ a ที่ผู้ใช้ i

$$C_a = C_a + 1 \quad (C_a \text{ ของผู้ใช้คนที่ } i)$$

สำหรับเว็บเพจ b ที่ถูกร้องขอตามหลังเว็บเพจ a ของผู้ใช้คนที่ i

$$C_{b|a} = C_{b|a} + 1 \quad (C_{b|a} \text{ ของผู้ใช้คนที่ } i)$$

// จำนวนค่า $P_{b|a}$ ของแต่เว็บเพจ a ของผู้ใช้แต่ละคน

สำหรับเว็บเพจ a ที่ถูกร้องขอมา

สำหรับเว็บเพจ b ที่ถูกร้องขอตามหลังเว็บเพจ a

$$P_{b|a} = C_{b|a} / C_a \quad (P_{b|a} \text{ ของผู้ใช้คนที่ } i)$$

ตารางที่ 5.1(ต่อ)

// สร้างอินสำหรับแต่ละคน

สำหรับผู้ใช้คนที่ i ของผู้ใช้ทั้งหมด

สำหรับเว็บเพจ a ที่ถูกร้องขอมาของผู้ใช้คนที่ i

สำหรับเว็บเพจ b ที่ถูกร้องขอตามหลังเว็บเพจ a ของผู้ใช้คนที่ i

ถ้า $P_{b|a}$ โคของผู้ใช้คนที่ i มีค่ามากกว่า $P_{b|a}$ แล้วให้เพิ่มเว็บเพจ b เข้าไปในอินของเว็บเพจ a ของผู้ใช้คนที่ i

ผลลัพธ์ที่ได้ : กลุ่มของอินที่จะใช้กับผู้ใช้เฉพาะคนๆ ไป

----- จบส่วนการทำงานที่สอง -----

// เวลาส่งอินกลับไปให้เว็บไคลเอนต์ของผู้ใช้ในกรณีที่ร้องขอเว็บเพจ a

สำหรับกลุ่มของเว็บเพจที่เป็นอินของเว็บเพจ a ของผู้ใช้คนที่ร้องขอมา (ส่วนการทำงานที่สอง)

สำหรับเว็บเพจ b ใดๆที่เป็นอินของเว็บเพจ a (จากส่วนการทำงานที่หนึ่ง)

ถ้าเว็บเพจ b ไม่อยู่ในอินของเว็บเพจ a ของผู้ใช้คนที่ร้องขอมา

เพิ่มเว็บเพจ b เข้าไปเป็นอินของเว็บเพจ a ของผู้ใช้คนที่ i

ผลลัพธ์สุดท้าย : กลุ่มของอินที่ได้จากการรวมกันของอินทั้งส่วน ซึ่งเป็นกลุ่มของอินเฉพาะของผู้ใช้แต่ละคนไปส่งกลับไปให้เว็บไคลเอนต์ของผู้ใช้

5.2 การวัดประสิทธิภาพของแพร์ไวส์อัลกอริทึมแบบใช้ 2 เทรสโสด

การวัดประสิทธิภาพของแพร์ไวส์อัลกอริทึมแบบใช้ 2 เทรสโสดนั้นจะวัดในแบบเช่นเดียวกับที่ใช้วัดประสิทธิภาพของแพร์ไวส์อัลกอริทึมเดิมดังที่ได้กล่าวไว้ในบทที่ 4 ก็คือจะใช้หลักในการวัดเดียวกัน ซึ่งจะวัดในรูปของอัตรานอมัลไลซ์รีคอล, นอมัลไลซ์พรีซิชั่นและขนาดของอินโดยเฉลี่ยเช่นเดียวกับในบทที่ 4 แต่จะวัดเป็นอินของผู้ใช้เป็นคนๆ ไป เมื่อได้อัตราทั้งสามอย่างจากอินของแต่ละคนแล้วจึงมาหาค่าเฉลี่ยจากผู้ใช้ทั้งหมดอีกครั้งหนึ่ง ดังสูตรที่ 1, 2, 3

Normalized Recall :

$$\text{Number of Client} \sum_{K=1} \left(\frac{\sum_{j=1}^{n_sendhint \text{ of Client } k} \left(\frac{Hited - \text{number of hinturl } a}{n_after a} \right)}{n_sendhint} \right) \text{Number of all client}$$

Normalized Precision :

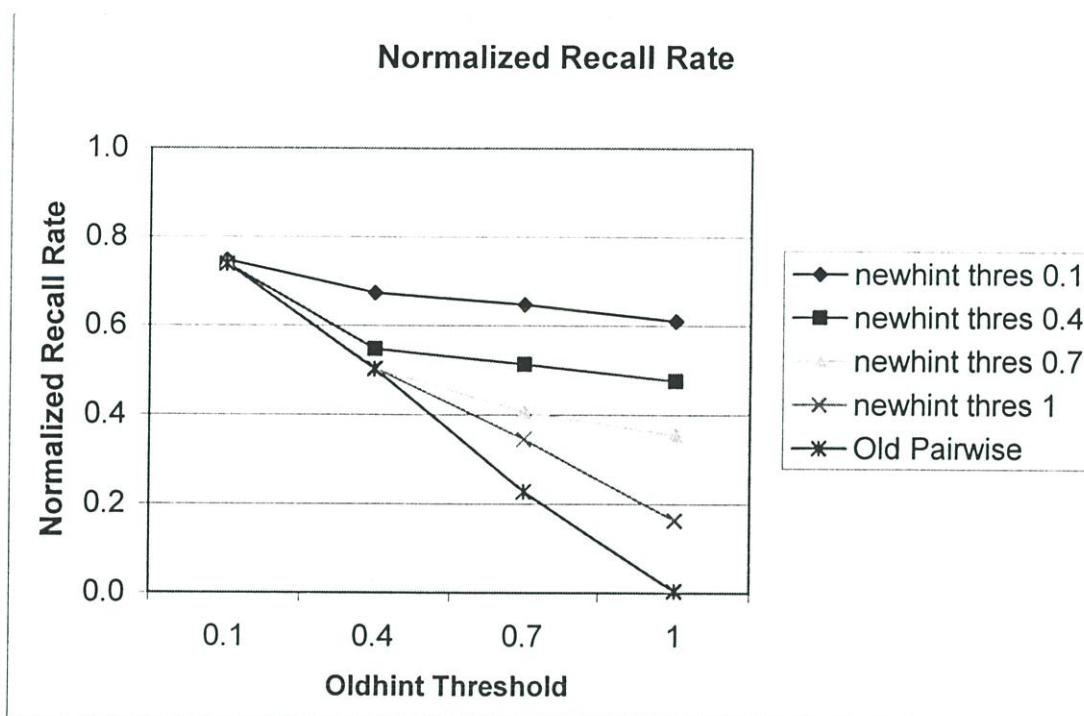
$$\text{Number of Client} \sum_{K=1} \left(\frac{\sum_{j=1}^{n_sendhint \text{ of Client } k} \left(\frac{\sum_{i=1}^{N_hinturl \text{ of } a \text{ of Client } k} Hited - \text{status of hinturl of } a}{n_hinturl \text{ of } a \text{ of Client } k} \right)}{n_sendhint} \right) \text{Number of All Client}$$

Average Hintsize :

$$\text{Number of Client} \sum_{K=1} \left(\frac{\sum_{i=1}^{n_sendhint \text{ of } a \text{ of Client } k} n_hinturl \text{ of } a}{n_sendhint} \right) \text{Number of All Client}$$


5.3 ประสิทธิภาพของแพรวีส์อัลกอริทึมที่มีการใช้เทรสโล 2 ระดับ

ในการจำลองสถานการณ์จะใช้ข้อมูลชุดเดียวกับที่ใช้ในการจำลองสถานการณ์ของแพรวีส์อัลกอริทึมเดิมดังในบทที่ 4 (ในการจำลองสถานการณ์เพื่อวัดประสิทธิภาพของแพรวีส์อัลกอริทึมแบบใช้เทรสโล 2 ระดับจะจำลองสถานการณ์ในอยู่บนสมมติฐานที่ว่าเครื่องเซิร์ฟเวอร์ที่ใช้ในการสร้างอิน์นั้นมึขนาดของเมมโมรีขนาดใหญ่และมีโพเรสเซอร์ที่มีความเร็วสูง เพราะการทำงานของแพรวีส์อัลกอริทึมแบบใช้เทรสโล 2 ระดับจะต้องใช้เมมโมรีสูง) ผลการจำลองสถานการณ์การทำงานแพรวีส์อัลกอริทึมแบบมีการใช้ เทรสโล 2 ระดับของผู้ใช้ 3 อันดับแรกที่มีการเข้าถึงเว็บเซิร์ฟเวอร์มากที่สุดเป็นดังรูปที่ 5.3 – 5.11




รูปที่ 5.3 แสดงอัตรานอมนัลไลซ์รีคอลที่ได้จากเพอร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้

203.107.128.249



รูปที่ 5.4 แสดงอัตรานอมนัลไลซ์รีคอลที่ได้จากเพอร์ไวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้

202.28.22.254




รูปที่ 5.5 แสดงอัตราอรรถประโยชน์ที่ได้ออกจากเพอร์โวลต์อัลกอริทึมแบบ 2 เทรสโวลต์ของผู้ใช้

202.44.10.80

จากรูปที่ 5.3 – 5.5 นั้นจะแสดงอัตราอรรถประโยชน์ของผู้ใช้ที่มีการร้องขอมาที่เว็บเซิร์ฟเวอร์มากที่สุด 3 อันดับแรก โดยในแกน X จะแทนค่า P_{11} นั่นก็คือค่าความน่าจะเป็นเทรสโวลต์ของเพอร์โวลต์อัลกอริทึมแบบใช้ 2 เทรสโวลต์ในส่วนที่หนึ่ง (เพอร์โวลต์อัลกอริทึมเดิม) ส่วนแต่ละเส้นของกราฟจะแสดงค่า P_{12} ที่ใช้ นั่นก็คือค่าความน่าจะเป็นเทรสโวลต์ของเพอร์โวลต์อัลกอริทึมแบบใช้ 2 เทรสโวลต์ส่วนการทำงานที่สองที่มีการใช้ข้อมูลเฉพาะแต่ละคนในการสร้างอื่น

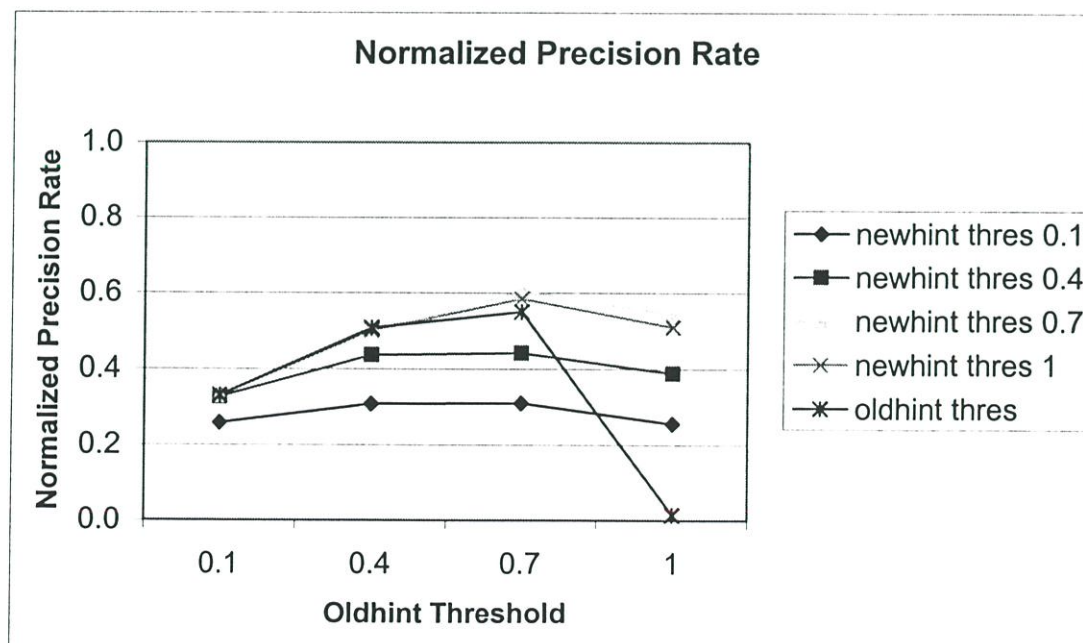
อัตราอรรถประโยชน์ของผู้ใช้ทั้ง 3 คนมีแนวโน้มที่คล้ายกันนั่นก็คือจะมีอัตราอรรถประโยชน์ที่ลดลงเมื่อมีการใช้ค่า P_{11} และ P_{12} ที่ต่ำ แต่ก็ลดลงตามลำดับเมื่อมีการใช้ค่า P_{11} หรือ P_{12} ที่เพิ่มขึ้น เมื่อพิจารณาที่ค่า P_{12} ค่าหนึ่งและเปลี่ยนค่า P_{11} ไปหลายค่าจาก 0.1- 1.0 จะเห็นว่าอัตราการลดลงของค่าอรรถประโยชน์จะน้อยกว่าเพอร์โวลต์อัลกอริทึมเดิม (ดูผลลัพธ์จากในบทที่ 4) มากซึ่งก็ทำให้แสดงถึงประสิทธิภาพที่ดีกว่าเพอร์โวลต์อัลกอริทึมเดิม

และสำหรับอัตราอรรถประโยชน์ของเพอร์โวลต์อัลกอริทึมแบบใช้เทรสโวลต์ 2 ระดับนั้นจะเป็นดังรูปที่ 5.6 – 5.8



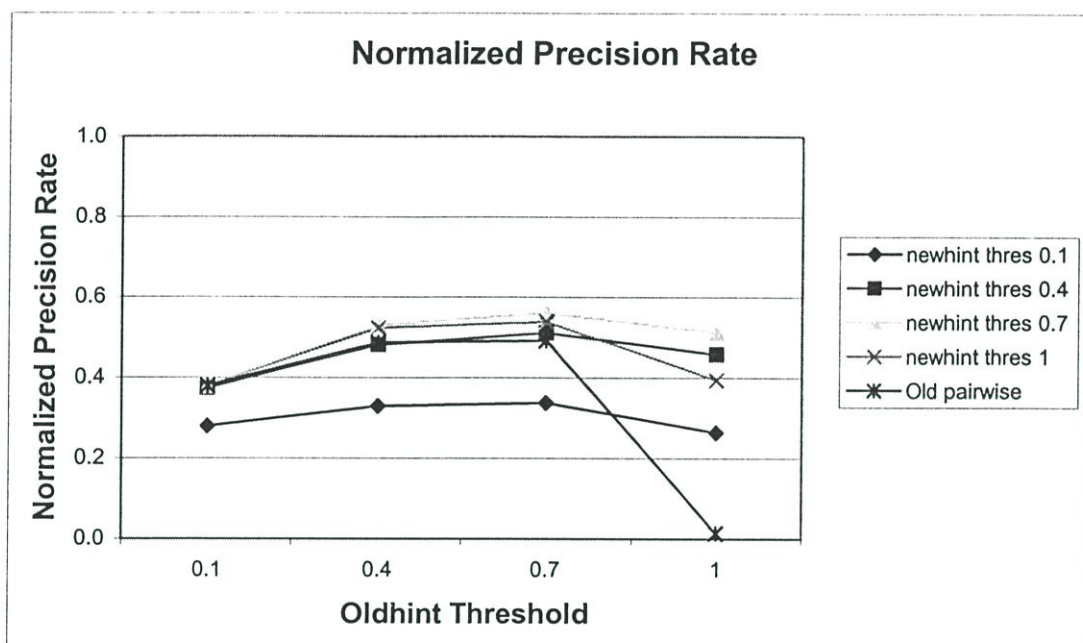
รูปที่ 5.6 แสดงอัตรานอ้มัลไลซ์พรีซิชั่นจากแพรวัวส์อัลกอริทึมแบบ 2 เทรสโสลของผูู้้ใช้

203.107.128.249



รูปที่ 5.7 แสดงอัตรานอ้มัลไลซ์พรีซิชั่นจากแพรวัวส์อัลกอริทึมแบบ 2 เทรสโสลของผูู้้ใช้

202.28.22.254

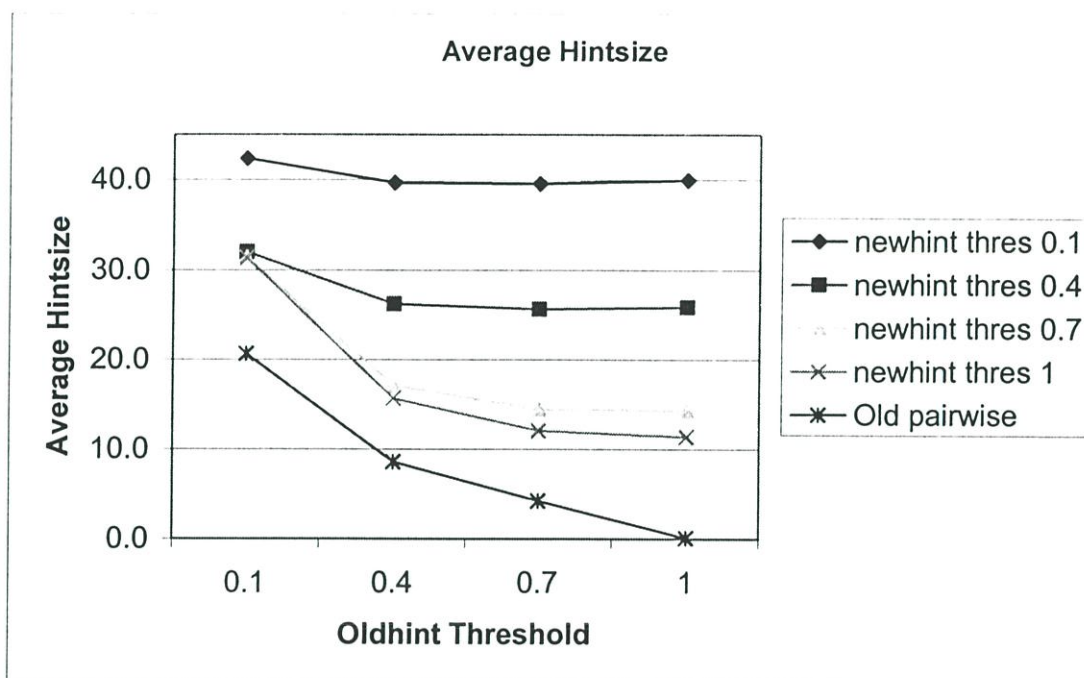


รูปที่ 5.8 แสดงอัตราอรรถนะไลซ์พรีซิชั่นที่ได้จากแพรวัวส์อัลกอริทึมแบบ 2 เทรส โสลของผู้ใช้

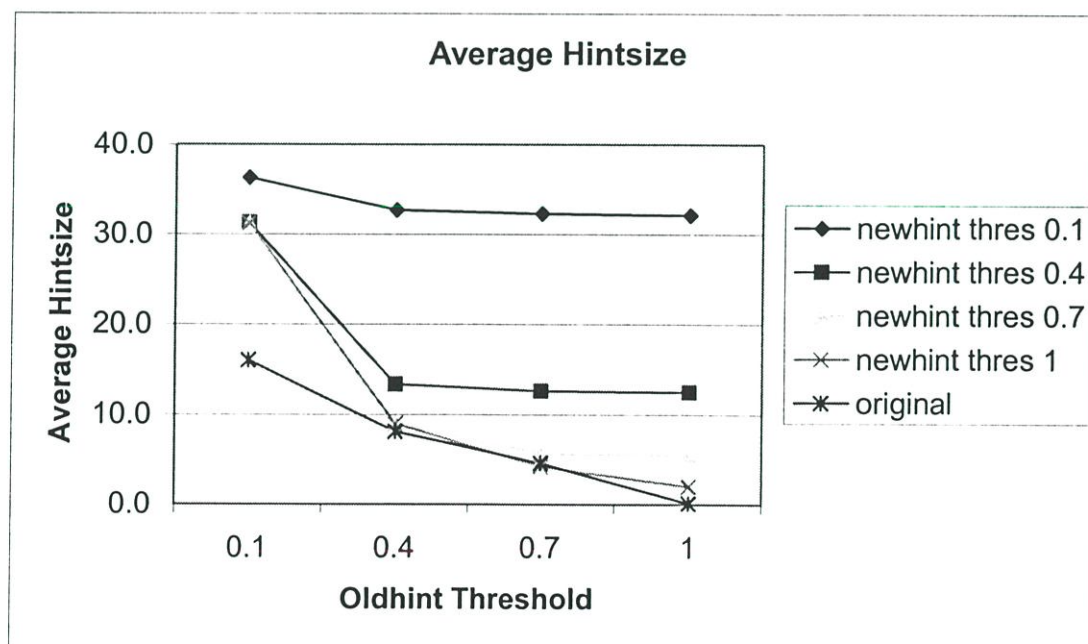
202.44.10.80

สำหรับอัตราอรรถนะไลซ์พรีซิชั่นของผู้ใช้ทั้งสามคน จะเห็นได้ว่าอัตราอรรถนะไลซ์พรีซิชั่นส่วนใหญ่จะมีค่าที่สูงกว่าแพรวัวส์อัลกอริทึมเดิม อีกทั้งการเพิ่มขึ้นของอัตราอรรถนะไลซ์พรีซิชั่นยังเพิ่มขึ้นหรือคงที่และถึงจะมีการตกลงของอัตราอรรถนะไลซ์พรีซิชั่นก็มีการลดลงเพียงเล็กน้อยเท่านั้น เมื่อเปรียบเทียบกับแพรวัวส์อัลกอริทึมเดิมที่มีการลดลงอย่างรวดเร็ว


สำหรับขนาดของอินเดิลซ์ของแพรวัวส์อัลกอริทึมเดิมเมื่อเทียบกับแพรวัวส์อัลกอริทึมที่มีการใช้เทรสโสลแบบ 2 ระดับจะเป็นดังรูปที่ 5.9 – 5.11 ซึ่งจะเห็นได้ว่าขนาดของอินเดิลซ์ที่ได้จากแพรวัวส์อัลกอริทึมแบบใช้ 2 เทรสโสนั้นค่อนข้างที่จะมีขนาดใหญ่กว่าแพรวัวส์อัลกอริทึมเดิมเมื่อมีการใช้ P_2 ที่มีค่าต่ำ แต่เมื่อมีการใช้ค่า P_2 ที่มีค่าสูงๆแล้ว ขนาดของอินเดิลซ์ที่ได้จากแพรวัวส์อัลกอริทึมแบบใช้ 2 เทรสโสลจะมีขนาดใหญ่กว่าแพรวัวส์อัลกอริทึมเดิมไม่มากเท่านั้นแต่ก็ทำให้ประสิทธิภาพของแพรวัวส์อัลกอริทึมแบบใช้ 2 เทรสโสลมีมากกว่าแพรวัวส์อัลกอริทึมเดิม ดังที่ได้กล่าวไปแล้วในส่วนของอัตราอรรถนะไลซ์รีคอลและอัตราอรรถนะไลซ์พรีซิชั่น



รูปที่ 5.9 แสดงขนาดชิ้นเฉลี่ยจากแพรวัวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 203.107.128.249




รูปที่ 5.10 แสดงขนาดชิ้นเฉลี่ยจากแพรวัวส์อัลกอริทึมแบบ 2 เทรสโสลของผู้ใช้ 202.28.22.254




รูปที่ 5.11 แสดงขนาดอินเทิลจี้จากแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโหลของผู้ใช้ 202.44.10.80


สำหรับเมื่อเปรียบเทียบแพร์ไวส์อัลกอริทึมแบบใช้ 2 เทรสโหลกับแพร์ไวส์อัลกอริทึมเดิมของผู้ใช้ทั้งหมดจะได้เป็นดังรูป



รูปที่ 5.12 แสดงอัตราอรรถประโยชน์ของแพร์ไวส์อัลกอริทึมแบบ 2 เทรสโหลของผู้ใช้ทั้งหมด



รูปที่ 5.13 แสดงอัตราanomัล ไลซ์พริซิชั่นเฉลี่ยของแพรวไอส์อัลกอริทึมแบบ 2 เทรสโหลของผู้ใช้ทั้งหมด



รูปที่ 5.14 แสดงอัตราขนาดของฮินเฉลี่ยของแพรวไอส์อัลกอริทึมแบบ 2 เทรสโหลของผู้ใช้ทั้งหมด


จากรูปที่ 5.12 – 5.14 แสดงผลสรุปของประสิทธิภาพของแพรวไอส์อัลกอริทึมที่มีการใช้เทรสโหล 2 ระดับของผู้ใช้ทั้งหมดเมื่อเปรียบเทียบกับแพรวไอส์อัลกอริทึมเดิม จะเห็นได้ว่าอัตรา

นมัลไลซ์รีคอดและอัทรานนมัลไลซ์พีริซิชัน ระหว่างแพรวัวส์อัลกอริทึมเดิมกับแพรวัวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับนี้มีค่าที่ไม่แตกต่างกันนัก นั่นก็เพราะว่าข้อมูลชุดนี้เป็นข้อมูลของล็อกไฟล์ (log file) ที่อยู่ด้านเซิร์ฟเวอร์นั่นเอง ทำให้การหารูปแบบการร้องขอที่นำมาสร้างเป็นอื่นเฉพาะนั้นไม่ค่อยดีพอ เพราะที่ทางด้านเซิร์ฟเวอร์นั้นไอพีแอดเดรสของไคลเอนต์ที่พร้อมของเซิร์ฟเวอร์เห็นอาจจะเป็นไอพีแอดเดรสที่มีการผ่านการแปลงไอพีแอดเดรสจากทางด้านไคลเอนต์แล้ว (Network Address Translation: NAT [11]) ซึ่งทำให้ข้อมูลที่ได้ไม่ได้แสดงถึงรูปแบบการร้องขอของไคลเอนต์จริง แต่ถึงอย่างไรก็ตามอัทรานนมัลไลซ์รีคอดและอัทรานนมัลไลซ์พีริซิชันของแพรวัวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับของไคลเอนต์ที่มีการร้องขอมามากครั้งจริงๆก็ยังคงสูงกว่าแพรวัวส์อัลกอริทึมเดิมดังเช่นรูปที่ 5.3 – 5.5 และรูปที่ 5.6 – 5.8 เพราะข้อมูลที่ได้นำมาสร้างเป็นอื่นได้เอาส่วนของอื่นที่มาจากไคลเอนต์นั้นๆ ครอบคลุมการร้องส่วนใหญ่ของไคลเอนต์นั้นๆ ส่วนขนาดอื่นเฉลี่ยของแพรวัวส์อัลกอริทึมแบบใช้ 2 ระดับจะมีขนาดใหญ่กว่าแพรวัวส์อัลกอริทึมเดิมไม่มากเมื่อใช้ค่า P_2 สูงๆแต่ก็ได้มาซึ่งประสิทธิภาพที่สูงขึ้น


5.4 การปรับปรุงแพรวัวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับ

แพรวัวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับนั้นจะสร้างอื่นจากข้อมูลสองส่วนคือ ข้อมูลการร้องขอเว็บเพจในอิตีคของผู้ทั้งหมด และข้อมูลการร้องขอเว็บในอิตีคของผู้ใช้แต่ละคน ซึ่งการทำงานในส่วนที่สองอาจจะได้อื่นที่มีจำนวนมากเพราะนำมาจากข้อมูลของผู้ใช้คนๆเดียวเท่านั้น ซึ่งข้อมูลหรือลำดับการร้องขอของผู้ใช้คนนั้นอาจจะไม่ได้แสดงถึงรูปแบบการร้องขอของผู้ใช้คนนั้นได้ดีพอได้ดีพอ


การปรับปรุงประสิทธิภาพแพรวัวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับคือ จะทำการสร้างอื่นในส่วนที่สองเฉพาะข้อมูลการร้องขอของผู้ใช้ที่มีจำนวนครั้งในการร้องขอมามากครั้งพอ เพราะถ้าผู้ใช้มีการร้องขอไม่มากครั้งพอ เมื่อนำมาสร้างเป็นอื่นก็จะได้อื่นที่ไม่มีประสิทธิภาพพอ และถึงแม้จะใช้ค่า P_2 ที่ใกล้ๆ 1 แล้วก็อาจยังคงได้อื่นที่ไม่มีประสิทธิภาพพอเพราะเหตุผลที่กล่าวข้างต้น แต่ถ้าข้อมูลมาจากการร้องขอเว็บเพจของผู้ใช้ที่มีการร้องขอมามากครั้ง ข้อมูลนั้นก็จะมีประสิทธิภาพพอที่จะนำมาสร้างเป็นอื่นได้ ในการจำลองสถานการณ์จะใช้จำนวนครั้งที่มาพอในการนำข้อมูลการร้องขอเว็บเพจของผู้ใช้เฉพาะคนมาสร้างเป็นอื่นในส่วนที่สองคือ 68 ครั้ง ซึ่งเป็นค่าเฉลี่ยของจำนวนการร้องขอของผู้ใช้ทั้งหมด และยังได้ลองกับค่าที่มากกว่าค่าเฉลี่ยอีกสองถึงสามค่าเพื่อเปรียบเทียบประสิทธิภาพกับด้วย ซึ่งได้ผลเป็นดังนี้




รูปที่ 5.15 แสดงอัตราอรรถประโยชน์ของแพรวัวส์อัลกอริทึมแบบ 2 เทสโธลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 0.1$




รูปที่ 5.16 แสดงอัตราอรรถประโยชน์ของแพรวัวส์อัลกอริทึมแบบ 2 เทสโธลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 0.4$




รูปที่ 5.17 แสดงอัตราอรรถประโยชน์รีคอลของแพรวัวส์อัลกอริทึมแบบ 2 เทสโธลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 0.7$




รูปที่ 5.18 แสดงอัตราอรรถประโยชน์รีคอลของแพรวัวส์อัลกอริทึมแบบ 2 เทสโธลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 1.0$




รูปที่ 5.19 แสดงอัตราอรรถประโยชน์ของแพรวัวส์อัลกอริทึมแบบ 2 เทรส โสลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 0.1$




รูปที่ 5.20 แสดงอัตราอรรถประโยชน์ของแพรวัวส์อัลกอริทึมแบบ 2 เทรส โสลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_{12} = 0.4$




รูปที่ 5.21 แสดงอัตราanomัลไลซ์พีรีซิชั่นของเพอร์ไวส์อัลกอริทึมแบบ 2 เทสโธลของใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_2 = 0.7$




รูปที่ 5.22 แสดงอัตราanomัลไลซ์พีรีซิชั่นของเพอร์ไวส์อัลกอริทึมแบบ 2 เทสโธลของใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_2 = 1.0$




รูปที่ 5.23 แสดงขนาดอินเทิลล์ของแพรวัวส์อัลกอริทึมแบบ 2 เทสโธลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_2 = 0.1$



รูปที่ 5.24 แสดงขนาดอินเทิลล์ของแพรวัวส์อัลกอริทึมแบบ 2 เทสโธลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_2 = 0.4$




รูปที่ 5.25 แสดงขนาดอินเทิลล์ของแพรวัวส์อัลกอริทึมแบบ 2 เทสโธลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_2 = 0.7$




รูปที่ 5.26 แสดงขนาดอินเทิลล์ของแพรวัวส์อัลกอริทึมแบบ 2 เทสโธลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 68 ครั้ง, มากกว่า 568 ครั้ง และมากกว่า 1068 ครั้ง เมื่อใช้ค่า $P_2 = 1.0$

จะเห็นได้ว่าเมื่อได้มีการปรับปรุงประสิทธิภาพของแพร์ไวส์อัลกอริทึมแบบใช้เทรสโฮล 2 ระดับด้วยการกำหนดจำนวนครั้งของผู้ใช้ที่มีการร้องขอมากพอ ถึงจะนำข้อมูลการเข้าถึงของผู้ใช้นั้น มาสร้างเป็นอินดิเคเตอร์เฉพาะของผู้ใช้นั้น (อินดิเคเตอร์ในส่วนการทำงานที่สอง) ซึ่งทำให้แพร์ไวส์อัลกอริทึมแบบใช้เทรสโฮล 2 ระดับที่มีการเพิ่มส่วนการทำงานนี้มีประสิทธิภาพยังคงใกล้เคียงกับแพร์ไวส์อัลกอริทึมแบบใช้เทรสโฮล 2 ระดับเดิม แต่ขนาดของอินดิเคเตอร์จะมีขนาดเล็กลง ซึ่งก็ทำให้การใช้ทรัพยากรในการเก็บอินดิเคเตอร์เป็นอย่างมาก ซึ่งจากรูปที่ 5.15 – 5.26 จะเห็นว่าเมื่อมีการสร้างอินดิเคเตอร์เฉพาะในส่วนการทำงานที่สองของไคลเอนต์ที่มีการร้องขอมากกว่า 68 ครั้งจะทำให้อินดิเคเตอร์มีขนาดลดลงอย่างมาก แต่เมื่อมีการเพิ่มจำนวนครั้งของไคลเอนต์ที่มีการร้องขอมากพอถึงจะนำมาสร้างเป็นอินดิเคเตอร์ที่สองขึ้นไม่ได้ทำให้มีผลกับขนาดของอินดิเคเตอร์หรืออัตราประสิทธิภาพและรีคอดมากนัก ทำให้เห็นว่าจำนวนครั้งของการร้องขอส่วนใหญ่ของไคลเอนต์อยู่ในช่วงไม่เกินค่าเฉลี่ย การกระจายตัวของจำนวนครั้งของการร้องขอของไคลเอนต์เป็นดังรูป 5.27




รูปที่ 5.27 แสดงกระจายตัวของจำนวนครั้งของการร้องขอที่มาจากไคลเอนต์ของล็อกไฟล์ฝั่งเซิร์ฟเวอร์


สำหรับการทดลองจำลองสถานการณ์การใช้งานแพร์ไวส์อัลกอริทึมแบบธรรมดา การใช้แพร์ไวส์อัลกอริทึมแบบใช้เทรสโฮล 2 ระดับและการใช้แพร์ไวส์อัลกอริทึมแบบใช้เทรสโฮล 2 ระดับที่ได้รับการปรับปรุงแล้ว กับข้อมูลการร้องขอของล็อกไฟล์ของพรีอิกซ์ทางด้านไคลเอนต์ของบริษัทขนาดใหญ่แห่งหนึ่ง นอกเหนือจากข้อมูลในบทที่ 4 ซึ่งข้อมูลชุดนี้มีค่าเฉลี่ยของจำนวนครั้งของการร้องขอของผู้ใช้ที่ใช่ ซึ่งใช้เป็นเทรสโฮลของการสร้างอินดิเคเตอร์มีค่าเป็น 59 ครั้งเป็นดังนี้




รูปที่ 5.28 แสดงอัตราอรรถประโยชน์ของแพรวัวส์อัลกอริทึมแบบ 2 เทรสโฮลของใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_2 = 0.1$




รูปที่ 5.29 แสดงอัตราอรรถประโยชน์ของแพรวัวส์อัลกอริทึมแบบ 2 เทรสโฮลของใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_2 = 0.4$



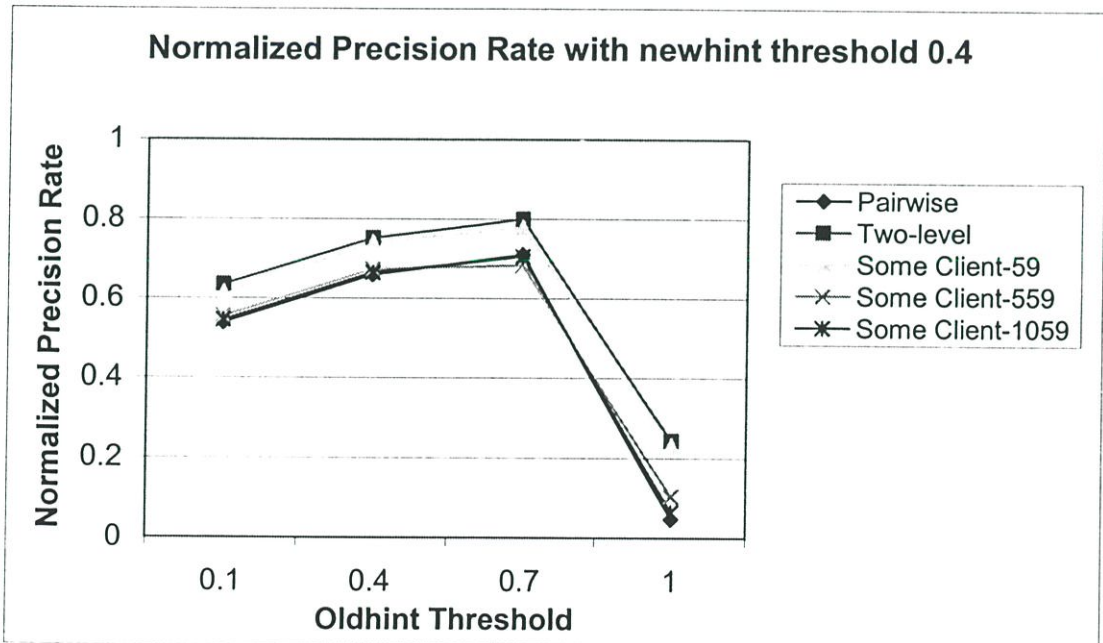
รูปที่ 5.30 แสดงอัตราอรรถประโยชน์ของแพรวัวส์อัลกอริทึมแบบ 2 เทรสโสตของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 0.7$




รูปที่ 5.31 แสดงอัตราอรรถประโยชน์ของแพรวัวส์อัลกอริทึมแบบ 2 เทรสโสตของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 1.0$




รูปที่ 5.32 แสดงอัตราanomัลไลซ์พรีซิชั่นของแพรวัวส์อัลกอริทึมแบบ 2 เทสโฮลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_2 = 0.1$




รูปที่ 5.33 แสดงอัตราanomัลไลซ์พรีซิชั่นของแพรวัวส์อัลกอริทึมแบบ 2 เทสโฮลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_2 = 0.4$




รูปที่ 5.34 แสดงอัตราอนุมัติไลซ์ฟรีชั้นของแพรว์ไวส์อัลกอริทึมแบบ 2 เทสต์โฮลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 0.7$




รูปที่ 5.35 แสดงอัตราอนุมัติไลซ์ฟรีชั้นของแพรว์ไวส์อัลกอริทึมแบบ 2 เทสต์โฮลของผู้ใช้ทั้งหมด เปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 1.0$




รูปที่ 5.36 แสดงขนาดชิ้นเฉลี่ยของแพรวัวส์อัลกอริทึมแบบ 2 เทรสโธลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 0.1$



รูปที่ 5.37 แสดงขนาดชิ้นเฉลี่ยของแพรวัวส์อัลกอริทึมแบบ 2 เทรสโธลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_{12} = 0.4$




รูปที่ 5.38 แสดงขนาดอินเทิลล์ของแพรวัวส์อัลกอริทึมแบบ 2 เทรสโธลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_2 = 0.7$



รูปที่ 5.39 แสดงขนาดอินเทิลล์ของแพรวัวส์อัลกอริทึมแบบ 2 เทรสโธลของผู้ใช้ทั้งหมดเปรียบเทียบระหว่างการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้แต่ละคนทั้งหมดกับการทำงานส่วนที่สองที่ใช้ข้อมูลของผู้ใช้ที่มีการร้องมามากกว่า 59 ครั้ง, มากกว่า 559 ครั้ง และมากกว่า 1059 ครั้ง เมื่อใช้ค่า $P_2 = 1.0$

จากรูปที่ 5.28 – 5.31 แสดงให้เห็นประสิทธิภาพที่เพิ่มขึ้นของแพรวัวส์อัลกอริทึมแบบใช้เทรตไฮส 2 ระดับเมื่อเปรียบเทียบกับแพรวัวส์อัลกอริทึมเดิม อัตราอนุมัติไลซ์รีคอลของแพรวัวส์อัลกอริทึมแบบใช้เทรตไฮส 2 ระดับมีค่าที่สูงกว่าแพรวัวส์อัลกอริทึมเดิม เมื่อเปรียบเทียบกันเมื่อใช้ค่า P_2 ค่าหนึ่งค่าใด อัตราแพรวัวส์อัลกอริทึมแบบใช้เทรตไฮส 2 ระดับจะมีค่าสูงกว่าแพรวัวส์อัลกอริทึมเดิมในทุกๆค่า สำหรับรูปที่ 5.32 – 5.35 แสดงอัตราอนุมัติไลซ์พีริซันของแพรวัวส์อัลกอริทึมเดิมเมื่อเปรียบเทียบกับแพรวัวส์อัลกอริทึมแบบใช้เทรตไฮส 2 ระดับ จะเห็นได้ว่าอัตราอนุมัติไลซ์พีริซันของแพรวัวส์อัลกอริทึมแบบใช้เทรตไฮส 2 ระดับจะมีค่าที่ดีกว่าแพรวัวส์อัลกอริทึมเดิมเช่นกัน

สำหรับรูปที่ 5.36 – 5.39 แสดงอัตราขนาดของอินเฉลี่ยของแพรวัวส์อัลกอริทึมแบบใช้เทรตไฮส 2 ระดับกับแพรวัวส์อัลกอริทึมเดิม ซึ่งแนวโน้มก็เป็นดังเช่นผลการจำลองสถานการณ์ที่ผ่านมาคือขนาดของอินเฉลี่ยของแพรวัวส์อัลกอริทึมแบบใช้เทรตไฮส 2 ระดับยังมีขนาดที่ใหญ่กว่าแพรวัวส์อัลกอริทึมเดิมพอสมควร



รูปที่ 5.40 แสดงกระจายตัวของจำนวนครั้งของการร้องขอที่มาจากไคลเอนต์ของล๊อคไฟล์ฝั่งไคลเอนต์

สำหรับการกระจายตัวของจำนวนการร้องขอของไคลเอนต์ของข้อมูลชุดนี้เป็นดังรูปที่ 5.40 และจากรูปที่ 5.28 – 5.31 ก็ได้แสดงถึงอัตรารีคอลของแพรวัวส์อัลกอริทึมแบบใช้เทรตไฮส 2 ระดับที่ได้รับการปรับปรุงแล้วคือจะนำข้อมูลการร้องขอของไคลเอนต์ที่มีการร้องขอมาครั้งพอถึง

จะนำมาสร้างเป็นอื่นในส่วนที่สอง ซึ่งค่าที่น่าจะเหมาะสมที่สุดก็คือจำนวนครั้งเฉลี่ยของโคลเอนต์ทั้งหมดนั่นเอง เพราะทำให้อัตราอัมัลไลซ์รีคอลยังคงอยู่ในระดับสูงและลดลงจากเพอร์ไวส์อัลกอริทึมแบบใช้เทรสโฮส 2 ระดับมาตรฐานเล็กน้อย

เช่นกันจากรูปที่ 5.32 – 5.35 ก็แสดงถึงอัตราอัมัลไลซ์รีชัชนั้ที่ลดลงเล็กน้อยเมื่อได้มีการปรับปรุงเพอร์ไวส์อัลกอริทึมแบบใช้เทรสโฮส 2 ระดับ ซึ่งผลที่ได้ก็คล้ายกับอัตราอัมัลไลซ์รีคอลที่ได้กล่าวไปแล้ว ส่วนขนาดของอื่นที่ได้ลดลงอย่างมากเมื่อได้มีการปรับปรุงเพอร์ไวส์อัลกอริทึมแบบใช้เทรสโฮส 2 ระดับแล้ว ดังรูปที่ 5.36 – 5.39 ทำให้สูญเสียทรัพยากรของระบบในการเก็บข้อมูลอื่นค่อนข้างมาก

จากผลการทดลองข้างต้นก็ทำให้เห็นความแตกต่างของประสิทธิภาพของเพอร์ไวส์อัลกอริทึมแบบใช้เทรสโฮส 2 ระดับเมื่อมีการใช้ข้อมูลล็อกไฟล์ระหว่างล็อกไฟล์จากพรีอ็อกซี่ทางด้านเซิร์ฟเวอร์และล็อกไฟล์จากพรีอ็อกซี่ทางด้านโคลเอนต์ ข้อมูลล็อกไฟล์จากทางด้านโคลเอนต์จะให้ผลการจำลองสถานการณ์ของเพอร์ไวส์อัลกอริทึมแบบใช้เทรสโฮส 2 ระดับที่ดีกว่าเพราะข้อมูลที่นำมาจะมีความถูกต้องมากกว่า ดังผลจากรูปที่ 5.28 – 5.39

จากข้อมูลทางด้านเซิร์ฟเวอร์โดยสรุปจะเห็นว่าอัตราอัมัลไลซ์รีชัชนั้และอัตราอัมัลไลซ์รีคอลของเพอร์ไวส์อัลกอริทึมแบบใช้ 2 เทรสโฮสและเพอร์ไวส์อัลกอริทึมแบบใช้เทรสโฮส 2 ระดับที่ได้รับการปรับปรุงจะเพิ่มขึ้นจากเพอร์ไวส์อัลกอริทึมเดิมอยู่ในช่วง 7-10 % ทั้งสองวิธีในขณะที่ขนาดของอื่นจะเพิ่มขึ้นประมาณ 2-2.5 เท่าและ 1 เท่าตามลำดับ

ส่วนข้อมูลที่ได้จากทางด้านโคลเอนต์จะเห็นว่าอัตราอัมัลไลซ์รีชัชนั้และอัตราอัมัลไลซ์รีคอลของเพอร์ไวส์อัลกอริทึมแบบใช้ 2 เทรสโฮสและเพอร์ไวส์อัลกอริทึมแบบใช้เทรสโฮส 2 ระดับที่ได้รับการปรับปรุงจะเพิ่มขึ้นจากเพอร์ไวส์อัลกอริทึมเดิมอยู่ในช่วง 10-15 % และ 8-15 % ตามลำดับ ในขณะที่ขนาดของอื่นจะเพิ่มขึ้นประมาณ 1.5-2 เท่าและ 0.5-1 เท่าตามลำดับ

บทที่ 6

บทสรุปและวิเคราะห์ผลการทดลอง

6.1 สรุปและวิเคราะห์ผลการทดลอง

จากผลการจำลองสถานการณ์ในบทที่ 4 จะเห็นได้ว่าแพรว์ไวส์อัลกอริทึมนี้เป็นอัลกอริทึมที่มีประสิทธิภาพในการทำนายเว็บเพจหรือริชอร์สใดๆ ที่จะถูกเข้าถึงในช่วงระยะเวลาหนึ่งหลังจากที่ได้มีการร้องขอเว็บเพจหรือริชอร์สหนึ่งๆ ได้ดีพอสมควร โดยแพรว์ไวส์อัลกอริทึมจะใช้วิธีการทางสถิติมาประยุกต์ใช้หาความน่าจะเป็นของการขึ้นต่อกันของเว็บเพจใดๆ จากนั้นก็จะนำกลุ่มของเว็บเพจใดๆ ที่ขึ้นกับเว็บเพจหนึ่งมาสร้างเป็นอื่น โดยอื่นจะเป็นกลุ่มของเว็บเพจที่น่าจะถูกร้องขอหลังจากที่ได้มีการร้องขอเว็บเพจที่เว็บเพจหลักของอีกกลุ่มนั้นแล้วการทำงานของแพรว์ไวส์อัลกอริทึมจะใช้ข้อมูลในอดีตในการประมวลผล เพื่อใช้ในการสร้างเป็นอื่นของเว็บเพจต่างประสิทธิภาพของแพรว์ไวส์อัลกอริทึมนี้ ค่าประสิทธิภาพที่ได้จะขึ้นกับคุณภาพของอื่นที่ถูกสร้างขึ้นมา โดยอื่นที่ถูกสร้างขึ้นมาโดยแพรว์ไวส์อัลกอริทึมนี้จะได้เป็นกลุ่มของอื่นเดี่ยว (Hints Pool) แล้วจะนำอื่นที่ได้นั้นมาใช้กับผู้ใช้งานทุกๆคนที่มีการร้องขอมา และจากการจำลองสถานการณ์ในบทที่ 4 นั้นแสดงให้เห็นว่าอื่นที่ได้จากแพรว์ไวส์อัลกอริทึมนี้ ก่อนข้างที่จะไม่ได้แสดงพฤติกรรมของผู้ใช้แต่ละคนได้คืนักเพราะสร้างจากข้อมูลการเข้าถึงเว็บเพจในอดีตของผู้ใช้ทุกๆคน ทำให้อื่นที่ได้เหมาะสมกับผู้ใช้บางคนเท่านั้นดังผลที่ได้ในบทที่ 4

วิธีการแพรว์ไวส์อัลกอริทึมแบบใช้เทอร์สโกล 2 ระดับซึ่งจะแบ่งข้อมูลของผู้ใช้ออกเป็น 2 ส่วนในการใช้สร้างเป็นอื่น ส่วนแรกจะแยกข้อมูลการร้องขอของผู้ใช้แต่ละคนแล้วนำข้อมูลของแต่ละคนนั้นมาสร้างเป็นอื่น ซึ่งอื่นที่ได้ก็ย่อมแสดงพฤติกรรมของผู้ใช้คนนั้นๆจริงๆ เพราะข้อมูลที่นำมาใช้สร้างเป็นอื่นนั้นมาจากเฉพาะผู้ใช้คนนั้นๆเท่านั้น ส่วนที่สองจะทำการสร้างอื่นโดยใช้ข้อมูลผู้ใช้ทั้งหมดไม่มีการแยกเป็นผู้ใช้คนไหน ซึ่งการทำงานส่วนนี้ก็เหมือนกับการทำงานของแพรว์ไวส์อัลกอริทึมเดิมนั่นเอง ที่ยังคงต้องมีส่วนการทำงานของแพรว์ไวส์อัลกอริทึมเดิมอยู่นั้น เพราะต้องการนำการขึ้นต่อกันของเว็บเพจที่มีความน่าจะเป็นสูงๆของผู้ใช้ส่วนใหญ่มาสร้างเป็นอื่นด้วยเพื่อเพิ่มประสิทธิภาพของอื่นของแพรว์ไวส์อัลกอริทึมขึ้น เมื่อได้อื่นจากทั้งสองส่วนการทำงานแล้ว เมื่อมีการร้องขอเว็บเพจใดๆมาที่เว็บเซิร์ฟเวอร์ ทางเซิร์ฟเวอร์ก็จะทำการรวมอื่นของเว็บเพจที่ถูกร้องขอจากทั้งสองส่วนเข้าด้วยกันในลักษณะยูเนียน (U) ก็ได้กลุ่มของอื่นที่จะใช้ส่งไปยังเว็บไคลเอนต์ของผู้ใช้เพื่อใช้ในการเฟิร์ชชิ่งต่อไป

จากการจำลองสถานการณ์ในบทที่ 5 จะเห็นได้ว่าประสิทธิภาพของแพรว์ไวส์อัลกอริทึมแบบใช้เทอร์สโกล 2 ระดับจะมีอัตราอ้อมัลไลซ์รีคอลที่สูงกว่าแพรว์ไวส์อัลกอริทึมเดิมอีกทั้งยังมีอัตราการ


ลดลงของอัตราอนุมัติไลเซนส์คอลที่น้อยกว่าแพร์ไวส์อัลกอริทึมเดิม ส่วนอนุมัติไลเซนส์ตราพีซีซีนั้น แพร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับนั้นจะมีระดับที่สูงกว่าแพร์ไวส์อัลกอริทึมเดิมเช่นกัน แต่ข้อดีของแพร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับนั้นคือสิ่งที่ได้จะมีขนาดค่อนข้างที่จะใหญ่กว่าแพร์ไวส์อัลกอริทึมเดิมพอสมควร เพราะเกิดจากการนำเอาชิ้นส่วนการทำงานสองส่วน ซึ่งในบทที่ 5 ก็ได้เสนอวิธีการที่จะลดขนาดของชิ้นส่วนของแพร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับนั้นจะทำได้โดยการเลือกที่จะสร้างชิ้นส่วนการทำงานที่หนึ่ง (อันที่ได้จากข้อมูลการร้องขอของผู้ใช้เฉพาะคน) สำหรับข้อมูลการร้องขอของผู้ใช้คนใดๆที่มีจำนวนครั้งของการเข้าถึงมากพอเท่านั้น เพราะถ้าผู้ใช้มีการร้องขอน้อยครั้งก็นำข้อมูลนั้นมาสร้างเป็นอันเฉพาะสำหรับผู้ใช้คนนั้นย่อมที่จะได้อันที่ไม่ดีพอ เพราะอันนั้นไม่ได้แสดงถึงพฤติกรรมของผู้ใช้ที่ได้อันนั้นจึงสามารถลดขนาดของอันเฉลี่ยได้มากพอสมควร ในขณะที่ยังคงระดับอัตราอนุมัติไลเซนส์คอลและอัตราอนุมัติไลเซนส์พีซีซีที่ใกล้เคียงกับแพร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับมาตรฐาน ผลการจำลองสถานการณ์ของแพร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับกับแพร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับที่ได้มีการปรับปรุงเพื่อลดขนาดของอันนั้นจะเห็นว่าอัตราอนุมัติไลเซนส์คอลและอัตราอนุมัติไลเซนส์พีซีซีลดลงเพียงเล็กน้อยเท่านั้นแต่สามารถที่จะลดขนาดของอันได้มากเลยทีเดียว

แต่สิ่งสำคัญอีกอย่างหนึ่งที่ต้องคำนึงถึงคือ แพร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับค่อนข้างที่จะไม่เหมาะสมกับข้อมูลการร้องขอของไคลเอนต์ที่ได้จากปลายทางหรือเซิร์ฟเวอร์ปลายทาง เพราะข้อมูลที่ได้นั้นไอพีแอดเดรสอาจจะไม่ใช่ไอพีแอดเดรสจริงๆของผู้ใช้ก็ได้ อีกทั้งถ้าเป็นข้อมูลล็อกไฟล์จากเซิร์ฟเวอร์ปลายทางแล้ว ข้อมูลส่วนที่สองซึ่งก็คือส่วนการทำงานที่มีการสร้างอันเฉพาะของแต่ละไคลเอนต์จะไม่ค่อยมีผลกับอัตราอนุมัติไลเซนส์คอลหรืออัตราอนุมัติไลเซนส์พีซีซีมากนักเพราะรูปแบบการร้องขอของไคลเอนต์ส่วนใหญ่ที่มาถึงเซิร์ฟเวอร์น่าจะมีรูปแบบที่คล้ายๆกัน เพราะรีซอร์สที่อยู่บนเซิร์ฟเวอร์มีจำกัด ทำให้การกระจายตัวของรูปแบบการร้องขอของไคลเอนต์ไม่ได้แตกต่างกันนั้นแต่สำหรับข้อมูลที่ได้จากต้นทางทางด้านไคลเอนต์ เช่น พร็อกซีทางด้านไคลเอนต์แพร์ไวส์อัลกอริทึมเหมาะสมมากที่จะนำมาใช้ เพราะไอพีแอดเดรสที่ได้เป็นไอพีแอดเดรสจริงๆของไคลเอนต์อีกทั้งการกระจายตัวของข้อมูลการร้องขอของไคลเอนต์มีมากกว่าข้อมูลการร้องขอที่ได้จากเซิร์ฟเวอร์ปลายทางแน่นอน ด้วยเหตุผลที่ได้กล่าวมาแล้วทั้งหมดก็เพียงพอที่จะกล่าวได้ว่าแพร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับเป็นอัลกอริทึมหนึ่งที่เหมาะสมในการนำมาใช้ในกระบวนการพีเรซซึ่งได้คือ


6.2 ทรัพยากรที่ใช้ในการทำงานของแพร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับ

การทำงานของแพร์ไวส์อัลกอริทึม, การทำงานแพร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับ

และการทำงานแพร์ไวยส์อัลกอริทึมแบบใช้เทรสโสล 2 ระดับที่ได้รับการปรับปรุง ต้องมีการใช้ทรัพยากรในการทำงานที่แตกต่างกัน และก็ใช้เวลาในการทำงานที่แตกต่างกันด้วย ดังรูปที่ 6.1



รูปที่ 6.1 แสดงเวลาการทำงานที่ใช้ของแพร์ไวยส์อัลกอริทึม, แพร์ไวยส์อัลกอริทึมแบบใช้เทรสโสล 2 ระดับและแพร์ไวยส์อัลกอริทึมแบบใช้เทรสโสล 2 ระดับที่ได้รับการปรับปรุงของข้อมูลที่ได้จากทางด้านเซิร์ฟเวอร์



รูปที่ 6.2 แสดงเวลาการทำงานที่ใช้ของแพร์ไวยส์อัลกอริทึม, แพร์ไวยส์อัลกอริทึมแบบใช้เทรสโสล 2 ระดับและแพร์ไวยส์อัลกอริทึมแบบใช้เทรสโสล 2 ระดับที่ได้รับการปรับปรุงของข้อมูลที่ได้จากทางด้านไคลเอนต์

จะเห็นว่าในการทำงานของแฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับและจะเห็นว่าในการทำงานของแฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับที่ได้รับการปรับปรุงแล้ว จะใช้เวลาในการสร้างอินที่ค่อนข้างนานกว่าแฟร์ไวส์อัลกอริทึมเดิม เพราะต้องมีการคำนวณในส่วนการทำงานที่สองเพิ่มขึ้นมาก

สำหรับขนาดของเมมโมรี (Memory) ที่ใช้นั้นแฟร์ไวส์อัลกอริทึมเดิม, แฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับและแฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับที่ได้รับการปรับปรุง จะใช้เมมโมรีสูงสุดประมาณ 447 MB, 978 MB และ 897 MB ตามลำดับ และสำหรับข้อมูลจากทางด้านเซิร์ฟเวอร์ในบทที่ 4 และ 5 สำหรับข้อมูลจากทางด้านไคลเอนต์จากบทที่ 4 และ 5 นั้นแฟร์ไวส์อัลกอริทึมเดิม, แฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับและแฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับที่ได้รับการปรับปรุง จะใช้เมมโมรีสูงสุด 421 MB, 945 MB และ 891 MB ตามลำดับ

จะเห็นว่าการทำงานแฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับที่ได้รับการปรับปรุงจะช่วยลดขนาดเมมโมรีที่ใช้ได้ได้ประมาณ 10 % และช่วยลดเวลาในการในการทำงานของแฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับประมาณ 7-10 % แต่ก็ยังคงใช้เมมโมรีและเวลาที่สูงกว่าแฟร์ไวส์อัลกอริทึมเดิมประมาณเกือบๆ 2 เท่าทั้งในขนาดของเมมโมรี ส่วนด้านเวลาแฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับที่ได้รับการปรับปรุงแล้วก็ยังคงใช้เวลาในการทำงานนานกว่าแฟร์ไวส์อัลกอริทึมเดิมประมาณ 2 เท่า และการใช้เมมโมรี, เวลาในการทำงานก็จะเพิ่มขึ้นถ้ามีข้อมูลที่นำมาสร้างอินที่เพิ่มขึ้น

แม้ว่าแฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับจะทำให้มีการใช้เมมโมรีและเวลาในการทำงานที่เพิ่มขึ้นแต่สำหรับองค์กรขนาดกลางที่มีจำนวนผู้ใช้ไม่มากนัก แฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับก็เป็นวิธีการน่าสนใจในการลดเวลาในการเข้าถึงของผู้ใช้วิธีการหนึ่ง

6.3 การเลือกใช้เทรสโสดในส่วนการทำงานแต่ละส่วน

สำหรับการเลือกใช้เทรสโสดสำหรับส่วนการทำงานแต่ละส่วนของแฟร์ไวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับนั้นส่วนใหญ่จะขึ้นกับข้อมูลที่นำมาใช้ในการสร้างอิน ซึ่งจากผลการจำลองสถานการณ์ที่ได้กล่าวถึงในบทนี้ ก็สามารถสรุปการเลือกใช้เทรสโสดต่างๆ ได้ดังนี้ ถ้าใช้ข้อมูลการร้องขอของผู้ใช้ที่ได้จากฝั่งไคลเอนต์นั้นควรที่จะเลือกใช้ค่าเทรสโสดของส่วนการทำงานแรก (ส่วนของแฟร์ไวส์อัลกอริทึมเดิม, P_{11}) ที่ค่าสูง 0.7 – 1.0 เพราะต้องการอินที่เกิดจากการร้องขอมาครั้งจากผู้ใช้ทั้งหมด ส่วนค่าเทรสโสดในส่วนการทำงานที่สอง (ส่วนที่เพิ่มเติม, P_{12}) ก็ควรเลือกใช้ค่าเทรสโสดที่อยู่ในช่วง 0.5 – 1.0 ขึ้นอยู่กับค่าอัตรานอ้มัลไลซ์รีคอล (Normalized Recall Rate) และอัตรานอ้มัลไลซ์พรีซิชั่น (Normalized Precision Rate) ที่ต้องการ ถ้าต้องการค่าอัตรานอ้มัลไลซ์รีคอล (Normalized Recall Rate) ที่สูงการอาจจะเลือกค่า P_{12} ที่ 0.5 ซึ่งให้ค่าอัตรานอ้มัลไลซ์รีคอล

(Normalized Recall Rate) ที่สูงในขณะที่ค่าอัตราอัมัลไลซ์พรีซิชั่น (Normalized Precision Rate) ที่ยังคงสูงอยู่ แต่ถ้านำค่าอัตราอัมัลไลซ์พรีซิชั่น (Normalized Precision Rate) ที่สูงๆ ก็อาจจะเลือกใช้ค่า P_{12} ที่ 0.7 ซึ่งจะให้อัตราอัมัลไลซ์พรีซิชั่น (Normalized Precision Rate) ที่สูงและยังคงให้อัตราอัมัลไลซ์รีคอล (Normalized Recall Rate) ที่สูงในระดับหนึ่ง

สำหรับถ้าใช้ข้อมูลที่ได้จากด้านเซิร์ฟเวอร์ก็คือเลือกใช้ค่า P_{11} ที่สูงเช่นกันอาจจะอยู่ในช่วง 0.7 – 1.0 เพราะต้องการอื่นที่ได้จากการร้องขอหลายๆ ครั้งของผู้ใช้ทั้งหมดเท่านั้น ในขณะที่ควรใช้ค่า P_{12} นั้นควรที่จะใช้ค่าที่ไม่สูงมากเพราะต้องการที่ได้อื่นที่ครอบคลุมกับการร้องขอผู้ใช้คนใดคนหนึ่ง (ซึ่งอาจจะเป็นผู้ใช้หลายๆคนที่มาจาก 1 ไอพีแอดเดรสก็ได้) อาจจะอยู่ในค่า 0.3 – 0.7 เพราะถ้าใช้ค่า P_{12} ที่สูงมากไปอื่นสำหรับส่วนการทำงานที่สองของข้อมูลที่ได้จากด้านเซิร์ฟเวอร์จะเป็นอื่นที่ค่อนข้างไม่ครอบคลุมการร้องขอของไอพีแอดเดรสหนึ่งไอพีนั้น

6.4 ข้อเสนอแนะ

จากการทำงานแพรวัวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับนั้นในส่วนการทำงานที่สองจะต้องมีการค้นหาเกี่ยวกับเคาเตอร์ต่างๆของผู้ใช้เฉพาะคน ซึ่งเวลาในการค้นหาเคาเตอร์ต่างๆสามารถปรับปรุงได้โดยอาจจะใช้วิธีการค้นหาใหม่ที่สามารถใช้เวลาในการค้นหาที่ลดลง ซึ่งจะช่วยให้เวลาในการทำงานโดยรวมของแพรวัวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับลดลงได้

6.5 การนำแพรวัวส์อัลกอริทึมแบบใช้ 2 เทรสโสดไปใช้งานจริง

การนำแพรวัวส์อัลกอริทึมแบบใช้เทรสโสด 2 ระดับไปใช้งานจริงนั้นสิ่งที่ต้องคำนึงอย่างแรกคือฮาร์ดแวร์ที่จะใช้เป็นเครื่องที่จะใช้ในการสร้างอื่น ควรที่จะมีขนาดเมมโมรี่ที่ค่อนข้างสูง เพราะในการสร้างอื่นเฉพาะสำหรับผู้ใช้คนหนึ่ง (ส่วนการทำงานที่สอง) ต้องมีการเก็บข้อมูลเฉพาะของผู้ใช้แต่ละคน สิ่งที่ต้องคำนึงต่อไปคือตำแหน่งที่อื่นจะถูกสร้างและเก็บไว้ซึ่งถ้าเป็นอื่นที่สร้างจากข้อมูลทางด้านเซิร์ฟเวอร์อื่นก็จะถูกเก็บไว้ที่เซิร์ฟเวอร์แล้วจะถูกส่งกลับไปให้ทางผู้ใช้ทำการพีเรซ อีกครั้งหนึ่ง ส่วนในการสร้างอื่นที่ได้จากข้อมูลด้านไคลเอนต์ควรที่จะใช้เครื่องที่เป็นพีร็อกซีทางด้านไคลเอนต์เป็นเครื่องที่ทำการสร้างอื่น เพราะอื่นที่สร้างก็ไม่จำเป็นต้องส่งไปให้ใคร พีร็อกซีจะเป็นเครื่องที่ทำการพีเรซอีก วิธีการยังมีข้อดีอีกอย่างคือไม่ต้องสูญเสียของสัญญาณของข้อมูลส่วนที่เป็นอื่นที่ส่งกลับมาให้ทางผู้ใช้ (พีร็อกซีของผู้ใช้ทำการพีเรซ)

การทำการสร้างอื่นน่าจะควรที่จะทำงานในแบบออฟไลน์ เพราะต้องมีการประมวลผลที่สูงไม่ว่าจะใช้แพร์ไวส์อัลกอริทึมแบบเดิมหรือแพร์ไวส์อัลกอริทึมแบบใช้เทรศโฮล 2 ระดับ และค่อนข้างใช้เวลานานในการสร้างอื่น

เอกสารอ้างอิง

- [1] J. C. Mogul, "Hinted caching in the Web," in *Proc. ACM SIGOPS European Workshop*, 1996.
- [2] E.Cohen, B. Krishnamurthy, and J. Rexford, "Evaluating server-assisted cache replacement in the web," in *Proc. European Symposium on Algorithms*, August 1998.
- [3] V.N. Padmanabhan and J. C. Mogul, "Using predictive prefetching to improve World Wide Web Latency," *Computer Communication Review*, vol 26, no. 3, pp. 22-36, 1996
- [4] M. Crovella and P. Barford, "The network effects of prefetching," in *Proc IEEE INFOCOM*, April 1998.
- [5] James F. Kurose, "Computer Networking: A Top-Down Approach Featuring the Internet", Addison Wesley Publisher, History of Computer Networking and the Internet section, Chapter 1.
- [6] Balachander Krishnamurthy and Jennifer Rexford, "Web protocols and Practice", Addison Wesley Publisher, Chapter 2. page 176 – 210.
- [7] ชูเกียรติ นาคพิทักษ์กุลและวิทยา ต่อศรีเจริญ, "เริ่มต้นสร้างโฮมเพจด้วย HTML", สำนักพิมพ์ WITTY Group, หน้า 26 – 27.
- [8] James F. Kurose, "Computer Networking: A Top-Down Approach Featuring the Internet", Addison Wesley Publisher, The Web and HTTP section, Chapter 2., page 84-87.
- [9] James F. Kurose, "Computer Networking: A Top-Down Approach Featuring the Internet", Addison Wesley Publisher, The Web and HTTP section, Chapter 2, page 88-96.
- [10] "RFC 2101", www.scit.wlv.ac.uk/rfc/rfc21xx/RFC2101.html .
- [11] Network Address Translation : NAT, http://searchwebservices.techtarget.com/sDefinition/0,,sid26_gci214107,00.html.

ภาคผนวก ก.

ผลงานวิจัยที่ได้รับการตีพิมพ์

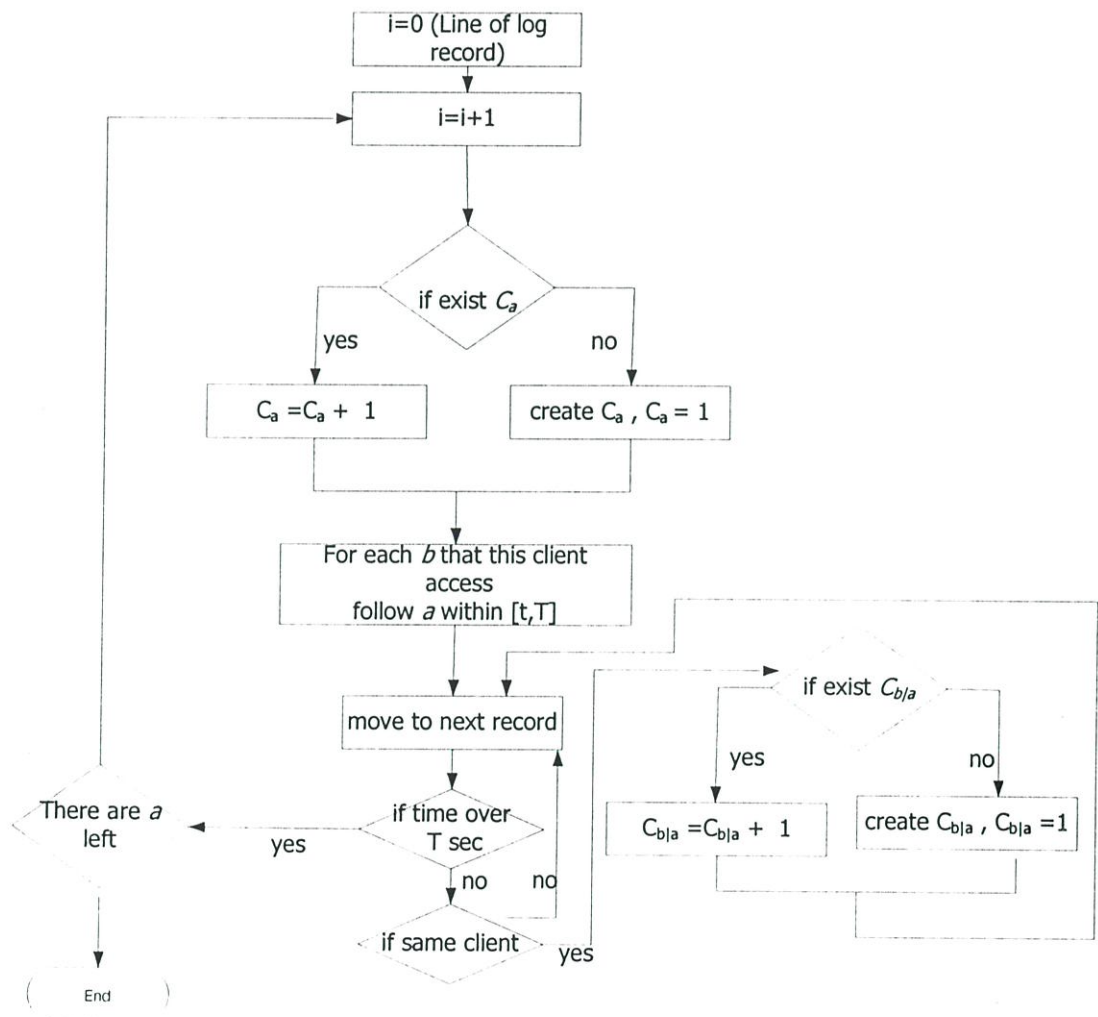
- [1] Chotipat Pornavalai and Wisit Phatchoo, “An Efficient Two-Level Thresholds Pairwise Alogrithm for Predicting Request to Web Server”, The Second International Symposium On Communication and Information Technology, 23-25 October 2002.

ภาคผนวก ข.

Flowchart 1 แสดงขั้นตอนการทำงานในส่วน Count Step ของเพอร์โวลส์อัลกอริทึม

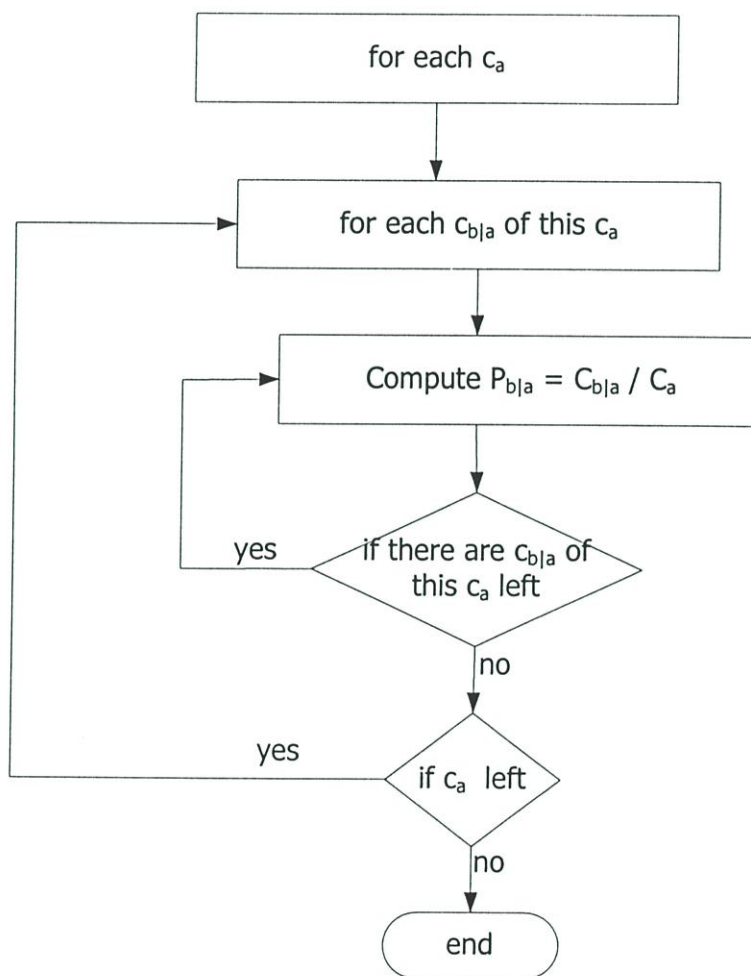
นิยาม C_a เป็นจำนวนครั้งที่มีการร้องขอเว็บเพจ a ใดๆ

$C_{b|a}$ เป็นจำนวนครั้งที่มีการร้องเว็บเพจ b ใดๆ ต่อจากเว็บเพจ a ใดๆ



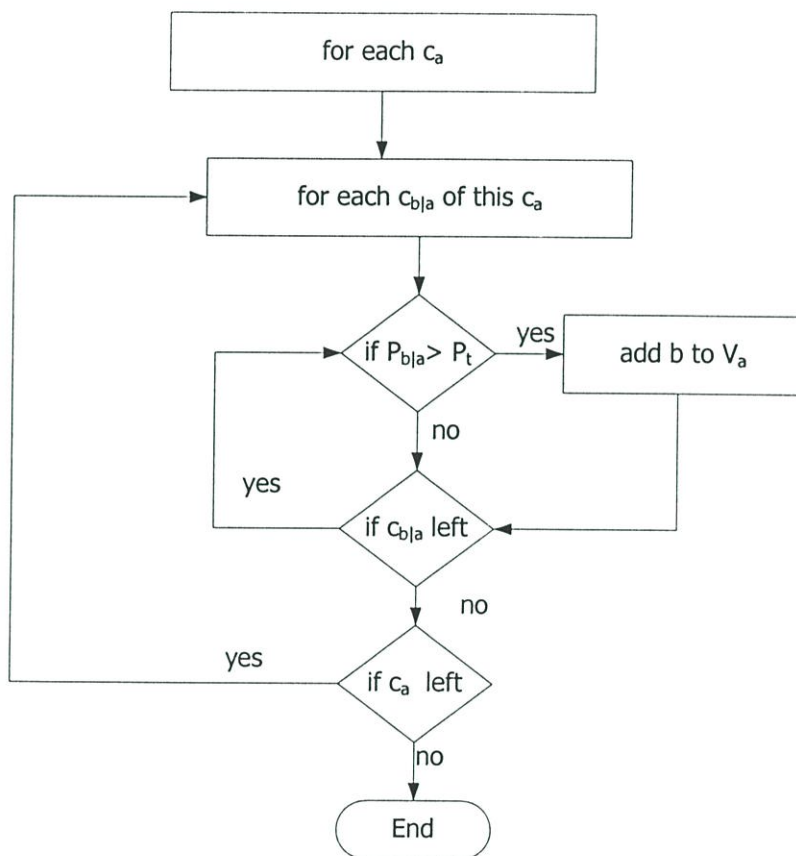
Flowchart 2 แสดงขั้นตอนการทำงานในส่วน Compute Probabilities Step ของแพรวัวส์อัลกอริทึม

นิยาม $P_{b|a}$ เป็นความน่าจะเป็นที่เว็บเพจ b ใดๆ ขึ้นกับเว็บเพจ a ใดๆ



Flowchart 3 แสดงขั้นตอนการทำงานในส่วน Hint Construction Step ของแพรวัวส์อัลกอริทึม

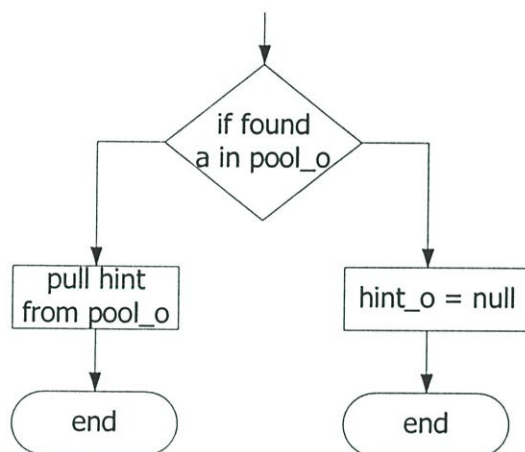
นิยาม P_t เป็นความน่าจะเป็นทรสโสด



Flowchart 4 แสดงขั้นตอนการทำงานในส่วน Send hint Step ของแพรวีไวรัสอัลกอริทึม

นิยาม *Pool_o* เป็นกลุ่มของอินโวลุ่มที่ได้จากแพรวีไวรัสอัลกอริทึม

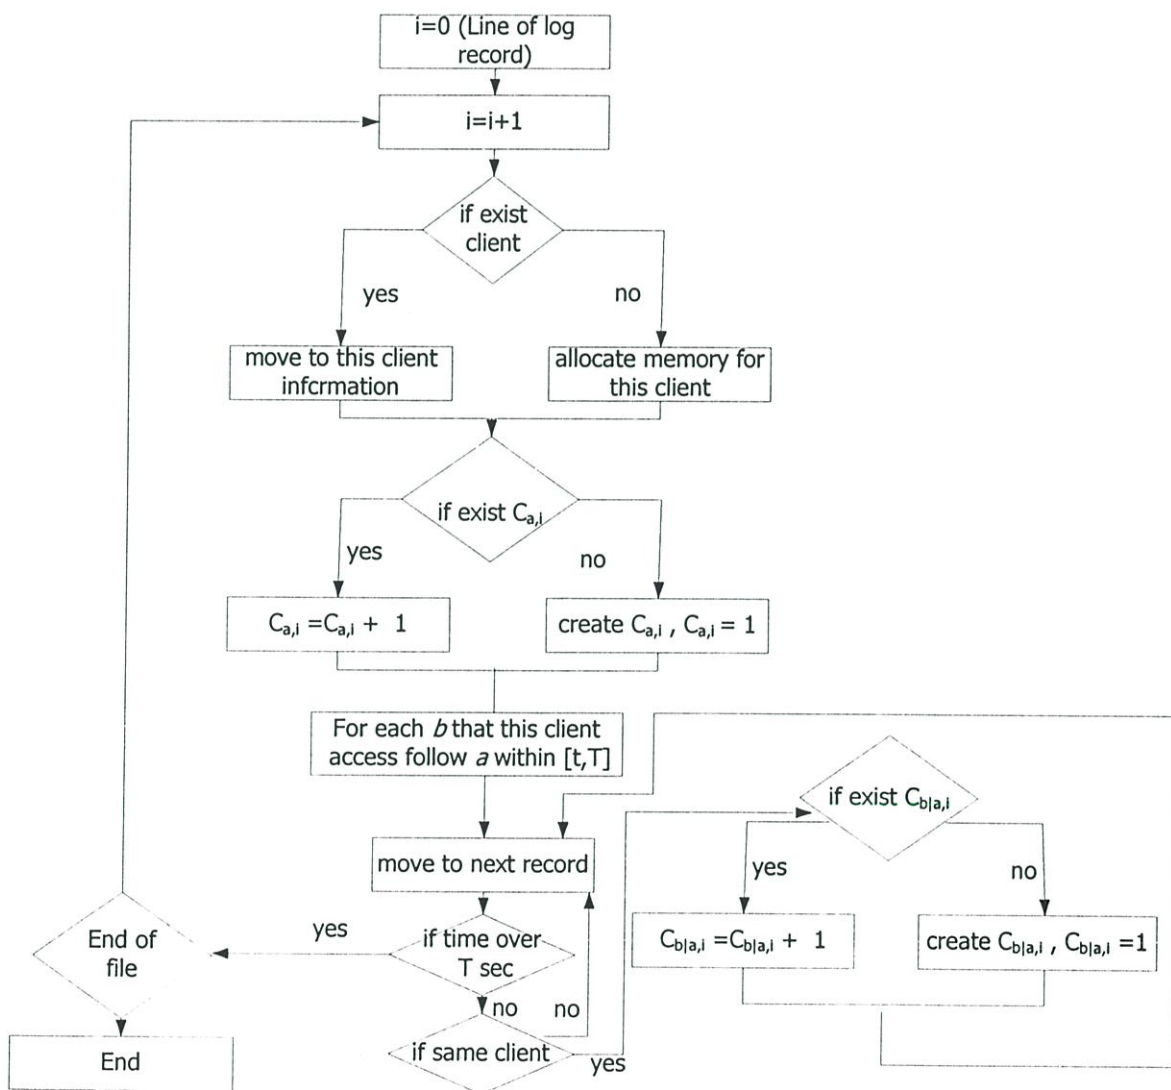
Hint_o เป็นอินที่จะถูกส่งกลับไปให้ผู้ใช้ทำการปริเฟรช



Flowchart 5 แสดงขั้นตอนการทำงานในส่วน Count Step for specific client ของแพรวีไวรัสอัลกอริทึมแบบใช้เทรสเตอร์ 2 ระดับ

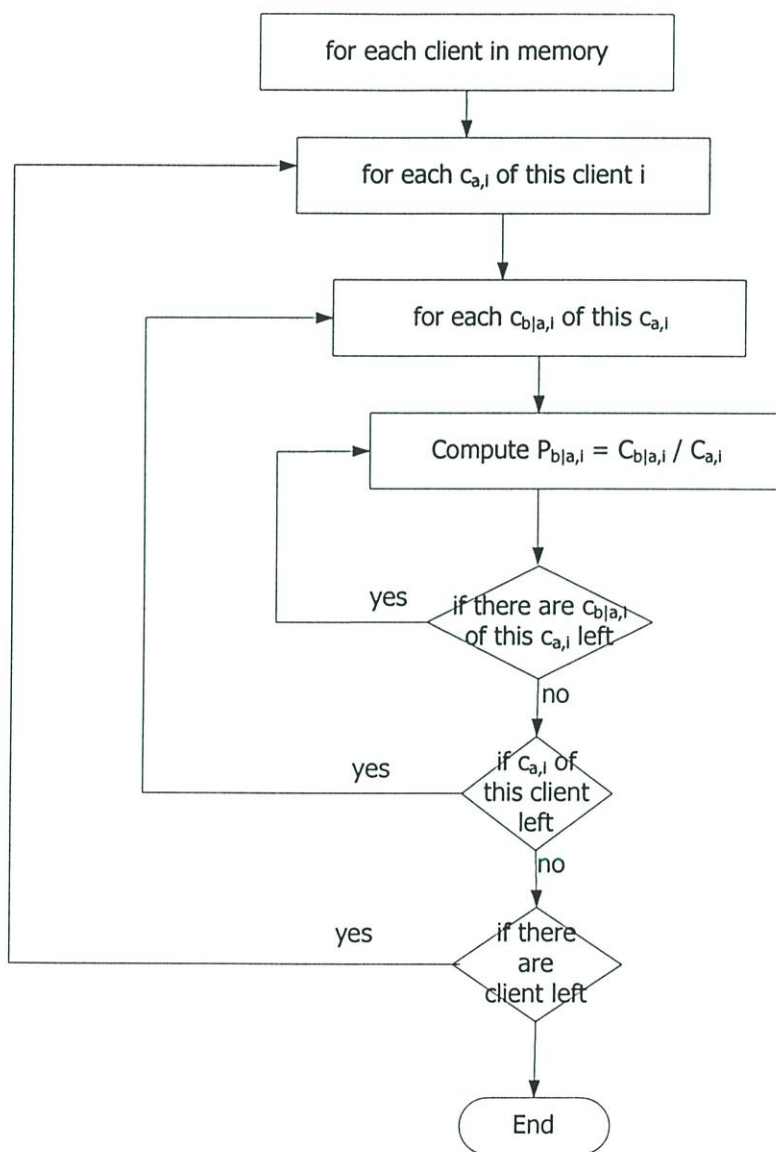
นิยาม $C_{a,i}$ เป็นจำนวนครั้งที่ผู้ใช้คนที่ i ร้องขอเว็บเพจ a ใดๆ

$C_{b|a,i}$ เป็นจำนวนครั้งที่ผู้ใช้คนที่ i มีการร้องเว็บเพจ b ใดๆ ต่อจากเว็บเพจ a ใดๆ



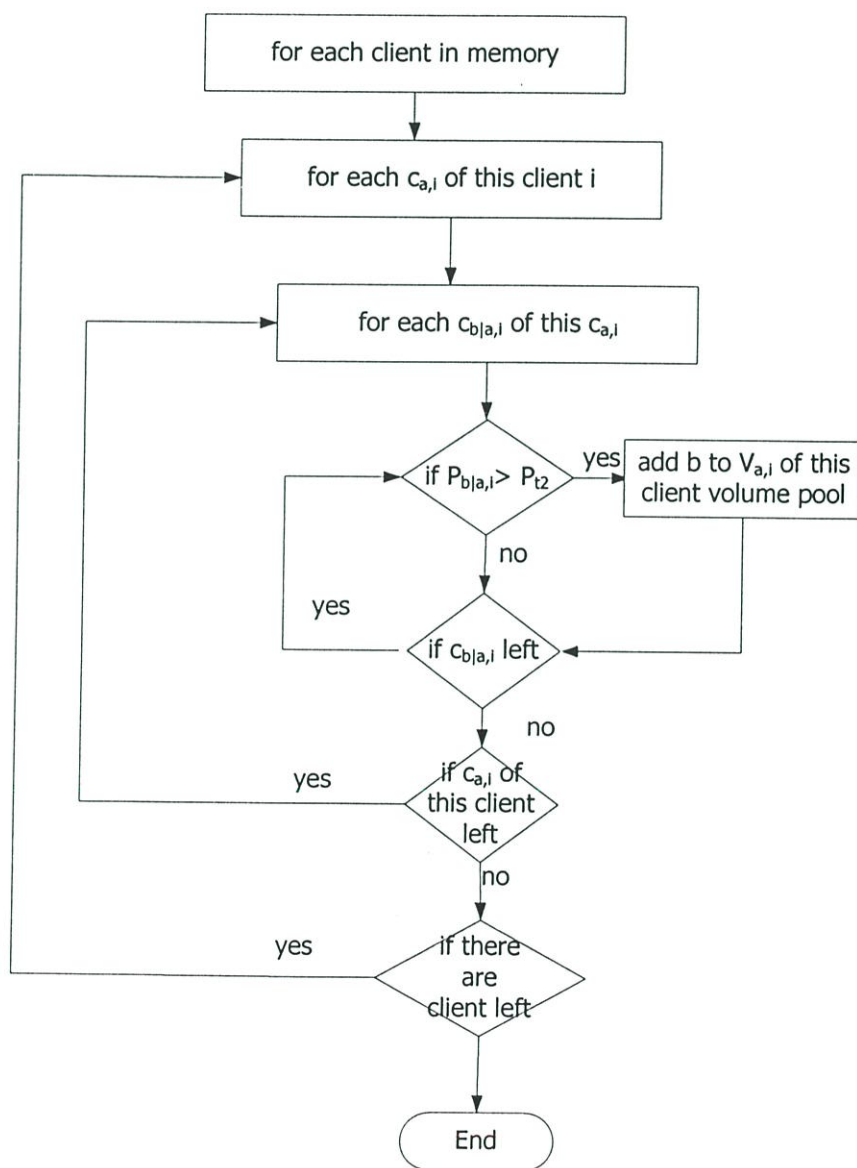
Flowchart 6 แสดงขั้นตอนการทำงานในส่วน Compute Probabilities Step for Specific client ของแพรว
ไวส์อัลกอริทึมแบบใช้เทรสด์ 2 ระดับ

นิยาม $P_{b|a,i}$ เป็นความน่าจะเป็นของผู้ใช้คนที่ i ที่ร้องขอเว็บเพจ b ขึ้นกับเว็บเพจ a ใดๆ



Flowchart 7 แสดงขั้นตอนการทำงานในส่วน Hint Construction Step for Specific client ของแพรวีไวัส อัลกอริทึมแบบใช้เทรสโวล 2 ระดับ

นิยาม P_{t2} เป็นความน่าจะเป็นเทรสโวลของส่วนการทำงานที่สองของแพรวีไวัสอัลกอริทึมแบบใช้เทรสโวล 2 ระดับ



Flowchart 8 แสดงขั้นตอนการทำงานในส่วน Send Hint Step for Specific client ของแพรวีไวรัส

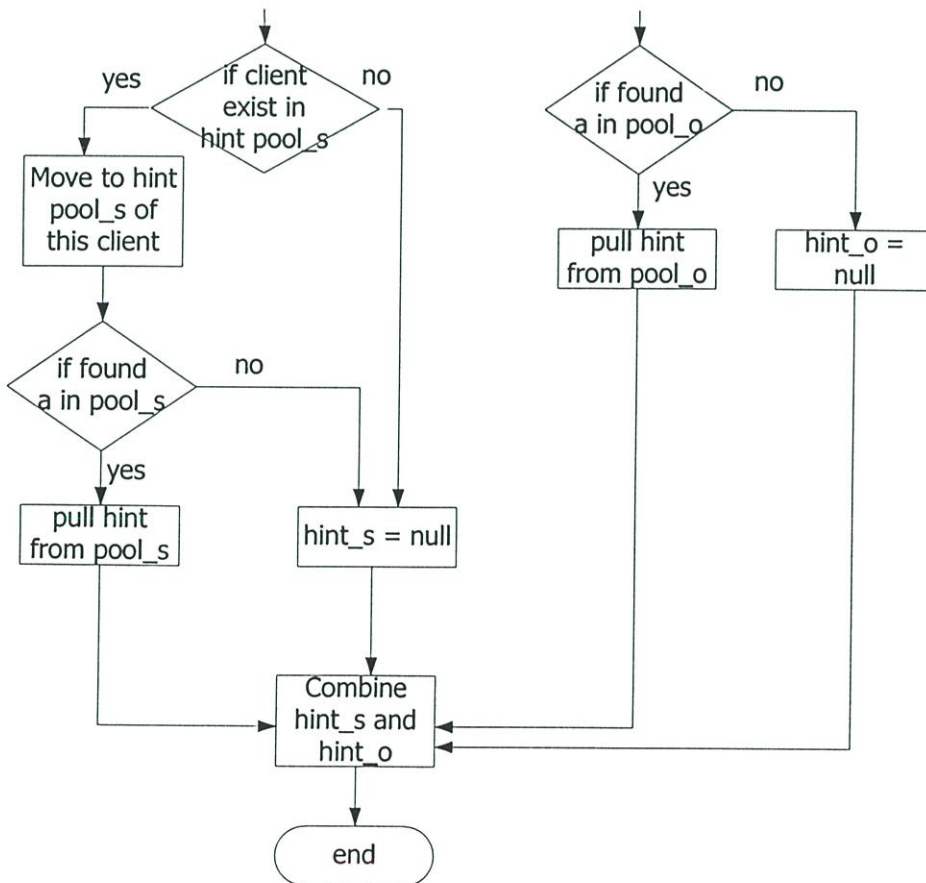
อัลกอริทึมแบบใช้เทอร์ส โสลด 2 ระดับ

นิยาม *Pool_o* คือกลุ่มของอินโวลลุ่มที่ได้จากส่วนการทำงานที่แรกของแพรวีไวรัสอัลกอริทึมแบบใช้เทอร์ส โสลด 2 ระดับ

Pool_s คือกลุ่มของอินโวลลุ่มที่ได้จากส่วนการทำงานที่สองของแพรวีไวรัสอัลกอริทึมแบบใช้เทอร์ส โสลด 2 ระดับ

Hint_o เป็นอินที่ได้จากส่วนการทำงานแรกของแพรวีไวรัสอัลกอริทึมแบบใช้เทอร์ส โสลด 2 ระดับ

Hint_s เป็นอินที่ได้จากส่วนการทำงานสองของแพรวีไวรัสอัลกอริทึมแบบใช้เทอร์ส โสลด 2 ระดับ



ประวัติผู้เขียน

ชื่อ-นามสกุล นายวิศิษฐ์ พัฒน์ชู
วัน เดือน ปีเกิด 23 สิงหาคม 2521 ที่กรุงเทพมหานคร
ที่อยู่ 52 ซอยพื้งมี 38 ถนนสุขุมวิท 93 แขวงบางจาก เขตพระโขนง กรุงเทพฯ
10260 โทร. 0-2311-0371

ประวัติการศึกษา 2539 วิทยาศาสตร์บัณฑิต สาขาวิทยาการคอมพิวเตอร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ความชำนาญเฉพาะด้าน

- 1.) ระบบเครือข่ายคอมพิวเตอร์
- 2.) เว็บโปรแกรมด้วย ASP, JSP

ประสบการณ์การทำงานและผลงานวิจัย

พ.ศ. 2543 – ปัจจุบัน ตำแหน่งผู้เชี่ยวชาญด้านเครือข่ายบริษัทค้าโปรแกรมคอมพิวเตอร์ซิสเต็มส์

- ให้คำปรึกษาด้านระบบเครือข่ายคอมพิวเตอร์
- ออกแบบและแก้ไขปัญหาของระบบเครือข่าย