

สถาบัตยกรรมแบบผสมสำหรับการประมวลผลบันทึกของระบบงานขนาดใหญ่



จุฬาลงกรณ์มหาวิทยาลัย

CHULALONGKORN UNIVERSITY

บทคัดย่อและแฟ้มข้อมูลฉบับเต็มของวิทยานิพนธ์ตั้งแต่ปีการศึกษา 2554 ที่ให้บริการในคลังปัญญาจุฬาฯ (CUIR)

เป็นแฟ้มข้อมูลของนิสิตเจ้าของวิทยานิพนธ์ ที่ส่งผ่านทางบันทิตวิทยาลัย

The abstract and full text of theses from the academic year 2011 in Chulalongkorn University Intellectual Repository (CUIR)

are the thesis authors' files submitted through the University Graduate School.

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตร์มหาบัณฑิต

สาขาวิชาจักรกลคอมพิวเตอร์ ภาควิชาจักรกลคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2558

ดิษฐิกิจของจุฬาลงกรณ์มหาวิทยาลัย

Hybrid Architecture for Large Scale Log Processing



A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Engineering Program in Computer Engineering  
Department of Computer Engineering  
Faculty of Engineering  
Chulalongkorn University  
Academic Year 2015  
Copyright of Chulalongkorn University

หัวขอวิทยานิพนธ์	สถาบัตยกรรมแบบผสมสำหรับการประมวลผลบันทึก
โดย	ของระบบงานขนาดใหญ่
สาขาวิชา	นายพิทยุตม์ ตั้งสัจจะธรรม
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	วิศวกรรมคอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม	ผู้ช่วยศาสตราจารย์ ดร. ณัฐวุฒิ หนูไฟโจน์
	ผู้ช่วยศาสตราจารย์ ดร. เกริก ภิรมย์โสกา

คณะกรรมการคัดเลือก  
อนุมัติให้นับวิทยานิพนธ์ฉบับนี้เป็น<sup>๑</sup>  
ผลงานของนักศึกษาตามหลักสูตรปัจจุบันที่ติดต่อ

คณะกรรมการคัดเลือก

(รองศาสตราจารย์ ดร. สุพจน์ เตชะรัตน์สกุล)

คณะกรรมการสอบบัณฑิตวิทยานิพนธ์

ประธานกรรมการ

(ผู้ช่วยศาสตราจารย์ ดร. วีระ เหมืองสิน)

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

(ผู้ช่วยศาสตราจารย์ ดร. ณัฐวุฒิ หนูไฟโจน์)

อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม

(ผู้ช่วยศาสตราจารย์ ดร. เกริก ภิรมย์โสกา)

กรรมการภายนอกมหาวิทยาลัย

(ผู้ช่วยศาสตราจารย์ ดร. ภูชิงค์ อุทโยภาศ)

**พิทยุตม์ ตั้งสัจจะธรรม** : สถาบันปัตยกรรมแบบผสมสำหรับการประมวลผลบันทึกของระบบงานขนาดใหญ่ (Hybrid Architecture for Large Scale Log Processing) อ.ที่ปรือกษาวิทยานิพนธ์หลัก: ผศ. ดร. ณัฐรุณิ หนูไฟโรจน์, อ.ที่ปรือกษาวิทยานิพนธ์ร่วม: ผศ. ดร. เกริก กิริมย์สกุล, 47 หน้า.

การประมวลผลบันทึกของระบบงานขนาดใหญ่ที่มาจากการหลายๆ เครื่องแม่ข่ายจะพบว่า บันทึกของระบบงานของแต่ละเครื่องแม่ข่ายนั้นมีขนาดใหญ่ ถูกส่งมาตลอดเวลา และมีรูปแบบที่แตกต่างกัน ซึ่งทำให้การประมวลผลข้อมูลของบันทึกของระบบงานเหล่านี้ทำได้ยากยิ่ง ตัวอย่างเช่น การตรวจจับความผิดปกติของระบบเป็นระบบที่จะต้องวิเคราะห์ข้อมูลล่าสุดร่วมกับข้อมูลในอดีต ถ้าหากเราต้องการความแม่นยำในการตรวจจับความผิดปกติอย่างทันท่วงที เราจะต้องประมวลผลข้อมูลเหล่านี้ให้ได้ภายในระยะเวลาที่จำกัด เพื่อแก้ปัญหาเหล่านี้ งานวิจัยนี้ นำเสนอ สถาบันปัตยกรรมแบบผสมสำหรับการประมวลผลบันทึกของระบบงานขนาดใหญ่โดยใช้ Apache Spark สำหรับทำการประมวลผลข้อมูล และ Apache Flume สำหรับการจัดการกับข้อมูล โดยใช้การตรวจจับความผิดปกติโดยใช้แบบจำลองเวลาชาbirima มาทดสอบและประเมินระบบ ซึ่งสถาบันปัตยกรรมที่นำเสนอจะประมวลผลทั้งในรูปแบบ Batch และ Real-Time จากผลการทดสอบพบว่า การใช้สถาบันปัตยกรรมแบบผสมสำหรับการประมวลผลบันทึกของระบบงานขนาดใหญ่นั้น สามารถช่วยเพิ่มประสิทธิภาพในการทำงานกับบันทึกของระบบงานขนาดใหญ่ได้ดียิ่งขึ้น โดยสามารถประมวลผลข้อมูลที่มีขนาดใหญ่แล้วนำมาสร้างแบบจำลองที่มีความซับซ้อน เพื่อใช้ทำการตรวจจับความผิดปกติอย่างมีประสิทธิภาพ ภายในระยะเวลาที่จำกัด

CHULALONGKORN UNIVERSITY

ภาควิชา วิศวกรรมคอมพิวเตอร์  
สาขาวิชา วิศวกรรมคอมพิวเตอร์  
ปีการศึกษา 2558

ลายมือชื่อนิสิต \_\_\_\_\_  
ลายมือชื่อ อ.ที่ปรือกษาหลัก \_\_\_\_\_  
ลายมือชื่อ อ.ที่ปรือกษาร่วม \_\_\_\_\_

# # 5670311621 : MAJOR COMPUTER ENGINEERING

KEYWORDS: HADOOP / REAL-TIME / LOG PROCESSING / LARGE-SCALE / HYBRID  
PROCESSING

PITTAYUT TANGSATJATHAM: Hybrid Architecture for Large Scale Log Processing. ADVISOR: ASST. PROF. NATAWUT NUPAIROJ, Ph.D., CO-ADVISOR: ASST. PROF. KRERK PIROMSOPA, Ph.D., 47 pp.

Log processing can be very challenging, especially for environments with lots of servers. In these environments, log data is large, coming at high-speed, and have various formats, the classic case of big data problem. This makes big data log processing very difficult. For example, anomaly detection needs to process both latest data and historical data. To get good accuracy, large amount of data must be processed in real-time. To solve this problem, this research proposes a hybrid architecture for log anomaly detection using Apache Spark for data processing and Apache Flume for data collecting. To demonstrate the capabilities of our proposed solution, we implement a SARIMA-based anomaly detection as a case study. The experimental results clearly indicated that our proposed architecture can support log processing in large-scale environment effectively.



Department: Computer Engineering Student's Signature .....

Field of Study: Computer Engineering Advisor's Signature .....

Academic Year: 2015 Co-Advisor's Signature .....

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยความกรุณาอย่างสูงจาก ผศ. ดร. ณัฐุณิ หนูไพรожน์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ และ ผศ. ดร. เกริก ภิรมย์สถาpa อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม ที่ได้กรุณาสละเวลาให้คำปรึกษา คำแนะนำ รวมทั้งให้แนวคิดที่เป็นประโยชน์ในการทำวิจัย และช่วยซึ่งแนะนำแนวทางในการแก้ปัญหาต่างๆ ที่เกิดขึ้นระหว่างการทำวิจัย ขอขอบพระคุณอาจารย์มา ณ โอกาสนี้

ขอกราบขอบพระคุณ ผศ. ดร. วีระ เนื่อง, ผศ. ดร. ภูษังค์ อุทธโยกาศ, ผศ. ดร. เกริก ภิรมย์สถาpa และ ผศ. ดร. ณัฐุณิ หนูไพรожน์ คณะกรรมการคุณสอบวิทยานิพนธ์เป็นอย่างยิ่ง ที่ได้กรุณาตรวจสอบและให้ข้อเสนอแนะอันเป็นประโยชน์ในการปรับปรุงแก้ไข วิทยานิพนธ์นี้ให้มีความถูกต้องและสมบูรณ์มากยิ่งขึ้น

ขอกราบขอบพระคุณ คณาจารย์ทุกท่านในภาควิชาวิศวกรรมคอมพิวเตอร์ จุฬาลงกรณ์มหาวิทยาลัย ที่ให้คำแนะนำ ความรู้ และแนวทางการทำวิทยานิพนธ์

ขอขอบคุณ เพื่อนๆ พี่ๆ หลักสูตรวิศวกรรมคอมพิวเตอร์ สาหรับกำลังใจ และ คำแนะนำใน การจัดทำวิทยานิพนธ์

สุดท้ายนี้ ขอกราบขอบพระคุณ บิดา มารดา รวมถึงสมาชิกในครอบครัว ที่ให้การสนับสนุน และให้กำลังใจที่ดีเสมอมา

**จุฬาลงกรณ์มหาวิทยาลัย**

**CHULALONGKORN UNIVERSITY**

## สารบัญ

หน้า

บทคัดย่อภาษาไทย .....	๑
บทคัดย่อภาษาอังกฤษ .....	๓
กิตติกรรมประกาศ .....	๘
สารบัญ .....	๙
สารบัญภาพ .....	๑๔
สารบัญตาราง .....	๑๕
บทที่ 1 บพนฯ .....	๑
1.1 ความเป็นมาและความสำคัญของปัญหา .....	๑
1.2 วัตถุประสงค์ของงานวิจัย .....	๔
1.3 ขอบเขตของงานวิจัย .....	๔
1.4 ประโยชน์ที่คาดว่าจะได้รับ .....	๔
1.5 แผนการดำเนินงานวิจัย .....	๔
1.6 ผลงานตีพิมพ์ .....	๕
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง .....	๖
2.1 บันทึกของระบบงาน (Log) .....	๖
2.2 Big Data .....	๗
2.3 Resilient Distributed Datasets (RDDs) .....	๘
2.4 Discretized Streams (D-Stream) .....	๘
2.5 Apache Hadoop [18, 19] .....	๙
2.5.1 สถาปัตยกรรมของ HDFS .....	๙
2.5.2 Hadoop Yarn (MapReduce version 2) .....	๑๑
2.6 Apache Flume [20] .....	๑๒

## หน้า

2.6.1 สถาปัตยกรรมของ Apache Flume .....	12
2.7 Apache Spark [19, 21] .....	13
2.8 การแก้ปัญหาไฟล์ขนาดเล็กบน Hadoop .....	13
2.9 แบบจำลองอนุกรมเวลาชาวิมา (SARIMA).....	14
2.10 Akaike information criterion (AIC).....	15
2.11 Bayesian information criterion (BIC).....	16
2.12 Maximum likelihood estimation (MLE).....	16
2.13 งานวิจัยที่เกี่ยวข้อง .....	16
2.13.1 โครงสร้างระบบประมวลผลบันทึกของระบบงาน.....	16
2.13.1.1              โครงสร้างการประมวลผลบันทึกของระบบงาน แบบ Batch     17	
2.13.1.2              โครงสร้างการประมวลผลบันทึกของระบบงาน แบบ Real- Time     18	
2.13.2 สถาปัตยกรรมแบบ Three-layered lambda .....	19
2.13.3 Anomaly detection base on SARIMA .....	20
บทที่ 3 แนวคิดและวิธีดำเนินงานวิจัย .....	21
3.1 ปัญหาการประมวลผลบันทึกของระบบงาน .....	21
3.2 หลักการทำงานของสถาปัตยกรรมแบบผสมสำหรับการประมวลผลบันทึกของ ระบบงานขนาดใหญ่ .....	22
3.3 หลักการทำงานของการพยากรณ์ปริมาณการใช้งานเครือข่ายโดยใช้บันทึกของ ระบบงาน .....	23
3.4 การสร้างแบบจำลองอนุกรมเวลาชาวิมา.....	25

## หน้า

3.5 การตรวจหาปริมาณการใช้งานเครือข่ายที่ผิดปกติโดยใช้แบบจำลองอนุกรมเวลาชา <small>ริ</small> มา.....	26
3.6 นิยามศัพท์ในงานวิจัย .....	28
บทที่ 4 การพัฒนาเครื่องมือและการทดสอบ .....	31
4.1 สภาพแวดล้อมที่ใช้ในการทดสอบ.....	31
4.2 ข้อมูลที่ใช้ในการทดสอบ .....	31
4.3 การทดสอบประสิทธิภาพ .....	31
4.3.1 การทดสอบประสิทธิภาพในการพยากรณ์ปริมาณการใช้งานเครือข่าย .....	32
4.3.2 การทดสอบประสิทธิภาพในการตรวจหาความผิดปกติของเครือข่าย .....	36
4.3.3 การทดสอบประสิทธิภาพในการประมาณผลและพยากรณ์ปริมาณการใช้งาน เครือข่าย .....	39
4.3.4 การทดสอบประสิทธิภาพในการทำงานในสภาวะแบบ Real-Time.....	41
4.5 วิเคราะห์ผลการทดลอง .....	42
บทที่ 5 บทสรุปและแนวทางในการพัฒนาต่อ .....	43
5.1 สรุปผลการวิจัย .....	43
5.2 แนวทางในการพัฒนาต่อ .....	43
รายการอ้างอิง .....	44
ประวัติผู้เขียนวิทยานิพนธ์.....	47

## สารบัญภาพ

หน้า

ภาพที่ 1 ตัวอย่างไฟล์ของบันทึกของระบบงาน .....	6
ภาพที่ 2 3Vs of Big Data .....	7
ภาพที่ 3 RDDs Transformation.....	8
ภาพที่ 4 D-Streams Operation .....	8
ภาพที่ 5 สถาปัตยกรรมของ HDFS.....	9
ภาพที่ 6 สถาปัตยกรรมของ Hadoop YARN .....	11
ภาพที่ 7 สถาปัตยกรรมของ Apache Flume .....	12
ภาพที่ 8 Spark Framework .....	13
ภาพที่ 9 โครงสร้างการประมวลบันทึกของระบบงาน โดยใช้ Hadoop .....	17
ภาพที่ 10 โครงสร้างการประมวลผลบันทึกของระบบงาน แบบ Real-Time .....	19
ภาพที่ 11 Three-layered lambda architecture .....	20
ภาพที่ 12 สถาปัตยกรรมแบบผสมสำหรับการประมวลผลบันทึกของระบบงานขนาดใหญ่ ..	23
ภาพที่ 13 แสดงการพยากรณ์ปริมาณการใช้งานเครือข่าย .....	23
ภาพที่ 14 แสดงตัวอย่างการพยากรณ์ที่ละ step (a) step ที่ 146 (b) step ที่ 147 .....	24
ภาพที่ 15 แสดงตัวอย่างการพยากรณ์ที่ละ 18 steps (a) step ที่ 145 ถึง step ที่ 162 (b) step ที่ 163 ถึง step ที่ 180.....	25
ภาพที่ 16 ปริมาณการใช้งานเครือข่ายจากบันทึกของระบบงาน โดยใช้ 5 นาทีเป็นหน่วยของเวลา .....	26
ภาพที่ 17 ปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจริง เทียบกับผลจากการพยากรณ์.....	27
ภาพที่ 18 ตัวอย่างการแจ้งเตือนความผิดปกติของการใช้งานอินเทอร์เน็ต .....	27
ภาพที่ 19 แสดงถึงช่วงเวลาที่ใช้ในการสร้างแบบจำลองและพยากรณ์.....	28

ภาพที่ 20 ผลการประมวลผลโดยใช้ช่วงเวลาที่แตกต่างกันในการประมวลผล .....	29
ภาพที่ 21 กราฟแสดงเวลาที่ใช้งานการประมวลผลเมื่อเทียบระหว่างช่วงเวลาของข้อมูลและปริมาณของข้อมูลที่ใช้งานการประมวลผล (a) 2 Nodes, (b) 3 Nodes, (c) 4 Nodes, และ 5 Nodes .....	30
ภาพที่ 22 ปริมาณการใช้งานระบบเครือข่ายที่เกิดขึ้นจริงเทียบกับค่าปริมาณการใช้งานระบบเครือข่ายที่พยากรณ์ และค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ (a) ระดับ 5 นาที, (b) ระดับ 10 นาที, (c) ระดับ 20 นาที, (d) ระดับ 30 นาที, และ (e) ระดับ 60 นาที .....	33
ภาพที่ 23 ตัวอย่างข้อมูลของปริมาณการใช้งานเครือข่าย .....	34
ภาพที่ 24 ปริมาณการใช้งานระบบเครือข่ายที่เกิดขึ้นจริงเทียบกับค่าปริมาณการใช้งานระบบเครือข่ายที่พยากรณ์ และค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ โดยการนำวันที่มีปริมาณเท่าๆ กัน โดย (a) ใช้ข้อมูลย้อนหลัง 2 วัน (b) ใช้ข้อมูลย้อนหลัง 7 วัน .....	35
ภาพที่ 25 ปริมาณการใช้งานระบบเครือข่ายที่เกิดขึ้นจริงเทียบกับค่าปริมาณการใช้งานระบบเครือข่ายที่พยากรณ์ และค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ โดยการนำวันธรรมดามาทำนายวันหยุด โดย (a) ใช้ข้อมูลย้อนหลัง 2 วัน (b) ใช้ข้อมูลย้อนหลัง 7 วัน .....	35
ภาพที่ 26 ปริมาณการใช้งานระบบเครือข่ายที่เกิดขึ้นจริงเทียบกับค่าปริมาณการใช้งานระบบเครือข่ายที่พยากรณ์ และค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ โดยการนำวันหยุดมาทำนายวันธรรมดा โดย (a) ใช้ข้อมูลย้อนหลัง 2 วัน (b) ใช้ข้อมูลย้อนหลัง 7 วัน .....	36
ภาพที่ 27 เวลาที่ใช้งานการประมวลผล (a) ระดับ 5 นาที, (b) ระดับ 10 นาที, (c) ระดับ 20 นาที, (d) ระดับ 30 นาที, และ (e) ระดับ 60 นาที .....	40
ภาพที่ 28 แสดงการทำงานประมวลผลของระบบในสภาวะ Real-Time .....	41

## สารบัญตาราง

หน้า

ตารางที่ 1 ตารางแสดงการแก้ไขปัญหาการไฟล์ขนาดเล็กบนระบบการเก็บข้อมูลแบบ กระจาย.....	14
ตารางที่ 2 ผลลัพธ์ของการทดสอบประสิทธิภาพในการตรวจหาความผิดปกติของ เครื่อข่าย .....	37
ตารางที่ 3 ผลการทดสอบประสิทธิภาพในการประมวลผลแบบ Real-Time.....	41



## บทที่ 1

### บทนำ

#### 1.1 ความเป็นมาและความสำคัญของปัญหา

ในองค์กรต่างๆ จะต้องมีระบบ IT เป็นพื้นฐานในการทำงาน ซึ่งจะประกอบไปด้วยอุปกรณ์ และบริการต่างๆ โดยที่อุปกรณ์และบริการเหล่านี้จะสร้างบันทึกของระบบงาน (Log) ที่ใช้เก็บบันทึกพฤติกรรมที่เกิดขึ้นกับตัวอุปกรณ์ หรือบริการนั้นๆ ระบบประมวลผลบันทึกของระบบงาน จึงเป็นเครื่องมือที่สำคัญที่จะใช้ในการสนับสนุนการทำงานของระบบงานขนาดใหญ่ (Large Scale System) เช่น การนำบันทึกของระบบงาน มาประมวลผลเพื่อศึกษาพฤติกรรมของผู้ใช้งานภายในระบบ, การตรวจสอบด้านความปลอดภัยของระบบ, หรือตรวจสอบการโจรตี และพฤติกรรมการฉ้อโกงของมิจฉาชีพ เป็นต้น เนื่องจากในปี พ.ศ.2550 พระราชบัญญัติว่าด้วยการกำกับดูแลและปรับปรุงการให้บริการด้านเทคโนโลยีสารสนเทศ จึงได้มีการกำหนดให้ห้ามนำข้อมูลทางการค้าและข้อมูลส่วนบุคคลของบุคคลที่สาม ที่เก็บรวบรวมโดยไม่ได้รับความยินยอมจากบุคคลนั้น ให้เป็นไปอย่างไร้เดียงสา แต่ในปัจจุบัน ไม่ว่าจะเป็นหน่วยงานใด ก็สามารถเข้าถึงข้อมูลนี้ได้ ทำให้เกิดปัญหาด้านความปลอดภัยและความเป็นส่วนตัว ซึ่งเป็นภัย对自己和他人造成损害。因此，必须采取适当的措施来保护这些数据的安全性和隐私性。

ในการทำงานของผู้ดูแลระบบของสำนักเทคโนโลยีสารสนเทศ ซึ่งจะต้องแก้ไขปัญหาทางเทคนิคให้แก่ผู้ใช้งาน จำเป็นอย่างยิ่งที่จะต้องใช้ข้อมูลบันทึกของระบบงาน ที่เก็บมาจากเครื่องแม่ข่ายต่างๆ ซึ่งเป็นข้อมูลประเภท Big Data ที่เก็บไว้ และ Fast Data ที่เข้ามาใหม่มาประมวลผลแบบ Real-Time อย่างไรก็ตามเนื่องจากปริมาณของข้อมูลบันทึกของระบบงาน ที่มีขนาดใหญ่

ดังกล่าว ทำให้ระบบการจัดเก็บบันทึกของระบบงาน ในปัจจุบันไม่สามารถตอบสนองความต้องการในการประมวลผลและเข้าถึงข้อมูลได้อย่างมีประสิทธิภาพ อีกทั้งการนำข้อมูลที่จัดเก็บไว้มาทำการวิเคราะห์เพื่อหาต้นตอของปัญหา (Root Cause) หรือความผิดปกติของระบบ (Failure) ก็จะทำได้ยาก ต้องใช้เวลาในการค้นหา และการคัดกรองข้อมูลเป็นเวลากว่า ทำให้เกิดข้อจำกัดในการทำงานเป็นอย่างมาก

จากการวิจัยที่ผ่านมาเราพบว่าระบบการประมวลผลบันทึกของระบบงาน ส่วนใหญ่นั้นจะเป็นการประมวลผลแบบ Batch [3-6] ซึ่งจะเน้น Throughput ของระบบ ทำให้สามารถประมวลผลข้อมูลที่มีปริมาณมากได้ แต่ว่าการประมวลผลแบบ Batch นั้นต้องใช้ระยะเวลาในการประมวลผลที่ค่อนข้างสูง ทางผู้จัดทำจึงได้นำเทคโนโลยี Hadoop ซึ่งเป็น platform ของการประมวลผลแบบกระจายที่มีความนิยม และสามารถทำให้ความเร็วในการประมวลผลแบบ Batch เพิ่มมากขึ้น มาใช้ในการแก้ปัญหาและจัดการกับข้อมูลประเกณฑ์ที่ก่อให้เกิดปัญหานี้ หรือ Big Data [7-10] โดย Hadoop Distributed File System (HDFS) ใน Hadoop นั้นจะช่วยในเรื่องของการจัดเก็บข้อมูลที่มีปริมาณมากโดยที่ HDFS นั้นจะมีการทำสำรองข้อมูลอัตโนมัติ (Replicate) เพื่อเพิ่มความทนทานต่อความสูญเสียของข้อมูล (Fault Tolerance) อยู่ด้วย นอกจากนั้น Hadoop ยังมี MapReduce Framework ที่สามารถประมวลผลข้อมูลขนาดใหญ่ที่เก็บไว้แบบ parallel ได้ ทำให้สามารถประมวลผลข้อมูลได้อย่างรวดเร็ว ถึงแม้ว่าเราจะนำ Hadoop มาใช้แล้วก็ตาม การประมวลผลแบบ Batch อย่างเดียวแน่นอนยังคงไม่เพียงพอต่อความต้องการของสำนักเทคโนโลยีสารสนเทศ ทำให้เราต้องนำการประมวลผลแบบ Real-Time มาใช้ร่วมกัน แต่การประมวลผลแบบ Real-Time ที่มีมานั้น [11-13] จะเน้นการประมวลผลให้ทันเวลาโดยที่จะประมวลผลข้อมูลที่เข้ามาให้ได้ผลลัพธ์ออกมาด้วยอัตราที่ทันท่วงทัน กับอัตราที่ข้อมูลไหลเข้ามาในระบบ อีกทั้งการประมวลผลบันทึกของระบบงาน แบบ Real-Time ส่วนใหญ่นั้นจะประมวลผลบันทึกของระบบงานก่อนแล้วนำผลลัพธ์นั้นๆ มาจัดเก็บลงฐานข้อมูลทำให้ไม่ต้องเก็บข้อมูลดิบหรือข้อมูลเก่าที่มีปริมาณมาก จึงทำให้การประมวลผลแบบ Real-Time ส่วนใหญ่ ไม่สามารถทำการประมวลผลข้อมูลย้อนหลังได้เหมือนกับการประมวลผลแบบ Batch นอกเหนือจากนี้ถึงแม้ว่าจะมีระบบงานที่รองรับการบริหารจัดการบันทึกของระบบงาน ขนาดใหญ่อย่างมีประสิทธิภาพเช่น Splunk, Loggy หรือว่า ArcSight Logger แต่ก็เป็นระบบงานแบบ Commercial ซึ่งมีราคาที่ค่อนข้างสูงและมีปัญหาในเรื่องการขยายของข้อมูล (data scale) เพราะต้องรับมือกับข้อมูลที่มีปริมาณมาก

ขนาดของบันทึกของระบบงาน ที่ส่งมาจากเครื่องแม่ข่ายแต่ละเครื่องนั้นมีขนาด (Volume) และความถี่ในการส่ง (Velocity) ไม่คงที่ โดยส่วนใหญ่แล้วจะเป็นไฟล์ที่มีขนาดเล็ก [14] ซึ่งไม่

หมายเหตุที่จะนำมาจัดเก็บบน HDFS เพราะว่า HDFS นั้นถูกออกแบบมาเพื่อจัดเก็บข้อมูลที่มีขนาดใหญ่ โดยที่ HDFS นั้นจะแบ่งข้อมูลขนาดใหญ่ออกเป็น block ของข้อมูลที่มีขนาดเล็กแล้วเก็บลงบน HDFS แต่ถ้าเราจัดเก็บข้อมูลที่มีขนาดเล็กลงไปซึ่งจะไม่เต็ม block ส่งผลให้เราใช้ทรัพยากรของเครื่องอย่างไม่มีประสิทธิภาพ อีกทั้งยังส่งผลให้มีจำนวนของ block มาเกินความจำเป็นเนื่องจาก HDFS นั้นมีโครงสร้างการทำงานแบบ single-master-multiple-slave โดยจะประกอบไปด้วย NameNode กับ DataNode โดยที่การทำงานทั้งหมดนั้นจะต้องทำงานผ่าน NameNode ซึ่งทำหน้าที่เป็น Master Node ดังนั้นบน NameNode จึงมีการจัดเก็บ metadata เอาไว้เพื่อโดยให้บริการกับผู้ใช้เมื่อมีการร้องขอ โดยที่ metadata บน NameNode นั้นจะถูกจัดเก็บไว้บนหน่วยความจำเพื่อความเร็วในการทำงาน จึงทำให้เกิดปัญหาคือขาด หรือ Bottleneck ตามมา กล่าวคือ เมื่อมีการร้องขอการใช้งานจำนวนมาก จะทำให้ NameNode ต้องรับการร้องขอเกี่ยวกับการจัดเก็บ หรือ การกระจาย block บ่อยๆ ส่งผลให้ NameNode ทำงานหนักและอาจจะทำให้ NameNode นั้นไม่สามารถทำงานได้อย่างมีประสิทธิภาพเท่าที่ควร นอกจากนั้นพื้นที่ที่ใช้เก็บข้อมูลบน NameNode ก็มีจำกัดตาม physical memory อีกด้วย เพราะว่า HDFS นั้นจัดเก็บ metadata เอาไว้ใน memory ของ NameNode ดังนั้น ยิ่งมีจำนวนไฟล์จัดเก็บในระบบมากเท่าไหร่ ก็ยิ่งต้องใช้พื้นที่ในการจัดเก็บบน memory ของ namenode มากเท่านั้น

ดังนั้นระบบการจัดการบันทึกของระบบงาน ที่ดีนั้นควรจะต้องรองรับการทำงานกับข้อมูลที่ มีลักษณะเป็น Fast และ Big Data โดยที่ข้อมูลที่จัดเก็บลงบนระบบจะต้องมีความคงทนต่อความเสียหายหรือศูนย์หาย และระบบการจัดการบันทึกของระบบงานนั้นจะต้องมีความสามารถในการ ประมวลผลข้อมูลทั้งในรูปแบบของ Batch และ Real-Time เพราะว่างานแต่ละประเภทนั้นมีความ ต้องการไม่เหมือนกัน เช่น งานบางประเภทมีความต้องการที่จะประมวลจากข้อมูลเก่าหรือข้อมูล ดิบที่เราเก็บเอาไว้เท่านั้น, งานบางประเภทมีความต้องการที่จะประมวลผลข้อมูลที่เข้ามาเพื่อให้ได้ คำตอบอย่างรวดเร็ว เช่น ห้องแม่ข่าย หรือห้องแม่ข่าย ที่มีความต้องนำคำตอบจากการประมวลผล ข้อมูลที่เก็บเอาไว้มาประมวลผลร่วมกับกับการประมวลผลข้อมูลที่เข้าใหม่ เป็นต้น

จากปัญหาที่กล่าวมาข้างต้น งานวิจัยนี้จึงได้มุ่งเน้นการพัฒนาสถาปัตยกรรมที่เหมาะสมแก่ การประมวลผลบันทึกของระบบงานขนาดใหญ่ โดยอ้างอิงจากสถาปัตยกรรมแบบ Three-Lambda [15] เพื่อรองรับการทำงานแบบ Real-Time และ Batch ที่มีโครงสร้างของข้อมูลเชิง Big data ซึ่งมีความซับซ้อนและมีขนาดใหญ่ โดยจะเป็นการนำเทคโนโลยี HDFS ใน Hadoop และ In-memory Processing เช่น Spark เข้ามาต่อยอด

## 1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อพัฒนากระบวนการบริหารจัดการบันทึกของระบบงาน ขนาดใหญ่ที่สามารถประมวลผลได้ทั้งแบบ Batch และแบบ Real-Time
2. เพื่อพัฒนาระบบที่สามารถเก็บข้อมูลที่มีความคงทน และสามารถขยายขนาดเพื่อรองรับการเติบโตของข้อมูลได้

## 1.3 ขอบเขตของงานวิจัย

1. สามารถประมวลผลได้ทั้งในรูปแบบ Batch และ Real-Time
2. ตรวจสอบความผิดปกติของการใช้งานอินเทอร์เน็ตของจุดลงทะเบียนมหาวิทยาลัย
3. ตรวจสอบความผิดปกติของการใช้งานอินเทอร์เน็ตจากการพยายามปริมาณการใช้งานโดยใช้แบบจำลองอนุกรมเวลาซาริมา (SARIMA)

## 1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. ได้เรียนรู้รูปแบบการทำงานของ HDFS
2. ได้ต้นแบบของสถาปัตยกรรมที่ใช้ในการจัดการกับบันทึกของระบบงาน ในโครงสร้างการทำงานเชิง Big data และสามารถรองรับการขยายของข้อมูลได้
3. นำเสนอวิธีการตรวจหาความผิดปกติของการใช้งานเครือข่าย จากบันทึกของระบบงาน โดยใช้แบบจำลองอนุกรมเวลาซาริมา
4. สามารถนำความรู้จากผลการวิจัยนี้ไปประยุกต์ใช้จริงต่อไปในอนาคต

## 1.5 แผนการดำเนินงานวิจัย

1. ศึกษางานวิจัยที่เกี่ยวข้อง
 

ทำการศึกษางานวิจัยที่เกี่ยวข้อง เช่น โครงสร้างระบบการประมวลผลบันทึกของระบบงานที่เคยมีมา, ต้นแบบสถาปัตยกรรมที่เราสนใจนำมาปรับใช้ เป็นต้น
2. ออกรูปแบบวิธีการ และการเขียนโปรแกรม
 

ทำการออกแบบสถาปัตยกรรมที่ใช้สำหรับการจัดเก็บและประมวลผลบันทึกของระบบงาน
3. ทดสอบโปรแกรม และปรับปรุงวิธีการ

นำสถาปัตยกรรมไปใช้ในการประมาณผลของบันทึกของระบบงาน โดยใช้วิธี SARIMA ในการทดสอบสถาปัตยกรรม เพื่อทดสอบประสิทธิภาพการทำงาน โดยใช้ตัวชี้วัดที่นำเสนอ

#### 4. สรุปผลการทดลอง และจัดทำวิทยานิพนธ์

นำผลการทดลองที่ได้มารวเคราะห์ เปรียบเทียบ และสรุปผล โดยพิจารณาจากสถาปัตยกรรมที่ได้ออกแบบว่า มีความสามารถในการจัดการกับบันทึกของระบบงานได้เมื่อ ประสิทธิภาพมากน้อยเพียงใด

#### 1.6 ผลงานตีพิมพ์

ส่วนหนึ่งของวิทยานิพนธ์ฉบับนี้ได้นำเสนอในการประชุมวิชาการ ดังนี้

Pittayut Tangsatjatham and Natawut Nupairoj, "Hybrid Big Data Architecture for High-Speed Log Anomaly Detection", The 13<sup>th</sup> International Joint Conference on Computer Science and Software Engineering (JCSSE 2016) , Khon Kaen, Thailand, July 13-15, 2016

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

#### 2.1 บันทึกของระบบงาน (Log)

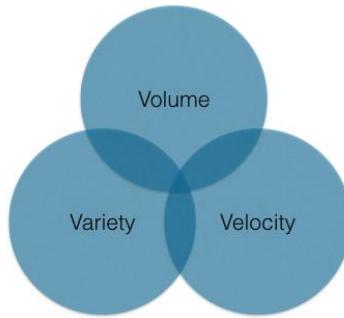
บันทึกของระบบงาน คือ ข้อมูลที่ถูกบันทึกไว้ตามลำดับเหตุการณ์ที่เกิดขึ้นบนคุปกรณ์คอมพิวเตอร์ หรือในบริการต่างๆ เพื่อที่จะสืบถึงพฤติกรรมต่างๆ ที่เกิดขึ้นทั้งเหตุการณ์ที่ปกติ และไม่ปกติที่เกิดขึ้นกับคุปกรณ์หรือ บริการนั้นๆ โดยปกติแล้วการสร้างบันทึกของระบบงานนั้นถูกใช้งานอย่างกว้างขวางทั้งใน Application, Operation system, Control system, Mobile devices, Super computer, รวมถึง Application component ดังนั้นเมื่อมีสิ่งที่ผิดปกติเกิดขึ้นกับระบบของเรา บันทึกของระบบงานสามารถเป็นตัวแทนที่สืบถึงพฤติกรรมของระบบ และสามารถนำไปวิเคราะห์หา failure ในระบบได้ โดยที่บันทึกของระบบงานนั้นจะจัดเก็บในรูปแบบที่ไม่เหมือนกัน รูปแบบที่นิยมใช้คือ Syslog format ซึ่งเป็นรูปแบบมาตรฐานหนึ่งของบันทึกของระบบงานโดยมีการบันทึกวันและเวลาของเหตุการณ์ที่เกิดขึ้น

```
Sep 26 22:09:24 ubuntu ntpd[1589]: Listen normally on 3 eth0 192.168.86.133 UDP 123
Sep 26 22:09:24 ubuntu ntpd[1589]: peers refreshed
Sep 26 22:09:24 ubuntu ntpd[1589]: Listening on routing socket on fd #20 for interface updates
Sep 26 22:09:24 ubuntu ntpd[1589]: Deferring DNS for 0.ubuntu.pool.ntp.org 1
Sep 26 22:09:24 ubuntu ntpd[1589]: Deferring DNS for 1.ubuntu.pool.ntp.org 1
Sep 26 22:09:24 ubuntu ntpd[1589]: Deferring DNS for 2.ubuntu.pool.ntp.org 1
Sep 26 22:09:24 ubuntu ntpd[1589]: Deferring DNS for 3.ubuntu.pool.ntp.org 1
Sep 26 22:09:24 ubuntu ntpd[1589]: Deferring DNS for ntp/ubuntu.com 1
Sep 26 22:09:29 ubuntu ntpd_intries[859]: parent died before we finished, exiting
Sep 26 22:09:51 ubuntu ntpd_intries[1530]: parent died before we finished, exiting
Sep 26 22:10:30 ubuntu dhclient: Internet Systems Consortium DHCP Client 4.2.4
Sep 26 22:10:30 ubuntu dhclient: Copyright 2004-2012 Internet Systems Consortium.
Sep 26 22:10:30 ubuntu dhclient: All rights reserved.
Sep 26 22:10:30 ubuntu dhclient: For info, please visit https://www.isc.org/software/dhcp/
```

ภาพที่ 1 ตัวอย่างไฟล์ของบันทึกของระบบงาน

จากภาพที่ 1 เป็นตัวอย่างของบันทึกของระบบงานซึ่งปกติแล้วจะประกอบไปด้วยข้อมูลต่างๆ เช่น วัน-เวลา, IP address หรือชื่อของ node ที่สร้างบันทึกของระบบงาน, และ message ซึ่งเป็นข้อมูลที่บอกถึงเหตุการณ์ปกติ (regular) ไปจนถึง Error ของระบบ โดยที่เหตุการณ์ปกติจะบอกถึงพฤติกรรมที่ไม่มีการ error เช่น Disk mount, Network status, และ User connection ส่วน error จะบอกเกี่ยวกับปัญหาของ Hardware, Software หรือการทำงานที่ผิดพลาดและไม่สำเร็จของคุปกรณ์ หรือบริการนั้นๆ

## 2.2 Big Data



ภาพที่ 2 3Vs of Big Data

Big data หรือฐานข้อมูลขนาดใหญ่ ในที่นี้หมายถึง เซตของข้อมูลที่ใหญ่มากขึ้นเรื่อยๆ และเกิดขึ้นอย่างรวดเร็ว จนยากแก่การใช้เครื่องมือแบบเก่าๆ ที่เคยมีมารวมถึงสภาพแวดล้อมในระบบที่มีความแตกต่างกันและสามารถเปลี่ยนแปลงได้ตลอดเวลาจนทำให้เกิดความซับซ้อนมากขึ้นเรื่อยๆ ภายในระบบ โดยที่ขนาด, ความซับซ้อน, การจัดเก็บ, การค้นหา, รวมถึงการวิเคราะห์ เป็นปั้นหาที่ยากต่อการจัดการในสภาพแวดล้อมที่เป็น Big data คือ ปริมาณ (Volume), ความเร็ว (velocity), และความหลากหลาย (variety) [1, 2]

1. ข้อมูลมีปริมาณมาก (Volume) : องค์กรต่างๆ มีการสร้างข้อมูลมากขึ้นเรื่อยๆ จนถึงขนาดเทราไปต์ ไม่ว่าจะเป็นการจัดเก็บข้อมูลที่มีความซับซ้อนมากขึ้น หรือการรับข้อมูลเข้ามา จนกระทั่งมีข้อมูลจำนวนมาก ทำให้เกิดความยากลำบากในการเข้าถึงข้อมูล เนื่องจากต้องเสียเวลา กับการไล่ลำดับการเข้าถึงข้อมูล
2. ข้อมูลถูกสร้างขึ้นด้วยความเร็ว (Velocity) : การที่ข้อมูลมีการไหลเข้ามาในระบบตลอดเวลา จำเป็นจะต้องใช้ประโยชน์จากข้อมูลเหล่านี้ให้ได้มากที่สุดในลักษณะ Real time เพื่อวิเคราะห์ข้อมูลได้ถูกต้องและรวดเร็วมากยิ่งขึ้น
3. ความหลากหลายข้อมูล (Variety) : ข้อมูลมีความหลากหลายจึงยากต่อการนำข้อมูลมาใช้เพื่อประมวลผล อาจเป็นข้อมูลชนิดใดก็ได้ ทั้งมีโครงสร้างและไม่มีโครงสร้าง เช่น ข้อมูล, ข้อมูลจากเซนเซอร์, วิดีโอ, เสียง, ข้อมูลบันทึกของระบบงาน เป็นต้น

### 2.3 Resilient Distributed Datasets (RDDs)

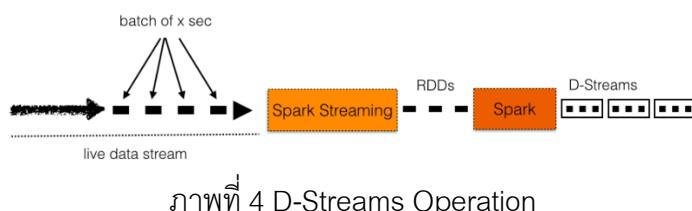
Resilient Distributed Datasets หรือ RDDs [16] เป็นสิ่งที่ช่วยให้โปรแกรมเมอร์สามารถเขียนเขียนโปรแกรมแบบขนานเพื่อประมวลผลบนหน่วยความจำ (In memory parallel programming) ของระบบคลัสเตอร์ได้ ซึ่งการสร้าง RDDs นั้น ทำได้โดยการนำข้อมูลจากภายนอกมาผ่าน parallel operations ต่างๆ โดยที่ parallel operations นั้นสามารถแบ่งออกได้เป็นสองแบบด้วยกันคือการ transformation ซึ่งเป็น operation ที่ใช้ในการสร้าง dataset และ action ซึ่งใช้ในการสั่งคำสั่งให้ประมวลผลข้อมูลบนคลัสเตอร์

RDDs นั้นเหมาะสมอย่างยิ่งกับการนำไปใช้ใน batch application ที่ทุกๆ datasets จะถูกกระทำโดยใช้คำสั่งเดียวกันในการประมวลผล และเนื่องจากการ transformation นั้นเป็นการแบ่งข้อมูลออกเป็นชิ้นเล็กๆ แล้วนำมาจัดกลุ่มเพื่อกระจายออกไปตามเครื่องต่างๆ ในคลัสเตอร์ โดยข้อมูลเหล่านี้จะถูกจัดเก็บไว้บนหน่วยความจำ ดังนั้นยิ่งหน่วยความจำมีขนาดของใหญ่เท่าไหร่ประสิทธิภาพในการประมวลผลก็จะยิ่งสูงมากเท่านั้น นอกจากนั้นการที่ RDDs ใช้การ transformation data ในการสร้าง datasets ทำให้ RDDs มีความสามารถในการ recovery partition ที่หายไปโดยไม่จำเป็นที่จะต้องเก็บข้อมูลทั้งหมด (fault-tolerant) โดยข้อมูลที่ได้รับความเสียหายนั้นจะถูกสร้างขึ้นมาใหม่จากการ transformation แทน



### 2.4 Discretized Streams (D-Stream)

Discretized Streams หรือ D-Stream [17] เป็น stream programming model ที่ใช้สำหรับระบบการกระจายขนาดใหญ่ ซึ่งมีความต้องกันของข้อมูล (Consistency) และมีความสามารถในการทำ fault recovery และยังสามารถทำงานรวมกับระบบ batch ได้อย่างลงตัว โดยมุ่งเน้นการจัดการกับข้อมูลที่เข้ามาในระบบ (Streaming Computation) ในรูปแบบชุดของ batch jobs ขนาดเล็ก (Batch Computation) และลดเวลาในการประมวลผลกับงานเหล่านี้ให้มากที่สุดเท่าที่จะมากได้ ซึ่งการทำแบบนี้จะส่งผลให้การทำ batch processing สามารถทำ stream processing ได้



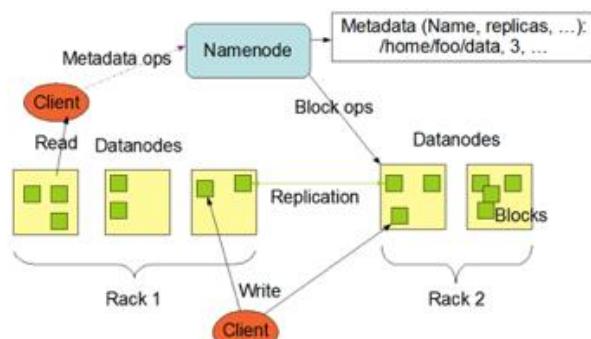
## 2.5 Apache Hadoop [18, 19]

Hadoop Distributed File System (HDFS) นั้นคือ ระบบการจัดเก็บข้อมูลแบบกระจายที่ออกแบบมาเพื่อทำงานบนระบบ commodity hardware ซึ่งคล้ายคลึงกับระบบการจัดเก็บข้อมูลแบบกระจายอื่นๆ แต่มีความแตกต่างตรงที่ HDFS นั้นสามารถทนต่อการสูญเสียสูง (Highly fault-tolerant) และออกแบบมาเพื่อรองรับการทำงานของอุปกรณ์ที่มีราคาไม่สูง (low-cost hardware) ซึ่งหมายความว่า HDFS นั้นมีความสามารถในการเข้าถึงหน่วยความจำขนาดใหญ่และสามารถเพิ่มจำนวนหน่วยได้ถึงหนึ่งหมื่นหน่วย, หนึ่งร้อยล้านไฟล์ และขนาดใหญ่ได้มากถึง 10 petabyte

โดยปกติแล้ว HDFS เป็นการจัดเก็บข้อมูลแบบ write-once-read-many access model โดยที่ไฟล์จะถูกเขียนเพียงครั้งเดียวและไม่สามารถแก้ไขได้ทำให้เหมาะสมกับการเก็บข้อมูลประเภทบันทึกของระบบงาน ซึ่งจะทำให้ความล้มเหลวต่างๆ ของข้อมูลมีความง่ายมากขึ้น และสามารถเข้าถึงข้อมูลได้แบบ high throughput นอกจากนั้นยังมีการย้ายการประมวลผลให้ไปอยู่ใกล้กับที่เก็บข้อมูล จะทำให้ช่วยลดความคับคั่งของเครือข่าย (Traffic Network) และยังช่วยเพิ่ม throughput ให้กับระบบอีกด้วย

### 2.5.1 สถาปัตยกรรมของ HDFS

HDFS นั้นจะมีการทำงานแบบ master-slave โดยจะมีหนึ่งที่สำคัญอยู่สองชนิดคือ NameNode และ DataNode



ภาพที่ 5 สถาปัตยกรรมของ HDFS

NameNode ทำหน้าที่เป็น Master server ที่ดูแลการจัดการกับ file system เช่น การเปิด-ปิดไฟล์, เปลี่ยนชื่อสาระบบ (Directories) นอกจากนั้นยังเป็นตัวที่จัดการกับการแบ่งข้อมูลไปเก็บเอาไว้ใน DataNode ต่างๆ ซึ่งจะถูกแสดงอยู่บน NameNode ในรูปของ inode ที่เก็บข้อมูลเกี่ยวกับ permissions, การแก้ไขต่างๆ, เวลาในการเข้าถึง namespace และ disk space quotas

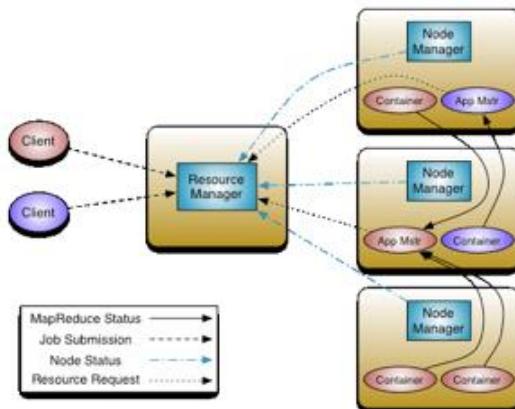
โดยไฟล์จะถูกแบ่งออกเป็น blocks ซึ่งจะถูกทำ replicate ไปจัดเก็บไว้บน DataNode ต่างๆ โดย NameNode จะเก็บ namespace ทั้งหมดเอาไว้ใน RAM ซึ่งในแต่ละไฟล์จะมี inode data และรายชื่อของ blocks และจะเก็บ metadata ทั้งหมดเอาไว้ใน Namespace image โดยจะถูกจัดเก็บเอาไว้ใน localhost ของ file system ที่เรียกว่า checkpoint นอกจากนั้น NameNode ยังมีการเก็บ Journal ซึ่งเป็นบันทึกของระบบงานที่จะเก็บการเปลี่ยนแปลงต่างๆ ภายในระบบเอาไว้ใน localhost file system และมีการทำ redundant copies ของ journal และ check point ที่ server อื่นๆ เอาไว้ด้วยเพื่อเพิ่มความทนทานของระบบ (Fault Tolerance)

DataNode จะมีในอยู่ในทุกๆ หนึ่ง ภายใน cluster ซึ่งจะอยู่ภายใต้การเกี่ยวข้องกับข้อมูล เช่น การสร้าง, การลบ block และการทำ replication ซึ่งรับคำสั่งมาจาก NameNode อีกทีหนึ่ง โดยแต่ละ block replica บน DataNode จะประกอบไปด้วยไฟล์สองไฟล์ โดยไฟล์แรกจะเป็นข้อมูล และไฟล์ที่สอง คือ block ของ metadata ซึ่งรวมถึง checksum ของ block data และ block's generation stamp โดยขนาดของไฟล์ข้อมูล จะเท่ากับความกว้างของ block จริงๆ และไม่มีการร้องขอพื้นที่พิเศษเพื่อใช้ในการปั๊ดให้ครบตามขนาดเหมือน file system แบบตั้งเดิม โดยในระหว่าง startup แต่ละ DataNode จะเชื่อมต่อไปยัง NameNode และทำการ handshake เพื่อยืนยัน namespace ID และ software version ของ DataNode หากไม่ตรงกับ NameNode ก็จะทำการ shutdown อัตโนมัติเพื่อไม่ให้ข้อมูลเกิดความเสียหายหรือสูญหาย หลังจากนั้นจะส่ง block report ไปยัง NameNode ซึ่งจะประกอบด้วย block id, generation stamp และ ความยาวของแต่ละ block replicat โดย block report จะทำการส่งทุกหนึ่งชั่วโมง โดยในระหว่างการทำงานปกติ DataNode จะส่งสัญญาณ heartbeats ไปยัง NameNode เพื่อยืนยันว่า DataNode นั้นยังทำงานอยู่ และ block replicas ภายในยังคงทำงานอยู่ เช่นเดียวกัน ซึ่งข้อมูลที่ถูกส่งไปใน heartbeats นั้นจะประกอบไปด้วย ความจุ, หน่วยความจำที่ถูกใช้งาน และจำนวนของ data transfer ที่กำลังทำงานอยู่ ซึ่งข้อมูลเหล่านี้จะใช้สำหรับการจดจำพื้นที่และการตัดสินใจในการทำ load balancing ของ NameNode โดยที่ปกติจะทำ heartbeat ทุกๆ 3 วินาที ถ้าหาก NameNode ไม่ได้รับ heartbeat จาก DataNode ภายใน 10 นาที NameNode หั้จะทำการเปลี่ยนสถานะของ DataNode นั้นให้กลายเป็น out-of-service และจะสร้าง replicas ที่อยู่ใน DataNode นั้นไปไว้ใน DataNode ใหม่

### 2.5.2 Hadoop Yarn (MapReduce version 2)

Hadoop Yarn เป็นตัวที่พัฒนามาจาก MapReduce ซึ่ง MapReduce คือ framework ที่ช่วยในการสร้าง application สำหรับประมวลผลข้อมูลที่มีขนาดใหญ่ในลักษณะการประมวลผลแบบขนาน (Parallel Programming) บนระบบการกระจายขนาดใหญ่ (large cluster) ที่มีความน่าเชื่อถือ (reliable) และการคงทนต่อความเสียหาย (Fault Tolerance)

โดยการทำงานของ MapReduce นั้นจะแบ่งข้อมูล input ออกเป็น chunks ซึ่ง chunks เหล่านี้จะถูกประมวลผลโดย map task ในรูปแบบของ parallel หลังจากนั้น framework จะนำผลที่ได้จาก map task มาจัดเรียงแล้วนำมาส่งต่อให้กับ reduce task แล้วจึงได้ผลลัพธ์ออกมา (output) โดยที่ทั้ง input และ output นั้นจะถูกจัดเก็บอยู่บน HDFS โดยที่ framework นั้นจะมีการทำการทำ scheduling tasks, monitoring task และจัดการกับ failed tasks โดยการ re-executes task นั้น



ภาพที่ 6 สถาปัตยกรรมของ Hadoop YARN

จากภาพที่ 6 สถาปัตยกรรมของ Hadoop YARN ประกอบด้วย

1. Resource Manager : ประกอบไปด้วย Scheduler กับ Applications Manager โดยที่ Scheduler ทำหน้าที่ในการจัดลำดับการประมวลผลงาน โดยดูจากปริมาณทรัพยากรที่งานนั้นๆ ร้องขอ และ Application Manager เป็นตัวที่รับงานมาจาก client และไปส่งให้ Application Master ทำงาน
2. Node Manager : จะมีอยู่บนทุกๆ โนนดภายใน cluster เป็นตัวที่ค่อยดูปริมาณทรัพยากรที่มีอยู่ของโนนตนั้นๆ และรายงานไปยัง Resource Manager รวมถึงเป็นตัว execute และ monitor งานทั้ง map task และ reduce task

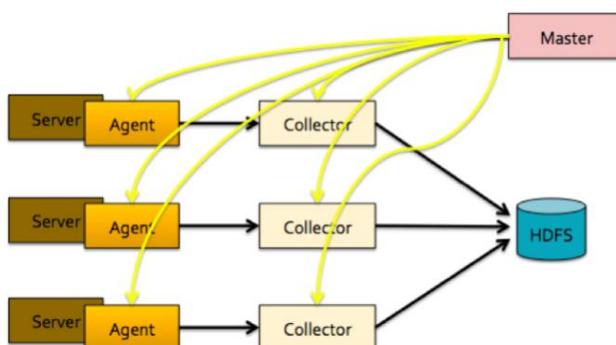
3. Application Master : เป็นตัวที่สร้างและร้องขอทรัพยากรสำหรับการทำงานไปยัง Scheduler บน Resource Manager รวมถึงติดตามและรายงานผลการทำงานไปยัง Resource Manager

## 2.6 Apache Flume [20]

Apache Flume เป็นโครงการของ Apache Software Foundation โดยจะนำเสนองานการผสานการทำงานของ Hadoop และข้อมูลที่มีลักษณะเป็น Streaming Data สำหรับการเก็บรวบรวมข้อมูลจากต้นทางหลายๆ แหล่งและส่งต่อไปยังศูนย์กลางที่เก็บข้อมูลเช่น Hadoop Distributed File System (HDFS) ด้วยความรวดเร็ว เพื่อที่จะนำข้อมูลเหล่านั้นมาวิเคราะห์ หรือตรวจสอบเพื่อความแม่นยำ เช่น ตรวจสอบพฤติกรรมและความผิดปกติในการทำงานที่เกิดขึ้น โดยที่ Apache Flume นั้นมี特คุณภาพเป็น Distributable, Reliable และ Available service ของการรวบรวมบันทึกของระบบงาน ได้อย่างมีประสิทธิภาพและยังมีความสามารถในการเคลื่อนย้ายบันทึกของระบบงาน ที่มีขนาดใหญ่โดยสามารถใช้ได้ทั้ง Simple และ Flexible architecture ที่เป็นแบบ Streaming dataflow

### 2.6.1 สถาปัตยกรรมของ Apache Flume

สถาปัตยกรรมของ Flume จะมีลักษณะ Stream-oriented data flow โดยจะมีเส้นทางส่งต่อไปยังปลายทาง และประกอบไปด้วย Logical node ที่สามารถส่งต่อหรือรวม event ที่ได้รับมา ซึ่งสามารถตั้งค่าได้ที่ Flume master



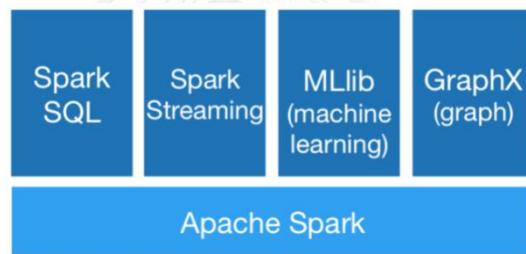
ภาพที่ 7 สถาปัตยกรรมของ Apache Flume

รูปที่ 6 แสดงถึงตัวอย่างการใช้งานของ Flume ในการจัดการกับบันทึกของระบบงาน จาก Server ซึ่งแบ่งออกเป็นสามส่วนคือ Agent, Collector และ Storage โดย Agent จะถูกติดตั้งบน node แต่ละ node ที่มีการสร้างบันทึกของระบบงาน Agent จะทำการส่งบันทึกของระบบงานไปยังส่วนต่อไปคือ Collector ซึ่งเป็นส่วนที่ติดตั้งบนเครื่องที่จะรวบรวมข้อมูลต่างๆ ของแต่ละ

data flow แล้วส่งต่อไปยัง storage ซึ่งเป็นส่วนสุดท้าย เช่น Agent อาจจะเก็บข้อมูล sysLog และส่งข้อมูลต่อไปยัง Collector จากนั้น collector ก็จะรวบรวมข้อมูลจากทุกๆ agent และทำการ stream ข้อมูลต่อไปยังที่เก็บข้อมูล เช่น HDFS

## 2.7 Apache Spark [19, 21]

Apache Spark เป็น framework สำหรับการทำ large-scale data processing โดยหมายของ spark นั้นคือการเพิ่มความเร็วในการทำงานของ batch processing, การทำงานแบบ iterative ใน machine learning, การทำ interactive query และการทำ graph processing โดยที่ spark สามารถประมวลผลได้เร็วว่า hadoop mapreduce ถึง 100 เท่า และสามารถพัฒนาได้ง่ายโดยใช้ภาษา Java, Scala หรือว่า Python จุดเด่นของ Spark อยู่ที่ Resilient Distributed Datasets หรือ RDDs ซึ่งช่วยให้ Spark นั้นมีความทนต่อความเสียหาย (Fault Tolerance) นอกจากนี้ Spark ยังมี high-level APIs อย่างเช่น Java, Scala และ Python อีกทั้งยังมีเครื่องมือมาให้อย่างในรูปที่ 8



ภาพที่ 8 Spark Framework

SparkSQL: ใช้สำหรับทำ SQL และ data processing

Spark Streaming: ใช้ในการทำ streaming data

MLlib: เป็น library ที่ใช้ในการทำ machine learning

GraphX: ใช้สำหรับทำ graph processing

## 2.8 การแก้ปัญหาไฟล์ขนาดเล็กบน Hadoop

โดยปกติขนาดของ block ใน HDFS นั้นจะมีขนาด 128MB (สามารถปรับเปลี่ยนได้) แต่ระบบที่ทางผู้วิจัยได้พัฒนาขึ้นนั้นจำเป็นที่จะต้องรองรับมีกับข้อมูลที่มีขนาดต่ำกว่า 128MB ซึ่งเป็นข้อมูลที่มีขนาดเล็ก โดยถ้าหากเราจัดเก็บไฟล์ขนาดเล็กเหล่านี้เอาไว้บน HDFS จะทำให้การทำงานภายใต้ HDFS ไม่มีประสิทธิภาพ เนื่องจาก metadata นั้นจะถูกจัดเก็บเอาไว้บน physical memory ของ NameNode ดังนั้นยิ่งมีไฟล์ขนาดเล็กมากเท่าใด เรา ก็จะเสียพื้นที่ในการจัดเก็บบน NameNode มากเท่านั้น ถ้าหากเก็บไฟล์ขนาดเล็กมากเกินไป ก็จะส่งผลให้ไม่เหลือ

พื้นที่บน NameNode เลย ปัญหาไฟล์ขนาดเล็กนั้นไม่ได้เกิดขึ้นเฉพาะกับ HDFS เท่านั้น Zhang, Xiaoxue [22] ได้อธิบายวิธีในการแก้ไขปัญหาการไฟล์ขนาดเล็กบนระบบการเก็บข้อมูลแบบกระจาย (Distributed File System) โดยสามารถทำได้ 4 รูปแบบด้วยกันคือ การจัดการกับ metadata ส่งผลให้ขนาดของ metadata ลดลง, การทำ performance optimization เป็นการนำเทคนิคในการทำ cashing เข้ามาช่วยเพื่อเพิ่มประสิทธิภาพในการเข้าถึงไฟล์, การนำไฟล์ขนาดเล็กมารวมกันให้กลายเป็นไฟล์ขนาดใหญ่ ทำให้ช่วยลด metadata ให้น้อยลง และการเก็บไฟล์ขนาดเล็กบนพื้นที่ที่แยกจากระบบกระจาย ดังในตารางที่ 1

method	illustration	advantage	disadvantage
Metadata Management	Metadata compression reduces metadata size	Improve space utilization	the metadata read performance was hurt due to extra steps of lookup file .
Performance Optimization	Utilizing prefetching and caching technologies to improve access efficiency e.g. Hot Files Caching, Metadata Caching	The improvement of the Cache hit ratio	Just for particular application
Small file merging	A set of correlated files is combined into a single large file to reduce the file count. An indexing mechanism has been built to access the individual files from the corresponding combined file.	Reduce the metadata	Two indexes, affect the speed
sequence files	Form by a series of binary, where key is the name of the file, the value of the file content.	Free access for small files, nor restrict how much users and files	Platform dependent
Way to store	Small files stored separately in separate areas	Reduce disk fragmentation	Complexity of the movement

ตารางที่ 1 ตารางแสดงการแก้ไขปัญหาการไฟล์ขนาดเล็กบนระบบการเก็บข้อมูลแบบกระจาย

ทาง Apache Hadoop เองก็ได้เสนอ Hadoop Archive (HAR) ซึ่งเป็นวิธีการจัดการกับไฟล์ขนาดเล็กโดยการรวมไฟล์ขนาดเล็กให้กลายเป็นไฟล์ขนาดใหญ่ และยังสามารถเข้าถึงไฟล์แบบ parallel transparently ได้อย่างมีประสิทธิภาพ แต่ถึงแม้ว่าการใช้งาน HAR นั้นจะสามารถลดขนาดของ metadata ลงได้ก็ตาม แต่การใช้งาน HAR นั้นก็ทำให้เพิ่ม overhead ที่ไม่จำเป็น จึงทำให้ประสิทธิภาพในการเข้าถึงข้ากับว่าการเข้าถึงไฟล์ใน HDFS ปกติ นอกจากนั้น Apache Hadoop ยังมีวิธีการแก้ปัญหาอีกวิธีหนึ่งคือ การเพิ่ม NameNode ในระบบเพื่อเพิ่มความสามารถในการรองรับ load ของระบบ โดยที่ HDFS Federation นั้นจะเพิ่มจำนวนของ NameNode โดยที่ NameNode แต่ละตัวนั้น จะทำงานเป็นอิสระจากกันโดยแต่ละ DataNode จะต้องทำการ register กับ NameNode ทั้งหมดใน cluster และต้องส่ง heartbeat และ block report ให้กับ NameNode ทุกตัวรวมถึงคolleyรับคำสั่งจาก NameNode แต่ปัญหาคือต้องทำการแก้ไขระบบภายในให้รองรับการทำงานที่มี master หลายตัว อีกทั้งยังสิ้นเปลืองทรัพยากรเนื่องจากต้องเพิ่มจำนวนเครื่องในระบบ

## 2.9 แบบจำลองอนุกรมเวลาชา里的มา (SARIMA)

แบบจำลองอนุกรมเวลาชา里的มา (SARIMA) หรือ Seasonal Autoregressive Integrate Moving Average เป็นแบบจำลองที่เพิ่มส่วนของ Seasonal Part เข้าไปในในแบบจำลองอนุกรมเวลาชา里的มา (ARIMA) โดยสามารถเขียนได้ในรูป  $ARIMA(p, d, q) \times (P, D, Q)_s$  ซึ่ง

$p, d, q, P, D, Q$ , และ  $S$  หมายถึง อันดับของ Autoregressive, Differencing, Moving average, Seasonal autoregressive, Seasonal differencing, Seasonal moving average , และ Seasonal period ตามลำดับ สมการของ  $ARIMA(p, d, q) \times (P, D, Q)_S$  คือ

$$\phi_p(B)\Phi_p(B^s)\nabla^d\nabla_s^D x_t = \theta_q(B)\Theta_Q(B^s)e_t \quad (1)$$

จากสมการที่ 1 ตัวแปรต่างๆ ของสมการมีดังนี้

- $B$  เป็นตัวดำเนินการ Backward-shift ซึ่ง
  - $BX_t = X_{t-1}$
  - $B^sX_t = X_{t-s}$
- $\nabla = 1 - B$  เป็นตัวดำเนินการ Differencing ซึ่ง
  - $\nabla^d = (1 - B^d)$
  - $\nabla_s^D = (1 - B^s)^D$
- ตัวดำเนินการ autoregressive
  - $\phi_p(B) = 1 - \phi_1B - \phi_2B^2 - \dots - \phi_pB^p, p \geq 0$
- ตัวดำเนินการ moving average
  - $\theta_q(B) = 1 - \theta_1B - \theta_2B^2 - \dots - \theta_qB^q, q \geq 0$
- ตัวดำเนินการ seasonal autoregressive
  - $\Phi_P(B) = 1 - \Phi_1B^{1s} - \Phi_2B^{2s} - \dots - \Phi_P B^{Ps}, P \geq 0$
- ตัวดำเนินการ seasonal moving average
  - $\Theta_Q(B) = 1 - \Theta_1B^{1s} - \Theta_2B^{2s} - \dots - \Theta_Q B^{Qs}, Q \geq 0$

## 2.10 Akaike information criterion (AIC)

AIC คือค่าการวัดความเหมาะสมของแบบจำลองทางสถิติที่ถูกประมาณโดยใช้แนวคิดของ เอนโทรปีเพื่อวัดการสูญเสียของข้อมูลเมื่อใช้แบบจำลองนั้นโดยแบบจำลองที่มีค่า AIC น้อยที่สุด คือแบบจำลองที่ดีที่สุด

## 2.11 Bayesian information criterion (BIC)

BIC คือค่าบรรทัดฐานในการเลือกแบบจำลองภายในกลุ่มของแบบจำลองที่มีการปรับค่าตัวแปรต่างๆ โดยค่า BIC นั้นมีความเกี่ยวข้องกับค่า AIC มาก แต่ว่าค่า BIC นั้นจะมีการให้โทษสำหรับตัวแปรเพิ่มขึ้นมากกว่า

## 2.12 Maximum likelihood estimation (MLE)

MLE คือวิธีการทางสถิติที่นิยมใช้งานการปรับแบบจำลองทางสถิติให้เหมาะสมกับข้อมูลนั้นๆ รวมถึงหาค่าประมาณของตัวแปรต่างๆ ในแบบจำลองทางสถิติ โดย MLE จะเลือกค่าตัวแปรที่ทำให้ฟังก์ชันภาวะน่าจะเป็น (Likelihood function) มีค่ามากที่สุด

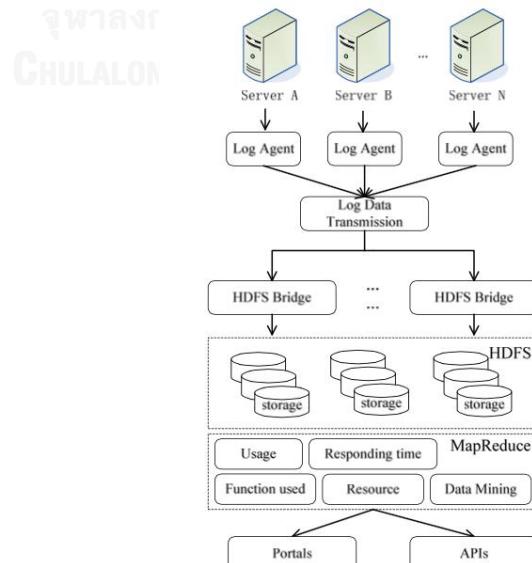
## 2.13 งานวิจัยที่เกี่ยวข้อง

### 2.13.1 โครงสร้างระบบประมวลผลบันทึกของระบบงาน

ในบันทึกของระบบงาน จะประกอบด้วยข้อมูลที่มีประโยชน์ซ่อนอยู่ โดยระบบการประมวลผลบันทึกของระบบงาน นั้นเป็นเครื่องมือที่ใช้ในการดึงเอาข้อมูลที่เป็นประโยชน์เหล่านั้นออกมายield อย่างเช่น การตรวจหาปัญหาภายในระบบ, การตรวจสอบพฤติกรรมการใช้งานของผู้ใช้, และ การตรวจสอบสถานะของระบบ เป็นต้น [3, 5, 6] เป็นตัวอย่างวิธีการที่ใช้ในการประมวลผลบันทึกของระบบงาน โดยนำเทคนิคต่างๆ เข้ามาช่วย แต่ระบบประมวลผลบันทึกของระบบงานแบบที่เคยมีมาบันทึกส่วนใหญ่จะเป็นระบบการประมวลผลแบบ Batch ซึ่งไม่เหมาะสมที่จะนำมาใช้จัดการกับบันทึกของระบบงาน ในปัจจุบัน เพราะบันทึกของระบบงาน ในปัจจุบันนั้นถูกสร้างขึ้นด้วยอัตราเร็วและมีปริมาณของข้อมูลมาก (Fast Data) ดังนั้นทางผู้วิจัยจึงนำระบบการประมวลผลแบบ Real-Time เข้ามาใช้ แต่ก็ไม่สามารถเลิกใช้ระบบการประมวลผลแบบ Batch ได้เนื่องจากในงานบางงานก็ยังจำเป็นที่จะต้องใช้ระบบการประมวลผลแบบ Batch ออยู่ เช่นการทำ checksum ของข้อมูล หรือ การทำสรุปยอดการเงินของธนาคารเป็นต้น ดังนั้นการที่เราจะประมวลผลบันทึกของระบบงาน ได้อย่างมีประสิทธิภาพนั้นเราจำเป็นอย่างยิ่งที่จะต้องมีระบบประมวลผลที่สามารถประมวลผลได้ทั้งแบบ Batch และแบบ Real-Time

### 2.13.1.1 โครงสร้างการประมวลผลบันทึกของระบบงานแบบ Batch

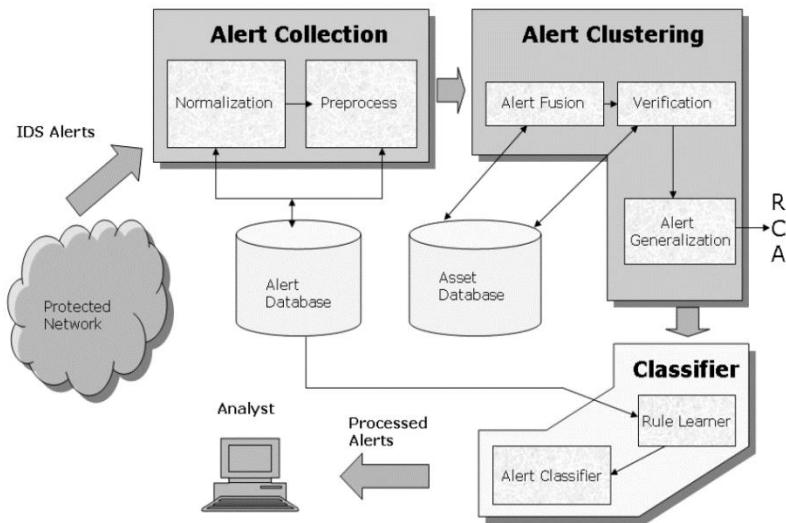
การประมวลผลแบบ Batch เป็นวิธีที่ใช้ในการประมวลผลข้อมูลที่มีปริมาณมากและสะสมมาเป็นระยะเวลานึง โดย Yu, Hongyong และ Deshuai Wang [8] ได้นำเสนอโครงสร้างการประมวลผลบันทึกของระบบงานโดยใช้เทคโนโลยี Hadoop เข้ามาประมวลผลเพื่อจัดการกับบันทึกของระบบงานขนาดใหญ่โดยมีสถาปัตยกรรมดังรูปที่ 8.1 เนื่องจากบันทึกของระบบงานจะถูกเก็บไว้ใน HDFS ทำให้ระบบสามารถที่จะขยายขนาดเพื่อที่จะรองรับข้อมูลที่อาจจะขยายขึ้นได้ในอนาคต Lee, Yeonhee et al [7] และ Therdphapiyanak, Jakarin et al [9] ได้นำเทคโนโลยี Hadoop เพื่อมาประมวลผลบันทึกของระบบงานโดยนำเทคนิค intrusion detection มาใช้ในการประมวลผลข้อมูลที่มีปริมาณมาก จากการวิจัยของ Cheon, JeongJin และ Choe, Tae-Young [10] เทคโนโลยี Hadoop สามารถเพิ่มประสิทธิภาพในการประมวลผล message Log ได้ถึง 426% เมื่อเทียบกับ single computer แต่จะเห็นได้ว่าการประมวลผลที่กล่าวมาข้างต้นนั้นใช้เทคโนโลยี Hadoop ซึ่งเป็นการประมวลผลแบบ Batch สามารถรองรับการประมวลผลข้อมูลที่มีปริมาณมาก แต่ก็ต้องใช้เวลาในการประมวลผลพอสมควร



ภาพที่ 9 โครงสร้างการประมวลผลบันทึกของระบบงานโดยใช้ Hadoop

### 2.13.1.2 โครงสร้างการประมวลผลบันทึกของระบบงาน แบบ Real-Time

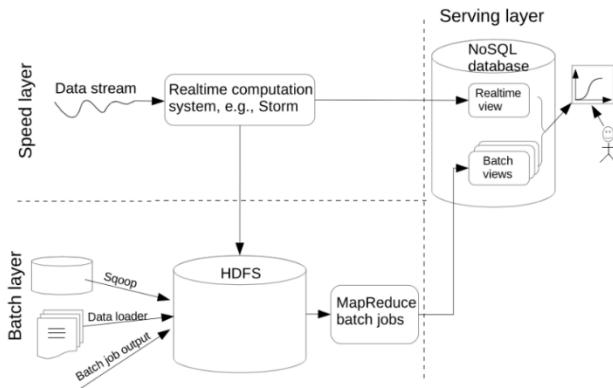
การประมวลผลบันทึกของระบบงาน แบบ Real-Time นั้นเป็นการประมวลผลที่เน้นที่ latency ของระบบ เพื่อที่จะประมวลผลข้อมูลที่มีความเร็วสูง ให้ได้ผลลัพธ์แล้วสามารถนำไปใช้ได้ทันที เช่น การ Monitoring การใช้งาน network ในระบบเพื่อนำมาปรับ Bandwidth ให้เหมาะสมกับการใช้งาน เป็นต้น การประมวลผลแบบ Real-Time นั้นจะประมวลผลข้อมูลที่เข้ามา ให้ได้ผลลัพธ์ออกมาด้วยอัตราเร็วที่เท่ากับอัตราเร็วที่ข้อมูลไหลเข้า ระบบ Subbulakshmi, T, et al. [12] ได้นำเสนอสถาปัตยกรรมระบบการแจ้งเตือนแบบ Real-Time ดังรูปที่ 8.2 โดยแบ่งการแจ้งเตือนออกเป็น 2 ระยะ แต่ใช้ได้กับบันทึกของระบบงาน ของ Intrusion Detection Systems (IDS) เท่านั้น Mohari, Bhupendra, et al. [13] ได้นำเสนอระบบการจัดการและวิเคราะห์บันทึกของระบบงาน แบบ real-time โดยการนำเอา platform ต่างๆ เข้ามาร่วมกัน โดยเน้นการประมวลผลให้ได้ผลลัพธ์ออกมาแล้วนำไปเก็บลงบนฐานข้อมูล (process-store) ซึ่งโดยปกติแล้วการประมวลผลบันทึกของระบบงาน นั้นจะมีขั้นตอนอยู่ด้วยกันสามขั้นตอนคือ เก็บข้อมูลลงฐานข้อมูลก่อนแล้วนำไปประมวลผล เมื่อได้ผลลัพธ์แล้วก็จะนำมาเก็บไว้ในฐานข้อมูลอีก (store-process-store) ทำให้การประมวลผลในรูปแบบนี้สามารถช่วยลดเวลาในการประมวลผลลงได้ แต่ว่าเนื่องจากงานวิจัยนี้ จำเป็นที่จะต้องเก็บบันทึกบันทึกของระบบงาน ย้อนหลังไว้เพื่อนำมาประมวลในภายภาคหน้าจึงไม่สามารถตัดขั้นตอนในการจัดเก็บบันทึกของระบบงาน ในขั้นแรกได้



ภาพที่ 10 โครงสร้างการประมวลผลบันทึกของระบบงานแบบ Real-Time

### 2.13.2 สถาปัตยกรรมแบบ Three-layered lambda

จากการที่ผ่านๆ ระบบการประมวลผลแบบ Batch ใช้ในการจัดการกับข้อมูลที่มีขนาดใหญ่ แต่ในปัจจุบันนั้นข้อมูลถูกสร้างขึ้นด้วยอัตราที่เร็วมาก (Fast Data) และทางผู้วิจัยมีความต้องการที่จะประมวลผลข้อมูลเหล่านั้น ทำให้การประมวลผลแบบ Batch นั้นไม่เพียงพอที่จะใช้ในการประมวลผล จึงต้องนำการประมวลผลแบบ Real-Time เข้ามาช่วยในการประมวลผล จากงานวิจัย Survey of Real-time Processing System for Big Data [15] ได้เสนอวิธีในการแก้ปัญหาโดยได้เสนอสถาปัตยกรรมแบบ Three-layered lambda ขึ้น จากรูปที่ 9 สถาปัตยกรรมแบบ Three-layered lambda จะประกอบไปด้วย Batch layer เป็นส่วนที่ใช้ในการประมวลผลข้อมูลที่ถูกจัดเก็บมา โดยที่ผลลัพธ์ของ Batch layer นั้นจะเป็นผลลัพธ์ที่ล่าช้า แต่จะมี Speed layer มาจัดการกับปัญหาโดย Speed layer จะประมวลผลข้อมูลที่วิ่งเข้ามาในระบบ Real-Time 속도 레이어와 함께 Serving layer ซึ่งเป็นส่วนที่ใช้เก็บผลลัพธ์จากทั้ง Speed layer และ Batch layer เพื่อให้ผู้ใช้นำข้อมูลไปใช้ได้



ภาพที่ 11 Three-layered lambda architecture

### 2.13.3 Anomaly detection base on SARIMA

จากการวิจัยที่ผ่านมานั้น ได้มีการนำเอาแบบจำลองอนุกรมเวลาชาร์มา (SARIMA) มาพยากรณ์ และใช้ผลจากการพยากรณ์มาตรวจสอบและจำแนกข้อมูลที่มีลักษณะเปลี่ยนแปลง หรือแปลงແgaไปจากข้อมูลปกติ เพื่อตรวจสอบหาความผิดปกติต่างๆ เช่นใน [23] ได้นำ SARIMA มาพยากรณ์การตรวจวิน WLAN นอกจากร้านนั้นใน [24] ยังมีการนำ SARIMA มาใช้พยากรณ์ปริมาณงานที่ใช้ในการทำงาน

ในงานวิจัยของ Aphichit และ Krerk [25] ได้นำเสนอการตรวจจับความผิดปกติของการใช้งานเครือข่ายโดยใช้แบบจำลองอนุกรมเวลาชาร์มา (SARIMA) โดยการพยากรณ์ปริมาณการใช้งานเครือข่ายที่จะเกิดขึ้นในอนาคต จากปริมาณการใช้งานเครือข่ายในอดีต แล้วเปรียบเทียบปริมาณการใช้งานเครือข่ายที่พยากรณ์ไว้กับปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจริง ว่ามีความแตกต่างมากกว่าค่า Threshold หรือไม่ ถ้าเกินจะถือว่ามีความผิดปกติเกิดขึ้น ชิ่งงานวิจัยนี้สามารถตรวจจับความผิดปกติที่เกิดขึ้นได้จริง แต่ว่าก็ยังมีข้อจำกัดอยู่สองด้าน ด้วยกันคือ ไม่สามารถใช้ตรวจจับปริมาณการใช้งานที่น้อยผิดปกติ และความผิดปกติที่เกิดขึ้นต่อเนื่องเป็นเวลานานได้

## บทที่ 3

### แนวคิดและวิธีดำเนินงานวิจัย

#### 3.1 ปัญหาการประมวลผลบันทึกของระบบงาน

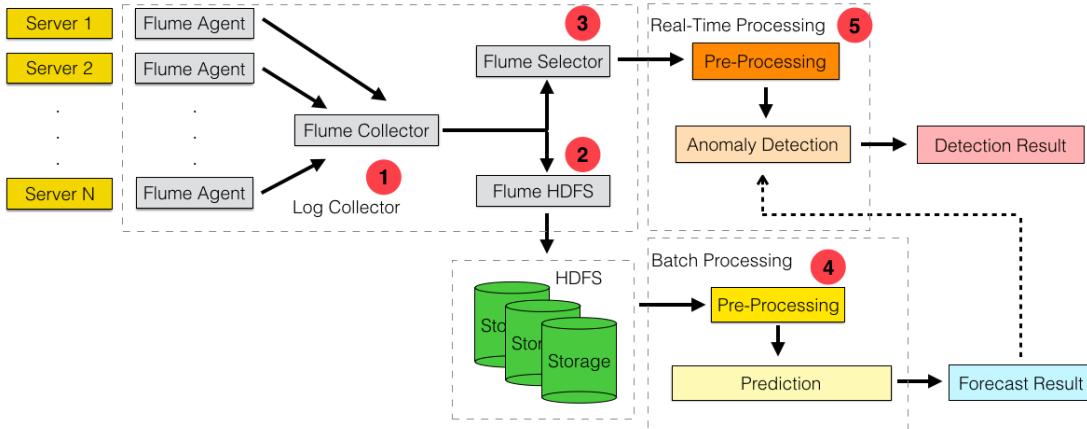
งานวิจัยนี้จะทำการศึกษาองค์ประกอบที่ส่งผลต่อประสิทธิภาพการทำงานของระบบงานแบบ Real-Time เพื่อมาตอบสนองความต้องการของสำนักเทคโนโลยีสารสนเทศ โดยจะออกแบบสถาปัตยกรรมที่รองรับการทำงานทั้งในด้านการจัดเก็บบันทึกของระบบงาน และมีความสามารถในการประมวลผลข้อมูลทั้งในรูปแบบ Real-Time และแบบ Batch โดยข้อมูลที่จัดเก็บนั้นต้องสามารถเรียกคืนมาได้ภายในหลัง 90 วัน

เนื่องจากในงานบางประเภทของสำนักเทคโนโลยีสารสนเทศจำเป็นที่จะต้องประมวลผลข้อมูลภายในระยะเวลาที่จำกัด เช่น การตรวจจับผู้ที่อาจจะใช้ระบบหรือเครื่องข่ายของสำนักเทคโนโลยีสารสนเทศไปเข้าเว็บไซต์ที่ไม่พึงประสงค์ โดยการนำบันทึกของระบบงานที่บันทึกเวลาการใช้งานของผู้ใช้ที่อยู่ในระบบ และบันทึกของระบบงานที่บันทึกการเข้าออกของเว็บไซต์ มาใช้เพื่อรับ user ของผู้ที่กระทำผิด นอกเหนือนั้นยังมีงานอีกประเภทหนึ่งที่จะต้องนำข้อมูลซึ่งเก็บไว้มาประมวลผลในภายหลังเช่น การทำรายงานเพื่อวิเคราะห์พฤติกรรมการใช้งานอินเทอร์เน็ตของแต่ละหน่วยงานเพื่อที่จะนำไปควบคุมปริมาณการจ่าย bandwidth ของแต่ละหน่วยงานให้เหมาะสม เป็นต้น แต่ข้อมูลบันทึกของระบบงานของสำนักเทคโนโลยีสารสนเทศนั้นเป็นข้อมูลที่มีปริมาณมาก (Volume), ถูกสร้างขึ้นด้วยความเร็วสูง (Velocity), และมีความรูปแบบที่แตกต่างกัน (Variety) ซึ่งเป็นข้อมูลเชิง Big Data ทำให้ทางผู้จัดทำจะต้องออกแบบระบบการจัดการบันทึกของระบบงานที่มีความคงทน (Reliability) และยังมีความสามารถในการเพิ่มขนาดของฐานข้อมูล (Scalability) รวมถึง สามารถที่จะประมวลผลได้อย่างรวดเร็วตามความต้องการของผู้ใช้ ดังนั้นทางผู้วิจัยจึงนำเทคโนโลยี HDFS ใน Hadoop มาปรับใช้กับงานวิจัย แต่ทางผู้วิจัยพบว่า HDFS นั้นถูกออกแบบมาเพื่อจัดเก็บไฟล์ข้อมูลที่มีขนาดใหญ่ เช่น 1GB, 1TB, หรือว่า 1PB โดยที่ HDFS นั้นจะนำข้อมูลขนาดใหญ่มาแบ่งเป็น block ขนาดเล็ก ซึ่งโดยปกติขนาดของ block จะอยู่ที่ 128MB (สามารถปรับเปลี่ยนได้) แต่ระบบที่ทางผู้วิจัยได้พัฒนาขึ้นนั้นจำเป็นที่จะต้องรับมือกับข้อมูลที่มีขนาดต่ำกว่า 128MB ซึ่งการที่จะใช้ HDFS ให้เกิดประสิทธิภาพนั้นเราอาจจะต้องรอให้ข้อมูลถูกเขียนเต็มขนาดของ block เสียก่อนจึงจะสามารถประมวลผลได้ ซึ่งการที่เราจะนำข้อมูลเหล่านี้ออกมานั้น จะต้องเสียเวลาในการรอค่อนข้างนาน

### 3.2 หลักการทำงานของสถาปัตยกรรมแบบผสมสำหรับการประมวลผลบันทึกของระบบงานขนาดใหญ่

จากปัญหาที่กล่าวไปแล้วในขั้นตอนนั้น ทางผู้วิจัยจึงได้นำสถาปัตยกรรมแบบ Three-layered lambda มาเป็นพื้นฐานในการแก้ปัญหา โดยแนวคิดในการแก้ปัญหานี้จะแบ่งออกเป็น 2 ส่วนด้วยกันคือ

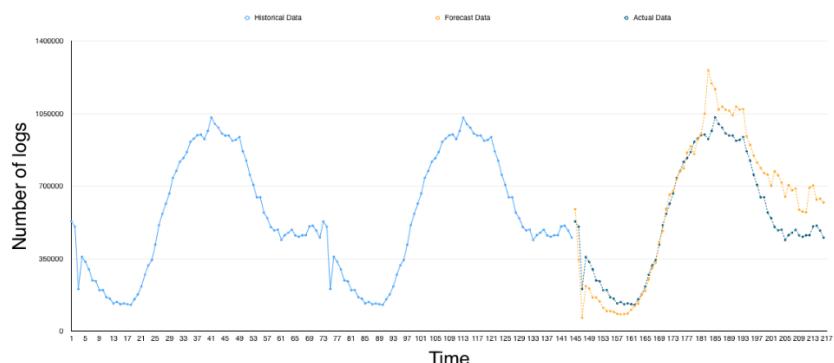
1. สร้างสถาปัตยกรรมที่สามารถประมวลผลบันทึกของระบบงานทั้งในรูปแบบ Batch และ Real-Time รวมถึงรองรับการจัดเก็บข้อมูลที่มีปริมาณมาก และมีแนวโน้มที่จะเพิ่มสูงขึ้น โดยใช้เทคโนโลยี Spark และ Spark Streaming ที่มีใน Spark มาใช้ ในการประมวลผลร่วมกับ HDFS ใน Hadoop
2. ทดลองใช้สถาปัตยกรรมที่ออกแบบ โดยใช้เทคนิคการวิเคราะห์อนุกรมเชิงเวลา (Time series analysis) แบบ SARIMA ในการพยากรณ์ปริมาณการใช้งาน Network และตรวจจับความผิดปกติของปริมาณบันทึกของระบบงานแบบ Real-Time โดยสถาปัตยกรรมที่เราออกแบบนั้น สามารถแบ่งออกเป็น 4 ส่วนหลักๆ ดังภาพที่ 12 คือ
  1. ส่วนที่ใช้ในการส่งและรวบรวมบันทึกของระบบงาน
  2. ส่วนที่ใช้ในการเก็บข้อมูล HDFS ใช้ในการเก็บบันทึกของระบบงานที่มาจากการที่ต่างๆ เพื่อใช้เป็น historical data
  3. ส่วนที่ใช้ในการเลือกบันทึกของระบบงานที่เราสนใจ หรือบันทึกของระบบงานที่เป็นประเภทเดียวกัน เนื่องจากระบบที่เราออกแบบจะต้องรองรับบันทึกของระบบงานที่มาจากหลายๆ แหล่ง
  4. ส่วนที่ใช้ในการประมวลผลแบบ Batch ใช้ในการประมวลผลเพื่อหาแบบจำลองที่เหมาะสมที่จะนำมาใช้ในการพยากรณ์ โดยใช้ SARIMA Time Series Analysis แล้วนำแบบจำลองที่ได้มาใช้เป็นข้อมูลในการพยากรณ์
  5. ส่วนที่ใช้ในการประมวลผลแบบ Real-Time ใช้ในการประมวลผล log ที่เข้ามาใหม่จากระบบอย่างต่อเนื่อง โดยมีการทำ pre-processing แล้วนำข้อมูลที่ได้มาเปรียบเทียบกับแบบจำลองที่เราทำขึ้นจากการประมวลผลแบบ Batch เพื่อตรวจจับและแจ้งเตือนเมื่อมีการใช้งานระบบเครือข่ายมากกว่าหรือน้อยกว่าปกติ



ภาพที่ 12 สถาปัตยกรรมแบบผสมสำหรับการประมวลผลบันทึกของระบบงานขนาดใหญ่

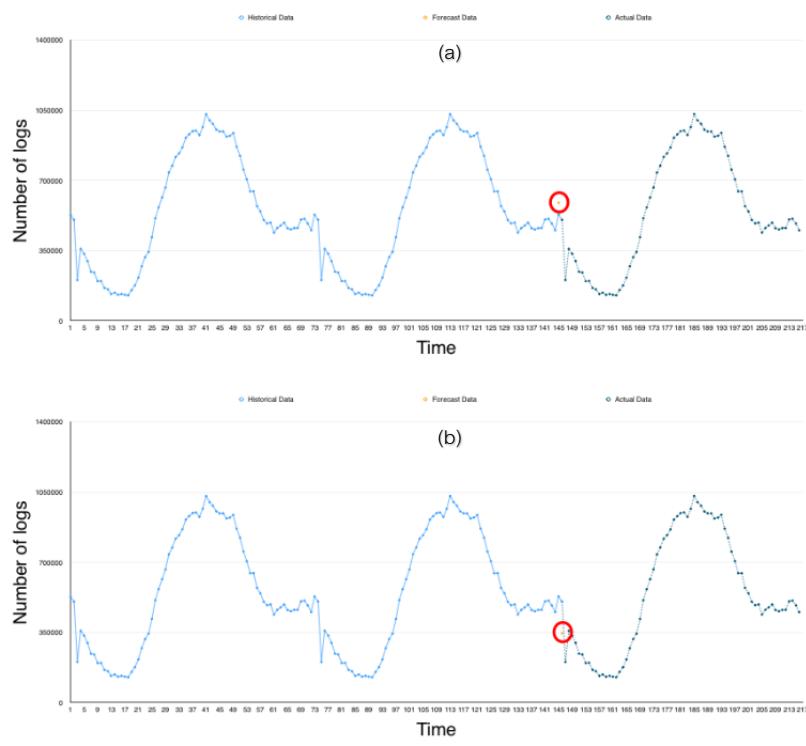
จากภาพที่ 12 ข้อมูลบันทึกของระบบงานจะถูกส่งเข้ามาในระบบโดยใช้ Apache Flume แล้วแยกออกเป็นสองทางโดยบันทึกของระบบงานทุกๆ ข้อมูลที่เข้ามายังจะถูกนำไปเก็บไว้ใน HDFS เป็น historical data และจะถูกนำไปประมวลผลแบบ Batch โดยการนำบันทึกของระบบงานมาหาปริมาณการใช้ระบบอินเทอร์เน็ตที่ผ่านมาและนำมาสร้าง SARIMA Time Series Model ที่เหมาะสม เพื่อนำมาพยากรณ์ถึงพฤติกรรมการใช้งานอินเทอร์เน็ตโดยปกติที่ควรจะเกิดขึ้น ส่วนอีกทางหนึ่งบันทึกของระบบงานจะถูกส่งเข้า Selector เพื่อเลือกเฉพาะบันทึกของระบบงานที่เราสนใจแล้วนำมาฝ่ายการ pre-processing เพื่อหาปริมาณการใช้งานระบบอินเทอร์เน็ตแบบ Real-Time และนำผลลัพธ์ที่ได้มาเปรียบเทียบกับผลการพยากรณ์จาก Time Series Model ที่เราสร้างขึ้นในการประมวลผลแบบ Batch เพื่อที่จะตรวจสอบและแจ้งเตือนเมื่อตรวจพบความผิดปกติแบบ Real-Time เช่นมีปริมาณการใช้งานอินเทอร์เน็ตมากกว่าปกติมากเป็นต้น

### 3.3 หลักการทำงานของการพยากรณ์ปริมาณการใช้งานเครือข่ายโดยใช้บันทึกของระบบงาน

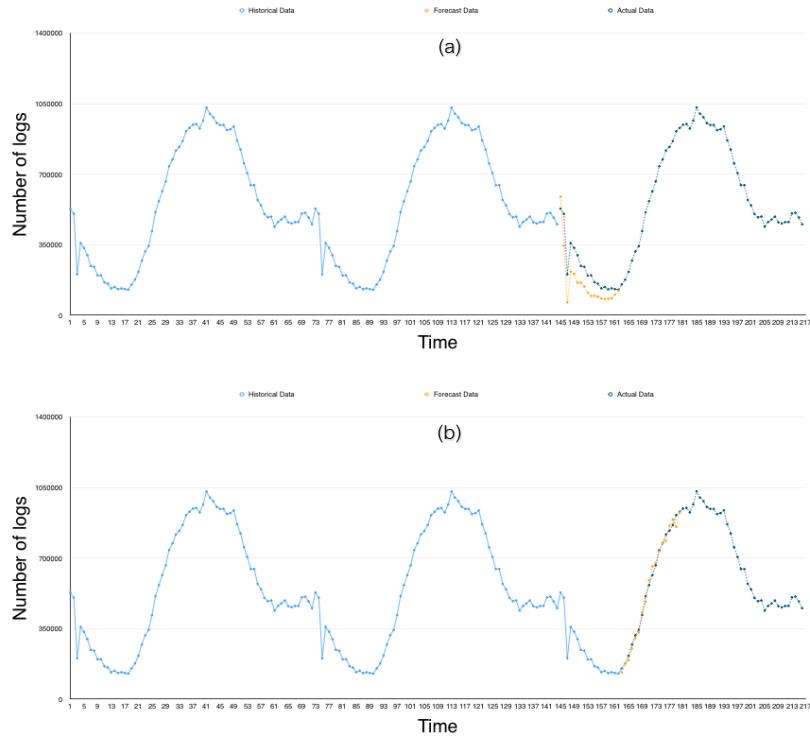


ภาพที่ 13 แสดงการพยากรณ์ปริมาณการใช้งานเครือข่าย

การพยากรณ์ปริมาณการใช้งานเครือข่ายที่จะเกิดขึ้นนั้น เราจะใช้ข้อมูลบันทึกของระบบงานในอดีต (historical log data) มาทำการประมวลผลเพื่อเปลี่ยนจากข้อมูลที่ไม่สามารถใช้งานได้หรือก็คือ unstructured data ให้เป็น structure ซึ่งก็คือ ปริมาณการใช้งานเครือข่าย แล้วนำเอาปริมาณการใช้งานเครือข่ายมาสร้างแบบจำลองอนุกรมเวลาชาริมา เพื่อพยากรณ์ปริมาณการใช้งานเครือข่ายที่จะเกิดขึ้นในอนาคต ภาพที่ 13 แสดงตัวอย่างการพยากรณ์การใช้งานเครือข่ายโดยที่กราฟเส้นสีฟ้าจะแสดงถึงปริมาณการใช้งานเครือข่ายในอดีต, สีเหลืองแสดงถึงปริมาณการใช้งานเครือข่ายที่เฉพาะกรณ์คาดไว้, และสีน้ำเงินแสดงถึงปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจริง ซึ่งรูปแบบการประมวลผลที่เคยมีมานั้นอาจจะประมวลผลและพยากรณ์ได้ครั้งละ step ข้างหน้า ดังในภาพที่ 14 เมื่อจากต้องประมวลผลข้อมูลที่มีปริมาณมากให้ได้ภายในระยะเวลาที่จำกัด ซึ่งการใช้สถาปัตยกรรมแบบผสมนี้จะสามารถทำให้เราประมวลผลและพยากรณ์ได้ครั้งละหลาย step เช่น 18 step ดังแสดงในภาพที่ 15 หรืออาจจะพยากรณ์ไว้ 1 วันล่วงหน้าดังแสดงในภาพที่ 13



ภาพที่ 14 แสดงตัวอย่างการพยากรณ์ที่ละ step (a) step ที่ 146 (b) step ที่ 147

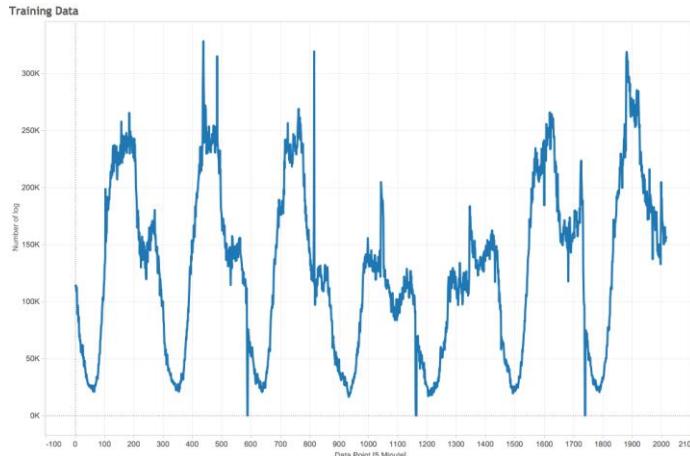


ภาพที่ 15 แสดงตัวอย่างการพยากรณ์ที่ลาก 18 steps (a) step ที่ 145 ถึง step ที่ 162 (b) step ที่ 163 ถึง step ที่ 180

### 3.4 การสร้างแบบจำลองอนุกรมเวลาซาริมา

งานวิจัยนี้จะนำข้อมูลบันทึกของระบบงานจากสำนักเทคโนโลยีของจุฬาลงกรณ์มหาวิทยาลัย ที่จำนวนวันต่างๆ มาใช้ในการสร้างแบบจำลองอนุกรมเวลาซาริมา โดยใช้วงเวลาต่างๆ เป็นหน่วยเวลา เช่น 5 นาที, 10 นาที, 20 นาที, 30 นาที, และ 60 นาที เป็นต้น นอกจากนั้นยังนำค่า BIG มาใช้ในการเลือกแบบจำลองที่มีความศูนย์เสียของข้อมูลน้อยที่สุด อัลกอริทึมในการสร้างแบบจำลองอนุกรมเวลาซาริมาที่เราใช้นั้น ถูกเสนอไว้ในงานวิจัย [25] ซึ่งงานวิจัยนี้ดำเนินตามขั้นตอนหลักๆ ดังนี้

1. หาค่าบขของคุณภาพ s จากกราฟ เซ็น จากภาพที่ 16 ค่าของค่าบจะมีค่าเท่ากับ 288



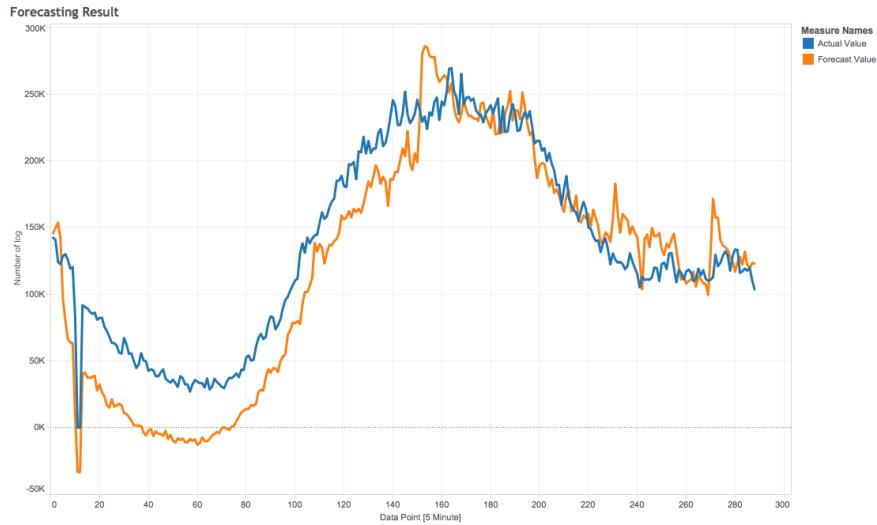
ภาพที่ 16 ปริมาณการใช้งานเครือข่ายจากบันทึกของระบบงาน โดยใช้ 5 นาทีเป็นหน่วย  
ของเวลา

2. หากค่าของ  $p, d, q, P, D$ , และ  $Q$  โดยการทดสอบแทนค่าโดยที่ค่าของ  $p$  และ  $P$  ไม่ควรเป็น 0 พร้อมกัน รวมทั้ง  $q$  และ  $Q$  ไม่ควรเป็น 0 พร้อมกัน จากนั้นเลือกรูปแบบการแทนค่าที่เหมาะสมที่สุดจากค่าของ BIG
3. หากค่าพารามิเตอร์ที่เหลือทั้งหมด เช่น  $\phi_1, \Phi_1, \theta_1$ , และ  $\Theta_1$  โดยใช้วิธี Maximum likelihood estimation [26]
4. สร้างแบบจำลองอนุกรมเวลา SARIMA ตามสมการที่ 1

### 3.5 การตรวจหาปริมาณการใช้งานเครือข่ายที่ผิดปกติโดยใช้แบบจำลองอนุกรมเวลาเชิงริมما

การตรวจหาความผิดปกติของปริมาณการใช้งานเครือข่าย สามารถทำได้โดยการเปรียบเทียบปริมาณการใช้งานเครือข่ายในปัจจุบัน กับค่าขีดสุด (Threshold) โดยในงานวิจัยนี้จะมีค่าขีดสุดซึ่งนำมาจากการวิจัย [27] สองค่าคือค่า inferior (IT) และค่า superior (ST) ถ้าค่าการใช้งานในปัจจุบันมากกว่าค่า superior หรือน้อยกว่าค่า inferior แสดงว่ามีความผิดปกติเกิดขึ้นกับปริมาณการใช้งานเครือข่าย ซึ่งการตรวจหาปริมาณการใช้งานเครือข่ายที่ผิดปกติโดยใช้แบบจำลองอนุกรมเวลาเชิงริมماมีขั้นตอนดังนี้

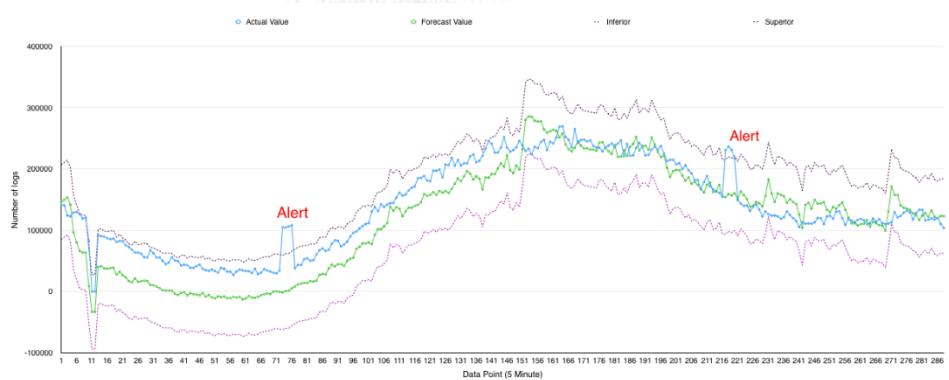
1. สร้างแบบจำลองอนุกรมเวลาเชิงริมมาโดยใช้วิธีที่อธิบายไปข้างต้น แล้วพยากรณ์ถึงปริมาณการใช้งานเครือข่ายที่ควรเกิดขึ้น ภาพที่ 17



ภาพที่ 17 บิวามนการใช้งานเครือข่ายที่เกิดขึ้นจริง เทียบกับผลจากการพยากรณ์

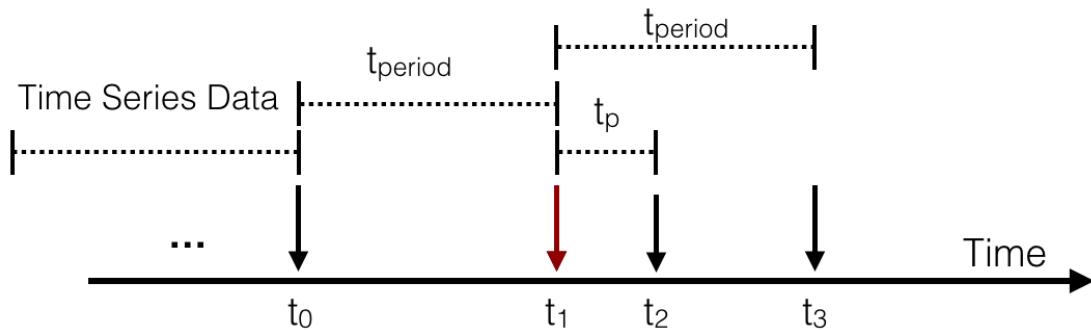
2. นำบิวามนการใช้งานเครือข่ายที่เราพยากรณ์ไว้ มาสร้างค่าขีดสุด
3. นำค่าบิวามนการใช้งานจริงมาเปรียบเทียบกับค่าขีดสุด ถ้าบิวามนการใช้งานเครือข่ายมากกว่า หรือน้อยกว่าค่าขีดสุด แสดงว่ามีความผิดปกติเกิดขึ้น ดังใน

ภาพที่ 18



ภาพที่ 18 ตัวอย่างการแจ้งเตือนความผิดปกติของการใช้งานอินเทอร์เน็ต

### 3.6 นิยามศัพท์ในงานวิจัย

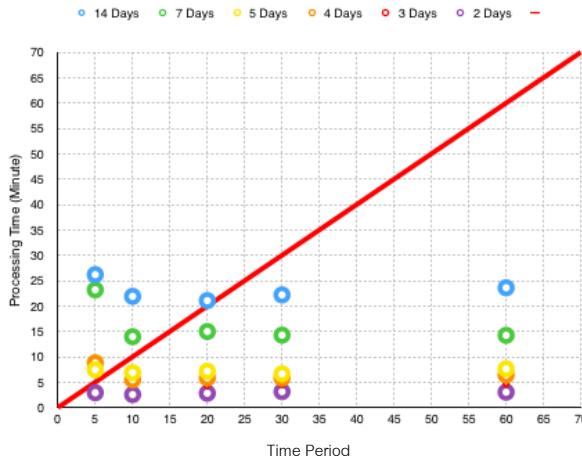


ภาพที่ 19 แสดงถึงช่วงเวลาที่ใช้ในการสร้างแบบจำลองและพยากรณ์

นิยามที่ใช้ในงานวิจัยนี้ มีดังต่อไปนี้

1. Time Series Data คือ เวลาของข้อมูลย้อนหลัง ที่เราจะใช้ในการประมวลผล อาจจะมีค่า 1 วัน, 2 วัน, 3 วัน, หรือ 7 วัน เป็นต้น
2. ช่วงเวลาสะสมข้อมูล (Time Period หรือ  $t_{\text{period}}$ ) เป็นหน่วยของช่วงเวลาที่จะทำการสะสมข้อมูลเพื่อใช้ในการสร้างแบบจำลองและพยากรณ์อาจจะมีค่า 5 นาที, 10 นาที, 20 นาที, หรือ 60 นาที เป็นต้น จากกราฟที่ 19 ค่า  $t_{\text{period}}$  จะเท่ากับ  $t_1 - t_0$  และ  $t_3 - t_1$
3. เวลาที่ใช้ในการประมวลผล (Processing Time หรือ  $t_p$ ) เป็นระยะเวลาที่ระบบจะต้องใช้ในการสร้างแบบจำลอง โดยจะใช้ข้อมูล Time Series Data ผนวกกับข้อมูลที่ได้ทำการสะสมในช่วงสะสมข้อมูล (Time Period) เพื่อทำการพยากรณ์ โดยจากกราฟที่ 19 ณ เวลา  $t_1$  ระบบจะทำการนำข้อมูล Time Series Data ที่ได้ทำการสะสมไว้ก่อนช่วง  $t_0$  ผนวกกับข้อมูลในช่วง  $t_1 - t_0$  มาทำการสร้างแบบจำลองและพยากรณ์ โดยใช้เวลา  $t_2 - t_1$  หรือ  $t_p$  ในการดำเนินการ

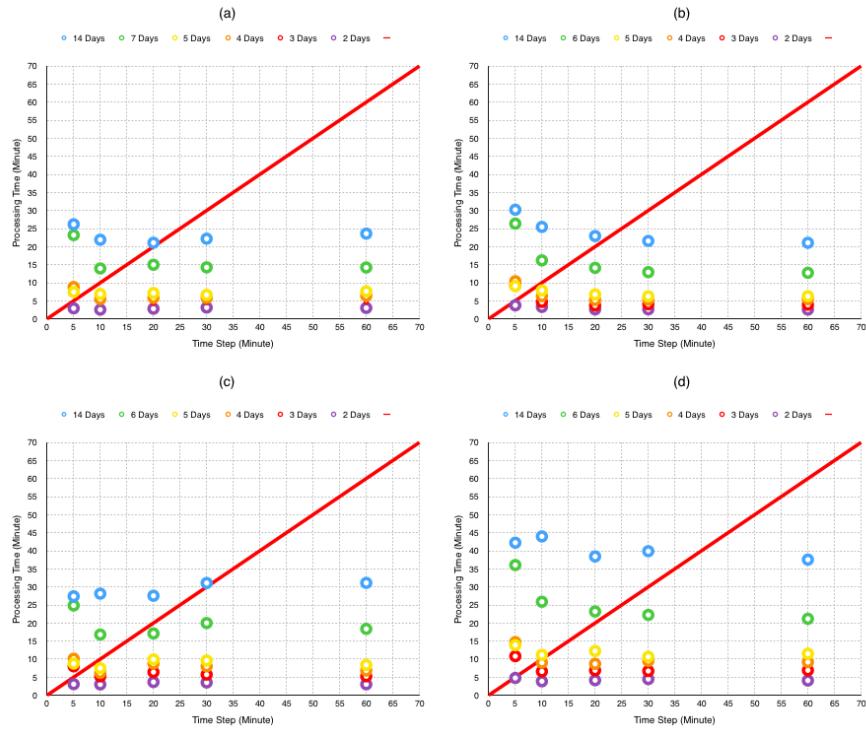
ดังนั้นถ้าหากว่าเราต้องการที่จะประมวลผลข้อมูลและพยากรณ์ปริมาณการใช้งานเครือข่ายให้ทันเวลา เราจะต้องทำให้  $t_p < t_{\text{period}}$  และถ้าหากว่า  $t_p > t_{\text{period}}$  แสดงว่าเราจะไม่สามารถประมวลผลข้อมูลและพยากรณ์ปริมาณการใช้งานเครือข่ายได้ทันเวลา แต่การที่เราจะประมวลผลให้ทันเวลา นั้น จะไม่สามารถประมวลผลด้วยข้อมูลย้อนหลังกลับไปได้หลายวัน ซึ่งจะส่งผลให้ค่าปริมาณการใช้งานเครือข่ายที่เราพยากรณ์ออกมานั้นมีค่าผิดไปจากค่าปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจริง ดังนั้น ถ้าเราต้องการพยากรณ์ปริมาณการใช้งานเครือข่ายให้ได้ค่าใกล้เคียงกับปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจริง เราจำเป็นต้องใช้ข้อมูลย้อนหลังในปริมาณที่มากทำให้ค่า  $t_p$  มีค่ามาก ทำให้อาจจะทำให้ประมวลผลได้ไม่ทันเวลา



ภาพที่ 20 ผลการประมวลผลโดยใช้ช่วงเวลาที่แตกต่างกันในการประมวลผล

ในภาพที่ 20 แสดงเวลาที่ใช้ในการประมวลผลเทียบกับช่วงเวลาต่างๆ ของข้อมูล และขนาดของข้อมูลย้อนหลัง โดยเส้นสีแดงจะแสดงถึง dead line ของการประมวลผลในช่วงเวลาต่างๆ ถ้าค่าระหว่างเวลาที่ใช้ในการประมวลผลกับช่วงเวลาอยู่เหนือเส้นสีแดง แสดงว่าเราไม่สามารถประมวลผลได้ทันเวลา แต่ถ้าอยู่ใต้เส้นสีแดง แสดงว่าเราสามารถประมวลผลได้ทันเวลา ยกตัวอย่างเช่น ที่ขนาดข้อมูล 2 วัน เวลาที่ใช้ในการประมวลผลในช่วงเวลาต่างๆ ของข้อมูลนั้นไม่เกิน 5 นาทีและอยู่ใต้เส้นสีแดง แสดงว่าเราสามารถประมวลผลโดยใช้ขนาดข้อมูล 2 วันในการประมวลผลแบบ Real-Time ได้ แต่สำหรับข้อมูลที่มีขนาด 14 วัน เราจะสามารถประมวลผลได้ทันเวลา ที่ช่วงเวลา 30 นาที และ 60 นาที แต่ไม่สามารถประมวลผลได้ทันเวลาในช่วงเวลา 5, 10, และ 20 นาที ดังนั้นในงานวิจัยชิ้นนี้ที่ใช้สถาปัตยกรรมแบบผสมนั้น จะประมวลผลข้อมูลหรือพยากรณ์ปริมาณการใช้งานไว้ล่วงหน้าและต้องคงอยู่ปรับแบบจำลอง, ผลของการพยากรณ์, รวมทั้งค่าขีดสุดที่ใช้ในการแบ่งความผิดปกติเป็น Batch แล้วจึงนำผลไปใช้ในการตรวจจับความผิดปกติของการใช้งานเครื่อข่ายแบบ Real-Time

นอกจากนั้นยังได้ทำการแสดงกราฟของเวลาที่ใช้ในการประมวลผลเมื่อเทียบกับช่วงเวลาของข้อมูลและปริมาณของข้อมูลที่ใช้ในการประมวลผลโดยทำการเพิ่มจำนวน Node ดังแสดงในรูปที่ 21



ภาพที่ 21 กราฟแสดงเวลาที่ใช้งานการประมวลผลเมื่อเทียบระหว่างช่วงเวลาของข้อมูลและปริมาณของข้อมูลที่ใช้งานการประมวลผล (a) 2 Nodes, (b) 3 Nodes, (c) 4 Nodes, และ 5 Nodes

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

## บทที่ 4

### การพัฒนาเครื่องมือและการทดสอบ

ในบทนี้จะเป็นการอธิบายองค์ประกอบของการพัฒนาเครื่องมือที่ใช้เพื่อวิเคราะห์ประสิทธิภาพในการทำงานของระบบ ของสถาปัตยกรรม โดยเริ่มต้นจากสภาพแวดล้อมที่ใช้ในการพัฒนาเครื่องมือ จากนั้นอธิบายวิธีการทำงานต่างๆ ที่ใช้ในการทดสอบ เพื่อวัดประสิทธิภาพในการทำงานของระบบดังที่นำเสนอไปในบทที่ 3 ซึ่งมีรายละเอียดดังนี้

#### 4.1 สภาพแวดล้อมที่ใช้ในการทดสอบ

ในงานวิจัยชิ้นนี้จะทำการสร้าง cluster ภายในเครื่องเสมือน (Virtual Machine) ขึ้นมาจำนวน 8 node เพื่อใช้เป็น platform สำหรับการทดสอบโดยกำหนดให้มี Master Node 1 ตัว และ มี Slave Node 8 ตัว โดยสภาพแวดล้อมที่ใช้ในการพัฒนาเครื่องมือมีดังต่อไปนี้

1. ฮาร์ดแวร์ (Hardware)
  - a. Intel(R) Xeon(R) CPU E5-2670 v2 @2.5GHz
  - b. หน่วยความจำสำรอง (RAM) 4 GB
2. ซอฟต์แวร์ (Software)
  - a. ระบบปฏิบัติการ (Operating System)
  - b. Apache Hadoop version 2.7.0
  - c. Apache Spark version 1.4.1
  - d. Apache Flume version 1.5.2

#### 4.2 ข้อมูลที่ใช้ในการทดสอบ

ข้อมูลบันทึกของระบบงานของจุฬาลงกรณ์มหาวิทยาลัย ในช่วงเดือน เมษายน ๒๕๕๙ และ พฤษภาคม พ.ศ. 2559

#### 4.3 การทดสอบประสิทธิภาพ

งานวิจัยชิ้นนี้ทดสอบประสิทธิภาพการประมวลผลบันทึกของระบบงาน และพยากรณ์ถึงปริมาณการใช้งานเครือข่ายที่จะเกิดขึ้น จากแบบจำลองอนุกรมเวลาชาริมา โดยแบ่งปริมาณบันทึกของระบบงานที่ใช้ในการสร้างและพยากรณ์ปริมาณการใช้งานเครือข่ายออกเป็น 2 วัน, 3

วัน, 4 วัน, 5 วัน, 10 วัน, และ 15 วัน รวมถึงใช้ช่วงเวลาต่างๆ ในการสร้างแบบจำลองและพยากรณ์ เป็นหน่วยเวลา เช่น 5 นาที, 10 นาที, 20 นาที, 30 นาที, และ 60 นาที

#### 4.3.1 การทดสอบประสิทธิภาพในการพยากรณ์ปริมาณการใช้งานเครือข่าย

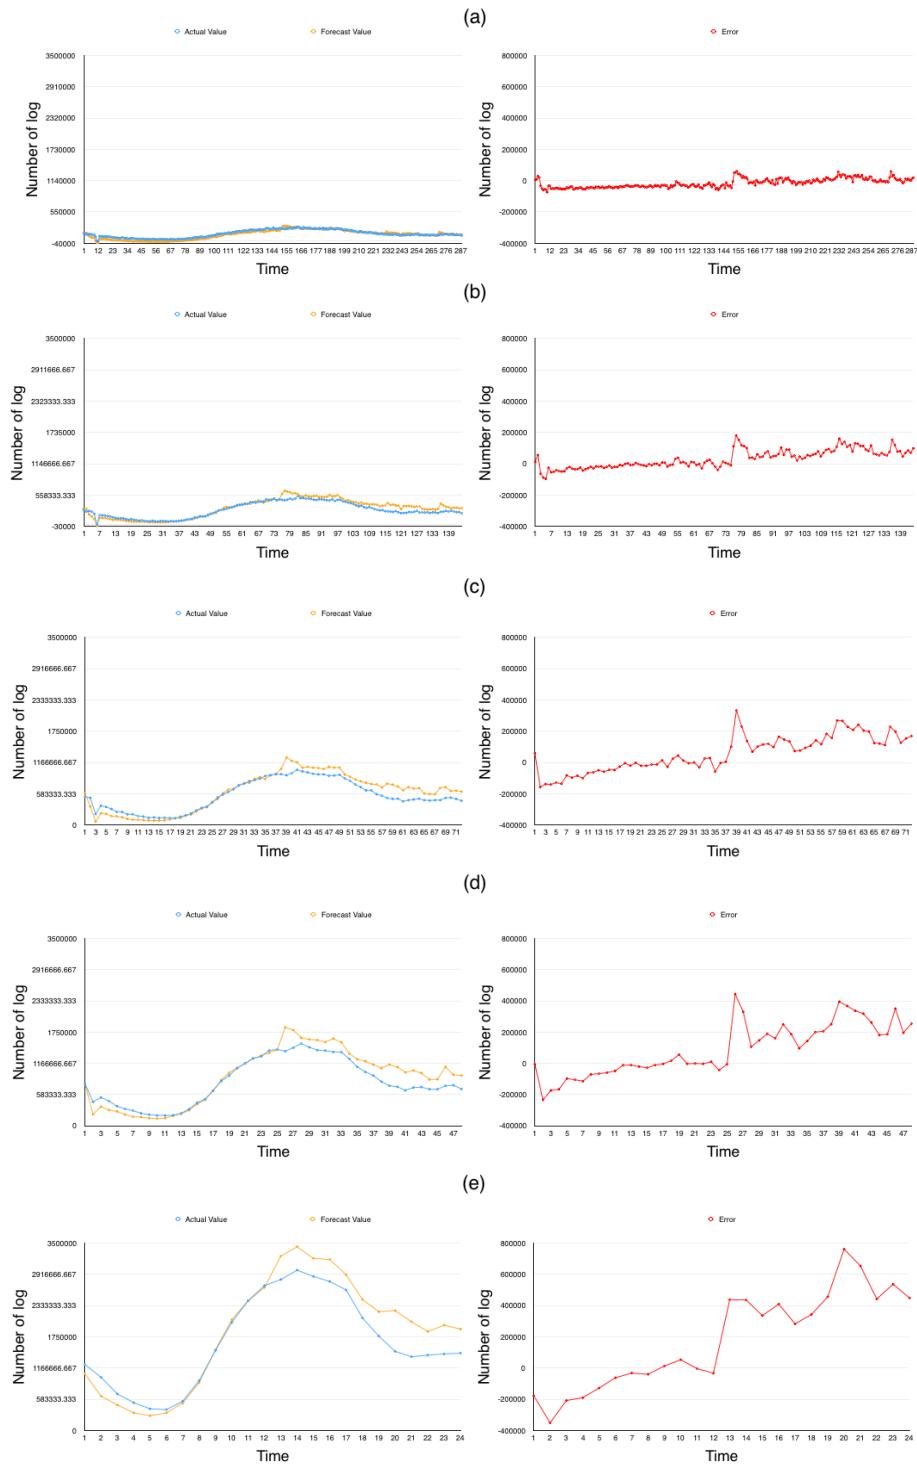
ภาพที่ 22 แสดงถึงปริมาณการใช้งานระบบเครือข่ายที่เกิดขึ้นจริงเทียบกับค่าปริมาณการใช้งานระบบเครือข่ายที่พยากรณ์เอาไว้ และค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ ในภาพที่ 22(a) แสดงกราฟเบรียบเทียบระหว่างผลการพยากรณ์ของปริมาณการใช้งานเครือข่ายเทียบกับปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจริงในระดับ 5 นาที พร้อมกับค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ ภาพที่ 22(b), 22(c), 22(d), และ 22(e) ในระดับ 10, 20, 30, และ 60 นาที ตามลำดับ

จากการทดสอบจะเห็นได้ว่า ถ้าหากใช้ช่วงเวลาสั้นๆ เช่น 5 นาที หรือ 10 นาที ในการสร้างแบบจำลองและพยากรณ์ ค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์จะมีค่าน้อย แต่ถ้าหากว่าเราใช้ช่วงเวลายาวๆ เช่น 30 นาที หรือ 60 นาทีในการสร้างแบบจำลองและพยากรณ์นั้น ค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ที่เกิดขึ้นก็จะสูงขึ้นตามไปด้วย ซึ่งค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ (Forecasting Error) ที่เกิดขึ้นนั้น เกิดมาจากการค่าความต่างของปริมาณการใช้งานเครือข่ายที่เราพยากรณ์เอาไว้ (Forecast value) กับค่าปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจริง (Actual value) ดังที่แสดงในสมการที่ 2

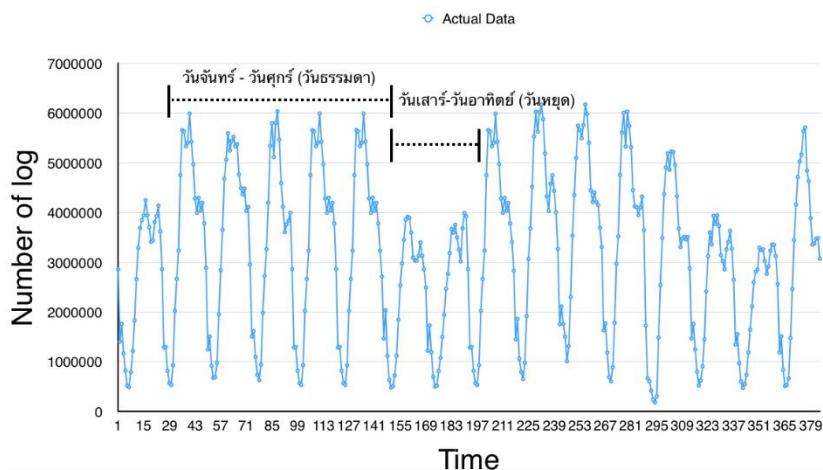
$$e(t) = \hat{y}(t) - y(t) \quad (2)$$

จากสมการที่ 2 ตัวแปรต่างๆ ของสมการมีดังนี้

- $e(t)$  คือค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์
- $\hat{y}(t)$  คือค่าปริมาณการใช้งานเครือข่ายที่เราพยากรณ์
- $y(t)$  คือค่าปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจริง



ภาพที่ 22 ปริมาณการใช้งานระบบเครือข่ายที่เกิดขึ้นจริงเทียบกับค่าปริมาณการใช้งานระบบเครือข่ายที่พยากรณ์ และค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ (a) ระดับ 5 นาที, (b) ระดับ 10 นาที, (c) ระดับ 20 นาที, (d) ระดับ 30 นาที, และ (e) ระดับ 60 นาที

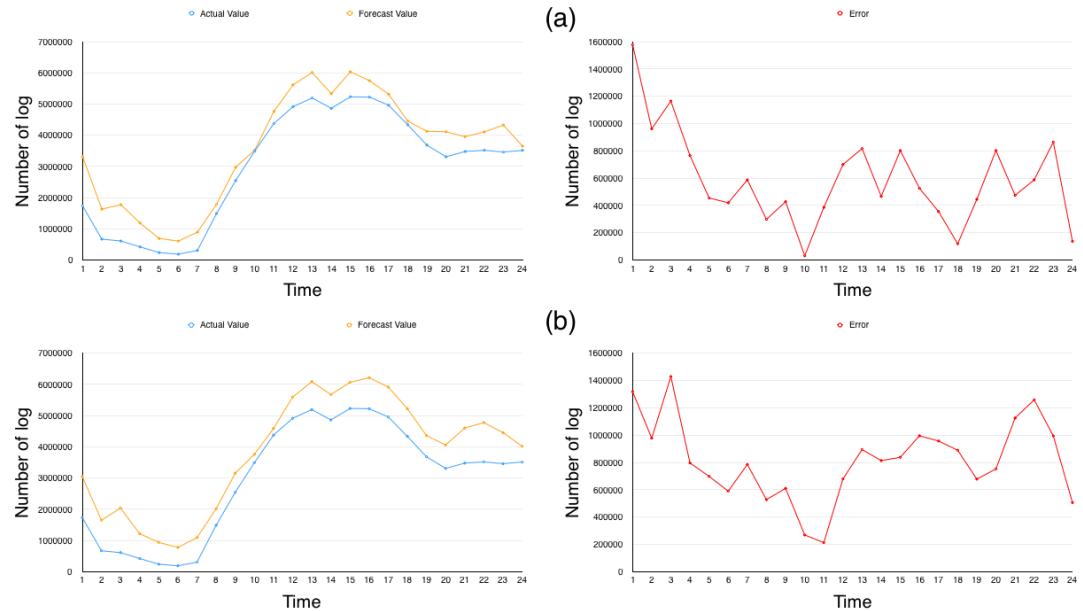


ภาพที่ 23 ตัวอย่างข้อมูลของปริมาณการใช้งานเครือข่าย  
นอกจากนั้นทางผู้วิจัยยังได้ทดสอบประสิทธิภาพการพยากรณ์ปริมาณการใช้งาน  
เครือข่าย โดยใช้ปริมาณข้อมูลที่แตกต่างกัน โดยจะแบ่งออกเป็น 2 กรณีด้วยกันคือ

1. นำเอาข้อมูลที่มีปริมาณเท่าๆ กันมาสร้างแบบจำลองเช่น การนำเอาวัน  
ธรรมด้า คือ จันทร์, อังคาร, พุธ, พฤหัสบดี, ศุกร์ มาเพื่อพยากรณ์ปริมาณ  
การใช้งานเครือข่ายของวันธรรมด้า หรือว่านำเอาวันหยุด คือ วันเสาร์  
และวันอาทิตย์ มาเพื่อพยากรณ์ปริมาณการใช้งานเครือข่ายของวันหยุด
2. นำเอาข้อมูลของวันธรรมดามาประมาณผลเพื่อพยากรณ์ปริมาณการใช้  
งานเครือข่ายในวันหยุด หรือ นำเอาข้อมูลของวันหยุดมาประมาณผลเพื่อ  
พยากรณ์ปริมาณการใช้งานเครือข่ายในวันธรรมด้า

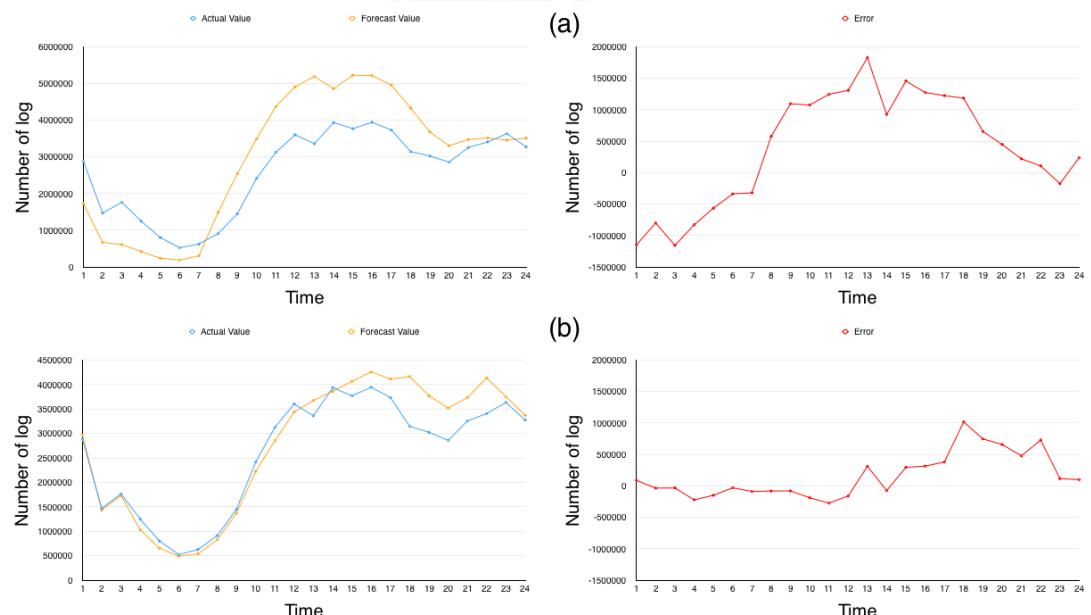
จะเห็นได้ว่าการที่เราใช้วันที่มีปริมาณการใช้งานเครือข่ายเท่าๆ กันหรือพอๆ กัน (กรณีที่ 1) มาสร้างแบบจำลองและพยากรณ์นั้น ถึงแม้ว่าเราจะใช้ปริมาณข้อมูลย้อนหลังไปไกล  
ค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ก็ไม่ได้แตกต่างไป  
จากเดิมมาก ดังแสดงในภาพที่ 24

ส่วนในกรณีที่ 2 จากภาพที่ 25 การที่เราใช้ปริมาณการใช้งานเครือข่ายจากวัน  
ธรรมดามาสร้างแบบจำลองและพยากรณ์ปริมาณการใช้งานเครือข่ายของวันหยุด เรายังคงพบว่าการที่  
เราเพิ่มปริมาณข้อมูลย้อนหลังไปไกลขึ้นนั้น ค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่  
เกิดขึ้นจากการพยากรณ์จะลดลง เช่นเดียวกับภาพที่ 26 การที่เราใช้ปริมาณการใช้งาน  
เครือข่ายจากวันหยุดมาสร้างแบบจำลองและพยากรณ์ปริมาณการใช้งานเครือข่ายของวันธรรมด้า  
เรายังคงพบว่าการที่เราเพิ่มปริมาณข้อมูลย้อนหลังไปไกลขึ้นนั้น ค่าความผิดพลาดของปริมาณการใช้  
งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์จะลดลง



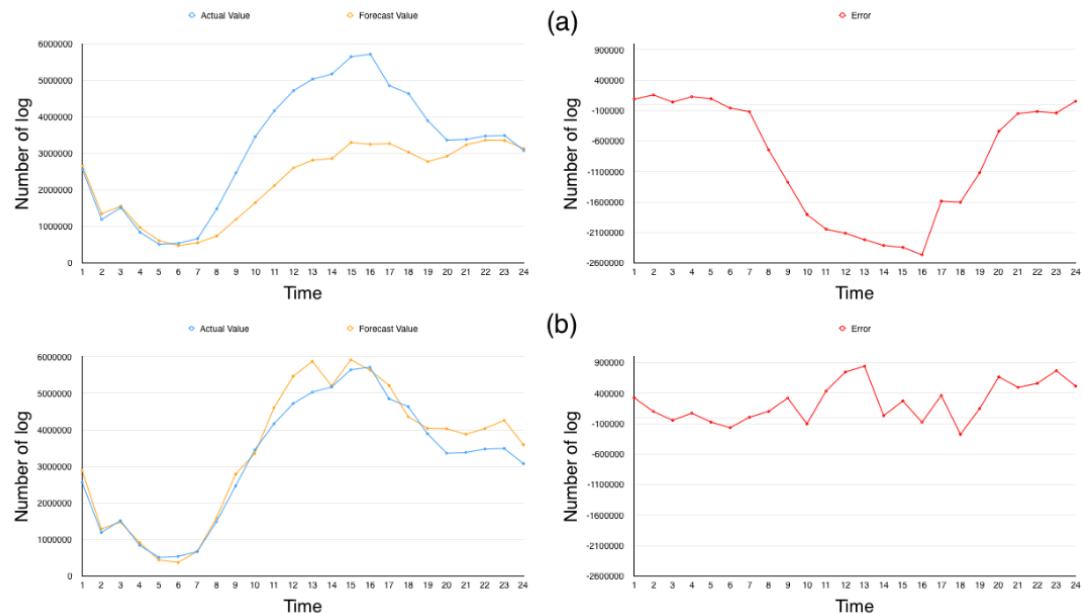
ภาพที่ 24 ปริมาณการใช้งานระบบเครือข่ายที่เกิดขึ้นจริงเทียบกับค่าปริมาณการใช้งานระบบเครือข่ายที่พยากรณ์ และค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ โดยการนำวันที่มีปริมาณเท่าๆ กัน โดย (a) ใช้ข้อมูลย้อนหลัง 2 วัน (b) ใช้ข้อมูล

#### ย้อนหลัง 7 วัน



ภาพที่ 25 ปริมาณการใช้งานระบบเครือข่ายที่เกิดขึ้นจริงเทียบกับค่าปริมาณการใช้งานระบบเครือข่ายที่พยากรณ์ และค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ โดยการนำวันที่รวมดามาทำนายวันหยุด โดย (a) ใช้ข้อมูลย้อนหลัง 2 วัน (b) ใช้ข้อมูล

#### ย้อนหลัง 7 วัน



ภาพที่ 26 ปริมาณการใช้งานระบบเครือข่ายที่เกิดขึ้นจริงเทียบกับค่าปริมาณการใช้งานระบบเครือข่ายที่พยากรณ์ และค่าความผิดพลาดของปริมาณการใช้งานเครือข่ายที่เกิดขึ้นจากการพยากรณ์ โดยการนำวันหยุดมาทำนายวันธรรมด้า โดย (a) ใช้ข้อมูลย้อนหลัง 2 วัน (b) ใช้ข้อมูลย้อนหลัง 7 วัน

#### 4.3.2 การทดสอบประสิทธิภาพในการตรวจหาความผิดปกติของเครือข่าย

งานวิจัยนี้ทดสอบประสิทธิภาพของการตรวจหาความผิดปกติของการใช้งานเครือข่ายโดยใช้แบบจำลองอนุกรมเวลาชาาริมา ด้วยการจำลองการโจมติเพื่อให้เกิดการหยุดให้บริการ โดยปัจจัยที่ใช้ในการจำลองการโจมติ มีดังนี้

1. อัตราการใช้งานอินเทอร์เน็ตที่ใช้ในการโจมติแบ่งออกเป็น 4 กรณีได้แก่

- a. 10 เปอร์เซ็นต์ของอัตราการใช้งานอินเทอร์เน็ตสูงสุด
- b. 25 เปอร์เซ็นต์ของอัตราการใช้งานอินเทอร์เน็ตสูงสุด
- c. 50 เปอร์เซ็นต์ของอัตราการใช้งานอินเทอร์เน็ตสูงสุด
- d. 70 เปอร์เซ็นต์ของอัตราการใช้งานอินเทอร์เน็ตสูงสุด

2. ระยะเวลาที่ใช้ในการโจมติแบ่งเป็น 2 กรณี

- a. 5 นาที
- b. 10 นาที
- c. 20 นาที

- ### 3. เวลาที่ใช้โฉมตี ได้แก่

- a. 6.00  $\mu$ .

- b. 18.00 ፳.

- #### 4. ช่วงเวลาของข้อมูล

- a. 5 นาที

- b. 10 นาที

- c. 20 นาที

- ด. 30 นาที

- e. 60 นาที

การทดสอบจะใช้การเปรียบปริมาณการใช้งานเครือข่าย มาเปรียบเทียบกับค่าขีดสุด ถ้าค่าปริมาณการใช้งานเครือข่ายมีค่ามากกว่า หรือน้อยกว่าค่าขีดสุด แสดงว่ามีการตรวจพบความผิดปกติของการใช้งาน

ตารางที่ 2 ผลลัพธ์ของการทดสอบประสิทธิภาพในการตรวจหาความผิดปกติของเครื่องข่าย

(a)

### 5 Minute Period

	5 Minute Data Point		10 Minute Data Point		20 Minute Data Point		30 Minute Data Point		60 Minute Data Point	
	6 A.M.	6 P.M.	6 A.M.	6 P.M.	6 A.M.	6 P.M.	6 A.M.	6 P.M.	6 A.M.	6 P.M.
DDOS 10%	YES	NO	NO	NO	NO	NO	NO	NO	NO	NO
DDOS 25%	YES	YES	NO	NO	NO	NO	NO	NO	NO	NO
DDOS 50%	YES	YES	YES	NO	NO	NO	NO	NO	NO	NO
DDOS 75%	YES	YES	YES	YES	YES	NO	NO	NO	NO	NO

(b)

10 Minute Period

	5 Minute Data Point		10 Minute Data Point		20 Minute Data Point		30 Minute Data Point		60 Minute Data Point	
	6 A.M.	6 P.M.	6 A.M.	6 P.M.	6 A.M.	6 P.M.	6 A.M.	6 P.M.	6 A.M.	6 P.M.
DDOS 10%	YES	NO	NO	NO	NO	NO	NO	NO	NO	NO
DDOS 25%	YES	YES	YES	NO	NO	NO	NO	NO	NO	NO
DDOS 50%	YES	YES	YES	YES	YES	NO	NO	NO	NO	NO
DDOS 75%	YES	YES	YES	YES	YES	YES	YES	NO	NO	NO

(c)

## 20 Minute Period



pragti ที่ช่วงเวลา 5 นาที เราจะสามารถตรวจสอบการใช้งานที่ผิดปกติของการใช้งานเครือข่ายที่เวลา 6 A.M. และ 6 P.M. ที่ช่วงเวลา 10 นาที และ 20 นาที เราจะสามารถตรวจสอบการใช้งานที่ผิดปกติในเวลา 6 A.M. เท่านั้น, ถ้าทำให้ความผิดปกติของเครือข่ายเพิ่มขึ้นเป็น 50% ของการใช้งานเครือข่าย pragti ที่ช่วงเวลา 5,10,20, และ 30 นาที เราจะสามารถตรวจสอบการใช้งานที่ผิดปกติของการใช้งานเครือข่ายที่เวลา 6 A.M. และ 6 P.M., ถ้าทำให้ความผิดปกติของเครือข่ายเพิ่มขึ้นเป็น 75% ของการใช้งานเครือข่าย pragti ที่ช่วงเวลา 5,10,20, และ 30 นาที เราจะสามารถตรวจสอบการใช้งานที่ผิดปกติของการใช้งานเครือข่ายที่เวลา 6 A.M. และ 6 P.M. ที่ช่วงเวลา 60 นาที เราจะสามารถตรวจสอบการใช้งานที่ผิดปกติในเวลา 6 A.M. เท่านั้น

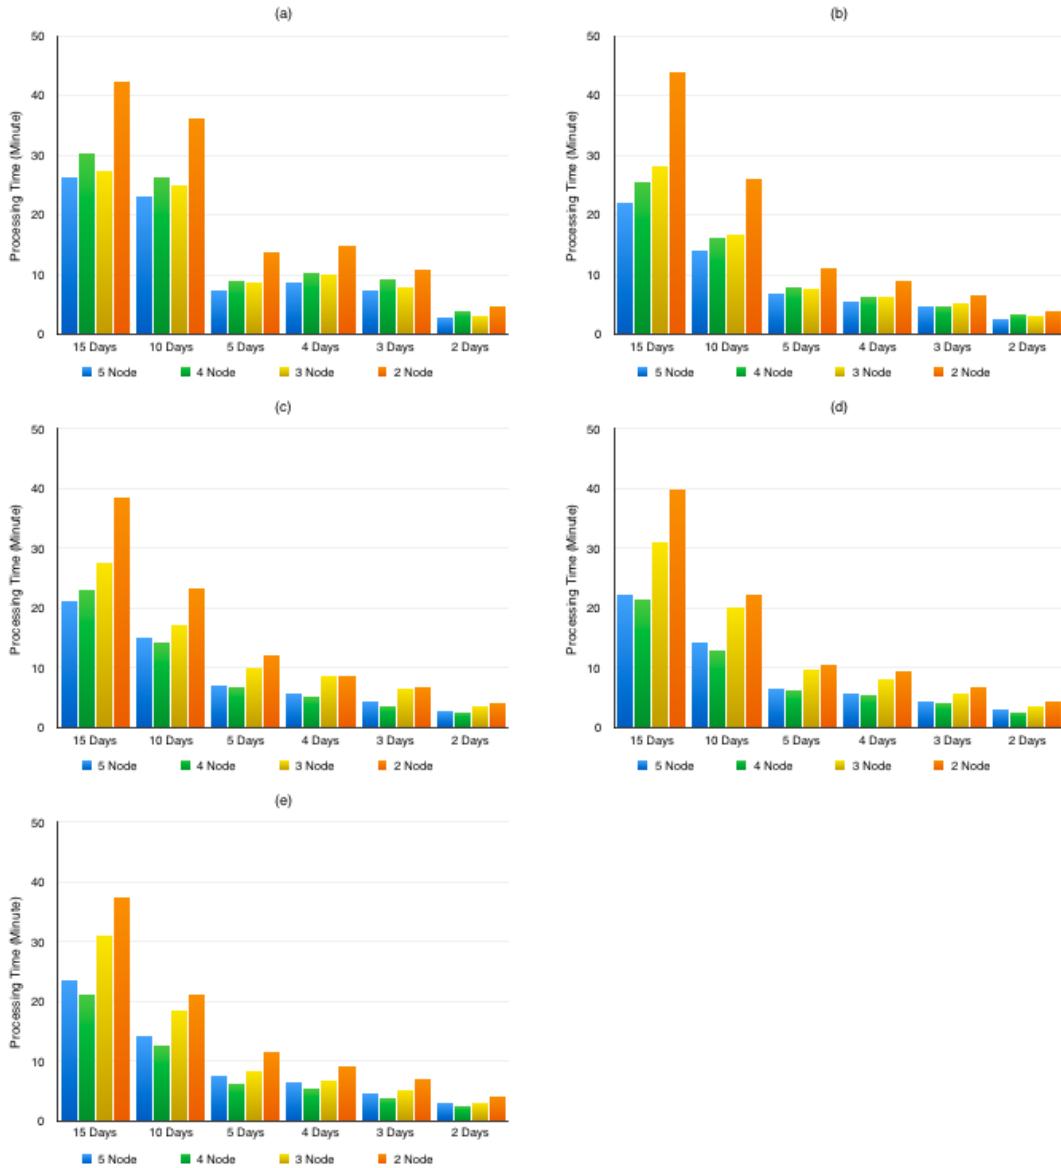
จากการทดสอบประสิทธิภาพในการตรวจสอบความผิดปกติของเครือข่าย จากตารางที่ 3 พบว่าการที่เราใช้ข้อมูลที่มีความถี่ต่ำๆ มาใช้ในการสร้างแบบจำลองอนุกรมเวลาและตรวจสอบความผิดปกตินั้น ทำให้เราสามารถตรวจสอบความผิดปกติของเครือข่ายที่เกิดจากการโจรใต้มีอัตราการใช้งานต่ำได้ดีกว่า การที่เราใช้ช่วงเวลาสูงในการสร้างแบบจำลองอนุกรมเวลาและตรวจสอบความผิดปกติ

#### 4.3.3 การทดสอบประสิทธิภาพในการประมวลผลและพยากรณ์ปริมาณการใช้งานเครือข่าย

ในภาพที่ 27 แสดงถึงเวลาที่ใช้งานการประมวลผลของบันทึกของระบบงาน โดยจะรวมเวลาที่ใช้งานการหาปริมาณการใช้งานเครือข่าย, สร้างแบบจำลองอนุกรมเวลาชาวิมา และการพยากรณ์ปริมาณการใช้งานเครือข่ายภาพที่ 27(a) และแสดงถึงเวลาที่ใช้ในการประมวลผลบันทึกของระบบงานโดยใช้ปริมาณของบันทึกของระบบงานย้อนหลัง 2 วัน, 3 วัน, 4 วัน, 5 วัน, 10 วัน, และ 15 วัน โดยใช้ช่วงเวลาของข้อมูลระดับ 5 นาที และแบ่งการประมวลผลออกเป็น 2 node, 3 node, 4 node, และ 5 node นอกจากนั้นในภาพที่ 27(b), 27(c), 27(d), และ 27(e) จะแสดงถึงการใช้ช่วงเวลาของข้อมูลที่แตกต่างกัน โดยที่ภาพที่ 27(b) จะใช้ 10 นาทีเป็นช่วงเวลาของข้อมูล, ภาพที่ 27(c) จะใช้ 20 นาทีเป็นช่วงเวลาของข้อมูล, ภาพที่ 27(d) จะใช้ 30 นาทีเป็นช่วงเวลาของข้อมูล, และ ภาพที่ 27(e) จะใช้ 60 นาทีเป็นช่วงเวลาของข้อมูล

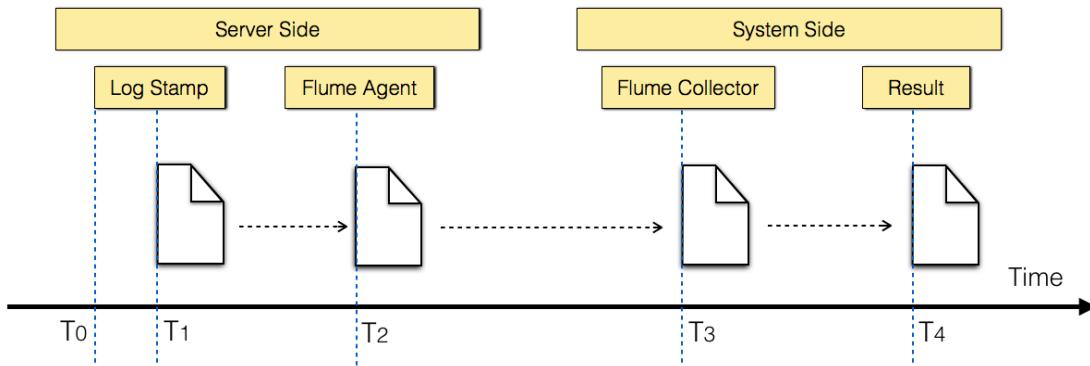
จากการทดสอบจะเห็นได้ว่าการที่เราเพิ่มปริมาณของข้อมูลที่ใช้ในการประมวลผลนั้น เวลาที่ใช้ในการประมวลผลก็จะเพิ่มขึ้นด้วย แต่ถ้าหากเราเพิ่มจำนวน node หรือหน่วยประมวลผลขึ้น จะทำให้เราสามารถลดระยะเวลาที่ใช้ในการประมวลผลให้น้อยลงได้ แต่ว่า

ในบางกรณี เช่น ในภาพที่ 27(e) นั้น การเพิ่มจำนวน node ที่ใช้ในการประมวลผลกลับ ไม่ได้ทำให้ การประมวลผลนั้นเร็วขึ้นแต่กลับทำให้ช้าลง



ภาพที่ 27 เวลาที่ใช้งานการประมวลผล (a) ระดับ 5 นาที, (b) ระดับ 10 นาที, (c) ระดับ 20 นาที, (d) ระดับ 30 นาที, และ (e) ระดับ 60 นาที

#### 4.3.4 การทดสอบประสิทธิภาพในการทำงานในสภาวะแบบ Real-Time



ภาพที่ 28 แสดงการทำงานประมวลผลของระบบในสภาวะ Real-Time

งานวิจัยนี้ทดสอบประสิทธิภาพของการตรวจหาความผิดปกติของการใช้งานเครือข่ายแบบ Real-Time โดยใช้แบบจำลองอนุกรมเวลาซาริมา ด้วยการจำลองการโจมตีเพื่อให้เกิดการหยุดให้บริการ โดยจะสร้างบันทึกของระบบงานโดยใช้ความถี่ที่แตกต่างกันคือ 1,000 messages/sec, 2,000 messages/sec, 3,000 messages/sec, 4,000 messages/sec, และ 5,000 messages/sec โดยใช้ระยะเวลา 5 นาที และแบ่งตัวชี้วัดออกเป็นสามอย่างด้วยกันคือ

1. ระยะเวลาที่ข้อมูลจะพร้อมใช้ (Delivery Time) ( $T_3 - T_1$ )
2. ระยะเวลาที่ใช้ในการตรวจจับความผิดปกติ (Detection Time) ( $T_4 - T_1$ )

ตารางที่ 3 ผลการทดสอบประสิทธิภาพในการประมวลผลแบบ Real-Time

	1000	2000	3000	4000	5000
ระยะเวลาที่ข้อมูลจะพร้อมใช้	1552.2	1473.6	2808.4	1797.6	1687
ระยะเวลาที่ใช้ในการตรวจจับความผิดปกติ	1560.8	1476.4	2873.6	1852.2	1730
<b>ผลลัพธ์</b>					

จากการทดสอบพบว่า ถ้าหากใช้ความถี่ในการสร้างบันทึกของระบบงาน 1,000 messages/sec ระยะเวลาที่ใช้ในการตรวจจับความผิดปกติมีค่าเท่ากับ 1560.8 มิลลิวินาที และระยะเวลาที่ข้อมูลจะพร้อมใช้เท่ากับ 1552.2 มิลลิวินาที ถ้าหากใช้ความถี่ในการสร้างบันทึกของระบบงาน 2,000 messages/sec ระยะเวลาที่ใช้ในการตรวจจับความผิดปกติมีค่าเท่ากับ 1476.4 มิลลิวินาที และ ระยะเวลาที่ข้อมูลจะพร้อมใช้เท่ากับ 1473.6 มิลลิวินาที ถ้าหากใช้ความถี่ในการสร้างบันทึกของระบบงาน 3,000 messages/sec ระยะเวลาที่ใช้ในการตรวจจับความผิดปกติมีค่าเท่ากับ 2873.6 มิลลิวินาที และ ระยะเวลาที่ข้อมูลจะพร้อมใช้เท่ากับ 2808.4

มิลลิวินาที ถ้าหากใช้ความถี่ในการสร้างบันทึกของระบบงาน 4,000 messages/sec ระยะเวลาที่ใช้ในการตรวจจับความผิดปกติมีค่าเท่ากับ 1852.2 มิลลิวินาที และ ระยะเวลาที่ข้อมูลจะพร้อมใช้เท่ากับ 1797.6 มิลลิวินาที และถ้าหากใช้ความถี่ในการสร้างบันทึกของระบบงาน 5,000 messages/sec ระยะเวลาที่ใช้ในการตรวจจับความผิดปกติมีค่าเท่ากับ 1730 มิลลิวินาที และระยะเวลาที่ข้อมูลจะพร้อมใช้เท่ากับ 1687 มิลลิวินาที

#### 4.5 วิเคราะห์ผลการทดลอง

เนื่องจากการพยากรณ์ปริมาณการใช้งานเครือข่ายโดยใช้แบบจำลองเวลาชาร์วิมา จากบันทึกของระบบงานนั้นเป็นการสร้างแบบจำลองที่เกิดขึ้นจากการนำข้อมูลในอดีตมาประมาณผลเพื่อที่จะพยากรณ์ถึงสิ่งที่จะเกิดขึ้น ดังนั้นการที่เรารู้ข้อมูลย้อนหลังกลับไปก็จะส่งผลให้ผลในการพยากรณ์นั้นแม่นยำขึ้น และจากการทดลองพบว่า ความถูกต้องของปริมาณการใช้งานเครือข่ายที่เราพยากรณ์ออกมานั้นจะเปลี่ยนไป ตามช่วงเวลาที่เราใช้ในการสร้างแบบจำลองและพยากรณ์ถ้าหากช่วงเวลาที่ใช้ในการสร้างแบบจำลองและพยากรณ์มีค่ามาก ค่าความผิดพลาดจากการพยากรณ์ที่เกิดขึ้นก็จะสูงมาก แต่ถ้าหากว่าเราต้องการที่จะพยากรณ์ปริมาณการใช้งานเครือข่ายให้มีค่าความผิดพลาดจากพยากรณ์ต่ำๆ นั้นเราจะต้องใช้ช่วงเวลาสั้นๆ อย่างเช่น 5 นาที มาใช้ในการประมาณผลดังแสดงในภาพที่ 22 เป็นต้น ดังนั้นถ้าหากว่าเราต้องการประมาณข้อมูลเหล่านี้เพื่อสร้างแบบจำลองและพยากรณ์ให้ได้ภายใน Real-Time หรือทันเวลา เราจะไม่สามารถประมาณผลข้อมูลย้อนหลังได้หลายวันดังแสดงในภาพที่ 20

แต่การใช้สถาปัตยกรรมแบบผสมสำหรับการประมาณผลบันทึกของระบบงานขนาดใหญ่ นั้นจะประมาณผลข้อมูลหรือพยากรณ์ปริมาณการใช้งานไว้ล่วงหน้าเป็น Batch และนำผลไปใช้ในการตรวจจับความผิดปกติของ การใช้งานเครือข่ายแบบ Real-Time ทำให้เราสามารถพยากรณ์ไปล่วงหน้าได้ ยกตัวอย่างเช่น จากภาพที่ 20 ถ้าหากว่าเราใช้ Time Period เป็น 10 นาที และใช้ข้อมูลย้อนหลัง 7 วันเราจะสามารถพยากรณ์ได้ภายใน 15 นาที โดยที่เราจะพยากรณ์ไว้ล่วงหน้าอย่างน้อย 20 นาทีหรือมากกว่านั้นก็ได้ และถ้าหากว่าเราใช้ข้อมูลย้อนหลังเป็น 14 วันเราจะสามารถพยากรณ์ได้ภายใน 22 นาที โดยที่เราจะพยากรณ์ไว้ล่วงหน้าอย่างน้อย 30 นาทีหรือมากกว่านั้นก็ได้

## บทที่ 5

### บทสรุปและแนวทางในการพัฒนาต่อ

#### 5.1 สรุปผลการวิจัย

งานวิจัยนี้เสนอสถาปัตยกรรมที่มีความสามารถในการประมวลผลข้อมูลได้ทันในรูปแบบ Batch และแบบ Real-Time ทดสอบโดยนำวิธีการตรวจจับความผิดปกติของเครือข่ายโดยใช้แบบจำลองอนุกรมเวลาชาวิมาประยุกต์ใช้ โดยในการประมวลผลแบบ Batch นั้นจะเป็นการประมวลผลข้อมูลที่เก็บไว้ เพื่อนำมาสร้างแบบจำลองอนุกรมเวลาชาวิมาและทำการพยากรณ์ถึงปริมาณการใช้งานเครือข่ายที่ควรจะเป็นรวมทั้งคำนวนหาค่าขีดสุดเพื่อแบ่งแยกระหว่างเครือข่ายที่ปกติและเครือข่ายที่ผิดปกติ ในส่วนของการประมวลผลแบบ Real-Time นั้นจะใช้ในการประมวลผลบันทึกของระบบงาน เพื่อหาปริมาณการใช้งานเครือข่ายแล้วนำมาเปรียบเทียบกับปริมาณการใช้งานเครือข่ายที่พยากรณ์เอาไว้ ถ้าปริมาณการใช้งานเครือข่ายมากกว่าค่าขีดสุด ก็แสดงว่ามีความผิดปกติของการใช้งานเครือข่ายเกิดขึ้น

แต่การที่เราใช้การตรวจจับความผิดปกติของเครือข่ายโดยใช้แบบจำลองอนุกรมเวลาชาวิมาได้อย่างแม่นยำนั้น เราจะต้องใช้ช่วงเวลาสั้นๆ เช่น 5 นาที ในการประมวลผลและตรวจจับความผิดปกติ นอกจากนั้นยังต้องใช้ปริมาณข้อมูลย้อนหลังหลายวัน ซึ่งทำให้เวลาที่ใช้ในการประมวลผลก็จะมากขึ้นตามไปด้วย จากการทดสอบพบว่าการใช้สถาปัตยกรรมแบบผสมสำหรับการประมวลผลบันทึกของระบบงานขนาดใหญ่นั้น สามารถซ่วยเพิ่มประสิทธิภาพในการทำงานกับบันทึกของระบบงานในระบบงานขนาดใหญ่ให้มากขึ้น โดยสามารถประมวลผลข้อมูลที่มีขนาดใหญ่แล้วนำมาสร้างแบบจำลองที่มีความซับซ้อน และยังสามารถตรวจจับความผิดปกติได้ภายในระยะเวลาที่จำกัดได้

#### 5.2 แนวทางในการพัฒนาต่อ

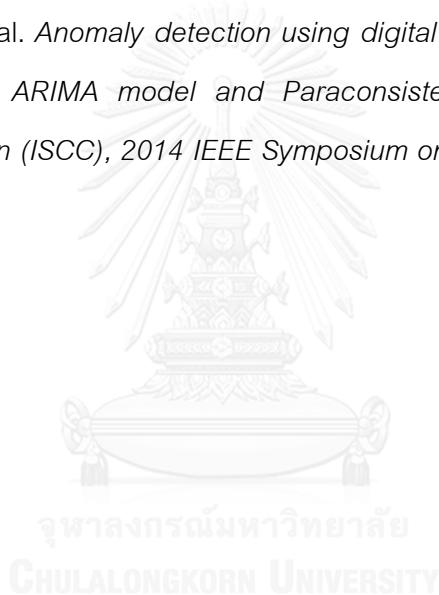
งานวิจัยนี้สามารถนำไปรับประทานได้เมื่อประสิทธิภาพดีขึ้นโดยนำไปทดสอบหาค่าที่เหมาะสมสำหรับการตรวจจับความผิดปกติ หรือทดสอบใช้แบบจำลองอื่นๆ เพื่อให้ผลลัพธ์ในการพยากรณ์ปริมาณการใช้งานเครือข่ายนั้นมีความแม่นยำมากยิ่งขึ้น รวมทั้งประยุกต์ใช้เทคนิคหรือวิธีการอื่นๆ ที่ใช้ในการตรวจจับความผิดปกติ เช่น การทำ Clustering หรือการใช้ neural network เป็นต้น และยังสามารถนำไปทดสอบในสภาพแวดล้อมจริง

## รายการอ้างอิง

1. Chen, M., S. Mao, and Y. Liu, *Big data: A survey*. Mobile Networks and Applications, 2014. 19(2): p. 171-209.
2. Hashem, I.A.T., et al., *The rise of “big data” on cloud computing: Review and open research issues*. Information Systems, 2015. 47: p. 98-115.
3. Xu, W., et al. *Detecting large-scale system problems by mining console logs*. in *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*. 2010.
4. Wei, J., et al. *Analysis farm: A cloud-based scalable aggregation and query platform for network log analysis*. in *Cloud and Service Computing (CSC), 2011 International Conference on*. 2011. IEEE.
5. Cinque, M., D. Cotroneo, and A. Pecchia, *Event logs for the analysis of software failures: A rule-based approach*. Software Engineering, IEEE Transactions on, 2013. 39(6): p. 806-821.
6. Jayathilake, D. *Towards structured log analysis*. in *Computer Science and Software Engineering (JCSSE), 2012 International Joint Conference on*. 2012. IEEE.
7. Lee, Y. and Y. Lee. *Detecting ddos attacks with hadoop*. in *Proceedings of The ACM CoNEXT Student Workshop*. 2011. ACM.
8. Yu, H. and D. Wang. *Mass log data processing and mining based on Hadoop and cloud computing*. in *Computer Science & Education (ICCSE), 2012 7th International Conference on*. 2012. IEEE.
9. Therdphapiyanak, J. and K. Piromsopa. *Applying Hadoop for log analysis toward distributed IDS*. in *Proceedings of the 7th International Conference on Ubiquitous Information Management and Communication*. 2013. ACM.
10. Cheon, J. and T.-Y. Choe, *Distributed processing of snort alert log using hadoop*. International Journal of Engineering and Technology, 2013. 5(3): p. 2685-2690.
11. Gunasekaran, R., et al., *Real-Time System Log Monitoring/Analytics Framework*.

12. Subbulakshmi, T., G. Mathew, and S.M. Shalinie, *Real time classification and clustering of IDS alerts using machine learning algorithms*. International journal of Artificial & Application, 2010. 1(1): p. 20.
13. Moharil, B., et al., *Real Time Generalized Log File Management and Analysis using Pattern Matching and Dynamic Clustering*. International Journal of Computer Applications, 2014. 91(16).
14. Vorapongkitipun, C. and N. Nupairoj. *Improving performance of small-file accessing in Hadoop*. in *Computer Science and Software Engineering (JCSSE), 2014 11th International Joint Conference on*. 2014. IEEE.
15. Liu, X., N. Iftikhar, and X. Xie. *Survey of real-time processing systems for big data*. in *Proceedings of the 18th International Database Engineering & Applications Symposium*. 2014. ACM.
16. Zaharia, M., et al. *Resilient distributed datasets: A fault-tolerant abstraction for in-memory cluster computing*. in *Proceedings of the 9th USENIX conference on Networked Systems Design and Implementation*. 2012. USENIX Association.
17. Zaharia, M., et al. *Discretized streams: an efficient and fault-tolerant model for stream processing on large clusters*. in *Presented as part of the*. 2012.
18. Hadoop, A. *Hadoop Homepage*. <http://hadoop.apache.org>.
19. da Silva Morais, T., *Survey on Frameworks for Distributed Computing: Hadoop, Spark and Storm*.
20. Flume, A. <https://flume.apache.org>.
21. Spark, A. *Spark Homepage* <http://spark.apache.org>.
22. Zhang, X. and F. Xu. *Survey of research on big data storage*. in *Distributed Computing and Applications to Business, Engineering & Science (DCABES), 2013 12th International Symposium on*. 2013. IEEE.
23. Chen, C., Q. Pei, and L. Ning. *Forecasting 802.11 Traffic Using Seasonal ARIMA Model*. in *Computer Science-Technology and Applications, 2009. IFCSTA'09. International Forum on*. 2009. IEEE.

24. Debusschere, V. and S. Bacha. *Hourly server workload forecasting up to 168 hours ahead using Seasonal ARIMA model.* in *2012 IEEE International Conference on Industrial Technology.* 2012.
25. Hanbanchong, A. and K. Piromsopa. *SARIMA based network bandwidth anomaly detection.* in *Computer Science and Software Engineering (JCSSE), 2012 International Joint Conference on.* 2012. IEEE.
26. Haslett, J. and A. Raftery, *Space-time modeling with long-memory dependence: assessing Ireland's wind-power resource. Technical report.* 1987, Washington Univ., Seattle (USA). Dept. of Statistics.
27. Pena, E.H., et al. *Anomaly detection using digital signature of network segment with adaptive ARIMA model and Paraconsistent Logic.* in *Computers and Communication (ISCC), 2014 IEEE Symposium on.* 2014. IEEE.



### ประวัติผู้เขียนวิทยานิพนธ์

นายพิทุร์ ตั้งสจจะธรรม เกิดเมื่อวันที่ 8 มีนาคม พ.ศ. 2533 ที่จังหวัดนครศรีธรรมราช สำเร็จการศึกษาระดับปริญญาบัณฑิต หลักสูตรวิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ เมื่อปี พ.ศ. 2556 และเข้าศึกษาต่อในหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชา วิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย เมื่อปี พ.ศ. 2556

