

การศึกษาตัวแบบการพยากรณ์ยอดขายสินค้าโดยวิธี  
โครงข่ายประสาทเทียม

A SALES FORECASTING MODEL BASED ON ARTIFICIAL  
NEURAL NETWORK



สหกิจศึกษานี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาวิทยาศาสตรบัณฑิต (สถิติประยุกต์)  
ภาควิชาสถิติ คณะวิทยาศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
ปีการศึกษา 2561

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

A SALES FORECASTING MODEL BASED ON ARTIFICIAL  
NEURAL NETWORK


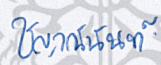

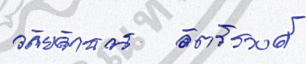


COOPERATIVE EDUCATION SUBMITTED IN PARTIAL FULFILLMENT  
OF THE REQUIREMENT FOR  
THE DEGREE OF BACHELOR OF SCIENCE (APPLIED STATISTICS)  
DEPARTMENT OF STATISTICS, FACULTY OF SCIENCE  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับ **ACADEMIC YEAR 2018** อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อสหกิจศึกษา	การศึกษาตัวแบบการพยากรณ์ยอดขายสินค้าโดยวิธี โครงข่ายประสาทเทียม A Sales Forecasting Model Based on Artificial Neural Network
ชื่อนักศึกษา	นายนราทร สากะสันต์ รหัสนักศึกษา 58051247
ปริญญา	วิทยาศาสตร์บัณฑิต (สถิติประยุกต์)
ภาควิชา	สถิติ
ปีการศึกษา	2561
อาจารย์ที่ปรึกษา	รศ.ดร.วลัยลักษณ์ อัครีรวงศ์

คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.) อนุมัติให้สหกิจศึกษานี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต (สถิติประยุกต์) ประจำปีการศึกษา 2561

คณะกรรมการสอบ	ลายมือชื่อ
ดร.พรพิมล ชัยวุฒิศักดิ์ ประธานกรรมการ	
คุณชญานันท์ นวพรอนันต์ กรรมการและพนักงานพี่เลี้ยง	
คุณวิศิษฐ์ กิจชัยนุกูล กรรมการและพนักงานพี่เลี้ยง	
รศ.ดร.วลัยลักษณ์ อัครีรวงศ์ กรรมการและอาจารย์ที่ปรึกษา	

ลิขสิทธิ์ของคณะวิทยาศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อสหกิจศึกษา	การศึกษาตัวแบบการพยากรณ์ยอดขายสินค้าโดยวิธี โครงข่ายประสาทเทียม
ชื่อนักศึกษา	นายนราทร สากระสันต์ รหัสนักศึกษา 58051247
ปริญญา	วิทยาศาสตร์บัณฑิต (สถิติประยุกต์)
ภาควิชา	สถิติ
คณะ	วิทยาศาสตร์
มหาวิทยาลัย	สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.)
ปีการศึกษา	2561
อาจารย์ที่ปรึกษา	รศ.ดร.วัลย์ลักษณ์ อัครีรวงศ์

### บทคัดย่อ

สหกิจศึกษาครั้งนี้มีวัตถุประสงค์เพื่อศึกษาวิธีพยากรณ์ยอดขายสินค้า A เพื่อช่วยลดระยะเวลาและทรัพยากรมนุษย์ของบริษัทกรณีศึกษา ปัจจุบันบริษัทกรณีศึกษาใช้วิธีการพยากรณ์สินค้า A โดยสามารถพยากรณ์สินค้า A ได้ในพื้นที่การขายเดียวและขนาดสินค้าเดียว ปัญหาคือบริษัทต้องสร้างตัวแบบการพยากรณ์ยอดขายสินค้า A หลายตัวแบบทำให้ใช้เวลาและใช้ทรัพยากรมนุษย์เป็นจำนวนมากซึ่งวิธีการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมสามารถพยากรณ์ยอดขายสินค้า A ในแต่ละพื้นที่การขายและในแต่ละขนาดสินค้าได้ภายในตัวแบบเดียว ผู้วิจัยจึงได้ทำการศึกษาการพยากรณ์ยอดขายสินค้า A โดยใช้วิธีโครงข่ายประสาทเทียม โดยตัวแปรอิสระทั้งหมดที่ใช้ในการวิเคราะห์คือ เดือนที่ขายสินค้า ปีที่ขายสินค้า พื้นที่การขายสินค้ามี 44 พื้นที่การขาย และขนาดสินค้ามี 2 ขนาด โดยผู้วิจัยจะทำการวัดประสิทธิภาพของการพยากรณ์ยอดขายสินค้า A ทั้ง 2 วิธี ด้วยค่าค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Deviation : MAD) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percent Error : MAPE)

ผลการวิจัยพบว่าโครงข่ายประสาทเทียมที่เหมาะสมสำหรับการพยากรณ์ยอดขายสินค้า A คือ 48-20-1 เมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.35 และค่าโมเมนตัมเท่ากับ 0.9 ซึ่งให้ค่า MAPE เท่ากับ 24.8% และ MAD เท่ากับ 35,630.36 ลิตร ซึ่งต่ำกว่าวิธีการพยากรณ์ของบริษัทซึ่งให้ค่า MAPE เท่ากับ 40.24% และ MAD เท่ากับ 57,519.79 ลิตร อย่างไรก็ตามการนำไปใช้ควรจะต้องระมัดระวังเนื่องจากตัวแบบที่ได้ยังไม่สามารถพยากรณ์ได้อย่างเหมาะสมเนื่องจากยังมีสาเหตุอื่น ๆ นอกจากเวลาที่มีอิทธิพลต่อยอดขาย

**คำสำคัญ :** โครงข่ายประสาทเทียม, การพยากรณ์, การศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

<b>Title</b>	A Sales Forecasting Model Based on Artificial Neural Network
<b>Students</b>	Mr. Narathon Sakrasan Student ID 58051247
<b>Degree</b>	Bachelor of Science (Applied Statistics)
<b>Department</b>	Statistics
<b>Faculty</b>	Science
<b>University</b>	King Mongkut's Institute of Technology Ladkrabang (KMITL)
<b>Academic Year</b>	2018
<b>Advisor</b>	Assoc. Prof. Dr. Walailak Atthirawong

### Abstract

The objective of this Co-operative Education study was to develop and test a sales forecasting model for product A that could replace several current models for each area and reduce time and effort in forecasting. Currently, a company that has been manufacturing product A is using several models to forecast the sales of this product. However, each of these models can only forecast the sales trend of product A in a single sales area and for a single product size. These multiple sales forecasting models take a long time and human resource. They asked us to develop a single sales forecasting model based on artificial neural network that can replace their current models. Therefore, we had developed such a model and tested it. The independent variables were month of sale, year of sale, 44 sales areas, and two product sizes. The efficiencies of the current sales forecasting models and our developed model were compared in terms of their Mean Absolute Deviation (MAD), and Mean Absolute Percent Error (MAPE).

The results reveal that the best artificial neural network that we had developed (48-20-1) achieved a learning rate and momentum of 0.35 and 0.9 and the evaluation metrics MAPE and MAD of 24.8% and 35,630.36 liter, respectively. These figures are less than (i.e., better than) the MAPE and MAD achieved by the company's current forecasting models at 40.24% and 57,519.79 liter, respectively. However, the developed model has to be used cautiously because it is still unable to forecast the sales of product A perfectly since its sales depends on several other factors or variables that have not been taken into account yet.

**Keywords :** Artificial Neural Network, Forecasting

## กิตติกรรมประกาศ

สหกิจศึกษานี้สำเร็จลุล่วงได้อย่างดีเนื่องจากได้รับการอนุเคราะห์จากอาจารย์ที่ปรึกษาสหกิจศึกษา รศ.ดร.วัลย์ลักษณ์ อัครีรวงศ์ ที่กรุณาให้คำแนะนำ ให้คำปรึกษา ตรวจสอบแก้ไขข้อบกพร่องต่าง ๆ เป็นอย่างดียิ่ง ข้าพเจ้ารู้สึกซาบซึ้งในความอนุเคราะห์จากท่านอาจารย์และขอขอบพระคุณเป็นอย่างสูง

ขอขอบพระคุณ ดร.พรพิมล ชัยวุฒิศักดิ์ ประธานการสอบสหกิจศึกษาที่ได้ให้คำแนะนำตลอดจนชี้แนะจนสหกิจศึกษานี้สำเร็จลุล่วงได้ด้วยดี

ขอขอบพระคุณ คุณชญานันท์ นวพรอนันต์ และ คุณวิศิษฐ์ กิจชัยนุกูล พนักงานพีเลียง ที่ให้การสนับสนุนในด้านการศึกษาและการทำสหกิจศึกษา รวมไปถึงบริษัทกรณีศึกษาที่อนุเคราะห์ข้อมูลในการทำสหกิจศึกษานี้

ขอขอบพระคุณคณาจารย์ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบังทุกท่านที่ได้ประสิทธิ์ประสาทวิชาความรู้พร้อมทั้งให้คำแนะนำและช่วยเหลือในเรื่องต่าง ๆ ตลอดมา

สุดท้ายนี้ขอขอบคุณครอบครัวที่ให้อำนาจใจและสนับสนุนในด้านการศึกษาหาวิชาความรู้ รวมถึงขอบคุณ เพื่อน ๆ ที่คอยให้อำนาจใจและห่วงใยเสมอมา

นราทร สากระสันต์

# สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	ก
บทคัดย่อภาษาอังกฤษ.....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญรูป.....	ซ
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตการศึกษา.....	2
1.4 ขั้นตอนการวิจัยและวิธีการดำเนินงาน.....	2
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.6 นิยามศัพท์เฉพาะ.....	3
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	4
2.1 กระบวนการมาตรฐานอุตสาหกรรมสำหรับการทำเหมืองข้อมูล.....	4
2.1.1 การทำความเข้าใจธุรกิจ.....	4
2.1.2 การทำความเข้าใจกับข้อมูล.....	5
2.1.3 การเตรียมข้อมูล.....	5
2.1.4 การสร้างตัวแบบ.....	5
2.1.5 การประเมินผล.....	5
2.1.6 การนำตัวแบบไปใช้.....	5
2.2 การเรียนรู้ของเครื่อง.....	6
2.2.1 การเรียนรู้แบบมีผู้สอน.....	6
2.2.2 การเรียนรู้แบบไม่มีผู้สอน.....	6

เอกสารนี้เป็นเอกสารที่ส.2.2.2 การเรียนรู้แบบไม่มีผู้สอน การศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

	หน้า
2.3 โครงข่ายประสาทเทียม .....	7
2.3.1 การแปลงข้อมูลให้อยู่ในรูปมาตรฐานเดียวกัน.....	8
2.3.2 ฟังก์ชันกระตุ้น.....	9
2.3.3 โครงข่ายประสาทเทียมแบบไปข้างหน้า.....	10
2.3.4 เทคนิคการแพร่แบบย้อนกลับ.....	12
2.3.5 วิธีลดองศา.....	12
2.3.6 อัตราการเรียนรู้.....	13
2.3.7 โมเมนตัม.....	14
2.2.8 ความซับซ้อนของตัวแบบมากเกินไป.....	16
2.2.9 การดรอปเอาต์ (Dropout).....	17
2.4 การวัดประสิทธิภาพของการพยากรณ์.....	18
2.4.1 ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์.....	18
2.4.2 ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย.....	18
2.5 งานวิจัยที่เกี่ยวข้อง.....	19
บทที่ 3 วิธีการดำเนินงานวิจัย .....	21
3.1 การทำความเข้าใจธุรกิจ.....	23
3.2 การทำความเข้าใจกับข้อมูล.....	23
3.2.1 การเก็บข้อมูลขั้นต้น.....	23
3.2.2 การอธิบายข้อมูล.....	23
3.3 การเตรียมข้อมูล.....	25
3.3.1 การคัดเลือกข้อมูล.....	25
3.3.2 การทำความสะอาดข้อมูล.....	25
3.3.3 การแปลงข้อมูลเชิงปริมาณ.....	28
3.3.4 การแปลงข้อมูลเชิงปริมาณ.....	29
3.4 การสร้างตัวแบบ.....	30
3.4.1 การพยากรณ์ยอดขายสินค้า A โดยวิธีโครงข่ายประสาทเทียม.....	30

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์โดยมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

	หน้า
3.5 การประเมินผล.....	31
3.6 การนำตัวแบบไปใช้งาน.....	31
บทที่ 4 ผลการวิเคราะห์ข้อมูล .....	32
4.1 ผลการวิเคราะห์สำหรับการพยากรณ์ยอดขายสินค้า A โดยใช้วิธีโครงข่ายประสาทเทียม.....	32
4.2 การเปรียบเทียบประสิทธิภาพของตัวแบบ.....	42
บทที่ 5 สรุปผลการวิจัย อภิปรายผลและข้อเสนอแนะ .....	43
5.1 สรุปผลการวิจัย .....	43
5.1.1 ผลการศึกษาวิธีการพยากรณ์ยอดขายสินค้า A โดยใช้โครงข่ายประสาทเทียม.....	43
5.1.2 การเปรียบเทียบประสิทธิภาพของตัวแบบการพยากรณ์ยอดขายสินค้า A.....	43
5.2 ข้อจำกัด.....	44
5.3 อภิปรายผล .....	44
5.4 ข้อเสนอแนะ.....	44
บรรณานุกรม.....	45
ภาคผนวก .....	46

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น. อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญตาราง

ตารางที่	หน้า
3.1 ตัวแปรที่ใช้ในการวิเคราะห์ .....	25
3.2 ข้อมูลยอดขายสินค้า A ก่อนการทำความสะอาดข้อมูล.....	26
3.3 ข้อมูลยอดขายสินค้า A หลังการทำความสะอาดข้อมูล .....	27
3.4 โค้งข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.1 และดรอปเอาทในชั้นซ่อน เท่ากับ 0.1.....	33
3.4 โค้งข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.15 และดรอปเอาทในชั้นซ่อน เท่ากับ 0.1.....	34
3.4 โค้งข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.2 และดรอปเอาทในชั้นซ่อน เท่ากับ 0.1.....	35
3.4 โค้งข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.25 และดรอปเอาทในชั้นซ่อน เท่ากับ 0.1.....	36
3.4 โค้งข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.3 และดรอปเอาทในชั้นซ่อน เท่ากับ 0.1.....	37
3.4 โค้งข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.35 และดรอปเอาทในชั้นซ่อน เท่ากับ 0.1.....	38
4.7 เปรียบเทียบประสิทธิภาพของการพยากรณ์ .....	42

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญรูป

รูปที่	หน้า
2.1 การเขียนโปรแกรมแบบดั้งเดิมกับการเรียนรู้ของเครื่อง .....	6
2.2 ตัวแบบเซลล์ประสาทของมนุษย์.....	7
2.3 โครงข่ายประสาทเทียมอย่างง่าย .....	8
2.4 Sigmoid Function.....	9
2.5 Tanh Function.....	9
2.6 ReLU Function .....	9
2.7 โครงข่ายประสาทเทียมแบบไปข้างหน้า.....	10
2.8 ความสัมพันธ์ระหว่าง SSE กับค่าถ่วงน้ำหนัก.....	12
2.9 ความสัมพันธ์ระหว่าง SSE และอัตราการเรียนรู้ .....	14
2.10 โมเมนต์มีค่าน้อยอาจจะทำให้อัลกอริทึมไปไม่ถึงค่าต่ำสุด.....	15
2.11 โมเมนต์มีค่ามากอาจจะทำให้อัลกอริทึมผ่านเลยค่าต่ำสุด.....	15
2.12 ความซับซ้อนของตัวแบบมากเกินไปจนเกินไป.....	16
2.13 การดรอปเอาต์ในชั้นซ่อน.....	17
3.1 ขั้นตอนการดำเนินงานด้วยกระบวนการ CRISP-DM.....	22
3.2 ยอดขายสินค้า A ในพื้นที่การขาย 25 สินค้าขนาดเล็ก ตั้งแต่เดือนมกราคม พ.ศ. 2559 ถึง กุมภาพันธ์ พ.ศ. 2562.....	24
3.3 ยอดขายสินค้า A ในพื้นที่การขาย 60 สินค้าขนาดใหญ่ ตั้งแต่เดือนมกราคม พ.ศ. 2559 ถึง กุมภาพันธ์ พ.ศ. 2562.....	24
3.4 การแปลงข้อมูลเชิงคุณภาพ .....	28
3.5 การแปลงข้อมูลเชิงปริมาณ.....	29
4.1 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย 25	

## สารบัญรูป (ต่อ)

รูปที่	หน้า
4.2 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย 25 สินค้าขนาดเล็ก .....	40
4.3 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย 44 สินค้าขนาดใหญ่ .....	40
4.4 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย 44 สินค้าขนาดเล็ก .....	41
4.5 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย 60 สินค้าขนาดใหญ่ .....	41
4.6 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย 60 สินค้าขนาดเล็ก .....	42

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาและความสำคัญของปัญหา

ในการที่จะทำให้ธุรกิจบรรลุเป้าหมาย และประสบความสำเร็จนั้น มีความจำเป็นอย่างยิ่งในการวางแผนกลยุทธ์เพื่อกำหนดทิศทางการดำเนินงานของบริษัท ซึ่งหนึ่งในการวางแผนกลยุทธ์คือการพยากรณ์ความต้องการสินค้าในตลาด ในการบริหารการผลิตมีความจำเป็นอย่างมากที่ต้องใช้ข้อมูลในการวางแผนและตัดสินใจดำเนินงานตามหน้าที่ต่าง ๆ ทั้งระยะสั้นและระยะยาว ซึ่งหนึ่งในข้อมูลที่มีความสำคัญคือ ความต้องการซื้อสินค้าของลูกค้า เพราะเป็นตัวกำหนดการบริหารการผลิตหลายประการ ทำให้สามารถจัดสรรทรัพยากรซึ่งมีอยู่อย่างจำกัดของบริษัทให้เหมาะสมกับปริมาณสินค้าที่ลูกค้าต้องการ การรู้ความต้องการซื้อสินค้าของลูกค้าในอนาคตจะมีผลในการวางแผนการบริหารการผลิตในระยะสั้นและในระยะยาวได้ถูกต้องใกล้เคียงกับความต้องการซื้อสินค้าของลูกค้ามากที่สุด

จะเห็นได้ว่าการพยากรณ์มีความสำคัญอย่างมากต่อบริษัท ปัจจุบันบริษัทกรณีศึกษาใช้วิธีการพยากรณ์สินค้า A โดยสามารถพยากรณ์สินค้า A ได้ในพื้นที่การขายเดียวและขนาดสินค้าเดียว ปัญหาคือบริษัทต้องสร้างตัวแบบการพยากรณ์ยอดขายสินค้า A หลายตัวแบบเพื่อที่จะพยากรณ์ยอดขายสินค้า A ในแต่ละพื้นที่การขายและในแต่ละขนาดสินค้าได้ ทำให้ใช้เวลาและใช้ทรัพยากรมนุษย์เป็นจำนวนมาก ดังนั้นในสหกิจศึกษาครั้งนี้ผู้วิจัยจึงศึกษาวิธีการพยากรณ์ที่ช่วยลดระยะเวลาและทรัพยากรมนุษย์ซึ่งวิธีการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมสามารถพยากรณ์ยอดขายสินค้า A ในแต่ละพื้นที่การขายและในแต่ละขนาดสินค้าได้ภายในตัวแบบเดียว ผู้วิจัยจึงทำการศึกษากการพยากรณ์ยอดขายสินค้า A โดยใช้วิธีโครงข่ายประสาทเทียม

โดยผู้วิจัยจะทำการวัดประสิทธิภาพของการพยากรณ์ยอดขายสินค้า A โดยวิธีโครงข่ายประสาทเทียมกับวิธีการพยากรณ์ของบริษัท ว่าวิธีใดจะมีประสิทธิภาพในการพยากรณ์ในการให้ค่าความคลาดเคลื่อนในการพยากรณ์ต่ำสุด การเปรียบเทียบประสิทธิภาพการพยากรณ์จะตรวจสอบโดยค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Deviation : MAD) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percent Error : MAPE)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อสร้างตัวแบบการพยากรณ์ยอดขายสินค้า A โดยวิธีโครงข่ายประสาทเทียมด้วยภาษา Python
2. เปรียบเทียบประสิทธิภาพของการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมกับวิธีการพยากรณ์ของบริษัทโดยใช้ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (MAD) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE)

## 1.3 ขอบเขตการศึกษา

ในการศึกษาครั้งนี้ใช้ข้อมูลทุติยภูมิจากการเก็บข้อมูลยอดขายสินค้า A โดยใช้ข้อมูลรายเดือน ตั้งแต่ มกราคม พ.ศ. 2559 ถึงเดือน กุมภาพันธ์ พ.ศ. 2562 รวม 38 เดือน

## 1.4 ขั้นตอนการวิจัยและวิธีการดำเนินงาน

1. การทำความเข้าใจเกี่ยวกับธุรกิจ (Business Understanding)
2. การทำความเข้าใจเกี่ยวกับข้อมูล (Data Understanding)
3. การเตรียมข้อมูล (Data Preparation)
4. การสร้างตัวแบบการพยากรณ์ (Modeling)
5. การประเมินผล (Evaluation)
6. การนำไปใช้งาน (Deployment)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. ได้ตัวแบบที่เหมาะสมสำหรับพยากรณ์ยอดขายสินค้า A
2. นำค่าพยากรณ์ที่ได้มาใช้เป็นส่วนหนึ่งในการวางแผนการตลาดและการตัดสินใจเกี่ยวกับการจัดโปรโมชั่นของบริษัทกรณีศึกษาในอนาคตได้
3. เพื่อให้บริษัทกรณีศึกษาสามารถวางแผนการผลิตสินค้าได้ตามปริมาณที่ผู้บริโภคต้องการ
4. แทนที่วิธีการพยากรณ์ยอดขายสินค้า A ของบริษัทด้วยวิธีการพยากรณ์ยอดขายสินค้า A ด้วยโครงข่ายประสาทเทียม

## 1.6 นิยามศัพท์เฉพาะ

1. การเรียนรู้ของเครื่อง (Machine Learning) เป็นศาสตร์แขนงหนึ่งที่ทำให้คอมพิวเตอร์มีความสามารถในการเรียนรู้ด้วยตนเอง เมื่อมีข้อมูลเข้าสามารถทำนายหรือตัดสินใจได้โดยปราศจากการทำงานตามลำดับคำสั่งโปรแกรม
2. ข้อมูล (Data) คือ ข่าวสาร เอกสาร ข้อเท็จจริงเกี่ยวกับบุคคล สิ่งของหรือเหตุการณ์ที่มีอยู่ในรูปของตัวเลข ภาษา ภาพ สัญลักษณ์ต่าง ๆ ที่มีความหมายเฉพาะตัว ซึ่งยังไม่มีประมวลผลไม่เกี่ยวกับการนำไปใช้ได้อย่างมีประสิทธิภาพ (ไพโรจน์ คชชา, 2542)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 2

# ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้ผู้วิจัยจะกล่าวถึงทฤษฎีและงานวิจัยที่เกี่ยวข้องโดยมีรายละเอียดของเนื้อหาประกอบด้วย 5 ส่วนดังนี้

1. กระบวนการมาตรฐานอุตสาหกรรมสำหรับการทำเหมืองข้อมูล (Cross-Industry Standard Process for Data Mining : CRISP-DM)
2. การเรียนรู้ของเครื่อง (Machine Learning)
3. โครงข่ายประสาทเทียม (Artificial Neural Network : ANN)
4. การวัดประสิทธิภาพของการพยากรณ์
5. งานวิจัยที่เกี่ยวข้อง

### 2.1 กระบวนการมาตรฐานอุตสาหกรรมสำหรับการทำเหมืองข้อมูล (Cross-Industry Standard Process for Data Mining : CRISP-DM)

เป็นกระบวนการมาตรฐานอุตสาหกรรมสำหรับการทำเหมืองข้อมูล พัฒนาโดยบริษัท DaimlerChrysler บริษัท SPSS และบริษัท NCR โดยเป็นขั้นตอนในการทำเหมืองข้อมูลที่นำเชื่อถือและเข้าใจได้ง่าย อีกทั้งยังเหมาะสมไว้ในกลยุทธ์การแก้ไขปัญหาทั่วไปของธุรกิจหรือการวิจัย โดยมีขั้นตอนและกระบวนการดังต่อไปนี้

#### 2.1.1 การทำความเข้าใจธุรกิจ (Business Understanding)

เป็นขั้นตอนทำความเข้าใจปัญหาวัตถุประสงค์ของธุรกิจ ต้องการคำตอบของปัญหาในทิศทางหรือลักษณะใด หากไม่เข้าใจปัญหาจะทำให้ขั้นตอนต่อไปดำเนินไปในทิศทางที่ไม่ถูกต้องซึ่งนอกจากจะไม่ได้คำตอบที่ต้องการแล้วยังสูญเสียเวลาและทรัพยากรไปโดยไร้ประโยชน์ด้วย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 2.1.2 การทำความเข้าใจกับข้อมูล (Data Understanding)

เป็นขั้นตอนการเก็บรวบรวมข้อมูลจากแหล่งข้อมูลที่ถูกต้องเหมาะสมเชื่อถือได้ รวมถึงการทำความเข้าใจและศึกษาลักษณะของข้อมูลต่าง ๆ และเป็นการตรวจสอบข้อมูลว่ามีความสมบูรณ์ถูกต้อง ครบคลุม และเพียงพอต่อความต้องการหรือไม่

### 2.1.3 การเตรียมข้อมูล (Data Preparation)

เป็นขั้นตอนการเตรียมข้อมูลให้พร้อมก่อนที่จะนำไปใช้วิเคราะห์ เพื่อให้ข้อมูลมีความสมบูรณ์และอยู่ในรูปแบบที่พร้อมนำไปใช้ในการวิเคราะห์ซึ่งจะต้องผ่านการกระบวนกรดังต่อไปนี้ การคัดเลือกข้อมูล (Data Selection) การทำความสะอาดข้อมูล (Data Cleansing) และ การแปลงข้อมูล (Data Transformation) เป็นต้น

### 2.1.4 การสร้างตัวแบบ (Modeling)

เป็นขั้นตอนการสร้างตัวแบบโดยการนำเทคนิคเหมืองข้อมูลมาใช้ในการวิเคราะห์ข้อมูลเพื่อให้ได้ผลลัพธ์ที่ดีที่สุด เช่น การหากฎความสัมพันธ์ (Association Rule) การจัดกลุ่ม (Clustering) และการจำแนกประเภทของข้อมูล (Classification) เป็นต้น

### 2.1.5 การประเมินผล (Evaluation)

เป็นขั้นตอนการประเมินประสิทธิภาพของตัวแบบว่าตัวแบบมีความถูกต้องแม่นยำมากน้อยเพียงใด และสามารถตอบปัญหาทางธุรกิจได้หรือไม่โดยอาจทดลองในระบบเสมือน (Simulation) หรือนำไปประมวลผลกับข้อมูลจริงที่มีอยู่เพื่อเปรียบเทียบผล

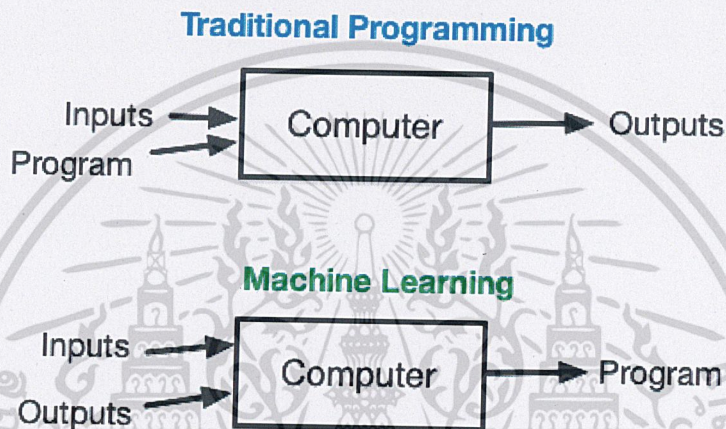
### 2.1.6 การนำตัวแบบไปใช้ (Deployment)

เป็นการนำตัวแบบไปใช้งานจริง โดยอาจต้องมีการปรับแต่งเพื่อความเหมาะสมในสภาวะจริง อย่างไรก็ตามควรมีการปรับปรุงตัวแบบเป็นระยะ ๆ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.2 การเรียนรู้ของเครื่อง (Machine Learning)

เป็นศาสตร์แขนงหนึ่งที่ทำให้คอมพิวเตอร์มีความสามารถในการเรียนรู้ด้วยตนเอง เมื่อมีข้อมูลเข้าสามารถทำนายหรือตัดสินใจได้โดยปราศจากการทำงานตามลำดับคำสั่งโปรแกรม ถ้าหากเป็นการเขียนโปรแกรมแบบเดิม ปกติแล้วจะต้องเขียน Program ในการหา Output เองดังรูปที่ 2.1 ตัวอย่าง  $y = x - 3$  ซึ่งต้องคิดสมการ  $x - 3$  แต่ถ้าเป็น Machine Learning แค่มีค่า  $x$  และ  $y$  แล้วนำไปใส่ใน Machine Learning มันจะทำการคำนวณแล้วคืนค่ากลับมาเป็น สมการให้แทนนั่นคือ “ $x - 3$ ”



รูปที่ 2.1 การเขียนโปรแกรมแบบดั้งเดิมกับการเรียนรู้ของเครื่อง

ที่มา: <https://medium.com/@dumpdatasci.th>

### 2.2.1 การเรียนรู้แบบมีผู้สอน (Supervised Learning)

ในข้อมูลที่ใช้ฝึก (Training Data) จะมีมนุษย์มาแยกประเภทหรือบอกผลเฉลย (Label) จากนั้นจะนำข้อมูลที่ใช้ฝึกที่มีผลเฉลย (Label) ไปผ่านอัลกอริทึมสำหรับสร้างโมเดลที่ไว้ทำนายผลลัพธ์

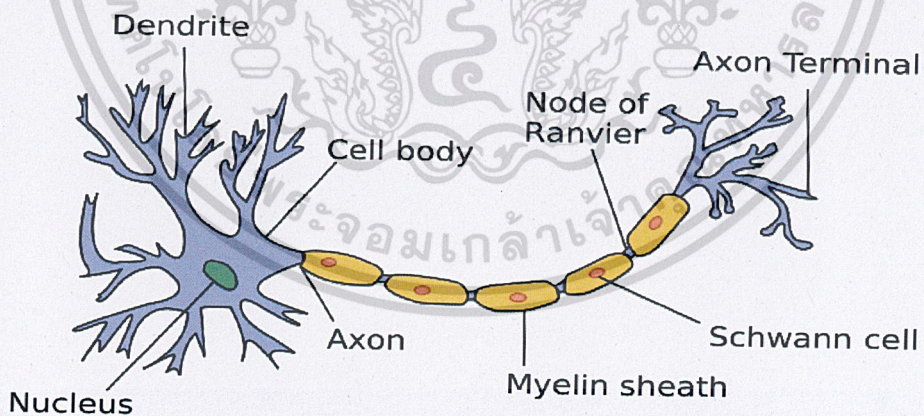
### 2.2.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

การเรียนรู้แบบ Unsupervised Learning นี้จะตรงกันข้ามกับ Supervised Learning ก็คือ Machine Learning สามารถเรียนรู้ได้โดยไม่มีการสอน (ไม่มีผลเฉลย) มีเพียงชุดข้อมูลที่ประกอบไปด้วยคุณลักษณะเท่านั้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.3 โครงข่ายประสาทเทียม (Artificial Neural Network: ANN)

Artificial Neural Network คือโครงข่ายประสาทเทียมที่เป็นการจำลองมาจากสมองของมนุษย์ โดยสมองของมนุษย์นั้นจะมีหน่วยประมวลผลขนาดเล็กอยู่เยอะเยวมมาก และเชื่อมโยงกันด้วยโครงข่ายประสาทมากมาย ช่วยให้ได้เรียนรู้และคิดวิเคราะห์ได้อย่างรวดเร็ว ซึ่งโครงข่ายประสาทเทียมจะทำการจำลองเครือข่ายประสาทในสมองมนุษย์เพื่อให้มีความสามารถในการเรียนรู้ การจดจำรูปแบบ (Pattern Recognition) เช่นเดียวกับความสามารถที่มีในสมองมนุษย์ ซึ่งประกอบด้วย เซลล์ประสาท หรือนิวรอน (Neurons) และ จุดประสานประสาท (Synapses) แต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาทซึ่งเป็นข้อมูลเข้า และปลายในการส่งกระแสประสาทซึ่งเป็นเหมือนผลลัพธ์ของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่าน (Dendrite) เข้าสู่นิวเคลียสซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอนิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทางแอกซอนดังรูปที่ 2.2 โครงสร้างของเครือข่ายประสาทเทียมประกอบด้วย นิวรอนซึ่งเชื่อมต่อกันเป็นชั้น ๆ ชั้นแรกเป็นข้อมูลเข้า (Input) และชั้นสุดท้ายจะเป็นชั้นผลลัพธ์ในระหว่างชั้นแรกกับชั้นสุดท้ายจะมีชั้นที่ซ่อนอยู่ระหว่างทั้ง 2 ชั้นนั้นอีกที่ก็ชั้นก็ได้หรือจะไม่มีเลยก็ได้ (ชญานิน บุญมานะ, 2558)

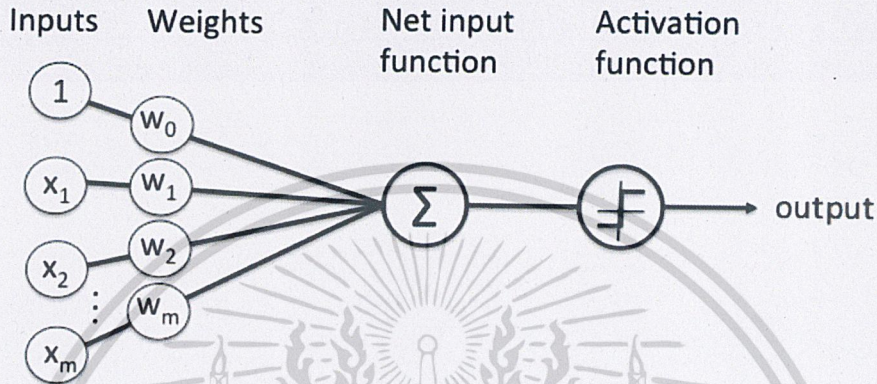


รูปที่ 2.2 ตัวแบบเซลล์ประสาทของมนุษย์

ที่มา: [https://vi.m.wikipedia.org/wiki/T%E1%BA%ADp\\_tin:Neuron.svg](https://vi.m.wikipedia.org/wiki/T%E1%BA%ADp_tin:Neuron.svg)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลักการทํางานของโครงข่ายประสาทเทียม เริ่มจากนำ Input (x) รวมกันโดยผ่านฟังก์ชันการรวม (Combination Function) กล่าวคือนำ Input (x) มาคูณกับค่าถ่วงน้ำหนัก (w) ของแต่ละเส้นทางของข้อมูลเข้า แล้วจึงนำข้อมูลเข้าไปในฟังก์ชันกระตุ้น (Activation Function) จะได้เป็นผลลัพธ์ (Output) ออกมาดังรูปที่ 2.3



รูปที่ 2.3 โครงข่ายประสาทเทียมอย่างง่าย

ที่มา: <https://skymind.ai/wiki/neural-network>

### 2.3.1 การแปลงข้อมูลให้อยู่ในรูปมาตรฐานเดียวกัน


ค่าคุณลักษณะทั้งหมดทั้งตัวแปรเชิงปริมาณและตัวแปรเชิงคุณภาพต้องแปลงข้อมูลให้เป็นมาตรฐานเดียวกัน โดยทำให้มีค่าอยู่ระหว่าง 0 และ 1 สำหรับตัวแปรเชิงคุณภาพจะต้องสร้างตัวแปรหุ่น (Dummy Variable) และสำหรับตัวแปรเชิงปริมาณจะแปลงข้อมูลให้อยู่ในรูปปรกติมาตรฐานน้อยที่สุด-มากที่สุด (Min-Max Normalization) ดังสมการ (2.1)

$$X^* = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (2.1)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


### 2.3.2 ฟังก์ชันกระตุ้น (Activation Function)

ฟังก์ชันกระตุ้น (Activation function) หรือ ฟังก์ชันการแปลง (Transfer function) ทำหน้าที่ปรับค่าของข้อมูลที่ได้จากฟังก์ชันการรวม (Combination Function) ให้อยู่ในช่วงที่ต้องการ การเลือก Activation Function ไม่ได้มีกฎตายตัวแต่ตัวเลือกที่นิยมใช้คือ Sigmoid Function รูปที่ 2.4 Tanh Function รูปที่ 2.5 และ ReLU Function รูปที่ 2.6 (พรรรณิภา คุ่มสิน, 2560)




รูปที่ 2.4 Sigmoid Function

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



รูปที่ 2.5 Tanh Function

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$$



รูปที่ 2.6 ReLU Function

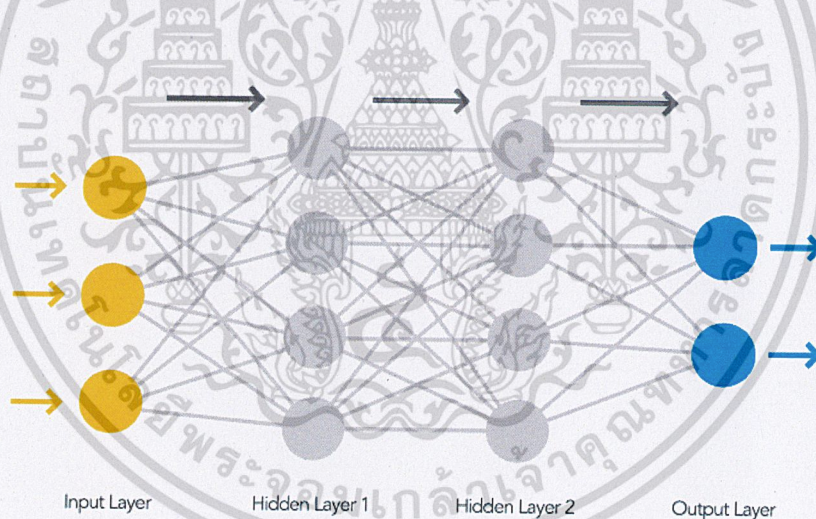
$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$$

ที่มา: <http://codeonthehill.com/machine-learning-2-neural-network>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 2.3.3 โครงข่ายประสาทเทียมแบบไปข้างหน้า (Feed Forward)

โครงข่ายประสาทเทียมแบบไปข้างหน้า เป็นโครงข่ายประสาทเทียมที่มีการจำกัดทิศทาง การเคลื่อนที่โดยข้อมูลที่เข้ามาจะไหลไปในทิศทางเดียว กล่าวคือโครงข่ายประสาทเทียมประเภทนี้จะประกอบด้วยชั้นต่าง ๆ โดยชั้นแรกจะเป็นชั้นข้อมูลนำเข้า (Input Layer) ชั้นถัดไปเป็นชั้นซ่อน (Hidden Layer) ซึ่งในโครงข่ายจะมีหรือไม่มีชั้นซ่อนก็ได้และชั้นสุดท้ายเป็นชั้นผลลัพธ์ (Output Layer) การเชื่อมต่อระหว่างชั้นของโครงข่ายประสาทเทียมแบบไปข้างหน้า จะมีค่าถ่วงน้ำหนัก (Weight) เป็นตัวเชื่อมและข้อมูลที่เข้ามาในโครงข่ายจะถูกส่งไปตามทิศทางของลูกศรที่มีการจำกัดทิศทาง การเคลื่อนที่เป็นแบบทางเดียวหรือเคลื่อนที่ไปข้างหน้าโดยโครงข่ายมีการเชื่อมต่อกันอย่างสมบูรณ์ (Complete Connected Network ) โหนดทุกโหนดในชั้นข้อมูลนำเข้าเชื่อมต่อกับทุกโหนดในชั้นถัดไปจนถึงชั้นผลลัพธ์โดยไม่มีการย้อนกลับดังรูปที่ 2.7 โดยทั่วไปจำนวนโหนดในชั้นข้อมูลนำเข้าขึ้นอยู่กับจำนวนและประเภทของข้อมูล จำนวนของชั้นซ่อนและจำนวนของโหนดในแต่ละชั้นซ่อนขึ้นอยู่กับผู้ใช้เป็นผู้กำหนดซึ่งขึ้นอยู่กับความซับซ้อนของปัญหา และในชั้นผลลัพธ์จะกำหนดจำนวนโหนดตามผลลัพธ์ที่ต้องการจากโครงข่าย



รูปที่ 2.7 โครงข่ายประสาทเทียมแบบไปข้างหน้า (Feed Forward)

ที่มา: <https://coladev.com/machine-learning/neural..network/2017/02/22/neural-network-basic>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตัวอย่างการคำนวณโครงข่ายประสาทเทียมแบบไปข้างหน้า (Feed Forward) ซึ่งประกอบด้วยชั้นข้อมูลนำเข้า 1 ชั้นภายใต้จำนวนโหนด 3 โหนด ชั้นซ่อน 1 ชั้นภายใต้จำนวนโหนด 1 โหนดโดยใช้ Sigmoid Logistics Function เป็นฟังก์ชันกระตุ้น (Activation function) และชั้นผลลัพธ์ 1 ชั้น โดยใช้ Sigmoid Logistics Function เป็นฟังก์ชันกระตุ้น (Activation function) โดยมีขั้นตอนดังต่อไปนี้

**ขั้นตอนที่ 1** คำนวณค่าผลรวมของโหนดในชั้นซ่อน (Hidden Layer) โดยใช้ฟังก์ชันการรวมกัน (Combination Function :  $\sum$ ) ซึ่งเป็นการนำค่าของโหนดข้อมูลนำเข้าที่เชื่อมโยงมาคูณกับค่าถ่วงน้ำหนักในแต่ละเส้นเชื่อมโยง แล้วจึงนำมารวมกันเป็นค่าสุดท้าย ดังนั้นค่าผลรวมของโหนดที่ A ในชั้นซ่อนเป็นดังสมการ (2.2)

$$\text{net}_A = \sum_i W_{iA} x_{iA} \quad \text{สำหรับ } i = 1, 2, 3 \quad (2.2)$$

โดยที่  $x_i$  แทน ข้อมูลนำเข้าที่  $i$

และ  $w_{iA}$  แทน ค่าถ่วงน้ำหนักที่สัมพันธ์กับข้อมูลนำเข้าที่  $i$  ไปยังโหนดที่ A ในชั้นซ่อน

**ขั้นตอนที่ 2** ทำการปรับค่าผลรวมของข้อมูลในชั้นซ่อน (Hidden Layer) ด้วยฟังก์ชันกระตุ้น (Activation function) เพื่อให้ได้ผลลัพธ์ ( $y_A$ ) ของชั้นซ่อน (Hidden Layer) โดยใช้ Sigmoid Logistic Function ดังสมการ (2.3)

$$y_A = f(\text{net}_A) = \frac{1}{1 + e^{-\text{net}_A}} \quad (2.3)$$

**ขั้นตอนที่ 3** คำนวณค่าผลรวมของโหนดในชั้นผลลัพธ์ (Output Layer) โดยใช้ฟังก์ชันการรวมกัน (Combination Function :  $\sum$ ) ดังสมการ (2.4)

$$\text{net}_z = \sum_i W_{iz} x_{iz} \quad \text{สำหรับ } i = 1 \quad (2.4)$$

**ขั้นตอนที่ 4** ทำการปรับค่าผลรวมของข้อมูลในชั้นผลลัพธ์ (Output Layer) ด้วยฟังก์ชันกระตุ้น (Activation Function) เพื่อให้ได้ผลลัพธ์ ( $y_z$ ) ของชั้นผลลัพธ์ (Output Layer) โดยใช้ Sigmoid Logistic Function ดังสมการ (2.5)

$$y_z = f(\text{net}_z) = \frac{1}{1 + e^{-\text{net}_z}} \quad (2.5)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

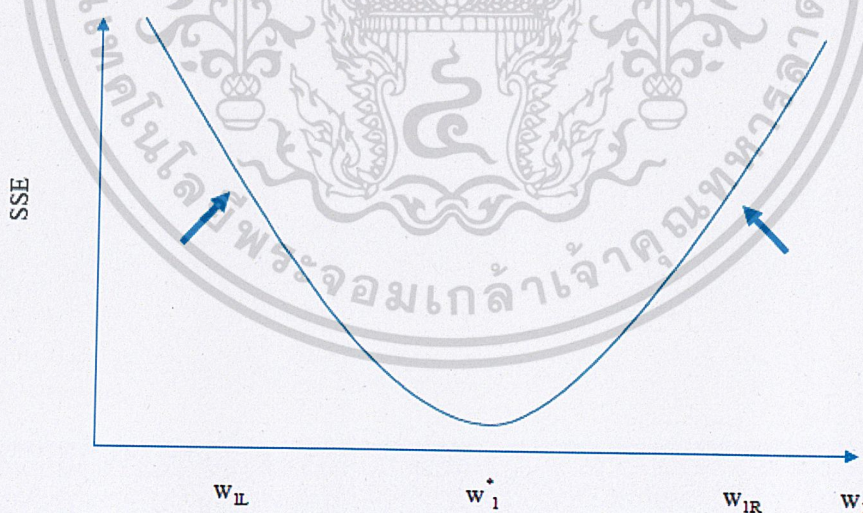
### 2.3.4 เทคนิคการแพร่แบบย้อนกลับ (Back-propagation)

การแพร่แบบย้อนกลับนั้นมีที่มาจาก วิธีการปรับค่าถ่วงน้ำหนักเพื่อให้ได้ค่าที่เหมาะสมจะใช้วิธีนำค่าผลลัพธ์ที่ได้จากตัวแบบประสาทเทียมเปรียบเทียบกับค่าจริงและคำนวณความคลาดเคลื่อน ตัวแบบประสาทเทียมส่วนใหญ่ใช้ผลบวกกำลังสองของค่าคลาดเคลื่อน (Sum of Squares Error : SSE) มาเป็นตัวชี้้นำในการปรับค่าถ่วงน้ำหนัก โดยการสร้างชุดของค่าถ่วงน้ำหนักที่ทำให้ SSE มีค่าน้อยที่สุด

### 2.3.5 วิธีลดองศา (Gradient Descent Method)

วิธีลดองศาจะให้ทิศทางที่ควรปรับค่าถ่วงน้ำหนักที่ทำให้ SSE มีค่าต่ำที่สุด กำหนดเวกเตอร์ของค่าถ่วงน้ำหนักจำนวน  $m$  ค่า คือ  $\underline{w} = w_0, w_1, w_2, \dots, w_m$  ในตัวแบบโครงข่ายประสาทเทียม และต้องการหาค่าถ่วงน้ำหนักแต่ละค่าที่ทำให้ SSE มีค่าต่ำที่สุด สามารถใช้วิธีลดองศา ซึ่งจะให้ทิศทางที่ควรปรับค่าถ่วงน้ำหนักเพื่อลด SSE อนุพันธ์ของ SSE เมื่อเทียบกับเวกเตอร์ของค่าถ่วงน้ำหนัก  $w$  คือการหาอนุพันธ์ของ SSE เมื่อเทียบกับค่าถ่วงน้ำหนักแต่ละค่าดังสมการ (2.6) และรูปที่ 2.8 (สายชล สินสมบูรณ์ทอง, 2560)

$$\nabla SSE(\underline{w}) = \left[ \frac{\partial SSE}{\partial w_0}, \frac{\partial SSE}{\partial w_1}, \dots, \frac{\partial SSE}{\partial w_m} \right] \quad (2.6)$$



รูปที่ 2.8 ความสัมพันธ์ระหว่าง SSE กับค่าถ่วงน้ำหนัก  $w_1$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 2.8 สมมติว่าถ้าค่าถ่วงน้ำหนักปัจจุบัน  $w_{\text{current}}$  อยู่ใกล้เคียงกับ  $w_{\text{IL}}$  ดังนั้นจึงต้องทำการปรับเพิ่มค่าถ่วงน้ำหนักปัจจุบันเพื่อให้ใกล้เคียงกับค่าที่เหมาะสมที่สุด  $w_1^*$  ในทำนองตรงกันข้าม ถ้าค่าถ่วงน้ำหนักปัจจุบัน  $w_{\text{current}}$  อยู่ใกล้เคียงกับ  $w_{\text{IR}}$  ดังนั้นจึงต้องลดค่าถ่วงน้ำหนักปัจจุบันเพื่อให้ใกล้เคียงกับค่าที่เหมาะสมที่สุด  $w_1^*$  ดังสมการ (2.7)

$$W_{\text{new}} = W_{\text{current}} + \Delta W_{\text{current}} \quad (2.7)$$

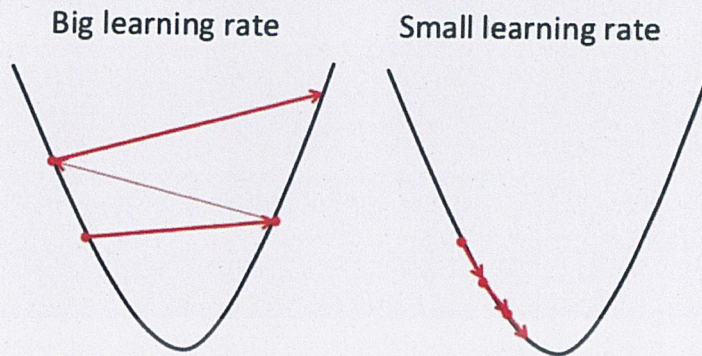
อนุพันธ์  $\left(\frac{\partial \text{SSE}}{\partial w_1}\right)$  คือความชันของเส้นโค้ง SSE ที่  $w_1$  สำหรับค่าที่ใกล้เคียงกับ  $w_{\text{IL}}$  ความชันของเส้นโค้งนี้จะเป็นลบ และสำหรับค่าของ  $w_1$  ที่ใกล้กับ  $w_{\text{IR}}$  ความชันของเส้นโค้งนี้จะเป็นบวก ดังนั้นทิศทางสำหรับการปรับ  $w_{\text{current}}$  จึงเป็นทิศทางตรงกันข้ามกับอนุพันธ์ของ SSE เมื่อเทียบกับค่าถ่วงน้ำหนัก  $w_1$  นั่นคือ  $-\left(\frac{\partial \text{SSE}}{\partial w_{\text{current}}}\right)$

จากนั้นทำการคูณค่าอนุพันธ์กับค่าคงที่ซึ่งช่วยในการเคลื่อนที่ของค่าถ่วงน้ำหนักในโครงข่ายประสาทเทียมไปยังจุดที่มีค่า SSE น้อยที่สุด เรียกค่าคงที่นั้นว่า อัตราการเรียนรู้ (Learning Rate) แทนด้วยสัญลักษณ์  $\eta$  มีค่าอยู่ระหว่าง 0 และ 1 สามารถเขียนรูปแบบของ  $\Delta w_{\text{current}}$  ได้ดังสมการ (2.8)

$$\Delta W_{\text{current}} = -\eta \left( \frac{\partial \text{SSE}}{\partial w_{\text{current}}} \right) \quad (2.8)$$

### 2.3.6 อัตราการเรียนรู้ (Learning Rate)

อัตราการเรียนรู้ (Learning Rate) แทนด้วยสัญลักษณ์  $\eta$  มีค่าอยู่ระหว่าง 0 และ 1 คือค่าคงที่ที่เลือกเพื่อช่วยให้การเคลื่อนย้ายค่าถ่วงน้ำหนักของโครงข่ายประสาทเทียมไปยังค่าต่ำสุด (Global) การกำหนดค่า  $\eta$  ไม่มีหลักเกณฑ์ที่ตายตัวถ้าค่า  $\eta$  มีค่าน้อยการปรับค่าถ่วงน้ำหนักจะมีค่าน้อยด้วยดังนั้นถ้า  $\eta$  มีค่าน้อย โครงข่ายประสาทเทียมจะใช้ระยะเวลาานเพื่อเข้าสู่ค่าเป้าหมายในทางตรงกันข้าม  $\eta$  มีค่ามากเกินไป การปรับค่าถ่วงน้ำหนักก็จะมากอาจจะเลยจุดที่ดีที่สุดดังรูปที่ 2.9 เพราะฉะนั้น  $\eta$  จึงเป็นสิ่งสำคัญมากใน Gradient Descent ถ้ากำหนด  $\eta$  ได้พอดีจะทำให้ได้คำตอบที่ดีที่สุดได้ (ธนพล พิมาณ, 2545)



รูปที่ 2.9 ความสัมพันธ์ระหว่าง SSE และอัตราการเรียนรู้

ที่มา: <https://towardsdatascience.com/gradient-descent-in-a-nutshell-eaf8c18212f0>

### 2.3.7 โมเมนตัม (Momentum Term)

โมเมนตัมแทนด้วยสัญลักษณ์  $\alpha$  เป็นค่าคงที่ที่ช่วยไม่ให้เกิดการเปลี่ยนแปลงของค่าถ่วงน้ำหนักมากเกินไปหากใส่โมเมนตัมเข้าไป การคำนวณตำแหน่งต่อไปจะมีผลจากการเปลี่ยนแปลงค่าถ่วงน้ำหนักในขั้นก่อนหน้ามาเกี่ยวข้องด้วย โดยจะพยายามรักษาทิศการเคลื่อนที่ในแนวเดิมดังสมการ (2.9)

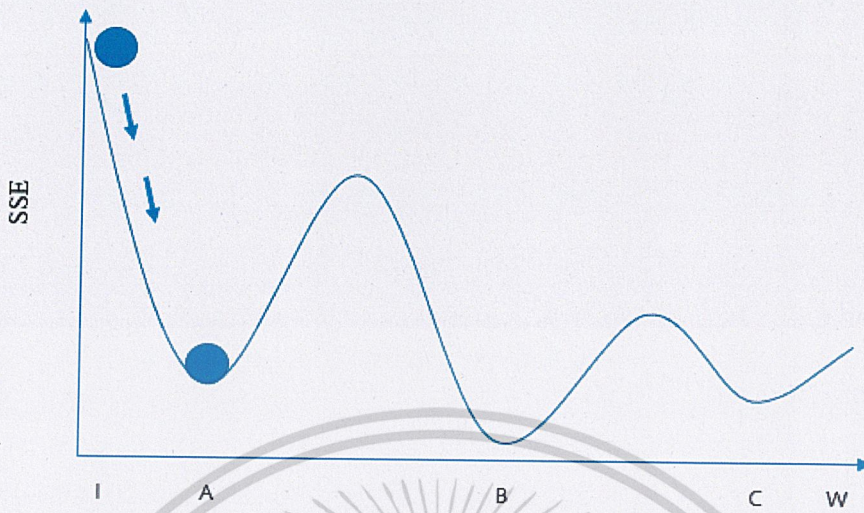
$$\Delta W_{\text{current}} = -\eta \left( \frac{\partial \text{SSE}}{\partial W_{\text{current}}} \right) + \alpha \Delta W_{\text{previous}} \quad (2.9)$$

จากสมการ (2.9) พบว่าค่าโมเมนตัมที่มากจะมีอิทธิพลต่อการปรับค่าถ่วงน้ำหนักปัจจุบัน ( $\Delta W_{\text{current}}$ ) เพื่อเคลื่อนที่ไปในทิศทางเดียวกันกับการปรับค่าถ่วงน้ำหนักที่ผ่านมา  $\Delta W_{\text{previous}}$  การรวมโมเมนตัมในการแพร่แบบย้อนกลับจะทำให้การปรับค่าถ่วงน้ำหนักเป็นการเฉลี่ยเอียงไปแนวจีของ การปรับค่าถ่วงน้ำหนักที่ผ่านมาทั้งหมดดังสมการ (2.10)

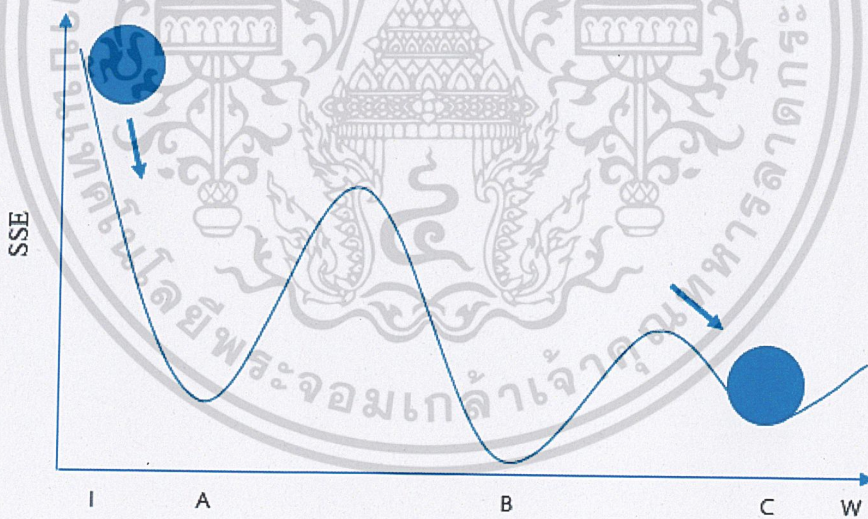
$$\Delta W_{\text{current}} = -\eta \sum_{k=0}^{\infty} \alpha^k \left( \frac{\partial \text{SSE}}{\partial W_{\text{current}-k}} \right) \quad (2.10)$$

ถ้าโมเมนตัมมีค่ามากจะทำให้มีอิทธิพลต่อการปรับค่าถ่วงน้ำหนักที่ผ่านมาที่มีค่ามากดังรูปที่ 2.10 ทางตรงกันข้ามถ้าค่าโมเมนตัมมีค่าน้อยจะช่วยลดอิทธิพลต่อการปรับค่าถ่วงน้ำหนักที่ผ่านมา ดังรูปที่ 2.11 และถ้าค่าโมเมนตัมเป็นศูนย์จะทำให้เทอมทั้งหมดนั้นหายไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.10 โมเมนต์มีค่าน้อยอาจจะทำให้อัลกอริทึมไม่ไปถึงค่าต่ำสุด



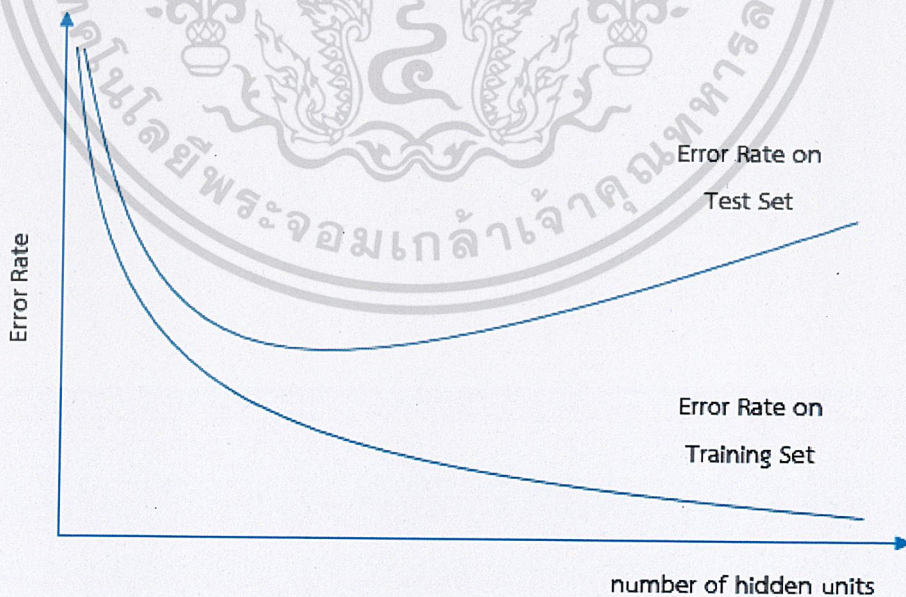
รูปที่ 2.11 โมเมนต์มีค่ามากอาจจะทำให้อัลกอริทึมผ่านเลยค่าต่ำสุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 2.10 และ 2.11 ค่าถ่วงน้ำหนักเริ่มต้นที่ตำแหน่ง  $I$  ซึ่งมีค่าต่ำสุด Local (Local Minimum) ของ SSE อยู่ที่ตำแหน่ง A และตำแหน่ง C โดยที่ค่าต่ำสุด Global (Global minimum) ของ SSE ที่เหมาะสมที่สุดอยู่ที่ตำแหน่ง B สมมติว่าโมเมนตัม ( $\alpha$ ) มีค่าน้อยดังรูปที่ 2.10 แทนด้วยลูกบอลขนาดเล็ก ถ้าทำการกลิ้งลูกบอลขนาดเล็กไปตามเส้นโค้ง ลูกบอลอาจจะหยุดอยู่ที่ตำแหน่ง A ทำให้สามารถหาค่าที่ต่ำสุด Local ของ SSE ที่ตำแหน่ง A ได้ แต่ไม่สามารถหาค่าต่ำสุด Global ของ SSE ที่ตำแหน่ง B ได้ในทางตรงกันข้ามถ้าสมมติว่าโมเมนตัม ( $\alpha$ ) มีค่ามากดังรูปที่ 2.11 แทนด้วยลูกบอลขนาดใหญ่ ถ้าทำการกลิ้งลูกบอลขนาดใหญ่ไปตามเส้นโค้ง ลูกบอลอาจจะไม่มีเมตัมมากจนผ่านเลยค่าต่ำสุด Global ของ SSE ที่ตำแหน่ง B ไปและหยุดอยู่ที่ค่าต่ำสุด Local ของ SSE ที่ตำแหน่ง C แทน ดังนั้นในการสร้างตัวแบบโครงข่ายประสาทเทียมจะต้องทำการพิจารณากำหนดทั้งค่าอัตราการเรียนรู้ ( $\eta$ ) และค่าโมเมนตัม ( $\alpha$ ) โดยทำการทดลองเลือกค่าอัตราการเรียนรู้และค่าโมเมนตัม ๓ ระดับต่าง ๆ เพื่อหาค่าที่ทำให้ได้ผลลัพธ์ที่ดีที่สุด

### 2.2.8 ความซับซ้อนของตัวแบบมากเกินไปจนเกิดความจำเป็น (Overfitting)

การเพิ่มโหนดในชั้นซ่อนมากเกินไป จะทำให้อัตราความผิดพลาดในชุดฝึกสอนน้อยลง แต่ในขณะเดียวกันจะนำไปสู่ความซับซ้อนของตัวแบบมากเกินไปจนเกิดความจำเป็น ซึ่งก็คือลักษณะที่โครงข่ายประสาทเทียมมีความผิดพลาดของชุดฝึกสอน (Training Set) ที่น้อยแต่มีความผิดพลาดของชุดทดสอบ (Test Set) ที่มากดังรูปที่ 2.12 (คงฤทธิ โกมาสถิตย์, 2555)

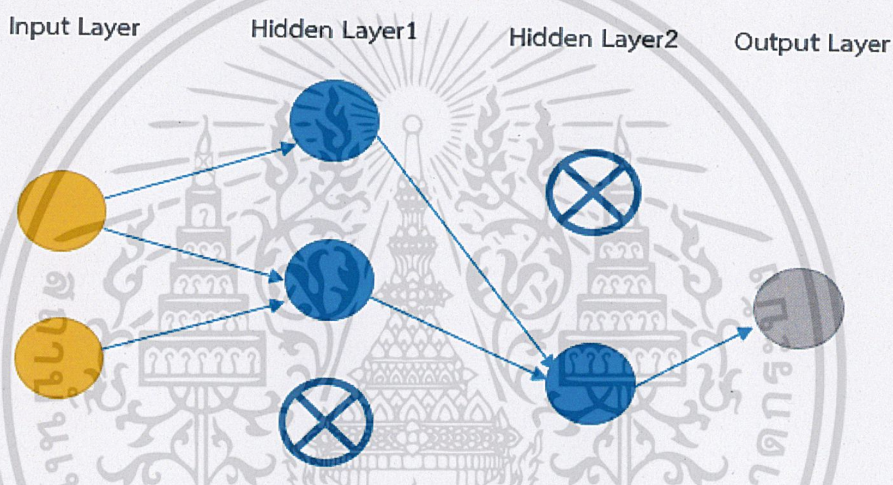


รูปที่ 2.12 ความซับซ้อนของตัวแบบมากเกินไปจนเกิดความจำเป็น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 2.2.9 การดรอปเอาต์ (Dropout)

เป็นวิธีป้องกันความซับซ้อนของตัวแบบมากเกินไปจนเกิดความจำเป็น (Overfitting) และปัญหาการตรวจจับคุณลักษณะซ้ำ ๆ กันของนิวรอลมากกว่าสองตัวขึ้นไปในโครงข่ายประสาทเทียม เรียกว่า การปรับตัวร่วมกัน (Co-Adaptation) ทำให้โครงข่ายประสาทเทียมไม่สามารถทำงานได้อย่างมีประสิทธิภาพและเป็นการสิ้นเปลืองทรัพยากรในคำนวณค่านิวรอลแต่ละตัวที่สุดท้ายแล้วได้ผลลัพธ์ออกมาเหมือนกัน การดรอปเอาต์มีหลักการการทำงานคือจะสุ่มตัดเส้นเชื่อมของโครงข่ายประสาทเทียมในระหว่างการเรียนรู้ในทุก ๆ รอบการเรียนรู้ดังรูปที่ 2.13 (มนัสการ์ต เสนหา, 2559)



รูปที่ 2.13 การดรอปเอาต์ในชั้นซ่อน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.4 การวัดประสิทธิภาพของการพยากรณ์

### 2.4.1 ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Deviation : MAD)

ค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์แทนด้วยสัญลักษณ์ MAD เป็นค่าวัดประสิทธิภาพของการพยากรณ์โดยวัดจากค่าความคลาดเคลื่อนโดยไม่คำนึงถึงทิศทางของความคลาดเคลื่อน MAD มีหน่วยวัดเดียวกับค่าสังเกตตั้งสมการ (2.11)

$$\text{MAD} = \frac{\sum_{t=1}^n |e_t|}{n} \quad (2.11)$$

### 2.4.2 ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percent Error : MAPE)

ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยแทนด้วยสัญลักษณ์ MAPE เป็นค่าวัดประสิทธิภาพของการพยากรณ์ที่วัดเปอร์เซ็นต์ความต่างว่าค่าจริงต่างจากค่าพยากรณ์กี่เปอร์เซ็นต์ โดยค่าวัดความถูกต้องนี้ไม่มีหน่วยตั้งสมการ (2.12)

$$\text{MAPE} = \frac{\sum_{t=1}^n \left| \frac{e_t}{Y_t} \right|}{n} \times 100 \quad (2.12)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.5 งานวิจัยที่เกี่ยวข้อง

คงฤทธิ โกมาสถิตย์ (2555) งานวิจัยนี้ได้ศึกษาวิธีการพยากรณ์อุปสงค์พลังงานไฟฟ้า (Electrical Energy Consumption) ของประเทศไทยในระยะยาวด้วยวิธีโครงข่ายประสาทเทียม (Artificial Neural Network : ANN) โดยได้นำโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Back-Propagation Neural Network : BPNN) โดยมีตัวแปรที่ป้อนเข้าในแบบจำลองจะพิจารณาจากตัวแปรด้านเศรษฐศาสตร์ ดินฟ้าอากาศ สังคมศาสตร์ และอุตสาหกรรม โดยพิจารณาตัวแปรที่มีความสัมพันธ์กับค่าพลังงานไฟฟ้าที่ดี (Strong Parameter) ไปออกแบบโครงข่ายประสาทเทียม ส่วนตัวแปรที่มีความสัมพันธ์ไม่ดี (Weak Parameter) จะถูกคัดออก การศึกษาและการออกแบบทำให้ได้โครงข่ายประสาทเทียม 1 ชั้นซ่อน ที่มี 4 นิวรอนเป็นฟังก์ชันเส้นตรงและมีตัวแปรป้อนเข้าแบบจำลอง 4 ตัวแปร คือ ผลผลิตมวลรวมในประเทศ (GDP) จำนวนลูกค้าการไฟฟ้า (Customer) ดรรชนีอุตสาหกรรม (Industrial Index) และจำนวนนักท่องเที่ยวต่างชาติ (Foreign Tourist) ส่วนตัวแปรผลลัพธ์มี 1 ตัวแปรคือ อุปสงค์พลังงานไฟฟ้า ซึ่งผลการศึกษสามารถสรุปได้ว่าวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับสามารถพยากรณ์ได้แม่นยำกว่าวิธีของคณะกรรมการพยากรณ์แห่งประเทศไทย (Thailand Load Forecast Sub-Committee : TLFS)

ปฏิมาพร อุดม (2556) งานวิจัยนี้ได้ศึกษาการพยากรณ์ของเครื่องมือที่สำคัญ สำหรับการวางแผนการดำเนินงานของผู้ประกอบการประเภทผู้แทนจำหน่ายเม็ดพลาสติก เนื่องจากการพยากรณ์ยอดขายที่ผิดพลาดจะส่งผลกระทบต่อการจัดการสินค้าคงคลัง ซึ่งอาจเกิดต้นทุนจากการเก็บสินค้าไว้มากเกินความจำเป็น และการเสียโอกาสทางการค้าในกรณีสินค้าขาดมือ โดยได้ทำการเปรียบเทียบระหว่างเทคนิคการพยากรณ์แบบบอซ-เจนกินส์ (ARIMA) การพยากรณ์โดยใช้โครงข่ายประสาทเทียม (Artificial Neural Network) และการพยากรณ์โดยประยุกต์ใช้วิธีทางพันธุศาสตร์ร่วมกับโครงข่ายประสาทเทียม (Genetic Algorithm With Artificial Neural Network) ซึ่งใช้วิธีทางพันธุศาสตร์ในการหาจำนวนชั้นซ่อนและจำนวนโหนดในชั้นซ่อนที่เหมาะสมของโครงข่ายประสาทเทียมเพื่อให้กระบวนการเรียนรู้ของโครงข่ายประสาทเทียมมีประสิทธิภาพมากยิ่งขึ้น และได้เปรียบเทียบผลจากเทคนิคการพยากรณ์ดังกล่าวกับวิธีการปรับเรียบเอกซ์โพเนนเชียลแบบวินเทอร์ (Winters Exponential Smoothing) และวิธีค่าเฉลี่ยเคลื่อนที่ (Moving Average) โดยใช้ร้อยละของค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) เป็นตัวชี้วัดผลลัพธ์ที่ได้จากการพยากรณ์แต่ละเทคนิค ผลการวิจัยพบว่าเทคนิคการพยากรณ์โครงข่ายประสาทเทียมโดยการประยุกต์ใช้วิธีการทางพันธุศาสตร์ในการหาจำนวนชั้นซ่อน และจำนวนโหนดในแต่ละชั้นซ่อน เป็นเทคนิคที่ให้ร้อยละของค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ยในการพยากรณ์น้อยที่สุดสำหรับสินค้ากลุ่มทั่วไป และเทคนิคการพยากรณ์โครงข่ายประสาทเทียมที่มีชั้นซ่อน 1 ชั้น เป็นเทคนิคที่ให้ร้อยละของค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ยในการพยากรณ์น้อยที่สุดสำหรับสินค้ากลุ่มที่มีคุณสมบัติพิเศษ

เอกสารนี้เป็นทรัพย์สินทางปัญญาของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี  
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผุสดี บุญรอด (2560) งานวิจัยนี้ได้ศึกษาการพยากรณ์ราคามันสำปะหลัง เนื่องจากมันสำปะหลังเป็นพืชอาหารที่สำคัญของโลกประกอบกับราคามันสำปะหลังมีความผันผวนอยู่ตลอดเวลา จึงประยุกต์ใช้โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-Layer Artificial Neural Network) ที่ใช้การเรียนรู้แบบแพร่กระจายย้อนกลับในการหารูปแบบโครงข่าย สำหรับพยากรณ์ราคามันสำปะหลัง จากการประเมินประสิทธิภาพแบบจำลองการพยากรณ์ที่พัฒนาขึ้นโดยหาค่าร้อยละเฉลี่ยของความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error : MAPE) โดยนำไปเปรียบเทียบกับ เคเนียร์เซนเบอร์ (k-Nearest Neighbor : K-NN) และการวิเคราะห์การถดถอยเชิงเส้น (Linear Regression Analysis) สามารถสรุปได้ว่าแบบจำลองการพยากรณ์ โดยใช้โครงข่ายประสาทเทียมแบบหลายชั้นมีประสิทธิภาพดีที่สุด ซึ่งสามารถนำไปประยุกต์ใช้และต่อยอดในการพยากรณ์ราคามันสำปะหลังได้ดีกว่าวิธีอื่น ๆ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 3

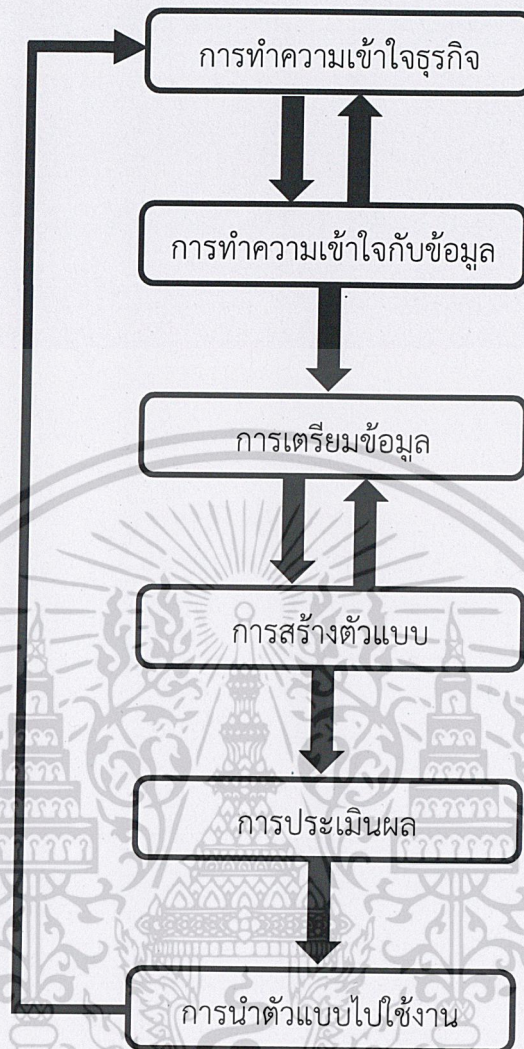
### วิธีการดำเนินงานวิจัย

ในบทนี้ผู้วิจัยจะกล่าวถึงวิธีดำเนินงานวิจัยโดยใช้กระบวนการ CRISP-DM ซึ่งมีขั้นตอนการดำเนินงาน 6 ขั้นตอนดังนี้

1. การทำความเข้าใจธุรกิจ (Business Understanding)
2. การทำความเข้าใจกับข้อมูล (Data Understanding)
3. การเตรียมข้อมูล (Data Preparation)
4. การสร้างตัวแบบการพยากรณ์ (Modeling)
5. การประเมินผล (Evaluation)
6. การนำตัวแบบไปใช้งาน (Deployment)



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.1 ขั้นตอนการดำเนินงานด้วยกระบวนการ CRISP-DM

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.1 การทำความเข้าใจธุรกิจ (Business Understanding)

ปัจจุบันบริษัทกรณีศึกษาใช้วิธีการพยากรณ์สินค้า A โดยสามารถพยากรณ์สินค้า A ได้ในพื้นที่การขายเดียวและขนาดสินค้าเดียว ปัญหาคือบริษัทต้องสร้างตัวแบบการพยากรณ์ยอดขายสินค้า A หลายตัวแบบเพื่อที่จะพยากรณ์ยอดขายสินค้า A ในแต่ละพื้นที่การขายและในแต่ละขนาดสินค้าได้ ทำให้ใช้เวลาและใช้ทรัพยากรมนุษย์เป็นจำนวนมาก ดังนั้นในสหกิจศึกษาครั้งนี้ผู้วิจัยจึงศึกษาวิธีการพยากรณ์ที่ช่วยลดระยะเวลาและทรัพยากรมนุษย์ซึ่งวิธีการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมสามารถพยากรณ์ยอดขายสินค้า A ในแต่ละพื้นที่การขายและในแต่ละขนาดสินค้าได้ภายในตัวแบบเดียว ผู้วิจัยจึงทำการศึกษาการพยากรณ์ยอดขายสินค้า A โดยใช้วิธีโครงข่ายประสาทเทียม

### 3.2 การทำความเข้าใจกับข้อมูล (Data Understanding)


#### 3.2.1 การเก็บข้อมูลขั้นต้น (Collect Initial Data)

ข้อมูลที่ใช้ในการวิจัยครั้งนี้ได้มาจากข้อมูลในอดีตของบริษัทที่ได้ทำการจัดเก็บไว้ในฐานข้อมูล (Database) โดยใช้ข้อมูลตั้งแต่ มกราคม พ.ศ. 2559 ถึง ธันวาคม พ.ศ. 2562 ข้อมูลที่บริษัทเก็บรวบรวมไว้เป็นข้อมูลยอดขายสินค้า A ในแต่ละพื้นที่การขายสินค้าและในแต่ละขนาดสินค้า

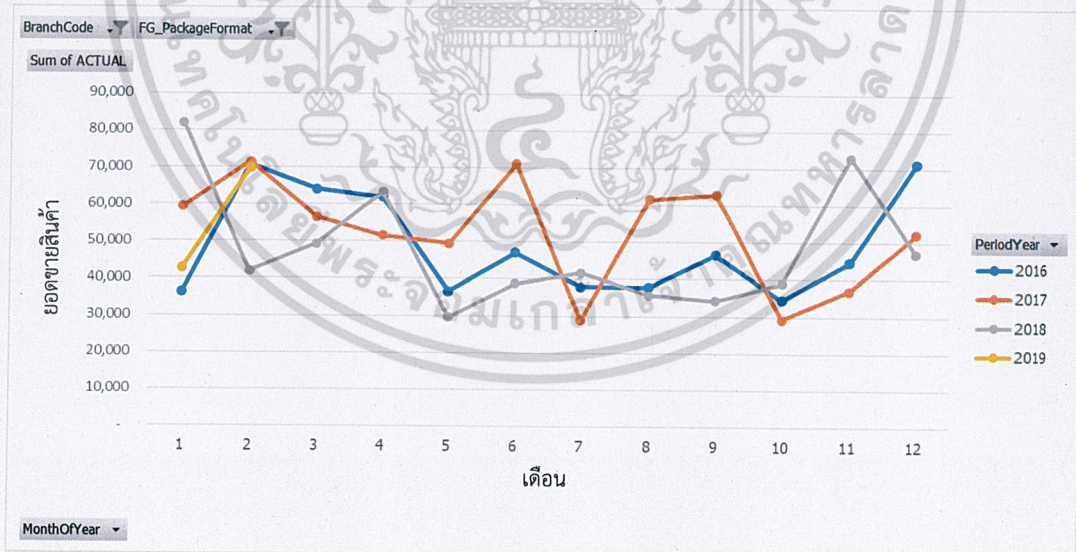
#### 3.2.2 การอธิบายข้อมูล (Describe Data)

ทำความเข้าใจและศึกษารายละเอียดของตัวแปรต่าง ๆ และทำการตรวจสอบว่าข้อมูลมีความสมบูรณ์ ถูกต้อง ครบคลุม และเพียงพอกับความต้องการหรือไม่ และทำการศึกษาลักษณะข้อมูลและหาความสัมพันธ์ของข้อมูลด้วยการ Pivot table โดยใช้โปรแกรม Microsoft Excel

ตัวอย่างการ Pivot table โดยใช้โปรแกรม Microsoft Excel ของยอดขายสินค้า A ในพื้นที่การขาย (BranchCode) 25 ขนาดสินค้า FG\_PackageFormat เล็ก (Small) ดังรูปที่ 3.2 และ ยอดขายสินค้า A ในพื้นที่การขาย (BranchCode) 60 ขนาดสินค้า FG\_PackageFormat ใหญ่ (Big) ดังรูปที่ 3.3



รูปที่ 3.2 ยอดขายสินค้า A ในพื้นที่การขาย (BranchCode) 25 ขนาดสินค้า (FG\_PackageFormat) เล็ก (Small) ตั้งแต่เดือนมกราคม พ.ศ. 2559 ถึง กุมภาพันธ์ พ.ศ. 2562



รูปที่ 3.3 ยอดขายสินค้า A ในพื้นที่การขาย (BranchCode) 60 ขนาดสินค้า (FG\_PackageFormat) ใหญ่ (Big) ตั้งแต่เดือนมกราคม พ.ศ. 2559 ถึง กุมภาพันธ์ พ.ศ. 2562

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.3 การเตรียมข้อมูล (Data Preparation)

เป็นขั้นตอนการจัดเตรียมข้อมูลให้พร้อมก่อนนำไปสร้างตัวแบบการพยากรณ์ยอดขายสินค้า A ด้วยวิธีโครงข่ายประสาทเทียม ซึ่งมีรายละเอียดดังต่อไปนี้

#### 3.3.1 การคัดเลือกข้อมูล (Data Selection)

โดยข้อมูลที่เลือกมาวิเคราะห์เป็นข้อมูลยอดขายสินค้า A ในแต่ละพื้นที่การขายและในแต่ละขนาดสินค้าโดยมีรายละเอียดดังตารางที่ 3.1

ตารางที่ 3.1 ตัวแปรที่ใช้ในการวิเคราะห์

ตัวแปร	คำอธิบาย
ACTUAL	ยอดขายการขายมีหน่วยเป็นลิตร
FG_PackageFormat	ขนาดของสินค้า
BranchCode	พื้นที่การขายสินค้า
PeriodYear	ปีที่ขายสินค้า
MonthOfYear	เดือนที่ขายสินค้า

#### 3.3.2 การทำความสะอาดข้อมูล (Data Cleansing)

เป็นขั้นตอนการทำความสะอาดข้อมูลยอดขายสินค้า เนื่องจากข้อมูลยอดขายสินค้า A มีข้อมูลสูญหาย (Missing) ดังตารางที่ 3.2 แสดงตัวอย่างข้อมูลยอดขายสินค้า A ในพื้นที่การขาย (BranchCode) 65, 67, 68 และ 69 ขนาดของสินค้า (FG\_PackageFormat) เล็ก (Small) มีข้อมูลยอดขายรายเดือนสูญหาย (Missing) จึงต้องทำความสะอาดข้อมูลโดยการเลือกข้อมูลพื้นที่การขาย (BranchCode) ที่มีจำนวนเดือนการขายสินค้ามากกว่า 80 เปอร์เซ็นต์จากนั้นแทนที่ข้อมูลสูญหายด้วยค่าเฉลี่ยของแต่ละพื้นที่การขายและขนาดสินค้านั้น ๆ ดังตารางที่ 3.3

ตารางที่ 3.2 ข้อมูลยอดขายสินค้า A ก่อนการทำความสะอาดข้อมูล

PeriodYear	MonthOfYear	Product_Brand A									
		FG_PackageFormat Big					Small				
		62	64	65	66	67	68	69	62	64	
2016	1	8316.00	10982.40	52.80	15800.40	NaN	26.40	NaN	13716.17280	8363.52000	
	2	19166.40	24129.60	211.20	35970.00	396.0	422.40	NaN	28603.23840	18580.95360	
	3	15813.60	16843.20	121.44	22836.00	NaN	100.32	158.4	19445.18400	14719.79520	
	4	17925.60	19470.00	356.40	25304.40	264.0	427.68	330.0	24714.20160	14371.31520	
	5	12408.00	11748.00	264.00	16368.00	184.8	264.00	132.0	17981.56800	7833.83040	
	6	19773.60	10045.20	132.00	34782.00	396.0	184.80	NaN	26317.20960	10908.81792	
	7	7035.60	12975.60	316.80	20196.00	132.0	501.60	NaN	16922.18880	11458.02240	
	8	7840.80	12896.40	198.00	11682.00	396.0	528.00	198.0	17117.33760	10761.06240	
	9	17437.20	15042.94	250.80	34254.00	660.0	409.20	198.0	24742.08000	12127.10400	
	10	8672.40	10629.96	198.00	16170.00	264.0	330.00	NaN	15263.42400	10891.36640	
	11	13450.80	11880.00	198.00	22506.00	396.0	607.20	198.0	21354.85440	10788.94080	
	12	13912.80	17938.80	303.60	26730.00	396.0	250.80	198.0	20142.14400	14664.03840	
2017	1	16500.00	17424.00	198.00	27588.00	396.0	356.40	198.0	23836.03200	14496.76800	
	2	17239.20	18202.80	198.00	35442.00	792.0	448.80	198.0	23306.34240	14914.94400	
	3	11602.80	14823.60	198.00	23007.60	132.0	198.00	NaN	20774.98368	11904.07680	
	4	12117.60	17965.20	277.20	27337.20	528.0	250.80	198.0	18748.22400	12322.25280	
	5	14242.80	10282.80	250.80	10560.00	264.0	580.80	NaN	18580.95360	12796.18560	
	6	19496.40	17371.20	673.20	43626.00	264.0	184.80	198.0	31641.98400	15249.48480	
	7	9398.40	10480.80	NaN	13662.00	NaN	132.00	198.0	16322.80320	9980.46720	
	8	15180.00	19282.56	594.00	34320.00	264.0	580.80	198.0	24100.87680	16056.56448	
	9	11959.20	20895.60	396.00	30690.00	660.0	448.80	198.0	20351.23200	16211.28960	
	10	10169.28	2798.40	422.40	7064.64	264.0	316.80	396.0	23100.04224	12712.55040	
	11	14533.20	12988.80	NaN	28248.00	528.0	250.80	NaN	20295.47520	6258.70080	
	12	16978.28	14203.20	699.60	22110.00	264.0	224.40	198.0	24491.17440	8224.12800	
2018	1	10227.36	14665.20	396.00	29449.20	792.0	NaN	396.0	17856.11520	17953.68960	
	2	12328.80	10641.84	396.00	16104.00	264.0	198.00	NaN	18093.08160	11947.28832	
	3	17233.92	13200.00	396.00	26400.00	264.0	396.00	198.0	28965.65760	12559.21920	
	4	23026.08	21587.28	396.00	36234.00	1320.0	594.00	396.0	30917.14560	15779.17440	
	5	4019.40	7827.60	198.00	4950.00	NaN	NaN	NaN	9255.62880	8753.81760	
	6	10414.80	5836.60	396.00	28630.80	924.0	NaN	264.0	18399.74400	11513.77920	
	7	12439.68	9385.20	198.00	17886.00	792.0	158.40	145.2	20992.43520	9353.20320	
	8	12672.00	8514.00	396.00	20658.00	792.0	330.00	264.0	21299.09760	8224.12800	
	9	11748.00	6700.32	594.00	21780.00	1056.0	594.00	39.6	16504.01280	10105.92000	
	10	14416.16	11027.28	198.00	22176.00	528.0	475.20	303.6	24282.08640	14454.95040	
	11	24966.48	17516.40	1188.00	40788.00	2376.0	554.40	554.4	34652.85120	13688.29440	

149ee7

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.3 ข้อมูลยอดขายสินค้า A หลังการทำความสะอาดข้อมูล

PeriodYear	MonthOfYear	Product_Brand A							
		FG_PackageFormat Big				Small			
BranchCode		62	64	65	66	67	68	62	64
2016	1	8316.00	10982.40	52 800000	15800.40	546.15	26 400000	13716.17280	8363 52000
	2	19166.40	24129.60	211 200000	35970.00	396.00	422 400000	28603 23840	18580 95360
	3	15813.60	16843.20	121 440000	22836.00	546.15	100 320000	19445 18400	14719 79520
	4	17925.60	19470.00	356 400000	25304.40	264.00	427 680000	24714 20160	14371 31520
	5	12408.00	11748.00	264 000000	16368.00	184.80	264 000000	17981 56800	7833 83040
	6	19773.60	10045.20	132 000000	34782.00	396.00	184 800000	26317 20960	10908 81792
	7	7035.60	12975.60	316 800000	20196.00	132.00	501 600000	16922 18880	11458 02240
	8	7840.80	12896.40	198 000000	11682.00	396.00	528 000000	17117 33760	10761 06240
	9	17437.20	15042.94	250 800000	34254.00	660.00	409 200000	24742 08000	12127 10400
	10	8672.40	10629.96	198 000000	16170.00	264.00	330 000000	15263 42400	10691 36640
	11	13450.80	11880.00	198 000000	22506.00	396.00	607 200000	21354 85440	10788 94080
	12	13912.80	17938.80	303 600000	26730.00	396.00	250 800000	20142 14400	14664 03840
2017	1	16500.00	17424.00	198 000000	27588.00	396.00	356 400000	23836 03200	14496 76800
	2	17239.20	18202.80	198 000000	35442.00	792.00	448 800000	23306 34240	14914 94400
	3	11602.80	14823.60	198 000000	23007 60	132.00	198 000000	20774 98368	11904 07680
	4	12117.60	17965.20	277 200000	27337 20	528.00	250 800000	18748 22400	12322 25280
	5	14242.80	10282.80	250 800000	10560.00	264.00	580 800000	18580 95360	12796 18560
	6	19496.40	17371.20	673 200000	43626.00	264.00	184 800000	31641 98400	15249 48480
	7	9398.40	10480.80	342 889412	13662.00	546 15	132 000000	16322 80320	9980 46720
	8	15180.00	19282 56	594 000000	34320.00	264.00	580 800000	24100 87680	16058 56448
	9	11959.20	20895 60	396 000000	30690.00	660.00	448 800000	20351 23200	16211 28960
	10	10169 28	2798 40	422 400000	7064 64	264.00	316 800000	23100 04224	12712 55040
	11	14533 20	12988 80	342 889412	28248 00	528.00	250 800000	20295 47520	6258 70080
	12	16978 28	14203 20	699 600000	22110 60	264.00	224 400000	24491 17440	8224 12800
2018	1	10227 36	14665 20	396 000000	29449 20	792.00	388 834286	17856 11520	17953 68960
	2	12328 80	10641 84	396 000000	16104 00	264.00	198 000000	18093 08160	11947 28832
	3	17233 92	13200 00	396 000000	26400 00	264.00	396 000000	28965 65760	12559 21920
	4	23026 08	21587 28	396 000000	36234 00	1320.00	594 000000	30917 14560	15779 17440
	5	4019 40	7827 60	198 000000	4950 00	546 15	388 834286	9255 62880	8753 81760
	6	10414 80	5836 60	396 000000	28630 80	924.00	388 834286	18399 74400	11513 77920
	7	12439 68	9385 20	198 000000	17886 00	792.00	158 400000	20992 43520	9353 20320
	8	12672 00	8514 00	396 000000	20658 00	792.00	330 000000	21299 09760	8224 12800
	9	11748 00	6700 32	594 000000	21780 00	1056.00	594 000000	16504 01280	10105 92000
	10	14416 16	11027 28	198 000000	22176 00	528.00	475 200000	24282 08640	14454 95040
	11	24966 48	17516 40	1188 000000	40788 00	2376.00	554 400000	34652 85120	13688 29440
	12	4749 80	12220 34	342 889412	18216 00	546 15	699 600000	10761 06240	12628 91520
2019	1	12936 00	9900 00	342 889412	23192 40	546 15	792 000000	23278 46400	10175 61600
	2	16051 86	14084 40	396 000000	30954 00	528.00	792 000000	20881 38624	19247 24736

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.3.3 การแปลงข้อมูลเชิงปริมาณ

#### 1. สร้างตัวแปรหุ่น (Dummies) ขนาดสินค้า (FG\_PackageFormat)

การสร้างตัวแปรหุ่นของสินค้าที่มีขนาดใหญ่ (Big) จะสร้างตัวแปร Big ซึ่งถ้าสินค้าที่ขายมีขนาดใหญ่ (Big) ตัวแปร Big จะมีค่าเท่ากับ 1 ถ้าสินค้าที่ขายไม่ได้มีขนาดใหญ่ตัวแปร Big จะมีค่าเท่ากับ 0 ดังรูปที่ 3.4 สินค้าที่มีขนาดเล็ก (Small) จะดำเนินการในทำนองเดียวกัน

#### 2. สร้างตัวแปรหุ่น (Dummies) พื้นที่การขาย (BranchCode)

การสร้างตัวแปรหุ่นของพื้นที่การขาย 58 จะสร้างตัวแปร 58 ซึ่งถ้าสินค้านั้นถูกขายในพื้นที่การขาย 58 ตัวแปร 58 จะมีค่าเท่ากับ 1 ถ้าสินค้านั้นไม่ถูกขายในพื้นที่การขาย 58 ตัวแปร 58 จะมีค่าเท่ากับ 0 ดังรูปที่ 3.4 พื้นที่การขายอื่น ๆ จะดำเนินการในทำนองเดียวกัน

FG_PackageFormat	BranchCode	Big	Small	1	2	3	6	8	10	...	58	59	60	61	62	64	66
Small	70	0	1	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Big	38	1	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Big	22	1	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Big	33	1	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Small	35	0	1	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Big	36	1	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Big	44	1	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Small	1	0	1	1	0	0	0	0	0	...	0	0	0	0	0	0	0
Big	36	1	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Small	27	0	1	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Small	59	0	1	0	0	0	0	0	0	...	0	1	0	0	0	0	0
Big	38	1	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Big	3	1	0	0	0	1	0	0	0	...	0	0	0	0	0	0	0
Small	94	0	1	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Big	59	1	0	0	0	0	0	0	0	...	0	1	0	0	0	0	0
Small	6	0	1	0	0	0	1	0	0	...	0	0	0	0	0	0	0
Big	58	1	0	0	0	0	0	0	0	...	1	0	0	0	0	0	0
Big	59	1	0	0	0	0	0	0	0	...	0	1	0	0	0	0	0
Small	22	0	1	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Small	28	0	1	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Big	74	1	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0
Big	3	1	0	0	0	1	0	0	0	...	0	0	0	0	0	0	0

รูปที่ 3.4 การแปลงข้อมูลเชิงคุณภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.3.4 การแปลงข้อมูลเชิงปริมาณ

ทำการแปลงตัวแปรยอดขายสินค้า (Actual) ปีที่ขายสินค้า (PeriodYear) เดือนที่ขายสินค้า (MonthOfYear) ให้อยู่ในรูปปรกติมาตรฐานน้อยที่สุด-มากที่สุด ดังรูปที่ 3.5

PeriodYear	MonthOfYear	ACTUAL	PeriodYear	MonthOfYear	ACTUAL
2018	11	20825.16480	1.0	0.909091	0.066685
2017	6	69286.80000	0.5	0.454545	0.229724
2017	5	11003.96000	0.5	0.363636	0.033644
2017	6	164506.32000	0.5	0.454545	0.550071
2017	2	75885.00480	0.5	0.090909	0.251923
2018	4	206991.84000	1.0	0.272727	0.693004
2017	4	40260.00000	0.5	0.272727	0.132070
2016	7	62336.10240	0.0	0.545455	0.206340
2018	12	138860.48000	1.0	1.000000	0.463791
2016	9	70392.96000	0.0	0.727273	0.233446
2017	7	80345.54880	0.5	0.545455	0.266929
2018	3	50021.40000	1.0	0.181818	0.164910
2018	10	35032.80000	1.0	0.818182	0.114484
2018	4	38193.40800	1.0	0.272727	0.125117
2018	11	113597.00000	1.0	0.909091	0.378797
2018	10	77052.29664	1.0	0.818182	0.255850
2018	8	40780.08000	1.0	0.636364	0.133820
2016	11	70379.76000	0.0	0.909091	0.233401
2016	12	24393.60000	0.0	1.000000	0.078691
2018	10	67911.78240	1.0	0.818182	0.225098
2016	12	14652.00000	0.0	1.000000	0.045917
2017	3	36890.92000	0.5	0.181818	0.120735

รูปที่ 3.5 การแปลงข้อมูลเชิงปริมาณ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.4 การสร้างตัวแบบ (Modeling)

#### 3.4.1 การพยากรณ์ยอดขายสินค้า A โดยวิธีโครงข่ายประสาทเทียม

ในสหกิจศึกษาครั้งนี้ได้ใช้โครงข่ายประสาทเทียมเป็นแบบจำลองในการพยากรณ์ยอดขายสินค้า A โดยมีขั้นตอนดังนี้

1. กำหนดโครงสร้างของโครงข่ายประสาทเทียม โดยจำนวนโหนดในชั้นข้อมูลนำเข้าจะเท่ากับจำนวนตัวแปรอิสระทั้งหมดที่ใช้ในการวิเคราะห์ซึ่งมีตัวแปร เดือนที่ขายสินค้า ปีที่ขายสินค้า พื้นที่การขายสินค้าจำนวน 44 พื้นที่การขาย และขนาดสินค้าจำนวน 2 ขนาด รวมทั้งสิ้น 48 โหนด จำนวนโหนดในชั้นผลลัพธ์เท่ากับจำนวนเดือนที่ต้องการพยากรณ์ล่วงหน้าซึ่งในที่นี้เท่ากับ 1 เดือน จึงกำหนดเป็น 1 โหนด เนื่องจากการกำหนดโหนดในชั้นซ่อนยังไม่มีกฎเกณฑ์ที่แน่นอนโดยทั่วไปจำนวนโหนดในชั้นซ่อนจะได้รับการทดลอง ซึ่งในที่นี้ผู้วิจัยได้ทำการทดลองกำหนดจำนวนโหนดเท่ากับ 10, 20 และ 30 โหนด
2. อัตราการเรียนรู้และโมเมนตัมจะอยู่ในช่วง (0,1) ซึ่งยังไม่มีกฎเกณฑ์ในการกำหนดที่แน่นอน โดยทั่วไปอัตราการเรียนรู้และโมเมนตัมจะได้รับการทดลอง ซึ่งในที่นี้ผู้วิจัยได้ทำการทดลองกำหนดอัตราการเรียนรู้เป็น 0.1, 0.15, 0.2, 0.25, 0.3 และ 0.35 และกำหนดค่าโมเมนตัมเป็น 0.5, 0.6, 0.7, 0.8 และ 0.9
3. สำหรับจำนวนรอบการสอนหากกำหนดให้จำนวนรอบการสอนมากเกินไปจะทำให้ใช้เวลานานในการฝึกสอนโครงข่ายประสาทเทียมและไม่ได้ทำให้โครงข่ายประสาทเทียมเรียนรู้ได้มากขึ้น ซึ่งในงานวิจัยครั้งนี้กำหนดจำนวนรอบการสอนเท่ากับ 1,000 รอบ และเพื่อไม่ให้เกิดความซับซ้อนของตัวแบบมากเกินไปจนเกิดความจำเป็น (Overfitting) จึงกำหนดรอบเอาท์ในชั้นซ่อนเท่ากับ 0.1 และทรานสเฟอร์ฟังก์ชันที่ใช้คือซิกมอยด์ฟังก์ชันเนื่องจากมีคุณสมบัติที่ให้ค่าผลลัพธ์ที่เป็นค่าต่อเนื่องระหว่าง 0 ถึง 1 และเป็นฟังก์ชันที่หาค่าอนุพันธ์ได้

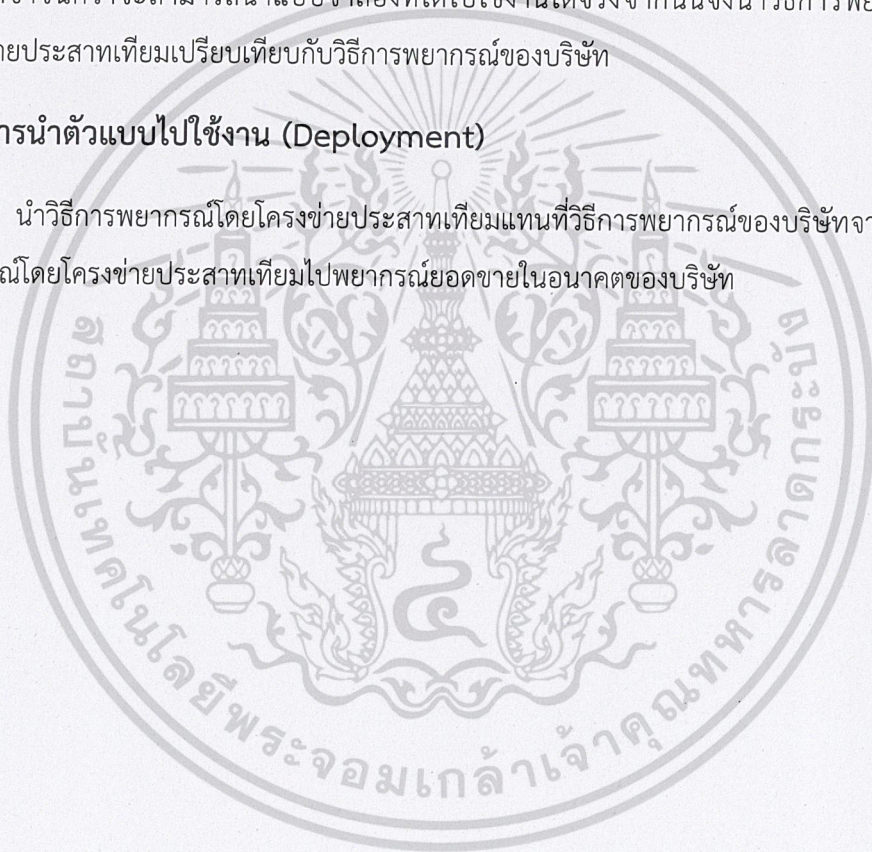
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.5 การประเมินผล (Evaluation)

การวัดประสิทธิภาพของการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมใช้หลักการสุ่มข้อมูลในปี 2559-2561 เป็นข้อมูลฝึกหัด (Train) คือ ข้อมูลที่ใช้ฝึกสอนโครงข่ายประสาทเทียม 70 เปอร์เซ็นต์ และข้อมูลทดสอบ (Test) คือชุดข้อมูลที่ใช้ทดสอบโครงข่ายประสาทเทียม 30 เปอร์เซ็นต์ และใช้ข้อมูลปี 2562 เป็นข้อมูลทดสอบ (Validation) โดยพิจารณาจากค่า MAPE และ MAD ถ้าตัวแบบที่ได้มีความคลาดเคลื่อนสูงจะกลับไปขั้นตอนการทำความเข้าใจปัญหา (Business Understanding) ใหม่ทำซ้ำจนกว่าจะสามารถนำแบบจำลองที่ได้ไปใช้งานได้จริงจากนั้นจึงนำวิธีการพยากรณ์โดยโครงข่ายประสาทเทียมเปรียบเทียบกับวิธีการพยากรณ์ของบริษัท

### 3.6 การนำตัวแบบไปใช้งาน (Deployment)

นำวิธีการพยากรณ์โดยโครงข่ายประสาทเทียมแทนที่วิธีการพยากรณ์ของบริษัทจากนั้นนำวิธีการพยากรณ์โดยโครงข่ายประสาทเทียมไปพยากรณ์ยอดขายในอนาคตของบริษัท



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 4

### ผลการวิเคราะห์ข้อมูล

ในบทนี้ผู้วิจัยจะกล่าวถึงผลการวิเคราะห์การพยากรณ์ยอดขายสินค้า A โดยมีรายละเอียดดังต่อไปนี้

1. ผลการวิเคราะห์สำหรับการพยากรณ์ยอดขายสินค้า A โดยใช้วิธีโครงข่ายประสาทเทียม
2. การเปรียบเทียบประสิทธิภาพของตัวแบบ

#### 4.1 ผลการวิเคราะห์สำหรับการพยากรณ์ยอดขายสินค้า A โดยใช้วิธีโครงข่ายประสาทเทียม

ในงานวิจัยครั้งนี้ได้กำหนดจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับจำนวนตัวแปรอิสระที่ใช้ในการวิเคราะห์คือ 48 โหนด จำนวนโหนดในชั้นซ่อนจะเท่ากับ 10, 20 และ 30 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยในงานวิจัยได้กำหนดลักษณะของโครงข่ายประสาทเทียมดังนี้

1. จำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48
2. จำนวนโหนดในชั้นซ่อนเท่ากับ 10, 20 และ 30
3. จำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1
4. ค่าอัตราการเรียนรู้เท่ากับ 0.1, 0.15, 0.2, 0.25, 0.3 และ 0.35
5. ค่าโมเมนตัมเท่ากับ 0.5, 0.6, 0.7, 0.8 และ 0.9
6. ดรออปเอาต์ในชั้นซ่อนเท่ากับ 0.1

ในงานวิจัยครั้งนี้ทางบริษัทกำหนดเกณฑ์ในการเลือกตัวแบบโดยโครงข่ายประสาทเทียมที่ให้ค่า MAPE (Mean Absolute Percent Error) ต่ำสุดในชุดข้อมูลทดสอบ (Test) จะเป็นโครงข่ายประสาทเทียมที่เหมาะสมสำหรับนำไปพยากรณ์ยอดขายสินค้า A ผลการวิเคราะห์โดยวิธีโครงข่ายประสาทเทียมแสดงดังตารางต่อไปนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.1 โครงข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.1 และ dropout เท่าที่  
ในชั้นซ่อนเท่ากับ 0.1

โครงข่าย	โมเมนตัม	Train		Test		Validation	
		MAPE	MAD	MAPE	MAD	MAPE	MAD
48-10-1	0.5	41.86	42,015.47	32.00	39,748.51	24.86	37,240.56
	0.6	41.12	41,861.18	31.11	39,398.75	23.53	36,864.81
	0.7	40.32	41,246.68	30.61	38,891.48	22.94	36,040.15
	0.8	39.10	41,048.18	29.45	38,818.22	22.07	35,994.33
	0.9	36.09	39,117.15	<b>26.48</b>	37,116.65	19.83	33,983.96
48-20-1	0.5	47.29	43,303.36	36.75	40,942.78	31.01	39,186.02
	0.6	43.63	42,317.54	33.50	40,040.19	26.38	37,470.45
	0.7	40.31	41,486.67	30.56	39,174.62	23.05	36,390.59
	0.8	40.03	40,821.01	30.18	38,598.48	21.88	35,618.65
	0.9	37.76	39,219.91	28.14	37,435.34	20.43	33,847.36
48-30-1	0.5	46.00	43,038.20	35.37	40,568.30	29.64	38,486.37
	0.6	43.03	42,310.67	33.01	39,899.17	25.71	37,213.15
	0.7	44.55	42,379.32	34.18	40,155.54	26.05	37,377.98
	0.8	43.01	41,362.47	32.83	39,378.76	24.53	36,140.59
	0.9	36.95	38,971.60	27.40	37,031.82	19.83	33,594.38

จากตารางที่ 4.1 เมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.1 dropout เท่าที่ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.5-0.9 พบว่าโครงข่ายประสาทเทียมที่ให้ค่า MAPE ต่ำสุดในชุดข้อมูลทดสอบ (Test) คือ 48-10-1 ซึ่งให้ค่า MAPE เท่ากับ 26.48% มีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 10 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยมีอัตราการเรียนรู้เท่ากับ 0.1 dropout ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.9

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.2 โครงข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.15 และดรอปเอาท์  
ในชั้นซ่อนเท่ากับ 0.1

โครงข่าย	โมเมนตัม	Train		Test		Validation	
		MAPE	MAD	MAPE	MAD	MAPE	MAD
48-10-1	0.5	41.29	41,814.97	31.59	39,525.81	24.18	36,762.89
	0.6	39.67	41,440.95	30.08	39,239.14	22.79	36,512.22
	0.7	39.36	40,535.13	29.71	38,371.57	22.27	35,358.07
	0.8	36.39	40,439.31	26.70	38,081.67	20.31	35,379.46
	0.9	35.66	38,726.44	25.84	36,738.28	19.88	33,628.45
48-20-1	0.5	41.97	41,802.46	32.03	39,515.83	24.58	36,714.77
	0.6	39.46	41,436.83	29.71	38,915.84	22.20	36,216.15
	0.7	38.04	41,028.28	28.62	38,696.72	21.36	35,798.65
	0.8	37.12	39,922.38	27.82	37,722.50	20.57	34,676.05
	0.9	35.87	38,567.13	26.17	36,568.71	19.54	33,386.69
48-30-1	0.5	44.40	42,443.14	33.91	40,063.24	26.29	37,378.67
	0.6	40.01	41,557.25	30.33	39,167.06	22.85	36,291.71
	0.7	41.75	40,640.97	31.68	38,711.27	23.64	35,381.51
	0.8	39.83	40,247.22	30.11	38,161.89	21.87	35,257.85
	0.9	37.62	38,541.45	27.80	36,779.53	20.10	33,306.84

จากตารางที่ 4.2 เมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.15 ดรอปเอาท์ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.5-0.9 พบว่าโครงข่ายประสาทเทียมที่ให้ค่า MAPE ต่ำสุดในชุดข้อมูลทดสอบ (Test) คือ 48-10-1 ซึ่งให้ค่า MAPE เท่ากับ 25.84% มีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 10 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยมีอัตราการเรียนรู้เท่ากับ 0.15 ดรอปเอาท์ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.9

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.3 โครงข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.2 และ dropout เท่ากับ 0.1

โครงข่าย	โมเมนตัม	Train		Test		Validation	
		MAPE	MAD	MAPE	MAD	MAPE	MAD
48-10-1	0.5	40.96	40,900.58	30.87	38,607.63	22.78	35,488.93
	0.6	38.25	40,814.40	28.54	38,464.92	21.48	35,794.13
	0.7	36.89	40,027.37	27.20	37,727.35	20.71	35,121.92
	0.8	36.28	38,559.08	26.50	36,830.73	20.22	34,331.23
	0.9	36.13	38,523.11	26.29	36,797.76	19.78	33,364.13
48-20-1	0.5	42.51	41,643.93	32.45	39,625.27	24.68	36,786.64
	0.6	39.42	40,480.74	29.79	38,344.66	22.19	35,156.66
	0.7	39.48	40,019.62	29.80	38,083.70	21.57	34,534.92
	0.8	36.24	38,955.20	26.68	36,840.57	20.12	33,857.94
	0.9	36.92	38,103.36	27.00	36,642.03	20.28	33,825.03
48-30-1	0.5	40.50	41,247.73	30.73	38,938.56	22.72	36,001.33
	0.6	40.62	40,803.39	30.55	38,541.55	22.12	35,462.93
	0.7	40.18	40,793.75	30.33	38,635.92	21.96	35,488.69
	0.8	38.85	39,198.53	28.99	37,418.52	20.42	33,717.99
	0.9	36.21	38,308.76	26.38	36,481.30	19.48	33,356.11

จากตารางที่ 4.3 เมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.2 dropout เท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.5-0.9 พบว่าโครงข่ายประสาทเทียมที่ให้ค่า MAPE ต่ำสุดในชุดข้อมูลทดสอบ (Test) คือ 48-10-1 ซึ่งให้ค่า MAPE เท่ากับ 26.29% มีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 10 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยมีอัตราการเรียนรู้เท่ากับ 0.2 dropout ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.9

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.4 โครงข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.25 และดรอปเอาต์  
ในชั้นซ่อนเท่ากับ 0.1

โครงข่าย	โมเมนตัม	Train		Test		Validation	
		MAPE	MAD	MAPE	MAD	MAPE	MAD
48-10-1	0.5	37.90	41,037.27	28.30	38,578.79	21.50	36,069.42
	0.6	37.68	40,092.28	28.11	37,976.63	21.12	35,026.36
	0.7	37.33	39,285.28	27.71	37,387.96	20.23	34,013.61
	0.8	37.01	38,920.08	27.47	37,160.54	20.41	33,601.96
	0.9	35.96	38,390.27	<b>26.23</b>	36,692.72	19.60	33,459.00
48-20-1	0.5	37.64	40,399.90	28.21	38,009.00	21.00	35,014.90
	0.6	37.88	39,692.86	28.64	37,751.32	21.14	34,646.64
	0.7	37.17	39,458.31	27.73	37,352.93	20.39	34,096.09
	0.8	37.17	38,908.48	27.50	37,050.23	19.88	33,479.34
	0.9	36.99	38,162.71	27.21	36,828.53	19.73	33,833.22
48-30-1	0.5	40.38	40,935.72	30.50	38,785.42	21.96	35,683.45
	0.6	40.60	40,089.51	30.93	38,325.66	22.46	34,639.37
	0.7	38.46	39,482.59	28.84	37,514.50	20.70	34,196.63
	0.8	37.83	38,879.32	28.12	37,076.30	20.42	33,635.44
	0.9	36.14	37,555.21	26.24	36,215.87	20.26	34,835.65

จากตารางที่ 4.4 เมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.25 ดรอปเอาต์ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.5-0.9 พบว่าโครงข่ายประสาทเทียมที่ให้ค่า MAPE ต่ำสุดในชุดข้อมูลทดสอบ (Test) คือ 48-10-1 ซึ่งให้ค่า MAPE เท่ากับ 26.23% มีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 10 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยมีอัตราการเรียนรู้เท่ากับ 0.25 ดรอปเอาต์ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.9

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.5 โครงข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.3 และดรอปเอาท์  
ในชั้นซ่อนเท่ากับ 0.1

โครงข่าย	โมเมนตัม	Train		Test		Validation	
		MAPE	MAD	MAPE	MAD	MAPE	MAD
48-10-1	0.5	37.83	40,132.80	28.27	38,006.99	21.06	34,877.80
	0.6	37.29	39,808.21	27.66	37,684.97	20.63	34,481.28
	0.7	36.75	39,098.52	27.05	37,095.84	20.21	34,124.15
	0.8	36.57	39,036.00	26.92	37,263.47	19.77	33,579.50
	0.9	35.36	38,315.94	25.54	36,547.37	19.89	33,763.72
48-20-1	0.5	38.13	40,319.89	28.61	37,970.20	21.04	34,896.04
	0.6	37.51	39,423.35	27.88	37,444.39	20.44	34,121.65
	0.7	37.79	39,018.15	28.07	37,125.20	20.45	33,946.72
	0.8	36.11	38,595.13	26.33	36,573.42	19.73	33,510.37
	0.9	35.96	37,568.53	25.89	36,242.79	19.38	34,174.17
48-30-1	0.5	37.51	40,559.02	27.97	38,112.52	20.69	35,221.69
	0.6	38.11	39,472.20	28.71	37,577.83	20.74	34,096.55
	0.7	37.29	39,190.22	27.98	37,243.71	20.51	34,112.10
	0.8	37.76	38,570.21	27.84	36,908.56	20.34	33,410.00
	0.9	35.05	37,440.35	<b>25.12</b>	35,940.22	20.44	35,502.27

จากตารางที่ 4.5 เมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.3 ดรอปเอาท์ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.5-0.9 พบว่าโครงข่ายประสาทเทียมที่ให้ค่า MAPE ต่ำสุดในชุดข้อมูลทดสอบ (Test) คือ 48-30-1 ซึ่งให้ค่า MAPE เท่ากับ 25.12% มีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 30 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยมีอัตราการเรียนรู้เท่ากับ 0.25 ดรอปเอาท์ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.9

ตารางที่ 4.6 โครงข่ายประสาทเทียมเมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.35 และดรอปเอาต์  
ในชั้นซ่อนเท่ากับ 0.1


โครงข่าย	โมเมนตัม	Train		Test		Validation	
		MAPE	MAD	MAPE	MAD	MAPE	MAD
48-10-1	0.5	37.39	39,762.65	27.60	37,689.76	20.70	34,614.94
	0.6	36.97	39,242.57	27.38	37,273.84	20.02	33,948.51
	0.7	35.89	39,013.61	26.12	36,948.90	19.68	33,869.42
	0.8	35.93	38,514.35	26.10	36,551.88	19.73	33,558.69
	0.9	35.93	38,352.51	26.06	36,695.97	19.31	33,305.09
48-20-1	0.5	36.52	39,942.08	27.26	37,534.37	20.46	34,697.32
	0.6	37.77	39,738.51	28.05	37,716.92	20.81	34,804.91
	0.7	35.65	38,835.98	26.02	36,717.92	19.73	33,951.40
	0.8	36.36	38,522.50	26.41	36,563.32	19.37	33,371.76
	0.9	34.58	36,837.61	24.80	35,630.36	19.96	35,124.47
48-30-1	0.5	36.86	39,916.27	27.41	37,465.57	20.33	34,756.52
	0.6	37.08	39,048.03	27.63	37,145.38	20.41	34,005.05
	0.7	36.52	38,816.44	26.85	36,793.50	19.77	33,681.09
	0.8	35.92	38,483.35	26.11	36,488.21	19.54	33,655.43
	0.9	36.79	37,088.46	26.60	36,328.63	21.25	36,348.67

จากตารางที่ 4.6 เมื่อกำหนดอัตราการเรียนรู้เท่ากับ 0.35 ดรอปเอาต์ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.5-0.9 พบว่าโครงข่ายประสาทเทียมที่ให้ค่า MAPE ต่ำสุดในชุดข้อมูลทดสอบ (Test) คือ 48-20-1 ซึ่งให้ค่า MAPE เท่ากับ 24.80% มีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 20 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยมีอัตราการเรียนรู้เท่ากับ 0.25 ดรอปเอาต์ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.9

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากการกำหนดค่าอัตราการเรียนรู้ตั้งแต่ 0.1-0.35 ได้ผลดังตารางที่ 4.1-4.6 โครงข่ายประสาทเทียมที่ให้ค่า MAPE ต่ำที่สุดในชุดข้อมูลทดสอบ (Test) คือโครงข่ายประสาทเทียม 48-20-1 ซึ่งเป็นโครงข่ายประสาทเทียมที่มีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 20 โหนด ครอบคลุมเอาทีในชั้นซ่อนเท่ากับ 0.1 และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด ซึ่งข้อมูลทดสอบ (Test) ได้ค่า MAPE เท่ากับ 24.80%

ตัวอย่างการพยากรณ์ยอดขายสินค้า A โดยวิธีโครงข่ายประสาทเทียม 48-20-1 ซึ่งเป็นโครงข่ายประสาทเทียมที่มีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 20 โหนด ครอบคลุมเอาทีในชั้นซ่อนเท่ากับ 0.1 และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 ในพื้นที่การขาย (BranchCode) 25, 43, 60 โดยแยกเป็นขนาดสินค้า (FG\_PackageFormat) ใหญ่ (Big) และเล็ก (Small) ดังรูปต่อไปนี้

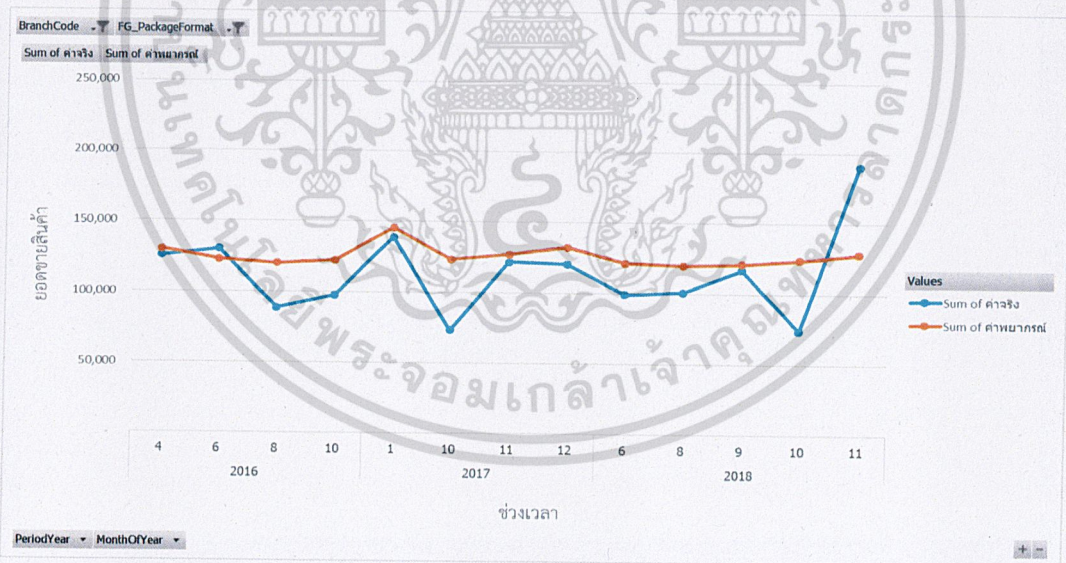


รูปที่ 4.1 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย (BranchCode) 25 ขนาดสินค้า (FG\_PackageFormat) ใหญ่ (Big)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.2 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย (BranchCode) 25 ขนาดสินค้า (FG\_PackageFormat) เล็ก (Small)

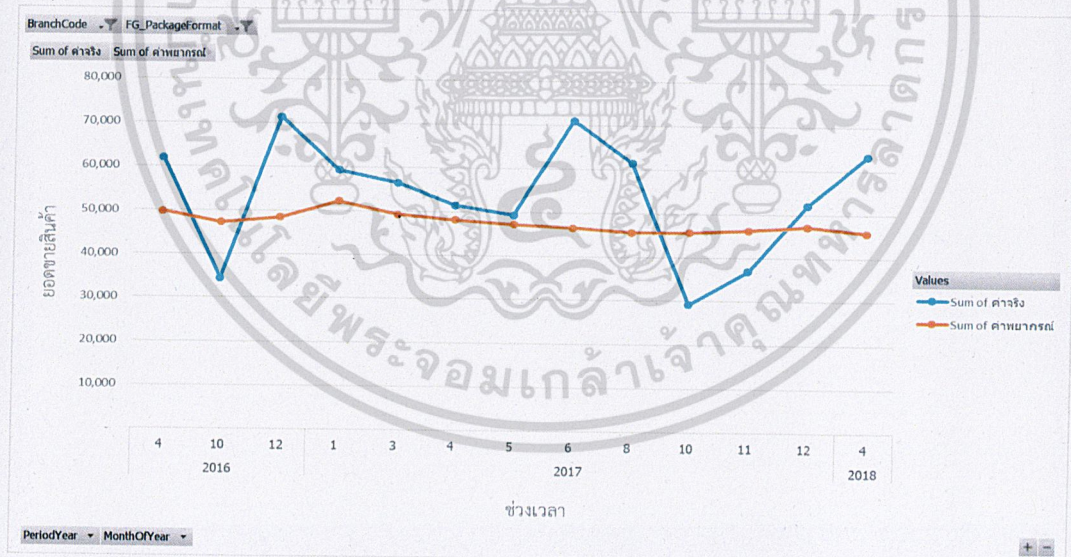


รูปที่ 4.3 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย (BranchCode) 44 ขนาดสินค้า (FG\_PackageFormat) ใหญ่ (Big)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

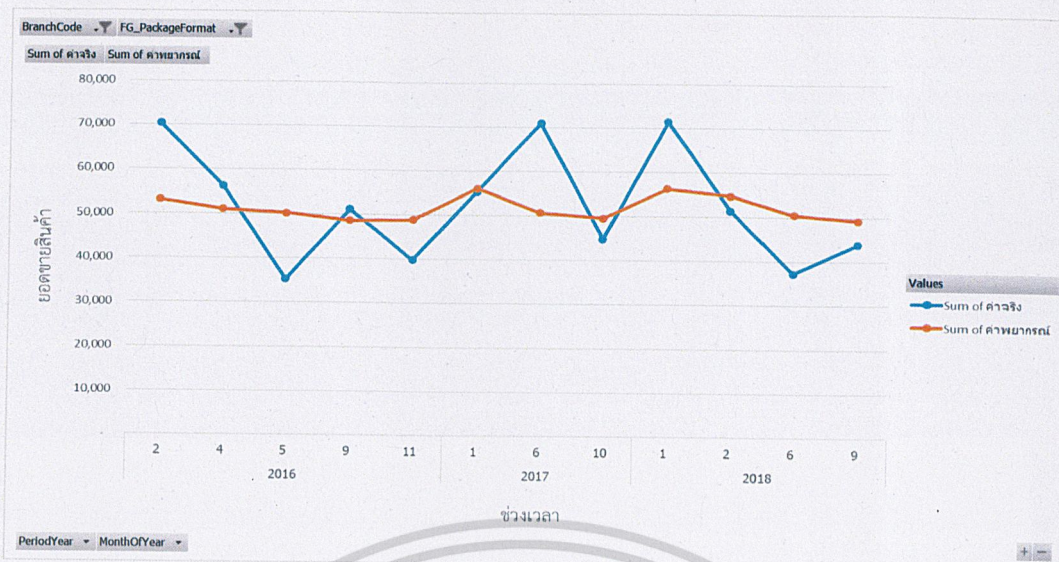


รูปที่ 4.4 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย (BranchCode) 44 ขนาดสินค้า (FG\_PackageFormat) เล็ก (Small)



รูปที่ 4.4 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย (BranchCode) 60 ขนาดสินค้า (FG\_PackageFormat) ใหญ่ (Big)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.6 ยอดขายสินค้า A ที่ได้จากการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในพื้นที่การขาย (BranchCode) 60 ขนาดสินค้า (FG\_PackageFormat) ใหญ่ (Big)

#### 4.2 การเปรียบเทียบประสิทธิภาพของตัวแบบ

การเปรียบเทียบวิธีการพยากรณ์ของบริษัทกับวิธีโครงข่ายประสาทเทียมซึ่งทางบริษัทกำหนดเกณฑ์ในการเลือกตัวแบบโดยจะเลือกจากค่า MAPE ต่ำสุดในชุดข้อมูลทดสอบ (Test) ทำการคำนวณค่า MAPE และ MAD ของข้อมูลฝึกสอน ข้อมูลทดสอบ และข้อมูลทวนสอบของโครงข่ายประสาทเทียมเปรียบเทียบกับวิธีการพยากรณ์ของบริษัทได้ผลดังตารางที่ 4.7

ตารางที่ 4.7 เปรียบเทียบประสิทธิภาพของการพยากรณ์

วิธีการพยากรณ์	ค่าวัดประสิทธิภาพของการพยากรณ์	
	MAPE (%)	MAD (ลิตร)
1.วิธีโครงข่ายประสาทเทียม	24.8	35,630.36
2.วิธีการพยากรณ์ของบริษัท	40.24	57,519.79

จากตารางที่ 4.7 วิธีการพยากรณ์โดยโครงข่ายประสาทเทียมให้ค่า MAPE ในชุดข้อมูลทดสอบ (Test) เท่ากับ 24.80% และวิธีการพยากรณ์ของบริษัทให้ค่า MAPE ในชุดข้อมูลทดสอบ (Test) เท่ากับ 40.24% จากผลที่ได้พบว่าวิธีการพยากรณ์โดยโครงข่ายประสาทเทียมให้ค่า MAPE ต่ำกว่าวิธีการพยากรณ์ของบริษัทและค่า MAD ก็ต่ำกว่าด้วย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สรุปผลการวิจัย อภิปรายผลและข้อเสนอแนะ

### 5.1 สรุปผลการวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาหาตัวแบบพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์ ยอดขายสินค้า A ซึ่งใช้วิธีการพยากรณ์โดยโครงข่ายประสาทเทียม และนำวิธีพยากรณ์โดยโครงข่ายประสาทเทียมเปรียบเทียบกับวิธีการพยากรณ์ของบริษัท โดยใช้ค่าสถิติวัดความถูกต้องคือค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE)

#### 5.1.1 ผลการศึกษาวิธีการพยากรณ์ยอดขายสินค้า A โดยใช้โครงข่ายประสาทเทียม

พบว่าโครงข่ายที่เหมาะสมคือ 48-20-1 ซึ่งให้ค่า MAPE ในชุดข้อมูลทดสอบ (Test) เท่ากับ 24.80% ซึ่งมีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 20 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยมีอัตราการเรียนรู้เท่ากับ 0.25 ครอบเอาท์ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.9

#### 5.1.2 การเปรียบเทียบประสิทธิภาพของตัวแบบการพยากรณ์ยอดขายสินค้า A

จากการเปรียบเทียบประสิทธิภาพของตัวแบบการพยากรณ์ยอดขายสินค้า A โดยวิธีโครงข่ายประสาทเทียมกับวิธีการพยากรณ์ของบริษัท โดยการใช้ค่าสถิติวัดค่าความถูกต้องคือ MAPE พบว่าวิธีโครงข่ายประสาทเทียมให้ค่า MAPE ในชุดข้อมูลทดสอบ (Test) เท่ากับ 24.8% ซึ่งต่ำกว่าวิธีการพยากรณ์ของบริษัทที่ให้ค่า MAPE เท่ากับ 40.24% ดังนั้นตัวแบบที่เหมาะสมสำหรับวิธีการพยากรณ์ยอดขายสินค้าคือตัวแบบที่ได้จากโครงข่ายประสาทเทียม โครงข่าย 48-20-1 ซึ่งมีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 20 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยมีอัตราการเรียนรู้เท่ากับ 0.25 ครอบเอาท์ในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.9

## 5.2 ข้อจำกัด

เนื่องจากผลการวิจัยพบว่าโครงข่ายประสาทเทียม 48-20-1 ซึ่งมีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 20 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยมีอัตราการเรียนรู้เท่ากับ 0.25 ครอบเอาทีในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.9 ยังไม่สามารถใช้พยากรณ์ยอดขายสินค้า A ได้อย่างเหมาะสมเนื่องจากยังมีสาเหตุอื่น ๆ นอกจากเวลาที่มีอิทธิพลต่อยอดขาย

## 5.3 อภิปรายผล

ผลการวิจัยพบว่าโครงข่ายประสาทเทียม 48-20-1 ซึ่งมีจำนวนโหนดในชั้นข้อมูลนำเข้าเท่ากับ 48 โหนด จำนวนโหนดในชั้นซ่อนเท่ากับ 20 โหนด และจำนวนโหนดในชั้นผลลัพธ์เท่ากับ 1 โหนด โดยมีอัตราการเรียนรู้เท่ากับ 0.25 ครอบเอาทีในชั้นซ่อนเท่ากับ 0.1 และค่าโมเมนตัมเท่ากับ 0.9 ซึ่งให้ค่า MAPE เท่ากับ 24.8% และ MAD เท่ากับ 35,630.36 ลิตร ซึ่งต่ำกว่าวิธีการพยากรณ์ของบริษัทซึ่งให้ค่า MAPE เท่ากับ 40.24% และ MAD เท่ากับ 57,519.79 ลิตร อย่างไรก็ตามการนำไปใช้ควรจะต้องระมัดระวังเนื่องจากตัวแบบที่ได้ยังไม่สามารถพยากรณ์ได้อย่างเหมาะสมเนื่องจากยังมีสาเหตุอื่น ๆ นอกจากเวลาที่มีอิทธิพลต่อยอดขาย

## 5.4 ข้อเสนอแนะ

เนื่องจากค่า MAPE ของวิธีการพยากรณ์โดยโครงข่ายประสาทเทียมที่ผู้วิจัยพัฒนาขึ้นยังมีค่าที่สูงและวิธีการพยากรณ์โครงข่ายประสาทเทียมยังไม่สามารถใช้พยากรณ์ยอดขายสินค้า A ได้อย่างเหมาะสมเนื่องจากยังมีสาเหตุอื่น ๆ นอกจากเวลาที่มีอิทธิพลต่อยอดขาย จำเป็นต้องหาตัวแปรอิสระที่มีอิทธิพลต่อยอดขายสินค้า A เพิ่มเติม เช่น ตัวแปรช่วงที่สินค้ามีโปรโมชั่น ตัวแปรทางด้านเศรษฐกิจ หรือเก็บข้อมูลจากลูกค้าว่าปัจจัยใดมีอิทธิพลต่อการซื้อสินค้า ถ้ามีตัวแปรอิสระที่มีผลต่อยอดขายสินค้ามากพออาจจะเลือกใช้วิธีการพยากรณ์แบบอื่น เช่น การวิเคราะห์การถดถอยเชิงเส้นตรงแบบพหุมาใช้เปรียบเทียบกับโครงข่ายประสาทเทียมว่าวิธีใดมีค่า MAPE ต่ำกว่ากัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บรรณานุกรม

- คงฤทธิ โกมาสถิต. 2555. “การพยากรณ์อุปสงค์พลังงานไฟฟ้าของประเทศไทยในระยะยาวด้วยวิธี  
โครงข่ายประสาทเทียม” วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมอุตสาหการณ บัณฑิตวิทยาลัย, จุฬาลงกรณ์มหาวิทยาลัย.
- ชฎานิน บุญมานะ. 2558. “การเปรียบเทียบความแม่นยำของการพยากรณ์ด้วยตัวแบบอนุกรม  
เวลาแบบผสม” วิทยานิพนธ์วิทยาศาสตร์มหาบัณฑิต สาขาวิชาสถิติ บัณฑิตวิทยาลัย,  
จุฬาลงกรณ์มหาวิทยาลัย.
- ธนพล พิมาณ. 2545. “การศึกษาความเหมาะสมของโครงข่ายในแบบจำลองใยประสาทเทียม  
สำหรับพยากรณ์น้ำท่ารายวันในพื้นที่ลุ่มน้ำปราจีนบุรี”  
วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมแหล่งน้ำ บัณฑิตวิทยาลัย,  
จุฬาลงกรณ์มหาวิทยาลัย.
- พรรณนิภา คุ่มสิน. 2560. “การเปรียบเทียบตัวแบบการพยากรณ์ยอดขายเครื่องปรับอากาศโดย  
วิธีปรับให้เรียบเอ็กซ์โพเนนเชียลแบบไฮลท์วินเทอร์ วิธีบ็อกซ์-เจนกินส์  
และวิธีโครงข่ายประสาทเทียม” วิทยานิพนธ์วิทยาศาสตร์มหาบัณฑิต  
สาขาวิชาสถิติประยุกต์ บัณฑิตวิทยาลัย, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง.
- ไพโรจน์ คชชา. 2542. ความรู้คอมพิวเตอร์และเทคโนโลยีสารสนเทศ. พิมพ์ครั้งที่ 1.  
กรุงเทพฯ : เซ็นเตอร์ดีสคัฟเวอรี่.
- มนัสกานต์ เสน่หา. 2559. “การทำนายอายุการใช้งานคงเหลือของเครื่องจักรด้วยเน็ตเวิร์ก  
คอนโวลูชันเชิงลึกที่เพิ่มประสิทธิภาพ” วิทยานิพนธ์วิทยาศาสตร์มหาบัณฑิต  
สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ บัณฑิตวิทยาลัย, จุฬาลงกรณ์มหาวิทยาลัย.
- สายชล สนิมบุญธอง. 2560. การทำเหมืองข้อมูล เล่ม 1 การค้นหาความรู้จากข้อมูล.  
พิมพ์ครั้งที่ 2. กรุงเทพฯ : จามจุรีโปรดักส์.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การพยากรณ์ยอดขายสินค้า A ด้วยวิธีโครงข่ายประสาทเทียมโดยใช้ภาษา Python มีคำสั่งดังต่อไปนี้

```
#import library

import pandas as pd

import numpy as np

from matplotlib import pyplot

from keras.models import Sequential

from keras.layers.core import Dense, Activation, Dropout

from keras import optimizers

%matplotlib inline

#นำข้อมูลเข้า

df_Product = pd.read_csv('Files/Product.csv')

#เลือกเฉพาะข้อมูลยอดขายสินค้า A

df_Product = df_Product[~((df_Product.PeriodYear ==
2019)&(df_Product.MonthOfYear >= 3))]

df_Product = df_Product[~(df_Product.PeriodYear==2015)]

df_Product = df_Product[(df_Product.Product_Brand == 'A')&(df_Product.COLOR ==
'GREEN')]

#ทำความสะอาดข้อมูลยอดขายสินค้า A

df_ProductAC = df_Product.dropna(subset = ['ACTUAL'])

df_ProductAC = df_ProductAC.pivot_table(index =
['PeriodYear','MonthOfYear'],columns =
['Product_Brand','COLOR','FG_PackageFormat','Region','BranchCode'],values = 'ACTUAL',
aggfunc = np.sum)
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

#เลือกพื้นที่การขายที่มีจำนวนเดือนที่ขายสินค้ามากกว่า 80 เปอร์เซนต์

df_ProductAC=df_ProductAC[df_ProductAC.columns[df_ProductAC.isin(['NaN']).sum()/
len(df_ProductAC)*100<20]]

#แทนที่ข้อมูลสูญหายในแต่ละพื้นที่การขายและในแต่ละขนาดสินค้าด้วยค่าเฉลี่ย

df_ProductAC = df_ProductAC.fillna(df_ProductAC.mean()[:])

df_ProductAC = df_ProductAC.reset_index()

df_ProductAC = pd.melt(df_ProductAC,id_vars= ['PeriodYear','MonthOfYear'])

df_ProductAC.rename(columns={'value':'ACTUAL'},inplace=True)

#ข้อมูลการพยากรณ์ยอดขายของวิธีบริษัท

df_Forecast=df_Product[['Product_Brand','COLOR','FG_PackageFormat','BranchCode','Pe
riodYear','MonthOfYear','Forecast']]

df_Forecast = df_Forecast[(df_Forecast.Forecast!=0)]

#JOIN (หลังทำความสะอาดข้อมูลยอดขายสินค้า A)

df = pd.merge(df_ProductAC,df_Forecast,how = 'left',on = ['Product_Brand','COLOR',
'FG_PackageFormat','BranchCode','PeriodYear','MonthOfYear'])

#คำนวณค่า MAPE และ MAD ของวิธีการพยากรณ์ของบริษัท

df['MAPE_Forecast'] = abs((df.ACTUAL - df.Forecast)/df.ACTUAL)*100

df['MAD_Forecast'] = abs(df.ACTUAL - df.Forecast)

df.drop(['COLOR'],axis=1,inplace=True)

df.drop(['Product_Brand'],axis=1,inplace=True)

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#แบ่งข้อมูลปี 2019 ออกมา

```
df_2019 = df[(df.PeriodYear == 2019)]
```

```
df = df[~(df.PeriodYear == 2019)]
```

#ตัดพื้นที่การขายที่มียอดขายสินค้าต่ำกว่า Quantile ที่ 1 ออก

```
df_Group =
```

```
df.groupby(['FG_PackageFormat','BranchCode'])['ACTUAL'].sum().reset_index()
```

```
df_Group.rename(columns={'ACTUAL':'SUM_ACTUAL'},inplace=True)
```

```
df_Group.SUM_ACTUAL.plot.box()
```

```
P1 = df_Group.SUM_ACTUAL.quantile([.25])[0.25]
```

```
df_P = df_Group[df_Group.SUM_ACTUAL > P1]
```

```
df = pd.merge(df,df_P,how = 'inner',on = ['FG_PackageFormat','BranchCode'])
```

```
df.drop(['SUM_ACTUAL'],axis=1,inplace=True)
```

```
df_2019 = pd.merge(df_2019,df_P,how = 'inner',on =
['FG_PackageFormat','BranchCode'])
```

```
df_2019.drop(['SUM_ACTUAL'],axis=1,inplace=True)
```

#แบ่ง Train and Test

```
df_train = df.sample(frac=0.7)
```

```
df_test = df[~df.index.isin(df_train.index)]
```

```
X_train=df_train.drop(['ACTUAL','Forecast','MAPE_Forecast','MAD_Forecast','Region'],axis
=1).reset_index(drop=True)
```

```
Y_train = df_train[['ACTUAL']].reset_index(drop=True)
```

```
X_test=df_test.drop(['ACTUAL','Forecast','MAPE_Forecast','MAD_Forecast','Region'],axis=
1).reset_index(drop=True)
```

เอกสารนี้เป็นเอกสารของบริษัทเอกชนที่จัดทำขึ้นเพื่อใช้ในการดำเนินงานเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

df_testCheck = df_test.reset_index(drop=True)

df_trainCheck = df_train.reset_index(drop=True)

X_2019=df_2019.drop(['ACTUAL','Forecast','MAPE_Forecast','MAD_Forecast','Region'],axis=1).reset_index(drop=True)

Y_2019 = df_2019.reset_index(drop=True)

#สร้าง Dummies

#สร้าง dummies ของ FG_PackageFormat

#X_train

dummiesFG = pd.get_dummies(X_train['FG_PackageFormat'])
X_train= pd.concat([X_train,dummiesFG],axis = 'columns')
X_train.drop(['FG_PackageFormat'],axis=1,inplace=True)

#X_test

dummiesFG = pd.get_dummies(X_test['FG_PackageFormat'])
X_test = pd.concat([X_test,dummiesFG],axis = 'columns')
X_test.drop(['FG_PackageFormat'],axis=1,inplace=True)

#X_2019

dummiesFG = pd.get_dummies(X_2019['FG_PackageFormat'])
X_2019 = pd.concat([X_2019,dummiesFG],axis = 'columns')
X_2019.drop(['FG_PackageFormat'],axis=1,inplace=True)

#สร้าง Dummies ของ BranchCode

#X_train

dummiesBranchCode = pd.get_dummies(X_train['BranchCode'])

X_train = pd.concat([X_train,dummiesBranchCode],axis='columns')

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ภายในเท่านั้น ไม่ควรเผยแพร่หรือใช้เพื่อวัตถุประสงค์อื่นใด  
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

X_train.drop(['BranchCode'],axis=1,inplace=True)

#X_test

dummiesBranchCode = pd.get_dummies(X_test['BranchCode'])

X_test = pd.concat([X_test,dummiesBranchCode],axis='columns')

X_test.drop(['BranchCode'],axis=1,inplace=True)

#X_2019

dummiesBranchCode = pd.get_dummies(X_2019['BranchCode'])

X_2019 = pd.concat([X_2019,dummiesBranchCode],axis='columns')

X_2019.drop(['BranchCode'],axis=1,inplace=True)

# Normalization

# MAX, MIN ของ ACTUAL เก็บไว้ตอนแปลงกลับเป็นหน่วยเดิม

maxAC = Y_train.ACTUAL.max()

minAC = Y_train.ACTUAL.min()

# แปลง ACTUAL

Y_train['ACTUAL_NORM'] = (Y_train.ACTUAL-
Y_train.ACTUAL.min())/(Y_train.ACTUAL.max()-Y_train.ACTUAL.min())

Y_test['ACTUAL_NORM'] = (Y_test.ACTUAL-
Y_train.ACTUAL.min())/(Y_train.ACTUAL.max()-Y_train.ACTUAL.min())

Y_train.drop(['ACTUAL'],axis=1,inplace=True)

Y_test.drop(['ACTUAL'],axis=1,inplace=True)

# แปลง PeriodYear

X_train['PeriodYear_NORM'] = (X_train.PeriodYear - X_train.PeriodYear.min())/
(X_train.PeriodYear.max()-X_train.PeriodYear.min())

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

X_test['PeriodYear_NORM'] = (X_test.PeriodYear - X_train.PeriodYear.min())/
(X_train.PeriodYear.max()-X_train.PeriodYear.min())

X_2019['PeriodYear_NORM'] = (X_2019.PeriodYear - X_train.PeriodYear.min())/
(X_train.PeriodYear.max()-X_train.PeriodYear.min())

X_train.drop(['PeriodYear'],axis=1,inplace=True)

X_test.drop(['PeriodYear'],axis=1,inplace=True)

X_2019.drop(['PeriodYear'],axis=1,inplace=True)

# แปลง MonthOfYear

X_train['MonthOfYear_NORM'] = (X_train.MonthOfYear -
X_train.MonthOfYear.min())/(X_train.MonthOfYear.max()-X_train.MonthOfYear.min())

X_test['MonthOfYear_NORM'] = (X_test.MonthOfYear - X_train.MonthOfYear.min())/
(X_train.MonthOfYear.max()-X_train.MonthOfYear.min())

X_2019['MonthOfYear_NORM'] = (X_2019.MonthOfYear - X_train.MonthOfYear.min())/
(X_train.MonthOfYear.max()-X_train.MonthOfYear.min())

X_train.drop(['MonthOfYear'],axis=1,inplace=True)

X_test.drop(['MonthOfYear'],axis=1,inplace=True)

X_2019.drop(['MonthOfYear'],axis=1,inplace=True)

#Create Model

model = Sequential()

#get number of columns in training data

n_cols = X_train.shape[1]

#add model layers

model.add(Dense(20, activation='sigmoid', input_shape=(n_cols,)))

model.add(Dropout (0.1))

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

model.add(Dense(1, activation='sigmoid'))

sgd = optimizers.SGD(lr=0.35, momentum=0.9)

model.compile(optimizer=sgd, loss='mean_squared_error',metrics=['acc'])

history = model.fit(X_train, Y_train, epochs = 1000,validation_data=(X_test,Y_test))

#Model Loss

import matplotlib.pyplot as plt

plt.plot(history.history['loss'])

plt.plot(history.history['val_loss'])

plt.title('Model loss')

plt.ylabel('Loss')

plt.xlabel('Epoch')

plt.legend(['Train', 'Val'], loc='upper right')

plt.show()

#Make a prediction test_set

yhatTest = model.predict(X_test)

df_predictTest = pd.DataFrame(yhatTest,columns=['yhatTest'])

df_predictTest = pd.concat([df_predictTest,df_testCheck],axis='columns')

df_predictTest['yhatTestTR'] = df_predictTest['yhatTest']*(maxAC-minAC)+minAC

df_predictTest['MAPE'] = abs((df_predictTest['ACTUAL'] -df_predictTest['yhatTestTR'])
/df_predictTest['ACTUAL'])*100

df_predictTest['MAD'] = abs((df_predictTest['ACTUAL']-df_predictTest['yhatTestTR']))

#Make a prediction train_set

yhatTrain = model.predict(X_train)

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

df_predictTrain = pd.DataFrame(yhatTrain,columns=['yhatTrain'])

df_predictTrain = pd.concat([df_predictTrain,df_trainCheck],axis='columns')

df_predictTrain['yhatTrainTR'] = df_predictTrain['yhatTrain']*(maxAC-minAC)+minAC

df_predictTrain['MAPE'] = abs((df_predictTrain['ACTUAL'] -
df_predictTrain['yhatTrainTR']) / df_predictTrain['ACTUAL'])*100

df_predictTrain['MAD'] = abs((df_predictTrain['ACTUAL']-
df_predictTrain['yhatTrainTR']))

#Make a prediction validation

yhat2019 = model.predict(X_2019)

df_2019 = pd.DataFrame(yhat2019,columns=['yhat2019'])

df_2019 = pd.concat([df_2019,Y_2019],axis='columns')

df_2019['yhat2019TR'] = df_2019['yhat2019']*(maxAC-minAC)+minAC

df_2019['MAPE'] = abs((df_2019['ACTUAL'] -df_2019['yhat2019TR'])/ df_2019['ACTUAL'])
*100

df_2019['MAD'] = abs((df_2019['ACTUAL']-df_2019['yhat2019TR']))

df_predictTrain[['MAPE','MAD','MAPE_Forecast','MAD_Forecast']].mean()

df_predictTest[['MAPE','MAD','MAPE_Forecast','MAD_Forecast']].mean()

df_2019[['MAPE','MAD','MAPE_Forecast','MAD_Forecast']].mean()

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้