

บทที่ 3

แบบจำลองการพยากรณ์ความต้องการสินค้า

การที่เราจะสามารถทำการพยากรณ์ระดับสินค้าคงคลังได้ถูกต้อง และแม่นยำนั้น ปัจจัยหนึ่งที่ส่งผลกระทบต่อให้การพยากรณ์มีความถูกต้องมากขึ้นคือ ข้อมูลความต้องการสินค้าในแต่ละช่วงเวลา เนื่องจากถ้าเราสามารถพยากรณ์ความต้องการสินค้าได้อย่างมีประสิทธิภาพ ก็จะสามารถทราบถึงยอดการผลิตสินค้าล่วงหน้าได้แม่นยำขึ้น ส่งผลให้การจัดการสินค้าคงคลังได้มีประสิทธิภาพยิ่งขึ้น ทำให้ดังนั้น ทางผู้วิจัยจึงได้ทำการสร้างรูปแบบจำลองการพยากรณ์ความต้องการสินค้าขึ้น

3.1 การสร้างแบบจำลองการพยากรณ์

ทางผู้วิจัยได้ทำการสร้างรูปแบบการพยากรณ์ความต้องการสินค้าขึ้น โดยได้ทำการใช้ข้อมูลที่มีความสัมพันธ์กันระหว่างช่วงระยะเวลา และยอดขาย มาเป็นข้อมูลหลักเพื่อทำการเรียนรู้ และประมวลผลหาค่ายอดขายสินค้า โดยได้นำทฤษฎีระบบโครงข่ายประสาท (Neural Network) มาช่วยในการสร้างรูปแบบแบบจำลอง และทำการประมวลผลโดยใช้รูปแบบการคำนวณของทฤษฎี Back-Propagation Neural Network มาช่วยในการประมวลผล ซึ่งสามารถหาค่ายอดขายสินค้าที่เหมาะสมได้ โดยทางผู้วิจัยจึงได้ทำการสร้างรูปแบบของการพยากรณ์ความต้องการสินค้าขึ้น ซึ่งโครงสร้างของแบบจำลองนั้นได้แบ่งออกเป็น 3 ส่วนได้แก่

1. Input Layer Node เป็นส่วนในการป้อนข้อมูลช่วงเวลา เพื่อการนำค่าของช่วงเวลาไปทำการประมวลผลในส่วนถัดไป
2. Hidden Layer Node เป็นส่วนของการประมวลผลโดยการเชื่อมต่อของเครือข่ายในแต่ละชั้น จะทำการเชื่อมต่อและประมวลผลโดยใช้สมการ Sigmoid Function เพื่อทำการคำนวณหาผลลัพธ์ในแต่ละชั้น โดยแสดงในสมการที่ (3.1)

$$f(I) = \frac{1}{1 + \exp^{-I}} \quad (3.1)$$

โดยที่ค่า I คือค่าข้อมูลที่เข้าสู่โครงข่ายในแต่ละชั้น

โดยในการประมวลผลแบบจำลองนั้น จะนำข้อมูลช่วงเวลาเข้าสู่ระบบโดยผ่านการแปลงค่าข้อมูลโดยใช้สมการที่ 3.1 และให้ค่า Learning Rate แก่ข้อมูลทีละตัว แล้ว

กระจายเข้าไปยังแต่ละจุดเชื่อมต่อ เพื่อทำการประมวลผลในแต่ละชั้น เพื่อทำการหาค่าผลลัพธ์ที่ต้องการคือ ค่ายอดขายสินค้า หลังจากทีระบบประมวลผลในแบบจำลองได้ทำการประมวลค่าได้ค่ายอดขายสินค้ามา ก็จะทำการเทียบกับค่าจริง แล้วทำการคิดค่าความผิดพลาดขึ้น ถ้าค่าที่คำนวณได้นั้นผิดจากค่าจริง ระบบก็ทำการประมวลผลใหม่ โดยจะทำการปรับแก้ค่าน้ำหนักใหม่ เพื่อทำการหาค่าน้ำหนักที่เหมาะสมโดยใช้ทฤษฎี BPN ซึ่งเมื่อระบบทำการคำนวณจนได้ค่าการพยากรณ์ที่มีความผิดพลาดตามที่เรที่ตั้งไว้ ระบบก็จะหยุดการประมวลผล และแสดงค่าผลลัพธ์ที่ได้จากการประมวล จากนั้นจะนำค่าที่พยากรณ์ได้ส่งไปยังส่วนแสดงผล เพื่อแสดงค่ายอดขายสินค้าที่ได้จากการพยากรณ์


3. Output Layer Node เป็นส่วนของการแสดงผลลัพธ์ที่ได้จากการคำนวณของระบบ ซึ่งคือค่าความต้องการสินค้า

ซึ่งโครงสร้างของแบบจำลองที่ได้สร้างขึ้นสามารถดูได้ดังรูปที่ 3.1 โดย

จุดสีขาว แสดง ส่วนที่ทำการรับข้อมูลช่วงเวลา

จุดสีฟ้าอ่อน แสดง ส่วนที่ทำการประมวลผลเพื่อหาค่ายอดขาย

จุดสีน้ำเงิน แสดง ส่วนที่ทำการแสดงผลข้อมูลยอดขายสินค้าที่ได้จากการประมวลผล



รูปที่ 3.1 แสดงโครงสร้างของแบบจำลองเพื่อใช้ในการพยากรณ์

หลังจากที่ได้ทำการสร้างแบบจำลองขึ้นมา ก็จะมีการฝึกฝนแบบจำลองโดยทำการป้อนข้อมูลเข้าสู่แบบจำลองเพื่อทำการเรียนรู้ โดยทำการป้อนทั้งค่า Input และ Output เพื่อให้แบบจำลองสามารถเรียนรู้รูปแบบ และแนวโน้มของข้อมูล เพื่อให้การประมวลผลเพื่อการพยากรณ์มีประสิทธิภาพมากขึ้น

3.2 รูปแบบของข้อมูลที่ใช้ในการพยากรณ์

รูปแบบของข้อมูลที่ทำมาใช้ในการพยากรณ์นั้นเป็นข้อมูลในส่วนของยอดขายสินค้าในแต่ละเดือนซึ่งจะมีรูปแบบของข้อมูลที่มีความสัมพันธ์กันระหว่างเวลา และยอดขาย โดยทางผู้วิจัยได้ใช้ข้อมูลทั้งสิ้น 63 ชุดข้อมูล ซึ่งในแต่ละชุดจะประกอบด้วยข้อมูลจำนวน 24 ถึง 48 ข้อมูล มาทำการทดสอบแบบจำลองนี้ โดยตัวอย่างของข้อมูลแสดงไว้ดังตารางที่ 3.1 ซึ่งข้อมูลทั้งหมดสามารถดูได้ในภาคผนวก ก.


ตารางที่ 3.1 แสดงข้อมูลที่ใช้ในการทดสอบแสดงถึงปริมาณการขายรถแต่ละเดือนในเมือง Quebec ประเทศ Canada ระหว่างปีค.ศ. 1960-1962

Month Year	car sales		
	1960	1961	1962
January	6550	7237	10677
February	8728	9374	10947
March	12026	11837	15200
April	14395	13784	17010
May	14587	15926	20900
June	13791	13821	16205
July	9498	11143	12143
August	8251	7975	8997
September	7049	7610	5568
October	9545	10015	11474
November	9364	12759	12256
December	8456	8816	10583

* ข้อมูล หน่วยเป็นคัน/เดือน

3.3 การประมวลผลของแบบจำลอง


ในการประมวลผลของแบบจำลองนั้น ช่วงแรกทางผู้วิจัยได้ทำการฝึกฝนโดยได้ทำการประมวลผลข้อมูลเป็นจำนวน 100,000 รอบของการประมวลผล และทดสอบแบบจำลองโดยนำเอาข้อมูล 63 ชุดข้อมูลมาทำการคำนวณ เพื่อหาค่าผลลัพธ์ที่ได้ โดยทางผู้วิจัยได้ทำการใช้โปรแกรม Qnetv2000 มาช่วยในการคำนวณ ซึ่งโปรแกรมนี้เป็นโปรแกรมที่ใช้ในการคำนวณ Neural Network โดยตรง ซึ่งสามารถทำการออกแบบ สร้างโครงสร้างของแบบจำลอง และกำหนดพารามิเตอร์ต่าง ๆ ที่ใช้ในการประมวลผลเช่น Learn Rate(ETA) Momentum จำนวนรอบในการประมวลผล ทั้งนี้โปรแกรมนี้ใช้หลักการคำนวณผลโดยใช้ทฤษฎี Back-Propagation มาทำการคำนวณ ซึ่งทางผู้วิจัยเห็นว่าโปรแกรมนี้มีความเหมาะสมที่จะใช้ในการประมวลผลโดยได้ทำการกำหนดค่าที่ใช้ในการประมวลผลดังนี้ Learning Rate = 0.01 Learning Rate Minimum = 0.001 Learning Rate Maximum = 0.3 Momentum = 0.1 จำนวนรอบในการประมวลผล = 100,00 รอบ โดยสามารถกำหนดค่าภายในโปรแกรมดังรูปที่ 3.2



รูปที่ 3.2 แสดงหน้าต่างกำหนดค่าในการประมวลผลของโปรแกรม Qnetv2000

จากนั้นทำการคำนวณโดยนำค่าของข้อมูลเข้าสู่แบบจำลองทีละชุดข้อมูล จนกระทั่งครบ 63 ชุดข้อมูล ทำการหาค่าผลลัพธ์ที่ได้ในแต่ละชุดข้อมูล และกิดค่าความผิดพลาดที่เกิดขึ้นและทำการ

เทียบกับค่าความผิดพลาดที่ยอมรับได้ โดยการประมวลผลนั้นแบบจำลองจะทำการประมวลผลของข้อมูลจนกระทั่งระบบการประมวลผลของแบบจำลองเข้าสู่สถานะคงที่ (Steady State) ซึ่งทำให้สามารถคำนวณค่าของผลลัพธ์ที่ต้องการ และค่าความผิดพลาดที่เราสามารถยอมรับได้โดยโปรแกรมที่นำมาใช้จะทำการประมวลผลข้อมูลทั้งหมดโดยแสดงดังรูปที่ 3.3



รูปที่ 3.3 แสดงหน้าต่างในการประมวลผลของโปรแกรม Qnetv2000

หลังจากการทดสอบแบบจำลองแล้วจะทำการประเมินประสิทธิภาพความแม่นยำของแบบจำลองในการพยากรณ์ในแต่ละข้อมูลทดสอบจากค่าของ Absolute Percentage Error (APE) แสดงดังสมการที่ (3.2) เพื่อทดสอบความแม่นยำของค่าการพยากรณ์ที่ได้ในแต่ละตัว และค่าของ Mean Absolute Percentage Error (MAPE) แสดงดังสมการที่ (3.3) เพื่อทดสอบค่าความแม่นยำของการพยากรณ์ทั้งหมด โดยมีสูตรดังต่อไปนี้

$$APE = \left(\frac{|t_i - y_i|}{t_i} \right) \times 100 \quad (3.2)$$

$$MAPE = \left(\frac{1}{N_t} \right) \sum APE \quad (3.3)$$

กำหนดให้ x_i แสดงถึงค่าของข้อมูลจริงในช่วงระยะเวลา i
 y_i แสดงถึงค่าของการพยากรณ์ที่ได้จากแบบจำลองในช่วง
 ระยะเวลา i
 N_i แสดงถึงจำนวนข้อมูลทั้งหมดในช่วงที่ทำการเปรียบเทียบ
 ข้อมูล t

จากการประมวลผลแบบจำลอง Neural network ที่ใช้โปรแกรม Qnetv200 ทำการประมวลผล
 จะได้ค่าพยากรณ์ยอดขายสินค้า เพื่อทำการหาประสิทธิภาพของแบบจำลอง จึงได้มีการนำข้อมูลทั้ง
 63 ข้อมูลมาทำการพยากรณ์โดยใช้วิธีที่ต่างกัน ได้แก่ วิธีการ Linear Trend, Exponential Smoothing,
 Trend and Seasonal และ Moving average เพื่อหาค่าผลลัพธ์ที่ได้ออกมา แล้วทำการคำนวณหาค่า
 ความผิดพลาด เพื่อทำการเปรียบเทียบกับค่าความผิดพลาดที่ได้เทียบกับวิธีการพยากรณ์โดยใช้
 Neural Network ในการพยากรณ์

3.4 ผลการวิจัย

จากการประมวลผลเพื่อหาค่าผลลัพธ์ของการพยากรณ์ในแต่ละวิธีนั้น ค่าผลลัพธ์ที่ได้จาก
 การพยากรณ์ในแต่ละวิธีจะมีความแตกต่างกัน โดยทางผู้วิจัยได้นำค่าของผลลัพธ์ที่ได้ในแต่ละค่า
 ของแต่ละชุดข้อมูลมาทำการเปรียบเทียบ ซึ่งทางผู้วิจัยได้ทำการเปรียบเทียบค่ายอดขายจริงกับค่า
 ยอดขายที่ได้จากการพยากรณ์ในรูปแบบต่างๆ สำหรับข้อมูลชุดแรก แสดงให้เห็นดังตารางที่ 3.2
 โดยตารางการเปรียบเทียบค่ายอดขายจริงกับค่ายอดขายที่ได้จากการพยากรณ์ของข้อมูลชุดที่ 1 โดย
 ในตารางมีทั้งสิ้น 7 สดมภ์ ในแต่ละสดมภ์ของตารางจะแสดงข้อมูลต่อไปนี้

สดมภ์ที่ 1 แสดงลำดับของข้อมูล

สดมภ์ที่ 2 แสดงค่าจริงของข้อมูล

สดมภ์ที่ 3 แสดงค่าพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์แบบ Moving Average

สดมภ์ที่ 4 แสดงค่าพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์แบบ Linear Trend

สดมภ์ที่ 5 แสดงค่าพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์แบบ Exponential Smoothing

สดมภ์ที่ 6 แสดงค่าพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์แบบ Trend and Seasonal

สดมภ์ที่ 7 แสดงค่าพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์แบบ Neural Network

โดยสามารถดูผลการพยากรณ์ทั้ง 63 ชุดข้อมูลเพิ่มเติมได้ที่ภาคผนวก ข.

ตารางที่ 3.2 แสดงข้อมูลผลของการพยากรณ์เทียบกับค่าจริงในแต่ละวิธีของข้อมูลชุดที่ 1

ข้อมูล	ค่าจริง	Moving Average	Linear Trend	Exponential Smoothing	Trend and Seasonal	Neural Network
1	6550		10046.98			7945.78
2	8728		10114.93	6550		8499.76
3	12026		10182.88	8292.4	11429.37	10771.65
4	14395	9101.33	10250.82	11279.28	13066.87	14567.94
5	14587	11716.33	10318.77	13771.85	13383.75	15758.33
6	13791	13669.33	10386.71	14423.97	12299.75	12973.11
7	9498	14257.67	10454.66	13917.59	10589.5	9487.32
8	8251	12625.33	10522.60	10381.92	9116.5	7842.08
9	7049	10513.33	10590.55	8677.18	8569	7673.12
10	9545	8266.00	10658.49	7374.63	8577.87	8241.62
11	9364	8281.67	10726.44	9110.93	8627	9097.25
12	8456	8652.67	10794.38	9313.38	8629.12	9987.14
13	7237	9121.67	10862.33	8627.48	8916.87	10780.91
14	9374	8352.33	10930.27	7515.09	9892	11417.76
15	11837	8355.67	10998.22	9002.21	11644.12	11867.52
16	13784	9482.67	11066.16	11270.04	13286.12	12100.84
17	15926	11665.00	11134.11	13281.21	13755.25	12061.95
18	13821	13849.00	11202.06	15397.04	12942.37	11648.38
19	11143	14510.33	11270.00	14136.21	11176.75	10757.96
20	7975	13630.00	11337.95	11741.64	9661.5	9579.58
21	7610	10979.67	11405.89	8728.33	9387.75	9040.18
22	10015	8909.33	11473.84	7833.66	9694.87	10470.00
23	12759	8533.33	11541.78	9578.73	10183.37	12728.95
24	8816	10128.00	11609.73	12122.95	10683.25	9255.86

ข้อมูล	ค่าจริง	Moving Average	Linear Trend	Exponential Smoothing	Trend and Seasonal	Neural Network
25	10677	10530.00	11677.67	9477.39	11104.87	8655.71
26	10947	10750.67	11745.62	10437.08	12434.25	11799.03
27	15200	10146.67	11813.56	10845.01	14736.37	14488.09
28	17010	12274.67	11881.51	14329	16671.5	17447.80
29	20900	14385.67	11949.45	16473.8	16946.62	20371.61
30	16205	17703.33	12017.40	20014.76	15562.875	16503.56
31	12143	18038.33	12085.34	16966.95	12644.75	11374.73
32	8997	16416.00	12153.29	13107.79	10136.875	9745.56
33	5568	12448.33	12221.23	9819.16	9559.62	9609.89
34	11474	8902.67	12289.18	6418.23	9772	9902.32
35	12256	8679.67	12357.13	10462.85		10272.64
36	10583	9766.00	12425.07	11897.37		10603.83

จากผลการพยากรณ์ในตารางที่ 3.2 ผลของการพยากรณ์ที่ได้จากแต่ละวิธีนั้นมีค่าแตกต่างกัน ทางผู้วิจัยจึงได้จัดทำกราฟเพื่อนำมาทำการเปรียบเทียบค่าผลลัพธ์ที่ได้จากการพยากรณ์เทียบกับค่าจริง โดยกราฟที่นำมาใช้ในการวิเคราะห์ เป็นรูปแบบกราฟเส้นเพื่อแสดงให้เห็นถึงความสัมพันธ์ของยอดขายสินค้า และเวลา และสามารถเปรียบเทียบค่าของการพยากรณ์ในแต่ละวิธี เพื่อเทียบกับค่าจริงให้ชัดเจนยิ่งขึ้น ซึ่งเส้นกราฟ แต่ละเส้นจะแสดงค่ายอดขายรายเดือนในแต่ละเดือน โดย

เส้นสีน้ำเงิน แสดง ค่ายอดขายรายเดือนที่เป็นค่าจริง

เส้นสีชมพู แสดง ค่าพยากรณ์ยอดขายรายเดือนจากวิธี Moving Average


เส้นสีเหลือง แสดง ค่าพยากรณ์ยอดขายรายเดือนจากวิธี Linear Trend

เส้นสีฟ้า แสดง ค่าพยากรณ์ยอดขายรายเดือนจากวิธี Exponential Smoothing

เส้นสีม่วง แสดง ค่าพยากรณ์ยอดขายรายเดือนจากวิธี Trend and Seasonal

เส้นสีแดง แสดง ค่าพยากรณ์ยอดขายรายเดือนจากวิธี Neural network

ซึ่งสามารถสรุปผลของการเปรียบเทียบผลที่ได้ดังกราฟที่จะแสดงดังรูปที่ 3.4



รูปที่ 3.4 แสดง กราฟเปรียบเทียบผลของการพยากรณ์ในแต่ละวิธีเทียบกับค่าจริง

จากกราฟเราจะเห็นได้ว่า ผลการพยากรณ์โดยการใช้วิธี Neural Network นั้นมีค่าใกล้เคียงกับค่าจริง โดยค่าที่ได้จากการพยากรณ์นั้นในบางจุดทับกับค่าที่เป็นค่าจริง จากนั้นนำค่าที่ได้จากการพยากรณ์ในแต่ละวิธีมาทำการคำนวณหาค่าดัชนีความผิดพลาดในแต่ละชุดข้อมูล และทำการหาค่าเฉลี่ยความผิดพลาดที่เกิดขึ้นจากการพยากรณ์ในแต่ละวิธี ซึ่งค่าดัชนีความผิดพลาดของแต่ละข้อมูลในข้อมูล 63 ชุดข้อมูลนั้นสามารถดูได้ใน โดยแสดงไว้ดังตารางที่ 3.3 โดยมีทั้งสิ้น 6 สดมภ์ ในแต่ละสดมภ์ของตารางจะแสดงข้อมูลต่อไปนี้

สดมภ์ที่ 1 แสดงลำดับของข้อมูล

สดมภ์ที่ 2 แสดงค่าความผิดพลาดของการพยากรณ์ยอดขายสินค้าโดยวิธีการพยากรณ์แบบ

Moving Average

สดมภ์ที่ 3 แสดงค่าความผิดพลาดของการพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์แบบ

Linear Trend

สดมภ์ที่ 4 แสดงค่าความผิดพลาดของการพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์แบบ

Exponential Smoothing

สดมภ์ที่ 5 แสดงค่าความผิดพลาดของการพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์แบบ

Trend and Seasonal

สทมรที่ 6 แสดงค่าความผิดพลาดของการพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์แบบ

Neural Network

สามารถดูผลความผิดพลาดเพิ่มเติมทั้ง 63 ชุดข้อมูลได้ที่ภาคผนวก ค.

ตารางที่ 3.3 แสดงผลการเปรียบเทียบค่าความผิดพลาด (Absolute Percentage Error)

ลำดับ ข้อมูล	Moving Average	Linear Trend	Exponential Smoothing	Trend and Seasonal	Neural Network
1		53.39			21.31
2		15.89	24.95		2.61
3		15.33	31.05	0.45	10.43
4	36.77	28.79	21.64	2.42	1.20
5	19.68	29.26	5.59	37.93	8.03
6	0.88	24.68	4.59	9.28	5.93
7	50.11	10.07	46.53	6.99	0.11
8	53.02	27.53	25.83	7.53	4.96
9	49.15	50.24	23.10	21.38	8.85
10	13.40	11.67	22.74	3.59	13.66
11	11.56	14.55	2.70	0.75	2.85
12	2.33	27.65	10.14	31.81	18.11
13	26.04	50.09	19.21	24.90	48.97
14	10.90	16.60	19.83	0.13	21.80
15	29.41	7.09	23.95	0.98	0.26
16	31.21	19.72	18.24	3.51	12.21
17	26.75	30.09	16.61	44.89	24.26
18	0.20	18.95	11.40	6.34	15.72
19	30.22	1.14	26.86	7.36	3.46
20	70.91	42.17	47.23	6.24	20.12
21	44.28	49.88	14.70	22.09	18.79
22	11.04	14.57	21.78	4.86	4.54

ลำดับ ข้อมูล	Moving Average	Linear Trend	Exponential Smoothing	Trend and Seasonal	Neural Network
23	33.12	9.54	24.93	1.40	0.24
24	14.88	31.69	37.51	24.29	4.99
25	1.38	9.37	11.24	28.94	18.93
26	1.79	7.30	4.66	3.70	7.78
27	33.25	22.28	28.65	2.55	4.68
28	27.84	30.15	15.76	3.56	2.57
29	31.17	42.83	21.18	44.75	2.53
30	9.25	25.84	23.51	7.42	1.84
31	48.55	0.47	39.73	7.92	6.33
32	82.46	35.08	45.69	6.18	8.32
33	123.57	119.49	76.35	22.47	72.59
34	22.41	7.10	44.06	5.20	13.70
35	29.18	0.83	14.63		16.18
36	7.72	17.41	12.42		0.20

หน่วย:%

จากตารางที่ 3.3 จะแสดงให้เห็นถึงค่าความผิดพลาดของข้อมูลที่ได้จากการพยากรณ์ในแต่ละวิธี ทางผู้วิจัยจึงได้ทำการคำนวณหาค่าเฉลี่ยของความผิดพลาด (MAPE) ในแต่ละชุดข้อมูลจนครบทั้ง 63 ชุดข้อมูล นำค่าเฉลี่ยของความผิดพลาดที่คำนวณได้ในแต่ละชุดข้อมูลมาทำการวิเคราะห์และเปรียบเทียบ เพื่อหาค่าประสิทธิภาพของการพยากรณ์ ซึ่งทางผู้วิจัยได้จัดทำเป็นตารางเพื่อทำการเปรียบเทียบค่า MAPE ทั้ง 63 ชุดข้อมูล โดยแสดงไว้ดังตารางที่ 3.4 โดยในตารางมีทั้งสิ้น 6 สดมภ์ ในแต่ละสดมภ์ของตารางจะแสดงข้อมูลต่อไปนี้

สดมภ์ที่ 1 แสดงลำดับของชุดของข้อมูล

สดมภ์ที่ 2 แสดงค่าความผิดพลาดเฉลี่ยของการพยากรณ์ยอดขายสินค้าโดยวิธีการพยากรณ์

แบบ Moving Average

สดมภ์ที่ 3 แสดงค่าความผิดพลาดเฉลี่ยของการพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์

แบบ Linear Trend

สดมภ์ที่ 4 แสดงค่าความผิดพลาดเฉลี่ยของการพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์

แบบ Exponential Smoothing

สคมภ์ที่ 5 แสดงค่าความผิดพลาดเฉลี่ยของการพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์

แบบ Trend and Seasonal

สคมภ์ที่ 6 แสดงค่าความผิดพลาดเฉลี่ยของการพยากรณ์ยอดขายสินค้าจากวิธีการพยากรณ์

แบบ Neural Network

ตารางที่ 3.4 แสดงผลการเปรียบเทียบค่าเฉลี่ยความผิดพลาด (Mean Absolute Percentage Error) ของการพยากรณ์ในแต่ละวิธี

Data Set	Moving Average	Linear Trend	Exponential Smoothing	Trend and Seasonal	Neural Network
1	29.83	25.52	23.97	11.44	11.92
2	29.32	23.99	20.34	13.14	5.43
3	22.19	19.36	17.01	18.78	7.60
4	44.22	46.91	30.74	10.72	13.01
5	16.48	14.29	16.98	12.56	7.97
6	16.44	14.82	17.76	13.37	6.80
7	15.99	15.39	15.02	10.62	8.16
8	16.51	14.44	17.19	10.95	8.43
9	18.91	15.60	21.45	13.34	8.76
10	52.32	65.97	36.31	16.50	8.06
11	42.35	49.15	28.75	13.36	8.70
12	16.35	13.93	14.77	10.88	7.28
13	16.32	14.60	19.06	13.56	9.35
14	18.31	14.90	17.46	12.09	6.43
15	20.48	17.39	20.02	13.83	6.74
16	20.43	15.17	20.58	13.30	5.57
17	8.02	6.30	8.25	6.39	4.39
18	14.63	16.34	15.06	10.86	6.43
19	19.06	42.86	17.66	13.52	17.86
20	20.94	22.18	20.36	12.75	10.76

Data Set	Moving Average	Linear Trend	Exponential Smoothing	Trend and Seasonal	Neural Network
21	25.81	22.21	22.38	14.55	8.00
22	24.15	19.72	25.48	16.63	12.94
23	40.72	33.78	33.29	21.59	8.41
24	38.91	37.29	34.20	23.29	13.70
25	48.96	41.93	41.46	25.16	9.07
26	44.82	41.32	35.64	18.48	7.35
27	52.19	38.96	45.18	25.69	16.55
28	22.03	22.91	26.69	16.96	13.51
29	0.88	1.08	0.61	0.29	0.24
30	0.76	0.84	0.60	0.30	0.25
31	1.18	1.55	0.74	0.22	0.32
32	0.44	0.75	0.34	0.16	0.20
33	28.27	23.23	24.64	17.95	9.72
34	20.08	17.84	22.64	16.09	7.38
35	23.97	21.33	23.12	14.95	11.87
36	24.04	19.33	24.93	16.49	8.57
37	25.51	18.92	25.10	16.13	12.48
38	23.34	21.93	17.93	10.51	9.40
39	25.39	21.29	17.93	13.91	9.03
40	21.97	20.79	19.28	11.63	11.15
41	20.67	20.50	19.14	12.34	8.55
42	28.84	23.33	26.11	18.06	13.49
43	12.29	9.09	14.09	7.24	4.71
44	12.01	11.61	14.40	9.91	6.89
45	10.03	8.86	11.50	7.61	5.74
46	7.97	6.98	8.02	5.77	3.10
47	13.24	12.96	10.24	5.80	4.63

Data Set	Moving Average	Linear Trend	Exponential Smoothing	Trend and Seasonal	Neural Network
48	11.45	13.95	8.96	4.78	3.13
49	11.60	10.91	9.83	5.08	4.63
50	16.99	20.00	12.65	4.87	4.20
51	12.43	12.88	10.13	4.66	4.71
52	15.87	14.22	12.23	5.70	5.12
53	11.49	13.18	9.88	5.07	5.28
54	13.69	12.97	10.58	5.37	5.81
55	11.78	12.70	9.61	5.24	7.45
56	10.57	10.43	8.90	4.62	4.50
57	49.71	44.46	55.43	33.60	28.98
58	55.13	48.02	53.51	30.30	20.20
59	20.98	18.38	16.81	9.55	6.70
60	21.04	19.87	19.48	12.56	9.28
61	27.28	21.45	22.09	13.84	9.47
62	26.36	21.51	21.67	13.42	9.51
63	27.25	23.18	22.64	13.71	11.08

หน่วย:%

จากตารางที่ 3.4 จะเห็นถึงค่าเฉลี่ยความผิดพลาดของการพยากรณ์ในแต่ละวิธีของทั้งสิ้น 63 ชุดข้อมูล ทางผู้วิจัยจึงได้ทำการวิเคราะห์ค่าที่ได้ ทำการสรุปหาค่าค่าเฉลี่ยของความผิดพลาด (Mean Mean Absolute Percentage Error; Mean MAPE) เพื่อจะได้สามารถวิเคราะห์ประสิทธิภาพของการพยากรณ์ในแต่ละวิธีได้ ซึ่งทางผู้วิจัยได้จัดทำเป็นตารางเพื่อทำการสรุป และวิเคราะห์ประสิทธิภาพของการพยากรณ์ได้ดังตารางที่ 3.5

Copyright © Chiang Mai University
All rights reserved

ตารางที่ 3.5 แสดงค่าประสิทธิภาพของการพยากรณ์ในแต่ละวิธี

ดัชนีในการวัด ประสิทธิภาพการพยากรณ์	Moving Average	Linear Trend	Neural Network
Max MAPE	55.13	65.96	28.98
Min MAPE	0.44	0.75	0.20
Mean MAPE	22.24	20.75	8.36
ดัชนีในการวัด ประสิทธิภาพการพยากรณ์	Trend and Seasonal	Exponential Smoothing	
Max MAPE	33.60	55.43	
Min MAPE	0.15	0.33	
Mean MAPE	12.25	19.82	

จากตารางที่ 3.5 แสดงให้เห็นถึงประสิทธิภาพของการพยากรณ์โดยใช้แบบจำลอง NN จะพบว่าค่าประสิทธิภาพของการพยากรณ์ มีประสิทธิภาพดีกว่าวิธีการอื่น ๆ โดยแบบจำลอง Neural Network นั้นมีค่า Mean MAPE อยู่ที่ 8.36% ค่า Max MAPE อยู่ที่ 28.98% และค่า Min MAPE อยู่ที่ 0.20% นั้นมีค่าน้อยกว่าวิธีการพยากรณ์รูปแบบอื่น ๆ จึงแสดงให้เห็นว่าการพยากรณ์โดยวิธี Neural Network นั้นมีประสิทธิภาพดีกว่าการพยากรณ์ด้วยวิธีอื่น

3.5 การเปรียบเทียบการพยากรณ์แบบจำลอง NN กับ การพยากรณ์วิธี Exponential Smoothing

ทางผู้วิจัยได้ทำการหาประสิทธิภาพจริงของการพยากรณ์ที่ใช้แบบจำลอง NN จึงได้ทำการเปรียบเทียบผลการพยากรณ์กับวิธีการพยากรณ์แบบ Exponential Smoothing โดยนำข้อมูลที่สามารถพยากรณ์ด้วยวิธีการ Exponential Smoothing ได้ค่าความผิดพลาดต่ำสุด เพื่อสามารถชี้เฉพาะได้ว่าแบบจำลอง NN มีประสิทธิภาพที่ดีกว่าวิธีการพยากรณ์แบบ Exponential Smoothing โดยข้อมูลที่นำมาพิจารณานั้นเป็นข้อมูลที่อยู่ในรูปของสมการ Exponential โดยตรงซึ่งสามารถใช้วิธีการพยากรณ์แบบ Exponential Smoothing แล้วผลการพยากรณ์มีค่าความผิดพลาดต่ำที่สุด โดยแสดงดังตารางที่ 3.6 ซึ่งตารางจะประกอบด้วยกัน 2 สดมภ์ ได้แก่

สดมภ์ ชั่วโมงที่ แสดง ค่าลำดับของชั่วโมง

สดมภ์ ปริมาณน้ำที่ลดลง แสดง ค่าปริมาณระดับน้ำที่ลดลงโดยมีหน่วยเป็น ฟุตต่อชั่วโมง

ตารางที่ 3.6 แสดงข้อมูล Exponential ของปริมาณระดับน้ำที่ลดลงในแม่น้ำ Snoqualmie ใน รัฐ Washington

ชั่วโมงที่	ปริมาณน้ำที่ลดลง	ชั่วโมงที่	ปริมาณน้ำที่ลดลง	ชั่วโมงที่	ปริมาณน้ำที่ลดลง	ชั่วโมงที่	ปริมาณน้ำที่ลดลง
1	2410	16	1210	31	684	46	459
2	2390	17	1190	32	661	47	446
3	2270	18	1130	33	645	48	433
4	2190	19	1100	34	629	49	425
5	2020	20	1030	35	608	50	417
6	2010	21	965	36	592	51	404
7	1890	22	965	37	582	52	392
8	1890	23	909	38	566	53	389
9	1880	24	868	39	552	54	377
10	1690	25	842	40	537	55	373
11	1600	26	810	41	518	56	366
12	1550	27	779	42	513	57	358
13	1430	28	754	43	499	58	351
14	1380	29	724	44	485	59	344
15	1290	30	707	45	472	60	336

จากข้อมูลในตารางที่ 3.6 ได้ทำการพยากรณ์โดยใช้วิธี Exponential ที่มี $\alpha = 1$ และ $\Delta\alpha = 0.1$ เพื่อทำการพยากรณ์โดยค่าที่กำหนดนี้ทำให้สามารถพยากรณ์ค่าได้ดีที่สุด และทำการพยากรณ์โดยใช้แบบจำลอง NN เพื่อทำการเปรียบเทียบค่าพยากรณ์ที่ได้ดังตารางที่ 3.7 ซึ่งประกอบด้วยกัน 4 สดมภ์ ได้แก่

สดมภ์ ลำดับข้อมูล

แสดง ค่าลำดับข้อมูล

สดมภ์ ค่าจริง

แสดง ค่าข้อมูลจริง

สดมภ์ Exponential Smoothing

แสดง ค่าการพยากรณ์จากวิธี Exponential Smoothing

สดมภ์ Neural Network

แสดง ค่าการพยากรณ์จากวิธี Neural Network

ตารางที่ 3.7 แสดงการเปรียบเทียบค่าการพยากรณ์ในวิธี Exponential Smoothing และแบบจำลอง NN เทียบกับค่าจริง

ลำดับ ข้อมูล	ค่า จริง	Exponential Smoothing	Neural Network	ลำดับ ข้อมูล	ค่า จริง	Exponential Smoothing	Neural Network
1	2410		2418.92	31	684	707	682.20
2	2390	2410	2347.89	32	661	684	660.87
3	2270	2390	2271.71	33	645	661	640.78
4	2190	2270	2191.33	34	629	645	621.83
5	2020	2190	2107.78	35	608	629	603.94
6	2010	2020	2022.21	36	592	608	587.02
7	1890	2010	1935.73	37	582	592	570.99
8	1890	1890	1849.42	38	566	582	555.80
9	1880	1890	1764.24	39	552	566	541.37
10	1690	1880	1681.01	40	537	552	527.64
11	1600	1690	1600.42	41	518	537	514.58
12	1550	1600	1522.98	42	513	518	502.13
13	1430	1550	1449.06	43	499	513	490.25
14	1380	1430	1378.89	44	485	499	478.91
15	1290	1380	1312.60	45	472	485	468.08
16	1210	1290	1250.21	46	459	472	457.71
17	1190	1210	1191.67	47	446	459	447.8
18	1130	1190	1136.87	48	433	446	438.31
19	1100	1130	1085.66	49	425	433	429.22
20	1030	1100	1037.87	50	417	425	420.52
21	965	1030	993.29	51	404	417	412.2
22	965	965	951.74	52	392	404	404.23
23	909	965	913.01	53	389	392	396.61


ลำดับข้อมูล	ค่าจริง	Exponential Smoothing	Neural Network	ลำดับข้อมูล	ค่าจริง	Exponential Smoothing	Neural Network
24	868	909	876.88	54	377	389	389.33
25	842	868	843.188	55	373	377	382.39
26	810	842	811.72	56	366	373	375.78
27	779	810	782.32	57	358	366	369.5
28	754	779	754.81	58	351	358	363.54
29	724	754	729.05	59	344	351	357.92
30	707	724	704.89	60	336	344	352.64

จากผลการพยากรณ์ที่ได้ทางผู้วิจัยได้ทำการแสดงผลของค่าการพยากรณ์เพื่อทำการเปรียบเทียบในรูปแบบของกราฟ เพื่อสามารถดูแนวโน้มของค่าการพยากรณ์ได้ชัดเจนยิ่งขึ้น โดย

เส้นสีน้ำเงิน แสดง ค่าจริงของปริมาณระดับน้ำที่ลดลง

เส้นสีชมพู แสดง ค่าพยากรณ์ปริมาณระดับน้ำที่ลดลงจากวิธี Exponential Smoothing

เส้นสีเหลือง แสดง ค่าพยากรณ์ปริมาณระดับน้ำที่ลดลงจากแบบจำลอง Neural Network



รูปที่ 3.5 แสดง กราฟเปรียบเทียบผลของการพยากรณ์ในแต่ละวิธีเทียบกับค่าจริง

จากรูปที่ 3.5 นำค่าของการพยากรณ์ทั้ง 2 วิธีไปทำการคำนวณหาค่าดัชนี APE และค่า MAPE เพื่อทำการวัดประสิทธิภาพของการพยากรณ์ทั้ง 2 วิธี โดยเมื่อคำนวณหาค่า MAPE ที่ได้ออกมา ก็สามารถเปรียบเทียบประสิทธิภาพของการพยากรณ์ทั้ง 2 วิธีโดยค่า MAPE ที่ได้จากการพยากรณ์โดยวิธี Exponential Smoothing นั้นมีค่า 3.36% ส่วนค่า MAPE จากแบบจำลอง NN นั้นมีค่าอยู่ที่ 1.49% ซึ่งสามารถบอกได้ว่าแบบจำลอง NN นั้นสามารถทำการพยากรณ์ได้ประสิทธิภาพดีกว่าวิธีการพยากรณ์แบบ Exponential Smoothing

3.6 การเปรียบเทียบการพยากรณ์แบบจำลอง NN กับ การพยากรณ์วิธี Linear Trend

ทางผู้วิจัยได้ทำการหาประสิทธิภาพจริงของการพยากรณ์ที่ใช้แบบจำลอง NN จึงได้ทำการเปรียบเทียบผลการพยากรณ์กับวิธีการพยากรณ์แบบ Linear Trend โดยทำการสร้างข้อมูลจากสมการ Linear Trend คือ $Y=5X+10$ เพื่อที่สามารถชี้เฉพาะได้ว่าแบบจำลอง NN มีประสิทธิภาพที่ดีกว่าวิธีการพยากรณ์แบบ Linear Trend โดยข้อมูลที่นำมาพิจารณานั้นสามารถใช้วิธีการพยากรณ์แบบ Linear Trend แล้วผลการพยากรณ์มีค่าความผิดพลาดต่ำที่สุด โดยแสดงดังตารางที่ 3.8 ซึ่งตารางจะประกอบด้วยกัน 2 สดมภ์ ได้แก่

สดมภ์ X แสดง ค่า X
สดมภ์ Y แสดง ค่า Y

ตารางที่ 3.8 แสดงค่าข้อมูลจากสมการ $Y=5X+10$

X	Y	X	Y	X	Y	X	Y
1	15	10	60	19	105	28	150
2	20	11	65	20	110	29	155
3	25	12	70	21	115	30	160
4	30	13	75	22	120	31	165
5	35	14	80	23	125	32	170
6	40	15	85	24	130	33	175
7	45	16	90	25	135	34	180
8	50	17	95	26	140	35	185
9	55	18	100	27	145	36	190

จากข้อมูลในตารางที่ 3.8 ได้ทำการพยากรณ์โดยใช้วิธี Linear Trend เพื่อทำการพยากรณ์โดยค่าที่กำหนดนี้ทำให้สามารถพยากรณ์ค่าได้ดีที่สุด และทำการพยากรณ์โดยใช้แบบจำลอง NN เพื่อทำการเปรียบเทียบค่าพยากรณ์ที่ได้ดังตารางที่ 3.9 ซึ่งประกอบด้วยกัน 4 สดมภ์ ได้แก่.

สดมภ์ ลำดับข้อมูล

แสดง ค่าลำดับข้อมูล

สดมภ์ ค่าจริง

แสดง ค่าข้อมูลจริง

สดมภ์ Linear Trend

แสดง ค่าการพยากรณ์จากวิธี Linear Trend

สดมภ์ Neural Network

แสดง ค่าการพยากรณ์จากวิธี Neural Network

ตารางที่ 3.9 แสดงการเปรียบเทียบค่าการพยากรณ์ในวิธี Linear Trend และแบบจำลอง NN เทียบกับค่าจริง

ลำดับ ข้อมูล	ค่า จริง	Linear Trend	Neural Network	ลำดับ ข้อมูล	ค่า จริง	Linear Trend	Neural Network
1	15	15	15	19	105	105	105
2	20	20	20	20	110	110	110
3	25	25	25	21	115	115	115
4	30	30	30	22	120	120	120
5	35	35	35	23	125	125	125
6	40	40	40	24	130	130	130
7	45	45	45	25	135	135	135
8	50	50	50	26	140	140	140
9	55	55	55	27	145	145	145
10	60	60	60	28	150	150	150
11	65	65	65	29	155	155	155
12	70	70	70	30	160	160	160
13	75	75	75	31	165	165	165
14	80	80	80	32	170	170	170
15	85	85	85	33	175	175	175


ลำดับ ข้อมูล	ค่า จริง	Linear Trend	Neural Network	ลำดับ ข้อมูล	ค่า จริง	Linear Trend	Neural Network
16	90	90	90	34	180	180	180
17	95	95	95	35	185	185	185
18	100	100	100	36	190	190	190

จากผลการพยากรณ์ที่ได้ทางผู้วิจัยได้ทำการแสดงผลของค่าการพยากรณ์เพื่อทำการเปรียบเทียบใน
รูปแบบของกราฟ เพื่อสามารถดูแนวโน้มของค่าการพยากรณ์ได้ชัดเจนยิ่งขึ้น โดย

เส้นสีน้ำเงิน แสดง ค่าจริง

เส้นสีชมพู แสดง ค่าพยากรณ์จากวิธี Linear Trend

เส้นสีเหลือง แสดง ค่าพยากรณ์ปริมาณระดับน้ำที่ลดลงจากแบบจำลอง Neural Network



รูปที่ 3.6 แสดง กราฟเปรียบเทียบผลของการพยากรณ์ในแต่ละวิธีเทียบกับค่าจริง

จากรูปที่ 3.6 นำค่าของการพยากรณ์ทั้ง 2 วิธีไปทำการคำนวณหาค่าดัชนี APE และค่า MAPE เพื่อ
ทำการวัดประสิทธิภาพของการพยากรณ์ทั้ง 2 วิธี โดยเมื่อคำนวณหาค่า MAPE ที่ได้ออกมา ก็
สามารถเปรียบเทียบประสิทธิภาพของการพยากรณ์ทั้ง 2 วิธีโดยค่า MAPE ที่ได้จากการพยากรณ์
โดยวิธี Linear Trend และค่า MAPE จากแบบจำลอง NN นั้นมีค่าเท่ากันคือ 0% ซึ่งสามารถบอกได้

ว่าแบบจำลอง NN นั้นสามารถทำการพยากรณ์มีประสิทธิภาพเท่ากับวิธีการพยากรณ์แบบ Linear Trend บนพื้นฐานข้อมูลที่อยู่ในลักษณะ Linear Trend ถ้ารูปแบบของข้อมูลเป็นแบบอื่นแล้วแบบจำลอง NN มีประสิทธิภาพการพยากรณ์ที่ดีกว่า

3.7 การเปรียบเทียบการพยากรณ์แบบจำลอง NN กับ การพยากรณ์วิธี Trend and Seasonal

ทางผู้วิจัยได้ทำการหาประสิทธิภาพจริงของการพยากรณ์ที่ใช้แบบจำลอง NN จึงได้ทำการเปรียบเทียบผลการพยากรณ์กับวิธีการพยากรณ์แบบ Trend and Seasonal โดยได้นำข้อมูลที่มีรูปแบบของข้อมูลแบบ Trend and Seasonal เพื่อที่สามารถชี้เฉพาะได้ว่าแบบจำลอง NN มีประสิทธิภาพที่ดีกว่าวิธีการพยากรณ์แบบ Trend and Seasonal โดยข้อมูลที่น่ามาพิจารณานั้นสามารถใช้วิธีการพยากรณ์แบบ Trend and Seasonal แล้วผลการพยากรณ์มีค่าความผิดพลาดต่ำที่สุด โดยแสดงดังตารางที่ 3.10 ซึ่งตารางจะประกอบด้วยกัน 2 สดมภ์ ได้แก่

สดมภ์ ช่วงเวลา แสดง ค่าลำดับช่วงเวลา หน่วยเป็นเดือน
สดมภ์ ยอดขายบ้าน แสดง ค่าปริมาณการขายบ้าน

ตารางที่ 3.10 แสดงปริมาณการขายบ้านในแต่ละเดือน

ช่วงเวลา	ยอดขายบ้าน	ช่วงเวลา	ยอดขายบ้าน	ช่วงเวลา	ยอดขายบ้าน	ช่วงเวลา	ยอดขายบ้าน
1	53	10	52	19	57	28	60
2	59	11	43	20	59	29	61
3	73	12	37	21	54	30	58
4	72	13	43	22	57	31	62
5	62	14	55	23	43	32	61
6	58	15	68	24	42	33	49
7	55	16	68	25	52	34	51
8	56	17	64	26	51	35	47
9	52	18	65	27	58	36	40

จากข้อมูลในตารางที่ 3.8 ได้ทำการพยากรณ์โดยใช้วิธี Trend and Seasonal เพื่อทำการพยากรณ์โดยกำหนดค่า Slope = -0.2153 Intercept = 59.455 Season Index 12 ค่าได้แก่ 0.8771 0.9738 1.1563

1.1762 1.1479 1.1260 1.0083 0.9069 0.9069 0.9069 0.9069 และ 0.9069 ซึ่งค่าที่กำหนดนี้ทำให้สามารถพยากรณ์ค่าได้ดีที่สุด และทำการพยากรณ์โดยใช้แบบจำลอง NN เพื่อทำการเปรียบเทียบค่าพยากรณ์ที่ได้ดังตารางที่ 3.11 ซึ่งประกอบด้วยกัน 4 สดมภ์ ได้แก่

สดมภ์ ลำดับข้อมูล

แสดง ค่าลำดับข้อมูล

สดมภ์ ค่าจริง

แสดง ค่าข้อมูลจริง

สดมภ์ Linear Trend

แสดง ค่าการพยากรณ์จากวิธี Trend and Seasonal

สดมภ์ Neural Network

แสดง ค่าการพยากรณ์จากวิธี Neural Network

ตารางที่ 3.11 แสดงการเปรียบเทียบค่าการพยากรณ์ในวิธี Trend and Seasonal และแบบจำลอง NN เทียบกับค่าจริง

ลำดับ ข้อมูล	ค่า จริง	Trend and Seasonal	Neural Network	ลำดับ ข้อมูล	ค่า จริง	Trend and Seasonal	Neural Network
1	53	51.96	62.69	19	57	55.83	59.33
2	59	57.48	62.65	20	59	50.01	58.03
3	73	68.00	62.57	21	54	49.82	56.41
4	72	68.92	62.39	22	57	49.62	52.10
5	62	67.01	62.01	23	43	49.43	47.25
6	58	65.49	61.18	24	42	49.23	45.21
7	55	58.43	59.39	25	52	47.43	47.14
8	56	52.36	55.80	26	51	52.45	53.21
9	52	52.16	50.97	27	58	62.03	57.68
10	52	51.96	52.33	28	60	62.84	60.20
11	43	51.77	42.80	29	61	61.08	61.24
12	37	51.57	36.55	30	58	59.67	57.83
13	43	49.70	42.70	31	62	53.22	62.08
14	55	54.96	56.49	32	61	47.67	60.67
15	68	65.01	65.98	33	49	47.47	50.81


ลำดับ ข้อมูล	ค่า จริง	Trend and Seasonal	Neural Network	ลำดับ ข้อมูล	ค่า จริง	Trend and Seasonal	Neural Network
16	68	65.88	68.21	34	51	47.28	48.51
17	64	64.05	66.31	35	47	47.08	47.95
18	65	62.58	62.49	36	40	46.89	47.78

จากผลการพยากรณ์ที่ได้ทางผู้วิจัยได้ทำการแสดงผลของค่าการพยากรณ์เพื่อทำการเปรียบเทียบในรูปแบบของกราฟ เพื่อสามารถดูแนวโน้มของค่าการพยากรณ์ได้ชัดเจนยิ่งขึ้น โดย

เส้นสีน้ำเงิน แสดง ค่าจริงของยอดขายบ้าน

เส้นสีชมพู แสดง ค่าพยากรณ์ยอดขายบ้านจากวิธี Trend and Seasonal

เส้นสีเหลือง แสดง ค่าพยากรณ์ยอดขายบ้านจากแบบจำลอง Neural Network



รูปที่ 3.7 แสดง กราฟเปรียบเทียบผลของการพยากรณ์ในแต่ละวิธีเทียบกับค่าจริง

จากรูปที่ 3.7 นำค่าของการพยากรณ์ทั้ง 2 วิธีไปทำการคำนวณหาค่าดัชนี APE และค่า MAPE เพื่อทำการวัดประสิทธิภาพของการพยากรณ์ทั้ง 2 วิธี โดยเมื่อกำหนดค่า MAPE ที่ได้ออกมา ก็สามารถเปรียบเทียบประสิทธิภาพของการพยากรณ์ทั้ง 2 วิธีโดยค่า MAPE ที่ได้จากการพยากรณ์โดยวิธี Trend and Seasonal นั้นมีค่า 8.24% ส่วนค่า MAPE จากแบบจำลอง NN นั้นมีค่า

อยู่ที่ 4.62% ซึ่งสามารถบอกได้ว่าแบบจำลอง NN นั้นสามารถทำการพยากรณ์ได้ประสิทธิภาพดีกว่าวิธีการพยากรณ์แบบ Trend and Seasonal

จากที่ได้ทำการเปรียบเทียบกับวิธีการพยากรณ์ทั้ง 3 วิธีนั้นจะเห็นได้ว่าค่าประสิทธิภาพของการพยากรณ์โดยใช้แบบจำลอง NN นั้นมีประสิทธิภาพดีกว่าการพยากรณ์ทั้ง 2 วิธี ซึ่งแสดงให้เห็นว่ารูปแบบของข้อมูลไม่ว่ารูปแบบใด แบบจำลอง NN ก็สามารถนำมาประยุกต์ใช้เพื่อนำไปพยากรณ์หาค่าที่ต้องการได้ถูกต้อง



ลิขสิทธิ์มหาวิทยาลัยเชียงใหม่
Copyright© by Chiang Mai University
All rights reserved