

การพยากรณ์อนุกรมเวลาดำวยตัวแบบผสม
ระหว่าง ARIMA และ เครือข่ายประสาทเทียม

โดย
นายพงษ์ศิริ ศิริพานิช

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาคณิตศาสตร์และเทคโนโลยีสารสนเทศ
ภาควิชาคณิตศาสตร์
บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร
ปีการศึกษา 2550
ลิขสิทธิ์ของบัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

**TIME SERIES FORECASTING USING A COMBINED ARIMA AND
ARTIFICIAL NEURAL NETWORK MODEL**

By

Pongsiri Siripanich

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

A Master's Report Submitted in Partial Fulfillment of the Requirements for the Degree

MASTER OF SCIENCE

Department of Mathematics

Graduate School

SILPAKORN UNIVERSITY

2007

บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร อนุมัติให้สารนิพนธ์เรื่อง “การพยากรณ์อนุกรมเวลาด้วยตัวแบบผสมระหว่าง ARIMA และ เครือข่ายประสาทเทียม” เสนอโดย นายพงษ์ศิริศิริพานิช เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาคณิตศาสตร์และเทคโนโลยีสารสนเทศ

.....

(รองศาสตราจารย์ ดร.ศิริชัย ชินะตั้งกูร)

คณบดีบัณฑิตวิทยาลัย

วันที่ เดือน พ.ศ.

ผู้ควบคุมสารนิพนธ์

ผู้ช่วยศาสตราจารย์ ดร.ปราณี นิลกรณ์

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

คณะกรรมการตรวจสอบวิทยานิพนธ์

.....ประธานกรรมการ

(รองศาสตราจารย์ ไพบุลย์ รัตนประเสริฐ)

...../...../.....

.....กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.ปราณี นิลกรณ์)

...../...../.....

.....กรรมการ

(รองศาสตราจารย์ ดร.สุดา ตระการเถลิงศักดิ์)

...../...../.....

47308303 : สาขาวิชาคณิตศาสตร์และเทคโนโลยีสารสนเทศ

คำสำคัญ : ตัวแบบผสมระหว่าง ARIMA และ เครือข่ายประสาทเทียม / การพยากรณ์อนุกรมเวลา

พงษ์ศิริ ศิริพานิช : การพยากรณ์อนุกรมเวลาด้วยตัวแบบผสมระหว่าง ARIMA และ เครือข่ายประสาทเทียม. อาจารย์ผู้ควบคุมสารนิพนธ์ : ผศ. ดร. ปราณี นิลกรณ์. 54 หน้า.

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อเพื่อเปรียบเทียบความถูกต้องของการพยากรณ์อนุกรมเวลาด้วยตัวแบบ ARIMA(Autoregressive Integrated Moving Average Model) ANN(Artificial Neural Network) และตัวแบบผสมระหว่าง ARIMA และ ANN ในการพยากรณ์ราคาหุ้นในตลาดหลักทรัพย์โดยใช้ข้อมูลของ บริษัท ปตท. จำกัด (มหาชน):PTT และ ธนาคารกรุงเทพ จำกัด (มหาชน) :BBL ตั้งแต่วันที่ 4 มกราคม 2548 ถึง 5 เมษายน 2550 รวมจำนวน 554 วัน โดยแบ่งข้อมูลเป็น 2 ส่วน คือข้อมูล 524 วันแรกเป็นชุดข้อมูลฝึกสอน และ ข้อมูล 30 วันหลังเป็นชุดข้อมูลทดสอบ

ผลการวิจัยพบว่าในการพยากรณ์ข้อมูลราคาปิดของหุ้น PTT ตัวแบบผสมระหว่าง ARIMA และ ANN สามารถให้ค่าพยากรณ์ในอนาคตระยะสั้นได้ถูกต้องมากกว่าวิธี ตัวแบบ ARIMA และ ตัวแบบ ANN แต่สำหรับการพยากรณ์ค่าในระยะยาว ตัวแบบ ANN ให้ค่าพยากรณ์ได้ถูกต้องมากที่สุด แต่ในการพยากรณ์ข้อมูลราคาปิดของหุ้น BBL พบว่าตัวแบบ ANN ให้ค่าพยากรณ์ได้ถูกต้องมากที่สุดทั้งระยะยาวและระยะสั้น

ภาควิชาคณิตศาสตร์

บัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร

ปีการศึกษา 2550

ลายมือชื่อนักศึกษา.....

ลายมืออาจารย์ผู้ควบคุมวิทยานิพนธ์

47308303 : MAJOR : MATHEMATICS AND INFORMATION TECHNOLOGY

KEY WORD : COMBINED ARIMA AND ARTIFICIAL NEURAL NETWORK MODEL /
TIME SERIES FORECASTING

PONGSIRI SIRIPANICH : TIME SERIES FORECASTING USING A COMBINED
ARIMA AND ARTIFICIAL NEURAL NETWORK MODEL. MASTER'S REPORT
ADVISORS : ASST. PROF. PRANEE NILAKORN, Ph.D. 54 pp.

The purpose of this master's report is to compare the efficiencies of the ARIMA(Autoregressive Integrated Moving Average Model), ANN(Artificial Neural Network) and combined ARIMA and ANN models for time series forecasting of the stock prices of The Stock Exchange of Thailand. The stock prices under study are of the PTT PUBLIC COMPANY LIMITED (PTT) and the BANGKOK BANK PUBLIC COMPANY LIMITED(BBL) from January 4, 2005 through April 5, 2007, totalling 554 days. The prices of the first 524 days are used as a training set and of the last 30 days are used as a test set.

It was found that for the PTT stock prices, the combined ARIMA and ANN model performed best for shorter term forecasting but the ANN model performed best for long term forecasting. For the BBL stock prices, the ANN model performed best both for short term and long term forecasting.

Department of Mathematics Graduate School, Silpakorn University Academic Year 2007

Student's signature

Master's Report Advisors's signature

กิตติกรรมประกาศ

ในการศึกษาและเรียบเรียงวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี ผู้วิจัยต้องขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.ปราณี นิลกรณ์ รองศาสตราจารย์ ดร.สุดา ตระการเถลิงศักดิ์ ซึ่งเป็นอาจารย์ที่ปรึกษาของงานวิจัยนี้ที่ให้คำแนะนำปรึกษา ตรวจสอบ ตลอดจนแก้ไขข้อผิดพลาดต่างๆ

ขอกราบขอบพระคุณคณะอาจารย์ ภาควิชาคณิตศาสตร์ ภาควิชาสถิติ และ ภาควิชาคอมพิวเตอร์ ทุกท่านที่ได้ช่วยอบรม สั่งสอน และให้ความรู้กับข้าพเจ้า

ขอกราบขอบพระคุณ คุณพ่อ คุณแม่ คุณป้าสุกัญญา แสงกระสินธุ์ ญาติพี่น้อง และเพื่อนๆ ผู้ให้กำลังใจ สนับสนุน และให้โอกาสทางการศึกษาจนถึงระดับนี้

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญตาราง.....	ญ
สารบัญภาพ.....	ฎ
บทที่	
1 บทนำ.....	1
ความเป็นมาและความสำคัญของปัญหา.....	1
วัตถุประสงค์ของการศึกษา	2
สมมติฐานของการศึกษา	2
ขอบเขตของการศึกษา	2
ขั้นตอนการศึกษา.....	2
ประโยชน์ที่คาดว่าจะได้รับ.....	2
นิยามศัพท์.....	3
2 เอกสารและงานวิจัยที่เกี่ยวข้อง.....	4
อนุกรมเวลา(Time Series).....	4
ตัวแบบ ARIMA	5
การกำหนดตัวแบบ.....	6
ฟังก์ชันสหสัมพันธ์ในตัวเอง.....	6
การทดสอบความมีนัยสำคัญของสหสัมพันธ์ในตัวเองจากตัวอย่าง....	7
ฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วน.....	7
การทดสอบความมีนัยสำคัญของสหสัมพันธ์ในตัวเองบางส่วน จากตัวอย่าง.....	8
การกำหนดตัวแบบและอันดับของ p และ q.....	8
การประมาณค่าพารามิเตอร์.....	9
การตรวจสอบความเหมาะสมของตัวแบบ.....	10

บทที่	หน้า
ตัวแบบ ANN	11
การทำงาน.....	12
การเรียนรู้ของเครือข่ายประสาทเทียม.....	12
ตัวแบบผสมระหว่าง ARIMA และ ANN	15
ข้อมูลเกี่ยวกับราคาหุ้น	15
การคำนวณราคาปิดของหลักทรัพย์ต่อวัน.....	16
หุ้น PTT.....	17
หุ้น BBL.....	17
งานวิจัยที่เกี่ยวข้อง	18
3 วิธีดำเนินการวิจัย.....	21
ขั้นตอนในการดำเนินการวิจัย.....	21
เครื่องมือที่ใช้ในการวิเคราะห์.....	22
4 ผลการวิเคราะห์ข้อมูล.....	23
ส่วนที่1 การวิเคราะห์ข้อมูลราคาหุ้น PTT	23
ลักษณะทั่วไปของข้อมูลอนุกรมเวลา.....	23
ตัวแบบ ARIMA.....	24
ตัวแบบ ANN.....	27
ตัวแบบผสมระหว่าง ARIMA และ ANN	28
ประสิทธิภาพของตัวแบบ.....	28
ส่วนที่2 การวิเคราะห์ข้อมูลราคาหุ้น BBL.....	34
ลักษณะทั่วไปของข้อมูลอนุกรมเวลา.....	34
ตัวแบบ ARIMA.....	34
ตัวแบบ ANN.....	38
ตัวแบบผสมระหว่าง ARIMA และ ANN	39
ประสิทธิภาพของตัวแบบ.....	39
5 สรุปอภิปรายผล และข้อเสนอแนะ	45
สรุปผลการวิจัย.....	45
อภิปรายผลการวิจัย.....	46

	หน้า
ข้อเสนอแนะเพื่อการวิจัยครั้งต่อไป.....	47
บรรณานุกรม.....	48
ภาคผนวก.....	50
feed-forward backpropagation neural networks Source Code.....	51
feed-forward backpropagation neural networks Source Code(Hybrid).....	52
ARIMA Syntax สำหรับหลักทรัพย์ BBL: ธนาคารกรุงเทพ จำกัด (มหาชน).....	53
ประวัติผู้วิจัย.....	54

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

สารบัญตาราง

ตารางที่		หน้า
1	สรุปข้อมูลงานวิจัยที่เกี่ยวข้อง.....	20
2	ความคลาดเคลื่อนในการพยากรณ์ด้วยแบบ ANN ใช้ข้อมูลเข้าราคาย้อนหลัง 1 วัน....	27
3	ความคลาดเคลื่อนในการพยากรณ์ด้วยแบบ ANN ใช้ข้อมูลเข้าราคาย้อนหลัง 2 วัน...	27
4	ความคลาดเคลื่อนในการพยากรณ์ด้วยแบบผสมระหว่าง ARIMA และ ANN.....	28
5	ประสิทธิภาพในการพยากรณ์หุ้น PTT ของด้วยแบบ ARIMA ANN และ ด้วยแบบผสม.....	29
6	ความคลาดเคลื่อนในการพยากรณ์ด้วยแบบ ANN ใช้ข้อมูลเข้าราคาย้อนหลัง 1 วัน....	38
7	ความคลาดเคลื่อนในการพยากรณ์ด้วยแบบ ANN ใช้ข้อมูลเข้าราคาย้อนหลัง 2 วัน...	38
8	ความคลาดเคลื่อนในการพยากรณ์แบบผสมระหว่าง ARIMA และ ANN.....	39
9	ประสิทธิภาพในการพยากรณ์หุ้น BBL ของด้วยแบบ ARIMA ANN และ ด้วยแบบผสม.....	40

สารบัญภาพ

ภาพที่	หน้า
1 ACF (Stationary).....	6
2 ACF (Non-Stationary)	6
3 Model ของ Neuron ในคอมพิวเตอร์.....	12
4 การเรียนรู้แบบมีการสอน (Supervised Learning)	13
5 การเรียนรู้แบบไม่มีการสอน (Unsupervised Learning).....	13
6 Feed forward BPNN ซึ่งมีชั้นซ่อน 1 ชั้น.....	14
7 ภาวะของ ราคาปิดของหุ้นการปิโตรเลียมแห่งประเทศไทย PTT ระหว่างปี 2548 – 2550.....	23
8 ACF ของราคาหุ้น PTT.....	24
9 ACF ผลต่างอันดับ 1 ของราคาหุ้น PTT.....	24
10 PACF ผลต่างอันดับ 1 ของราคาหุ้น PTT.....	25
11 ค่าประมาณพารามิเตอร์ของตัวแบบ ARIMA(1,1,0).....	25
12 ACF ของส่วนเหลือที่ได้จากตัวแบบ ARIMA(1,1,0).....	26
13 เปรียบเทียบค่าพยากรณ์โดย ARIMA กับ ข้อมูลจริง.....	30
14 เปรียบเทียบค่าพยากรณ์โดย ANN กับ ข้อมูลจริง.....	31
15 เปรียบเทียบค่าพยากรณ์โดย ตัวแบบผสม กับ ข้อมูลจริง.....	32
16 เปรียบเทียบค่าพยากรณ์กับข้อมูลจริง.....	33
17 ภาวะของ ราคาปิดของหุ้นการปิโตรเลียมแห่งประเทศไทย BBL ระหว่างปี 2548 – 2550.....	34
18 ACF ของราคาหุ้น BBL.....	35
19 ACF ผลต่างอันดับ 1 ของราคาหุ้น BBL.....	35
20 PACF ผลต่างอันดับ 1 ของราคาหุ้น BBL.....	36
21 ค่าประมาณพารามิเตอร์ของตัวแบบ ARIMA(1,1,0).....	36
22 ACF ของส่วนเหลือที่ได้จากตัวแบบ ARIMA(1,1,0).....	37

ภาพที่		หน้า
23	เปรียบเทียบค่าพยากรณ์โดย ARIMA กับ ข้อมูลจริง.....	41
24	เปรียบเทียบค่าพยากรณ์โดย ANN กับ ข้อมูลจริง.....	42
25	เปรียบเทียบค่าพยากรณ์โดย ตัวแบบผสม กับ ข้อมูลจริง.....	43
26	เปรียบเทียบค่าพยากรณ์กับข้อมูลจริง.....	44

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

บทที่ 1

บทนำ

ความเป็นมาและความสำคัญของปัญหา

การพยากรณ์อนุกรมเวลา (Time Series Forecasting) เป็นวิธีการทางสถิติที่ใช้ข้อมูลในอดีตวิเคราะห์หาตัวแบบอธิบายลักษณะความสัมพันธ์ระหว่างค่าสังเกตที่เก็บตามลำดับเวลา และใช้ตัวแบบนั้นในการพยากรณ์ค่าสังเกตในอนาคต วิธีการวิเคราะห์อนุกรมเวลามีหลายวิธี ซึ่งแบ่งเป็น 2 กลุ่มใหญ่ ๆ คือ วิธีการแบบเชิงเส้น (Linear approach) ซึ่งมีข้อสมมติว่าลักษณะความสัมพันธ์ของค่าสังเกตปัจจุบันเป็นฟังก์ชันเชิงเส้นของค่าสังเกตในอดีต วิธีที่นิยมใช้กันอย่างแพร่หลาย คือวิธี Box-Jenkins หรือตัวแบบ ARIMA (Autoregressive Integrated Moving Average Model) ส่วนกลุ่มที่ 2 คือ วิธีการแบบไม่เชิงเส้น (Non-linear approach) ซึ่งเป็นวิธีการที่พยายามอธิบายลักษณะความสัมพันธ์ที่ไม่ใช่เชิงเส้นของอนุกรมเวลา ตัวแบบเครือข่ายประสาทเทียม (Artificial Neural Network Model) เรียกย่อ ๆ ว่า ANN เป็นตัวแบบในกลุ่มนี้ที่นิยมใช้กันในปัจจุบัน

ข้อมูลอนุกรมเวลาทางธุรกิจส่วนใหญ่ มักมีโครงสร้างซึ่งมีทั้งส่วนประกอบที่เป็นแบบเชิงเส้น และแบบไม่เชิงเส้น ดังนั้นวิธีการ ARIMA หรือ ANN เพียงอย่างเดียวอาจไม่สามารถอธิบายลักษณะความผันแปรของข้อมูลอนุกรมเวลาเหล่านั้นได้อย่างถูกต้องนัก Zhang (2003) พัฒนาวิธีการตัวแบบผสมระหว่าง ARIMA และ ANN เพื่อพยากรณ์ข้อมูลที่มีส่วนประกอบเชิงเส้นและไม่เชิงเส้นอยู่ให้ถูกต้องยิ่งขึ้น โดยตัวแบบ ARIMA อธิบายส่วนประกอบที่มีลักษณะเชิงเส้น และตัวแบบ ANN อธิบายส่วนประกอบที่ไม่เชิงเส้น หลังจากนั้นรวมทั้งสองส่วนประกอบนี้เข้าด้วยกัน

การซื้อขายหุ้นในตลาดหลักทรัพย์ก็เป็นวิธีการหนึ่งแบบหนึ่งสำหรับนักลงทุนเพื่อสร้างผลกำไรให้กับตนเอง ถ้านักลงทุนสามารถทราบข้อมูลข่าวสารที่เป็นปัจจุบันและทันเหตุการณ์ก็สามารถนำข้อมูลและข่าวสารเหล่านั้นไปใช้ในการวิเคราะห์เพื่อที่จะซื้อขายหุ้นเหล่านั้นได้ถูกต้องยิ่งขึ้น โดยเฉพาะอย่างยิ่งสามารถพยากรณ์ราคาของหุ้นที่สนใจในตลาดหลักทรัพย์ล่วงหน้าได้เพื่อเป็นแนวทางในการวิเคราะห์เพื่อที่จะทำการซื้อขายหุ้นของตนเอง

หุ้นที่สำคัญที่ซื้อขายกันในตลาดหลักทรัพย์แห่งประเทศไทยมีหลายหุ้นด้วยกัน หุ้นที่น่าสนใจ 2 หุ้นได้แก่ บริษัท ปตท. จำกัด (มหาชน) :PTT เป็นหุ้นด้านพลังงาน และ ธนาคาร

กรุงเทพ จำกัด (มหาชน) :BBL ซึ่งเป็นหุ้นด้านสถาบันการเงิน ทั้งสองหุ้นมีมูลค่าซื้อขายต่อวันสูง อยู่ใน 5 อันดับแรก

ดังนั้นในงานวิจัยนี้จะทดลองใช้วิธีการตัวแบบ ARIMA ตัวแบบ ANN และตัวแบบผสมระหว่าง ARIMA และ ANN กับข้อมูลราคาปิดของหุ้นทั้งสองดังกล่าว

วัตถุประสงค์ของการศึกษา

เพื่อเปรียบเทียบการพยากรณ์อนุกรมเวลาด้วยตัวแบบ ARIMA ANN และตัวแบบผสมระหว่าง ARIMA และ ANN ในการพยากรณ์ราคาปิดของหุ้นในตลาดหลักทรัพย์แห่งประเทศไทย

สมมติฐานของการศึกษา

1. ราคาปิดของหุ้นในอดีตสามารถนำมาใช้ในการพยากรณ์ราคาปิดของหุ้นในอนาคตได้

2. ตัวแบบผสมระหว่าง ARIMA และ ANN มีประสิทธิภาพในการพยากรณ์ราคาปิดของหุ้นได้ดีกว่า ตัวแบบ ARIMA และตัวแบบ ANN

ขอบเขตของการศึกษา

1. ข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลราคาปิดของหุ้นของบริษัท ปตท. จำกัด (มหาชน) : PTT และ ราคาปิดของหุ้นของธนาคารกรุงเทพ จำกัด (มหาชน) :BBL ตั้งแต่วันที่ 4 มกราคม 2548 ถึงวันที่ 5 เมษายน 2550 รวมจำนวน 554 วัน

2. ตัวแบบที่ใช้ในการพยากรณ์ได้แก่ ARIMA ANN และตัวแบบผสม ARIMA และ ANN

ขั้นตอนของการศึกษา

1. รวบรวมข้อมูลราคาหุ้น PTT และ BBL จาก <http://www.setsmart.com>
2. สร้างตัวแบบ ARIMA ANN และ ตัวแบบผสมระหว่าง ARIMA และ ANN
3. เปรียบเทียบประสิทธิภาพของตัวแบบโดยการทดลองใช้ตัวแบบในการพยากรณ์ทั้งระยะสั้น(7 วัน) และระยะยาว(30 วัน)
4. สรุปผลการวิจัยและข้อเสนอแนะ

ประโยชน์ที่คาดว่าจะได้รับ

ได้ตัวแบบที่เหมาะสมในการพยากรณ์ราคาปิดของหุ้น PTT และ หุ้น BBL เพื่อเป็นแนวทางในการพยากรณ์ราคาปิดของหุ้นอื่นๆ ต่อไป

นิยามศัพท์

1. ราคาปิดของหุ้นในตลาดหลักทรัพย์ต่อวัน(Close Price)

คือ ราคาปิดของหุ้น ณ สิ้นวันทำการอย่างเป็นทางการของตลาดหลักทรัพย์แห่งประเทศไทย

2. ประสิทธิภาพของตัวแบบ วัดโดยใช้ MSE MAE MAPE

2.1) ค่ากลางของความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error ; MAE)

$$MAE = \frac{\sum_{t=1}^n |\hat{\epsilon}_t|}{n}$$

2.2) ค่ากลางของความคลาดเคลื่อนกำลังสอง (Mean Square Error ; MSE)

$$MSE = \frac{\sum_{t=1}^n (\hat{\epsilon}_t)^2}{n}$$

2.3) ค่ากลางของเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute

Percentage Error ; MAPE)

$$MAPE = \left(\frac{100}{n} \right) \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|$$

เมื่อ $\hat{\epsilon}_t$ คือ $y_t - \hat{y}_t$ ส่วนเหลือที่วิเคราะห์ได้

n คือจำนวนวัน

y_t คือราคาหุ้น ณ เวลา t

\hat{y}_t คือราคาหุ้น ณ เวลา t ที่ได้จากการพยากรณ์

บทที่ 2

ทฤษฎีและวรรณกรรมที่เกี่ยวข้อง

ในงานวิจัยนี้ ผู้วิจัยต้องการประยุกต์วิธีการพยากรณ์อนุกรมเวลาด้วยตัวแบบ ARIMA ตัวแบบเครือข่ายประสาทเทียม(ANN) และตัวแบบผสมระหว่าง ARIMA และ ANN โดยศึกษากรณีพยากรณ์ราคาหุ้นของตลาดหลักทรัพย์แห่งประเทศไทย ดังนั้น ในบทนี้ จะนำเสนอทฤษฎีและวรรณกรรมที่เกี่ยวข้องเรียงตามลำดับดังนี้

1. อนุกรมเวลา (Time Series)
2. ตัวแบบ ARIMA(Autoregressive Integrated Moving Average Model)
3. ตัวแบบเครือข่ายประสาทเทียม(Artificial Neural Network:ANN)
4. ตัวแบบผสมระหว่าง ARIMA และ ANN
5. ข้อมูลเกี่ยวกับราคาหุ้น PTT และ BBL
6. งานวิจัยที่เกี่ยวข้อง

1 อนุกรมเวลา (Time Series)

อนุกรมเวลา คือ เซตของข้อมูลเชิงปริมาณที่จัดเก็บในช่วงเวลาหนึ่ง ตัวอย่างเช่น ดัชนีตลาดหลักทรัพย์เมื่อปิดทำการซื้อขายในแต่ละวัน รายได้ประชาชาติ(GNP)รายไตรมาส รายรับในแต่ละปีของบริษัทแห่งหนึ่ง ข้อมูลอนุกรมเวลาอาจอยู่ในลักษณะที่เป็นข้อมูลรายปี รายไตรมาส หรือรายเดือนก็ได้ ทั้งนี้ขึ้นอยู่กับความเหมาะสมในการนำไปใช้ประโยชน์

การพยากรณ์อนุกรมเวลา (Time Series Forecasting) เป็นวิธีการทางสถิติที่ใช้ข้อมูลในอดีตวิเคราะห์หาตัวแบบอธิบายลักษณะความสัมพันธ์ระหว่างค่าสังเกตที่เก็บตามลำดับเวลา และใช้ตัวแบบนั้นในการพยากรณ์ค่าสังเกตในอนาคต วิธีการวิเคราะห์อนุกรมเวลามีหลายวิธี ซึ่งแบ่งเป็น 2 กลุ่มใหญ่ ๆ คือ วิธีการแบบเชิงเส้น (Linear approach) เช่น Box-Jenkins หรือตัวแบบ ARIMA(Autoregressive Integrated Moving Average Model) ส่วนกลุ่มที่ 2 คือ วิธีการแบบไม่เชิงเส้น (Non-linear approach) ซึ่งเป็นวิธีการที่พยายามอธิบายลักษณะความสัมพันธ์ที่ไม่ใช่เชิงเส้นของอนุกรมเวลา เช่น ตัวแบบเครือข่ายประสาทเทียม (Artificial Neural Network Model) เรียกย่อ ๆ ว่า ANN เป็นตัวแบบในกลุ่มนี้ที่นิยมใช้กันในปัจจุบัน

เนื่องจากข้อมูลทางธุรกิจมีการเปลี่ยนแปลงตลอดเวลา ผู้นำทางธุรกิจหรือองค์กรต้องหาวิธีพัฒนาต่าง ๆ ที่สามารถนำไปใช้ประกอบการตัดสินใจวางแผน เกี่ยวกับผลที่เกิดจากความเปลี่ยนแปลงในการดำเนินการอย่างใดอย่างหนึ่ง ดังนั้นการวิเคราะห์อนุกรมเวลาจึงเข้ามามีบทบาทช่วยในการตัดสินใจ เทคนิคอย่างหนึ่งที่ใช้ช่วยในการควบคุมการดำเนินการในปัจจุบันและการวางแผนความต้องการในอนาคต คือ การพยากรณ์ (forecasting) ซึ่งการพยากรณ์นั้นทำได้หลายวิธี แต่ละวิธีต่างมีเป้าหมายเดียวกัน คือ ทำนายเหตุการณ์ในอนาคต

2. ตัวแบบ ARIMA(Autoregressive Integrated Moving Average Model)

การวิเคราะห์อนุกรมเวลาแบบ Box-Jenkins (Box-Jenkins 1976) เป็นระเบียบวิธีทางสถิติสำหรับหาตัวแบบพยากรณ์ เทคนิคนี้อาศัยความสัมพันธ์จากข้อมูลในอดีตเพื่อหาตัวแบบแสดงพฤติกรรมของข้อมูลและใช้เป็นแนวทางในการพยากรณ์พฤติกรรมในอนาคต เป็นเทคนิคที่มีประสิทธิภาพสูงสำหรับการพยากรณ์ในระยะสั้น ตัวแบบที่ใช้ในการวิเคราะห์อนุกรมเวลาแบบ Box-Jenkins เรียกตัวแบบ ARIMA ซึ่งย่อมาจากคำว่า AutoRegressive Integrated Moving Average ตัวแบบ ARIMA มีข้อสมมติว่าค่าปัจจุบันของค่าสังเกตเป็นฟังก์ชันเชิงเส้นของค่าสังเกต และค่าความคลาดเคลื่อนสุ่มในอดีต ตัวแบบคือ

$$y_t = \delta + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

โดย y_t เป็นค่าสังเกตของอนุกรมเวลาที่เวลา t

δ เป็นค่าคงที่ในตัวแบบ

ε_t เป็นความคลาดเคลื่อนสุ่มที่เวลา t ซึ่งมีข้อสมมติว่า ε_t เป็นตัวแปรสุ่มที่เป็นอิสระกัน ค่าเฉลี่ย 0 ความแปรปรวนคงที่

ϕ_i ($i = 1, \dots, p$) และ θ_j ($j = 1, \dots, q$) เป็นพารามิเตอร์ในตัวแบบ ส่วน p และ q เป็นจำนวนเต็มซึ่งแสดงอันดับของตัวแบบ

ส่วนของค่าสังเกตในอดีตที่อยู่ในตัวแบบเรียกเป็นเทอมการถดถอยในตนเอง (AutoRegressive หรือ AR) และส่วนของความคลาดเคลื่อนสุ่มในอดีตที่อยู่ในตัวแบบเรียกเป็นเทอมค่าเฉลี่ยเคลื่อนที่ (Moving Average หรือ MA) และอนุกรมเวลาที่ต้องมีการหาผลต่างก่อนเพื่อแปลงให้เป็นอนุกรมเวลาที่มีลักษณะคงที่ เรียกเป็นว่าเป็นอนุกรมเวลาที่ปรับให้มีลักษณะคงที่แล้ว (Integrated version of a stationary series หรือ I) ตัวแบบ ARIMA นิยมเขียนโดยบอกอันดับ p ของ AR อันดับ d ของการหาผลต่างของอนุกรมเพื่อให้เป็นอนุกรมเวลาลักษณะคงที่ และอันดับ q ของ

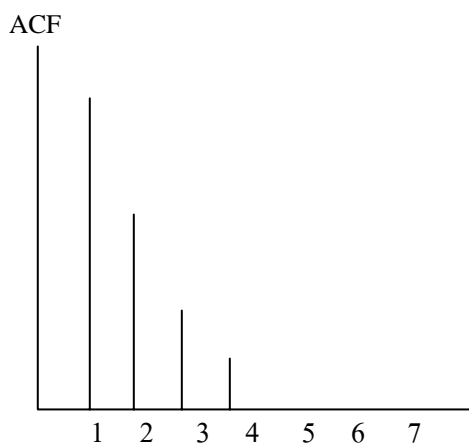
MA โดยเขียนแทนด้วย ARIMA(p, d, q) ถ้า $q = 0$ จะเป็นตัวแบบ AR(p) แต่ถ้า $p = 0$ จะเป็นตัวแบบ MA(q)

ในการวิเคราะห์ห้อนุกรมเวลานั้น Box-Jenkins ได้แบ่งออกเป็น 3 ขั้นตอนหลักๆ คือ 1. การกำหนดตัวแบบ 2. การประมาณค่าพารามิเตอร์ของตัวแบบ 3. การตรวจสอบตัวแบบ


2.1 การกำหนดตัวแบบ

ข้อมูลอนุกรมเวลาที่จะนำมาสร้างตัวแบบต้องมีสมบัติคงที่ (Stationary) คือลักษณะทางสถิติ เช่น ค่าเฉลี่ย ความแปรปรวน และ ลักษณะของสหสัมพันธ์ในตัวเองของข้อมูลต้องคงที่ตลอดช่วงเวลาการพิจารณาว่าข้อมูลเป็นข้อมูลที่เป็น stationary หรือไม่อาจดูได้จากฟังก์ชันสหสัมพันธ์ในตัวเองในเชิงทฤษฎี (Theoretical Autocorrelation Function : ACF) กล่าวคือ ACF ของอนุกรมเวลาที่คงที่ จะมีลักษณะลดลง (die down) เข้าสู่ศูนย์อย่างรวดเร็วเมื่อข้อมูลอนุกรมเวลามีระยะห่างกันเพิ่มขึ้นหรือถูกตัดออก (cut off) ที่ระยะห่างช่วงใดช่วงหนึ่ง แต่ถ้า ACF มีลักษณะลดลงเข้าสู่ศูนย์ช้าๆ แสดงว่าข้อมูลอนุกรมเวลาไม่คงที่ (Non-stationary) ถ้าข้อมูลอนุกรมเวลามีแนวโน้ม หรือความแปรปรวนไม่คงที่ จะต้องปรับให้มีลักษณะคงที่ก่อนโดยการหาผลต่าง หรือการแปลงรูปกำลัง (Power transformation) (สุชัยศรี ไกลอนส์ 2540 : 27-36)

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์



ภาพที่ 1 ACF (Stationary)



ภาพที่ 2 ACF (Non-Stationary)

ฟังก์ชันสหสัมพันธ์ในตัวเอง (Autocorrelation Function : ACF)

ฟังก์ชันสหสัมพันธ์ในตัวเองเป็นมาตรวัดความสัมพันธ์ในค่าของข้อมูลที่เกิดขึ้น ณ เวลาต่างๆ สัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปร Y_t และ Y_{t+k} ในอนุกรมเวลาที่อยู่ห่างกัน k ช่วงเวลา เรียกว่าสหสัมพันธ์ในตัวเองที่อยู่ห่างกัน k ช่วงเวลา แทนด้วย ρ_k และสามารถประมาณได้

ด้วย สหสัมพันธ์ในตัวเองจากตัวอย่างในอนุกรมเวลาที่อยู่ห่างกัน k ช่วงเวลา (Sample Autocorrelation of Lag k) แทนด้วย

$$r_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad k = 1, 2, \dots$$

โดยที่

$$\bar{Y} = \sum_{t=1}^n \frac{Y_t}{n}$$

การทดสอบความมีนัยสำคัญของสหสัมพันธ์ในตัวเองจากตัวอย่าง

ในการทดสอบความมีนัยสำคัญของสหสัมพันธ์ในตัวเองจากตัวอย่าง มีขั้นตอนในการทดสอบดังนี้

สมมติฐานในการทดสอบ

$$H_0 : \rho_k = 0$$

$$H_1 : \rho_k \neq 0$$

ตัวสถิติที่ใช้ทดสอบ : r_k

การตัดสินใจปฏิเสธหรือยอมรับสมมติฐานว่าง : ($\alpha = 0.05$ และ n มีค่ามาก)

ปฏิเสธ H_0 ถ้า $|r_k| > \frac{t_{\alpha/2, df}}{\sqrt{n}} = \frac{1.96}{\sqrt{n}} \approx \frac{2}{\sqrt{n}}$

ถ้าปฏิเสธ H_0 แสดงว่าสหสัมพันธ์ในตัวเองที่อยู่ห่างกัน k ช่วงเวลาแตกต่างจากศูนย์

ฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วน(Partial Autocorrelation Function : PACF)

สหสัมพันธ์ในตัวเองบางส่วนคือสหสัมพันธ์ในตัวเอง(autocorrelation) ระหว่างตัวแปร Y_t และ Y_{t+k} ในอนุกรมเวลาที่อยู่ห่างกัน k ช่วงเวลาที่ขจัดอิทธิพลของตัวแปรที่อยู่ระหว่างตัวแปรทั้งสอง ได้แก่ $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$ ออกไป แทนด้วย ρ_{kk} และสามารถประมาณได้ด้วยสหสัมพันธ์ในตัวเองบางส่วนจากตัวอย่างที่อยู่ห่างกัน k ช่วงเวลา(Sample Partial Autocorrelation of Lag k) แทนด้วย

$$\text{โดยที่} \quad r_{kk} = \begin{cases} r_1, & k = 1 \\ \frac{r_k - \sum_{j=1}^{k-1} r_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} r_{k-1,j} r_j} & k = 2, 3, \dots \end{cases}$$

$$r_{kj} = r_{k-1,j} - r_{kk} r_{k-1,k-j} \quad j = 1, 2, \dots, k-1$$

การทดสอบความมีนัยสำคัญของสหสัมพันธ์ในตัวเองบางส่วนจากตัวอย่าง

การทดสอบความมีนัยสำคัญของสหสัมพันธ์ในตัวเองบางส่วนจากตัวอย่าง มีขั้นตอนในการทดสอบดังนี้

สมมติฐานในการทดสอบ $H_0 : \rho_{kk} = 0$

ตัวสถิติที่ใช้ทดสอบ : r_{kk} $H_1 : \rho_{kk} \neq 0$

การตัดสินใจปฏิเสธหรือยอมรับสมมติฐานว่าง : ($\alpha = 0.05$ และ n มีค่ามาก ๆ)

$$\text{ปฏิเสธ } H_0 \text{ ถ้า } |r_{kk}| > \frac{t_{\alpha/2, df}}{\sqrt{n}} = \frac{1.96}{\sqrt{n}} \approx \frac{2}{\sqrt{n}}$$

การสรุปผล : ถ้าปฏิเสธ H_0 แสดงว่าสหสัมพันธ์ในตัวเองบางส่วนที่อยู่ห่างกัน k ช่วงเวลาแตกต่างจากศูนย์

การกำหนดตัวแบบและอันดับของ p และ q

การกำหนดตัวแบบและอันดับของตัวแบบทำโดยการเปรียบเทียบลักษณะของฟังก์ชันสหสัมพันธ์ในตัวเอง (ACF) และฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วน (Partial Auto-Correlation Function: PACF) ของค่าสังเกต กับลักษณะของ ACF และ PACF ตามทฤษฎีของตัวแบบ ARIMA อันดับต่าง ๆ ซึ่งเสนอโดย Box-Jenkins (1976) โดยการกำหนดอันดับของ p และ q พิจารณาจาก ACF และ PACF ประกอบกัน ถ้าเป็นตัวแบบ AR อันดับ p (AR(p)) สหสัมพันธ์ในตัวเอง (ACF) จะมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็ว และสหสัมพันธ์ในตัวเองบางส่วน (PACF) ที่ห่างกันเกิน p ช่วงเวลาจะมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็ว

ถ้าเป็นตัวแบบ MA อันดับ q (MA(q)) สหสัมพันธ์ในตัวเองที่ห่างกันเกิน q ช่วงเวลาจะมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็ว และสหสัมพันธ์ในตัวเองบางส่วนจะมีลักษณะลดลงเข้าสู่ศูนย์ อย่างรวดเร็ว

ถ้าเป็นตัวแทนผสมระหว่าง AR และ MA (Mixed Autoregressive Moving Average :ARMA(p,q)) สหสัมพันธ์ในตัวเองที่ห่างกันเกิน q ช่วงเวลา และสหสัมพันธ์ในตัวเองบางส่วนที่ห่างกันเกิน p ช่วงเวลา จะมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็ว

ถ้าทั้งสหสัมพันธ์ในตัวเองและสหสัมพันธ์ในตัวเองบางส่วนมีค่าเท่ากับศูนย์ทุกช่วงห่าง จะได้แบบจำลองที่เรียกว่า White Noise นิยามคือ

$$Y_t = \theta_0 + \varepsilon_t$$

โดยที่

$$\varepsilon_t \sim IN(0, \sigma_A^2)$$

ถ้าทั้งสหสัมพันธ์ในตัวเองและสหสัมพันธ์ในตัวเองบางส่วนจากข้อมูลอนุกรมเวลาที่ ได้จากการแปลงให้เป็นอนุกรมเวลาคงที่โดยการหาผลต่าง มีค่าเท่ากับศูนย์ จะได้ตัวแทนที่เรียกว่า

Random Walk นิยามคือ

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

$$Y_t = Y_{t-1} + \theta_0 + \varepsilon_t$$

โดยที่

$$\varepsilon_t \sim IN(0, \sigma_A^2)$$

2.2 การประมาณค่าพารามิเตอร์(Estimation)

หลังจากได้กำหนดแบบจำลองในขั้นตอนที่ 1 แล้ว จะประมาณค่าพารามิเตอร์ของแบบจำลองโดยวิธี กำลังสองน้อยที่สุด (Least-Squares Method) โดยโปรแกรมสำเร็จรูปจะกำหนดค่าประมาณเบื้องต้น (initial estimates) เพื่อประมวลผลจนได้ค่าประมาณสุดท้าย ซึ่งโปรแกรมสำเร็จรูปจะทำการคำนวณแบบย้อนซ้ำ(iterative) จนกว่าจะให้ค่าผลรวมค่าประมาณความคลาดเคลื่อนกำลังสอง ($\sum_{t=1}^n \hat{\varepsilon}_t^2$) มีค่าน้อยที่สุด โดยที่ $\hat{\varepsilon}_t$ คือค่าประมาณความคลาดเคลื่อน ε_t จากนั้นนำแบบจำลองที่ได้ไปตรวจสอบเหมาะสม

2.3 การตรวจสอบความเหมาะสมของตัวแบบ (Diagnostic Checking)

ในขั้นตอนการตรวจสอบความเหมาะสมของแบบจำลอง เป็นการตรวจสอบว่าแบบจำลองที่เลือกมีความเหมาะสมกับข้อมูลอนุกรมเวลาที่ทำการวิเคราะห์หรือไม่โดย

2.3.1 ทดสอบค่าประมาณพารามิเตอร์ในแบบจำลองตามขั้นตอนดังนี้

2.3.1.1 สมมติฐานในการทดสอบ H_0 พารามิเตอร์ = 0

H_1 พารามิเตอร์ $\neq 0$

2.3.1.2 ตัวสถิติทดสอบ $t =$ ตัวประมาณพารามิเตอร์ / ส่วนเบี่ยงเบนมาตรฐานของตัวประมาณ

2.3.1.3 กำหนด α

2.3.1.4 เขตวิกฤต $|t| > t_{\frac{\alpha}{2}, df}$

2.3.1.5 สรุปผล ถ้าผลการทดสอบนำไปสู่การปฏิเสธสมมติฐานว่าง แสดงว่าพารามิเตอร์ตัวที่ทดสอบนั้นแตกต่างจากศูนย์ ควรรวมพารามิเตอร์ตัวนั้นอยู่ในแบบจำลอง

2.3.2 พิจารณาค่าประมาณความคลาดเคลื่อนที่คำนวณได้จากการสร้างสมการพยากรณ์แบบจำลอง

2.3.2.1 สร้างกราฟค่าประมาณความคลาดเคลื่อนเทียบกับเวลา ถ้ากราฟที่ได้แสดงให้เห็นว่าค่าประมาณความคลาดเคลื่อนมีการกระจายไม่คงที่เปลี่ยนแปลงตามเวลา แสดงว่าค่าความคลาดเคลื่อนมีความแปรปรวนไม่คงที่และข้อมูลอนุกรมเวลาที่มีความแปรปรวนไม่คงที่

2.3.2.2 ดูจาก Theoretical Autocorrelation Function (ACF) และ Theoretical Partial Autocorrelation Function (PACF) ของค่าประมาณความคลาดเคลื่อน ถ้ามีแบบจำลองเป็น White Noise แสดงว่าแบบจำลองที่ได้เป็นแบบจำลองที่เหมาะสม

2.3.2.3 การทดสอบสหสัมพันธ์ในตนเองของค่าประมาณความคลาดเคลื่อน Box และ Pierce ได้เสนอวิธีทดสอบ โดยสร้างตัวสถิติที่มีการแจกแจงแบบไคสแควร์ที่มีค่าองศาแห่งความอิสระ (degree of freedom) เท่ากับจำนวนสหสัมพันธ์ในตัวเองจากตัวอย่าง (sample autocorrelations) ของค่าประมาณความคลาดเคลื่อน K ตัวที่ใช้ในการทดสอบลบจำนวนพารามิเตอร์ (m) ที่ประมาณค่าในแบบจำลอง ตัวสถิตินี้เรียกว่า Box-Pierce Chi-Square Statistic

$$Q = n \sum_{k=1}^K r_k^2(\hat{\varepsilon})$$

โดยที่

$n =$ จำนวนข้อมูลของค่าความคลาดเคลื่อนของค่าสังเกตอนุกรมเวลาหลังจากปรับให้เป็นอนุกรมเวลาคงที่แล้ว

K = จำนวนสหสัมพันธ์ในตัวเองของค่าประมาณความคลาดเคลื่อนที่ใช้ในการ
คำนวณค่า Q

$r_k(\hat{\varepsilon})$ = ฟังก์ชันสหสัมพันธ์ในตัวเองของค่าประมาณความคลาดเคลื่อน

ตัวสถิติ Box-Pierce คำนวณจากฟังก์ชันสหสัมพันธ์ในตัวเองของค่าประมาณความ
คลาดเคลื่อนในอนุกรมเวลาที่ห่างกันในหน่วยเวลาต่างๆ ซึ่งจะทดสอบว่าความคลาดเคลื่อนเป็น
อิสระต่อกันหรือไม่

- สมมติฐานในการทดสอบ $H_0 : \rho_k = 0$ ทุกๆค่าที่ $k \leq K$
 $H_1 : \rho_k \neq 0$ อย่างน้อย 1 ค่าที่ $k \leq K$

- ตัวสถิติทดสอบ $t = n \sum_{k=1}^K r_k^2(\varepsilon)$

- กำหนด α

- เขตวิกฤต $Q > \chi^2_{\alpha, k-m}$

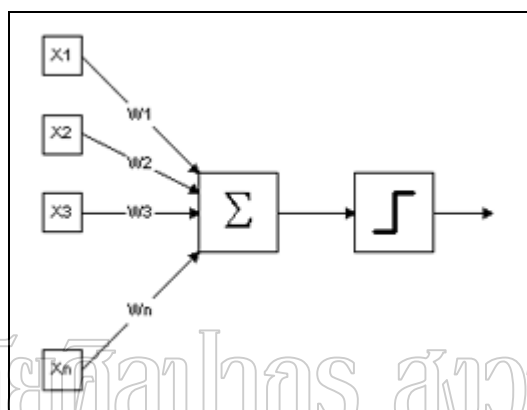
- สรุปผล ถ้าผลการทดสอบนำไปสู่การปฏิเสธสมมติฐานว่าง แสดงว่าความ
คลาดเคลื่อนยังมีสหสัมพันธ์กันอยู่ จึงต้องปรับปรุงแบบจำลองใหม่ แต่ถ้าผลการทดสอบยอมรับ
สมมติฐาน แสดงว่าแบบจำลองที่ได้เป็นแบบจำลองที่เหมาะสม

ถ้าพบว่าแบบจำลองที่ได้ไม่เหมาะสมจะต้องพิจารณาเลือกแบบจำลองใหม่คือกลับไป
ขั้นตอนกำหนดแบบจำลองใหม่จนกว่าจะได้แบบจำลองที่เหมาะสม

3. ตัวแบบ ANN

เครือข่ายประสาทเทียม (Artificial neural network) (Artificial Neural Network
โครงข่ายประสาทเทียม : 2007) หรือที่มักจะเรียกสั้น ๆ ว่า **ข่ายงานประสาท** (neural network หรือ
neural net) คือโมเดลทางคณิตศาสตร์ ที่ได้จำลองการทำงานของเครือข่ายประสาทในสมองมนุษย์
ด้วยวัตถุประสงค์ที่จะสร้างเครื่องมือซึ่งมีความสามารถในการเรียนรู้การจดจำแบบรูป (Pattern
Recognition) และการอุปมาความรู้ (Knowledge deduction) เช่นเดียวกับความสามารถที่มีใน
สมองมนุษย์ แนวคิดเริ่มต้นของเทคนิคนี้ได้มาจากการศึกษาข่ายงานไฟฟ้าชีวภาพ (bioelectric
network) ในสมอง ซึ่งประกอบด้วย เซลล์ประสาท หรือ "นิวรอน" (neurons) และ จุดประสาน
ประสาท (synapses) แต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า
"เดนไดรต์" (Dendrite) ซึ่งเป็น **ข้อมูลเข้า** และปลายในการส่งกระแสประสาทเรียกว่า "แอกซอน"
(Axon) ซึ่งเป็นเหมือน **ผลลัพธ์** ของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการ

กระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่านเดนไดรต์เข้าสู่ นิวเคลียสซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทางแอกซอนของมัน โครงสร้างของเครือข่ายประสาทเทียมประกอบด้วยนิวรอนซึ่งเชื่อมต่อกันเป็นชั้นๆ ชั้นแรกเป็นข้อมูลเข้า(input) และชั้นสุดท้ายจะเป็นชั้นผลลัพธ์ในระหว่างชั้นแรกกับชั้นสุดท้ายจะมีชั้นที่ซ่อนอยู่ระหว่างทั้ง 2 ชั้นนั้นอีก ที่ที่ชั้นก็ได้หรือจะไม่มีเลยก็ได้



ภาพที่ 3 Model ของ Neuron ในคอมพิวเตอร์

ที่มา : Artificial Neural Network โครงข่ายประสาทเทียม [Online]. Accessed 20 April 2007.

Available from http://202.28.94.55/web/320417/2548/work1/g26/Files/Report_Neural%20Network.doc

การทำงาน

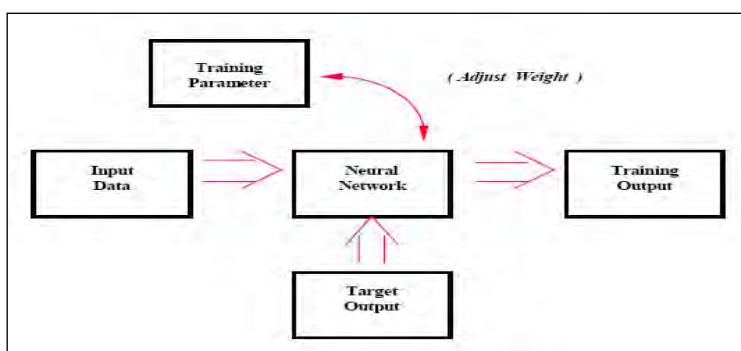
การทำงานของ Neural networks คือเมื่อรับข้อมูลเข้ามายัง network จะให้นำหนักข้อมูลเข้าทุกหน่วยผลที่ได้จากข้อมูลเข้าทุก ๆ ขาของ นิวรอน จะเอามารวมกันแล้วก็เอามาเทียบกับ ค่าควบคุมระดับผลลัพธ์ของนิวรอน(threshold) ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่า threshold แล้วนิวรอน ก็จะส่ง ผลลัพธ์ ออกไป ผลลัพธ์ นี้ก็จะถูกส่งไปเป็นข้อมูลเข้า ของ นิวรอน อื่น ๆ ที่ เชื่อมกัน ใน network ถ้าค่าน้อยกว่า threshold ก็จะไม่ให้ผลลัพธ์ออกมา

การเรียนรู้ของเครือข่ายประสาทเทียม

การเรียนรู้ของเครือข่ายประสาทเทียม มี 2 ประเภท คือ

1. การเรียนแบบมีการสอน(Supervised Learning)

เป็นการเรียนแบบที่มีการตรวจคำตอบเพื่อให้วงจรข่ายปรับตัว ชุดข้อมูลที่ใช้สอนวงจรข่ายจะมีคำตอบไว้คอยตรวจดูว่าวงจรข่ายให้คำตอบที่ถูกต้องหรือไม่ ถ้าตอบไม่ถูก วงจรข่ายก็จะปรับตัวเองเพื่อให้ได้คำตอบที่ดีขึ้น เปรียบเทียบกับคน เหมือนกับการสอนนักเรียน โดยมีครูผู้สอนคอยแนะนำ



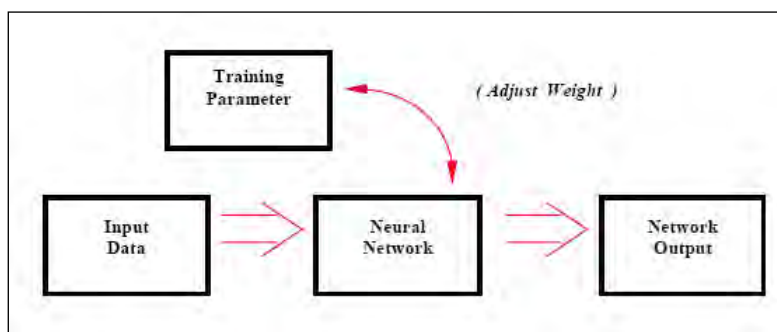
ภาพที่ 4 การเรียนรู้แบบมีการสอน (Supervised Learning)

ที่มา : Artificial Neural Network โครงข่ายประสาทเทียม [Online]. Accessed 20 April 2007.

Available from http://202.28.94.55/web/320417/2548/work1/g26/Files/Report_Neural%20Network.doc

2. การเรียนแบบไม่มีการสอน(Unsupervised Learning)

เป็นการเรียนแบบไม่มีผู้แนะนำ ไม่มีการตรวจคำตอบว่าถูกหรือผิด วงจรข่ายจะจัดเรียงโครงสร้างด้วยตัวเองตามลักษณะของข้อมูล ผลลัพธ์ที่ได้ วงจรข่ายจะสามารถจัดหมวดหมู่ของข้อมูลได้ เปรียบเทียบกับคน เช่น การที่เราสามารถแยกแยะพันธุ์พืช พันธุ์สัตว์ตามลักษณะรูปร่างของมันได้เองโดยไม่มีใครสอน การเรียนรู้เหล่านี้เช่น การจัดกลุ่มสิ่งของ




ภาพที่ 5 การเรียนรู้แบบไม่มีการสอน (Unsupervised Learning)

ที่มา : Artificial Neural Network โครงข่ายประสาทเทียม [Online]. Accessed 20 April 2007.

Available from http://202.28.94.55/web/320417/2548/work1/g26/Files/Report_Neural%20Network.doc

ตัวแบบ ANN มีหลายรูปแบบด้วยกัน ในงานวิจัยนี้ใช้ตัวแบบ ANN แบบ Feed Forward Back Propagation Neural Network (FBPNN) ซึ่งเป็น การเรียนรู้แบบมีการสอน (Supervised Learning) โหนดในชั้นข้อมูลเข้าทุกโหนดจะถูกเชื่อมไปข้างหน้ากับทุกโหนดที่อยู่ในชั้นถัดไป และโหนดในชั้นถัดไปจะถูกเชื่อมกับในชั้นถัดต่อไปอีกตามลำดับจนกระทั่งถึงชั้น ผลลัพธ์ ตัวอย่างของ FBPNN ซึ่งมีชั้นที่ซ่อน 1 ชั้นดังในภาพที่ 6



ภาพที่ 6 Feed forward BPNN ซึ่งมีชั้นซ่อน 1 ชั้น

โดยชั้นข้อมูลเข้าแทนด้วยเวกเตอร์ $X=(x_1, x_2, \dots, x_p)$ ชั้นที่ซ่อนอยู่แทนด้วยเวกเตอร์ $H=(h_1, h_2, \dots, h_m)$ และชั้นผลลัพธ์แทนด้วยเวกเตอร์ $Y=(y_1, y_2, \dots, y_n)$ ผลลัพธ์ของหน่วยที่ j ของชั้นที่ซ่อนอยู่ได้จากการคำนวณผลบวกถ่วงน้ำหนักของข้อมูลเข้าทั้ง p ค่าและบวกกับค่าความคลาดเคลื่อน(Bias) จากนั้นผลบวกดังกล่าวจะถูกแปลงโดยฟังก์ชันถ่ายโอน(transfer function) g ให้เป็นผลลัพธ์ออกมา

$$h_j = g\left(\sum_{i=1}^p w_{ji}^{(1)} x_i + b_{0j}\right)$$

โดย g ที่นิยมใช้กรณีที่ไม่ใช่ฟังก์ชันเชิงเส้น คือ sigmoid function x_i คือข้อมูลเข้าหน่วยที่ i และ b_{0j} คือ ความคลาดเคลื่อน สำหรับชั้นผลลัพธ์ ค่าของหน่วยผลลัพธ์ที่ k คำนวณได้จาก

$$y_k = f\left(\sum_{j=1}^m w_{jk}^{(2)} h_j + b_{0c}\right) = f\left(\sum_{j=1}^m w_{jk}^{(2)} g\left(\sum_{i=1}^p w_{ji}^{(1)} x_i + b_{0j}\right) + b_{0c}\right) \quad (1)$$

เมื่อ f เป็นฟังก์ชันถ่ายโอนและ b_{0c} เป็นความคลาดเคลื่อน

ในการวิเคราะห์หอนุกรมเวลาซึ่งต้องการพยากรณ์ค่าอนาคตด้วยข้อมูลจากอดีต นั่นคือ พยากรณ์ค่าผลลัพธ์ที่เวลา t ซึ่งคือ y_t ด้วยข้อมูลจากอดีต d ค่า สมการ (1) เขียนได้เป็น

$$y_t = f\left(\sum_{j=1}^m w_{jk}^{(2)} h_j + b_{0c}\right) = f\left(\sum_{j=1}^m w_{jk}^{(2)} g\left(\sum_{i=1}^d w_{ji}^{(1)} y_{t-i} + b_{0j}\right) + b_{0c}\right) \quad (2)$$

ในการฝึกสอน จะใส่ข้อมูลเข้าและผลลัพธ์เป้าหมายให้ ANN การเรียนรู้ของ ANN คือการปรับน้ำหนัก w_{ij} ในแต่ละชั้นเพื่อให้ค่าพยากรณ์ใกล้เคียงกับค่าจริงให้มากที่สุด ฟังก์ชันที่นิยมใช้ในการวัดความคลาดเคลื่อนระหว่างค่าจริงและค่าพยากรณ์ฟังก์ชันหนึ่ง คือค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Squared Error) สำหรับการทำงานของ BPNN ในขั้นแรกจะกำหนดน้ำหนักและความคลาดเคลื่อนเบื้องต้น คำนวณค่าพยากรณ์จากข้อมูลเข้า คำนวณความคลาดเคลื่อนโดยคำนวณจากผลต่างระหว่างค่าจริงและค่าพยากรณ์ จากนั้นส่งค่าความคลาดเคลื่อนของชั้นผลลัพธ์ย้อนกลับไปยังชั้นต่างๆของ ANN เพื่อปรับน้ำหนัก w_{ij} ใหม่เพื่อลดความคลาดเคลื่อน

4. ตัวแบบผสมระหว่าง ARIMA และ ANN

(Zhang 2003) ตัวแบบนี้มีข้อสมมติว่าอนุกรมเวลามีส่วนประกอบแบบเชิงเส้น L_t และส่วนประกอบแบบไม่เชิงเส้น N_t นั่นคือตัวแบบเป็น

$$Y_t = L_t + N_t + \varepsilon_t$$

โดย Y_t เป็นค่าสังเกตของอนุกรมเวลาที่เวลา t L_t เป็นส่วนประกอบแบบเชิงเส้น N_t เป็นส่วนประกอบแบบไม่เชิงเส้น และ ε_t เป็นความคลาดเคลื่อนสุ่มที่เวลา t ขั้นตอนวิธีของตัวแบบผสมระหว่าง ARIMA และ ANN มีดังนี้

ขั้นที่ 1 ใช้ตัวแบบ ARIMA วิเคราะห์ข้อมูลอนุกรมเวลาเพื่อประมาณส่วนประกอบที่เป็นเชิงเส้น \hat{L}_t

ขั้นที่ 2 หาส่วนเหลือจากตัวแบบ ARIMA นั่นคือ $\varepsilon_t = Y_t - \hat{L}_t$ (ส่วนเหลือ ε_t เป็นค่าสังเกตที่ถูกจำกัดส่วนประกอบเชิงเส้นออกแล้ว)

ขั้นที่ 3 ใช้วิธี ANN กับส่วนเหลือ (ε_t) ที่ได้ในขั้นที่ 2 เพื่อประมาณส่วนประกอบที่ไม่ใช่เชิงเส้น \hat{N}_t

ขั้นที่ 4 รวมค่าประมาณส่วนประกอบทั้ง 2 ส่วน เพื่อใช้ประมาณค่าอนุกรมเวลา

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t$$

5. ข้อมูลเกี่ยวกับราคาหุ้น

ตลาดหลักทรัพย์แห่งประเทศไทย (The Stock Exchange of Thailand :SET) (แหล่งความรู้ผู้ลงทุน 2007) เป็นตลาดที่จัดตั้งขึ้นอย่างเป็นทางการ ทำหน้าที่ในการกำกับดูแลการซื้อขายหลักทรัพย์ จัดทะเบียนการซื้อขายของบริษัทสมาชิก และการเปิดเผยข้อมูลที่เป็นสาระสำคัญ

เกี่ยวกับการดำเนินงานของบริษัทจดทะเบียน อย่างไรก็ตาม ตลาดหลักทรัพย์ฯ ไม่ได้ทำหน้าที่ซื้อขายหลักทรัพย์โดยตรง แต่จะควบคุมดูแลให้การซื้อขายหลักทรัพย์ดำเนินไปอย่างมีระเบียบ คล่องตัว โปร่งใส และยุติธรรม เพื่อสร้างความมั่นใจแก่ผู้ลงทุนและส่งเสริมให้เกิดการระดมเงินออมจากประชาชนไปลงทุนในกิจการต่างๆ ที่เป็นประโยชน์ต่อการพัฒนาเศรษฐกิจโดยรวม โดยเริ่มเปิดทำการซื้อขายหลักทรัพย์ เมื่อวันที่ 30 เมษายน 2518

การคำนวณราคาปิดของหลักทรัพย์ต่อวัน(Close Price)

ตลาดหลักทรัพย์(แหล่งความรู้ผู้ลงทุน 2007) ได้นำวิธีการคำนวณซึ่งจะกล่าวในรายละเอียดต่อไปมาใช้ตั้งแต่ พ.ศ. 2534 ตลาดหลักทรัพย์ได้เปลี่ยนแปลงวิธีการคำนวณราคาปิดของหลักทรัพย์จากเดิมที่กำหนดให้ราคาซื้อขายครั้งสุดท้าย (Last Transaction) เป็นราคาปิด เป็นการใช่วิธีผสมผสานระหว่างการสุ่มเลือกเวลา (Random Time) และวิธี Call Market เพื่อเป็นการลดโอกาสในการสร้างราคาปิดและทำให้ราคาปิดของหลักทรัพย์ในตลาดหลักทรัพย์มีเสถียรภาพยิ่งขึ้น ในการคำนวณราคาปิด ตลาดหลักทรัพย์คงเปิดให้ซื้อขายได้ตามปกติจนถึงเวลา 16.30 น. จากนั้นระบบจะหาเวลาปิดโดยการสุ่มเลือก (Random) เวลาในช่วง 16.35-16.40 น. และเปิดโอกาสให้สมาชิกสามารถส่งคำสั่งซื้อขายเพิ่มเติมได้อีกเป็นเวลาอย่างน้อย 5 นาที คือตั้งแต่ 16.30 น. ถึงเวลาปิดที่ได้จากการสุ่มเลือก และจะยังไม่จับคู่การซื้อขาย จนกว่าจะถึงเวลาปิด จึงใช้วิธี Call Market (ซึ่งเป็นวิธีเดียวกับวิธีการคำนวณหาราคาปิดในช่วง Pre-open) คำนวณหาราคาปิด โดยนำคำสั่งซื้อขายทั้งหมดที่ค้างอยู่ในระบบจนกระทั่งถึงเวลาปิด มาคำนวณหาราคาปิดตามหลักการดังนี้

1. เป็นราคาที่ให้เกิดการซื้อขายได้ปริมาณมากที่สุด
2. ถ้ามีราคาที่ทำให้เกิดปริมาณซื้อขายมากที่สุดมากกว่า 1 ราคา ให้ใช้ราคาที่ใกล้เคียงกับราคา ซื้อขายครั้งสุดท้ายก่อนหน้านั้นมากที่สุด
3. ถ้ามีราคาที่ใกล้เคียงกับราคาซื้อขายครั้งสุดท้ายก่อนหน้านั้นมากกว่า 1 ราคา ให้ใช้ราคาที่สูงกว่าเป็นราคาปิด

อย่างไรก็ตาม หากระบบไม่สามารถคำนวณหาราคาปิดของหลักทรัพย์ตามหลักเกณฑ์ข้างต้นได้ ให้ถือว่าราคาซื้อขายครั้งสุดท้ายของหลักทรัพย์ในวันนั้นเป็นราคาปิด ข้อมูลที่นำมาศึกษาในครั้งนี้ ได้เลือกนำราคาปิดต่อวันของหุ้นของบริษัทการปิโตรเลียมแห่งประเทศไทย จำกัด (มหาชน) และราคาปิดต่อวันของหุ้นธนาคารกรุงเทพ จำกัด(มหาชน) เนื่องจากหุ้นทั้ง 2 รายการนี้เป็นหุ้นที่มีความโดดเด่น มีมูลค่าการซื้อขายต่อวันส่วนใหญ่อยู่ใน 5 ลำดับแรก บริษัทแรกเป็นบริษัทด้านพลังงาน และบริษัทหลังเป็นสถาบันการเงิน

หุ้น PTT

หุ้นของบริษัท การปิโตรเลียมแห่งประเทศไทย จำกัด (มหาชน) หรือ บริษัท ปตท. จำกัด(มหาชน) : PTT (ข้อมูลองค์กร 2007) จัดทะเบียนจัดตั้งขึ้นเมื่อวันที่ 1 ตุลาคม 2544 หลังการแปลงสภาพ ตามพระราชบัญญัติทุนรัฐวิสาหกิจ พ.ศ. 2542 โดยรับโอนกิจการ สิทธิ หนี้ ความรับผิดชอบ สินทรัพย์ และพนักงานทั้งหมดจากการปิโตรเลียมแห่งประเทศไทย (ปตท.) (ก่อตั้งขึ้นในปี พ.ศ. 2521) บมจ.ปตท.มีทุนจดทะเบียนเริ่มแรก 20,000 ล้านบาท แบ่งเป็นหุ้นสามัญจำนวน 2,000 ล้านหุ้น มูลค่าหุ้นละ 10 บาท ทั้งนี้ หุ้นของ บมจ.ปตท. ได้ทำการซื้อขายในตลาดหลักทรัพย์แห่งประเทศไทยวันแรก ในวันที่ 6 ธันวาคม พ.ศ. 2544 และมีกระทรวงการคลังเป็นผู้ถือหุ้นรายใหญ่

หุ้น BBL

ธนาคารกรุงเทพ (สำหรับผู้ถือหุ้น 2007) ได้จดทะเบียนก่อตั้งขึ้นอย่างเป็นทางการเมื่อวันที่ 20 พฤศจิกายน พ.ศ. 2487 และ เริ่มดำเนินธุรกิจเมื่อวันที่ 1 ธันวาคม พ.ศ. 2487 มีสำนักงานตั้งอยู่ที่อาคารพาณิชย์สองคูหาในย่านราชวงศ์ ใจกลางกรุงเทพฯ ในขณะนั้น มีพนักงานทั้งสิ้น 23 คน และมีหลวงรอบรู้กิจเป็นกรรมการผู้จัดการใหญ่ท่านแรก ท่านเป็นผู้ริเริ่มสร้างฐานลูกค้าของธนาคารด้วยการให้บริการตามความต้องการของลูกค้าแต่ละราย ธนาคารกรุงเทพในยุคต้น มีบทบาทอย่างมากในการสนับสนุนการผลิตและการค้าของคนไทยเพื่อฟื้นฟูประเทศภายหลังสงครามอย่างเต็มความสามารถ และเจริญก้าวหน้าเคียงคู่เศรษฐกิจและสังคมไทยอย่างต่อเนื่องและมั่นคง ปัจจุบันธนาคารกรุงเทพเป็นธนาคารพาณิชย์ที่ใหญ่ที่สุดในประเทศไทยและใหญ่เป็นอันดับที่ 5 ในภูมิภาคเอเชียตะวันออกเฉียงใต้ โดยมีมูลค่าสินทรัพย์รวมกว่า 1,490,000 ล้านบาท อีกทั้งยังเป็นธนาคารชั้นนำของประเทศในตลาดลูกค้าธุรกิจขนาดใหญ่และผู้ประกอบการขนาดกลางและขนาดย่อม พร้อมด้วยฐานลูกค้าบุคคลที่กว้างขวางที่สุดในประเทศ โดยมีจำนวนลูกค้าทุกประเภทรวมทั้งสิ้นประมาณ 16 ล้านบัญชี เครือข่ายบริการของธนาคารประกอบด้วยสำนักธุรกิจและสำนักธุรกิจย่อยรวม 250 แห่ง และสาขามากกว่า 750 แห่งทั่วประเทศ นอกจากนี้ ยังมีเครือข่ายบริการธนาคารอัตโนมัติ อันได้แก่ เครื่องเอทีเอ็มและเครื่องรับฝากเงินสดอัตโนมัติกว่า 3,600 เครื่อง บริการธนาคารทางโทรศัพท์ และบริการธนาคารทางอินเทอร์เน็ตที่ใช้ง่ายและมีสมรรถนะสูง ล้วนพร้อมอำนวยความสะดวกให้ลูกค้าสามารถทำธุรกรรมทางการเงินได้ทุกที่ ทุกเวลา

ธนาคารมีทุนจดทะเบียน 40,000 ล้านบาท ซึ่งแบ่งเป็นหุ้นสามัญ 3,998 ล้านหุ้น และหุ้นบุริมสิทธิ 2 ล้านหุ้น ที่ราคาพาร์ 10 บาท ทุนจดทะเบียนในส่วนที่ชำระแล้ว คือ 19,085 ล้านบาท แบ่งเป็น หุ้นสามัญ 1,908 ล้านหุ้น และหุ้นบุริมสิทธิ 345,000 หุ้น ที่ราคาพาร์ 10 บาท เป็นหลักทรัพย์จดทะเบียน เมื่อวันที่ 25 เมษายน 2518

ผู้ถือหุ้นรายใหญ่ของธนาคารกรุงเทพ จากข้อมูล ณ เดือนกันยายน พ.ศ 2549 มีดังนี้

1. ตลาดหลักทรัพย์แห่งประเทศไทย
2. บริษัท ไทยเอ็นวีดีอาร์ จำกัด
3. HSBC (SINGAPORE) NOMINEES PTE, LTD.
4. STATE STREET BANK AND TRUST COMPANY
5. CHASE NOMINEE LIMITED
6. THE BANK OF NEW YORK (NOMINEES) LIMITED
7. HSBC BANK PLC - CLIENTS GENERAL A/C
8. STATE STREET BANK AND TRUST COMPANY, FOR LONDON
9. บริษัท กรุงเทพประกันภัย จำกัด (มหาชน)
10. กระทรวงการคลัง

6. งานวิจัยที่เกี่ยวข้อง

Wang and Leu(1996) ได้ศึกษาการพยากรณ์ราคาหุ้นตลาดหลักทรัพย์ของไต้หวันโดยใช้ตัวแบบเครือข่ายประสาทเทียมพยากรณ์ประกอบกับสารสนเทศที่ได้จากตัวแบบ ARIMA ข้อมูลอนุกรมเวลาที่นำมาศึกษาได้แก่ราคาหุ้นในปี 1991-1995 ผู้วิจัยสร้างตัวแบบ ARIMA เพื่อพยากรณ์ราคา พบว่าตัวแบบที่เหมาะสมคือ ARIMA(1,2,1) จากตัวแบบนี้ ผู้วิจัยจึงสร้างตัวแบบ ANN แบบ recurrent โดยข้อมูลเข้า ประกอบด้วยจำนวนโหนดเท่ากับ 2 โหนดซึ่งคือ $p+q$ ในตัวแบบ ARIMA นั้นเอง ข้อมูลเข้าของตัวแบบใช้ผลต่างลำดับ 2 ซึ่งทราบจากตัวแบบและผลลัพธ์มีเพียงโหนดเดียว ส่วนจำนวนโหนดในชั้นซ่อนพิจารณาโดยการทดลองที่จำนวนโหนดต่างๆกันและเลือกจำนวนที่ให้ผลพยากรณ์ตามเกณฑ์มากที่สุด ผลการศึกษาพบว่าจากการสร้างตัวแบบโดยใช้ข้อมูลรายสัปดาห์ระยะเวลา 4 ปี สามารถใช้พยากรณ์แนวโน้มของตลาดล่วงหน้า 6 สัปดาห์ได้น่าพอใจ

Khaloozadeh and Sedigh(2001) ได้ศึกษาการพยากรณ์ราคาหุ้นในตลาดหุ้นเตหราน (Tehran Stock Exchange) ในกรณีที่มีเหตุการณ์ผิดปกติเกิดขึ้น ใช้ข้อมูลราคาหุ้นรายวันในช่วงปี 1996-1999 ในการศึกษาใช้ตัวแบบ ARIMA ตัวแบบ ANN แบบผลลัพธ์ค่าเดียว และตัวแบบ ANN แบบผลลัพธ์หลายค่า(Multivariate neural network หรือ Neural network with multi-output) ผลการศึกษาพบว่าการใช้ตัวแบบ ARIMA และตัวแบบ Auto Regressive Conditional Heteroscedasticity (ARCH) ในการพยากรณ์กรณีข้อมูลมีการเปลี่ยนแปลงเนื่องจากเหตุการณ์ผิดปกติ นั้น จะพยากรณ์ในระยะสั้นได้ดีระดับหนึ่ง แต่พยากรณ์ระยะยาวได้ไม่ดี ตัวแบบ ANN

แบบผลลัพท์เดียวกันก็ใช้พยากรณ์ในระยะยาวได้ไม่ดีเช่นกัน ตัวแบบ ANN แบบหลายตัวแปรสามารถพยากรณ์ราคาหุ้นในระยะยาวได้ดีที่สุด

Zhang(2003) ศึกษาการพยากรณ์ข้อมูลทางธุรกิจซึ่งข้อมูลมักมีส่วนประกอบทั้งเชิงเส้นและไม่เชิงเส้นผสมอยู่ โดยเสนอให้นำวิธีการ ARIMA และ วิธีการเครือข่ายประสาทเทียมมาผสมกันเพื่อพยากรณ์ข้อมูลที่มีส่วนประกอบเชิงเส้นและไม่เชิงเส้นอยู่ให้ถูกต้องยิ่งขึ้น โดยตัวแบบ ARIMA อธิบายส่วนประกอบที่มีลักษณะเชิงเส้น และตัวแบบ ANN อธิบายส่วนประกอบที่ไม่เชิงเส้น หลังจากนั้นรวมทั้งสองส่วนประกอบนี้เข้าด้วยกันเพื่อสร้างตัวแบบวิธีการพยากรณ์ที่เรียกว่าตัวแบบผสม(Hybrid Model) เนื่องจาก ARIMA เป็นวิธีการที่เหมาะสมกับข้อมูลที่มีลักษณะเป็นเส้นตรง(Linear) ซึ่งค่าส่วนเหลือที่ได้จากการวิเคราะห์โดย ARIMA เป็น nonlinear จึงนำไปใช้กับการวิเคราะห์โดย ANN เพื่อเรียนรู้พฤติกรรมและทำการสร้างแบบจำลองเพื่อไปใช้ในการสร้างตัวแบบผสม(Hybrid Model) ข้อมูลที่ใช้ในการศึกษาคือข้อมูลอนุกรมเวลาทุก 3 เดือนตั้งแต่ปี 1947-2001 ของบริษัทอุตสาหกรรม 3 บริษัทในสหรัฐอเมริกาได้แก่บริษัท 1)Clothing 2)Residential utilities และ 3)Auto Products ในการสร้างตัวแบบ ANN พิจารณาตัวแบบทั้งสิ้น 60 ตัวแบบ ประกอบด้วยตัวแบบที่ชั้นข้อมูลเข้ามีจำนวนโหนดตั้งแต่ 1 ถึง 6 โหนด ชั้นซ่อน 1 ชั้นมีจำนวนโหนดตั้งแต่ 1 ถึง 10 โหนด และชั้นผลลัพท์มีโหนดเดียวและข้อมูลเข้าเป็นอนุกรมเวลาที่ได้กำจัดแนวโน้มออกจากข้อมูลด้วยการวิเคราะห์การถดถอยแล้ว ผลการศึกษาพบว่าตัวแบบผสมให้ค่าพยากรณ์ที่ถูกต้องกว่าตัวแบบ ARIMA และตัวแบบ ANN

Fatima and Hussian(2006) ได้ใช้ตัวแบบผสม ซึ่งเรียกเป็น Hybrid Financial Systems(HFS) ในการพยากรณ์ดัชนีตลาดหลักทรัพย์การากิจ(Karachi Stock Exchange index: KSE100) เปรียบเทียบกับตัวแบบ ARIMA ตัวแบบ Auto Regressive Conditional Heteroscedasticity(ARCH) / Generalized Autoregressive Conditional Heteroscedasticity (GARCH) และตัวแบบ ANN ตัวแบบ HFS ที่ใช้เป็นตัวแบบผสมระหว่างตัวแบบ ANN กับตัวแบบ ARIMA และตัวแบบผสมระหว่าง ANN กับตัวแบบ ARCH/GARCH ตัวแบบ ANN ที่สร้าง ใช้ผลต่างของ log ของข้อมูลดัชนีรายวัน KSE100 เป็นข้อมูลเข้า และใช้ MSE เป็นเกณฑ์ในการเลือกตัวแบบ ตัวแบบ ANN สุดท้ายที่ได้คือ ตัวแบบ 7-1-1(ชั้นข้อมูลเข้า 7 โหนด ชั้นซ่อน 1 ชั้น 1 โหนด และชั้นผลลัพท์ 1 โหนด) ในการสร้างตัวแบบผสม จะพิจารณาสร้างตัวแบบ ARIMA หรือตัวแบบ ARCH/GARCH ซึ่งเป็นตัวแบบทางสถิติที่นิยมใช้พยากรณ์ข้อมูลอนุกรมเวลาโดยตัวแบบ ARIMA นิยมใช้กรณีข้อมูลปัจจุบันอาจเขียนในรูปผลบวกเชิงเส้นของข้อมูลในอดีต ขณะที่ตัวแบบ ARCH/GARCH ใช้กรณีที่ ข้อมูลปัจจุบันอาจเขียนในรูปผลบวกที่ไม่ใช่เชิงเส้น(nonlinear) ของข้อมูลในอดีต เมื่อสร้างตัวแบบ ARIMA หรือตัวแบบ ARCH/GARCH จากข้อมูลแล้ว นำค่า

พยากรณ์ที่ได้จากตัวแบบมาสร้างตัวแบบดังกล่าวมาสร้างตัวแบบ ANN ในการเปรียบเทียบประสิทธิภาพของตัวแบบ ใช้ค่าเฉลี่ยกำลังสองของความคลาดเคลื่อนในการพยากรณ์(Forecast Mean Squared Error: FMSE) โดยศึกษาการพยากรณ์ระยะสั้น ผลการวิจัยพบว่า ตัวแบบ ANN มีประสิทธิภาพดีกว่าตัวแบบ ARIMA และตัวแบบ ARCH/GARCH และตัวแบบผสม $ANN_{ARCH/GARCH}$ มีประสิทธิภาพมากกว่าตัวแบบ ANN และ ANN_{ARIMA} ในการพยากรณ์

Khoa et. al.(2006) ได้ศึกษาการพยากรณ์ราคาหุ้นโดยใช้ตัวแบบ ANN ทั้งแบบ feed forward (FFANN) และ แบบ recurrent(RANN) โดยนอกจากปัจจัยเวลาแล้ว ผู้วิจัยยังได้นำกำไรมาเป็นอีกปัจจัยหนึ่งที่ใช้ในการปรับน้ำหนักโดยวิธีการเรียนรู้แบบ Back Propagation ผลการวิจัยพบว่า การนำกำไรมาพิจารณาในตัวแบบด้วยการพยากรณ์แม่นยำขึ้นและตัวแบบ RANN ให้ผลการพยากรณ์ดีกว่าตัวแบบ FFANN ในทุกกรณีการศึกษา

ผู้วิจัย	ตัวแบบ	ข้อมูลเข้า
Wang and Leu(1996)	ARIMA และ ANN แบบ Recurrent	ราคาหุ้นตลาดหลักทรัพย์ไต้หวัน 199-1995 รายสัปดาห์
Khaloozadeh and Sedighi(2001)	ตัวแบบ ARIMA- ตัวแบบ ANN ผลลัพธ์ค่าเดียว ตัวแบบ ANN ผลลัพธ์หลายค่า Auto Regressive Conditional Heteroscedasticity (ARCH)	ราคาหุ้นรายวันในตลาดหุ้นเตหะรานปี1996-1999 โดยศึกษากรณีที่มีเหตุการณ์ผิดปกติเกิดขึ้น
Zhang(2003)	ARIMA , ANN และ ตัวแบบผสมระหว่าง ARIMA และ ANN(Hybrid Model)	ข้อมูลอนุกรมเวลาทุก 3 เดือนตั้งแต่ปี 1947-2001 ของบริษัทอุตสาหกรรม 3 บริษัทในสหรัฐอเมริกา ได้แก่บริษัท 1)Clothing 2)Residential utilities และ 3)Auto Products ข้อมูลเข้าของตัวแบบ ANN คือส่วนเหลือจากการพยากรณ์ด้วยตัวแบบ ARIMA เพื่อเรียนรู้พฤติกรรมในการสร้างตัวแบบผสม
Fatima and Hussian(2006)	Hybrid Financial Systems(HFS) , ARIMA, ANN ARCH/GARCH , $ANN_{ARCH/GARCH}$, ANN_{ARIMA}	ดัชนีตลาดหลักทรัพย์การจี 2006 ใช้ผลต่างของ log ของอนุกรมเวลาเป็นข้อมูลเข้าสำหรับตัวแบบ ANN ส่วนตัวแบบผสมนั้น นำค่าพยากรณ์ที่ได้จากตัวแบบ ARIMA/ARCH/GARCH เป็นข้อมูลเข้าสำหรับตัวแบบส่วน ANN
Khoa(2006)	ANN แบบ feed forward (FFANN) ANN แบบ recurrent(RANN)	ข้อมูลหุ้น S&P January 1990 to July 2005 และนำกำไรมาเป็นปัจจัยในการปรับน้ำหนักของ ANN

ตารางที่ 1 สรุปข้อมูลงานวิจัยที่เกี่ยวข้อง

บทที่ 3

วิธีการดำเนินการวิจัย

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อเปรียบเทียบการพยากรณ์อนุกรมเวลาด้วยตัวแบบ ARIMA ANN และตัวแบบผสมระหว่าง ARIMA และ ANN ในการพยากรณ์ราคาหุ้นของตลาดหลักทรัพย์แห่งประเทศไทย เพื่อให้บรรลุวัตถุประสงค์ดังกล่าว ผู้วิจัยดำเนินการวิจัยโดยมีรายละเอียดเกี่ยวกับระเบียบวิธีดำเนินการวิจัยและเครื่องมือที่ใช้ในการวิจัยดังนี้

ขั้นตอนในการดำเนินการวิจัย

ขั้นที่ 1 เก็บรวบรวมข้อมูลที่ใช้ในการวิจัย ได้แก่ข้อมูลราคาปิดของหลักทรัพย์ที่ตลาดหลักทรัพย์แห่งประเทศไทยได้รวบรวมไว้เป็นรายวัน ข้อมูลที่รวบรวมมาได้แก่ราคาปิดของหุ้น PTT และหุ้น BBL ตั้งแต่วันที่ 4 เดือน มกราคม พ.ศ.2548 ถึงวันที่ 5 เดือน เมษายน พ.ศ. 2550 รวม จำนวน 554 วัน โดยแบ่งข้อมูลเป็น 2 ส่วน คือข้อมูล 524 วันแรกเป็นชุดข้อมูลฝึกสอน และ ข้อมูล 30 วันหลังเป็นชุดข้อมูลทดสอบ

ขั้นที่ 2 นำข้อมูลอนุกรมเวลามาพล็อตกราฟเพื่อศึกษาลักษณะทั่วไปของอนุกรมเวลา

ขั้นที่ 3 สร้างตัวแบบที่เหมาะสมสำหรับข้อมูลชุดฝึกสอน 3 วิธี คือ วิธี ARIMA วิธี ANN และวิธีผสมระหว่าง ARIMA และ ANN โดยแต่ละวิธีมีขั้นตอนในการวิเคราะห์ดังนี้

1. ตัวแบบ ARIMA โดยวิธี Box-Jenkins มีขั้นตอนดังนี้

1.1 ตรวจสอบสมบัติคงที่ของอนุกรมเวลา

1.2 กำหนดตัวแบบ ARIMA(p,d,q) โดยพิจารณาลักษณะ ACF และ PACF ของ

ข้อมูลอนุกรมเวลาเทียบกับลักษณะ ACF และ PACF ทางทฤษฎี

1.3 ประมาณค่าพารามิเตอร์ในตัวแบบ

1.4 ตรวจสอบความเหมาะสมของตัวแบบ

2. ตัวแบบ ANN โดยเลือกตัวแบบแบบ Feed Forward Back Propagation โดยการทดลองสร้างตัวแบบที่เป็นไปได้ 6 ตัวแบบโดยมีรายละเอียดเกี่ยวกับโครงสร้างและการฝึกสอนที่ใช้ดังนี้

2.1 จำนวนข้อมูลเข้า ทดลองใช้ 1 และ 2 โหนด คือใช้ค่าอนุกรมเวลาที่เวลา $t-1$ และเวลา $t-2$ (y_{t-1} และ y_{t-2}) และให้เป็นผลลัพธ์ 1 ค่าคือค่าพยากรณ์ที่เวลา t (ค่าพยากรณ์ของ y_t)

2.2 ชั้นซ่อนใช้ 1 ชั้นเพื่อให้ตัวแบบง่าย และจำนวนโหนดในชั้นนี้ทดลองใช้ 3 จำนวนด้วยกัน คือ 5 10 และ 15 โหนด

2.3 ชั้นซ่อน ใช้ฟังก์ชันถ่ายโอน tangent sigmoid ส่วนชั้นผลลัพธ์ ใช้ฟังก์ชันถ่ายโอนเชิงเส้น

2.4 อัตราการเรียนรู้ 0.01

2.5 ฟังก์ชันที่ใช้วัดความเหมาะสมในการเลือกตัวแบบ (Performance function) คือ MSE จากนั้น เลือกตัวแบบที่ให้ MSE ต่ำสุด

3. ตัวแบบผสมระหว่าง ARIMA และ ANN มีรายละเอียดดังนี้

3.1 คำนวณส่วนเหลือ (Residuals) ของข้อมูลอนุกรมเวลาเมื่อพยากรณ์ด้วยตัวแบบ ARIMA ที่ได้ในข้อ 1.

3.2 ใช้ส่วนเหลือที่คำนวณได้จาก (1) นำมาสร้างตัวแบบ ANN โดยมีรายละเอียดและวิธีการเช่นเดียวกับในข้อ 2.

ขั้นที่ 4 เปรียบเทียบประสิทธิภาพของทั้ง 3 ตัวแบบที่ได้ โดยทำการพยากรณ์ล่วงหน้า 7 วัน และ 30 วัน นำไปเปรียบเทียบกับค่าจริงของข้อมูลชุดทดสอบจำนวน 30 ค่า แล้วคำนวณ MSE MAE MAPE ของตัวแบบทั้งสาม

เครื่องมือที่ใช้ในการวิเคราะห์

ในงานวิจัยนี้ การวิเคราะห์ตัวแบบ ARIMA ใช้โปรแกรมสำเร็จรูป SPSS และการวิเคราะห์ตัวแบบเครือข่ายประสาทเทียม (Artificial Neural Network : ANN) ใช้โปรแกรมสำเร็จรูป MATLAB

บทที่ 4


ผลการวิจัย

ในบทนี้ จะนำเสนอผลการวิจัยเป็น 2 ส่วน ส่วนแรกเป็นการวิเคราะห์ข้อมูลราคาหุ้น บริษัทปิโตรเลียมแห่งประเทศไทย จำกัด(มหาชน) หรือ PTT และส่วนที่สอง เป็นการวิเคราะห์ข้อมูลราคาหุ้นธนาคารกรุงเทพ จำกัด(มหาชน) หรือ BBL โดยในแต่ละส่วน จะประกอบด้วย 3 ตอน คือ (1) ลักษณะของข้อมูลอนุกรมเวลา (2) การกำหนดตัวแบบ ARIMA ANN และตัวแบบผสม (3) การเปรียบเทียบประสิทธิภาพของตัวแบบทั้ง 3 โดยตอนที่ (1) และ (2) เป็นการใช้อ้างอิงข้อมูลฝึกสอน จำนวน 524 ค่า และตอนที่ 3 เป็นการประเมินโดยใช้ข้อมูลทดสอบ 30 ค่า

ส่วนที่ 1 การวิเคราะห์ข้อมูลราคาหุ้น PTT

ลักษณะทั่วไปของข้อมูลอนุกรมเวลา


ราคาปิดรายวันของหุ้น PTT ตั้งแต่วันที่ 4 มกราคม 2548 ถึงวันที่ 21 กุมภาพันธ์ 2550 รวม 524 วัน เมื่อนำมาพล็อตตามเวลา ดังภาพที่ 7 จากกราฟพบว่าภาวะของราคามีลักษณะไม่คงที่ โดยในช่วงแรกข้อมูลมีแนวโน้มเพิ่มขึ้นแต่ในช่วงหลังกลับมีแนวโน้มลดลง




ภาพที่ 7 ภาวะของ ราคาปิดของหุ้นการปิโตรเลียมแห่งประเทศไทย PTT ระหว่างปี 2548 – 2550

ตัวแบบ ARIMA


จากการตรวจสอบค่า ACF ในภาพที่ 8 พบว่าฟังก์ชันสหสัมพันธ์ในตัวเองของราคาหุ้น PTT รายวันลดลงอย่างช้าๆ แสดงว่าอนุกรมเวลาเป็นแบบ Non-stationary จึงแปลงข้อมูลอนุกรมเวลาโดยการหาผลต่างอันดับ 1 เพื่อปรับให้เป็นอนุกรมเวลาแบบ Stationary



ภาพที่ 8 ACF ของราคาหุ้น PTT



ภาพที่ 9 ACF ผลต่างอันดับ 1 ของราคาหุ้น PTT




ภาพที่ 10 PACF ผลต่างอันดับ 1 ของราคาหุ้น PTT

การประมาณค่าพารามิเตอร์ตัวแบบ ARIMA

จากการตรวจสอบค่า ACF ของผลต่างอันดับ 1 ของอนุกรมเวลาของราคาหุ้น PTT ในภาพที่ 9 จะพบว่าสหสัมพันธ์ในตัวเองมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็วแสดงว่าอนุกรมเวลาของผลต่าง อันดับ 1 เป็นแบบ stationary และจากการเปรียบเทียบรูปแบบของ ACF และ PACF (ภาพที่ 9 และ 10) ของอนุกรมเวลานี้กับลักษณะของ ACF และ PACF ตามทฤษฎี Box-Jenkins พบว่าตัวแบบที่น่าจะเป็นคือตัวแบบ ARIMA(1,1,0) โดยจะพบว่าตัวแบบเป็น $\nabla y_t = -0.124\nabla y_{t-1}$ ซึ่ง ∇y_t เป็นผลต่างอันดับ 1 ของอนุกรมเวลาราคาหุ้นที่เวลา t ภาพที่ 11

Analysis of Variance:				
	DF	Adj. Sum of Squares	Residual Variance	
Residuals	522	9242.1551	17.704755	
Variables in the Model:				
	B	SEB	T-RATIO	APPROX. PROB.
AR1	-.12378901	.04346788	-2.8478275	.00457538

ภาพที่ 11 ค่าประมาณพารามิเตอร์ของตัวแบบ ARIMA(1,1,0)



ภาพที่ 12 ACF ของส่วนเหลือที่ได้จากตัวแบบ ARIMA(1,1,0)

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

การตรวจสอบความเหมาะสมตัวแบบ ARIMA

พิจารณาแผนภาพ ACF ของส่วนเหลือที่ได้จากตัวแบบ ARIMA(1,1,0) และ ตัวสถิติ Box-Ljung ในภาพที่ 12 พบว่ามีค่าประมาณสัมประสิทธิ์สหสัมพันธ์ในตัวเองของส่วนเหลือทุกๆ lag ไม่มีนัยสำคัญทางสถิติที่ระดับ 0.05 แสดงว่าส่วนเหลือที่ได้จากตัวแบบนี้ไม่มีสหสัมพันธ์กัน จึงนำค่าพยากรณ์ที่ได้ไปหาค่าประมาณความคลาดเคลื่อน MSE MAE และ MAPE ได้เป็น 16.67 2.95 และ 1.32 ตามลำดับ

ค่าความคลาดเคลื่อนของตัวแบบ ARIMA(1,1,0) (524 วัน)

MSE	MAE	MAPE
16.6709	2.9466	1.3240

ตัวแบบ ANN

จากการทดลองสร้างตัวแบบ ANN แบบ Feed Forward Back Propagation จากข้อมูลชุดฝึกสอนโดยเปลี่ยนจำนวนข้อมูลเข้าและจำนวนโหนดในชั้นซ่อน โดยใช้อัตราการเรียนรู้ 0.01 ฟังก์ชันถ่ายโอน tangent sigmoid ในชั้นซ่อนและฟังก์ชันเชิงเส้นในชั้นผลลัพธ์และใช้ MSE เป็นเกณฑ์ในการประเมินตัวแบบ และทำซ้ำ 20 รอบ ผลการทดลองใช้ตัวแบบภายใต้เงื่อนไขดังกล่าวพยากรณ์ดังตารางที่ 2 และ 3

ครั้งที่	Hidden Layer	Epochs	MSE		MAE		MAPE	
			train	test	train	test	train	test
1	5	20	18.901	3.4975	3.1116	1.44	1.4160	0.6991
2	10	20	17.8305	4.3719	2.9491	1.6270	1.3314	0.7899
3	15	20	16.6645	4.2482	2.8784	1.5559	1.2978	0.7545
4	20	20	16.5232	4.1784	2.8454	1.4875	1.2754	0.7232

ตารางที่ 2 ความคลาดเคลื่อนในการพยากรณ์ตัวแบบ ANN ใช้ข้อมูลเข้าราคาย้อนหลัง 1 วัน

ครั้งที่	Hidden Layer	Epochs	MSE		MAE		MAPE	
			train	test	train	test	train	test
1	5	20	31.0613	6.1825	4.0732	1.8817	1.8357	0.9137
2	10	20	30.4281	6.8356	4.0264	1.9654	1.8111	0.9546
3	15	20	29.0753	6.2612	3.9738	1.9464	1.7894	0.9430
4	20	20	28.9745	6.0851	3.9541	1.9296	1.7820	0.9343

ตารางที่ 3 ความคลาดเคลื่อนในการพยากรณ์ตัวแบบ ANN ใช้ข้อมูลเข้าราคาย้อนหลัง 2 วัน

ผลการทดลองพบว่าการใช้ข้อมูลเข้าเป็นราคาย้อนหลัง 1 วันจะให้ค่าความคลาดเคลื่อนน้อยกว่าการใช้ข้อมูลเข้าเป็นราคาย้อนหลัง 2 วัน สำหรับจำนวนโหนดในชั้นซ่อน พบว่าถ้าจำนวนโหนดในชั้นซ่อนเพิ่มขึ้น จะทำให้การพยากรณ์มีความถูกต้องมากขึ้น โดยจะพบว่าค่าความคลาดเคลื่อน MAE MSE และ MAPE จะลดน้อยลง อย่างไรก็ตาม เมื่อพิจารณา MSE พบว่ามีค่าใกล้เคียงกับค่า MSE ที่ได้จากตัวแบบ ARIMA ดังนั้นเพื่อให้ตัวแบบไม่ซับซ้อน จึงจะไม่เพิ่มจำนวนโหนดในชั้นซ่อนอีก และถือว่าจำนวนโหนด 15 ในชั้นซ่อนเป็นจำนวนโหนดที่เหมาะสม

ตัวแบบผสมระหว่าง ARIMA และ ANN

จากการนำอนุกรมเวลาของส่วนเหลือที่ได้จากตัวแบบ ARIMA(1,1,0) มาสร้างตัวแบบ ANN สำหรับพยากรณ์ส่วนประกอบที่ไม่เป็นเชิงเส้นของส่วนเหลือ ซึ่งจากการทดลอง พบว่าตัวแบบที่ใช้ข้อมูลย้อนหลัง 1 วัน จำนวนโหนดในชั้นซ่อน 15 โหนดและทำซ้ำ 20 ครั้งจะให้ตัวแบบ ANN ที่เหมาะสม จากนั้นนำค่าพยากรณ์ส่วนที่ได้จาก ANN ไปรวมกับค่าพยากรณ์ที่ได้จาก ARIMA และคำนวณค่าความคลาดเคลื่อน ได้ผลดังตารางที่ 4

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

Hidden Layer	Epochs	MSE	MAE	MAPE
15	20	15.6632	2.8204	1.2678

ตารางที่ 4 ความคลาดเคลื่อนในการพยากรณ์สำหรับตัวแบบผสมระหว่าง ARIMA และ ANN


ประสิทธิภาพของตัวแบบ

เพื่อเปรียบเทียบประสิทธิภาพของตัวแบบทั้ง 3 ที่ได้ในขั้นที่ (2) ได้นำข้อมูลทดสอบจำนวน 30 ค่าซึ่งเป็นราคาหุ้น PTT ตั้งแต่วันที่ 22 กุมภาพันธ์ 2550 ถึงวันที่ 5 เมษายน 2550 มาเปรียบเทียบกับข้อมูลที่ได้จากการพยากรณ์โดยใช้ตัวแบบทั้ง 3 โดยพิจารณาทั้งกรณีพยากรณ์ระยะสั้น 7 วัน และระยะยาว 30 วันล่วงหน้า ผลการเปรียบเทียบดังตารางที่ 5 แสดงการเปรียบเทียบค่า MSE , MAE และ MAPE ที่ได้จากการพยากรณ์ราคาหุ้นโดยตัวแบบ 3 ตัวแบบข้างต้น จะเห็นว่าการพยากรณ์ในช่วงข้อมูลฝึกสอน (training) ทั้ง 3 ตัวแบบให้ค่าวัดความถูกต้องในการ

พยากรณ์ใกล้เคียงกัน โดยตัวแบบผสมระหว่าง ARIMA และ ANN สามารถพยากรณ์ได้ถูกต้องมากกว่าเล็กน้อย สำหรับการพยากรณ์โดยใช้ข้อมูลทดสอบ (testing) พบว่าในการพยากรณ์ระยะยาว (30 วัน) ตัวแบบ ANN ให้ค่าความคลาดเคลื่อนในการพยากรณ์ต่ำกว่าอย่างเห็นได้ชัด แต่สำหรับการพยากรณ์ระยะสั้น (7 วัน) ตัวแบบผสมระหว่าง ARIMA และ ANN ให้ค่าความคลาดเคลื่อนในการพยากรณ์ต่ำสุด ดังภาพที่ 13-16

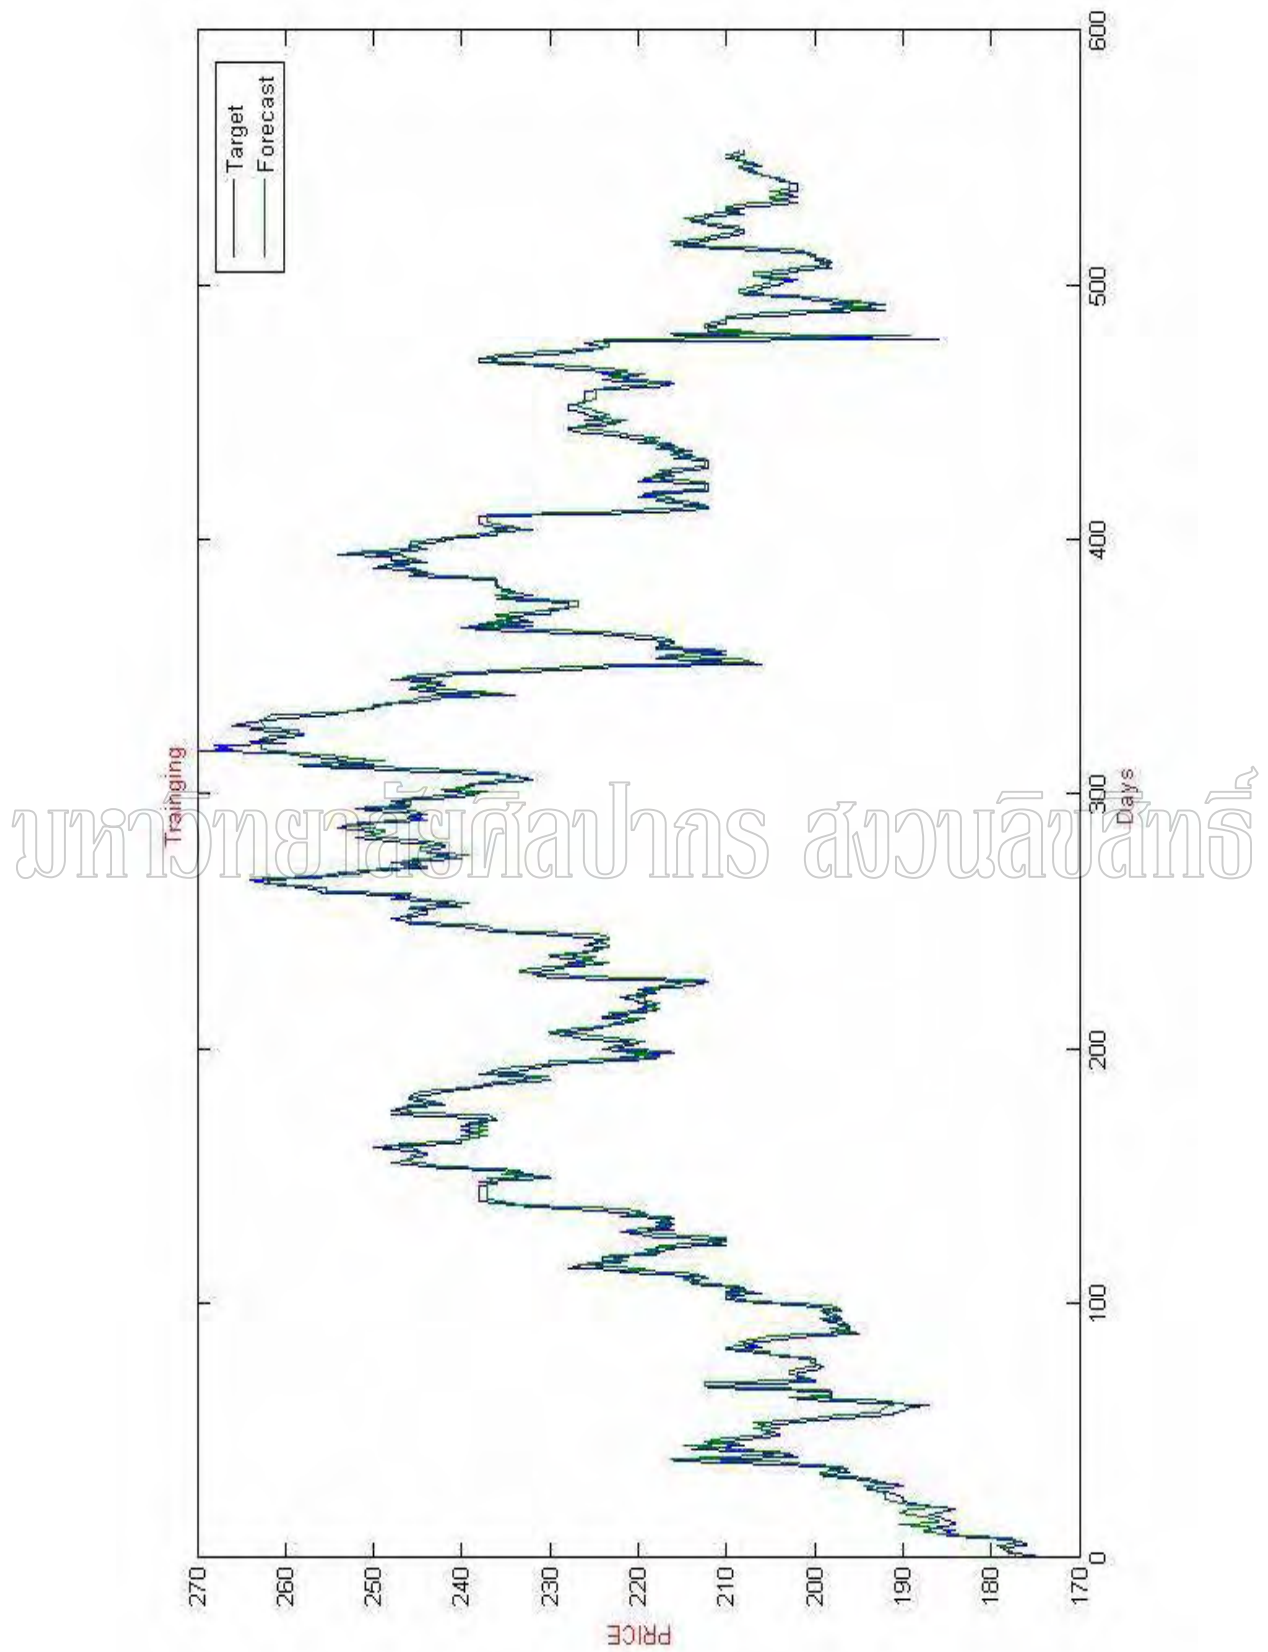
Method	MSE			MAE			MAPE		
	train	test(30)	test(7)	train	test(30)	test(7)	train	test(30)	test(7)
ARIMA	16.6709	35.7616	3.4404	2.9466	5.1452	1.4986	1.324	2.5141	0.7102
ANN	16.6645	4.2482	4.1376	2.8784	1.5559	1.4219	1.2978	0.7545	0.6756
Hybrid	15.6632	27.2158	1.7895	2.8204	4.3502	1.1278	1.2678	2.1277	0.5355

ตารางที่ 5 ประสิทธิภาพในการพยากรณ์หุ้น PTT ของตัวแบบ ARIMA ANN และตัวแบบผสม




มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

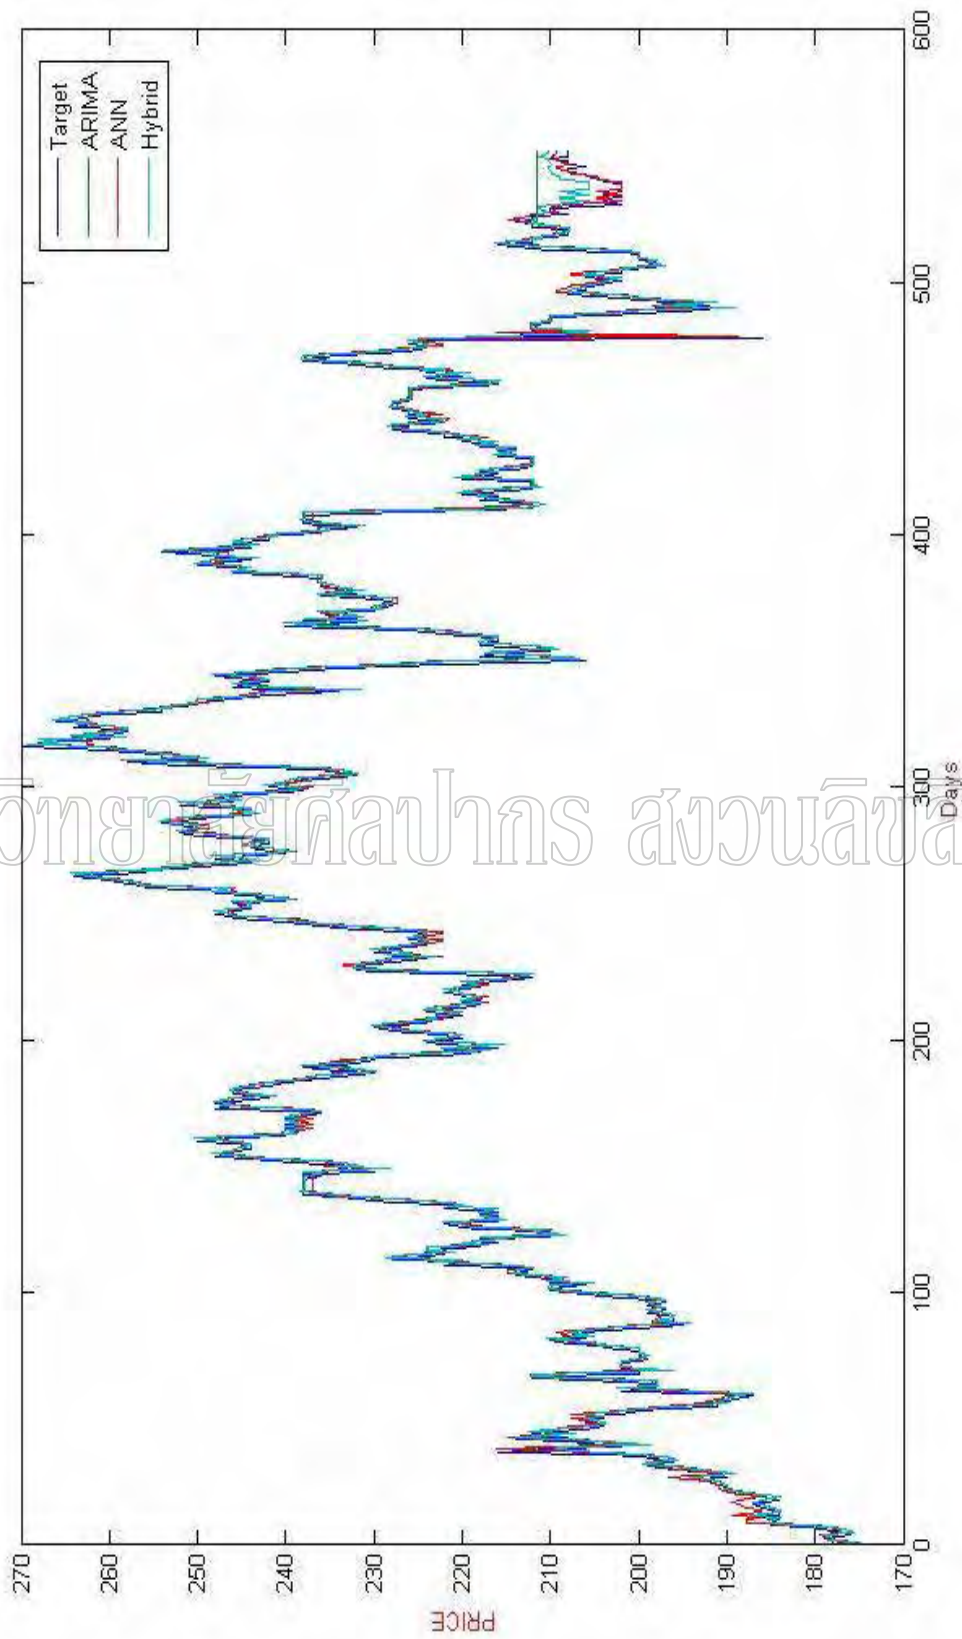
ภาพที่ 13 เปรียบเทียบค่าพยากรณ์โดย ARIMA กับ ข้อมูลจริง



ภาพที่ 14 เปรียบเทียบค่าพยากรณ์โดย ANN กับ ข้อมูลจริง



ภาพที่ 15 เปรียบเทียบค่าพยากรณ์โดย ตัวแบบผสม กับ ข้อมูลจริง




มหาวิทยาลัยศิลปากร ส่วนลิขสิทธิ์

ภาพที่ 16 เปรียบเทียบค่าพยากรณ์กับข้อมูลจริง

ส่วนที่ 2 การวิเคราะห์ราคาหุ้น BBL

ลักษณะทั่วไปของข้อมูลอนุกรมเวลา

ราคาปิดรายวันของหุ้น BBL ตั้งแต่วันที่ 4 มกราคม 2548 ถึงวันที่ 21 กุมภาพันธ์ 2550 รวม 524 วัน เมื่อนำมาพล็อตตามเวลา ดังภาพที่ 17 จากกราฟพบว่าภาวะของราคามีลักษณะไม่คงที่ โดยในช่วงแรกข้อมูลมีแนวโน้มเพิ่มขึ้นแต่ในช่วงหลังกลับมีแนวโน้มลดลง



ภาพที่ 17 ภาวะของ ราคาปิดของหุ้นธนาคารกรุงเทพ จำกัด มหาชน BBL ระหว่างปี 2548 – 2550

ตัวแบบ ARIMA

จากการตรวจสอบค่า ACF ในภาพที่ 18 พบว่าฟังก์ชันสหสัมพันธ์ในตัวเองของราคาหุ้น PTT รายวันลดลงอย่างช้าๆ แสดงว่าอนุกรมเวลาเป็นแบบ Non-stationary จึงแปลงข้อมูลอนุกรมเวลาโดยการหาผลต่างอันดับ 1 เพื่อปรับให้เป็นอนุกรมเวลาแบบ Stationary

Autocorrelations: PRICE

Lag	Auto-Corr.	Stand. Err.	-1 -0.75 -0.5 -0.25 0 .25 .5 .75 1							Box-Ljung	Prob.
1	.959	.044						*	*****	484.186	.000
2	.925	.044						*	*****	936.432	.000
3	.891	.043						*	*****	1355.975	.000
4	.861	.043						*	*****	1748.553	.000
5	.828	.043						*	*****	2112.570	.000
6	.797	.043						*	*****	2450.659	.000
7	.768	.043						*	*****	2765.066	.000
8	.743	.043						*	*****	3059.879	.000
9	.722	.043						*	*****	3339.178	.000
10	.704	.043						*	*****	3604.744	.000
11	.687	.043						*	*****	3858.610	.000
12	.670	.043						*	*****	4100.360	.000
13	.651	.043						*	*****	4328.855	.000
14	.623	.043						*	*****	4538.464	.000
15	.601	.043						*	*****	4733.942	.000
16	.578	.043						*	*****	4915.060	.000

Plot Symbols: Autocorrelations * Two Standard Error Limits .

Total cases: 524 Computable first lags: 523

ภาพที่ 18 ACF ของราคาหุ้น BBL

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

Autocorrelations: PRICE


Transformations: difference (1)

Lag	Auto-Corr.	Stand. Err.	-1 -0.75 -0.5 -0.25 0 .25 .5 .75 1							Box-Ljung	Prob.
1	-.103	.044					**	.		5.562	.018
2	.022	.044					.	*	.	5.821	.054
3	-.062	.044					.	*	.	7.863	.049
4	.032	.043					.	*	.	8.396	.078
5	-.023	.043					.	*	.	8.678	.123
6	-.016	.043					.	*	.	8.810	.185
7	-.050	.043					.	*	.	10.159	.180
8	-.057	.043					.	*	.	11.897	.156
9	-.021	.043					.	*	.	12.142	.205
10	-.023	.043					.	*	.	12.429	.257
11	.009	.043					.	*	.	12.473	.329
12	.023	.043					.	*	.	12.769	.386
13	.111	.043					.	**	.	19.461	.109
14	-.070	.043					.	*	.	22.082	.077
15	.015	.043					.	*	.	22.196	.103
16	.002	.043					.	*	.	22.198	.137

Plot Symbols: Autocorrelations * Two Standard Error Limits .

Total cases: 524 Computable first lags after differencing: 522

ภาพที่ 19 ACF ผลต่างอันดับ 1 ของราคาหุ้น BBL




ภาพที่ 20 PACF ผลต่างอันดับ 1 ของราคาหุ้น BBL

การประมาณค่าพารามิเตอร์ตัวแบบ ARIMA

จากการตรวจสอบค่า ACF ผลต่างอันดับ 1 ของอนุกรมเวลาของราคาหุ้น BBL ในภาพที่ 19 จะพบว่าสหสัมพันธ์ในตัวเองมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็วแสดงว่าอนุกรมเวลาของผลต่างอันดับ 1 เป็นแบบ stationary และจากการเปรียบเทียบรูปแบบของ ACF และ PACF (ภาพที่ 19 และ 20) ของอนุกรมเวลานี้กับลักษณะของ ACF และ PACF ตามทฤษฎี Box-Jenkins พบว่าตัวแบบที่น่าจะเป็นคือตัวแบบ ARIMA(1,1,0) และเนื่องจากค่าสหสัมพันธ์ในตัวเอง lag ที่ 1 และ lag ที่ 13 มีนัยสำคัญทางสถิติที่ระดับ 0.05 ดังนั้นกำหนดตัวแบบเป็น $\nabla y_t = -0.105\nabla y_{t-1} + 0.114\nabla y_{t-13}$ ซึ่ง ∇y_t เป็นผลต่างอันดับ 1 ของอนุกรมเวลาราคาหุ้นที่เวลา t ตามผลลัพธ์ที่ได้ดังภาพที่ 21

Analysis of Variance:				
	DF	Adj. Sum of Squares	Residual Variance	
Residuals	521	1915.8196	3.6759090	
Variables in the Model:				
	B	SEB	T-RATIO	APPROX. PROB.
AR1	-.10526449	.04328362	-2.4319702	.01535280
AR13	.11397136	.04346082	2.6223929	.00898700

ภาพที่ 21 ค่าประมาณพารามิเตอร์ของตัวแบบ ARIMA(1,1,0)



ภาพที่ 22 ACF ของส่วนเหลือที่ได้จากตัวแบบ ARIMA(1,1,0)

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

การตรวจสอบความเหมาะสมตัวแบบ ARIMA

พิจารณาแผนภาพ ACF ของส่วนเหลือที่ได้จากตัวแบบ ARIMA(1,1,0) และ ตัวสถิติ Box-Ljung ในภาพที่ 22 พบว่ามีค่าประมาณสัมประสิทธิ์สหสัมพันธ์ในตัวเองของส่วนเหลือทุกๆ lag ไม่มีนัยสำคัญทางสถิติที่ระดับ 0.05 แสดงว่าส่วนเหลือที่ได้จากตัวแบบนี้ไม่มีสหสัมพันธ์กัน จึงนำค่าพยากรณ์ที่ได้ไปหาค่าประมาณความคลาดเคลื่อน MSE MAE และ MAPE ได้เป็น 3.66 1.34 และ 1.24 ตามลำดับ

ผลการวิเคราะห์ค่าความคลาดเคลื่อนของ ARIMA MODEL (524 วัน)

MSE	MAE	MAPE
3.6626	1.3353	1.2430

ตัวแบบ ANN

จากการทดลองสร้างตัวแบบ ANN แบบ Feed Forward Back Propagation จากข้อมูลชุดฝึกสอนโดยเปลี่ยนจำนวนข้อมูลเข้าและจำนวนโหนดในชั้นซ่อน โดยใช้อัตราการเรียนรู้ 0.01 ฟังก์ชันถ่ายโอน tangent sigmoid ในชั้นซ่อนและฟังก์ชันเชิงเส้นในชั้นผลลัพธ์และใช้ MSE เป็นเกณฑ์ในการประเมินตัวแบบ และทำซ้ำ 20 รอบ ผลการทดลองใช้ตัวแบบภายใต้เงื่อนไขดังกล่าวพยากรณ์ดังตารางที่ 6 และ 7

ครั้งที่	Hidden Layer	Epochs	MSE		MAE		MAPE	
			train	test	train	test	train	test
1	5	20	3.6773	1.7264	1.3563	1.0549	1.2615	0.9725
2	10	20	3.6248	1.4446	1.3410	0.9220	1.2478	0.8496
3	15	20	3.5961	1.5488	1.3238	0.9573	1.2316	0.8821
4	20	20	3.5852	1.4470	1.3632	0.9380	1.2664	0.8628

ตารางที่ 6 ความคลาดเคลื่อนในการพยากรณ์ตัวแบบ ANN ใช้ข้อมูลเข้าราคาย้อนหลัง 1 วัน

ครั้งที่	Hidden Layer	Epochs	MSE		MAE		MAPE	
			train	test	train	test	train	test
1	5	20	6.4317	2.3443	1.8629	1.1527	1.7308	1.0560
2	10	20	6.2132	2.2847	1.8205	1.1429	1.6935	1.0484
3	15	20	6.1086	2.5062	1.8206	1.1679	1.6921	1.0726
4	20	20	6.0805	2.6220	1.8140	1.1747	1.6851	1.0793

ตารางที่ 7 ความคลาดเคลื่อนในการพยากรณ์ตัวแบบ ANN ใช้ข้อมูลเข้าราคาย้อนหลัง 2 วัน

ผลการทดลองพบว่าการใช้ข้อมูลเข้าเป็นราคาย้อนหลัง 1 วันจะให้ค่าความคลาดเคลื่อนน้อยกว่าการใช้ข้อมูลเข้าเป็นราคาย้อนหลัง 2 วัน สำหรับจำนวนโหนดในชั้นซ่อน พบว่าถ้าจำนวนโหนดในชั้นซ่อนเพิ่มขึ้น จะทำให้การพยากรณ์มีความถูกต้องมากขึ้น โดยจะพบว่าค่าความคลาดเคลื่อน MAE MSE และ MAPE จะลดน้อยลง อย่างไรก็ตาม เมื่อพิจารณา MSE พบว่ามีค่าใกล้เคียงกับค่า MSE ที่ได้จากตัวแบบ ARIMA ดังนั้นเพื่อให้ตัวแบบไม่ซับซ้อน จึงจะไม่เพิ่มจำนวนโหนดในชั้นซ่อนอีก และถือว่าจำนวนโหนด 15 ในชั้นซ่อนเป็นจำนวนโหนดที่เหมาะสม

ตัวแบบผสมระหว่าง ARIMA และ ANN

จากการนำอนุกรมเวลาของส่วนเหลือที่ได้จากตัวแบบ ARIMA(1,1,0) มาสร้างตัวแบบ ANN สำหรับพยากรณ์ส่วนประกอบที่ไม่เป็นเชิงเส้นของส่วนเหลือ ซึ่งจากการทดลอง พบว่าตัวแบบที่ใช้ข้อมูลย้อนหลัง 1 วัน จำนวนโหนดในชั้นซ่อน 15 โหนดและทำซ้ำ 20 ครั้งจะให้ตัวแบบ ANN ที่เหมาะสม จากนั้นนำค่าพยากรณ์ส่วนที่เหลือที่ได้จาก ANN ไปรวมกับค่าพยากรณ์ที่ได้จาก ARIMA และคำนวณค่าความคลาดเคลื่อน ได้ผลดังตารางที่ 8

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

Hidden Layer	Epochs	MSE	MAE	MAPE
15	20	3.4088	1.3296	1.2371

ตารางที่ 8 ความคลาดเคลื่อนในการพยากรณ์ตัวแบบผสมระหว่าง ARIMA และ ANN

ประสิทธิภาพของตัวแบบ

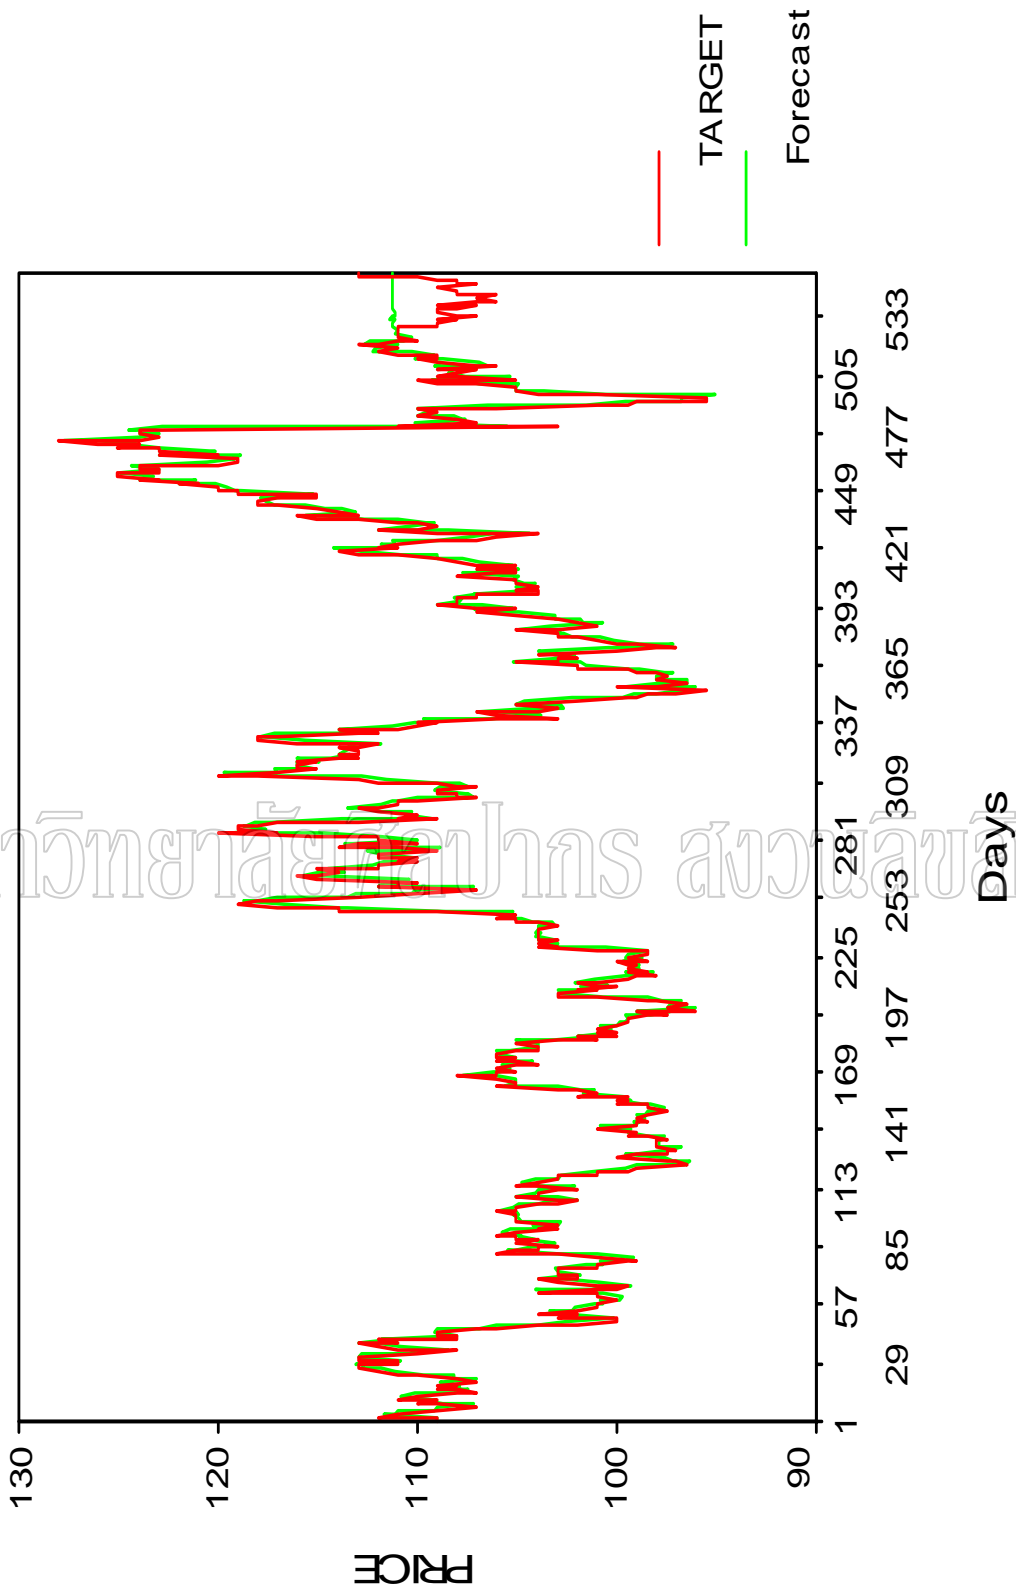
เพื่อเปรียบเทียบประสิทธิภาพของตัวแบบทั้ง 3 ที่ได้ในขั้นที่ (2) ได้นำข้อมูลทดสอบจำนวน 30 ค่าซึ่งเป็นราคาหุ้น BBL ตั้งแต่วันที่ 22 กุมภาพันธ์ 2550 ถึงวันที่ 5 เมษายน 2550 มาเปรียบเทียบกับข้อมูลที่ได้จากการพยากรณ์โดยใช้ตัวแบบทั้ง 3 โดยพิจารณาทั้งกรณีพยากรณ์ระยะสั้น 7 วัน และระยะยาว 30 วันล่วงหน้า ผลการเปรียบเทียบดังตารางที่ 9 แสดงการเปรียบเทียบค่า MSE , MAE และ MAPE ที่ได้จากการพยากรณ์ราคาหุ้นโดยตัวแบบ 3 ตัวแบบข้างต้น จะเห็นว่าสำหรับการพยากรณ์ในช่วงข้อมูลฝึกสอน (training) ทั้ง 3 ตัวแบบให้ค่าวัดความถูกต้องในการ

พยากรณ์ใกล้เคียงกัน โดยตัวแบบผสมระหว่าง ARIMA และ ANN สามารถพยากรณ์ได้ถูกต้องมากกว่าเล็กน้อย สำหรับการพยากรณ์โดยใช้ข้อมูลทดสอบ (testing) พบว่าในการพยากรณ์ระยะยาว (30 วัน) และ (7 วัน) ตัวแบบ ANN ให้ค่าความคลาดเคลื่อนในการพยากรณ์ต่ำกว่าอย่างเห็นได้ชัดดังภาพที่ 23-26


Method	MSE			MAE			MAPE		
	train	test(30)	test(7)	train	test(30)	test(7)	train	test(30)	test(7)
ARIMA	3.6626	9.2022	2.9968	1.3353	2.6857	1.1681	1.2430	2.4880	1.0747
ANN	3.5961	1.5488	0.6459	1.3238	0.9573	0.4791	1.2316	0.8821	0.4396
Hybrid	3.4088	8.4541	2.6523	1.3296	2.5734	1.1002	1.2371	2.3843	1.0122

ตารางที่ 9 ประสิทธิภาพในการพยากรณ์หุ้น BBL ของตัวแบบ ARIMA ANN และตัวแบบผสม

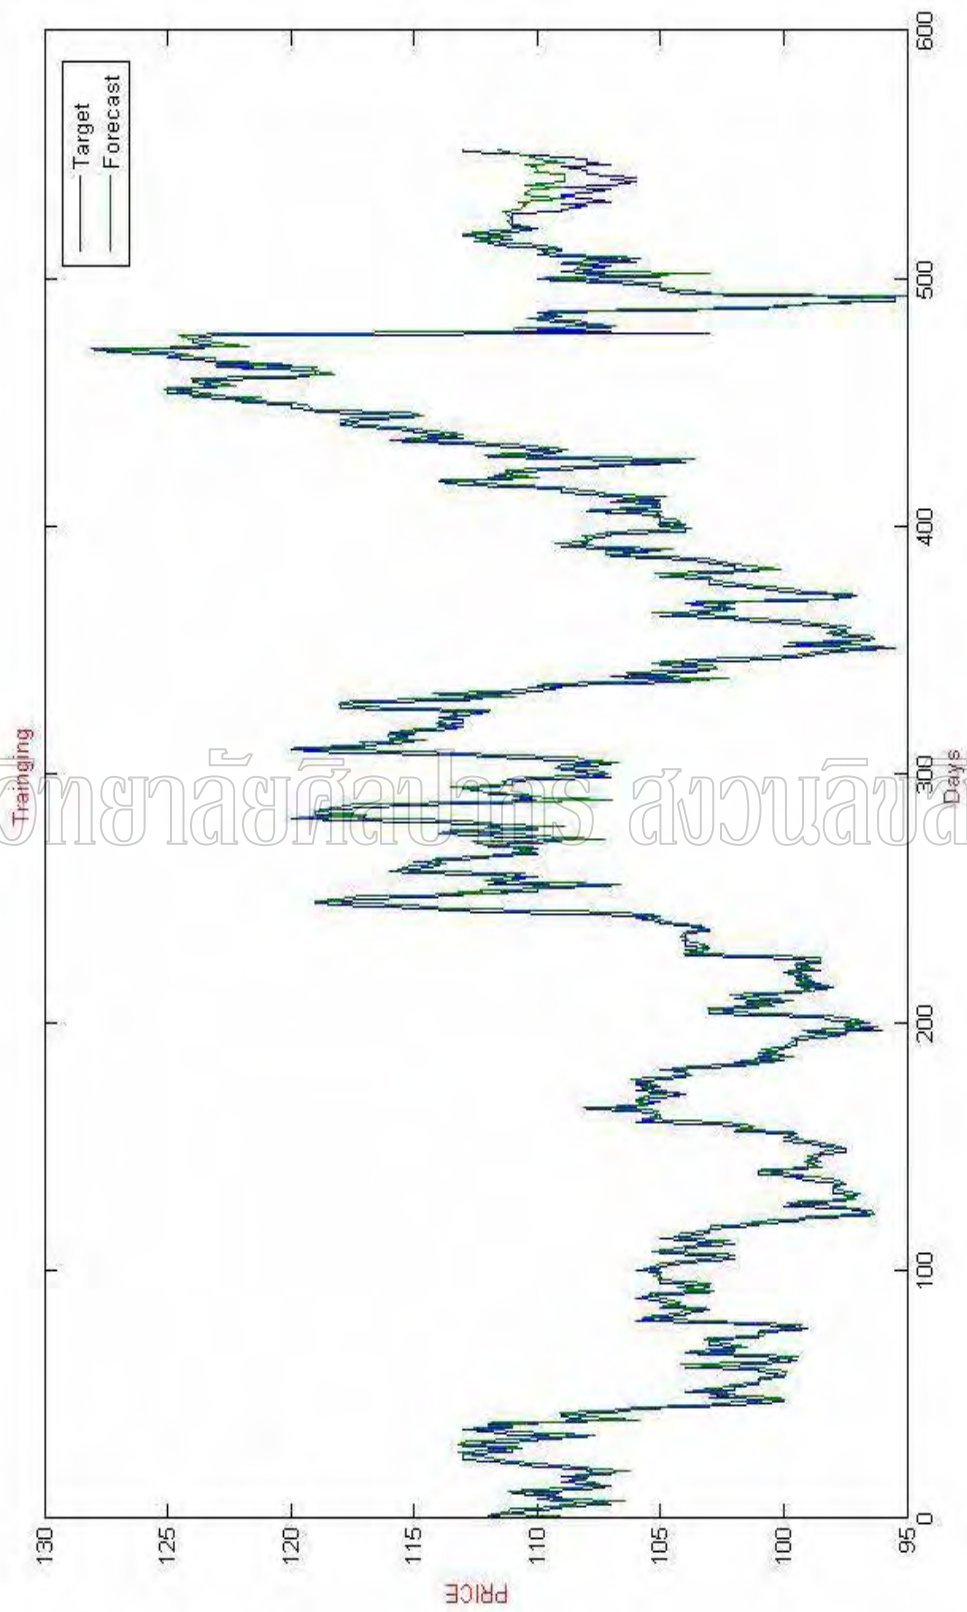
มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์




ภาพที่ 23 เปรียบเทียบค่าพยากรณ์โดย ARIMA กับ ข้อมูลจริง



ภาพที่ 24 เปรียบเทียบค่าพยากรณ์โดย ANN กับ ข้อมูลจริง



ภาพที่ 25 เปรียบเทียบค่าพยากรณ์โดย ตัวแบบผสม กับ ข้อมูลจริง



มหาวิทยาลัยศิลปากร ส่วนลิขสิทธิ์

ภาพที่ 26 เปรียบเทียบค่าพยากรณ์กับข้อมูลจริง

บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

สรุปผลการวิจัย

ในงานวิจัยเรื่องการพยากรณ์อนุกรมเวลาด้วยตัวแบบผสม ARIMA และ เครือข่ายประสาทเทียมมีวัตถุประสงค์เพื่อเปรียบเทียบการพยากรณ์อนุกรมเวลาด้วยตัวแบบ ARIMA ตัวแบบ ANN และตัวแบบผสมระหว่าง ARIMA และ ANN ในการพยากรณ์หุ้นโดยใช้ข้อมูลราคาปิดของหุ้น PTT และหุ้น BBL จำนวน 554 วัน โดยแบ่งเป็นข้อมูลฝึกสอน 524 วันและข้อมูลทดสอบ 30 วัน

ผลการวิจัยสรุปได้ดังนี้

1. หุ้น PTT

- ตัวแบบ ARIMA ที่เหมาะสมคือ $\nabla y_t = -0.124\nabla y_{t-1}$ ซึ่ง ∇y_t เป็นผลต่าง

อันดับ 1 ของอนุกรมเวลาราคาหุ้นที่เวลา t

- ตัวแบบ ANN ที่เหมาะสมคือ 1-15-1 หรือตัวแบบที่ประกอบด้วยชั้นข้อมูลเข้า 1 โหนด (y_{t-1}) ชั้นซ่อน 1 ชั้น 15 โหนด และชั้นผลลัพธ์ 1 โหนด (y_t) ทำซ้ำ 20 ครั้ง อัตราการเรียนรู้ 0.01

- ตัวแบบผสมระหว่าง ARIMA และ ANN ที่เหมาะสมคือ จากการใช้หลักการเดียวกันของตัวแบบ ANN กับอนุกรมของส่วนเหลือที่ได้จากตัวแบบ ARIMA (1, 1, 0) ตัวแบบที่ได้คือตัวแบบ 1-15-1 เช่นกัน (ชั้นข้อมูลเข้า 1 โหนด ชั้นซ่อน 1 ชั้น 15 โหนด และชั้นผลลัพธ์ 1 โหนด)

เมื่อเปรียบเทียบประสิทธิภาพในการพยากรณ์แล้ว พบว่า ในการพยากรณ์ระยะสั้น (7 วัน) ตัวแบบผสมระหว่าง ARIMA-ANN ให้ค่าความคลาดเคลื่อนในการพยากรณ์ต่ำสุด และในการพยากรณ์ระยะยาว (30 วัน) ตัวแบบ ANN ให้ค่าความคลาดเคลื่อนในการพยากรณ์ต่ำกว่าอย่างเห็นได้ชัด

2. หุ่น BBL

- ตัวแบบ ARIMA ที่เหมาะสมคือ $\nabla y_t = -0.105\nabla y_{t-1} + 0.114\nabla y_{t-13}$ ซึ่ง ∇y_t เป็นผลต่างอันดับ 1 ของอนุกรมเวลาราคาหุ้นที่เวลา t

- ตัวแบบ ANN ที่เหมาะสมคือ 1-15-1 หรือตัวแบบที่ประกอบด้วยชั้นข้อมูลเข้า 1 โหนด (y_{t-1}) ชั้นซ่อน 1 ชั้น 15 โหนด และชั้นผลลัพธ์ 1 โหนด (y_t) ทำซ้ำ 20 ครั้ง อัตราการเรียนรู้ 0.01

- ตัวแบบผสมระหว่าง ARIMA และ ANN ที่เหมาะสมคือ จากการใช้หลักการเดียวกันของตัวแบบ ANN กับอนุกรมของส่วนเหลือที่ได้จากตัวแบบ ARIMA (1, 1, 0) ตัวแบบที่ได้คือตัวแบบ 1-15-1 เช่นกัน (ชั้นข้อมูลเข้า 1 โหนด ชั้นซ่อน 1 ชั้น 15 โหนด และชั้นผลลัพธ์ 1 โหนด)

เมื่อเปรียบเทียบประสิทธิภาพในการพยากรณ์แล้วพบว่าตัวแบบ ANN ให้ค่าความคลาดเคลื่อนในการพยากรณ์ต่ำสุด ทั้งในการพยากรณ์ระยะสั้น (7 วัน) และในการพยากรณ์ระยะยาว (30 วัน)

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

อภิปรายผลการวิจัย

จากทดลองใช้ตัวแบบ ARIMA ตัวแบบ ANN และตัวแบบผสมระหว่าง ARIMA-ANN ในการพยากรณ์ข้อมูลราคาปิดของหุ้น PTT พบว่าตัวแบบผสมระหว่าง ARIMA-ANN สามารถให้ค่าพยากรณ์ในอนาคตระยะสั้นได้ถูกต้องมากกว่าวิธีตัวแบบ ARIMA และวิธีตัวแบบ ANN แต่สำหรับการพยากรณ์ค่าในระยะยาว วิธีตัวแบบ ANN ให้ค่าพยากรณ์ได้ถูกต้องมากที่สุด

แต่ในการพยากรณ์ข้อมูลราคาปิดของหุ้น BBL พบว่าตัวแบบ ANN ให้ค่าพยากรณ์ได้ถูกต้องมากที่สุดทั้งระยะยาวและระยะสั้น ซึ่งเมื่อตรวจสอบพบว่าเนื่องจากการพยากรณ์ระยะสั้น (7 วัน) โดยตัวแบบ ARIMA ให้ค่าประมาณความคลาดเคลื่อนสูงกว่าค่าประมาณความคลาดเคลื่อนของตัวแบบ ANN มากซึ่งมีผลต่อค่าพยากรณ์ของตัวแบบผสมระหว่าง ARIMA-ANN ทำให้เกิดความคลาดเคลื่อนถูกต้องมากกว่าตัวแบบ ARIMA แต่น้อยกว่าตัวแบบ ANN ส่วนการพยากรณ์ระยะสั้น (7 วัน) ของ PTT โดยตัวแบบ ARIMA ให้ค่าความคลาดเคลื่อนใกล้เคียงกับตัวแบบ ANN ส่งผลให้ค่าพยากรณ์ของตัวแบบผสมระหว่าง ARIMA และ ANN ถูกต้องมากกว่าวิธีตัวแบบ ARIMA และวิธีตัวแบบ ANN จึงมีข้อสังเกตว่าค่าพยากรณ์โดยตัวแบบ ARIMA มีผลต่อค่าพยากรณ์ของตัวแบบผสมระหว่าง ARIMA-ANN

ข้อเสนอแนะเพื่อการค้นคว้าวิจัยต่อไป

1. ในการศึกษาครั้งนี้ ศึกษาการพยากรณ์ข้อมูลอนุกรมเวลาโดยใช้ตัวแบบ ARIMA ในการศึกษาครั้งต่อไป อาจนำตัวแบบ ARCH หรือ GARCH มาใช้และศึกษาตัวแบบผสมระหว่าง ARCH/GARCH กับ ตัวแบบ ANN
2. ตัวแบบ ANN ที่นำมาศึกษาครั้งนี้ จำกัดเฉพาะตัวแบบ Feed Forward Neural Network ในงานวิจัยต่อไป อาจนำตัวแบบ Recurrent Neural Network มาใช้
3. ข้อมูลที่ใช้เป็นข้อมูลเข้าสำหรับตัวแบบ ANN ในศึกษานี้ ใช้ราคาหุ้นโดยตรง ในการศึกษาครั้งต่อไป อาจลองใช้ข้อมูลเข้าที่เป็นผลต่างตามอันดับที่ได้จากตัวแบบ ARIMA

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

บรรณานุกรม

ภาษาไทย

สุชัยศรี ไลออน. “แบบจำลองเชิงอนุกรมของความเสี่ยงแบบมีระบบของหลักทรัพย์กลุ่มธนาคารพาณิชย์ในตลาดหลักทรัพย์แห่งประเทศไทย.” วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ มหาวิทยาลัยศิลปากร, 2540.

ระบบข้อมูลตลาดหลักทรัพย์ฉบับออนไลน์ [Online]. Accessed 16 April 2007.

Available from <http://www.setsmart.com>

Artificial Neural Network โครงข่ายประสาทเทียม [Online]. Accessed 20 April 2007.

Available from http://202.28.94.55/web/320417/2548/work1/g26/Files/Report_Neural%20Network.doc

แหล่งความรู้ผู้ลงทุน [Online]. Accessed 20 April 2007.

Available from <http://www.set.or.th/th/index.html>

ข้อมูลองค์กร [Online]. Accessed 1 May 2007.

Available from <http://www.ptplc.com/th/default.asp>

สำหรับผู้ถือหุ้น [Online]. Accessed 1 May 2007.

Available from <http://www.bangkokbank.com/Bangkok+Bank+Thai/main.htm>

ภาษาต่างประเทศ

Ball, R. and P. Tisot. “Demonstration of Artificial Neural Network in Matlab.” Texas A&M University –Corpus Christi, USA 2006.

Box, G.E.P. and G. Jenkins. “Time Series Analysis Forecasting and Control.” Holden-Day, San Francisco, CA, 1976.

Fatima, S. and G. Hussian. “Statistical Models of KSE 100 Index Using Hybrid Financial Systems.” IEEE International Conference on Engineering of Intelligent Systems, 22-23 April 2006, :1-6.

Khaloozadeh, H. and A.K. Sedigh. “Long Term Prediction of Tehran Price Index (TEPIX) Using Neural Networks.” IFSA World Congress and 20th NAFIPS International Conference, Vol. 1, 25-28 July 2001, :563-567.

Khoa, N.L.D., Sakakibara, K. and I. Nishikawa. "Stock Price Forecasting using Back Propagation Neural Networks with Time and Profit Based Adjusted Weight Factors." SICE-ICASE International Joint Conference, October, 2006, :5484-5488.

Matlab R2006b Help, Math Works, 2006.

Thawornwong S. "Forecasting Stock Returns with Artificial Neural Networks." University of Missouri-Rolla, USA, 2004 :47-64.

Wang, J.H. and J.Y. Leu. "Stock Market Trend Prediction Using ARIMA –Based Neural Networks." IEEE International Conference on Neural Networks, Vol. 4, 3-6 June 1996, :2160-2165.

Zhang G.P. "A Combined ARIMA and Neural Network Approach for Time Series Forecasting." In Neural Networks in Business Forecasting , 2004, :213-225.

Zhang, G.P. "Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model." Neurocomputing, 50, 2004 :159-175.

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

ภาคผนวก

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

feed-forward backpropagation neural networks Source Code

```

nB = length(an);           //สร้างตัวแปรในการ training และ testing
nL = length(an)-30;       //โดยกำหนดข้อมูล testing 30 ที่เหลือเป็นการ training
an_tr = an(1:nL);
an_te = an(nL+1:nB);
bn_tr = bn(1:nL);
bn_te = bn(nL+1:nB);
price=an_tr;
target=bn_tr;
i=[1:length(price)];
TV.P = an_te;
TV.T = bn_te;
Hlayer=15;               //กำหนด Hidden Layer

net = newff(minmax(price),[Hlayer 1],{'tansig' 'purelin'}); //สร้าง network
net.trainParam.epochs = 20; //กำหนดจำนวนรอบในการปรับค่าน้ำหนักและส่วนเบี่ยงเบน
[net,tr,Y,E,Pf,Af] = train(net,price,target,[],[],[],TV);
fprintf('%g hidden units: %g train error, %g validate error, %g test
error\n',Hlayer,tr.perf(end),tr.vperf(end),tr.tperf(end))
Y2=sim(net,an_te);       //พยากรณ์ข้อมูลในการ Testing
i2=[1:length(an_te)];
target2=bn_te;
mse1=mse(target-Y)       //ตรวจสอบค่าความคลาดเคลื่อนเฉลี่ย
mse2=mse(target2-Y2)
mae1=mae(target-Y)
mae2=mae(target2-Y2)

```

```

mape1=sum(abs(target-Y)./target)*100/i(end)

mape2=sum(abs(target2-Y2)./target2)*100/i2(end)

```

feed-forward backpropagation neural networks Source Code(Hybrid)

```

net = newff(minmax(resi),[15 1],{'tansig' 'purelin'});           // สร้าง network
net.trainParam.epochs = 20;           // กำหนดจำนวนรอบในการปรับค่าน้ำหนักและส่วนเบี่ยงเบน
[net,tr,Y,E,Pf,Af] = train(net,resi,resit);           // ฝึกสอน pattern ให้กลับ network
plot(i,resit,i,Y);
xlabel('Days','color','r')
ylabel('PRICE blue line is target / green line is forecasting')
title('Forecasting')

hybrid=predict+Y           //สร้างค่า Hybrid
mse1=mse(thybrid-hybrid)           //คำนวณค่าความคลาดเคลื่อนของการพยากรณ์จาก Hybrid Model
mae1=mae(thybrid-hybrid)
mape1=sum(abs(thybrid-hybrid)./thybrid)*100/i(end)

Y2=sim(net,res_te);           //พยากรณ์ข้อมูลในการ Testing
hybrid_te=predict_te+Y2;
mse2=mse(thybrid_te-hybrid_te)           //คำนวณค่าความคลาดเคลื่อนเฉลี่ย
mae2=mae(thybrid_te-hybrid_te)
mape2=sum(abs(thybrid_te-hybrid_te)./thybrid_te)*100/length(hybrid_te)

```


ARIMA Syntax สำหรับหลักทรัพย์ BBL : ธนาคารกรุงเทพ จำกัด (มหาชน)

* ARIMA.

TSET PRINT=DEFAULT CIN=95 NEWVAR=ALL .

PREDICT THRU END.

ARIMA price

/MODEL=(1 1 0)NOCONSTANT/P=(1,13)

/MXITER 10

/PAREPS .001

/SSQPCT .001

/FORECAST EXACT .

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์

ประวัติผู้วิจัย

ชื่อ-สกุล นายพงษ์ศิริ ศิริพานิช
 วัน เดือน ปีเกิด 10 สิงหาคม พ.ศ.2520
 ที่อยู่ 1/17 หมู่ 7 ต.ดอนขมื่น อ.ท่ามะกา จ.กาญจนบุรี 71121
 ที่ทำงาน 1/17 หมู่ 7 ต.ดอนขมื่น อ.ท่ามะกา จ.กาญจนบุรี 71121

ประวัติการศึกษา

พ.ศ.2541 สำเร็จการศึกษาปริญญาวิทยาศาสตรบัณฑิต สาขา วิทยาการคอมพิวเตอร์
 คณะวิทยาศาสตร์ มหาวิทยาลัยกรุงเทพ

พ.ศ.2547 ศึกษาต่อในหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต สาขา คณิตศาสตร์
 และเทคโนโลยีสารสนเทศ คณะวิทยาศาสตร์ มหาวิทยาลัยศิลปากร

ประวัติการทำงาน

พ.ศ.2549 ประกอบธุรกิจส่วนตัว

พ.ศ.2545 อาจารย์ ประจำโรงเรียน สารสิทธิ์พิทยาลัย อ.บ้านโป่ง จ.ราชบุรี

พ.ศ.2544 อาจารย์ ประจำวิทยาลัยการอาชีพบ้านโป่ง จ.ราชบุรี

มหาวิทยาลัยศิลปากร สงวนลิขสิทธิ์