

การคาดการณ์การเปลี่ยนแปลงของทราฟฟิกโทรศัพท์
โดยใช้โครงข่ายประสาทเทียม

TELEPHONE TRAFFIC FLUCTUATION EXPECTATION BY
NEURAL NETWORK

ศรีวิชัย อารณา
SRIWICHAI ARDHAN

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาโท สาขาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมสารสนเทศ

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2551

KASITL-2008-EN-M-230-174

สำนักหอสมุดกลาง พระจอมเกล้าลาดกระบัง

การคาดการณ์การเปลี่ยนแปลงของทราฟฟิกโทรศัพท์
โดยใช้โครงข่ายประสาทเทียม

TELEPHONE TRAFFIC FLUCTUATION EXPECTATION BY
NEURAL NETWORK



ศรีวิชัย อางหาญ

SRIWICHAI ARDHAN

เลขหมู่.....
เลขทะเบียน..... 87880
วัน,เดือน,ปี..... 19 ส.ค. 2552

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมสารสนเทศ

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2551

KMITL-2008-EN-M-230-174

**TELEPHONE TRAFFIC FLUCTUATION EXPECTATION BY
NEURAL NETWORK**

SRIWICHAI ARDHAN

**A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENTS FOR THE DEGREE OF
MASTER OF ENGINEERING INFORMATION ENGINEERING
FACULTY OF ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

2008

KMITL-2008-EN-M-230-174

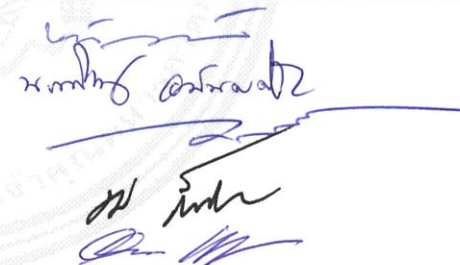
COPYRIGHT 2008

FACULTY OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ใบรับรองวิทยานิพนธ์

หัวข้อวิทยานิพนธ์ การคาดการณ์การเปลี่ยนแปลงของทราฟฟิกโทรศัพท์โดยใช้โครงข่ายประสาทเทียม
Thesis Title Telephone Traffic Fluctuation Expectation by Neural Network
นักศึกษา นายศรีวิชัย อาจหาญ
รหัสประจำตัว 47061124
ปริญญา วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา วิศวกรรมสารสนเทศ
อาจารย์ที่ปรึกษาวิทยานิพนธ์ รศ.อรลาภ แสงอรุณ
หมายเลขวิทยานิพนธ์ KMITL-2008-EN-M-230-174

คณะกรรมการสอบวิทยานิพนธ์		ลายมือชื่อ
รศ.ดร.ชวลิต	เบญจางคประเสริฐ	
รศ.นภพินท์	อนันตรศิริชัย	
รศ.ดร.กนก	เจนจิระพงศ์เวช	
รศ.ดร.ชม	กิมปาน	
รศ.อรลาภ	แสงอรุณ	

วัน / เดือน / ปี ที่สอบ วันจันทร์ที่ 22 กันยายน พ.ศ. 2551 เวลา 11.30-13.30 น.

สถานที่สอบ ณ อาคาร A ชั้น 5 ห้องประชุม 3

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

คณะวิศวกรรมศาสตร์ รับรองแล้ว



(รองศาสตราจารย์ ดร.กอบชัย เดชหาญ)

คณบดี คณะวิศวกรรมศาสตร์

วันที่ 22 กันยายน พ.ศ. 2551

หัวข้อวิทยานิพนธ์	การคาดการณ์การเปลี่ยนแปลงของกราฟฟิคโทรศัพท์โดยใช้ โครงข่ายประสาทเทียม
นักศึกษา	นายศรีวิชัย อัจหาญ
รหัสประจำตัว	47061124
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมสารสนเทศ
พ.ศ	2551
อาจารย์ที่ปรึกษาวิทยานิพนธ์	รศ.อรลภก แสงอรุณ

บทคัดย่อ

การเปลี่ยนแปลงของปริมาณ กราฟฟิคโทรศัพท์ในอนาคต เป็นปัญหาที่สำคัญของการจัดการบริหารโครงข่ายให้สามารถใช้งานได้อย่างมีประสิทธิภาพ และได้รับประโยชน์สูงสุด วิทยานิพนธ์นี้เสนอการศึกษา และวิเคราะห์ข้อมูลเชิงสถิติของการเปลี่ยนแปลงกราฟฟิคในโครงข่ายโทรศัพท์หลักของบริษัทไอที จำกัด (มหาชน) เพื่อหาวิธีการคาดการณ์การเปลี่ยนแปลงกราฟฟิคโทรศัพท์ที่จะเกิดในอนาคตได้อย่างเหมาะสม รวดเร็ว และถูกต้อง โดยนำเสนอวิธีการคาดการณ์โดยใช้โครงข่ายประสาทเทียม (Artificial Neural Network) ชนิด แพร่กระจายย้อนกลับ (Back Propagation Neural Network) ที่มีการเรียนรู้แบบมีการควบคุม (Supervised learning) เปรียบเทียบกับการพยากรณ์ด้วยวิธีการทางสถิติ ข้อมูลที่ใช้ในการคาดการณ์การได้จากการใช้โทรศัพท์เรียกผ่านชุมสายหลักที่มีใช้งานอยู่ทั่วประเทศ 13 ชุมสาย ซึ่งมีเส้นทางการเชื่อมโยงวงจร (Trunk Circuit) ระหว่างชุมสายโดยรวม 561 เส้นทาง และมีเส้นทางต่อเชื่อมกับโครงข่ายของบริษัทร่วมการงาน 6 บริษัท สำหรับวิทยานิพนธ์นี้เสนอข้อมูลในเส้นทางตัวอย่าง อุดรฯ-กรุงเทพฯ ที่ถูกบันทึกจากระบบชุมสายที่แจ้งวัฒนะ ตั้งแต่ปี พ.ศ. 2547 ถึงปี พ.ศ.2550 เป็นข้อมูลในการเรียนรู้ และทดสอบความถูกต้องของโครงข่ายประสาทเทียม ผลการเปรียบเทียบพบว่า ค่าผิดพลาดที่เกิดจากการคาดการณ์โดยใช้โครงข่ายประสาทเทียม น้อยกว่าค่าผิดพลาดที่ได้จากการคาดการณ์ด้วยวิธีการทางสถิติมาก อีกทั้งยังสะดวก และรวดเร็วกว่า สามารถนำไปประยุกต์ใช้เพื่อคาดการณ์ การเปลี่ยนแปลงของ กราฟฟิคในเส้นทางอื่นๆ ได้อย่างมีประสิทธิภาพ

Thesis Title	Telephone Traffic Fluctuation Expectation by Neural Network
Student	Mr. Sriwichai Ardhan
Student ID.	47061124
Degree	Master of Engineering
Program	Information Engineering
Year	2008
Thesis Advisor	Assoc. Prof. Ornlarp Sangaroon

ABSTRACT

The traffic fluctuation predictions are mainly used to improve the performance of telecommunication network management in the future. This thesis studies and analyzes the statistic data of telephone traffic fluctuation in the main routes of TOT Public Company Limited in Thailand. In order to find out the best methods, herein, the comparison of the neural networks with back propagation by means of supervised learning algorithms and statistical methods are carried out. The data used in the prediction is accumulated at different node in 13 main routes in conjunction with trunk circuit, 561 links and sixth links of division of companies spread out of Thailand. The thesis presents the comparative results of simulation using the data links from Ayutaya – Khunkasem as an example. The data used for learning and testing in this experiment have been accumulated since 2006 to 2008. It is shown that the traffic fluctuation prediction using the method of the neural networks with back propagation have less error than statistical method. Moreover, its can be applied in predictions of the traffic fluctuation in other routes with high efficiency and more convenience.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สามารถสำเร็จลุล่วงด้วยดี เนื่องจากได้รับคำแนะนำ และช่วยเหลือจากรศ.อรลาภ แสงอรุณ ด้วยดีตลอดมา ข้าพเจ้ารู้สึกซาบซึ้งในความอนุเคราะห์จากท่าน และขอกราบขอบพระคุณเป็นอย่างสูง

ขอกราบขอบพระคุณ คุณพ่อ คุณแม่ และพี่ ๆ ทุกคนที่ให้โอกาส และสนับสนุนให้ข้าพเจ้าได้มีโอกาสเล่าเรียนจนถึงระดับปริญญาโทและปริญญาตรี ขอขอบคุณภรรยา และบุตรที่ให้กำลังใจในการเล่าเรียน และทำวิทยานิพนธ์จนสำเร็จลุล่วงไปด้วยดี

ขอขอบคุณพี่ ๆ บริษัททีโอที จำกัด (มหาชน) โดยเฉพาะส่วนงานวิเคราะห์กราฟฟิก ที่ให้คำแนะนำ และความช่วยเหลือเสมอมา

คุณค่า และประโยชน์อันพึงมีจากวิทยานิพนธ์ฉบับนี้ ผู้วิจัยขอมอบแด่ คุณพ่อ คุณแม่ และผู้มีพระคุณทุกท่าน

ศรีวิชัย อางหาญ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VII
สารบัญรูป.....	VIII
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมา และความสำคัญของ ปัญหา.....	1
1.2 วัตถุประสงค์ของการศึกษา.....	2
1.3 แนวความคิดที่ใช้ในการทำวิจัย.....	2
1.4 ขอบเขตของวิทยานิพนธ์.....	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.6 รายละเอียดของวิทยานิพนธ์.....	3
บทที่ 2 ระบบชุมสาย โทรศัพท์พื้นฐาน และกราฟฟิก โทรศัพท์.....	4
2.1 บทนำ	4
2.2 โครงสร้างพื้นฐานของระบบ โทรศัพท์สาธารณะ	4
2.3 กราฟฟิก โทรศัพท์ (Traffic Telephone).....	7
2.3.1 หน่วยของการวัดกราฟฟิก (The Unit of Traffic Measurement).....	8
2.3.2 ปัจจัยที่มีผลกระทบต่อกราฟฟิก	9
2.3.3 การแจกแจงการเปลี่ยนแปลงปริมาณกราฟฟิก	9
2.3.4 ค่าการสูญเสียเออแลงบี (Erlang B loss).....	11
2.3.5 การจัดหาจำนวนอุปกรณ์ และจำนวนวงจร	12
2.4 อัตราการเรียกไม่ผ่าน (Blocking probability).....	12
2.5 ประสิทธิภาพ (Efficiency).....	13
2.6 ชั้นของบริการ (Grade of Service: GOS).....	13
2.7 การแจกแจงความน่าจะเป็น (Probability distribution) ของปริมาณกราฟฟิก	15

สารบัญ (ต่อ)

	หน้า
บทที่ 3 ทฤษฎีที่ใช้คาดการณ์.....	16
3.1 การพยากรณ์ด้วยวิธีการ Least-Square Method (LSM).....	16
3.2 เทคนิคการทำให้เรียบ (Smoothing Method).....	17
3.3 นิวรอลเน็ตเวิร์ค (Artificial Neural Networks)	18
3.3.1 ความรู้เบื้องต้นเกี่ยวกับโครงข่ายประสาท	19
3.3.2 คุณลักษณะทั่วไปของโครงข่ายประสาท	20
3.3.3 แบบจำลองของเซลล์ประสาทเทียม	20
3.3.4 สถาปัตยกรรมของโครงข่ายประสาทเทียม.....	23
3.3.5 ชนิดของฟังก์ชันแอคทิเวชัน.....	24
3.3.6 กระบวนการเรียนรู้ของโครงข่ายประสาทเทียม	27
3.3.7 การประยุกต์โครงข่ายประสาทเทียมในการใช้งาน.....	36
3.3.8 โครงข่ายนิวรอลเน็ตเวิร์คที่ใช้ในงานวิจัย	36
3.3.9 การตรวจสอบประสิทธิภาพของการพยากรณ์.....	39
3.3.10 สรุป	40
บทที่ 4 วิธีการดำเนินการวิจัย และผลการวิจัย.....	41
4.1 รายละเอียดการเก็บข้อมูลกราฟฟิค (Measurement Setup)	41
4.2 ขั้นตอนในการพยากรณ์.....	46
4.3 ผลการวิจัย.....	49
4.3.1 ผลการทดลอง กำหนดโครงสร้างของโครงข่ายประสาทเทียม	49
4.3.2 ผลการพยากรณ์.....	52
4.3.3 การจัดวางการใช้งานที่เหมาะสม.....	66
บทที่ 5 สรุปผลการวิจัย และข้อเสนอแนะ.....	71
5.1 สรุปผลการวิจัย.....	71
5.2 ข้อเสนอแนะ	72

สารบัญ (ต่อ)

	หน้า
เอกสารอ้างอิง.....	73
ภาคผนวก.....	74
ผลงานทางวิชาการที่ได้รับการตีพิมพ์	74
ประวัติผู้เขียน	81

สารบัญตาราง

ตารางที่	หน้า
2.1 ตัวอย่างการคำนวณ เกรดของบริการ (Grade of Service).....	14
3.1 เปรียบเทียบระหว่างนิรอลธรรมชาติ และแบบจำลองที่ประดิษฐ์ขึ้น	22
4.1 ข้อมูลกราฟฟิโกอินพุทที่นอร์มอลไลต์.....	46
4.2 เปรียบเทียบความคลาดเคลื่อนของการพยากรณ์ล่วงหน้า 6 เดือนในขั้นตอนทดสอบ	47
4.3 เปรียบเทียบการพยากรณ์ทั้งสามวิธีกับค่าเป้าหมาย ระหว่างวันที่ 1 - 28 พ.ย. 50.....	52
4.4 จำนวนวงจรใช้งานปัจจุบัน และจัดวงจรใช้งานใหม่ตามการพยากรณ์	54

สารบัญรูป

รูปที่	หน้า
2.1	โครงข่ายโทรศัพท์แบบพื้นฐาน..... 5
2.2	ตัวอย่างการต่อโครงข่ายแบบใยแมลงมุม แบบรูปดาว และแบบรูปดาวทวิคูณ 6
2.3	ตัวอย่างการต่อรวมกันของโครงข่ายใยแมลงมุม และ โครงข่ายรูปดาว..... 6
2.4	การเปลี่ยนแปลงปริมาณทราฟฟิกในช่วงเวลาสั้น (Short-term traffic variation) 7
2.5	การเปลี่ยนแปลงเฉลี่ยของทราฟฟิกในระหว่างวัน(Variation during a day) 7
2.6	ตัวอย่างการวัดปริมาณ ทราฟฟิกระหว่างวันจากโครงข่ายบริษัททีโอที จำกัด (มหาชน) เส้นทาง อยุรยา S1-กรุงเทพฯ S1 10
2.7	ปริมาณทราฟฟิกระหว่างประจำสัปดาห์ บันทึกตลอดเวลาเส้นทาง อยุรยา S1 -หลักสี่ S1..... 10
2.8	การเปรียบเทียบปริมาณการใช้ทราฟฟิกระหว่างปี เปรียบเทียบ 3 ปี..... 11
2.9	ทราฟฟิกโทรศัพท์ เส้นทาง เชียงใหม่ S1- กรุงเทพฯ S1 บันทึกตลอดปี 2550..... 11
2.10	ค่าเบี่ยงเบนมาตรฐาน และค่าเฉลี่ยของทราฟฟิก 15
3.1	โครงสร้างของเซลล์ประสาทชีวภาพ..... 19
3.2	การจำลองโครงข่ายประสาทในรูปแบบคณิตศาสตร์..... 21
3.3	ผลของค่าขีดจำกัด 22
3.4	ลักษณะโครงสร้างของโครงข่ายแบบชั้นเดียว..... 23
3.5	ลักษณะโครงสร้างของโครงข่ายแบบหลายชั้น 24
3.6	ฟังก์ชันเทรสโฮลด์ 24
3.7	ฟังก์ชันเชิงเส้นอิมตัว..... 25
3.8	ฟังก์ชันลอจิสติกที่ค่าความชันต่าง ๆ 26
3.9	ความสัมพันธ์แบบต่าง ๆ ของโครงข่ายประสาท..... 28
3.10	รูปแบบการเรียนรู้..... 35
3.11	ไดอะแกรมเชื่อมโยงระหว่างชั้นของนิวโรลแบบ 2 ชั้น ของ Backpropagation Networks 37
4.1	a โครงข่ายโทรศัพท์ชุมสายหลัก b แสดงการเชื่อมต่อระหว่างชุมสายหลัก 42
4.2	a การแบ่งระดับชุมสายโทรศัพท์ b โครงข่ายชุมสายโทรศัพท์หลักอยุรยา S1 กับชุมสาย S1 อื่น ๆ 12 เส้นทาง..... 43
4.3	ตัวอย่างเส้นทางส่งผ่านทราฟฟิกของผู้ให้บริการร่วมรายอื่น ๆ ผ่านทางโครงข่าย โทรศัพท์หลัก เส้นทางชุมสายอยุรยา S1 กับ ชุมสายกรุงเทพฯ S1 43

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.4 การใช้งานวงจร 2 Mb/s (E1) เส้นทางชุมสายอยุธยา S1 – ชุมสายยูนิตอื่น ๆ	44
4.5 อุปกรณ์การเก็บบันทึก (Monitor) ณ ชุมสายโทรศัพท์หลักของบริษัท ทีโอที จำกัด	45
4.6 ตัวอย่างสัญญาณข้อมูลทราฟฟิกที่เก็บบันทึกบนเส้นทาง อยุธยา S1- กรุงเทพมหานคร S1	45
4.7 ทราฟฟิกของผู้ให้บริการต่าง ๆ ที่เชื่อมเข้ากับโครงข่ายทีโอทีโดยรวมทั่วประเทศ	45
4.8 ทดสอบการหาโมเดลที่มีค่า MSE ต่ำที่สุด	47
4.9 โครงข่ายประสาทเทียมที่ทำการทดสอบ	50
4.10 ผลการทดสอบการหาโมเมนตัมของนิวรอลเน็ตเวิร์ค	50
4.11 ผลการทดสอบการหาอัตราการเรียนรู้นิวรอลเส้นทาง อยุธยา S1-เชียงใหม่ S1	50
4.12 ผลการทดสอบการหาจำนวนรอบในการเรียนรู้นิวรอลเส้นทาง อยุธยา S1-เชียงใหม่ S1	51
4.13 ผลการทดสอบการหาจำนวนรอบ และเวลาในการเรียนรู้ของโครงข่ายนิวรอล	51
4.14 ผลการทดสอบนิวรอลเส้นทาง อยุธยา S1 – ชลบุรี S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี ...	55
4.15 ผลการทดสอบนิวรอลเส้นทาง อยุธยา S1-เชียงใหม่ S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี .	56
4.16 ผลการทดสอบนิวรอลเส้นทาง อยุธยา S1-หาดใหญ่ S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี .	57
4.17 ผลการทดสอบนิวรอลเส้นทาง อยุธยา S1-กรุงเทพมหานคร S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี .	58
4.18 ผลการทดสอบนิวรอลเส้นทาง อยุธยา S1-ขอนแก่น S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี .	59
4.19 ผลการทดสอบนิวรอลเส้นทาง อยุธยา S1 – หลักสี่ S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี ...	60
4.20 ผลการทดสอบนิวรอลเส้นทาง อยุธยา S1-ลาดหญ้า S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี ...	61
4.21 ผลการทดสอบนิวรอลเส้นทาง อยุธยา S1-นครราชสีมา S1 และการพยากรณ์ล่วงหน้า 1ปี ...	62
4.22 ผลการทดสอบนิวรอลเส้นทาง อยุธยา S1-เพชรบุรี S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี ...	63
4.23 ผลการทดสอบนิวรอลเส้นทางอยุธยา S1-พระโขนง S1และการพยากรณ์ล่วงหน้ารวม 1 ปี..	64
4.24 ผลการทดสอบนิวรอลเส้นทางอยุธยา S1-พิษณุโลก S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี .	65
4.25 ผลการทดสอบนิวรอลเส้นทาง อยุธยา S1 – พุนพิน S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี..	66
4.26 การพยากรณ์การใช่วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- ชลบุรี S1	66
4.27 การพยากรณ์การใช่วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- เชียงใหม่ S1	67
4.28 การพยากรณ์การใช่วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- หาดใหญ่ S1	67
4.29 การพยากรณ์การใช่วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- กรุงเทพมหานคร S1	67
4.30 การพยากรณ์การใช่วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- ขอนแก่น S1	67
4.31 การพยากรณ์การใช่วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- หลักสี่มา S1	68
4.32 การพยากรณ์การใช่วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- ลาดหญ้า S1	68

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.33 การพยากรณ์การใช้วงจรถ่วงหน้ารวม 1 ปีเส้นทาง อยุธา S1- นครราชสีมา S1	68
4.34 การพยากรณ์การใช้วงจรถ่วงหน้ารวม 1 ปีเส้นทาง อยุธา S1- เพชรบุรี S1	68
4.35 การพยากรณ์การใช้วงจรถ่วงหน้ารวม 1 ปีเส้นทาง อยุธา S1- พิษณุโลก S1	69
4.36 การพยากรณ์การใช้วงจรถ่วงหน้ารวม 1 ปีเส้นทาง อยุธา S1- พระโขนง S1	69
4.37 การพยากรณ์การใช้วงจรถ่วงหน้ารวม 1 ปี และจำนวนวงจรที่จัดใหม่ 12 เส้นทาง.....	70

บทที่ 1

บทนำ

1.1 ความเป็นมา และความสำคัญของปัญหา

บริษัท ทีโอที จำกัด (มหาชน) เป็นผู้ให้บริการโทรศัพท์พื้นฐานมาตั้งแต่ปี พ.ศ. 2497 ในนามขององค์การโทรศัพท์แห่งประเทศไทย โดยมีสถานะภาพเป็นนิติบุคคล ทำหน้าที่ให้บริการติดต่อสื่อสารผ่านโทรศัพท์ และบริการกิจการโทรคมนาคมสาธารณะเพื่อกระจายข่าวสารออกสู่ชนบททั่วประเทศ ด้วยบริการสื่อสารโทรคมนาคมที่ทันสมัย มีการขยายโครงข่ายเพื่อเพิ่มขีดความสามารถในการให้บริการให้ทั่วถึงอยู่ตลอดเวลา ทั้งด้านความเร็ว ความจุ และ แนวคิดทางวิศวกรรม เพื่อให้สามารถบริการข่าวสารข้อมูลได้ทุกรูปแบบ ด้วยความถูกต้อง และเชื่อถือได้ ในกรณีนี้ บริษัท ทีโอที จึงได้วางแผนในการปรับเปลี่ยนระบบชุมสายโทรศัพท์หลัก จากโครงข่ายเดิมที่เป็นโครงข่ายสวิตช์วงจร (Circuit Switching Network) ซึ่งมีการเชื่อมโยงระหว่างชุมสายระดับ 2 Mb/s ต่อ 1 พอร์ต มาใช้โครงข่ายสวิตช์ข้อมูล (Packet Switching Network) ซึ่งมีการเชื่อมโยงระหว่างชุมสายระดับ 155 Mb/s ต่อ 1 พอร์ต

ในการวางแผนติดตั้งชุมสายโทรศัพท์หลักหรือโครงข่ายโทรศัพท์ทางไกล อุปกรณ์ที่สำคัญคือ อุปกรณ์สื่อสัญญาณที่ทำหน้าที่รวม และแยกข่าวสารเพื่อส่งไปยังชุมสายต่อผ่านทางไกล (Transit Exchange) หรือชุมสายต่อผ่านท้องถิ่น จะต้องมีการจัดการอุปกรณ์ให้เหมาะสมกับจำนวนการใช้งานหรือปริมาณทราฟฟิก (Traffic) ในแต่ละพื้นที่ โดยคำนึงถึงองค์ประกอบที่สำคัญ คือ สภาพภูมิศาสตร์ เศรษฐกิจ และสังคม ความน่าเชื่อถือของโครงข่าย มาตรฐานสากลที่กำหนดให้ อุปกรณ์ชุมสาย และข้อมูลนิสัยการใช้โทรศัพท์ของผู้ใช้บริการ ดังนั้นจึงต้องมีการคาดการณ์หรือพยากรณ์ ทราฟฟิกล่วงหน้าให้ใกล้เคียงความเป็นจริงมากที่สุด เพื่อเป็นแนวทางในการเพิ่มหรือลดอุปกรณ์เหล่านั้น ถ้าการพยากรณ์ ทราฟฟิกในอนาคตมีค่าสูงเกินไป จะเกิดสถานะการณ์ลงทุนไม่คุ้มค่า และไม่ได้ประโยชน์จากการใช้งานอุปกรณ์นั้นเท่าที่ควร ในทางตรงกันข้าม ถ้าการพยากรณ์ ทราฟฟิก มีค่าต่ำเกินไป จะทำให้จำนวนอุปกรณ์ไม่เพียงพอต่อการใช้งาน ส่งผลให้ เกิดความเสียหายต่อระดับการบริการได้ ด้วยเหตุผลดังกล่าวแล้วนั้น และเพื่อประโยชน์ในการจัดการติดตั้งวงจรต่อผ่าน (Trunk circuit) ระหว่างชุมสายโทรศัพท์หลัก ตลอดทั้งพอร์ตเชื่อมโยง (Interface Port) ระหว่างระบบสื่อสัญญาณกับระบบชุมสาย ระดับ 155 Mb/s ต่อ 1 พอร์ตสำหรับโครงข่ายยุคหน้า (Next Generation Network, NGN) จึงเป็นที่มาของการตรวจสอบคาดการณ์การเปลี่ยนแปลงปริมาณทราฟฟิกในแต่ละเส้นทางล่วงหน้าในบทวิจัยนี้ เพื่อสามารถนำไปประยุกต์ใช้งานจริงกับการวางแผนโครงข่ายโทรศัพท์ของบริษัท ทีโอที จำกัด (มหาชน) ต่อไป

ยังต้องกำหนดค่าอัตราการเรียนรู้ (Learning rate) จำนวนครั้งในการทำซ้ำของกระบวนการ เพื่อให้ได้ค่าการทำนายที่เหมาะสม

1.4 ขอบเขตของวิทยานิพนธ์

1. วัดกราฟฟิค ในโครงข่ายโทรศัพท์หลัก 13 ชุมสาย 325 เส้นทาง ตลอดเวลาอย่างน้อย 1 ปี
2. คาดการณ์การเปลี่ยนแปลงกราฟฟิคโทรศัพท์ ในอนาคต โดยใช้การใช้โครงข่ายประสาทเทียม และเปรียบเทียบผลการพยากรณ์เพื่อคาดการณ์กับวิธีการพยากรณ์ทางสถิติ
3. หาโมเดลโครงข่ายประสาทเทียมที่เหมาะสม เพื่อนำไปประยุกต์ใช้งานจริงในการคาดการณ์การเปลี่ยนแปลงปริมาณกราฟฟิคที่อาจเพิ่มขึ้นหรือลดลงในโครงข่ายโทรศัพท์หลักของบริษัท ทีโอที จำกัด (มหาชน) เพื่อประโยชน์ในการวางแผนโครงข่ายต่อไป

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. เรียนรู้ลักษณะ และผลลัพธ์ของการคำนวณแบบแพร่ย้อนกลับของโครงข่ายประสาทเทียม
2. สามารถขยายผลที่ได้รับไปยังส่วนงานวิเคราะห์กราฟฟิค และงานด้านวิศวกรรมระบบโครงข่ายโทรคมนาคมได้
3. เป็นแนวทางในการวิจัย ออกแบบโครงข่ายสื่อสารสัญญาณรองรับกราฟฟิคโทรศัพท์ระบบใหม่ และสามารถนำไปประยุกต์ใช้งานได้จริง

1.6 รายละเอียดของวิทยานิพนธ์

วิทยานิพนธ์ฉบับนี้ แบ่งเป็น 5 บท กล่าวคือ

บทที่ 1 บทนำ กล่าวถึงความเป็นมา และความสำคัญของปัญหา วัตถุประสงค์ในการศึกษาขอบเขตวิทยานิพนธ์ ขั้นตอน และวิธีดำเนินการ และประโยชน์ที่คาดว่าจะได้รับ

บทที่ 2 กล่าวถึงระบบชุมสายโทรศัพท์พื้นฐาน และกราฟฟิคโทรศัพท์ โดยกล่าวถึงทฤษฎีกราฟฟิค และการวัดกราฟฟิค (Traffic Measurement) อัตราการเรียกไม่ผ่านประสิทธิภาพการให้บริการ และการแจกแจงความน่าจะเป็นในการเปลี่ยนแปลงปริมาณกราฟฟิคโทรศัพท์

บทที่ 3 กล่าวถึงทฤษฎีที่ใช้พยากรณ์การเปลี่ยนแปลงปริมาณกราฟฟิคโทรศัพท์ และแบบจำลองทางคณิตศาสตร์ วิธีพยากรณ์อนุกรมเวลาแบบกำลังสองน้อยสุด (Least-square method) และเทคนิคการทำให้เรียบ (Smoothing Method)

บทที่ 4 วิธีการดำเนินการวิจัย และผลการวิจัย

บทที่ 5 สรุปของผลการวิจัย และข้อเสนอแนะในการพัฒนาเพื่อปรับปรุง และข้อจำกัดในวิธีการที่ได้เสนอขึ้น

บทที่ 2

ระบบชุมสายโทรศัพท์พื้นฐาน และทราฟฟิกโทรศัพท์ (Telephone Traffic)


2.1 บทนำ

โครงข่ายโทรศัพท์พื้นฐานแบบดั้งเดิม [1] ถูกพัฒนาขึ้นเพื่อการส่งสัญญาณเสียงพูดไปในระยะทางไกล โดยระยะแรก ระบบการส่งเป็นแบบอนาล็อก (Analog) ในย่านความถี่เสียง 4 kHz ด้วยการรวมสัญญาณจากหลาย ๆ คู่สาย (Multiplexing) แล้วส่งไปบนสายเส้นเดียว ต่อมาด้วยความต้องการในการส่งข้อมูลดิจิทัล ส่งผลให้มีการประดิษฐ์คิดค้น โมเด็มขึ้นเพื่อส่งข้อมูลระหว่างคอมพิวเตอร์โดยใช้ระบบโทรศัพท์เป็นสื่อ โดยโมเด็มเป็นอุปกรณ์ที่ทำหน้าที่แปลงสัญญาณดิจิทัลจากคอมพิวเตอร์ให้เป็นสัญญาณอนาล็อกก่อนส่งไปตามสายโทรศัพท์ และเมื่ออินเตอร์เน็ตความเร็วสูง (High-Speed Internet) เข้ามามีบทบาทในการย่อโลกให้แคบลง ความเร็วของโมเด็มที่ถูกพัฒนาขึ้นยังไม่เพียงพอในการไหลข้อมูล บริษัทผู้ผลิตโทรศัพท์จึงได้พัฒนาเทคโนโลยีใหม่ที่เรียกว่า ดิเอสแอล (Digital Subscriber Line) ขึ้น แต่สำหรับงานวิจัยนี้ จะพิจารณาเฉพาะโครงข่าย PSTN (Public Switched Telephone Network) ภายใต้วงกลางเสียงเท่านั้น โดยบทนี้จะกล่าวถึงโครงสร้างของโครงข่าย PSTN ที่ใช้อยู่ในปัจจุบัน ซึ่งในตอนต่อไปของวิทยานิพนธ์นี้จะเรียกสั้น ๆ ว่าโครงข่ายโทรศัพท์ และทราฟฟิกโทรศัพท์ (Traffic) ของโครงข่ายโทรศัพท์ภายใต้วงกลางเสียง เพื่อเป็นแนวทางในการบริหารจัดการโครงข่ายยุคหน้า (Next Generation Network : NGN) ต่อไป

2.2 โครงสร้างพื้นฐานของระบบโทรศัพท์สาธารณะ


โครงสร้างพื้นฐานทั่วไปของโครงข่ายโทรศัพท์ ประกอบด้วยอุปกรณ์หลัก 3 ส่วน คือ อุปกรณ์ส่วนของลูกค้า (The customer premise equipment : CPE) อุปกรณ์สื่อสัญญาณ (Transmission facilities) และอุปกรณ์สลับสาย (Switching facilities) CPE คืออุปกรณ์ที่อยู่กับลูกค้า ทำหน้าที่รับ และส่งข่าวสาร เช่นเครื่องโทรศัพท์พื้นฐาน โทรศัพท์เคลื่อนที่ คอมพิวเตอร์ โมเด็ม เครื่องตอบรับอัตโนมัติ เป็นต้น ส่วนอุปกรณ์การสื่อสัญญาณหรืออุปกรณ์ที่ทำหน้าที่นำสัญญาณไปแบ่งเป็นส่วนของข่ายสายท้องถิ่น (Local loop or Subscriber loop) ซึ่งทำหน้าที่เชื่อมต่อระหว่าง CPF กับอุปกรณ์สลับสายซึ่งติดตั้งไว้ ณ ชุมสายโทรศัพท์ (Exchange) โดยข่ายสายท้องถิ่นเดิมส่วนใหญ่ใช้สายทองแดงซึ่งเป็นสายคู่ (Wire-pair) เป็นตัวกลาง สำหรับระบบที่ติดตั้งใหม่หันมาใช้เส้นใยแก้วนำแสง (Fiber optic) แทน โดยมักจะมีระยะทางประมาณ 2 ไมล์ในแต่ละจุด หรือกล่าวได้ว่าข่ายสายท้องถิ่นให้บริการผู้ใช้แต่ละรายในระยะใกล้ ๆ และส่วนของข่ายสายทางไกล (Trunk lines or

trunk circuit) ซึ่งทำหน้าที่เป็นอุปกรณ์เชื่อมต่อระหว่างชุมสายกับชุมสาย ปัจจุบันเป็นดิจิทัล (Digital trunk) และเป็นอุปกรณ์รับ-ส่งสัญญาณควบคุมการตัดต่อวงจรเชื่อมต่อ โดยจะเชื่อมต่อระยะไกลในช่วงหนึ่งไมล์ถึงหลายพันไมล์ โดยอาศัยตัวกลางการสื่อสารชนิดต่าง ๆ เช่น คู่สายทองแดง สายโคแอกเชียล ระบบไมโครเวฟ ดาวเทียม และเส้นใยแก้วนำแสง ในส่วนของอุปกรณ์ระบบชุมสาย (Switching system) หน้าที่หลัก คือ การสลับเส้นทางการสนทนา และหาเส้นทางที่เหมาะสมเพื่อเชื่อมต่อกับชุมสายอื่นหรือเครือข่ายอื่น โดยใช้เทคนิคการสวิตช์แบบสวิตช์วงจร (Circuit switching) ซึ่งมีทางเดินที่ถูกจอง มีลำดับการเชื่อมต่อของทางเชื่อม ระหว่างการเรียก และคู่สายที่ถูกเรียก สำหรับความต่อเนื่องของการเรียก ข่าวดูสารที่มีสัญญาณพิเศษ (Dialing tone) จะเดินทางข้ามเครือข่ายและจับช่องสัญญาณ ในทางเดินนั้น เพื่อดำเนินการต่อไปสู่การติดตั้งวงจร หลังจากที่ทางเดินได้ถูกติดตั้งขึ้นแล้ว สัญญาณจะถูกส่งคืนกลับเพื่อให้ต้นทางส่งข้อมูลต่อไป




รูปที่ 2.1 โครงข่ายโทรศัพท์แบบพื้นฐาน

รูปที่ 2.1 แสดงระดับชั้นของชุมสายในระบบโทรศัพท์ โดยแบ่งเป็น 2 กลุ่มคือ กลุ่มท้องถิ่น (Local) และกลุ่มทางไกล (Tandem) กลุ่มท้องถิ่นคือส่วนที่เชื่อมต่อกับคู่สายของผู้ใช้โดยตรง หรือระหว่างผู้ใช้กับระบบทางไกลเรียกว่า ชุมสายท้องถิ่น (Central Office : CO) สำหรับกลุ่มทางไกลซึ่งเชื่อมต่อระหว่างคู่สายทางไกลด้วยกัน (Trunks to trunks) หรือ ต่อกับชุมสายท้องถิ่นอื่น ๆ เรียกว่าชุมสายต่อผ่านทางไกล (Tandem Switching) และถ้าเป็นกลุ่มทางไกลที่ให้บริการเฉพาะคู่สายทางไกลอย่างเดียว จะถูกเรียกว่าชุมสายทางไกล (Toll Switching) ชุมสายประเภทนี้จะไม่มียอดหมายโทรศัพท์ของผู้เข้าต่อเข้ามาโดยตรง แต่จะบริการเรียกระหว่างชุมสายท้องถิ่นกับชุมสายท้องถิ่นด้วยกัน โดยการเรียกระหว่างโทรศัพท์ 2 เลขหมาย อาจเรียกผ่านไปยังชุมสายต่อผ่านไปยังชุมสายต่อผ่านหลาย ๆ ชุมสายก็ได้โดยผ่านจุดต่อ (Junction) ลักษณะการเชื่อมต่อที่แต่ละชุมสายต่อกัน อาจเป็นแบบใยแมลงมุม (Mesh Shaped) แบบรูปดาว (Star Shaped) และแบบรูปดาวทวิคูณ (Double Star) ดังแสดงตามรูปที่ 2.2 ตัวอย่างการต่อรวมกันของโครงข่ายทั้ง 3 แสดงดังรูปที่ 2.3



(a) ไบแมลงมุม (Mesh) (b) รูปดาว (Star) (c) รูปดาวทวิคูณ (Double Star)

รูปที่ 2.2 ตัวอย่างการต่อโครงข่ายแบบไบแมลงมุม แบบรูปดาว และแบบรูปดาวทวิคูณ




รูปที่ 2.3 ตัวอย่างการต่อรวมกันของโครงข่ายไบแมลงมุม และโครงข่ายรูปดาว โดยมี a เป็นชุมสายลำดับสูงสุด และเป็น Point Of Presence (POP) in U.S network b คือชุมสายท้องถิ่น และ c อาจเป็น ชุมสายโทรศัพท์เคลื่อนที่หรือ สถานีดาวเทียม


จากรูปแบบการต่อเชื่อมโครงข่ายจะเห็นว่า สิ่งสำคัญอย่างหนึ่งในการปฏิบัติการด้านวิศวกรรมโทรศัพท์ คือการกำหนดจำนวนวงจรเชื่อมต่อที่เหมาะสมกับความต้องการในแต่ละเส้นทาง (Route) หรือการเชื่อมต่อระหว่างชุมสาย โดยพิจารณาจาก ทราฟฟิก (Traffic) ที่ทำให้เกิดอัตราการสูญเสียทางการเรียก (Loss call) น้อยที่สุด โดยทราฟฟิกในที่นี้หมายถึงการเรียก (Call) ผ่านโครงข่ายวงจร (Switching Network) ระบบใดระบบหนึ่ง ดังจะกล่าวถึงรายละเอียดในหัวข้อต่อไป

2.3 ทราฟฟิกโทรศัพท์ (Telephone Traffic)

ทราฟฟิก (Traffic) เป็นปริมาณที่บอกการใช้งานในระบบสื่อสารทุกชนิด สำหรับระบบโทรศัพท์ ทราฟฟิก หมายถึงการเรียก (Call) ผ่านโครงข่ายวงจร (Switching Network) ระบบใดระบบหนึ่ง โดยพิจารณาการเรียกในช่วงเวลาต่าง ๆ ถ้าพิจารณาการเรียกในช่วงเวลาสั้น ๆ ในระบบโทรศัพท์ การเปลี่ยนแปลงปริมาณทราฟฟิก (จำนวนการเรียกผ่าน) ที่ดำเนินไปในแต่ละนาทีแสดงตามรูปที่ 2.4 [1] โดยปริมาณทราฟฟิกนี้จะเปลี่ยนแปลงตาม ลักษณะนิสัยของผู้ใช้โทรศัพท์แต่ละคนตั้งแต่เริ่มสนทนาจนจบ



รูปที่ 2.4 การเปลี่ยนแปลงปริมาณทราฟฟิกในช่วงเวลาสั้น (Short - term traffic variation)



รูปที่ 2.5 การเปลี่ยนแปลงเฉลี่ยของทราฟฟิกในระหว่างวัน (Variation during a day)

จากรูปที่ 2.4 ถ้าหาค่าประมาณของค่าการเปลี่ยนแปลงแบบไม่แน่นอนตลอดวัน จะได้จำนวนการเรียกผ่านที่เรียกว่า ทราฟฟิก ที่ดำเนินไปในแต่ละวันแสดงตามรูปที่ 2.5 [1] และตัวอย่างการวัดปริมาณทราฟฟิกของโครงข่ายโทรศัพท์หลัก บนเครือข่ายของบริษัท ทีโอที จำกัด (มหาชน) เส้นทาง ระหว่างอยุธยา S1-กรุงเทพฯ S1 แสดงดังรูปที่ 2.6 จากตัวอย่างที่ยกมานี้ จะเห็นได้ว่าในเวลากลางคืนจะมีการใช้โทรศัพท์น้อยมาก โดยเฉพาะตั้งแต่หลังเที่ยงคืน และจำนวนการใช้

โทรศัพท์ที่จะเพิ่มขึ้นในตอนเช้าเมื่อผู้คนเริ่มต้นขึ้นมาปฏิบัติงาน โดยจะมีค่าสูงสุดในช่วงเวลา 10.00-11.00 น. จากนั้นจำนวนการใช้จะลดลงระหว่างช่วงเวลาหยุดพักรับประทานอาหารกลางวัน และเพิ่มขึ้นอีกในตอนบ่ายเมื่อเริ่มปฏิบัติงานใหม่ และจะลดลงมาเล็กน้อยช่วงเลิกงานระหว่างเดินทางกลับบ้าน จากนั้นจะเพิ่มขึ้นตอนหัวค่ำช่วงเวลา 19.00 น. ถึง 22.00 น. ซึ่งเป็นช่วงเวลาโทรเสวนาทั่วไป จากตัวอย่างการวัดที่แสดงไว้ในรูปที่ 2.5 และ 2.6 เป็นปริมาณทราฟฟิก ซึ่งได้จากการวัดทราฟฟิกของชุมสายในเมืองใหญ่สำหรับเมืองเล็ก ๆ ซึ่งมีประชากรน้อยในช่วงเวลาค่า อาจจะไม่มีการใช้โทรศัพท์เลย

จากที่กล่าวมาล้วนเป็นข้อที่ควรคำนึงถึงในการกำหนดจำนวนวงจรเชื่อมต่อระหว่างชุมสาย และจำนวนอุปกรณ์สวิตซ์ต่าง ๆ ในชุมสายให้เพียงพอ และไม่มากหรือน้อยเกินไป พอสรุปได้ว่าในการพิจารณาทราฟฟิกมีสิ่งที่จะต้องทราบคือ

- จำนวน และประเภทของผู้เช่า
- ปริมาณการใช้โทรศัพท์ในช่วงเวลาต่าง ๆ

เนื่องจากปริมาณทราฟฟิก หรือจำนวนการใช้โทรศัพท์ มีค่าเปลี่ยนแปลงไปตามช่วงเวลาต่าง ๆ ดังนั้น จึงมีข้อตกลงกำหนดมาตรฐานโดย CCITT (Consultative Committee International Telegraph and Telephone) ให้ใช้ค่าทราฟฟิกเฉลี่ยในช่วง (Busy Hour : BH) มากจนอาจเกิดภาวะที่เรียกว่าคับคั่ง (Congestion) เป็นตัวกำหนดมาตรฐานการคำนวณค่าของทราฟฟิก ตามรูปที่ 2.5 ค่าสูงสุดจะอยู่ในช่วงเวลา 10.00-11.00 น. รายละเอียดการคำนวณตามหัวข้อ 2.3.1

2.3.1 หน่วยของการวัดทราฟฟิก (The Unit of Traffic Measurement)

Aner Grasup Erlang นักคณิตศาสตร์ชาวเดนมาร์กได้คิดค้นทฤษฎีเกี่ยวกับทราฟฟิกในระบบสื่อสารขึ้นในปี ค.ศ.1917 โดยกำหนดให้ การเรียกผ่านโครงข่ายใดโครงข่ายหนึ่งตลอดเวลา 1 ชั่วโมง มีค่าทราฟฟิกเท่ากับ 1 Erlang ค่าทราฟฟิกดังกล่าวสามารถคำนวณได้จากสมการที่ 2.1 [8]

$$A = C.T \quad (2.1)$$

- เมื่อ A แทนปริมาณทราฟฟิก (Traffic flow)
 C แทนจำนวนการเรียกในหนึ่งหน่วยเวลา (One hour)
 T แทนเวลาเฉลี่ย (Holding time) ที่ใช้ในการเรียก 1 ครั้ง

โดยกำหนดให้ Holding Time เป็นเวลาที่เริ่มนับตั้งแต่เริ่มต่อวงจรการเรียก จนถึงสิ้นสุดการสนทนาตามมาตรฐานกำหนดค่าเฉลี่ยประมาณ 2.5 นาที หน่วยอื่น ๆ ที่นิยมใช้ในการวัดปริมาณทราฟฟิก คือ CCS (Hundred Call Second) ซึ่งใช้กันอย่างแพร่หลาย สะดวกในการปฏิบัติ และสามารถเปรียบเทียบกันคือ $1 \text{ Erlang} = 36 \text{ CCS}$

จากสมการจะเห็นได้ว่าค่าทราฟฟิกที่เรียกผ่านระบบชุมสายโคชุมสายหนึ่งแปรผันโดยตรงกับจำนวนการเรียก และเวลาเฉลี่ย ที่ใช้ในการเรียก 1 ครั้ง ซึ่งชุมสายหนึ่ง ๆ อาจมีการเรียกออก (Originating Traffic) หรือเรียกเข้า (Terminating Traffic) ผ่านระบบชุมสายนั้นแตกต่างกันนอกจากนี้ยังมีการเรียกภายในชุมสายเดียวกันอีก ซึ่งเหล่านี้ ต่างก็ขึ้นอยู่กับการใช้งานของผู้เช่าในแต่ละพื้นที่

2.3.2 ปัจจัยที่มีผลกระทบต่อปริมาณทราฟฟิก

การที่จะพยากรณ์ปริมาณทราฟฟิกได้อย่างแม่นยำนั้น จะต้องทราบปัจจัยที่มีผลต่อปริมาณทราฟฟิกด้วย ซึ่งปัจจัยโดยทั่วไปที่มีผลกระทบกับปริมาณทราฟฟิกคือ

2.3.2.1 ปัจจัยด้านเวลา

ปัจจัยด้านเวลาที่มีอิทธิพลต่อปริมาณทราฟฟิก ได้แก่ ผลกระทบจากวัฏจักรของแต่ละสัปดาห์หรือของแต่ละวัน วันหยุดนักขัตฤกษ์ และวันหยุดสุดสัปดาห์ เป็นต้น

2.3.2.2 ปัจจัยเศรษฐกิจ และประชากร

สภาวะเศรษฐกิจก็เป็นปัจจัยหนึ่งที่มีผลกระทบ เช่น ในสภาวะเศรษฐกิจกำลังชะลอตัวก็จะทำให้ปริมาณการใช้โทรศัพท์ลดลงด้วย สภาวะเศรษฐกิจดีขึ้นปริมาณการใช้โทรศัพท์ก็เพิ่มขึ้นตาม

2.3.2.3 พื้นที่การให้บริการ

พื้นที่การให้บริการจะมีผลกระทบต่อปริมาณทราฟฟิกมากเนื่องจากพื้นที่ที่มีความหนาแน่นเหมือนกันแต่ประเภทของผู้ใช้ต่างกันก็ทำให้เกิดความคับคั่งของปริมาณทราฟฟิกต่างกันด้วย เช่น พื้นที่ธุรกิจ พื้นที่ศูนย์การค้า พื้นที่อุตสาหกรรม พื้นที่ที่อยู่อาศัย เป็นต้น

2.3.2.4 ปัจจัยเนื่องจากความไม่สม่ำเสมอ หรือความผันแปรแบบสุ่ม


ปัจจัยแบบสุ่ม ที่จะมีผลกระทบต่อปริมาณทราฟฟิก เป็นความผันแปรที่ไม่สามารถพยากรณ์ล่วงหน้าได้ เช่น การเกิดสงคราม การเกิดภัยธรรมชาติ หรือกรณีชุมสายโทรศัพท์ขัดข้อง หรือ BS ขัดข้อง ก็จะทำให้เกิดปริมาณทราฟฟิกที่สูง หรือพื้นที่ข้างเคียงได้

2.3.3 การแจกแจงการเปลี่ยนแปลงปริมาณทราฟฟิก

ถ้าสุ่มตัวอย่างการเปลี่ยนแปลงปริมาณทราฟฟิกตามลักษณะการเกิด โดยปกติแล้วจะแยกเป็นการเปลี่ยนแปลงระหว่างวัน การเปลี่ยนแปลงระหว่างสัปดาห์ และการเปลี่ยนแปลงระหว่างปี ดังตัวอย่างข้อมูลการเปลี่ยนแปลงปริมาณทราฟฟิกที่เก็บบันทึกผ่าน โครงข่ายโทรศัพท์ของบริษัทที่โอที จำกัด (มหาชน) ที่แสดงในรูปที่ 2.6 รูปที่ 2.7 และรูปที่ 2.8

2.3.3.1 การเปลี่ยนแปลงระหว่างวัน


จากการบันทึกข้อมูลตลอด 24 ชั่วโมง พบว่าการใช้โทรศัพท์ทั่วไปจะมีมากในช่วงเวลา สำหรับประเทศไทยอยู่ระหว่าง 09 : 00 น. ถึง 14 : 00 น. ยกเว้นบางกรณีที่มีเหตุการณ์สำคัญ ๆ เช่น มีการแข่งขันกีฬา จำนวนการใช้งานลดลงอย่างมาก ดังแสดงในรูปที่ 2.6



รูปที่ 2.6 ตัวอย่างการวัดปริมาณทราฟฟิกระหว่างวันจากโครงข่ายโทรศัพท์หลักของบริษัททีโอที จำกัด (มหาชน) เส้นทาง อยุธยา S1-กรุงเทพมหานคร S1

2.3.3.2 การเปลี่ยนแปลงระหว่างสัปดาห์


การเปลี่ยนแปลงระหว่างสัปดาห์อาจวัดในรูปการเปรียบเทียบจำนวนในการเรียกแต่ละวัน หรือเปรียบเทียบในแต่ละวันในช่วงเวลาใดเวลาหนึ่งก็ได้ ซึ่งปกติในวันทำงานจำนวนการเรียกในช่วงเช้าจะมาก ส่วนวันหยุดจะมีการเรียกน้อย ดังแสดงในรูปที่ 2.7



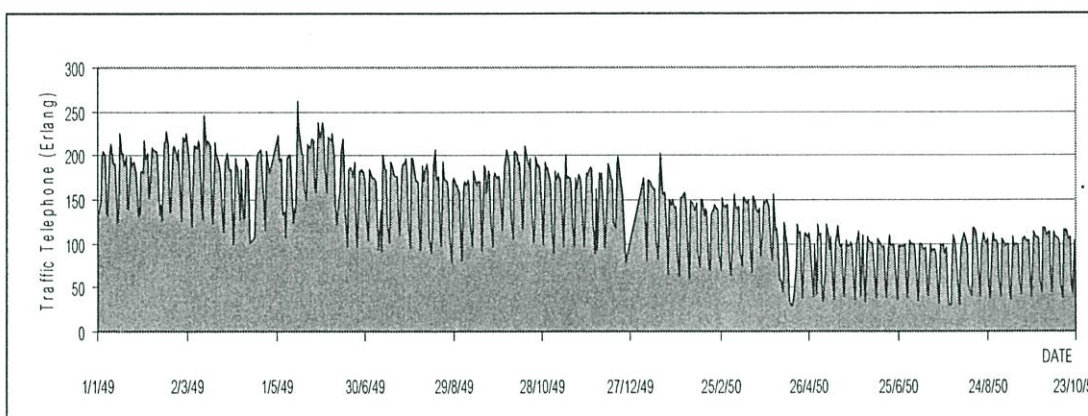
รูปที่ 2.7 ปริมาณทราฟฟิกประจำสัปดาห์ บันทึกตลอดเวลา 1 เดือน เส้นทาง อยุธยา S1-หลักสี่ S1

2.3.3.3 การเปลี่ยนแปลงระหว่างปี

การเปลี่ยนแปลงในระหว่างปี จะสามารถบอกถึงฤดูกาลที่มีผลต่อการเปลี่ยนแปลงมากในช่วงที่เป็นเทศกาลสำคัญ ๆ จำนวนการเรียกจะลดน้อยลง ดังแสดงในรูปที่ 2.8 ซึ่งเป็นช่วงเทศกาลวันสงกรานต์ ซึ่งวันหยุดราชการ สำหรับรูปที่ 2.9 แสดงปริมาณทราฟฟิกในระหว่างปี 2550 เส้นทาง เชียงใหม่ S1- กรุงเทพมหานคร S1



รูปที่ 2.8 การเปรียบเทียบปริมาณการใช้โทรศัพท์ระหว่างปี เปรียบเทียบ 3 ปี เส้นทาง อูธรยา S1-หลักสี่ S1



รูปที่ 2.9 ทราฟฟิกโทรศัพท์ เส้นทาง เชียงใหม่ S1- กรุงเทพมหานคร S1 บันทึกตลอดปี 2550

2.3.4 ค่าการสูญเสียเออแลงบี (Erlang B loss)

ในการหาจำนวนวงจรเชื่อมต่อ ที่ต้องใช้ในเส้นทางการติดต่อ นั้น มีการคำนวณได้หลายรูปแบบบนพื้นฐานของชั่วโมงที่มีการใช้โทรศัพท์สูงสุด โดยพิจารณาปัจจัยที่เกี่ยวข้องอยู่ 4 อย่าง ได้แก่

1. การเรียกเข้า และการกระจายของ Holding Time
2. จำนวนที่มาหรือแหล่งกำเนิดทราฟฟิก
3. ความพร้อมที่จะใช้งานของอุปกรณ์
4. การปฏิบัติต่อการเรียกที่สูญเสีย

ตามสูตรคำนวณปกติที่นิยมใช้มาก ได้แก่ สูตรการสูญเสียเออแลงบี (Erlang B loss Formula) ซึ่งการสูญเสียนี้หมายถึงความเป็นไปได้ที่จะกำจัด หรือยกเลิกการเรียกเนื่องจากการเรียกที่มากเกินไป หรือสายผ่านทั้งหมดถูกใช้งานสูงสุด [8] ปัจจัยหลัก 2 ประการของสูตรนี้ได้แก่ค่าเฉลี่ยของทราฟฟิกที่เสนอให้ (Offer Traffic) และจำนวนสายผ่าน หรือช่องสัญญาณที่พร้อมให้บริการ ดังความสัมพันธ์ที่แสดงในสมการที่ (2.2)

$$EB = \frac{A^n / n!}{1 + A - A^2 / 2! + \dots + A^n / n!} \quad (2.2)$$

โดยที่ n คือจำนวนสายผ่านหรือช่องสัญญาณที่จะบริการ

A คือค่าเฉลี่ยของทราฟฟิกที่เสนอให้

EB คือเกรดของบริการโดยใช้สูตรการสูญเสีย เออแลงบี ภายใต้เงื่อนไขที่ว่า แหล่งกำเนิดมีจำนวนมากจนนับไม่ได้ มีการยกเลิกการเรียกที่สูญเสีย สายผ่านหรือช่องสัญญาณ บริการมีจำนวนจำกัด และมีบางสายผ่านหรือบางช่องสัญญาณพร้อมที่จะให้บริการ

2.3.5 การจัดหาจำนวนอุปกรณ์ และจำนวนวงจร

ในการกำหนดจำนวนอุปกรณ์สวิตซ์ซิง และสายผ่านต่าง ๆ จะขึ้นอยู่กับปริมาณของทราฟฟิกที่เกิดขึ้นในช่วงที่มีการใช้ทราฟฟิกสูงสุดเป็นสำคัญ การจัดการอุปกรณ์เหล่านี้ต้องมีจำนวนที่เหมาะสม โดยไม่จำเป็นต้องจัดหาอุปกรณ์ต่าง ๆ ให้สามารถรองรับทราฟฟิกในช่วงช่วงที่มีการใช้สูงสุดได้ทั้งหมด เนื่องจากในช่วงเวลาอื่น ๆ อุปกรณ์เหล่านี้จะไม่ได้ถูกใช้งาน เป็นการสิ้นเปลืองมากเกินไป ดังนั้นในการกำหนดอุปกรณ์ต่าง ๆ เหล่านี้มีสิ่งที่จะต้องคำนึงถึงอยู่หลายประการได้แก่

1. เกรดของบริการ (Grade of Service)
2. อัตราการเรียกของผู้เช่า (Subscriber's Calling Rate)
3. การเรียกที่มากเกินไป (Call Congestion)

2.4 อัตราการเรียกไม่ผ่าน (Blocking probability)

ความน่าจะเป็นของการเรียกติดขัด (Blocking probability) เนื่องจากการเรียกขอบริการ (Offered call) ในช่วงชั่วโมงใช้โทรศัพท์ที่สูงสุด (Busy hour) มากเกินทรัพยากร เช่น สายผ่านในเส้นทางต่าง ๆ ที่จัดไว้ด้วยจำนวนจำกัด การเรียกที่เกินจำนวนดังกล่าว คือการเรียกไม่ได้ (Lost call) โดยแสดงทางสมการคณิตศาสตร์ได้ ดังนี้ [8]

$$B = \frac{X_L}{X_O} \quad (2.3)$$

$$X_O = X_C + X_L \quad (2.4)$$

เมื่อ B = ความน่าจะเป็นของการเรียกติดขัด

X_L = ทราฟฟิกไม่ได้บริการหรือ การเรียกไม่ได้

X_O = ทราฟฟิกขอบริการหรือการเรียกขอบริการ

X_C = ทราฟฟิกได้บริการหรือการเรียกได้บริการ (carried calls) จะได้

$$B = 1 - \frac{X_c}{X_o} \quad (2.5)$$

หรือเมื่อต้องการหาการเรียกได้บริการ ได้ดังนี้

$$X_c = X_o(1 - B) \quad (2.6)$$

2.5 ประสิทธิภาพ (Efficiency)

การหาประสิทธิภาพ เช่น ชั้นของบริการ (Grade Of Service : GOS) จากความน่าจะเป็นของการเรียกติดขัด (Blocking probability, B) หนึ่งในร้อย คือ 1 เปอร์เซนต์

การหาประสิทธิภาพของวงจร (η) หาได้จากอัตราส่วนของทราฟฟิกได้บริการต่อจำนวนวงจรที่ทราฟฟิกได้บริการผ่าน คูณด้วยร้อย มีหน่วยเป็นเปอร์เซนต์

$$\eta = \frac{X_c}{n} \times 100(\%) \quad (2.7)$$

เมื่อ X_c = ทราฟฟิกได้บริการ

n = จำนวนวงจรที่ทราฟฟิกได้บริการผ่านภายใต้ชั้นบริการที่กำหนดให้จะพบว่า

“ประสิทธิภาพวงจรของทราฟฟิกแพ็กเก็ตใหญ่จะดีกว่าของทราฟฟิกแพ็กเก็ตเล็ก”

2.6 ชั้นของบริการ (Grade of Service : GOS)

ชุมสายโทรศัพท์ท้องถิ่นต่าง ๆ ในพื้นที่เขตเมือง ๆ หนึ่งที่ติดตั้งสายผู้เช่าเพิ่มขึ้นอย่างต่อเนื่อง ระยะเวลาหนึ่งจนผู้ใช้เริ่มบ่นว่าเรียกไม่ได้มากกว่าเดิม ทำให้ผู้บริหารสั่งให้ดำเนินการตรวจสอบทุกชุมสาย ในชั่วโมงใช้โทรศัพท์สูงสุด ได้ตัวเลขความน่าจะเป็นของการติดขัดต่าง ๆ กัน ความน่าจะเป็นของการติดขัด 3 ครั้ง ในการเรียก 100 ครั้ง คิดเป็นอัตราการเรียกไม่ติดดังสมการที่ (2.8)

$$\text{อัตราการเรียกไม่ติด} = \frac{\text{การเรียกไม่ได้}}{\text{การเรียกขอบริการ}} = \frac{(\text{lost call})}{(\text{offered call})} = \frac{X_L}{X_O} = \frac{3}{100} \quad (2.8)$$

โดยอัตราการเรียกไม่ติดนี้ สามารถตรวจสอบจากชุมสายท้องถิ่นต่าง ๆ มาได้หลายค่านำมาเทียบกัน การเรียกไม่ได้น้อยกว่าจะดีกว่า ในการเรียกขอบริการ 100 ครั้ง ด้วยกันในชั่วโมงใช้โทรศัพท์สูงสุด จึงจัดเป็นชั้นของบริการ (Grade of Service) ได้เช่น 1/100, 2/100, 5/100 หรือ 0.01, 0.02, หรือ 0.05 ตามลำดับ [8]

ตารางที่ 2.1 ตัวอย่างการคำนวณ เกรดของบริการ (Grade of Service)

ปริมาณทราฟฟิก						
จำนวน สายผ่าน	เกรดของ บริการ 0.1%	เกรดของ บริการ 0.2%	เกรดของ บริการ 0.5%	เกรดของ บริการ 1%	เกรดของ บริการ 2%	เกรดของ บริการ 5%
1	0.001	0.002	0.005	0.01	0.02	0.05
2	0.05	0.07	0.11	0.15	0.22	0.38
3	0.19	0.25	0.35	0.46	0.6	0.9
4	0.44	0.53	0.7	0.87	1.09	1.52
5	0.76	0.9	1.13	1.36	1.66	2.22
6	1.15	1.33	1.62	1.91	2.28	2.96
7	1.58	1.8	2.16	2.5	2.94	3.74
8	2.05	2.31	2.73	3.13	3.63	4.54
9	2.56	2.85	3.33	3.78	4.34	5.37
10	3.09	3.43	3.96	4.16	5.08	6.22
11	3.65	4.02	4.61	5.16	5.84	7.08
12	4.23	4.64	5.28	5.88	6.62	7.95
13	4.83	5.27	5.96	6.61	7.41	8.83
14	5.45	5.92	6.66	7.35	8.2	9.73
15	6.08	6.85	7.38	8.11	9.01	10.63
16	6.72	7.26	8.1	8.87	9.83	11.54
17	7.38	7.95	8.83	9.65	10.66	12.46
18	8.05	8.64	9.58	10.44	11.49	13.38
19	8.72	9.35	10.33	11.23	12.33	14.31
20	9.41	10.07	11.09	12.03	13.18	15.25
21	10.11	10.79	11.86	12.84	14.04	16.19
22	10.81	11.53	12.63	13.65	14.9	17.13
23	11.52	12.27	13.42	14.47	15.76	18.08
24	12.24	13.01	14.2	15.29	16.63	19.03
25	12.97	13.76	15	16.12	17.5	19.99
26	13.7	14.52	15.8	16.96	18.38	20.94
27	14.44	15.28	16.6	17.8	19.26	21.9
28	15.18	16.05	17.41	18.64	20.15	22.87
29	15.93	16.83	18.22	19.49	21.04	23.83
30	16.68	17.61	19.03	20.34	21.93	24.8

2.7 การแจกแจงความน่าจะเป็น (Probability distribution) ของปริมาณกราฟฟีก

โดยทั่วไปการแจกแจงความน่าจะเป็นของปริมาณใด ๆ สามารถแสดงได้ด้วยพารามิเตอร์ 2 อย่าง คือ

- แจกแจงโดยใช้ค่าเฉลี่ย (Mean) ของปริมาณนั้น ๆ และค่าการเปลี่ยนแปลง (Variance)
- แจกแจงโดยค่าการกระจัดกระจาย (Dispersion) ของปริมาณนั้น


สำหรับค่าปริมาณกราฟฟีกของการเรียกเข้า และการเรียกออก ณ ชุมสายใด ๆ โดยพื้นฐานพบว่าสอดคล้องกับการแจกแจงความน่าจะเป็นของ Poisson [1] โดย ได้นำเสนอการแจกแจงความน่าจะเป็นด้วยอัตราส่วนของค่าการเปลี่ยนแปลงต่อค่าเฉลี่ย (The Variance-to-Mean Ratio : VMR) เรียกว่าค่า Coefficient of over dispersion แสดงด้วยสูตรในสมการที่ (2.9)

$$\text{(Variance to Mean Ratio ; VMR)} \quad \alpha = \frac{\sigma^2}{\bar{X}} \quad (2.9)$$

โดยที่ สูตรการหาค่า เบี่ยงเบนมาตรฐาน (Standard Deviation : STD) ของข้อมูลกราฟฟีก

$$\sigma = \sqrt{\left\{ \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \right\}} \quad (2.10)$$

$$\text{การหาค่าความแปรปรวน Variance} = \text{STD}^2 \text{ หรือ } \sigma^2 = \left(\frac{1}{n-1} \right) \sum_{i=1}^n (X_i - \bar{X})^2 \quad (2.11)$$



รูปที่ 2.10 ค่าเบี่ยงเบนมาตรฐาน และค่าเฉลี่ยของกราฟฟีก

บทที่ 3

ทฤษฎีที่ใช้คาดการณ์

เนื้อหาในบทนี้ เป็นการศึกษาความเคลื่อนไหวหรือพฤติกรรมของข้อมูลอนุกรมเวลา เพื่อสร้างตัวแบบ (Model) สำหรับพยากรณ์ค่าอนุกรมเวลาเพื่อจะคาดการณ์การเปลี่ยนแปลงปริมาณ ทรานซิปทฤษฎีที่เกี่ยวข้องกับการพยากรณ์อนุกรมเวลา แบ่งย่อยออกได้หลายวิธี แต่จะกล่าวถึง เฉพาะที่ใช้เพื่อจะคาดการณ์การเปลี่ยนแปลงปริมาณ ทรานซิป ในบทวิจัยนี้ คือ

1. วิธีอนุกรมเวลากำลังสองน้อยสุด (Least-square method)
2. เทคนิคการทำให้เรียบ (Smoothing Method)
3. การพยากรณ์โดยใช้โครงข่ายประสาทเทียม (Artificial Neural Networks) แบบ แพร่กระจายย้อนกลับ (Backpropagation Neural Networks)

3.1 วิธีอนุกรมเวลากำลังสองน้อยสุด (Least-square method, LSM)

การสร้างเส้นแนวโน้มด้วยวิธีกำลังสองน้อยสุด (Least - square method) [4] เป็นวิธีที่นิยม ใช้กันมากในการหาสมการแนวโน้ม ทำได้โดยการสร้างสมการคณิตศาสตร์ วิธีนี้ผู้สร้างหรือผู้พยากรณ์ จะต้องตัดสินใจในการเลือกแบบ หรือเลือกสมการแนวโน้ม และมีจำนวนข้อมูลมากพอที่จะวิเคราะห์ วิธีกำลังสองน้อยสุดนี้เป็นวิธีการหาค่าแนวโน้มที่ให้ผลรวมของผลต่างระหว่างค่าข้อมูลที่เก็บมาได้ (Y) กับค่าแนวโน้ม (\hat{Y}) ยกกำลังสอง หรือค่ากำลังสองของส่วนเบี่ยงเบนที่วัดตามแนวตั้งฉากของ ข้อมูล ไปยังเส้นแนวโน้มรวมตัวกันจะมีค่าน้อยที่สุด หรือ $\sum (Y - \hat{Y})^2$ มีค่าน้อยที่สุด (Least - square error) และการจะทราบว่าข้อมูลอนุกรมเวลาชุดใดมีแนวโน้มลักษณะใด วิธีการหนึ่งคือให้นำข้อมูลดังกล่าวนั้น มาเขียนเป็นแผนภาพการกระจาย (Scatter - diagram) ซึ่งจะเป็นตัวบอกว่า ข้อมูลอนุกรมเวลามีแนวโน้มในลักษณะใดลักษณะหนึ่งได้ เช่น แนวโน้มแบบเส้นตรง แนวโน้มแบบพาราโบลา หรือแบบโพลีโนเมียลกำลังสอง เป็นต้น ข้อดีของวิธีกำลังสองน้อยที่สุดคือ ค่าแนวโน้มที่ได้จะเป็นตัวแทนที่ดีที่สุดของอนุกรมเวลาชุดนั้น เพราะผลรวมของผลต่างระหว่างค่าจริง (Y) กับค่าแนวโน้ม (\hat{Y}) ยกกำลังสองมีค่าน้อยกว่าวิธีอื่น ๆ

หลักการสร้างสมการแนวโน้มด้วยวิธีกำลังสองน้อยที่สุดนั้น จะต้องประมาณค่าคงที่ใน สมการแนวโน้ม (\hat{Y}) ดังต่อไปนี้คือ

กำหนดให้ Y_t เป็นค่าจริงของข้อมูลที่เก็บรวบรวมมาได้ตัวที่ t

\hat{Y}_t เป็นค่าแนวโน้มของข้อมูลตัวที่ t

X_t หน่วยเวลาของข้อมูลตัวที่ t

n เป็นจำนวนข้อมูลอนุกรมเวลาทั้งหมด เมื่อ $t = 1, 2, 3, \dots, n$
 จากคุณสมบัติกำลังสองน้อยที่สุด (Least - square error) จะได้ว่า $\sum_{t=1}^n (Y_t - \hat{Y}_t)$ มีค่าน้อยที่สุด
 และในการที่จะให้ $\sum_{t=1}^n (Y_t - \hat{Y}_t)^2$ มีค่าน้อยที่สุด จะทำได้โดย การหาค่าอนุพันธ์ย่อย (Partial
 derivative) เทียบกับค่าคงที่ในสมการแนวโน้ม (\hat{Y}) และให้ผลจากการหาค่าอนุพันธ์ย่อยเท่ากับศูนย์
 ซึ่งจะได้สมการที่มีจำนวนเท่ากับค่าคงที่ สมการนี้เราเรียกว่าสมการปกติ (Normal equation) ดังนั้น
 เราจะได้สมการปกติที่ใช้ประมาณค่าคงที่ ซึ่งขึ้นอยู่กับว่าสมการแนวโน้ม (\hat{Y}) มีรูปร่างแบบใด
 สมการแนวโน้มที่เป็นสมการเส้นตรง และรูปสมการคือ

$$\hat{Y} = a + bX \quad (3.1)$$

เมื่อ a และ b เป็นค่าคงที่ จะได้สมการปกติดังต่อไปนี้

$$\sum Y = na + b\sum X \quad (3.2)$$

$$\sum XY = a\sum X + b\sum X^2 \quad (3.3)$$

หรือค่า

$$a = \bar{Y} - b\bar{X} \quad \text{และ}$$

$$b = \frac{\sum XY - n\bar{X}\bar{Y}}{\sum X^2 - n\bar{X}^2} \quad (3.4)$$

3.2 เทคนิคการทำให้เรียบ (Smoothing Method)

การพยากรณ์แบบนี้ ค่าพยากรณ์ในอนาคตจะขึ้นอยู่กับค่าสังเกต ในอดีตที่มีการให้น้ำหนัก (Weight) กับค่าสังเกตในอดีตที่ต่างออกไป เช่น กรณีที่ ให้น้ำหนัก กับค่าสังเกตไม่เท่ากันหมดทุกค่า จะเรียกว่าวิธีการเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก (Weight average method) และกรณีการให้ค่าสังเกตลดหลั่นกันแบบเอกซ์โพเนนเชียล (Exponential) หรือจะเรียกว่าวิธีการทำให้เรียบแบบเอกซ์โพเนนเชียลอย่างง่าย (Simple exponential smoothing method)

การพยากรณ์ด้วย การทำให้เรียบแบบเอกซ์โพเนนเชียลอย่างง่าย (Simple exponential smoothing) [4] เป็นวิธีการคำนวณที่เหมาะสมกับข้อมูลที่มีการเปลี่ยนแปลง หรือการเคลื่อนไหวอยู่ในระดับคงที่ (Horizontal data) หรือข้อมูลที่ไม่มีแนวโน้ม และไม่มีความผันแปรตามฤดูกาล มีเฉพาะความผันแปรเนื่องจากเหตุการณ์ที่ผิดปกติอย่างเดียว และเป็นวิธีการที่เหมาะสมสำหรับการพยากรณ์ในระยะสั้นที่

ทันใด และในระยะสั้น สำหรับจำนวนข้อมูลที่เหมาะสมที่จะใช้วิธีนี้จะมีข้อมูลอย่างน้อย 5 รายการ ถึง 10 รายการ การทำให้เรียบแบบเอ็กซ์โพเนนเชียลอย่างง่าย ค่าพยากรณ์จะคำนวณได้จากข้อมูลที่ผ่านมาทั้งหมด โดยมีการใช้น้ำหนักหรือความสำคัญของข้อมูลแต่ละค่าไม่เท่ากัน การใช้น้ำหนักจะให้กับค่าที่เกิดขึ้นล่าสุด (Y_t) มีค่ามากที่สุด และลดหลั่นกันไปในลักษณะของเอ็กซ์โพเนนเชียล สำหรับค่าสังเกตที่อยู่ห่างออกไปคือ (Y_{t-1}, Y_{t-2}, \dots) ส่วนน้ำหนักที่ให้จะขึ้นอยู่กับค่าคงที่การทำให้เรียบ (Smoothing constant, α) หรือบางทีก็เรียกว่า ค่าสัมประสิทธิ์ทำให้เรียบ (Smoothing coefficient) โดยที่มีค่า ระหว่าง 0 กับ 1 ($0 \leq \alpha \leq 1$) ในทางปฏิบัตินิยมใช้สูตรดังนี้

$$\hat{Y}_{t+1} = \alpha Y_t + (1 - \alpha) \hat{Y}_t \quad (3.5)$$

การใช้สูตรนี้จะมีปัญหา 2 อย่างคือการกำหนดค่าเริ่มต้นของการพยากรณ์ (\hat{Y}_{ini}) เพื่อจะหาค่าพยากรณ์ตัวถัดไป และการกำหนดค่า α ซึ่งในทางปฏิบัติเรามีวิธีการแก้ปัญหาค่าเริ่มต้นของการพยากรณ์ดังนี้

กำหนดให้ $\hat{Y}_{ini} = \hat{Y}_1 = Y_1$ จะทำให้หาค่าพยากรณ์ (\hat{Y}_t) สำหรับ $t = 2, 3, 4, \dots$ ได้

$\hat{Y}_{ini} = \bar{Y} =$ ค่าเฉลี่ยของข้อมูลทั้งหมด

$\hat{Y}_{ini} = \hat{Y}_1 = \bar{Y} =$ ค่าเฉลี่ยของกราฟฟิคโทรศัพท์ที่จัดเก็บมาใช้ในการพยากรณ์

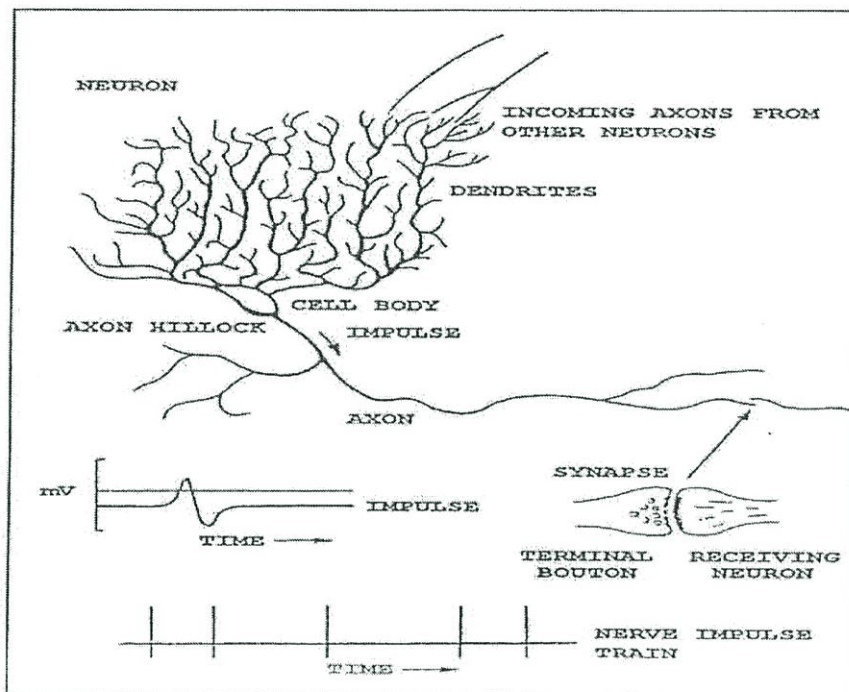
ส่วนค่า α นั้นผู้พยากรณ์เป็นผู้กำหนดเองได้ หรืออาจจะใช้ค่า α ที่ทำให้ค่า SSE หรือ MSE หรือ RMSE มีค่าต่ำที่สุดก็ได้

3.3 การพยากรณ์โดยใช้โครงข่ายประสาทเทียม (Artificial Neural Networks)

โครงข่ายประสาทเทียม (Artificial Neural Networks) เป็นแขนงหนึ่งของระบบปัญญาประดิษฐ์ (Artificial Intelligence) โดยมีโครงสร้างและการทำงานคล้ายกับระบบประสาทของมนุษย์ แนวความคิดทฤษฎีโครงข่ายประสาทเทียม ได้แก่ การนำข้อดีของระบบประสาทมาใช้ในการทำงานร่วมกับความสามารถของคอมพิวเตอร์ เช่น ความสามารถเรียนรู้จากประสบการณ์ การจำแนกลักษณะสิ่งของที่มีคุณลักษณะใกล้เคียงกัน และการแปลความหมายของสัญลักษณ์ และภาพ (Hebb, 1958) และงานอีกประเภทหนึ่งที่น่าวิธีโครงข่ายประสาทเทียมมาใช้ คือ งานด้านการพยากรณ์ Delurgio (1998) กล่าวว่า วิธีโครงข่ายประสาทเทียมสามารถเรียนรู้รูปแบบของระบบที่มีความซับซ้อนสูง และหาค่าพยากรณ์จากข้อมูลในอดีตได้ดีกว่าวิธีการพยากรณ์แบบดั้งเดิม (Traditional Statistical Method)

3.3.1 ความรู้เบื้องต้นเกี่ยวกับโครงข่ายประสาท

ระบบคิดคำนึงของมนุษย์ มีโครงสร้างพื้นฐานจากเซลล์สมองที่เรียกว่าเซลล์ประสาท (Neurons) เรียงเป็นชั้น ๆ อย่างซับซ้อนจำนวนมหาศาล ประมาณ 1011 เซลล์ประสาท และอาจมีจุดเชื่อมโยงส่งผ่านจุดเชื่อมโยงภายในถึง 1015 จุด แต่ละเซลล์ประสาทจะมีคุณลักษณะแตกต่างกันออกไปโดยมีการทำงานคล้ายกัน ดังรายละเอียดในรูปที่ 3.1



รูปที่ 3.1 โครงสร้างของเซลล์ประสาทชีวภาพ

รูปที่ 3.1 แสดงโครงสร้างทางชีวภาพของเซลล์ประสาท การทำงานของเซลล์ประสาท จะเริ่มจากเซลล์ประสาทรับอินพุต (Input) จากเซลล์ประสาทตัวอื่น ผ่านจุดเชื่อมโยงที่เรียกว่าไซแนป (Synapse) สัญญาณข้อมูลจาก ไซแนป จะถูกส่งผ่านเข้าทาง เดนไดรต์ (Dendrite) ซึ่งเป็นส่วนที่ทำหน้าที่เป็นตัวรับข้อมูลอินพุตเข้าสู่ตัวเซลล์ (Cell Body) สัญญาณอินพุตจะถูกประมวลผล บางประการตามกระบวนการที่เกิดขึ้นภายในเซลล์ และส่งสัญญาณเอาต์พุต (Output) ออกจากส่วนของเซลล์ที่เรียกว่า แอกซอน (Axon) สัญญาณดังกล่าวจะผ่านข้าม ไซแนป ด้วยเงื่อนไขบางประการ ซึ่งเป็นส่วนอินพุตของเซลล์อื่นต่อไป [8] ลักษณะโดยทั่วไปของส่วนประกอบ และโครงสร้างของเซลล์ประสาท

จากผลการวิจัย[8]พบว่าแต่ละเซลล์ประสาท จะเชื่อมต่อออกไปยังเซลล์ประสาทอื่น ๆ ซึ่งแต่ละเซลล์ประสาทจะมีคุณสมบัติในการเพิ่มหรือขยายหรือลดทอนความเข้มของสัญญาณบางสัญญาณ ที่เข้ามาทางเดนไดรต์ของเซลล์ (ซึ่งมีสาขามากมาย) อาจสามารถกระตุ้นตัวเซลล์ซึ่งมีเดนไดรต์มาก ฉะนั้น สัญญาณกระตุ้นจากเดนไดรต์ที่รับเข้ามาจากเซลล์ประสาทอื่น ๆ จะถูกนำมารวมกันที่ตัว

เซลล์ประสาท และที่เซลล์ประสาทจะมีค่าเทรชโฮลด์ (Threshold) ค่าหนึ่งหากผลรวมของสัญญาณไฟฟ้าเคมี (Electrochemical) มีค่ามากกว่าเทรชโฮลด์ เซลล์ประสาทก็จะส่งสัญญาณขนาดหนึ่งผ่านทางแอกซอนไปยังนิวรอลอื่น ๆ การจัดเรียงชั้น (Layer) และลักษณะการเชื่อมโยงระหว่างเซลล์ประสาทในสมองนั้นมีการจัดเรียงที่ซับซ้อน สอดคล้องกับหน้าที่การทำงานเฉพาะส่วน มีการเจริญเติบโตสัมพันธ์กับสิ่งแวดล้อม และมีการเรียนรู้ตลอดเวลาซึ่งใช้เวลานานนับปี ดังนั้น จึงยากที่จะสร้างโมเดลขึ้นมาเพื่อเลียนแบบให้มีคุณลักษณะคล้ายสมองชีวภาพได้ทั้งหมด ผลงานที่ได้จากการทำวิจัยในปัจจุบันเป็นเพียงการจำลอง และเลียนแบบการทำงานเฉพาะบางส่วนของโครงข่ายประสาทมาใช้โดยเรียกว่าโครงข่ายประสาทเทียม (Artificial Neural Networks) ซึ่งมีการวิจัยลักษณะของโครงข่ายในรูปแบบต่าง ๆ ขึ้นมา โดยแต่ละแบบจะเหมาะกับงานประเภทหนึ่ง ๆ เท่านั้น โครงข่ายประสาทเทียมมีคุณลักษณะคล้ายกับสมองในโดยที่สามารถรวบรวมความรู้ (Knowledge) ได้ด้วยการผ่านกระบวนการเรียนรู้ (Learning Process) และความรู้เหล่านั้นจะถูกจัดเก็บอยู่ในโครงข่ายด้วยค่าน้ำหนัก (Weight) ซึ่งสามารถปรับเปลี่ยนค่าได้เมื่อมีการเรียนรู้สิ่งใหม่เข้ามา

3.3.2 คุณลักษณะทั่วไปของโครงข่ายประสาท

3.3.2.1 การประมวลผลต่าง ๆ เกิดขึ้นในหน่วยประมวลผลย่อยเรียกว่า โหนด (Node) ซึ่งจำลองลักษณะการทำงานมาจากตัวเซลล์


3.3.2.2 การส่งสัญญาณ (Signal) ต่าง ๆ ระหว่าง โหนด โดยส่วนที่เชื่อมต่อกัน (Connection Link) จำลองมาจากการเชื่อมต่อกันของเดนไดรต์ และแอกซอนในระบบประสาทของมนุษย์

3.3.2.3 แต่ละการเชื่อมต่อจะมีค่าน้ำหนัก (Weight) ที่ต่างกันขึ้นอยู่กับอิทธิพลที่โหนดจะได้รับจากโหนดอื่น ๆ ซึ่งจำลองมาจากไซแนปส์ ค่าน้ำหนักที่ได้จะทำหน้าที่เปรียบเสมือนความรู้ที่รวบรวมไว้ใช้ในการแก้ปัญหาเฉพาะอย่างของมนุษย์

3.3.2.4 ภายในโหนดจะมีฟังก์ชันกำหนดสัญญาณเอาต์พุตถูกเรียกว่า Activation function หรือ Transfer Function ซึ่งทำหน้าที่เปรียบเสมือนกระบวนการทำงานในตัวเซลล์ประสาท

3.3.3 แบบจำลองของเซลล์ประสาทเทียม

จากคุณลักษณะที่สำคัญของเซลล์ประสาทหรือนิวรอล (Neuron) ใน (3.3.2) สามารถสร้างแบบจำลองของโครงข่ายประสาทเทียม โดยมีองค์ประกอบ 3 ส่วน ดังรูปที่ 3.2



รูปที่ 3.2 การจำลองโครงข่ายประสาทเทียมในรูปแบบคณิตศาสตร์

3.3.3.1 กลุ่มของการเชื่อมโยงหรือไซแนปส์ การเชื่อมโยงระหว่างเซลล์ประสาท จะถูกควบคุมด้วยค่าการเชื่อมโยง โดยกำหนดให้

x_n เป็นข้อมูลที่ป้อนเข้าของไซแนปส์ หรือข้อมูลอินพุตจำนวน n อินพุต ที่ป้อนให้กับเซลล์ประสาท ในชั้น k

w_{kn} คือค่าการเชื่อมโยง ข้อมูลป้อนเข้า ซึ่งถูกคูณด้วยค่าการเชื่อมโยง w_{kn} โดยค่า w_{kn} มีเครื่องหมายเป็นบวกหมายถึงการกระตุ้นเสริม และค่าลบหมายถึงการกระตุ้นแบบหักล้าง

3.3.3.2 ตัวบวก (Summation หรือ Adder) สำหรับรวมข้อมูลที่คูณด้วยค่าการเชื่อมโยงแล้ว เราเรียกว่า การรวมแบบเชิงเส้น (Linear combiner)

3.3.3.3 ฟังก์ชัน Activation เพื่อจำกัดช่วงข้อมูลป้อนออกหรือเอาต์พุตให้อยู่ในช่วงที่ต้องการ

จากรูปที่ 3.2 สามารถอธิบายนิเวศ k อยู่ในรูปสมการได้ด้วยสมการ 2 สมการคือ

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (3.6)$$

$$y_k = g(u_k - \theta_k) \quad (3.7)$$

เมื่อ $x_1, x_2, x_3, \dots, x_n$ คือจำนวนข้อมูลที่ป้อนให้โครงข่าย

$w_{k1}, w_{k2}, w_{k3}, \dots, w_{kn}$ คือค่าการเชื่อมโยงของ นิเวศ ในชั้น k


u_k คือข้อมูลส่งออกภายในนิเวศ (Internal output) หรือข้อมูลป้อนเข้าสุทธิ (net_k)

θ_k คือค่าขีดจำกัด (Threshold หรือ Bias หรือ Offset) ซึ่งรับมาจากภายนอก

$g(\cdot)$ คือฟังก์ชันแอคทิเวชัน

y_k คือข้อมูลส่งออกหรือเอาต์พุต

โดยการป้อนค่าขีดจำกัดให้กับนิวรอนจะได้ความสัมพันธ์ระหว่างระดับแอกทิเวชันภายใน (Internal activity level หรือ Internal activation potential) ค่าขีดจำกัด และข้อมูลป้อนเข้า แสดงดังรูปที่ 3.3 และสมการที่ (3.8)



รูปที่ 3.3 ผลของค่าขีดจำกัด

$$v_k = u_k - \theta_k \quad (3.8)$$

โดยที่ v_k คือระดับแอกทิเวชันภายใน

จากโครงสร้างทางชีวภาพของเซลล์ประสาท และแบบจำลองเซลล์ประสาทเทียม ซึ่งเป็นแบบจำลองทางคณิตศาสตร์ที่ประดิษฐ์ขึ้นมา สามารถเปรียบเทียบได้ ดังตารางที่ 3.1 [9-11]

ตารางที่ 3.1 เปรียบเทียบระหว่างนิวรอนธรรมชาติ และแบบจำลองที่ประดิษฐ์ขึ้น

ลำดับ	นิวรอนธรรมชาติ	แบบจำลองนิวรอนที่ประดิษฐ์ขึ้น
1	โซมา	ส่วนประมวลผล (ตัวรวม และฟังก์ชันแอกทิเวชัน)
2	เดนไดรต์	ข้อมูลป้อนเข้า
3	แอกซอน	ข้อมูลส่งออก
4	ไซแนปส์	ค่าการเชื่อมโยง
5	ความเร็วในการประมวลผลต่ำ	ความเร็วในการประมวลผลสูง
6	โครงข่ายมีนิวรอนจำนวนมาก	โครงข่ายมีนิวรอนจำนวนน้อย


3.3.4 สถาปัตยกรรมของโครงข่ายประสาทเทียม (Artificial Neural Networks

Architecture)

โครงข่ายประสาทเทียมประกอบด้วยเซลล์ประสาทเทียมหรือโหนดจำนวนมากที่เชื่อมต่อกัน ซึ่งการเชื่อมต่อนี้จะแบ่งออกเป็นกลุ่มย่อยเรียกว่า ชั้น (Layer) ในชั้นแรกจะเป็นชั้นนำข้อมูลเข้าเรียกว่า ชั้นอินพุต (Input Layer) ส่วนชั้นสุดท้ายเรียกว่าชั้นเอาต์พุต (Output Layer) และชั้นที่อยู่ระหว่างชั้นอินพุต และชั้นเอาต์พุต เรียกว่า ชั้นฮิดเดน (Hidden Layer) ซึ่งชั้นฮิดเดนจะมีมากกว่า 1 ชั้นก็ได้ จึงสามารถแบ่งประเภทโครงข่ายประสาทเทียมตามจำนวนชั้นของโครงข่ายแบบกว้าง ๆ ได้ 2 แบบคือ โครงข่ายแบบชั้นเดียว (Single Layer) และโครงข่ายแบบหลายชั้น (Multi Layer) การนับชั้นของโครงข่ายจะนับเฉพาะชั้นที่มีการประมวลผลเท่านั้น หรืออาจกล่าวได้ว่า จำนวนชั้นของโครงข่าย ประสาทเทียมคือ จำนวนชั้นฮิดเดนรวมกับจำนวนชั้นเอาต์พุต (สุภัทรา สุนทรภักย์, 2539)[12]

3.3.4.1 โครงข่ายแบบชั้นเดียว

โครงข่ายแบบชั้นเดียวเป็นโครงข่ายอย่างง่ายที่มีเพียงชั้นอินพุต และชั้นเอาต์พุตเท่านั้น โหนดในชั้นอินพุตจะทำหน้าที่ในการรับข้อมูลอินพุต (Input Value) แล้วส่งข้อมูลอินพุตผ่านเส้นเชื่อมโยงต่าง ๆ ไปให้โหนดในชั้นเอาต์พุต ความเข้มของสัญญาณหรือปริมาณข้อมูลที่นำเข้าสู่โหนดในชั้นเอาต์พุตจะขึ้นอยู่กับค่าน้ำหนักที่อยู่บนเส้นเชื่อมโยง โหนดในชั้นเอาต์พุตจะนำข้อมูลที่รับมาทำการคำนวณโดยใช้ฟังก์ชันทางคณิตศาสตร์ที่เรียกว่า ทรานสเฟอร์ฟังก์ชัน ที่เหมาะสมกับปัญหา แล้วส่งผลลัพธ์ที่ได้ออกมาเป็นข้อมูลเอาต์พุต ตัวอย่างโครงข่ายแบบชั้นเดียว เช่น เพอเซปตรอนอย่างง่าย (Simple Perceptron) โครงข่ายโฮปฟิลด์ (Hopfield Networks) เป็นต้น ลักษณะโครงสร้างของโครงข่ายแบบชั้นเดียวแสดงดังรูปที่ 3.4




รูปที่ 3.4 ลักษณะโครงสร้างของโครงข่ายแบบชั้นเดียว

3.3.4.2 โครงข่ายแบบหลายชั้น

โครงข่ายแบบหลายชั้นเป็นโครงข่ายที่มีชั้นฮิดเดนตั้งแต่ 1 ชั้นขึ้นไป จะใช้ในกรณีที่มีปัญหาซับซ้อนสูง ซึ่งโครงข่ายแบบชั้นเดียวไม่เพียงพอในการแก้ปัญหา จึงเพิ่มจำนวนของโหนดที่มีการคำนวณหรือชั้นฮิดเดนให้กับโครงข่าย ตัวอย่างของโครงข่ายแบบหลายชั้น เช่น การแพร่แบบ

ย้อนกลับ (Backpropagation) เซลฟออร์แกนไนซิงแมปส์ (Self Organizing Maps) และเคาน์เตอร์พรอพะเกชัน (Counterpropagation) เป็นต้น ลักษณะโครงสร้างของโครงข่ายแบบหลายชั้นแสดงดังรูปที่ 3.5




รูปที่ 3.5 แสดงลักษณะโครงสร้างของโครงข่ายแบบหลายชั้น

3.3.5 ชนิดของฟังก์ชันแอคทิเวชัน

ฟังก์ชันแอคทิเวชันที่แทนด้วย $g(\cdot)$ เป็นตัวกำหนดค่าข้อมูลส่งออกเราอาจแบ่งฟังก์ชันแอคทิเวชันพื้นฐานออกได้เป็น 3 ชนิด คือ

3.3.5.1 ฟังก์ชันเทรสโฮลด์ (Threshold function หรือ Step function) แสดงดังรูปที่ 3.6 โดยมีความสัมพันธ์ดังสมการที่ 3.9

$$g(v) = \begin{cases} 1; & v \geq 0 \\ 0; & v < 0 \end{cases} \quad (3.9)$$



รูปที่ 3.6 ฟังก์ชันเทรสโฮลด์


3.3.5.2 ฟังก์ชันเชิงเส้นอิ่มตัว (Saturating Linear Function หรือ Piecewise-Linear Function) ตัวอย่างของฟังก์ชันแบบนี้ ดังแสดงในรูปที่ 3.7 โดยมีความสัมพันธ์ดังสมการ (3.10)

$$g(v) = \begin{cases} 1; v \geq 0 \\ av; -b < v < b \\ 0; v \leq 0 \end{cases} \quad (3.10)$$

โดยที่ a คือค่าความชัน (Slope) ในช่วงความเป็นเชิงเส้น

b คือช่วงที่เป็นเชิงเส้นของฟังก์ชันเชิงเส้นอิ่มตัว

จากฟังก์ชันเชิงเส้นอิ่มตัวจะสังเกตเห็นได้ว่า เมื่อไม่มีช่วงอิ่มตัว ($b = \infty$) จะได้ฟังก์ชันเชิงเส้น นั่นคือ $g(v) = av$ และฟังก์ชันเชิงเส้นอิ่มตัวจะเปลี่ยนรูปไปเป็นฟังก์ชันเทรสโฮลด์เมื่อค่าความชันเท่ากับอนันต์ ($a = \infty$)




รูปที่ 3.7 ฟังก์ชันเชิงเส้นอิ่มตัว

3.3.5.3 ฟังก์ชันซิกมอยด์ (Sigmoid function) เป็นฟังก์ชันที่ได้รับความนิยมนำมาใช้เป็นฟังก์ชันแอคทิเวชันของโครงข่ายประสาทเทียมกันมาก เนื่องจากเป็นฟังก์ชันที่เพิ่มขึ้นอย่างสม่ำเสมอ (Smoothness) ฟังก์ชันซิกมอยด์ จัดเป็นฟังก์ชันแอคทิเวชันที่ไม่เป็นเชิงเส้น ตัวอย่างของฟังก์ชันซิกมอยด์คือ ฟังก์ชันลอจิสติก (Logistic function) และฟังก์ชันแทนเจนไฮเพอร์โบลิก (Hyperbolic tangent function) ซึ่งมีความสัมพันธ์ดังสมการที่ (3.11) และสมการที่ (3.12)

ฟังก์ชันลอจิสติก
$$g(v) = \frac{1}{1 + \exp(-\lambda v)} \quad (3.11)$$

โดยที่ λ คือค่าความชันของ slop

ฟังก์ชันแทนเจนต์ไฮเปอร์โบลิค
$$g(v) = \tanh\left(\frac{v}{2}\right) = \frac{1 - \exp(-v)}{1 + \exp(-v)} \quad (3.12)$$



รูปที่ 3.8 ฟังก์ชันลอจิสติกที่ค่าความชันต่าง ๆ

ฟังก์ชันแอคทิเวชันพื้นฐานทั้ง 3 ชนิด ที่กล่าวข้างต้นในสมการ (3.9), (3.10), (3.11) จะจำกัดช่วงข้อมูลส่งออกอยู่ตั้งแต่ 0 ถึง +1 ในการประยุกต์ใช้งานบางกรณีอาจมีความจำเป็นต้องใช้ฟังก์ชันที่ได้ค่าออกมาเหนือช่วงดังกล่าว เช่น เมื่อต้องการข้อมูลส่งออกอยู่ในช่วงตั้งแต่ -1 ถึง +1 อาจปรับเปลี่ยนฟังก์ชันพื้นฐานเหล่านี้ ตัวอย่าง เช่น ฟังก์ชันซิกนัม (Signum function) ซึ่งประยุกต์มาจากฟังก์ชันเทรสโฮลด์ มีความสัมพันธ์ดังสมการ

$$g(v) = \begin{cases} 1; v > 0 \\ 0; v = 0 \\ -1; v < 0 \end{cases} \quad (3.13)$$

นอกเหนือจากฟังก์ชันแอกทิเวชันพื้นฐานทั้งสาม แล้วยังสามารถนำความสัมพันธ์ระหว่างชุดข้อมูลในรูปแบบอื่น ๆ มาเป็นฟังก์ชันแอกทิเวชันได้ ตัวอย่างเช่น ฟังก์ชันแอกทิเวชันแบบคอมเพทิทีฟ (Competitive)

$$g(v) = \begin{cases} 1; v_j & \text{คือค่าที่มากที่สุดในกลุ่ม } v_1, v_2, \dots, v_j, \dots, v_n \\ 0; v_j & \text{ไม่ใช่ค่าที่มากที่สุดในกลุ่ม} \end{cases} \quad (3.14)$$

ฟังก์ชันแอกทิเวชันแบบคอมเพทิทีฟนี้จะให้ค่าออกมาเท่ากับหนึ่ง เพียงค่าเดียวเท่านั้นสำหรับ v ที่มากที่สุดจากจำนวนทั้งหมดเท่ากับ n ส่วนค่าอื่น ๆ จะมีค่าเป็นศูนย์

ตัวอย่างการใช้ฟังก์ชันเทรโซลด์เป็นฟังก์ชันแอกทิเวชันของนิวรอล k

$$\text{จะได้ข้อมูลส่งออกดังนี้} \quad y_k = \begin{cases} 1; v_k \geq 0 \\ 0; v_k < 0 \end{cases}$$

เมื่อ v_k คือระดับแอกทิเวชันภายในซึ่งมีค่า

$$v_k = \sum_{j=1}^n w_{kj} x_j - \theta_j$$

สำหรับการพิจารณาเลือกใช้ฟังก์ชันแอกทิเวชันแบบใดนั้น ในปัจจุบันยังไม่มีข้อกำหนดที่แน่นอน แต่อาจจะพิจารณาจากองค์ประกอบดังต่อไปนี้


- 1) ความเป็นเชิงเส้น หรือไม่เชิงเส้น
- 2) ลักษณะของข้อมูลป้อนเข้า
- 3) ขอบเขตที่ต้องการ และลักษณะของข้อมูลส่งออก
- 4) ปัจจัยอื่นที่มีนัยสำคัญต่อผลตอบสนองของโครงข่ายประสาทโดยรวม

โดยบางครั้งอาจเลือกใช้ฟังก์ชันสโตชาสติก (Stochastic function) เป็นฟังก์ชันแบบเชิงเส้นและไม่เป็นเชิงเส้นในโครงข่ายประสาทเดียวกัน ตัวอย่างเช่น โครงข่ายประสาทแบบ RBF (Radial basis function) ซึ่งใช้ฟังก์ชันแอกทิเวชันแบบไม่เป็นเชิงเส้นในชั้นซ่อน (Hidden Layer) ของโครงข่ายประสาท ขณะที่ชั้นข้อมูลส่งออก (Output layer) ใช้แอกทิเวชันแบบเป็นเชิงเส้น

3.3.6 กระบวนการเรียนรู้ของโครงข่ายประสาทเทียม

การเรียนรู้ของโครงข่ายประสาทเทียม เป็นกระบวนการทำให้เกิดความรู้ สามารถกล่าวคือ การเรียนรู้ของโครงข่ายประสาทเทียมเป็นกระบวนการปรับค่าตัวแปรอิสระ (Free parameters) ของโครงข่ายประสาทเทียมเพื่อปรับพฤติกรรมให้สอดคล้องกับการกระตุ้นจากสิ่งแวดล้อม

กระบวนการเรียนรู้ของโครงข่ายประสาทเทียมจึงเป็นกระบวนการทำซ้ำ (Iterative) โดยสามารถลำดับกระบวนการเรียนรู้ได้ดังนี้ คือ เมื่อโครงข่ายประสาทถูกกระตุ้นโดยสิ่งแวดล้อม โครงข่ายจะปรับตัวเพื่อตอบสนองต่อสิ่งที่มากระตุ้น และตอบสนองต่อสิ่งแวดล้อมด้วยภาวะใหม่หลังจากการปรับตัว ซึ่งอาจจะกล่าวถึงกระบวนการเรียนรู้ใน 2 แนวทาง คือ กฎการเรียนรู้ (Learning rules หรือ Learning algorithm) และรูปแบบการเรียนรู้ (Learning pattern หรือ Learning paradigm) ดังโคอะแกรมในรูปที่ 3.9



รูปที่ 3.9 กระบวนการเรียนรู้ของโครงข่ายประสาทเทียม

3.3.6.1 กฎการเรียนรู้

กฎพื้นฐานในการเรียนรู้ของโครงข่ายประสาท [8] จะเกี่ยวกับการเปลี่ยนแปลงเวกเตอร์ค่าการเชื่อมโยง (Connection vector) $w_i = [w_{i1} w_{i2} \dots w_{in}]^T$ โดยที่ $[]^T$ คือการทรานโพส (Transposition) การเปลี่ยนแปลงนั้นจะขึ้นอยู่กับข้อมูลป้อนเข้า x และสัญญาณการเรียนรู้ (Learning signal) l โดยปกติแล้ว l เป็นฟังก์ชันของ w_i และ x แต่ในบางครั้งอาจมีตัวแปรเพิ่มเติมคือสัญญาณควบคุมการเรียนรู้ (Teacher's signal) c_i นั่นคือ

$$\text{สัญญาณการเรียนรู้} \quad l = f(w_i, x, c_i) \quad (3.15)$$

จากพื้นฐานที่กล่าวมาคือ การเปลี่ยนแปลงของเวกเตอร์ของค่าการเชื่อมโยง ณ เวลา t มีความสัมพันธ์ ดังนี้

$$\Delta w_i(t) = \alpha l(t) x(t) = \alpha f[w_i(t), x(t), c_i(t)] x(t) \quad (3.16)$$

โดยที่ α คือค่าคงที่การเรียนรู้ (Learning constant)

ค่าคงที่การเรียนรู้เป็นตัวกำหนดอัตราการเรียนรู้ (Rate of learning) ให้เหมาะสมไม่เร็วหรือช้าเกินไปค่าดังกล่าวนี้จึงมีค่าเป็นบวก (Positive)

เวกเตอร์ของค่าการเชื่อมโยง ณ เวลา $t+1$ เป็นผลจากการเปลี่ยนแปลงค่าการเชื่อมโยง ขั้นตอนการปรับตัวสู่ค่าการเชื่อมโยงใหม่นี้เรียกขั้นตอนนี้ว่า ขั้นตอนการเรียนรู้ (Learning step)

$$w_i(t+1) = w_i(t) + \Delta w_i(t) \quad (3.17)$$

เมื่อนำค่า $w_i(t)$ จากสมการที่ 3.16 มาแทนจะได้

$$w_i(t+1) = w_i(t) + \alpha f[w_i(t), x(t), c_i(t)]x(t) \quad (3.18)$$

เมื่อพิจารณาการปรับค่าเวกเตอร์ของค่าการเชื่อมโยงเป็นกระบวนการทำซ้ำ (Iteration) จากสมการ 3.18 สามารถเขียนได้ดังนี้

$$w_i^{k+1} = w_i^k + \alpha f[w_i^k, x^k, c_i^k]x^k \quad (3.19)$$

สำหรับตัวยก (Superscript) $k+1$ หมายถึง การคำนวณในปัจจุบัน ส่วนตัวยก k คือ การคำนวณในครั้งที่ผ่านมาก่อนหน้านี้ ในการปรับค่าเวกเตอร์ของค่าการเชื่อมโยงนั้น อาจจะเริ่มต้นด้วยการสุ่มค่า (Random) ค่าการเชื่อมโยงที่เหมาะสม ตัวอย่างกฎการเรียนรู้ที่มีชื่อเสียงได้แก่

- 1) กฎการเรียนรู้แบบเฮบบีเยน (Hebbian learning rule)
- 2) กฎการเรียนรู้แบบปรับค่าผิดพลาด (Error correction learning rule)
- 3) กฎการเรียนรู้แบบคอมแพติทีฟ (Competitive learning rule)
- 4) กฎการเรียนรู้แบบโบลท์ซมานน์ (Boltzmann learning rule)

3.3.6.1.1) กฎการเรียนรู้แบบเฮบบีเยน

การเรียนรู้ของ Hebb นับว่าเป็นกฎการเรียนรู้ที่เก่าแก่และมีชื่อเสียง กล่าวไว้ในหนังสือ Organization of Behavior หน้า 62 ซึ่งตีพิมพ์ในปี ค.ศ.1949 จะได้สัญญาณการเรียนรู้เป็นฟังก์ชันของข้อมูลส่งออกของนิวรอลดังนี้

$$I \triangleq f(w_i^T x) \quad (3.20)$$

$$\Delta w_i = \alpha f(w_i^T x)x \quad (3.21)$$

การเปลี่ยนแปลงค่าการเชื่อมโยงแต่ละค่าหาได้จากความสัมพันธ์

$$\Delta w_{ij} = \alpha f(w_i^T x) x_j; j = 1, 2, \dots, n \quad (3.22)$$

จากกฎการเรียนรู้ของเฮบเบียน จะเห็นว่ารูปแบบการเรียนรู้ เป็นแบบไม่มีการควบคุม (Unsupervised) และเป็นแบบป้อนสู่ด้านหน้า สามารถเขียนในรูปย่อได้ดังนี้

$$\Delta w_{ij} = \alpha y_i x_j \quad (3.23)$$

คำดังกล่าวเป็นผลคูณระหว่างข้อมูลป้อนเข้า และข้อมูลส่งออกเราอาจจะเรียกว่า activity product rule ต่อมาในปี ค.ศ.1988 Kohonen ได้เพิ่มพจน์ที่เป็นฟังก์ชันของ w_{ij} เองเพื่อให้การปรับตัวของค่าการเชื่อมโยงให้เป็นอย่างค่อยเป็นค่อยไป สามารถเขียนสมการได้ดังนี้

$$\Delta w_{ij} = \alpha y_i x_j - \beta y_i w_{ij}; j = 1, 2, \dots, n \quad (3.24)$$

โดยที่ β คือค่าคงที่การเรียนรู้อีกค่าหนึ่ง

จากสมการที่ 3.19 สามารถจัดรูปแบบได้ใหม่ดังนี้

$$\Delta w_{ij} = \alpha y_i [\gamma x_j - w_{ij}]; \gamma = \frac{\beta}{\alpha} \quad (3.25)$$

จากสมการที่ 3.20 เรียกว่า กฎการเรียนรู้แบบ Generalized activity product ในกรณีที่ทราบข้อมูลส่งออกที่ต้องการ คือสัญญาณควบคุมการเรียนรู้ ทำให้การเรียนรู้กลายเป็นการเรียนรู้แบบมีการควบคุม (Supervised) เรียกการเรียนรู้แบบนี้ว่า Correction learning rule ซึ่งมีความสัมพันธ์ดังนี้

$$\Delta w_{ij} = \alpha d_i x_j \quad (3.26)$$

เมื่อพิจารณาสมการที่ 3.18 และสมการที่ 3.21 จะเห็นได้ว่าแตกต่างกันที่สัญญาณการเรียนรู้ l ในสมการที่ 3.18 ใช้ข้อมูลส่งออกที่ได้จากนิเวศจริง ๆ y_i ขณะที่สมการที่ 3.21 ใช้ข้อมูลส่งออกที่ต้องการ จะได้ d_i สำหรับรูปแบบในสมการที่ 3.21 เราสามารถเรียกได้ว่าเป็นการเรียนรู้แบบเฮบเบียนที่มีการควบคุม (Supervised Hebbian learning)

นอกจากการจำลองทางคณิตศาสตร์ของกฎการเรียนรู้แบบ Hebb ดังกล่าวมา ได้มีการนำเสนอ กฎการเรียนรู้ของ Hebb ในแบบที่แก้ปัญหาเชิงสถิติ การเปลี่ยนแปลงของค่าการเชื่อมโยงขึ้นกับค่า โควาเรียนซ์ (Covariance) ระหว่างข้อมูลป้อนเข้า และข้อมูลส่งออก เขียนเป็นความสัมพันธ์ได้ดังนี้

$$\begin{aligned}\Delta w_{ij} &= \alpha \text{cov}[y_i, x_j]; j = 1, 2, \dots, n \\ &= \alpha E[(y_i - \overline{y_i})(x_j - \overline{x_j})] \\ &= \alpha \{E[y_i x_j] - \overline{y_i x_j}\} \end{aligned} \quad (3.27)$$

โดยที่ E คือ Statistical expectation operator

เมื่อพิจารณาสมการที่ 3.23 และสมการที่ 3.27 จะเห็นว่าพจน์แรกต่างกันตรงที่สมการที่ 3.27 ใช้ตัวปฏิบัติการ E กับผลคูณระหว่างข้อมูลป้อนเข้ากับข้อมูลส่งออกแทนที่จะเป็นค่าผลคูณนั้นโดยตรง สำหรับพจน์ที่ 2 ของสมการที่ 3.27 $\overline{y_i x_j}$ สามารถพิจารณาเป็นค่าขีดจำกัดที่ป้อนให้โครงข่ายประสาทเทียม

3.3.6.1.2) กฎการเรียนรู้แบบปรับค่าผิดพลาด

การเรียนรู้แบบปรับค่าผิดพลาดนับว่าเป็นการเรียนรู้ที่สำคัญวิธีหนึ่ง ค่าผลต่างระหว่างข้อมูลส่งออกที่ต้องการจะได้ d_i และข้อมูลส่งออกที่ได้รับจากโครงข่ายจริง ๆ y_i เรียกว่าค่าผิดพลาด e_i นั่นคือ

$$e_i = d_i - y_i \quad (3.28)$$

เป้าหมายของการเรียนรู้แบบปรับค่าผิดพลาด คือ การหาค่าต่ำสุดของฟังก์ชันเป้าหมาย (Cost function) ซึ่งเป็นฟังก์ชันของค่าผิดพลาด เมื่อเลือกฟังก์ชันเป้าหมายที่แทนค่าผิดพลาดโดยรวมอย่างเหมาะสม ก็จะได้ผลลัพธ์ที่ดี สัญญาณการเรียนรู้ l มีค่าดังนี้

$$l \triangleq [d_i - f(w_i^T x)] f'(w_i^T x) \quad (3.29)$$

โดยที่ $f'(w_i^T x)$ คืออนุพันธ์ของฟังก์ชันแอกทิเวชันเทียบกับ w_i

จะสังเกตได้ว่าการเรียนรู้แบบปรับค่าผิดพลาดเป็นการเรียนรู้แบบมีการควบคุม และฟังก์ชันแอกทิเวชัน ต้องเป็นฟังก์ชันที่สามารถหาอนุพันธ์ได้เมื่อใช้ฟังก์ชันเป้าหมาย E ที่เป็นฟังก์ชันของค่าผิดพลาดกำลังสอง นั่นคือ

$$E = \frac{1}{2}[d_i - f(w_i^T x)]^2 = \frac{1}{2}[d_i - y_i]^2 \quad (3.30)$$

เมื่อหาค่าเกรเดียนท์ (Gradient) ของ E เพื่อหาค่าต่ำสุดนั้นคือ

$$\nabla E = -(d_i - y_i)f'(w_i^T x)x \quad (3.31)$$

แต่ค่าของเวกเตอร์ของเกรเดียนท์สามารถหาค่าได้จาก

$$\frac{\partial E}{\partial w_{ij}} = -(d_i - y_i)f'(w_i^T x)x_j \quad (3.32)$$

เนื่องจาก $\Delta w_i = -\alpha \nabla E$ นำค่า ∇E จากสมการที่ 3.31 มาแทนจะได้

$$\Delta w_i = \alpha(d_i - y_i)f'(w_i^T x)x \quad (3.33)$$

การเปลี่ยนแปลงของค่าการเชื่อมโยงแต่ละค่าหาได้จากความสัมพันธ์

$$\Delta w_{ij} = \alpha(d_i - y_i)f'(w_i^T x)x_j \quad (3.34)$$

การเลือกใช้ฟังก์ชันเป้าหมายดังสมการที่ 3.30 สามารถเรียกได้ว่าการเรียนรู้แบบผลต่าง (Delta learning rule) หรือการเรียนรู้แบบเพอร์เซพตรอนสำหรับฟังก์ชันแอกทีเวชันแบบต่อเนื่อง (Continuous Perceptron learning rule)

ในกรณีที่ $f(w_i^T x) = w_i^T x$ สามารถเรียกได้ว่าการเรียนรู้แบบ Windrow Hoff หรือการเรียนรู้แบบ LMS (Least mean square learning rule) นั่นคือจะได้สัญญาณการเรียนรู้

$$l \triangleq d_i - w_i^T x \quad (3.35)$$

สามารถหาค่าเปลี่ยนแปลงของเวกเตอร์ของค่าการเชื่อมโยงดังนี้

$$\Delta w_i = \alpha(d_i - w_i^T x)x \quad (3.36)$$

การเปลี่ยนแปลงของค่าการเชื่อมโยงแต่ละค่าหาได้จากความสัมพันธ์

$$\Delta w_{ij} = \alpha(d_i - w_i^T x)x_j; j = 1, 2, \dots, n \quad (3.37)$$

3.3.6.1.3) การเรียนรู้แบบคอมแพ็คทิฟ

การเรียนรู้แบบคอมแพ็คทิฟนี้จะมีนิวรอลที่เหมาะสมที่สุดในกลุ่มเพียงหนึ่งเดียวเท่านั้น ที่จะได้รับการกระตุ้น กล่าวคือ ณ เวลาหนึ่งจะมีเพียงนิวรอลที่ได้รับการคัดเลือกเท่านั้น ที่จะมีการเรียนรู้ เราอาจจะเรียกว่าการเรียนรู้แบบผู้ชนะ (Winner take all learning) นิวรอลที่ได้รับการปรับสอนคือนิวรอลที่มีความเหมาะสมในกลุ่ม หรืออาจเป็นนิวรอลที่เหมาะสมที่สุด นั่นคือก็อาจมีนิวรอลเพียงหนึ่งเดียว หรือหลายนิวรอลที่จะมีการเรียนรู้ในเวลาหนึ่ง เวกเตอร์ค่าการเชื่อมโยงของนิวรอลที่เหมาะสม (Winning neuron)

$$w_m = [w_{m1} w_{m2} \dots w_{mn}]^T \quad (3.38)$$

เวกเตอร์ค่าการเชื่อมโยงเปลี่ยนแปลงดังนี้

$$\Delta w_m = \alpha(x - w_m) \quad (3.39)$$

การเปลี่ยนแปลงของค่าการเชื่อมโยงแต่ละค่าหาได้จากความสัมพันธ์

$$\Delta w_{mj} = \alpha(x_j - w_{mj}); j = 1, 2, \dots, n \quad (3.40)$$

สำหรับเวกเตอร์ของค่าการเชื่อมโยงไปยังนิวรอลอื่น ๆ จะไม่เปลี่ยนแปลงนั่นคือ

$$\Delta w_k = 0; k \neq m \quad (3.41)$$

ในการเลือกนิวรอลที่เหมาะสมนั้นจะใช้ระดับแอกทิเวชันเป็นเกณฑ์การตัดสินใจ ตัวอย่างเช่น

$$w_m^T x = \max_{i=1,2,\dots,p} (w_i^T x) \quad (3.42)$$

โดยที่ p คือจำนวนนิวรอลทั้งหมด

การเรียนรู้แบบคอมแพ็คทิฟจัดว่าเป็นการเรียนรู้ที่ไม่มีการควบคุมตัวอย่างการประยุกต์ใช้งานได้แก่ใช้ในการจำแนกกลุ่มข้อมูลป้อนเข้าหรือใช้กับโครงข่ายแบบจัดตัวเอง (Self organizing network) เป็นต้น

3.3.6.1.4) กฎการเรียนรู้แบบ โบลท์มานน์

การเรียนรู้แบบ โบลท์มานน์เป็นการเรียนรู้ที่ต่างจากที่กล่าวมา เนื่องจากเป็นขั้นตอนวิธีการเรียนรู้แบบสโตคาสติก ซึ่งประยุกต์มาจากทฤษฎีเทอร์โมไดนามิกส์ โครงข่ายแบบ โบลท์มานน์ ซึ่งใช้การเรียนรู้แบบ โบลท์มานน์เป็นโครงข่ายแบบย้อนกลับสถานะของนิวรอลจะเป็นเปิด/ปิด (on/off) คุณสมบัติของโครงข่ายถูกกำหนดด้วยฟังก์ชันพลังงาน (Energy function) E ซึ่งเป็นฟังก์ชันที่บอกความสัมพันธ์ระหว่างนิวรอล ฟังก์ชันพลังงานมีรูปสมการดังนี้

$$E = -\frac{1}{2} \sum_i \sum_{j \neq i} w_{ij} s_i s_j \quad (3.43)$$

โดยที่ s_i คือสถานะของนิวรอล i

w_{ij} คือค่าการเชื่อมโยงระหว่างนิวรอล i กับนิวรอล j

จากสมการที่ 3.43 จะไม่มีการป้อนกลับมาให้ตัวมันเอง ($i \neq j$) การทำงานเริ่มจากการสุ่มเลือกนิวรอลเพื่อทำการปรับสอน การเปลี่ยนแปลงสถานะของนิวรอล i จากปิดไปเปิด หรือจากเปิดไปเป็นปิด ที่อุณหภูมิ T มีค่าความน่าจะเป็นดังนี้

$$w(s_i \rightarrow -s_i) = \frac{1}{1 + \exp(-\Delta E_i / T)} \quad (3.44)$$

โดยที่ ΔE คือพลังงานที่เปลี่ยนแปลง

โครงข่ายประสาทเทียมแบบ โบลท์มานน์แบ่งออกเป็นนิวรอลที่มองเห็น (Visible neuron) และนิวรอลซ่อนนิวรอลที่มองเห็นจะเชื่อม (Interface) ระหว่างโครงข่ายประสาทภายนอก โดยการทำงานของโครงข่ายมี 2 สถานะ คือ

- 1) ภาวะมีเงื่อนไข (Clamped condition) ทำให้นิวรอลที่มองเห็นถูกควบคุมจากภายนอก
- 2) ภาวะอิสระ (Free running condition) ยอมให้นิวรอลทั้งสองแบบทำงาน โดยอิสระ

นิวรอลซ่อนจะทำงานที่ภาวะอิสระเสมอ

การเปลี่ยนแปลงค่าการเชื่อมโยงแต่ละค่าหาได้จากความสัมพันธ์

$$\Delta w_{ij} = \alpha(PC_{ij} - PF_{ij}) \quad (3.45)$$

โดยที่ PC_{ij} คือค่าความน่าจะเป็นที่ s_i และ s_j จะอยู่ในภาวะเปิดเมื่อนิวรอลที่มองเห็น อยู่ในภาวะมีเงื่อนไขขณะที่โครงข่ายอยู่ในสถานะสมดุลย์


PF_{ij} คือความน่าจะเป็นที่ s_i และ s_j จะอยู่ในภาวะเปิด เมื่อทุกนิวรอลอยู่ในภาวะอิสระ ขณะที่โครงข่ายอยู่ในสถานะสมดุลย์

การเรียนรู้แบบโบลท์มานน์ จะผ่านกระบวนการทำซ้ำจนกระทั่งจุดที่เรียกว่า สมดุลทางอุณหภูมิจึง

3.3.6.2 รูปแบบการเรียนรู้

รูปแบบการเรียนรู้แบ่งออกเป็น 3 รูปแบบ คือ

- 1) การเรียนรู้แบบมีการควบคุม (Supervised learning)
- 2) การเรียนรู้แบบไม่มีการควบคุม (Unsupervised learning)
- 3) การเรียนรู้แบบเสริม (Reinforcement learning)



รูปที่ 3.10 รูปแบบการเรียนรู้ (ก) แบบมีการควบคุม (ข) แบบไม่มีการควบคุม

จากรูปที่ 3.8 เป็นรูปแบบของการเรียนรู้ (ก) เป็นการเรียนรู้แบบมีการควบคุม และ (ข) เป็นการเรียนรู้แบบไม่มีการควบคุม การเรียนรู้ทั้งสองรูปแบบก็เพื่อปรับค่าถ่วงน้ำหนัก (W) หรือค่าการเชื่อมโยงให้อยู่ในช่วงที่เหมาะสม

3.3.6.2.1) การเรียนรู้แบบมีการควบคุม

การเรียนรู้แบบนี้จะทราบข้อมูลส่งออกที่ต้องการ (o,d relationship generator) ทำหน้าที่เป็นครูที่คอยควบคุมการเรียนรู้ ข้อมูลส่งออกที่ต้องการคือข้อมูลที่ครูใช้เปรียบเทียบกับผลตอบสนองที่ได้รับผลที่ได้ ($f(o,d)$) จะใช้ในการปรับทิศทางการเรียนรู้ให้เหมาะสม จากพฤติกรรมดังกล่าวทำให้โครงข่ายประสาทที่มีการเรียนรู้แบบมีการควบคุมจึงต้องมีชุดข้อมูลป้อนเข้า และข้อมูลส่งออก เราเรียกว่า ชุดการปรับสอน (Training set หรือ Training data) ตัวอย่างแบบจำลองนี้ได้แก่ การแพร่แบบย้อนกลับ (Backpropagation) อะคาไลน์ (Adaline) และเพอเซปตรอน (Perceptron) เป็นต้น

3.3.6.2.2) การเรียนรู้แบบไม่มีการควบคุม

การเรียนรู้แบบไม่มีการควบคุมต่างจากแบบมีการควบคุม เนื่องจากเราไม่ทราบข้อมูลส่งออกที่ต้องการ การเรียนรู้จึงใช้ข้อมูลป้อนเข้า ภาวะแวดล้อม และตัวโครงข่ายเอง ในการปรับเข้าหาคำตอบ หากจะเปรียบเทียบกับ การเรียนรู้จริงก็คือการศึกษาด้วยตนเอง ตัวอย่างแบบจำลองนี้ได้แก่ เคาน์เตอร์พรองพะเกชัน (Counterpropagation : CPN) แบบจำลองอะแดปทีฟรีโซแนนซ์เทียร์ (Adaptive Resonance Theory Neural Networks : ART) เป็นต้น

3.3.6.2.3) การเรียนรู้แบบเสริม

การเรียนรู้แบบเสริมเหมือนกับการเรียนรู้แบบมีการควบคุม [19] ยกเว้นข้อมูลส่งออกแทนที่จะได้ข้อมูลส่งออกที่ถูกต้องสำหรับข้อมูลป้อนเข้าแต่ละชุด การเรียนรู้แบบเสริมนี้จะให้ค่าข้อมูลส่งออกเป็นระดับหรือคะแนนที่บอกพฤติกรรมของโครงข่ายที่มีต่อข้อมูลป้อนเข้าแต่ละชุดการเรียนรู้แบบเสริมสามารถนำไปประยุกต์ใช้กับงานระบบควบคุมได้เป็นอย่างดี

3.3.7 การประยุกต์โครงข่ายประสาทเทียมในการใช้งาน

โครงข่ายประสาทเทียมสามารถนำมาประยุกต์ใช้งานต่าง ๆ ได้ดังต่อไปนี้

3.3.7.1 การจำแนกรูปแบบ (Pattern Recognition) เช่น การมองเห็นวัตถุ และการวิเคราะห์เสียงพูดเพื่อแปลความหมาย ซึ่งได้แก่การสื่อสารผ่านเครือข่ายต่าง ๆ ระบบรักษาความปลอดภัยด้วยเสียง และระบบตอบรับโทรศัพท์อัตโนมัติ เป็นต้น

3.3.7.2 การทำนาย (Prediction) หรือการพยากรณ์ (Forecasting) เช่น การทำนายหุ้น การพยากรณ์อัตราการไหลของน้ำ การพยากรณ์ราคาสินค้า

3.3.7.3 การควบคุม (Control) เช่น การควบคุมระบบของเครื่องปรับอากาศ การควบคุมระบบเครื่องยนต์และการควบคุมหุ่นยนต์ เป็นต้น

3.3.7.4 การหาความเหมาะสม (Optimization) เช่น การเลือกกระยะทางที่ใกล้ที่สุดในการเดินทาง เป็นต้น

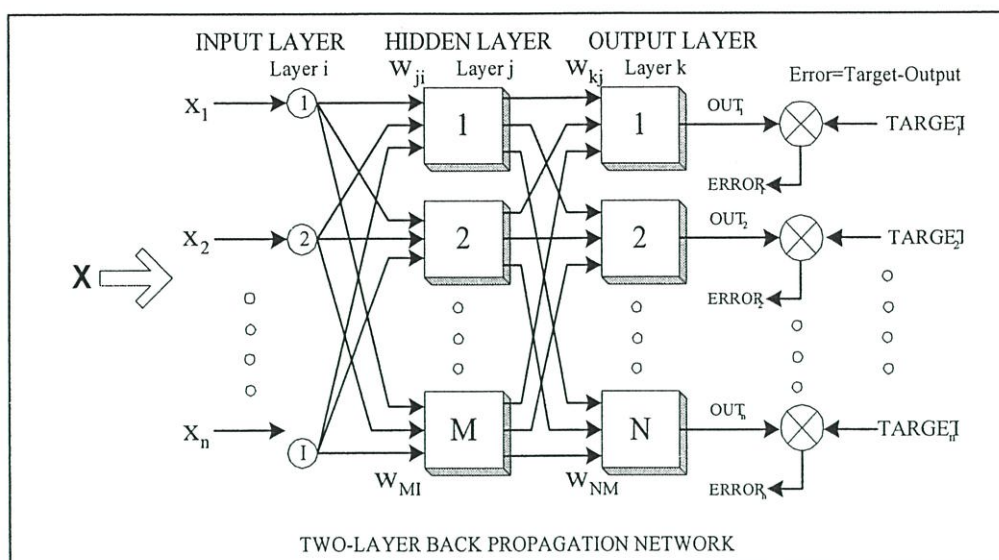
3.3.7.5 การจัดกลุ่ม (Clustering) และการจัดหมู่ (Categorization)

3.3.7.6 การบีบอัดข้อมูล (Data Compression)

3.3.7.7 การจดจำตำแหน่ง (Content Addressable)

3.3.8 โครงข่ายประสาทเทียมที่ใช้ในงานวิจัย

อัลกอริทึมที่นำมาใช้ในบทความนี้เป็นโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ (Backpropagation Neural Networks) ซึ่งเป็นอัลกอริทึมที่เลียนแบบการเรียนรู้ของสมองมนุษย์ โดยมีองค์ประกอบของโครงสร้างพื้นฐานดังนี้คือ โหนด หรือยูนิต (Unit) ชั้นอินพุต (Input layer) ชั้นเอาต์พุต (Output layer) และค่าถ่วงน้ำหนัก (Weight value) แบบจำลองของนิวโรลเน็ตเวิร์คแบ่งได้เป็น 3 กลุ่มคือ Perceptron, Associative Memory, และ Biological Model [11]



รูปที่ 3.11 โค้ดแกรมเชื่อมโยงระหว่างชั้นของนิเวรอลแบบ 2 ชั้น ของ Backpropagation Networks

ขั้นตอนของการเรียนรู้แบบแพร่ย้อนกลับนั้นจะเป็นการสร้างโครงข่ายประสาทเทียมให้มีจำนวนอินพุต และเอาต์พุตเท่ากับจำนวนอินพุตบิต และเอาต์พุตบิตของปัญหาที่จะต้องการแก้ไขตามลำดับ ส่วนจำนวนนิเวรอลของชั้นซ่อนให้กำหนดขึ้น ซึ่งควรจะเริ่มที่ค่ามากพอสมควรก่อน จากนั้นกำหนดค่าเริ่มต้นแก่ค่าน้ำหนักทุกเส้นทางโครงข่ายประสาทเทียมซึ่งควรจะเป็นค่าสุ่มในช่วง $(-1, 1)$ สำหรับแต่ละนิเวรอล j ของชั้นซ่อนเป็นดังนี้ [8]

$$\sum_{i=1}^n X_i W_{ij} = U_j \quad (3.46)$$

โดยที่ X_i คือ อินพุตบิตที่ i สมมติว่ามีอินพุตบิตทั้งหมด n บิต ($i=1,2,3,\dots,n$)
 W_{ij} คือ เวกเตอร์ถ่วงน้ำหนักที่เชื่อมต่อระหว่างชั้น j กับต้นทางชั้น i
 U_j คือ เวกเตอร์เอาต์พุตของ ชั้นซ่อน (Hidden layer) ของโครงข่ายและค่ากระตุ้น (Activation) สำหรับแต่ละนิเวรอล j จำนวนเอาต์พุตที่ชั้นซ่อนได้จากสมการ

$$Y_j = f(U_i) \quad (3.47)$$

เมื่อ Y_j แทนฟังก์ชันแอคทิเวชันเวกเตอร์ของซ่อน j

โดยฟังก์ชันที่นิยมใช้ (Logistic function) คือ

$$f(X) = \frac{1}{1 + e^{-x}} \quad (3.48)$$

สำหรับแต่ละ k นิวรอลของชั้นเอาต์พุต คือ

$$\sum_{i=1}^n Y_j W_{ki} = V_k \quad (3.49)$$

เมื่อ W_{kj} คือเวกเตอร์ถ่วงน้ำหนักที่เชื่อมต่อเอาต์พุตเลเยอร์ และค่ากระตุ้น (Activation) สำหรับแต่ละนิวรอล k ของชั้นเอาต์พุต คือ

$$Z_k = f(V_j) \quad (3.50)$$

เมื่อ Z_k คือ เอาต์พุตบิตที่ k สมมติว่ามีทั้งหมด P บิต นำค่า Z_k มาเปรียบเทียบกับค่าเอาต์พุตจริงที่น่าจะเป็น และคำนวณหาค่าผิดพลาดที่เกิดขึ้น ถ้าค่าความผิดพลาดที่ได้้น้อยกว่าระดับที่เราตั้งไว้ก็จบการเรียนรู้ มิฉะนั้นก็กลับไปทำการปรับค่าน้ำหนักแต่ละค่าดังนี้
การคำนวณค่าน้ำหนักสำหรับการเชื่อมระหว่างชั้นซ่อนกับชั้นเอาต์พุต

$$\Delta W_{jk} = \alpha \delta_k Y_j \quad (3.51)$$

โดยที่
$$\delta_k = (t_k - Z_k) f'(V_k) \quad (3.52)$$

เมื่อ α คือ อัตราการเรียนรู้ มีค่าในช่วง (0 - 1) สำหรับเส้นเชื่อมระหว่างชั้นอินพุตกับชั้นซ่อน

$$\Delta W_{ij} = \alpha \delta_j X_i \quad (3.53)$$

$$\delta_k = \sum_{k=1}^P \delta_k W_{jk} f'(U_j) \quad (3.54)$$

การปรับค่าน้ำหนักของเส้นเชื่อมจากนิวรอล r ไปยังนิวรอล s ด้วยสมการต่อไปนี้

$$W_{rs}(\text{new}) = W_{rs}(\text{old}) + \Delta W_{rs} \quad (3.55)$$

3.3.9 การตรวจสอบประสิทธิภาพของการพยากรณ์

หลังจากทำการพยากรณ์แล้ว การนำผลการพยากรณ์มาวิเคราะห์ตรวจสอบความแม่นยำของการพยากรณ์นั้น การตรวจสอบการพยากรณ์เชิงคุณภาพจะไม่มีหลักเกณฑ์ที่แน่ชัด หรือหลักเกณฑ์ที่แน่นอนเหมือนกับการตรวจสอบความแม่นยำของการพยากรณ์เชิงปริมาณ เพราะการพยากรณ์เชิงคุณภาพต้องอาศัยประสบการณ์ความรู้ความชำนาญของผู้พยากรณ์เป็นหลัก ส่วนการพยากรณ์เชิงปริมาณมีการนำหลักสถิติไปใช้กับข้อมูลที่เก็บมารวบรวมได้ ดังนั้นการตรวจสอบความแม่นยำของการพยากรณ์เชิงปริมาณเท่านั้น

การตรวจสอบความแม่นยำของการพยากรณ์จะพิจารณาจากค่าจริงของข้อมูล (Y_t) เปรียบเทียบกับค่าพยากรณ์ข้อมูล (\hat{Y}_t) โดยกำหนดให้

$$(Y_t) \text{ แทนค่าข้อมูลจริงชุดที่ } t = 1, 2, 3, \dots, n$$

$$(\hat{Y}_t) \text{ แทนค่าพยากรณ์ชุดที่ } t = 1, 2, 3, \dots, n$$

$$(e_t) \text{ แทนการคลาดเคลื่อนของการพยากรณ์ชุดที่ } t$$

$$t = 1, 2, 3, \dots, n \text{ และ } n \text{ แทนจำนวนข้อมูลทั้งหมด}$$

$$(e_t) = Y_t - \hat{Y}_t; t = 1, 2, 3, \dots, n$$

วิธีตรวจสอบความแม่นยำของการพยากรณ์ โดยทั่วไปที่นิยมใช้กันมีดังนี้ [9]

3.3.9.1 ค่าเบี่ยงเบนสัมบูรณ์เฉลี่ย (Mean absolute deviation :MAD)

เป็นการวัดความแม่นยำที่วัดจากการคลาดเคลื่อนของการพยากรณ์ โดยไม่คำนึงถึงทิศทางของความคลาดเคลื่อน MAD จะมีหน่วยวัดเหมือนกับค่าสังเกต

$$MAD = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (3.56)$$

3.3.9.2 ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean square error :MSE)

ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย เป็นการวัดความแม่นยำที่วัดจากค่าความคลาดเคลื่อนของการพยากรณ์ (Sum Square Error : SSE) โดยที่

$$SSE = \sum_{t=1}^n e_t^2$$

ดั่งสมการ

$$MSE = \frac{1}{n} \sum_{t=1}^n (\text{ทราฟฟิก} - \text{ทราฟฟิกพยากรณ์})^2 \dots\dots\dots (3.57)$$

ในบางครั้งผู้พยากรณ์อาจจะใช้ RMSE (Root Mean Square Error) แทน MSE ก็ได้โดยที่

$$RMSE = \sqrt{MSE} \dots\dots\dots (3.58)$$

3.3.9.3 เปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error, MAPE) เปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย เป็นการวัดค่าความแม่นยำจากค่าความคลาดเคลื่อน ของการพยากรณ์เทียบกับข้อมูลจริงโดยไม่คิดเครื่องหมาย ค่า MAPE เป็นค่าวัดความแม่นยำที่ไม่มีหน่วย จึงเหมาะที่จะใช้เปรียบเทียบอนุกรมเวลาหลายชุดเมื่อใช้วิธีการพยากรณ์เดียวกันหรือเปรียบเทียบการพยากรณ์หลายวิธีเมื่อใช้อนุกรมเวลาเดียวกัน

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{Y_t} \right| \times 100 \dots\dots\dots (3.59)$$

3.3.10 สรุป

ในบทนี้ได้เสนอวิธีการพยากรณ์ 3 วิธี ซึ่งใช้ในการประกอบทำวิจัยคือ การพยากรณ์ด้วยวิธีการ Least-Square Method (LSM) เทคนิคการทำให้เรียบ (Smoothing Method) และการพยากรณ์นิวรอลเน็ตเวิร์ค (Artificial Neural Networks) สำหรับประสิทธิภาพของการพยากรณ์ ในวิทยานิพนธ์นี้พิจารณาจากค่าที่ใช้วัดความถูกต้องของการพยากรณ์ 3 วิธี คือค่าเบี่ยงเบนสัมบูรณ์เฉลี่ย (Mean absolute deviation ,MAD) ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean square error ,MSE) และเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error, MAPE)

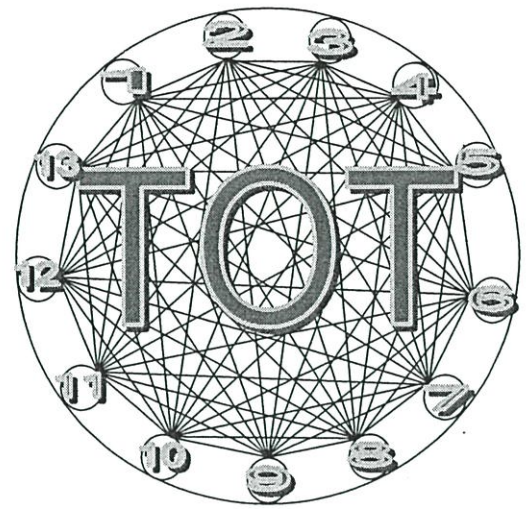

บทที่ 4

วิธีการดำเนินการวิจัย และผลการวิจัย

ในบทนี้เสนอวิธีการวิจัย โดยเริ่มจากการเก็บรวบรวมข้อมูลกราฟฟิคโทรศัพท์ และขั้นตอนในการคาดการณ์การเปลี่ยนแปลงปริมาณกราฟฟิคโทรศัพท์ที่จะเกิดในอนาคต โดยนำเสนอวิธีการคาดการณ์โดยใช้โครงข่ายประสาทเทียม (Artificial Neural Network) ชนิดแพร่กระจายย้อนกลับ (BackPropagation Neural Network) ที่มีการเรียนรู้แบบมีการควบคุม (Supervised learning) และใช้ฟังก์ชันซิกมอยด์ (Sigmoid function) เป็นฟังก์ชันในการตัดสินใจ จากนั้นเปรียบเทียบผลการคาดการณ์กับการพยากรณ์ด้วยวิธีการทางสถิติ โดยใช้เทคนิคของการหาเส้นแนวโน้มกำลังสองน้อยสุด (Least-square method) ของสมการเส้นตรง และเทคนิคการทำให้เรียบ (Smoothing Method) สำหรับการตรวจสอบประสิทธิภาพของการพยากรณ์ที่นำมาใช้ในบทวิจัยนี้ พิจารณาจากค่าที่ใช้วัดความถูกต้องของการพยากรณ์ 3 วิธี คือค่าเบี่ยงเบนสัมบูรณ์เฉลี่ย (Mean Absolute Deviation: MAD) ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error: MSE) และเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean AbsoluteP Error: MAPE)

4.1 รายละเอียดการเก็บข้อมูลกราฟฟิค (Measurement Setup)


ชุมสายโทรศัพท์หลักของบริษัท ทีโอที จำกัด (มหาชน) ซึ่งมีทั้งหมด 13 ชุมสาย กระจายอยู่ทั่วประเทศ ดังแสดงในรูปที่ 4.1 a แต่ละชุมสายจะมีการเชื่อมต่อเป็นโครงข่ายใยแมงมุม ดังแสดงในรูปที่ 4.1 b โดยตั้งอยู่ในกรุงเทพมหานคร มีชุมสายหลัก 4 ชุมสาย ตั้งอยู่ที่ เขตลาดหญ้า กรุงเทพมหานคร และหลักสี่ แต่ละชุมสายหลักนี้มี 4 ยูนิต คือ S1 S2 M1 และ M2 ต่อเชื่อมระหว่างชุมสายหลัก เป็นโครงข่ายรูปดาว ดังแสดงในรูปที่ 4.2 b สำหรับในต่างจังหวัดมีชุมสายหลัก 9 ชุมสาย แต่ละชุมสายประกอบด้วย 2 ยูนิต คือ S1 และ S2 ต่อเชื่อมระหว่างระบบชุมสายหลักเป็นโครงข่ายรูปดาวเช่นกัน รวมทั้งหมดเป็น 34 ชุมสายโดยรวมมีการเชื่อมต่อกัน 561 เส้นทาง แบ่งระดับชุมสายเป็น 2 ระดับ ดังรูปที่ 4.2a สำหรับรูปที่ 4.3 แสดงการส่งผ่านกราฟฟิคของผู้ให้บริการร่วมอื่น ๆ ผ่านทางโครงข่ายโทรศัพท์หลัก ยกตัวอย่าง เส้นทางชุมสายอยุธยา S1 กับชุมสายกรุงเทพมหานคร S1 โดยในการศึกษาครั้งนี้ มีการเก็บข้อมูลกราฟฟิคจาก 12 เส้นทาง (2Mb/s, E1) โดยใช้เส้นอยุธยา S1 เป็นเส้นทางหลัก และ เชื่อมต่อ กับเชียงใหม่ CMI S1 หาดใหญ่ HYI S1 กรุงเทพมหานคร KKM S1 ขอนแก่น KKN S1 หลักสี่ LKS S1 ลาดหญ้า LTY S1 นครราชสีมา NMA S1 เพชรบุรี PBI S1 พิษณุโลก PLK S1 พระโขนง PKG S1 และ พุนพิน PPN S1 ตามลำดับยกตัวอย่างแผนผังการเชื่อมต่อเส้นทางระหว่างชุมสายอยุธยา S1 กับ ชุมสายกรุงเทพมหานคร S1 แสดงดังรูปที่ 4.3




a

b

รูปที่ 4.1 a โครงข่ายโทรศัพท์หลัก b การเชื่อมต่อระหว่างชุมสายหลัก



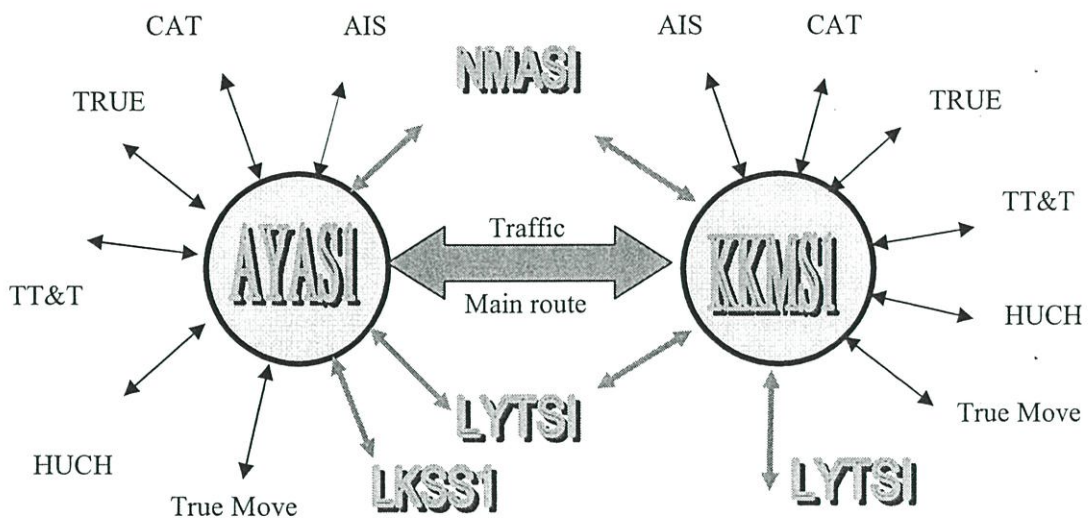
a



b

รูปที่ 4.2 a การแบ่งระดับชุมสายโทรศัพท์ b การเชื่อมต่อชุมสาย หลักอยุธยา กับชุมสายอื่น ๆ 12 เส้นทาง

ส่วนแผนผังการเชื่อมต่อเส้นทางรวม แสดงดังรูปที่ 4.4 อุปกรณ์การเก็บบันทึก (Monitor) แสดงดังรูปที่ 4.5 และตัวอย่างสัญญาณข้อมูลที่เก็บบันทึกได้แสดงดังรูปที่ 4.6

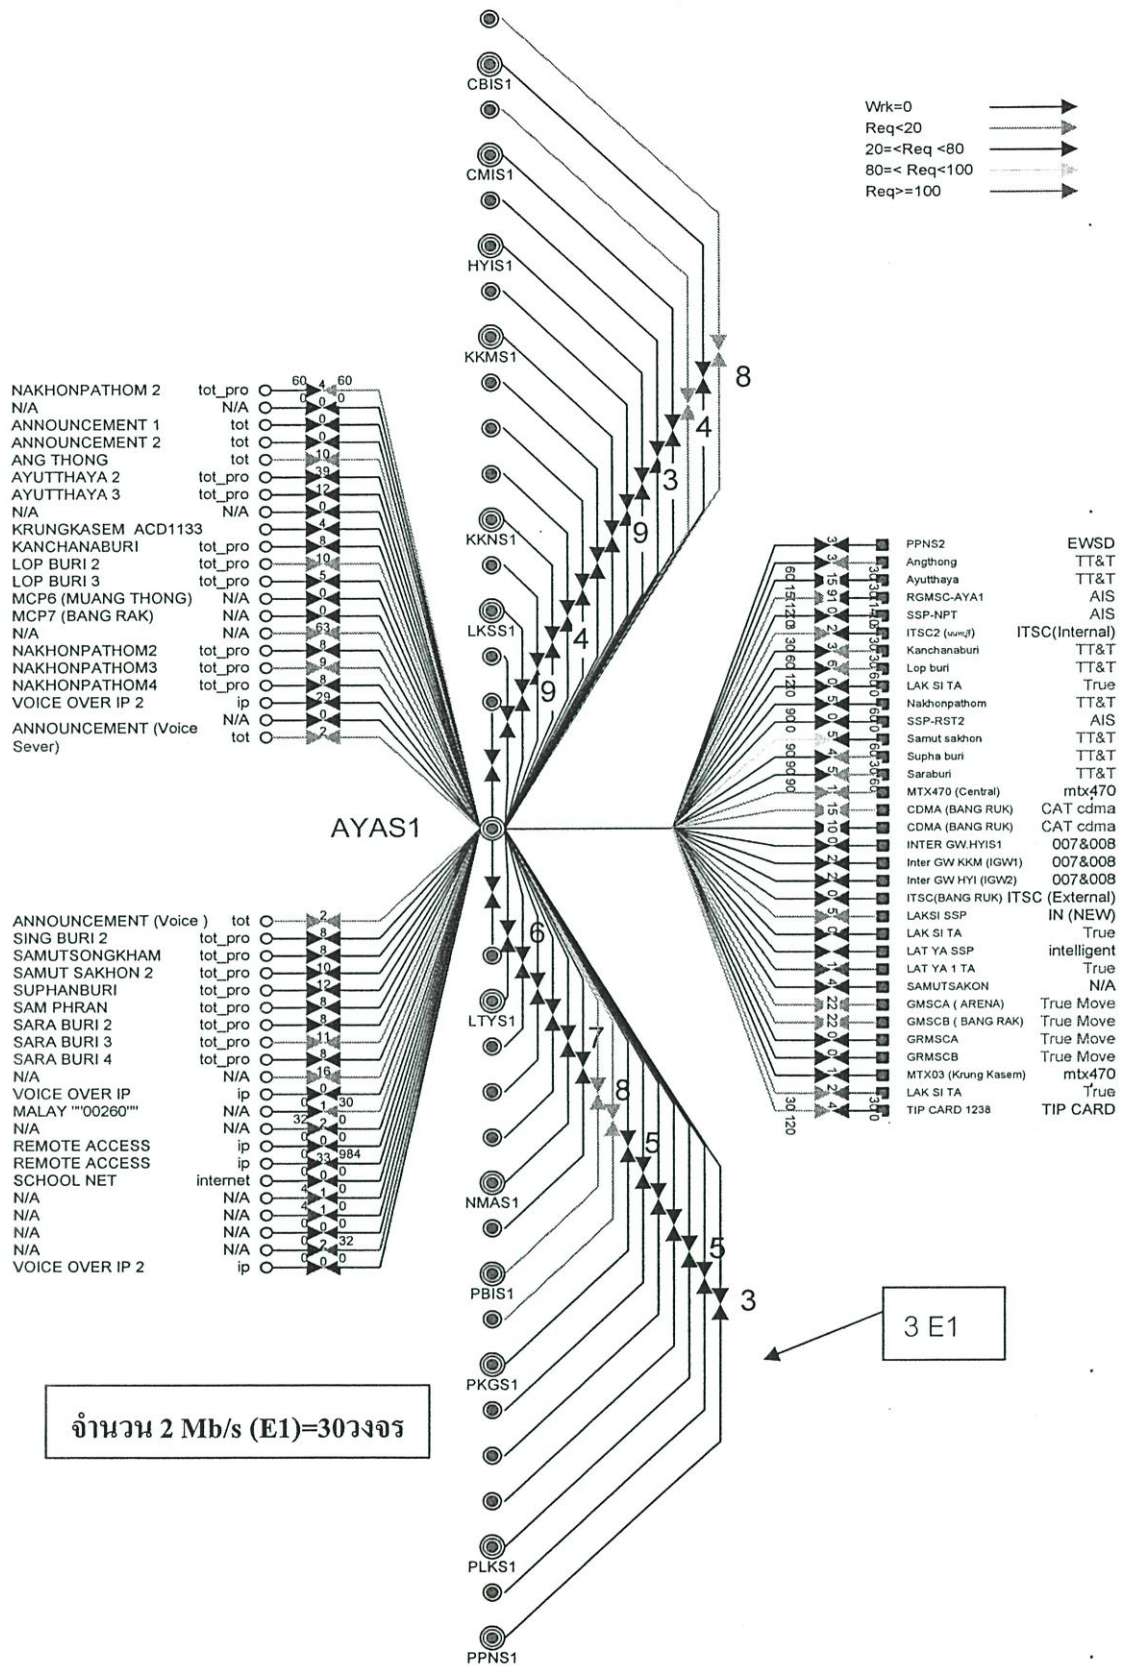


รูปที่ 4.3 ตัวอย่างเส้นทางการส่งผ่านทราฟฟิกของผู้ให้บริการร่วมรายอื่น ๆ ผ่านทางโครงข่ายโทรศัพท์หลัก เส้นทางชุมสายอยุธยา S1 กับชุมสายกรุงเทพมหานคร S1


จากรูปที่ 4.3 แสดงแหล่งข้อมูลอินเทอร์เน็ต (ทราฟฟิก) ที่เกี่ยวข้องโดยตรงที่ส่งผ่านบนเส้นทางหลักในบทวิจัยนี้ได้เลือกอินเทอร์เน็ตที่มีเปอร์เซ็นต์การใช้งานทราฟฟิกสูง ๆ 7 อินพุต โดยทำการเก็บข้อมูลที่มีทราฟฟิกสูงสุดทุกวันในช่วงเวลา Busy hour ตลอดระยะเวลา 3 ปี เพื่อเป็นข้อมูลที่ใช้ในการทดสอบ แหล่งข้อมูลอินเทอร์เน็ต (ทราฟฟิก) ที่เกี่ยวข้องโดยตรง ที่ส่งผ่านบนเส้นทางหลักในบทวิจัยนี้ 7 อินพุต คือ

1. ทราฟฟิก โทรศัพท์ในเส้นทางที่จะพยากรณ์
2. ทราฟฟิกโทรศัพท์เคลื่อนที่บริษัท AIS
3. ทราฟฟิก โทรศัพท์เคลื่อนที่บริษัท TRUE Move
4. ทราฟฟิก โทรศัพท์เคลื่อนที่บริษัท CAT CDMA
5. ทราฟฟิก โทรศัพท์เคลื่อนที่บริษัท HUCH
6. ทราฟฟิก โทรศัพท์พื้นฐานบริษัท TT&T
7. ทราฟฟิก โทรศัพท์พื้นฐานบริษัท TRUE

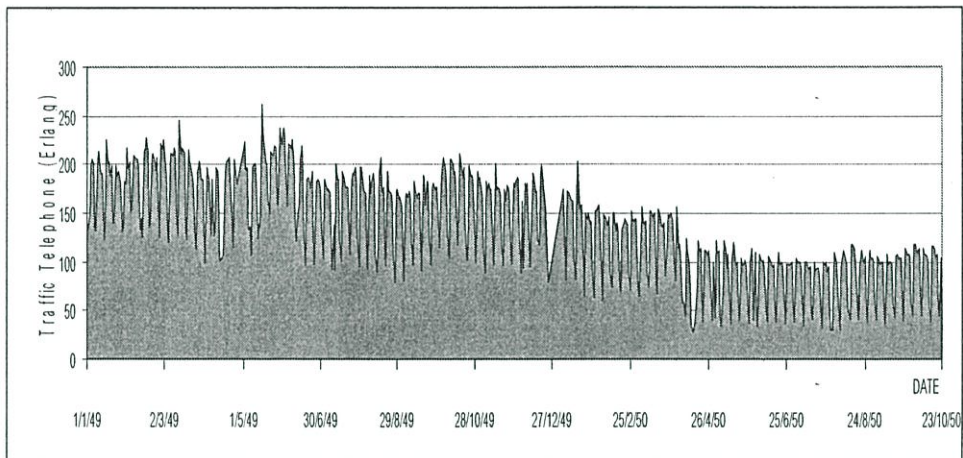
สำหรับรูปที่ 4.7 เป็นตัวอย่างข้อมูลทราฟฟิกซึ่งเก็บได้จากการวัดทราฟฟิกของผู้ให้บริการต่าง ๆ ที่เชื่อมเข้ากับโครงข่าย บริษัท ทีโอที จำกัด (มหาชน) โดยรวมทั่วประเทศ




รูปที่ 4.4 การใช้งานวงจร 2 Mb/s (E1) เส้นทางชุมสายอยุธยา S1 – ชุมสาย ยูนิคชั่น



รูปที่ 4.5 อุปกรณ์การเก็บบันทึก (Monitor) ณ ชุมสายโทรศัพท์หลักของ บมจ. ทีโอที



รูปที่ 4.6 ตัวอย่างสัญญาณข้อมูลกราฟิกที่เก็บบันทึกบนเส้นทางอยุธยา S1- กรุงเทพมหานคร S1



รูปที่ 4.7 กราฟฟิกของผู้ให้บริการต่างๆ ที่เชื่อมเข้ากับโครงข่ายทีโอทีโดยรวมทั่วประเทศ

4.2 ขั้นตอนในการพยากรณ์

เนื่องจากวิทยานิพนธ์นี้เน้นการคาดการณ์การเปลี่ยนแปลงข้อมูลอนุกรมเวลาของปริมาณกราฟฟิคที่จะเกิดขึ้นในอนาคต โดยใช้โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ (BackPropagation Neural Network) เป็นสำคัญ จึงมีการนำเสนอขั้นตอนอย่างละเอียดสำหรับการคาดการณ์การเปลี่ยนแปลงของปริมาณกราฟฟิคด้วยวิธีการทางสถิติจะกล่าวถึงแต่ละวิธีโดยย่อ จากนั้นนำผลการคาดการณ์มาเปรียบเทียบในตารางเท่านั้น ขั้นตอนในการคาดการณ์การเปลี่ยนแปลงข้อมูลอนุกรมเวลา โดยวิธีโครงข่ายประสาทเทียมชนิดแพร่กระจายย้อนกลับ (BackPropagation Neural Network) ที่มีการเรียนรู้แบบมีการควบคุม (Supervised learning) และใช้ฟังก์ชันซิกมอยด์ (Sigmoid function) เป็นฟังก์ชันในการตัดสินใจ มีรายละเอียดดังนี้

4.2.1 แบ่งข้อมูลกราฟฟิคที่บันทึกได้ตั้งแต่ วันที่ 1 ม.ค. 47 ถึง 18 ธ.ค. 50 ในเส้นทางที่ต้องการวิเคราะห์ออกเป็น 2 กลุ่ม ตัวอย่างข้อมูลที่บันทึกได้ แสดงดังตารางที่ 4.1 ซึ่งประกอบด้วยข้อมูล 7 อินพุต โดยข้อมูลกลุ่มที่ 1 ใช้เพื่อฝึกสอนโครงข่าย และข้อมูลกลุ่ม 2. ใช้เพื่อยืนยันความถูกต้อง (Validation) ในการคาดการณ์ว่าสามารถแสดงการเปลี่ยนแปลงของข้อมูลอนุกรมเวลาได้ตามสภาพจริงหรือไม่ เพื่อช่วยเพิ่มความมั่นใจในการนำโครงข่ายประสาทเทียมที่ได้ไปใช้งาน

ตารางที่ 4.1 ข้อมูลกราฟฟิคที่บันทึกได้ จากเส้นทาง อยุธยา S1- เชียงใหม่ S1

DATE	AYA S1-CMI S1	AIS	True Move	CAT CDMA	HUCH	TRUE	TT&T
1/1/2547	65.76	789.03	129.02	125.15	137.81	36.38	199.74
2/1/2547	59.66	788.35	144.57	124.87	133.26	37.68	191.19
3/1/2547	64.72	802.39	142.80	134.35	146.27	36.65	213.15
5/1/2547	83.13	801.78	192.32	191.66	148.32	56.43	214.44
6/1/2547	91.98	792.29	203.11	174.99	148.28	57.16	254.72
7/1/2547	86.48	813.23	195.73	167.73	148.25	56.17	211.09
8/1/2547	82.18	802.10	188.63	167.89	148.28	57.13	209.84
9/1/2547	77.68	822.96	184.95	159.87	147.92	56.62	212.22
10/1/2547	75.08	815.32	169.13	147.19	147.14	44.82	135.13
11/1/2547	73.53	775.34	177.43	151.50	147.78	44.96	181.35
12/1/2547	80.48	809.68	200.73	165.86	148.05	56.72	173.06
↓	↓	↓	↓	↓	↓	↓	↓
18/12/2550	28.35	525.88	89.67	73.48	141.89	215.37	357.26

4.2.2 ปรับค่าของตัวแปรให้อยู่ในสเกลเดียวกัน ทั้งในส่วนของตัวแปรอินพุต และตัวแปรเอาต์พุตให้มีค่าอยู่ระหว่าง 0 ถึง 1 โดยการนอร์มอลไลต์ข้อมูลในตาราง 4.1 โดยใช้สมการ (4.1) ถึง (4.3) ข้อมูลที่ผ่านการนอร์มอลไลต์แล้วแสดงตามตารางที่ 4.2

$$x_{Normalized} = \frac{x_i}{2(\mu + \sigma)} \quad (4.1)$$

$$\mu = \frac{1}{N} \sum_{i=0}^{N-1} x_i \quad (4.2)$$

$$\sigma^2 = \frac{1}{N-1} \sum_{i=0}^{N-1} (x_i - \mu)^2 \quad (4.3)$$

โดย x_i คือข้อมูล และตัวแปรที่เกี่ยวข้องกับ Traffic Telephone

μ คือค่าเฉลี่ยของข้อมูล (Mean of Data)

σ คือค่าเบี่ยงเบนมาตรฐาน (Standard deviation) และ N คือจำนวนข้อมูลทั้งหมด

ตารางที่ 4.2 ข้อมูลกราฟฟิคที่ผ่านการนอร์มอลไลต์แล้ว จากเส้นทาง อยุรยา S1- เชียงใหม่ S1

DATE/ Input Data	AYA S1-CMI S1	AIS	True Move	CAT CDMA	HUCH	TRUE	TT&T
1/1/2547	0.405	0.200	0.118	0.288	0.427	0.473	0.490
2/1/2547	0.312	0.199	0.132	0.288	0.412	0.490	0.469
3/1/2547	0.324	0.203	0.131	0.310	0.453	0.477	0.523
5/1/2547	0.442	0.203	0.176	0.442	0.459	0.734	0.526
6/1/2547	0.421	0.200	0.186	0.403	0.459	0.743	0.625
7/1/2547	0.403	0.206	0.179	0.386	0.459	0.731	0.518
8/1/2547	0.448	0.203	0.173	0.387	0.459	0.743	0.515
9/1/2547	0.334	0.208	0.169	0.368	0.458	0.736	0.521
10/1/2547	0.359	0.206	0.155	0.339	0.455	0.583	0.332
11/1/2547	0.390	0.196	0.162	0.349	0.457	0.585	0.445
12/1/2547	0.307	0.205	0.184	0.382	0.458	0.738	0.425
↓	↓	↓	↓	↓	↓	↓	↓
18/12/2550	0.164	0.133	0.082	0.169	0.392	0.368	0.158

4.2.3 กำหนดโครงสร้างของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ คือ กำหนดจำนวน โหนดในชั้นอินพุต จำนวนชั้นฮิดเดน จำนวนโหนดในชั้นฮิดเดน จำนวนโหนดในชั้นเอาต์พุต ประเภทของทรานสเฟอร์ฟังก์ชัน และพารามิเตอร์ต่าง ๆ ที่ใช้ในการคาดการณ์ล่วงหน้าให้เหมาะสมกับลักษณะการเกิดข้อมูล ซึ่งโดยปกติไม่มีกฎเกณฑ์ที่แน่นอน ดังนั้นการได้มาซึ่งโครงสร้างที่เหมาะสมจะต้องทำการทดสอบ

ในบทวิจัยนี้ตั้งสมมุติฐานในการทดสอบจากโครงสร้างของโครงข่ายโทรศัพท์ตามรูปที่ 4.4 ตามเส้นทางที่มีการต่อผ่าน โดยเลือกจำนวนโหนดในชั้นอินพุต เท่ากับจำนวน ทราฟฟิกอินพุตที่มีการใช้งานมากคือ 7 โหนด และ ตามคุณสมบัติของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับคือ จำนวนโหนดเอาต์พุตต้องเท่ากับโหนดอินพุต คือ 7 โหนด เช่นกัน สำหรับจำนวนชั้นฮิดเดน กำหนดเป็น 1 ชั้นแทนโหนดหุ้มสายอยุธยา S1 จากนั้นต่อออกโหนดเชียงใหม่ S1 และโหนดบริษัทร่วมการงานอื่นตามจำนวนอินพุต สำหรับจำนวนโหนดในชั้นฮิดเดนนั่นคือปัญหาที่ต้องปรับเพื่อหาคำตอบที่ดีที่สุด จากการจำลองการทำงานตามโครงสร้างของโมเดลตามลำดับนี้คือ Model 7-7-7, 7-10-7, 7-15-7, 7-20-7, 7-25-7, 14-15-14, 14-20-14, 14-25-14 โดยจำนวนแรกแทนจำนวนอินพุต จำนวนต่อมาแทนจำนวนฮิดเดน และจำนวนสุดท้ายแทนจำนวนเอาต์พุต ในการทดสอบมีการสุ่มค่าน้ำหนักเริ่มต้นให้กับเส้นเชื่อมระหว่างโหนด และมีการปรับเปลี่ยนค่าโมเมนตัม ปรับอัตราการเรียนรู้ และปรับจำนวนรอบการวนลูปของโปรแกรมจนได้ค่า MSE ต่ำที่สุด ตามขั้นตอนในหัวข้อที่จะกล่าวถึงต่อไป

4.2.4 กำหนดค่าน้ำหนักเริ่มต้นให้กับเส้นเชื่อมระหว่างโหนดโดยการสุ่มค่าระหว่าง -1 และ 1 จากนั้นป้อนข้อมูลเข้าสู่โหนดอินพุต และส่งข้อมูลจากโหนดอินพุตไปยังโหนดในชั้นฮิดเดน โดยไม่ผ่านขั้นตอนการคำนวณใด ๆ

4.2.5 คำนวณผลรวมของสัญญาณอินพุตของแต่ละโหนดในชั้นฮิดเดนได้จากสมการ (3.46)

รายละเอียดดังแสดงในบทที่ 3 คือ
$$\sum_{i=1}^n X_i W_{ij} = U_j$$

4.2.6 คำนวณค่าเอาต์พุตของโหนดที่ j ในชั้นฮิดเดน โดยใช้ทรานสเฟอร์ฟังก์ชัน โดยทั่วไปนิยมใช้ซิกมอยด์ฟังก์ชัน (Sigmoid Function) ซึ่งเป็นฟังก์ชันที่ได้รับความนิยมนำมาใช้เป็นฟังก์ชันแอคทิเวชันของโครงข่ายประสาทเทียมกันมาก เนื่องจากเป็นฟังก์ชันที่เพิ่มขึ้นอย่างสม่ำเสมอ (Smoothness) ฟังก์ชันซิกมอยด์ จัดเป็นฟังก์ชันแอคทิเวชันที่ไม่เป็นเชิงเส้น ตัวอย่างของฟังก์ชันซิกมอยด์คือ ฟังก์ชันลอจิสติก (Logistic function)

$$\text{ฟังก์ชันลอจิสติก} \quad g(v) = \frac{1}{1 + \exp(-\lambda v)} \quad (4.4)$$

โดยที่ λ เป็นค่าความชันของ Slope

4.2.7 คำนวณผลรวมสัญญาณอินพุตของแต่ละโหนดในชั้นเอาต์พุต จากสมการ (3.49)

4.2.8 คำนวณค่าเอาต์พุตของโหนด k จากสมการ (3.50)

4.2.9 คำนวณค่าความคลาดเคลื่อน (e_k) โดยนำค่าเอาต์พุตของโหนด $k(z_k)$ ในชั้นเอาต์พุต มาเปรียบเทียบกับค่าเป้าหมาย (T_k) โดยใช้กฎการเรียนรู้แบบปรับค่าผิดพลาดที่กล่าวถึงในบทที่ 3 หัวข้อ 3.3.6.1.2

4.2.10 ปรับน้ำหนักของเส้นเชื่อมโยงในการแพร่กระจายย้อนกลับตามแบบการเรียนรู้แบบมีผู้สอนตามรายละเอียดในสมการ (3.51)-(3.55)

4.2.11 วนซ้ำตามขั้นตอนที่ 4.2.5 ถึง 4.2.11 จนข้อมูลหมดครบรอบ (Epoch)


4.2.12 ประมวลค่าความคลาดเคลื่อนมาตรฐาน (MSE: Mean Square Error) ตามรายละเอียดในหัวข้อ 3.3.9.2 ใน MSE บทที่ 3 ถ้าค่า RMSE มีค่าต่ำสุด หรืออยู่ในเงื่อนไขที่ตั้งไว้ จะนำไปดำเนินการต่อใน ข้อ 4.2.14 แต่ถ้า ค่า MSE มากกว่าเกณฑ์ที่กำหนด จะกลับไปทำซ้ำที่ขั้นตอนที่ 4.2.5 ถึง 4.2.13 ใหม่

4.2.13 ตรวจสอบความถูกต้องของการพยากรณ์ของโครงข่ายประสาทเทียมที่ได้ฝึกสอนไว้ด้วยข้อมูลกลุ่มที่ 2 และเปรียบเทียบค่า MSE ที่ได้กับค่า MSE ของข้อมูลที่ใช้ฝึกสอน ให้มีค่าใกล้เคียงกันมากที่สุด แล้วจึงนำโครงข่ายประสาทเทียมที่ได้ไปใช้ในการพยากรณ์ต่อไป

4.3 ผลการวิจัย

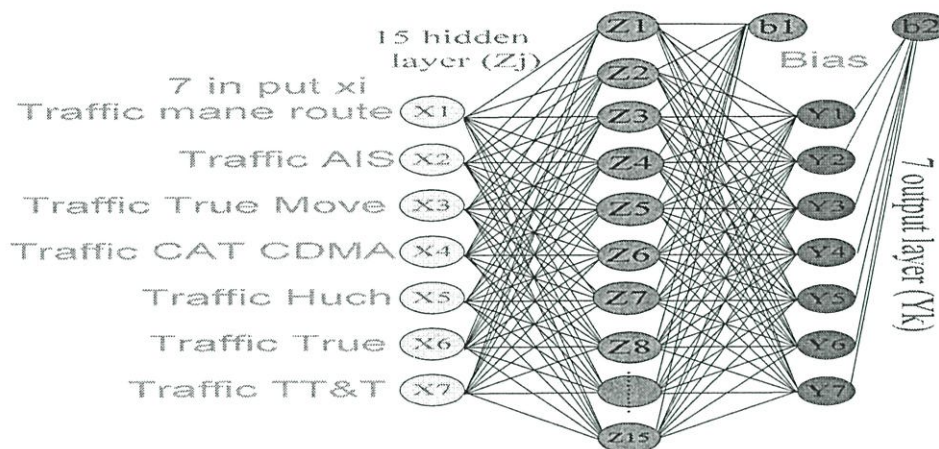
4.3.1 ผลการทดลอง กำหนดโครงสร้างของโครงข่ายประสาทเทียม

ในการทดสอบ ได้มีการปรับเปลี่ยนค่า โมเมนตัม อัตราการเรียนรู้ จำนวนรอบการวนลูปของโปรแกรมจนได้ค่า MSE ต่ำที่สุด โดยพยากรณ์การเปลี่ยนแปลงของกราฟฟีกล่วงหน้าเป็นเวลา 6 เดือน และ 1 ปี โดยใช้ข้อมูลกราฟฟีกที่เก็บในช่วงเวลา 12000 วัน ในการสอนให้โครงข่าย และใช้ข้อมูลทดสอบความแม่นยำ 30 วัน ค่า MSE ที่ได้จากการกำหนดโครงสร้างของโครงข่ายประสาทเทียมแสดงดังรูปที่ 4.8 และ 4.9




รูปที่ 4.8 ทดสอบการหาโมเดลที่มีค่า MSE ต่ำที่สุด


รูปที่ 4.8 เป็นผลการทดลองหาโมเดลโครงสร้างของโครงข่ายประสาทเทียม ซึ่งประกอบด้วยจำนวน อินพุต - ฮิดเด้น - เอาต์พุต จะเห็นว่าโครงสร้าง ที่มีค่า MSE ต่ำที่สุดคือ 0.85 มีจำนวน อินพุต - ฮิดเด้น - เอาต์พุต เป็น 7-15-7 ตามลำดับ โครงสร้างโมเดลที่ได้แสดงดังรูปที่ 4.9 จากนั้น นำโมเดลนี้ไปทดสอบหาค่าพารามิเตอร์อื่นต่อไป



รูปที่ 4.9 โครงข่ายประสาทเทียมที่ทำการทดสอบ




รูปที่ 4.10 ผลการทดสอบการหาโมเมนต์ของนิวรอลเน็ตเวิร์ค




รูปที่ 4.11 ผลการทดสอบการหาอัตราการเรียนรู้นิวรอลเส้นทาง อุทยา S1-เชียงใหม่ S1

รูปที่ 4.10 โดยใช้โมเดลที่มีโครงสร้าง 7-15-7 มาทดสอบโดยการปรับค่า โมเมนตัม (μ) ปรับจนกระทั่งได้ค่า MSE ต่ำสุด คือ 0.2 และจากรูปที่ 4.11 เป็นการทดลองปรับอัตราการเรียนรู้ (η) ของโครงข่ายจนกระทั่ง ได้ค่า MSE ต่ำสุด คือ 0.2



รูปที่ 4.12 ผลการทดสอบการหาจำนวนรอบในการเรียนรู้นิวรอลเส้นทางอยุธยา S1-เชียงใหม่ S1

รูปที่ 4.12 เป็นกราฟแสดงการหาจำนวนรอบในการเรียนรู้ของโครงข่ายประสาทเทียม โดยพิจารณาจากกราฟจะเห็นความแตกต่าง 2 ช่วง คือช่วงระหว่าง 800-2000 รอบจะมีค่าผิดพลาดน้อยกว่า กล่าวคือเส้นกราฟอยู่ใกล้กับค่าเป้าหมาย (Target) มากกว่า และค่าดูเข้าสู่ค่าคงที่ โดยการตรวจสอบค่า MSE ต่ำสุดใกล้ค่าคงที่ 800 รอบ โมเดล 7-15-7 จะมีค่าอัตราการเรียนรู้เท่ากับ 0.2 ค่าโมเมนตัมเท่ากับ 0.2 และใช้เวลาในการเรียนรู้เท่า 27.2 นาที



รูปที่ 4.13 ผลการทดสอบการหาจำนวนรอบ และเวลาในการเรียนรู้ของโครงข่ายนิวรอล

รูปที่ 4.13 เป็นกราฟแสดงการหาจำนวนรอบของการวนซ้ำในการเรียนรู้เทียบกับเวลาที่ใช้ในการเรียนรู้ และค่าความผิดพลาดในรูปของค่า MSE เทียบกับจำนวนรอบของการวนซ้ำของโครงข่ายประสาทเทียมตามโครงสร้างรูปที่ 4.9

4.3.2 ผลการคาดการณ์การเปลี่ยนแปลงปริมาณ ทราฟฟิก

ในหัวข้อนี้ได้เปรียบเทียบผลการคาดการณ์ที่ได้จากการใช้โครงข่ายประสาทเทียม (Artificial Neural Networks, ANN) ที่ได้จากการทดสอบเปรียบเทียบกับวิธีการคาดการณ์ทางสถิติ 2 วิธีคือ Single exponential smoothing ซึ่งเลือกค่า α ที่ดีที่สุดเท่ากับ 0.9 และวิธี LMS [4] โดยได้คาดการณ์การเปลี่ยนแปลงทราฟฟิกที่วิ่งผ่านชุมสายโทรศัพท์ในแต่ละเส้นทางล่วงหน้าเป็นเวลา 6 เดือน ทั้งหมด 12 เส้นทาง ผลที่ได้จากการคำนวณได้แสดงเปรียบเทียบไว้ในตารางที่ 4.3 และ 4.4 และเปรียบเทียบผลที่ได้จากการพยากรณ์เพื่อคาดการณ์โดยการเรียนรู้แบบการทำงานด้วยโปรแกรม (Simulate) ได้แสดงเปรียบเทียบไว้ในรูปที่ 4.14 ถึงรูปที่ 4.24

ตารางที่ 4.3 เปรียบเทียบความคลาดเคลื่อนของการคาดการณ์ล่วงหน้า 6 เดือนในขั้นตอนทดสอบ

เส้นทาง	แบบจำลอง	MAD	MAPE	MSE	RMSE
อยุธยา S1- ชลบุรี S1	ANN	0.035	14.01%	0.002	0.042
	เอ็กโพเนนเชียลใช้ α 0.9	0.134	30.47%	0.02	0.148
	LSM	0.401	92.97%	0.001	0.023
อยุธยา S1- เชียงใหม่ S1	ANN	0.039	20.21%	0.002	0.048
	เอ็กโพเนนเชียลใช้ α 0.9	0.227	56.01%	0.054	0.231
	LSM	0.386	95.28%	0.002	0.039
อยุธยา S1- หาดใหญ่ S1	ANN	0.027	74.53%	0.001	0.032
	เอ็กโพเนนเชียลใช้ α 0.9	0.099	59.04%	0.010	0.101
	LSM	0.207	105.3%	0.001	0.024
อยุธยา S1- กรุงเทพมหานคร S1	ANN	0.056	29.96%	0.005	0.068
	เอ็กโพเนนเชียลใช้ α 0.9	0.084	40.34%	0.009	0.095
	LSM	0.218	102.2%	0.001	0.013
อยุธยา S1- ขอนแก่น S1	ANN	0.040	19.29%	0.003	0.051
	เอ็กโพเนนเชียลใช้ α 0.9	0.180	8.27%	0.034	0.184
	LSM	0.313	94.0%	0.001	0.031
อยุธยา S1- หล่มสัก S1	ANN	0.051	15.66%	0.005	0.070
	เอ็กโพเนนเชียลใช้ α 0.9	0.084	22.24%	0.014	0.177
	LSM	0.358	97.0%	0.001	0.016

ตารางที่ 4.3 (ต่อ)

เส้นทาง	แบบจำลอง	MAD	MAPE	MSE	RMSE
อยุธยา S1- ลาดหญ้า S1	ANN	0.045	18.16%	0.004	0.061
	เอ็กโพแนนเชียลใช้ α 0.9	0.069	24.88%	0.009	0.093
	LSM	0.245	97.65%	0.001	0.012
อยุธยา S1- นครราชสีมา S1	ANN	0.054	22.17%	0.004	0.065
	เอ็กโพแนนเชียลใช้ α 0.9	0.344	25.62%	0.005	0.072
	LSM	0.241	97.50%	0.001	0.011
อยุธยา S1- เพชรบุรี S1	ANN	0.033	41.63%	0.002	0.040
	เอ็กโพแนนเชียลใช้ α 0.9	0.034	19.60%	0.002	0.043
	LSM	0.183	118.6%	0.001	0.005
อยุธยา S1- พระโขนง S1	ANN	0.041	22.35%	0.003	0.051
	เอ็กโพแนนเชียลใช้ α 0.9	0.048	22.17%	0.004	0.059
	LSM	0.224	100.7%	0.001	0.007
อยุธยา S1- พิษณุโลก S1	ANN	0.054	29.93%	0.004	0.063
	เอ็กโพแนนเชียลใช้ α 0.9	0.308	65.44%	0.0096	0.310
	LSM	0.458	97.53%	0.003	0.055
อยุธยา S1- พุนพิน S1	ANN	0.075	33.23%	0.008	0.090
	เอ็กโพแนนเชียลใช้ α 0.9	0.148	52.84%	0.023	0.150
	LSM	0.267	94.91%	0.001	0.0259

จากตารางเปรียบเทียบจะเห็นได้ว่าการพยากรณ์ด้วยวิธีการของโครงข่ายประสาทเทียม มีความถูกต้องมากที่สุด สำหรับการเปรียบเทียบผลการพยากรณ์เพื่อคาดการณ์ล่วงหน้าได้ข้อมูลจาก 12 เส้นทาง การใช้งาน โดยในหนึ่งเส้นทางจะประกอบด้วย



รูป (A) แสดงกราฟ สหความสัมพันธ์ (Correlation) ของการพยากรณ์ทั้ง 3 วิธีกับค่ากราฟฟิกเป้าหมาย (Target Traffic) ซึ่งเป็นค่าที่บันทึกไว้ ตั้งแต่วันที่ 29 ต.ค. 50 – 30 ธ.ค. 50

รูป (B) แสดงกราฟเปรียบเทียบเส้นแนวโน้มของค่ากราฟฟิกที่ได้จากการพยากรณ์แต่ละวิธีกับค่ากราฟฟิกเป้าหมาย


รูป (C) แสดงการพยากรณ์เพื่อคาดการณ์ล่วงหน้า 1 ปี ตั้งแต่วันที่ 1 ธ.ค. 50 ถึง 30 พ.ย. 51

ตารางที่ 4.4 เปรียบเทียบการพยากรณ์ทั้งสามวิธีกับค่าเป้าหมาย ระหว่างวันที่ 1 - 28 พ.ย. 50

Date	Target	Neural	Exponential	LMS
1/11/2550	0.3189	0.2676	0.387501	0.464
2/11/2550	0.3128	0.2749	0.421	0.460
3/11/2550	0.2498	0.2452	0.419418	0.455
4/11/2550	0.2646	0.2148	0.416652	0.451
5/11/2550	0.3102	0.21	0.41523	0.447
6/11/2550	0.3031	0.235	0.414053	0.442
7/11/2550	0.3016	0.2813	0.413097	0.438
8/11/2550	0.2900	0.2789	0.452924	0.433
9/11/2550	0.2920	0.2569	0.440828	0.429
10/11/2550	0.2386	0.2616	0.485177	0.424
11/11/2550	0.2219	0.2071	0.510588	0.420
12/11/2550	0.2906	0.2458	0.514792	0.416
13/11/2550	0.3021	0.2814	0.457765	0.411
14/11/2550	0.2944	0.2969	0.42757	0.407
15/11/2550	0.3002	0.2951	0.420145	0.402
16/11/2550	0.3246	0.2856	0.452884	0.398
17/11/2550	0.2608	0.2589	0.472385	0.394
18/11/2550	0.2394	0.2181	0.468802	0.389
19/11/2550	0.2977	0.2628	0.478591	0.385
20/11/2550	0.2889	0.2684	0.438379	0.380
21/11/2550	0.3331	0.268	0.420491	0.376
22/11/2550	0.3112	0.2702	0.312106	0.372
23/11/2550	0.2939	0.2769	0.286007	0.367
24/11/2550	0.2247	0.2454	0.365698	0.363
25/11/2550	0.2519	0.2121	0.425703	0.358
26/11/2550	0.3179	0.254	0.416136	0.354
27/11/2550	0.2915	0.2662	0.380708	0.349
28/11/2550	0.3002	0.2892	0.363348	0.344




(A)




(R)

(C)


รูปที่ 4.14 ผลการทดสอบนิรอรอลเส้นทาง อุษยา SI-ชดบุรี S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี



(A)




(R)




(C)


รูปที่ 4.15 ผลการทดสอบนิเวศเส้นทาง อุทยาน SI-เชียงใหม่ SI และการพยากรณ์ล่วงหน้ารวม 1 ปี



(A)






(B)




(C)


รูปที่ 4.16 ผลการทดสอบนิเวศเส้นทาง อุทยาน SI-หาค่าใหญ่ SI และการพยากรณ์ล่วงหน้ารวม 1 ปี




รูปที่ 4.17 ผลการทดสอบนิรवलเส้นทาง อุทยาน SI-กรุงเทพฯ S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี



(A)






(R)




(C)


รูปที่ 4.18 ผลทดสอบนิเวศเส้นทาง อยูทยา SI - ขอนแก่น SI และการพยากรณ์ด้วยน้ารวม 1 ปี




รูปที่ 4.19 ผลทดสอบนิรवलลเส้นทาง อยุธา S1- หลักสี่ S1 และการพยากรณ์ช่วงหนักรวม 1 ปี



(A)




(B)




(C)


รูปที่ 4.20 ผลทดสอบนิ่วรอลเส้นทาง อูชยา S1 - ลาดหญ้า S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี



(A)




(B)




(C)


รูปที่ 4.21 ผลทดสอบนิเวศเส้นทาง อุทยานฯ SI- นครราชสีมา SI และการพยากรณ์ล่วงหน้ารวม 1 ปี



(A)




(R)




(C)


รูปที่ 4.22 ผลทดสอบนิเวศเส้นทาง อุทยาน SI- เพชรบุรี SI และการพยากรณ์ล่วงหน้ารวม 1 ปี



(A)




(R)




(C)


รูปที่ 4.23 ผลทดสอบนิเวศเส้นทาง อุทยาน S1- พระโขนง S1 และการพยากรณ์ล่วงหน้ารวม 1 ปี



(A)



(B)




(C)

รูปที่ 4.24 ผลทดสอบนิรเวอร์อลเส้นทาง อู่ขยา S1- พืชญโลก S1 และการพยากรณ์ถ่วงหนารวม 1 ฐี


4.3.3 การหาจำนวนวงจร ใช้งานที่เหมาะสม

จากค่าที่ได้จากการคาดการณ์การเปลี่ยนแปลงปริมาณทราฟฟิกในแต่ละเส้นทางนำไปหาจำนวนวงจรการเชื่อมต่อที่เหมาะสมกับสภาพการเปลี่ยนแปลงของทราฟฟิกใช้ในอนาคต โดยทำการคืนอร์มอลไลต์กลับเป็นค่าทราฟฟิกจริงด้วยสมการที่ (4.5) จะได้ค่าทราฟฟิกในหน่วย Erlang ซึ่งเท่ากับจำนวนวงจรที่สามารถรองรับการใช้งานได้ดังแสดงในรูปที่ 4.25 ถึง 4.35


$$x_i = 2(\mu + \sigma) * x_{Normalized} \quad (4.5)$$




รูปที่ 4.25 การพยากรณ์การใช่วงจรล่องหน้ารวม 1 ปีเส้นทาง อยุธา S1- ชลบุรี S1




รูปที่ 4.26 การพยากรณ์การใช่วงจรล่องหน้ารวม 1 ปีเส้นทาง อยุธา S1-เชียงใหม่ S1




รูปที่ 4.27 การพยากรณ์การใช้วงจรถ่วงหน้ารวม 1 ปีเส้นทาง อยุรยา S1- หาดใหญ่ S1




รูปที่ 4.28 การพยากรณ์การใช้วงจรถ่วงหน้ารวม 1 ปีเส้นทาง อยุรยา S1- กรุงเทพฯ S1




รูปที่ 4.29 การพยากรณ์การใช้วงจรถ่วงหน้ารวม 1 ปีเส้นทาง อยุรยา S1- ขอนแก่น S1




รูปที่ 4.30 การพยากรณ์การใช้วงจรถ่วงหน้ารวม 1 ปีเส้นทาง อยุรยา S1- ภูเก็ต S1




รูปที่ 4.31 การพยากรณ์การใช้วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- ลาดหญ้า S1




รูปที่ 4.32 การพยากรณ์การใช้วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- นครราชสีมา S1




รูปที่ 4.33 การพยากรณ์การใช้วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- เพชรบุรี S1



รูปที่ 4.34 การพยากรณ์การใช้วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- พระโขนง S1



รูปที่ 4.35 การพยากรณ์การใช้วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- พิษณุโลก S1



รูปที่ 4.36 การพยากรณ์การใช้วงจรล่วงหน้ารวม 1 ปีเส้นทาง อยุธยา S1- พุนพิน S1


จากรูปที่ 4.25 ถึง 4.36 จะเห็นได้ว่าข้อมูลพยากรณ์จะแบ่งออกเป็น 2 ช่วง ซึ่งมีความแตกต่างจึงจัดวงจรใหม่ตามค่าสูงสุด แต่การจัดวงจรของสื่อสัญญาณจะจัดที่ระดับ 2Mb/s (E1) ซึ่งจะเท่ากับ 30 วงจร หรือใช้งานได้สูงสุด 30 คู่สายโทรศัพท์ ดังนั้นการเพิ่มหรือลดจะทำได้ที่ระดับ 30, 60, 90, 120 วงจร เช่น เส้นทางอยุธยา S1-ชลบุรี S1 มีจำนวนวงจร 240 จะเท่ากับ 8 E1 หรือ 2Mb/s 8 ชุด ดังแสดงในรูปที่ 4.4 เป็นต้น และ

จากรูปที่ 4.25 ถึงรูปที่ 4.36 นำมาสรุปหาจำนวนวงจร (Trunk) ที่จะใช้รองรับ ทราฟฟิกในอนาคตได้ตาม ตารางที่ 4.3 และจากตารางที่ 4.3 นำไปแสดงเป็นกราฟแท่งเพื่อเปรียบเทียบจำนวนการใช้วงจร (Trunk) ตามรูปที่ 4.36

จากตารางที่ 4.3 และรูปที่ 4.36 จะแสดงให้เห็นความสามารถในการลดจำนวนวงจรที่ใช้ลงงานเดิม 60 ถึง 210 วงจร และเนื่องจากแต่ละเส้นทางมีระยะทางที่ไกลมาก ถ้าเปรียบเทียบเป็นวงจรเช่าจะมีมูลค่าที่สูง ดังนั้นจึงสมควรที่จะนำไปใช้ประโยชน์อย่างอื่นได้ เช่น วงจรของ Internet หรือใช้เป็นระบบสัญญาณข้อมูลที่มีการใช้งานเพิ่มขึ้นอย่างมากในปัจจุบัน และในอนาคต โดยถ้าคิดที่วงจรโดยรวมทั้งโครงข่าย 34 ยูนิต 561 เส้นทางการเชื่อมโยง จะทำให้มีจำนวนวงจรที่ว่างเป็นจำนวนมากในการรองรับการบริการใหม่ต่อไป

ตารางที่ 4.4 แสดงจำนวนวงจรใช้งานปัจจุบัน และจัดวงจรใช้งานใหม่ตามการพยากรณ์

เส้นทาง อยุธยา S1 -	วงจรที่ใช้ งานปัจจุบัน	วงจรที่พยากรณ์ ล่วงหน้า 6 เดือนแรก	วงจรที่พยากรณ์ ล่วงหน้า 6 เดือนหลัง	จัดวงจรใช้ งานใหม่	วงจรที่ ยกเลิก
ชลบุรี S1	240 (8E1)	55	50	60 (2E1)	180
เชียงใหม่ S1	120 (4E1)	22	14	30 (1E1)	90
หาดใหญ่ S1	90 (3E1)	4	5	30 (1E1)	60
กรุงเทพมหานคร S1	270 (9E1)	72	37	90 (3E1)	180
ขอนแก่น S1	120 (4E1)	17	10	30 (1E1)	90
หลักระ S1	270 (9E1)	95	86	120 (4E1)	150
ลาดหญ้า S1	180 (6E1)	60	63	90 (2E1)	90
นครราชสีมา S1	210 (7E1)	20	25	30 (1E1)	180
เพชรบุรี S1	240 (8E1)	21	12	30 (1E1)	210
พระโขนง S1	150 (5E1)	48	39	60 (2E1)	90
พิษณุโลก S1	150 (5E1)	65	50	90 (3E1)	60
พุนพิน S1	90 (3E1)	15	21	30 (1E1)	60



รูปที่ 4.37 การพยากรณ์การใช้วงจรล่วงหน้ารวม 1 ปี และจำนวนวงจรที่จัดใหม่ทั้ง 12 เส้นทาง

บทที่ 5

สรุปผลการวิจัย และข้อเสนอแนะ

5.1 สรุปผลการวิจัย

การศึกษาเรื่องการพยากรณ์เพื่อคาดการณ์การเปลี่ยนแปลงของกราฟฟิคโทรศัพท์โดยใช้โครงข่ายประสาทเทียมมีจุดประสงค์เพื่อศึกษา และสร้างตัวแบบพยากรณ์ด้วยอัลกอริทึมโครงข่ายประสาทเทียมที่เหมาะสม ถูกต้อง มีประสิทธิภาพในการพยากรณ์การเปลี่ยนแปลงของกราฟฟิคโทรศัพท์ และสามารถนำไปใช้ได้สะดวกเมื่อเปรียบเทียบกับวิธีการทางสถิติที่ใช้อยู่เดิม

จากการศึกษา พบว่า โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ สามารถใช้กับข้อมูลอนุกรมเวลาการเปลี่ยนแปลงกราฟฟิคย้อนหลังเป็นข้อมูลอินพุตโมเดลของโครงข่ายที่เหมาะสมคือ 7-15-7 โดยมีการปรับจำนวนรอบเข้าสู่ค่าเสถียรที่ 800 รอบ สำหรับการปรับอัตราการเรียนรู้ (η) โมเมนตัม (μ) พบว่า มีผลแตกต่างที่น้อยมากเมื่อเปรียบเทียบกับค่าการปรับเปลี่ยนแปลงจำนวนรอบ อินพุตชั้นซ่อน และ เอาต์พุต แต่เนื่องจากคาดการณ์การเปลี่ยนแปลงของกราฟฟิคนี้ได้นำข้อมูลของกราฟฟิคเพียงอย่างเดียวมาเป็นอินพุต มิได้พิจารณาปัจจัยอย่างอื่น ๆ ประกอบด้วย ดังนั้นการเปลี่ยนแปลงที่เกิดจากปัจจัยอื่น ๆ เช่น การเปลี่ยนแปลงทางเศรษฐกิจ การเปลี่ยนแปลงเทคโนโลยี หรือการเปลี่ยนแปลงทางพฤติกรรมการใช้โทรศัพท์ในวันหยุด ฯลฯ จึงมีผลต่อค่าผิดพลาดได้ ฉะนั้นในการนำโมเดลนี้ไปงานในเส้นทางอื่น จะต้องใช้ข้อมูลในเส้นทางนั้นในการเรียนรู้เท่านั้น ผลการคาดการณ์การเปลี่ยนแปลงของกราฟฟิคจึงจะถูกต้องมากที่สุด

การตรวจสอบความถูกต้องในการคาดการณ์การเปลี่ยนแปลงของกราฟฟิคในบทวิจัยนี้ ใช้ค่าสถิติวัดความถูกต้อง 3 ค่าได้แก่ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) ค่าเบี่ยงเบนสัมบูรณ์เฉลี่ย (MAD) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE)

ผลการวิจัย พบว่า การคาดการณ์การเปลี่ยนแปลงของกราฟฟิค ในระบบโทรศัพท์โดยใช้โครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับมีความแม่นยำมากกว่าวิธีทางสถิติ เมื่อมีการปรับสอนด้วยข้อมูลอนุกรมเวลาที่เหมาะสมมีโครงสร้างโมเดลเหมาะสมที่ 7-15-7 ค่าอัตราการเรียนรู้ และค่าโมเมนตัม มีค่าเท่ากับ 0.2 และจำนวนรอบเข้าสู่ค่าเสถียรที่ 800 รอบ ก็เพียงพอสำหรับการพยากรณ์ที่ได้ตั้งเป้าหมายไว้ โดยมีค่า MSE ไม่มากกว่า 0.1 แต่ที่ทำให้ดีที่สุดที่สุดคือ ค่า MSE เท่ากับ 0.025 โมเดลของโครงข่ายประสาทเทียมนี้ สามารถนำไปใช้พยากรณ์ เพื่อคาดการณ์การเปลี่ยนแปลงของกราฟฟิคโทรศัพท์ในเส้นทางอื่น ๆ ได้ตามต้องการเพื่อประโยชน์ในการจัดวางจรรยาบรรณการเปลี่ยนแปลง กราฟฟิคในอนาคต ได้อย่างมีประสิทธิภาพ

5.2 ข้อเสนอแนะ

1. งานวิจัยนี้ได้ทำการศึกษาปัจจัยที่เกี่ยวข้องเพียงตัวแปรเดียว ซึ่งถ้าเพิ่มตัวแปรเข้ามาร่วมพิจารณาอาจทำให้ความถูกต้องในการคาดการณ์การเปลี่ยนแปลงของ ทราฟฟิกสูงขึ้น
2. งานวิจัยนี้อาศัยแนวความคิดการวิเคราะห์ความสัมพันธ์ของค่าสังเกตตามทฤษฎีของอนุกรมเวลาโดยถือว่าข้อมูลที่เกิดขึ้นนั้นเป็นไปตามเวลาที่เปลี่ยนแปลงไม่ได้ศึกษาตัวแบบหรือทฤษฎีทางเศรษฐศาสตร์ ในงานวิจัยครั้งต่อไป อาจทำการศึกษาตามทฤษฎีทางเศรษฐศาสตร์ และเปรียบเทียบค่าพยากรณ์เพื่อคาดการณ์การเปลี่ยนแปลงของทราฟฟิกของตัวแบบทางเศรษฐศาสตร์กับค่าพยากรณ์ที่ได้จากตัวแบบอนุกรมเวลา
3. งานวิจัยครั้งต่อไป การศึกษาวิธีโครงข่ายประสาทเทียมอาจทำการแปลงข้อมูล เช่น การยกกำลังสอง การถอดรากที่สอง หรือการแปลงเป็นค่าลอการิทึมเป็นต้น เพื่อเพิ่มประสิทธิภาพในการคาดการณ์การเปลี่ยนแปลงของ ทราฟฟิก
4. งานวิจัยครั้งต่อไป อาจจะเปรียบเทียบผลการพยากรณ์ระหว่างอัลกอริทึมของโครงข่ายประสาทเทียมที่แตกต่างกัน เช่น เปรียบเทียบระหว่างวิธีการแพร่กระจายย้อนกลับกับวิธีการที่ใหม่กว่า เช่น วิธีโครงข่ายเรเดียลเบสิกฟังก์ชันนาร์มา (Radial Basic Function NARAMA)

เอกสารอ้างอิง

- [1] Roger L, Freeman, **Telecommunication System Engineering**, Printed in United State of America, 2004.
- [2] Tawil Paungma, Manoon Sukkasem, Winai Sangkhawijit, Phicet Moungmoul., “Utilizing The_Neural Network Model For Traffic Prediction At Loaded Area Of GSM System”, CITA Malaysia 17-19 Oct 2001 pp.280-288
- [3] ประสิทธิ์ ทัพพุดิ, การสื่อสารโทรคมนาคม กรุงเทพมหานคร : บริษัทซีเคียวเคชั่น จำกัด (มหาชน)
- [4] สมเกียรติ เกตุเอี่ยม, เทคนิคการพยากรณ์ : มหาวิทยาลัยทักษิณ
- [5] University of uwichill FTP site
<http://scitec.uwichill.edu.bb/cmp/online/p21h/lecture1/lect1.htm>
- [6] N.K. Bose and P. Liang, **Neural Network Fundamentals with Graphs, Algorithm, and Application**, New York: McGraw Hill, 1996.
- [7] R.P. Lippman, “An Introduction to Computing with Neural Nets,” IEEE Trans. ASSP, pp.170-174, 1987.
- [8] L. Fausette, **Fundamentals of Neural Network Architecture Algorithm, and Applications**, Prentice-Hall 1994.
- [9] L. M. Fu, **Neural Network in Computer Intelligence**, MacGraw-Hill 1994.
- [10] S. Haykin, **Digital Neural Network –A Comprehensive Foundation**, Macmillan College Publishing Co., 1994.
- [11] S.Y.Kung, **Digital Neural Network** , Prentice-Hall, 1994.
- [12] D.O.Hebb, The **Organization of Behavior: A neuropsychological theory**, New York : Wiley, 1949.
- [13] M.T.Hagan, H.B. Demuth, and M.Beal, **Neural network design.**, Boston:PWS Publishing Co., 1996.

ภาคผนวก

ผลงานทางวิชาการที่ได้รับการตีพิมพ์

ผลงานทางวิชาการที่ได้รับการตีพิมพ์

1. **S. Ardhan**, S. Satsri, V. Chutchavong and O. Sangaroon, “Improved Model for traffic Fluctuation prediction by Neural network” , International Conference on Control, Automation and Systems in COEX, Seoul, Korea, Oct. 17-20, 2007.
2. S. Satsri, **S. Ardhan**, V. Chutchavong and O. Sangaroon, “ANN based NGN IP Traffic Prediction in Thailand”, International Conference on Control, Automation and Systems in COEX, Seoul, Korea, Oct. 17-20, 2007.
3. S. Satsri, **S. Ardhan**, V. Chutchavong and O. Sangaroon, “IP Traffic Prediction in Ip-based NGN in THAILAND by Neural Network”, International Conference on Engineering, Applied Science, and Technology in The Swissotel Le Concorde, Bangkok, Thailand, Nov. 21-23, 2007.

ICCAS 2007

International Conference on
Control, Automation and Systems

October 17(Wed.) - 20(Sat.), 2007
COEX, Seoul, Korea

Improved Model for traffic fluctuation prediction by Neural network

S. Ardhan, S. Satsri V. Chutchavong and O. Sangaroon

Research Center for Communication and Information Technology (ReCCIT) and

Department of Information Engineering, Faculty of Engineering,

King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520, Thailand

E-mail: ksornlar@kmitl.ac.th

Abstract: The traffic prediction are mainly used to improve the performance of telecommunication network management. This paper improved model for telephone traffic prediction in Thailand by using artificial neural network (ANN) with back propagation learning algorithms. By applied data which is collected at different node in main routes of TOT, Thailand telephone network for learning process and testing. The neural network structure and input/output musters are descried in detail. We present the comparatively results of simulation with another methods, the results shows traffic fluctuation prediction by the method of ANN is accurately.

Keywords: telephone traffic prediction, neural network

1. INTRODUCTION

A main route of telephone network in Thailand can be model as a set of nodes (switching offices) and link (trunk groups) are shown in figure 1. Trunk groups are used to link between switching offices which is carries the telephone traffic flow, each of which can support a conversation. A telephone network can occasionally encounter an extremely high traffic load resulting from a social event, natural disaster or network equipment failure. In many cases, however, having a large network capacity just to cope with occasional high traffic loads cannot be economically justified. To prevent the problem of traffic congestion from taking place, efficient network management is required

This paper proposes traffic prediction by means of neural network with back propagation learning algorithms, because nonlinear elements in neural network is reasonable to use for unknown function approximation[1-2]. In the following, we describe on the structures of neural networks with fitting with the measurement data in difference area and compared the results with statistical method.




Fig.1 Main route of TOT telephone network, Thailand.

2. TRAFFIC TELEPHONE AND DATA ACQUISITION

Traffic is the number of message over a trunk circuit in duration of calls, includes the relationship between busy hour call attempt and busy hour call. From the definition of the Erlang , traffic carried by trunk group is given by equation of traffic density

$$A = \frac{Q_i T}{60} \quad , \quad \text{Where } A \text{ is offered traffic (Erlangs),}$$

Q_i is number of calls in one hour (calls) and T is average call holding time (minute). The traffic data measures from originated on inlets is called traffic offered this equal to the average number of calls which engages the outlets is called the traffic carried by the outlets.

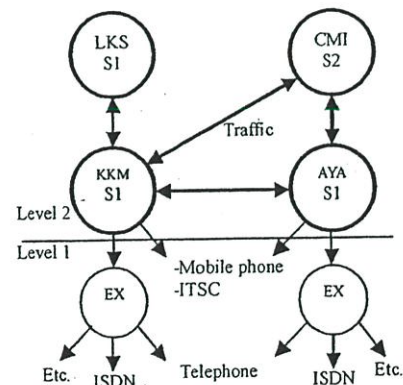


Fig. 2 Selected 4 node of telephone network for testing.

Traffic data in this work are collected from TOT's thirteen node (main exchange) in figure 1, four node is in Bangkok and nine node is in provincial area. The total is 561 routes. The example for analysis selected from main route of KKMM2 to AYAS1, KKMM2 to CMIS2, KKMS2 to LKKS2, CMIS2 to AYAS1, illustrated in figure 2 And then we used this data for train and test.

Figure 3 shows the examples of traffic variation collecting for one year from November, 2004 to October, 2005 over route of KKM M1 to AYA S1. The maximum traffic are occurring about 110 erlangs . The average volume of traffic during a maximum of 30 days a year is specified as Reference (standard) traffic.




Fig. 3 Traffic variation measures in 1 years (Nov,2004 to Oct,2005) KKM M1 to AYA S1 route.

Figure 4 shows daily telephone traffic variation in one week of October, 2006. It can be seen that the maximum traffic occurring in busy hour of Tuesday, Wednesday, Thursday and Friday, respectively. And decrease to a haft in Saturday, Monday and Sunday. Finally, data are spit in two subsets (4 days and 3days periods) for which the class distribution is 60 erlangs and 30 erlangs are shown in figure 4.




Fig. 4 Daily traffic variation measures over KKM M1 to AYA S1 route in one week of October, 2006.

3. NEURAL NETWORK (NN) MODEL

The neural network model is that mimics the learning of the human brain, composed of four processing element as follows, input node, hidden unit, output node and weight value (called its training or learning algorithm). There are many of different neural network models and many applications, applied to a wide variety of problem, are described in the literature. Therefore, this section will focus on model of a multilayer feedforward with back propagation learning algorithms (MLFN).The chief disadvantage that the long training periods are often required.

Figure 5 shows the modification model of typical MLFN architecture which consist of 7 units of input, (X_p units), one layer of 15 hidden units (Z_j units), and 7

output units (Y_p units). The output units and hidden units also may have biases (b_2 and b_1).




Fig.5 Back propagation MLFN with one hidden layer.

As it can be seen in figure 5, Only the direction of information flow for feaddorward phase operation is shown. During the back propagation phase of learning , signal are sent in the reverse direction. Its must learn to map the input to the output and takes many iterations for conventional feed forward [1-4].

As mentioned earlier, the flowchart of training process shown in figuer 6.




Fig. 6 Sizing and training a MLFN.

The algorithm is as follows: By specific each input units $Xp = (x_{p1}, x_{p2}, x_{p3}, \dots, x_{pn})$, the traffic data which are fed to input layers, while p is the training sequence and obtain net input j^{th} of hidden layer is

$$net_{pj}^h = \sum_{i=1}^N V_{ji}^h x_{pi} + b_j^h \tag{1}$$

The output at hidden layer is

$$Z_{pj} = f(net_{pj}^h) \tag{2}$$

Given equations at output layer is

$$net_{pk}^o = \sum_{j=1}^N W_{kj}^o Z_{pj} + b_k^o \quad (3)$$

$$Y_{pk} = f(net_{pk}^o) \quad (4)$$

Where $f(x)$ is the binary sigmoid function ,

$$f(x) = \frac{1}{1+e^{-x}}, \quad W_k (k = 1 \dots m) \text{ is weight value of hidden nodes}$$

For the back propagation of error, each output units receives a target pattern corresponding to the input training pattern ,computes its error information term, Which, μ is learning rate, are η is momentum value.

$$\delta_{pk} = f'(net_{pk}^o)(tk - Y_{pk}) \quad (5)$$

Where $(tk - Y_{pk})$ is an error at output layer.

Calculates its weight correction term,

$$\Delta W_{kj}(t+1) = \eta \delta_{pk} Z_{pj} + \mu \Delta W_{kj}(t) \quad (6)$$

$$W_{kj}(t+1) = W_{kj}(t) + \Delta W_{kj}(t+1) \quad (7)$$

And compensation of hidden layer can be calculated from the following equations

$$\delta_{pj} = f'(net_{pk}^h) \sum_k \delta_{pk} W_{kj} \quad (8)$$

where $\sum_k \delta_{pk} W_{kj}$ is an error in the hidden layer.

Calculates its weight correction term (used to update V_{ij} later),

$$\Delta V_{ji}(t+1) = \eta \delta_{pj} X_{pi} + \mu \Delta V_{ji}(t) \quad (9)$$

$$V_{ji}(t+1) = V_{ji}(t) + \Delta V_{ji}(t+1) \quad (10)$$

From equation (1) to (10), its seen that during training , each out put unit computed activation with its target values to determine the associated error for that pattern and used to update the weights between the hidden layer and input layer. In this paper we used Mean Absolute Percentage Error (MAPE), Mean Square Error (MES), Root Mean Square Error (RMES) to defined the error between the desired response and the output obtained with the neural network. That is

$$MES = \frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2 \quad (11)$$

$$MAD = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (12)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{e_i}{Y_i} \times 100 \quad (13)$$

4. SIMULATION RESULTS

In these experiments, back propagation MLFN with one hidden layer was used. The neural network had 7 inputs, 7 outputs and trial and error shows that 15 hidden units give best results. The linear output unit is used to aid function fitting. This architecture is fixed prior to training. By using actual data from four route have shown in figure 2, the training set took 50 % , the test set took the same as 50% ,we used MATLAB to design the neural network is feasible.

The example results of traffic prediction, comparison with actual data and statistic prediction in period of one month and one year, are in figure 7 to figure 14 Table 1, illustrated the comparison of error in various methods in one month and one year

Table 1 Prediction error comparison

Period	Model	MAD	MAPE	MSE
1-month KKMM1- AYASI	ANN	0.026	6.95%	0.0007
	Exponential	0.104	26.73%	0.104
1-year KKMM1- AYASI	ANN	0.012	7.39%	0.0034
	Exponential	0.046	25.40%	0.0459
1-month AYASI-CMISI	ANN	0.012	9.30%	0.0058
	Exponential	0.253	11.50%	0.011
1-year AYASI-CMISI	ANN	0.012	7.39%	0.0034
	Exponential	0.046	25.40%	0.0459

5. CONCLUSIONS

In the simulation, MLMF neural net work have applied to the prediction of offered traffic load at switching node. The neural method has been compared with other prediction approaches, the results of simulation shows that its can simplify the procedure of prediction and enhance the efficiency, the performance of dynamic routing and rerouting can be improved, but it is difficult to establish a precise mathematical model because of the complexity of nonlinear mapping of function. This kind of NN can be applied

6. REFERENCE

- [1] Kaastra I and Boyd, M. (1996). "Desing a neural network for forecasting and economic time series." *Neurocomputing* 10:215-236
- [2] T.Paungma, M.Sukkasem, W.Sangkawijit, P.Moung moul., "Utilizing The Neural Network Model For Traffic Prediction At Loaded Area Of GSM System", No.280-288 CITA Malaysia 2001
- [3] Maier, H.R. and Dancy G.C. , "The Use of Artificittial Neural Network for The Prediction of Water Quality Parameter, Water Resources Research" Vol.32, No.4 1013-1022 ,Aril,1996
- [4] Patterson, D.W. "Artificittial Neural Network ,Simon & Schuster (Asia) Ple." Ltd., New York, 1996




Fig. 7 Monthly comparison of actual traffic and prediction measure from KKM M1 to LKS S2.




Fig. 8 One year comparison of actual traffic and prediction measure from KKM M1 to LKS S2.




Fig. 9 Monthly comparison of actual traffic and prediction measure from KKM M1 to AYA S1.




Fig. 10. One year comparison of actual traffic and prediction measure from 10 KKM M1 to AYA S1.




Fig. 11 Monthly comparison of actual traffic and prediction measure from KKM M1 to CMI S1.




Fig. 12 One year comparison of actual traffic and prediction measure from KKM M1 to CMI S1.




Fig. 13 Monthly comparison of actual traffic and prediction measure from AYA S1 to CMI S1.




Fig. 14 One year comparison of actual traffic and prediction measure from AYA S1 to CMI S1.

ประวัติผู้เขียน

นายศรีวิชัย อางหาญ เกิดเมื่อวันที่ 17 เมษายน พ.ศ.2516 จังหวัดชุมพร จบการศึกษา
ระดับปริญญาวิศวกรรมศาสตรบัณฑิต สาขาเทคโนโลยีโทรคมนาคม จากสถาบันเทคโนโลยีราชมงคล
(คลองหก) ในปี พ.ศ.2543 และทำงานกับบริษัท ทีโอที จำกัด (มหาชน) ปัจจุบันดำรงตำแหน่ง
วิศวกร 5