



รายงานผลการวิจัย

ตัวแบบการพยากรณ์ความต้องการเหล็กภายใต้ความไม่แน่นอนโดยใช้วิธีเบย์

**Forecasting Model for Steel Demand under Uncertainty Using Bayesian
Methods**

ผศ. วัชรินทร์ แสงมา

ดร. พิษณุ ทองขาว

นางสาวอรศิริ จันท์เมือง

งานวิจัยนี้ได้รับทุนสนับสนุนจากงบประมาณ ปี พ.ศ. 2556

มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร

ชื่อเรื่อง : ตัวแบบการพยากรณ์ความต้องการเหล็ก ภายใต้ความไม่แน่นอนโดยวิธีเบย์


ผู้วิจัย : วัชรินทร์ แสงมา พิษณุ ทองขาว และอรศิริ จันทร์เมือง

พ.ศ. : 2556

บทคัดย่อ

งานวิจัยนี้มีจุดประสงค์เพื่อ สร้างตัวแบบการพยากรณ์วิธีการพยากรณ์แบบเบย์สำหรับพยากรณ์ข้อมูลดัชนีปริมาณความต้องการของเหล็กที่มีความไม่แน่นอน ซึ่งได้ทำการประยุกต์ตัวแบบของ Yelland (2010) โดยการปรับค่าฟังก์ชันของค่าพารามิเตอร์ต่างๆ เพื่อให้เหมาะสมกับข้อมูลปริมาณความต้องการเหล็กของไทย โดยเขียนอัลกอริทึมในโปรแกรม OpenBUGS หลังจากนั้นนำตัวแบบที่นำเสนอในงานวิจัยนี้มาเปรียบเทียบกับวิธีพยากรณ์ที่นิยมพยากรณ์ได้ดีกับข้อมูลอนุกรมเวลาในปัจจุบัน ได้แก่วิธีพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล ผลการวิจัยพบว่าตัวแบบที่นำเสนอในงานวิจัยนี้ได้ค่าพยากรณ์ที่มีความผิดพลาดต่ำที่สุด

คำสำคัญ: การพยากรณ์แบบเบย์, ปริมาณความต้องการเหล็ก, วิธีพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล



Title : Forecasting Model for Steel Demand under Uncertainty Using Bayesian Methods

Researcher: Watcharin Sangma , Pitsanu Tongkhow and Onsiri Junmuang

Year : 2013



Abstract

The objective of this research is to propose a forecasting model for uncertain demand index data of steel. The forecasting model proposed by Yelland (2010) was modified by adjusting the prior distributions of some parameters in the model in order that it is suitable for the demand of steel in Thailand. The algorithms for model fitting were written in OpenBUGS. The proposed model was compared to a classical exponential smoothing model. The research found that the forecast errors from the proposed forecasting model were minimum.

Keyword: Bayesian forecasting method, Demand of steel, Exponential smoothing forecasting method

กิตติกรรมประกาศ

การวิจัยนี้สำเร็จลงด้วยดี ด้วยความช่วยเหลือจากหลายท่าน คณะผู้วิจัยขอขอบคุณ อธิการบดีมหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร ผศ. จุฑามาศ พีรพัชระ รักษาการแทน อธิการบดี และผู้อำนวยการสถาบันวิจัยและพัฒนามหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร และ ผศ. ดร. วัลลภ ภูผา คณบดีคณะวิศวกรรมศาสตร์มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร ที่ให้การสนับสนุนการทำงานวิจัยของอาจารย์ในมหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร มาตั้งแต่เริ่มต้น ขอขอบคุณ สำนักงานเศรษฐกิจอุตสาหกรรม รองกรรมการบริหาร ผู้จัดการ วิศวกร และพนักงานโรงงานผลิตเหล็กและเหล็กกล้าของโรงงานตัวอย่าง จังหวัดสมุทรปราการ ที่ช่วยในเรื่องของข้อมูล เป็นอย่างดี ทำนี้คณะผู้วิจัยขอขอบคุณมหาวิทยาลัยเทคโนโลยีราชมงคลพระนครที่ได้ให้ทุนสนับสนุน จนกระทั่งงานวิจัยฉบับนี้สำเร็จลงด้วยดี

คณะผู้วิจัย



สารบัญ

| | หน้า |
|--|------|
| กิตติกรรมประกาศ | ก |
| บทคัดย่อภาษาไทย | ข |
| บทคัดย่อภาษาอังกฤษ | ค |
| สารบัญ | ง |
| บทที่ 1 บทนำ | 1 |
| ความเป็นมาและความสำคัญของปัญหา | 1 |
| วัตถุประสงค์ของการวิจัย | 2 |
| ขอบเขตของการวิจัย | 2 |
| สมมุติฐานในการวิจัย | 2 |
| ประโยชน์ที่คาดว่าจะได้รับ | 2 |
| บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง | 4 |
| ทฤษฎีที่เกี่ยวข้องกับเทคนิคการพยากรณ์ | 4 |
| ทฤษฎีที่เกี่ยวข้องกับอุตสาหกรรมเหล็กและเหล็กกล้าของไทย | 22 |
| งานวิจัยที่เกี่ยวข้อง | 25 |
| บทที่ 3 วิธีดำเนินการวิจัย | 33 |
| ประชากรและกลุ่มตัวอย่าง | 29 |
| เครื่องมือที่ใช้ในการศึกษา | 29 |
| วิธีการดำเนินศึกษา | 29 |
| การสร้างตัวแบบโดยวิธีของเบย์ | 30 |
| การประเมินผลวิจัย | 30 |
| บทที่ 4 ผลการวิจัย | 32 |
| ผลการวิเคราะห์ลักษณะของข้อมูล | 32 |
| ผลการสร้างตัวแบบ | 34 |
| ผลของการประเมินประสิทธิภาพของตัวแบบ | 38 |
| ผลของการประมาณค่าพารามิเตอร์ | 39 |
| ผลของการเปรียบเทียบตัวแบบพยากรณ์ | 41 |
| บทที่ 5 สรุปผลการวิจัย และข้อเสนอแนะ | 44 |

| | |
|--------------------------------|----|
| สรุปผลการวิจัย | 44 |
| ข้อเสนอแนะในการวิจัยครั้งต่อไป | 46 |
| บรรณานุกรม | 49 |
| ภาคผนวก | 51 |
| ประวัติคณะผู้วิจัย | 53 |



บทที่ 1

บทนำ

ความเป็นมาและสำคัญของปัญหา

เหล็กซึ่งใช้เป็นวัตถุดิบในการผลิตของอุตสาหกรรมต่อเนื่องต่างๆ เป็นจำนวนมาก เช่น การก่อสร้าง การผลิตท่อเหล็ก การผลิตถังแก๊ส การผลิตชิ้นส่วนประกอบรถยนต์ การผลิตเครื่องใช้ไฟฟ้า การผลิตเฟอร์นิเจอร์เหล็ก การผลิตตู้คอนเทนเนอร์ การผลิตเหล็กแผ่นรีดเย็น และศูนย์บริการเหล็ก (Service Center) เป็นต้น ซึ่งถือว่าเป็นสินค้าที่มีความต้องการนำมาใช้ในการผลิตและสร้างสิ่งต่างๆตามความต้องการในปัจจุบันเป็นอย่างมาก ดังนั้นอุตสาหกรรมเหล็กของไทยจึงจัดเป็นอุตสาหกรรมพื้นฐานที่สำคัญของประเทศ เนื่องจากเหล็กเป็นวัตถุดิบของอุตสาหกรรมต่อเนื่องหลายประเภท ดังที่กล่าวมาข้างต้น สำหรับผลิตภัณฑ์สำคัญที่มีความโดดเด่นในอุตสาหกรรมเหล็กและเหล็กกล้า ได้แก่ กลุ่มเหล็กทรงยาว เช่น เหล็กเส้น ลวดเหล็ก และกลุ่มเหล็กทรงแบน เช่น เหล็กแผ่นรีดร้อนและรีดเย็น เหล็กแผ่นเคลือบและเหล็กโครงสร้างรูปพรรณ ซึ่งมีความต้องการใช้เหล็กในประเทศมีแนวโน้มเพิ่มสูงขึ้น รวมทั้งความต้องการใช้ของอุตสาหกรรมต่อเนื่องที่มีความเชื่อมโยงกับอุตสาหกรรมอื่นๆ เป็นจำนวนมาก เช่น อุตสาหกรรมยานยนต์ เครื่องใช้ไฟฟ้าและอิเล็กทรอนิกส์ เฟอร์นิเจอร์ บรรจุภัณฑ์ของอาหารกระป๋อง เครื่องจักรกล และอุตสาหกรรมก่อสร้างในประเทศและการส่งออกที่เพิ่มมากขึ้น เป็นเหตุทำให้อุตสาหกรรมเหล็กและเหล็กกล่ามีการใช้งานที่เพิ่มสูงขึ้นอย่างมากเช่นกัน จากราคาเหล็กในตลาดโลกมีแนวโน้มเพิ่มสูงขึ้นอย่างต่อเนื่อง และประกอบกับอุตสาหกรรมก่อสร้างที่มีการขยายตัวสูงขึ้นอย่างมาคนั้น ทำให้อุตสาหกรรมเหล็กและเหล็กกล้ามีการแข่งขันกันสูงในตลาดโลกตามไปด้วย ซึ่งได้ส่งผลมาถึงตลาดในประเทศไทยเช่นกัน และก็ทำให้ปริมาณความต้องการใช้เหล็กมีความผันผวนและไม่มีแน่นอน (การเก็บรวบรวมข้อมูลจากสำนักงานเศรษฐกิจอุตสาหกรรม) ทำให้ผู้วิจัยสนใจที่จะศึกษาถึงการวิเคราะห์ตัวแบบการพยากรณ์ภายใต้ความไม่แน่นอนของปริมาณความต้องการ โดยวิธีเบย์ เพื่อใช้เป็นข้อมูลที่สำคัญอย่างหนึ่งในการวางแผนตัดสินใจเกี่ยวกับการวางแผนการผลิตของระบบอุตสาหกรรมเหล็กและเหล็กกล้าของประเทศไทยในอนาคตได้อย่างมีประสิทธิภาพและมีความแม่นยำมากยิ่งขึ้น ตัวแบบที่ใช้ในการพยากรณ์มีหลากหลายเช่น วิธีการพยากรณ์อย่างง่าย (Naïve method), Multiple Regression, Moving Average (MA), Exponential smoothing (EXPS), ARIMA เป็นต้น แต่ยังมีวิธีการพยากรณ์อีกวิธีหนึ่งที่กำลังได้รับความสนใจอย่างสูงในทุกสาขาคือวิธีการของเบย์ เนื่องจากสามารถแก้ปัญหาตัวแบบที่ซับซ้อนได้ ซึ่งYelland (2010) ก็ได้ประยุกต์ใช้ตัวแบบเบย์ สำหรับการพยากรณ์ปริมาณความต้องการซื้อชิ้นส่วนอุปกรณ์คอมพิวเตอร์

เช่นกัน โดยตัวแบบของเขามีความซับซ้อนมากเพื่อวิเคราะห์ข้อมูลให้ใกล้เคียงกับสภาพความเป็นจริงมากที่สุด โดยมีการนำฟังก์ชันของข้อมูลที่มีความผิดปกติ (outliners) ฟังก์ชันของ Autoregression ที่ซ่อนเร้น (Latent Autoregression) และฟังก์ชันของเวลาที่แสดงปริมาณความต้องการซื้อภาค คังนั้นในงานวิจัยนี้ผู้วิจัยจึงสนใจที่จะใช้ตัวแบบของ Yelland (2010) โดยจะมีการปรับค่าฟังก์ชันของค่าพารามิเตอร์ต่างๆ เพื่อให้เหมาะสมกับข้อมูลปริมาณความต้องการเหล็กและเหล็กกล้าของไทย และเขียนอัลกอริทึมในโปรแกรมคอมพิวเตอร์

วัตถุประสงค์ของการวิจัย

1. เพื่อหาตัวแบบการพยากรณ์ภายใต้ความไม่แน่นอนที่เหมาะสมสำหรับปริมาณความต้องการของอุตสาหกรรมเหล็กและเหล็กกล้าของประเทศไทย

สมมุติฐานของการวิจัย

ทราบฟังก์ชันการแจกแจงความน่าจะเป็นของปริมาณความต้องการเพื่อนำไปสร้างตัวแบบการพยากรณ์ปริมาณความต้องการที่ไม่แน่นอนของข้อมูลอนุกรมเวลาที่ผู้วิจัยเสนอขึ้น โดยใช้วิธีของเบย์ต้องมีค่าต่ำกว่าตัวแบบพยากรณ์ที่นิยมใช้กันอยู่ทั่วไปที่ทำให้ค่าพยากรณ์ที่มีค่าผิดพลาดต่ำได้แก่ วิธีการพยากรณ์แบบปรับเรียบเอ็กซ์โปเนนเชียล (Yelland, 2010)

ขอบเขตของโครงการวิจัย

ปริมาณความต้องการของลูกค้ายรายเดือนจากผู้ผลิตเหล็ก และเหล็กกล้าของประเทศไทย จากสำนักงานเศรษฐกิจอุตสาหกรรม

ประโยชน์ที่คาดว่าจะได้รับ

- 1) ได้ตัวแบบการพยากรณ์ที่สามารถนำไปใช้ในการพยากรณ์ปริมาณความต้องการเหล็กและเหล็กกล้าของไทยได้อย่างแม่นยำยิ่งขึ้น
- 2) ค่าพยากรณ์ที่ได้สามารถนำไปใช้สำหรับวางแผนการผลิตที่เหมาะสมให้กับหน่วยงานของรัฐเพื่อใช้สำหรับวางแผนนโยบายให้กับโรงงานผู้ผลิต ผู้ผลิตสินค้าต่อเนื่อง และผู้มีส่วนเกี่ยวข้องกับอุตสาหกรรมเหล็กต่างๆได้
- 3) เพื่อใช้เป็นข้อมูลในวางแผนการตัดสินใจในอนาคตสำหรับผู้ผลิตเหล็กและเหล็กกล้าในประเทศไทยได้อย่างมีประสิทธิภาพ

- 4) นำตัวแบบการพยากรณ์ที่ได้ไปประยุกต์ใช้กับการพยากรณ์ด้านอื่นๆได้
- 5) ใช้เป็นพื้นฐานในการพัฒนาตัวแบบต่อไป



บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

ตัวแบบการพยากรณ์ความต้องการเหล็ก ภายใต้ความไม่แน่นอน โดยวิธีเบย์ ในครั้งนี้ผู้ศึกษาได้ศึกษาเอกสารและงานวิจัยที่เกี่ยวข้องตามหัวข้อดังต่อไปนี้

ทฤษฎีที่เกี่ยวข้อง
งานวิจัยที่เกี่ยวข้อง

ทฤษฎีที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้องกับเทคนิคการพยากรณ์

ก่อนที่จะทำการตัดสินใจเลือกวิธีการพยากรณ์ใดๆ ควรจะพิจารณาถึงลักษณะรูปแบบของข้อมูลที่กำลังตัดสินใจว่ามีความสอดคล้องกับลักษณะของวิธีการพยากรณ์ใดที่ต้องการจะเลือกใช้สำหรับการพยากรณ์โดยทั่วไป มีหลักเกณฑ์ในการพิจารณาความรู้พื้นฐานที่เกี่ยวข้องดังต่อไปนี้

2.1.1 เทคนิคการพยากรณ์ (Box et al., 1994)

เป็นวิธีการที่ใช้คาดการณ์ข้อมูลในอนาคต โดยคาดว่าจะมีลักษณะเช่นเดียวกับข้อมูลในปัจจุบันหรืออดีต เช่น ข้อมูลยอดขายหรืออุปสงค์ในความเป็นจริง ซึ่งได้รับอิทธิพลจากแนวโน้ม (Trend) ฤดูกาล (Seasonal) วัฏจักร (Cycle) และเหตุการณ์ผิดปกติ (Irregular Variation) ต่างๆ เป็นต้น การพยากรณ์ (Forecasting) มีการนำไปใช้อย่างแพร่หลาย ทั้งทางด้านเศรษฐกิจและสังคม ยกตัวอย่างเช่น การพยากรณ์ความต้องการ ราคา ผลผลิต หรือแม้กระทั่งการพยากรณ์อากาศ อุณหภูมิ ปริมาณน้ำฝน การพยากรณ์เป็นสิ่งที่จำเป็นอย่างมากในการวางแผนในด้านต่างๆ ทั้งนี้ ความแม่นยำ รวดเร็ว เป็นปัจจัยสำคัญในการวัดคุณภาพของการพยากรณ์ เทคนิคหรือวิธีการพยากรณ์ก็ได้มีการพัฒนามาอย่างต่อเนื่องเพื่อตอบสนองต่อความต้องการดังกล่าว ซึ่งเทคนิคการพยากรณ์สามารถแบ่งได้เป็นสองประเภทหลักๆคือ เทคนิคการพยากรณ์เชิงคุณภาพ (Qualitative Forecasting Techniques) และ เทคนิคการพยากรณ์เชิงปริมาณ (Quantitative Forecasting Techniques)

ในส่วนของเทคนิคการพยากรณ์เชิงปริมาณ สามารถแบ่งออกเป็นสองกลุ่มหลักๆ ได้แก่ การพยากรณ์แบบอนุกรมเวลา (Time Series Forecasting) เช่น วิธีนาอิว (Naive) วิธีปรับเรียบ (Exponential Smoothing) วิธี ARIMA วิธีของเบย์ (Bayesian) และ การพยากรณ์แบบวิเคราะห์ความสัมพันธ์ (Causal Forecasting) เช่น วิธีวิเคราะห์ความถดถอย (Regression Analysis) วิธี Econometric วิธี Input-Output นอกจากนี้ก็ยังมีเทคนิคการพยากรณ์สมัยใหม่อีกหลายวิธีที่ได้รับความนิยม เช่น วิธีโครงข่ายประสาทเทียม (Artificial Neural Network, ANN) วิธีจีเนติกอัลกอริทึม (Genetic Algorithms, GA) วิธีตรรกศาสตร์คลุมเครือ สำหรับในงานวิจัยนี้จะขออธิบายเทคนิคการพยากรณ์ที่นิยมใช้ในปัจจุบัน และเทคนิคที่ใช้เป็นพื้นฐานความรู้ในการศึกษาและทำวิจัย

1) วิธีการพยากรณ์อย่างง่าย (Naïve Method) (Bisgaard,2011)

เป็นการพยากรณ์ว่ายอดขายในอนาคตจะเท่ากับยอดขายปัจจุบัน เช่น เดือนมกราคมขายได้ 10 ตัน เดือนกุมภาพันธ์จะขายได้ 10 ตัน เช่นกัน แต่ถ้าเดือนกุมภาพันธ์ขายได้จริง 15 ตัน ก็จะพยากรณ์เดือนมีนาคมว่าขายได้ 15 ตันเช่นกัน การพยากรณ์อย่างง่ายอาจแสดงเป็นแนวโน้มของอุปสงค์ ดังนี้ ถ้าเดือนมกราคมขายได้ 10 ตัน เดือนกุมภาพันธ์ขายได้ 14 ตัน จะพยากรณ์เดือนมีนาคมว่าขายได้ $14 + (14-10)$ เท่ากับ 18 ตัน ถ้าเดือนมีนาคมขายได้จริง 15 ตัน เดือนเมษายนจะมียอดขายพยากรณ์ $15 + (15-14)$ เท่ากับ 16 ตัน และใช้พยากรณ์ฤดูกาลว่าถ้าปีที่แล้วในช่วงเวลานี้ขายได้เท่าไร ปีนี้ก็ควรจะขายได้เท่านั้น วิธีนี้ง่ายและมีค่าใช้จ่ายต่ำ แต่ใช้ได้ ณ กรณีที่อิทธิพลต่างๆ ที่มีต่อยอดขายส่งผลอย่างสม่ำเสมอเท่านั้น แต่ถ้ามีเหตุการณ์ผิดปกติเกิดขึ้น จะทำให้เกิดความคลาดเคลื่อนขึ้นได้

2) วิธีการพยากรณ์แบบถดถอยเชิงพหุ (Multiple Regression) (Yan,2009)

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \beta_k X_{kt} + \varepsilon_t \quad (1)$$

เมื่อ t แทนเวลา โดยที่ $t = 1, \dots, n$

Y_t แทน ตัวแปรตาม ณ เวลา t และ X_{it} แทนตัวแปรอิสระ ณ เวลา t โดยที่ $i = 1, \dots, k$

$\beta_0, \beta_1, \beta_2, \dots, \beta_k$ แทน ค่าคงที่ และ ε_t แทน ค่าความผิดพลาด ณ เวลา t และเป็นอิสระกัน โดย ε_t จะมีการแจกแจงแบบปกติ มีค่าเฉลี่ย เท่ากับ 0 และค่าความแปรปรวน คือ σ^2 สำหรับ

$$\text{การพยากรณ์ ณ เวลา } t \text{ จะได้ } \hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 X_{1t} + \hat{\beta}_2 X_{2t} + \dots + \hat{\beta}_k X_{kt} + \varepsilon_t \quad (2)$$

เมื่อ $\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$ ได้จากการประมาณค่าโดยวิธี maximum likelihood

3) วิธีการพยากรณ์แบบค่าเฉลี่ยเคลื่อนที่ (Moving Average (MA)) (Bisgaard,2011)

$$F_{t+1} = \frac{y_t + y_{t-1} + y_{t-2} + \dots + y_{t+1-n}}{N} \quad (3)$$

เมื่อ N = ขนาดของ moving average โดยที่ $N = 1, \dots, n$

ตัวอย่างเช่น

$$F_4 = \frac{y_3 + y_2 + y_1}{3}$$

$$F_5 = \frac{y_4 + y_3 + y_2 + y_1}{4}$$

เมื่อ

$$N = 1 \rightarrow F_2 = y_1, F_3 = y_2, \dots$$

$$N = n \rightarrow F_{n+1} = \bar{y}$$

ถ้า N เป็นคู่คี่ใด ๆ จะสามารถกำจัดฤดูกาลไปได้ในตัว

สำหรับวิธี Moving Average ที่ได้กล่าวมาแล้ว ยังมีวิธี double MA, triple MA และ centered MA อีก เช่น 2×2 MA, 3×5 MA, $3 \times 3 \times 5$ MA เป็นต้น

กรณีมี trend ในข้อมูล

ให้ใช้วิธี MA และ double MA โดยกำหนดให้มี moving average length ที่เท่ากันดังนี้

$$F_{t+m} = a_t + b_t m, \quad \text{โดยที่ } m = 1, 2, 3, \dots \quad (4)$$

เมื่อ

$$a_t = 2S'_t - S''_t$$

$$b_t = \frac{2}{N-1} (S'_t - S''_t)$$

$$S'_t = \frac{1}{N} (y_t + y_{t-1} + y_{t-2} + \dots + y_{t+1-n})$$

$$S''_t = \frac{1}{N} (S'_t + S'_{t-1} + S'_{t-2} + \dots + S'_{t+1-n})$$

4) วิธีการพยากรณ์แบบ Exponential Smoothing (EXPS) (Montgomery,2008)

Exponential smoothing เป็นการพยากรณ์โดยกำหนดน้ำหนักให้ค่าสังเกตในปัจจุบันมีค่ามากกว่าน้ำหนักของค่าสังเกตก่อนหน้านั้น มี 3 แบบคือ

1. Single exponential smoothing

ตัวแบบการพยากรณ์แบบ Single exponential smoothing นิยามดังนี้

ให้ S_t แทนค่าพยากรณ์ของค่าสังเกต Y_t ณ เวลา t เมื่อ $t=1, \dots, n$

$$S_t = \alpha Y_t + (1-\alpha)S_{t-1}, \quad 0 \leq \alpha \leq 1 \quad (5)$$

ค่าพยากรณ์ S_t ไม่เกิดขึ้นเนื่องจากไม่มีเทอม S_0 นอกเสียจากจะกำหนดค่าเริ่มต้นให้ S_0 เทคนิคนี้ใช้สำหรับข้อมูลที่ ไม่มี trend และ seasonal ถ้าข้อมูลมี trend จะใช้ Double exponential smoothing และถ้ามีทั้ง trend และ seasonal จะใช้ Triple Exponential Smoothing

2. Double exponential smoothing หรือ Holt's method

ตัวแบบการพยากรณ์แบบ Double exponential smoothing ได้จากขยายตัวแบบของ Single exponential smoothing ออกไปดังนี้

$$S_t = \alpha Y_t + (1-\alpha)(S_{t-1} + A_{t-1}), \quad 0 \leq \alpha \leq 1 \quad (6)$$

$$\text{โดยที่ } A_t = \beta(S_t - S_{t-1}) + (1-\beta)A_{t-1}, \quad 0 \leq \beta \leq 1 \quad (7)$$

เมื่อ β คือค่าคงที่แสดง trend

3. Triple Exponential Smoothing หรือ Holt-Winters method

ตัวแบบการพยากรณ์แบบ Triple exponential smoothing ได้จากขยายตัวแบบของ Double exponential smoothing ออกไป มี 2 แบบคือ

3.1 Multiplicative Seasonal Model

$$S_t = \alpha(Y_t / B_{t-s}) + (1-\alpha)(S_{t-1} + A_{t-1}), \quad 0 \leq \alpha \leq 1, \quad (8)$$

$$A_t = \beta(S_t - S_{t-1}) + (1-\beta)A_{t-1}, \quad 0 \leq \beta \leq 1, \quad (9)$$

$$B_t = \gamma(Y_t / S_t) + (1-\gamma)B_{t-s}, \quad 0 \leq \gamma \leq 1, \quad (10)$$

เมื่อ γ คือค่าคงที่แสดง seasonal และ s คือความยาวช่วงของ seasonal ใช้ตัวแบบการพยากรณ์นี้เมื่อข้อมูลมี seasonal เป็นแบบการคูณ (multiplicative seasonality) คือในเวลาเดียวกันของแต่ละฤดูกาล ค่าสังเกตจะเพิ่มขึ้นหรือลดลงเป็นค่าร้อยละ ตัวอย่างเช่นข้อมูลรายเดือน 5 ปี ความยาวช่วงของ seasonal คือ 12 และข้อมูลปรากฏให้เห็นว่าในเดือนธันวาคมของแต่ละปี ค่าสังเกตจะเพิ่มขึ้นร้อยละ 40 ไม่ใช่เพิ่มขึ้นหรือลดลงเป็นค่าคงที่

3.2 Additive Seasonal Model

$$S_t = \alpha(Y_t - B_{t-s}) + (1-\alpha)(S_{t-1} + A_{t-1}), 0 \leq \alpha \leq 1, \quad (11)$$

$$A_t = \beta(S_t - S_{t-1}) + (1-\beta)A_{t-1}, 0 \leq \beta \leq 1, \quad (12)$$

$$B_t = \gamma(Y_t - S_t) + (1-\gamma)B_{t-s}, 0 \leq \gamma \leq 1, \quad (13)$$

เมื่อ γ คือค่าคงที่แสดง seasonal และ s คือความยาวช่วงของ seasonal ใช้ตัวแบบการพยากรณ์นี้เมื่อข้อมูลมี seasonal เป็นแบบการบวก (additive seasonality) คือในเวลาเดียวกันของแต่ละฤดูกาล ค่าสังเกตจะเพิ่มขึ้นหรือลดลงเป็นค่าคงที่ ในทางปฏิบัติเราไม่ทราบว่าจะต้องกำหนดค่า moving average length เท่าไรดี จึงจะทำให้ ค่า error หรือ mean square error (MSE) หรือ ค่าวัดความผิดพลาดอื่นๆ ให้ค่าต่ำที่สุด ดังนั้นเราควรจะต้องกำหนดค่า α ให้เหมาะสม

5) วิธีการพยากรณ์แบบ Autoregressive Integrated Moving Average Model (ARIMA)

(Montgomery,2008)

แบบจำลอง ARIMA เป็นแบบจำลองที่ได้รับความนิยม และเป็นวิธีที่ให้ค่าพยากรณ์ในระยะสั้นที่ดี อีกทั้งในการจัดทำสมการและการพยากรณ์ยังมีขั้นตอนที่ยุ่งยาก และซับซ้อนน้อยกว่าแบบมหภาคที่อยู่ในลักษณะระบบสมการหลายชั้น สำหรับแบบจำลอง ARIMA เป็นแบบจำลองที่พัฒนาโดย George E.P.Box และ Gwilym M. Jenkins ในปี ค.ศ. 1970 โดยพื้นฐานแล้วแบบจำลอง ARIMA เป็นวิธีที่ให้ค่าพยากรณ์ในระยะสั้นที่ดี หรือเหมาะกับการพยากรณ์ไปข้างหน้าในช่วงเวลาสั้นๆ และต้องมีช่วงของข้อมูลที่ยาวพอสมควร แบบจำลอง ARIMA(p,d,q) ประกอบด้วย 3 ส่วนหลักๆ ได้แก่ แบบจำลอง Auto Regressive (AR(p)) กระบวนการ Integrated (I(d)) และแบบจำลอง Moving Average (MA(q)) โดยรายละเอียดของแต่ละส่วนมีดังนี้

1. แบบจำลอง Auto Regressive (AR(p))

แบบจำลอง Auto Regressive เป็นรูปแบบที่แสดงว่าค่าสังเกต y_t ถูกกำหนดจากค่าของ y_t, \dots, y_{t-p} หรือ ค่าสังเกตที่เกิดขึ้นก่อนหน้า p โดยกระบวนการหรือระบบ AR(p) คือกระบวนการหรือระบบ Auto Regressive ที่มีอันดับที่ p ซึ่งเขียนอยู่ในรูปสมการได้ดังนี้

$$AR(p) \text{ คือ } x_t = \mu + \phi_1 y_{t-1} + \phi_2 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (14)$$

โดยที่

μ คือ ค่าคงที่ (Constant Term)

ϕ_j คือ พารามิเตอร์ตัวที่ j

ε_t คือ ความคลาดเคลื่อน ณ เวลา t

ในกรณี ของ AR(1) สามารถเขียนรูปแบบสมการได้ดังนี้

$$y_t = \mu + \phi_1 y_{t-1} + \varepsilon_t \quad (15)$$

หรือ

$$y_t - \phi_1 y_{t-1} = \mu + \varepsilon_t \quad (16)$$

หรือ

$$(1 - \phi_1 \beta) x_t = \mu + \varepsilon_t \quad (17)$$

เมื่อ β คือ backward shift operation

และในกรณี ของ AR(2) สามารถเขียนรูปแบบสมการได้ดังนี้

$$y_t = \mu + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \varepsilon_t \quad (18)$$

หรือ

$$y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} = \mu + \varepsilon_t \quad (19)$$

หรือ

$$(1 - \phi_1 \beta - \phi_2 \beta^2) y_t = \mu + \varepsilon_t \quad (20)$$

2. แบบจำลอง Moving Average (MA(q))

แบบจำลอง Moving Average (MA) เป็นรูปแบบที่แสดงว่าค่าสังเกต y_t ถูกกำหนดจากค่าความคลาดเคลื่อน $\varepsilon_{t-1}, \dots, \varepsilon_{t-p}$ หรือค่าความคลาดเคลื่อนที่อยู่ก่อนหน้า โดยกระบวนการหรือระบบ MA(q) คือกระบวนการหรือระบบ Moving Average ที่มีอันดับ q ซึ่งเขียนในรูปของ MA (q) ได้ดังนี้

$$\text{MA (q) คือ } y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (21)$$

โดยที่

μ คือ ค่าคงที่ (Constant Term)

θ_j คือ พารามิเตอร์ตัวที่ j

ε_t คือ ความคลาดเคลื่อน ณ เวลา t

ในกรณี MA(1) สามารถเขียนรูปแบบสมการได้ดังนี้

$$y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (22)$$

หรือ

$$y_t = \mu + (1 - \theta_1 \beta) \varepsilon_t \quad (23)$$

และในกรณี MA(2) สามารถเขียนรูปแบบสมการได้ดังนี้

$$y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} \quad (24)$$

หรือ

$$y_t = \mu + (1 - \theta_1 \beta - \theta_2 \beta^2) \varepsilon_t \quad (25)$$

3. แบบจำลอง Auto Regressive Moving Average (ARMA(p,q))

เป็นแบบจำลองที่นำเอากระบวนการ Auto Regressive และ Moving Average มาใช้รวมกัน โดยกระบวนการหรือระบบ ARMA(p,q) คือกระบวนการหรือระบบ Auto Regressive ที่มีอันดับที่ p และ Moving Average ที่มีอันดับ q ซึ่งเขียนอยู่ในรูปสมการได้ดังนี้

$$\Delta_t y_t = \delta + \phi y_{t-1} + \phi y_{t-2} + \dots + \phi y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (26)$$

โดยที่

y_t คือ ค่าสังเกตในอนุกรมเวลา ณ เวลา t

p คือ อันดับของ Autoregressive

q คือ อันดับของ Moving Average

δ คือ ค่าคงที่ (Constant Term)

t คือ เวลา

ϕ คือ พารามิเตอร์ของ Auto Regressive

θ คือ พารามิเตอร์ของ Moving Average

ε_t คือ กระบวนการ white noise ซึ่งก็คือ ค่าความคลาดเคลื่อน ณ เวลา t

4. กระบวนการ Integrated (I (d))

กระบวนการ Integrated (I(d)) เป็นการหาผลต่างของอนุกรมเวลาระหว่างข้อมูล ณ ปัจจุบัน กับข้อมูลถอยหลังไป d คาบเวลา โดยสาเหตุที่ต้องทำการหาผลต่างของอนุกรมเวลา เนื่องจากแบบจำลอง ARIMA ต้องใช้ในการวิเคราะห์ข้อมูลอนุกรมเวลาที่มีคุณสมบัติคงที่ (Stationary) เท่านั้น โดยในกรณีข้อมูลอนุกรมเวลาที่ใช้ในการวิเคราะห์มีคุณสมบัติไม่คงที่ (Nonstationary) จะต้องทำการแปลงข้อมูลดังกล่าวให้เป็นข้อมูลที่มีคุณสมบัติคงที่

ก่อน โดยการหาผลต่างของข้อมูลอนุกรมเวลาก่อนที่นำไปสร้างแบบจำลอง ARIMA ซึ่งโดยทั่วไปแล้วถ้าต้องการหาผลต่างอันดับที่ d สามารถเขียนในรูปของ $I(d)$ ได้ดังนี้

$$I(d) \text{ คือ } \Delta_d x_t = \Delta_{d-1}(x_t - x_{t-1}) \text{ หรือ } (1-\beta)^d x_t \quad (27)$$

ในกรณี $I(1)$ สามารถเขียนรูปแบบได้ดังนี้

$$I(1) \text{ คือ } \Delta x_t = (x_t - x_{t-1}) \text{ หรือ } (1-\beta)x_t$$

ในกรณี $I(2)$ สามารถเขียนรูปแบบได้ดังนี้

$$I(2) \text{ คือ } \Delta_2 x_t = \Delta(x_t - x_{t-1}) \text{ หรือ } (1-\beta)^2 x_t$$

โดยที่

ε_t คือ พจน์ความคลาดเคลื่อน ณ เวลา t

$(1-\beta)^d x_t$ คือ ผลต่างอันดับที่ d

β คือ Backward shift operation

จากรายละเอียดต่างๆ ที่กล่าวข้างต้นถ้านำแบบจำลอง Auto Regressive แบบจำลอง Moving Average และ กระบวนการ Integrated มาพิจารณารวมกันสามารถนำมากำหนดเป็นรูปแบบทั่วไปของแบบจำลอง ARIMA ที่ใช้ในการประมาณการคือ

$$\Delta_d y_t = \delta + \phi \Delta_d y_{t-1} + \phi \Delta_d y_{t-2} + \dots + \phi \Delta_d y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (28)$$

โดยที่

y_t คือ ค่าสังเกตในอนุกรมเวลา ณ เวลา t

d คือ จำนวนครั้งของการหาผลต่างเพื่อให้อนุกรมเวลามีคุณสมบัติคงที่ (Stationary)

p คือ อันดับของ Autoregressive

q คือ อันดับของ Moving Average

δ คือ ค่าคงที่ (Constant Term)

t คือ เวลา

Δ_d คือ ผลต่างอันดับที่ d

ϕ_1, \dots, ϕ_p คือ พารามิเตอร์ของ Auto Regressive

$\theta_1, \dots, \theta_q$ คือ พารามิเตอร์ของ Moving Average

ε_t คือ กระบวนการ white noise ซึ่งก็คือ ค่าความคลาดเคลื่อน ณ เวลา t

ภายใต้ข้อสมมติที่ว่าความคลาดเคลื่อนที่คนละเวลาเป็นตัวแปรสุ่มที่เป็นอิสระต่อ

กันโดยมีการแจกแจงปกติที่มีค่าเฉลี่ยเป็นศูนย์ และความแปรปรวนคงที่
 ดังนั้นเพื่อให้ง่ายขึ้นสำหรับการหาค่าพยากรณ์ Y_t ของ ARIMA สามารถหาได้
 จากนิยามที่สรุปไว้ต่อไปนี้

$$(1 - \phi_1\beta - \phi_2\beta^2 - \dots - \phi_p\beta^p)(1 - \beta)^d Y_t = (1 - \omega_1\beta - \omega_2\beta^2 - \dots - \omega_q\beta^q)\varepsilon_t \quad (29)$$

$$\text{เมื่อ } \beta Y_t = Y_{t-1}, \beta^2 Y_t = Y_{t-2}, \beta^3 Y_t = Y_{t-3}, \dots \quad (30)$$

$$\beta\varepsilon_t = \varepsilon_{t-1}, \beta^2\varepsilon_t = \varepsilon_{t-2}, \beta^3\varepsilon_t = \varepsilon_{t-3}, \dots \quad (31)$$

ตัวอย่างเช่น

ARIMA(0,1,0) คือ

$$\begin{aligned} (1 - \beta)Y_t &= \varepsilon_t \\ Y_t - \beta Y_t &= \varepsilon_t \\ Y_t - Y_{t-1} &= \varepsilon_t \\ Y_t &= Y_{t-1} + \varepsilon_t \end{aligned} \quad (32)$$

ARIMA(2,1,2) คือ

$$\begin{aligned} (1 - \phi_1\beta - \phi_2\beta^2)(1 - \beta)Y_t &= (1 - \omega_1\beta - \omega_2\beta^2)\varepsilon_t \\ (1 - \phi_1\beta - \phi_2\beta^2)(Y_t - \beta Y_t) &= \varepsilon_t - \omega_1\beta\varepsilon_t - \omega_2\beta^2\varepsilon_t \\ (Y_t - \phi_1\beta Y_t - \phi_2\beta^2 Y_t) - (\beta Y_t - \phi_1\beta^2 Y_t - \phi_2\beta^3 Y_t) &= \varepsilon_t - \omega_1\varepsilon_{t-1} - \omega_2\varepsilon_{t-2} \\ Y_t - \phi_1\beta Y_t - \phi_2\beta^2 Y_t - \beta Y_t + \phi_1\beta^2 Y_t + \phi_2\beta^3 Y_t &= \varepsilon_t - \omega_1\varepsilon_{t-1} - \omega_2\varepsilon_{t-2} \\ Y_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - Y_{t-1} + \phi_1 Y_{t-2} + \phi_2 Y_{t-3} &= \varepsilon_t - \omega_1\varepsilon_{t-1} - \omega_2\varepsilon_{t-2} \\ Y_t - \phi_1 Y_{t-1} - Y_{t-1} - \phi_2 Y_{t-2} + \phi_1 Y_{t-2} + \phi_2 Y_{t-3} &= \varepsilon_t - \omega_1\varepsilon_{t-1} - \omega_2\varepsilon_{t-2} \\ Y_t - (\phi_1 - 1)Y_{t-1} - (\phi_2 - \phi_1)Y_{t-2} + \phi_2 Y_{t-3} &= \varepsilon_t - \omega_1\varepsilon_{t-1} - \omega_2\varepsilon_{t-2} \\ Y_t &= (\phi_1 - 1)Y_{t-1} + (\phi_2 - \phi_1)Y_{t-2} - \phi_2 Y_{t-3} + \varepsilon_t - \omega_1\varepsilon_{t-1} - \omega_2\varepsilon_{t-2} \end{aligned} \quad (33)$$

ตัวแบบ ARIMA ใช้วิเคราะห์ข้อมูลได้ทั้งแบบ stationary และ nonstationary ข้อมูล stationary คือข้อมูลที่ mean และ variance ไม่เปลี่ยนแปลงไปตามเวลา ข้อมูล nonstationary คือข้อมูลที่ mean หรือ variance เปลี่ยนแปลงไปตามเวลา ค่า variance ทำให้ stationary ได้โดยการแปลงข้อมูลด้วยฟังก์ชันลอการิทึม (Log transform) ซึ่งต้องทำก่อนใช้ตัวแบบ A สำหรับค่า mean ทำให้ stationary ได้โดยการทำผลต่างข้อมูล (differencing) ซึ่งสามารถทำในตัวแบบ ARIMA ได้ โดยการกำหนดค่าให้กับ d ส่วนระดับของ autocorrelation (p) และระดับของ moving average (q) พิจารณาได้จากกราฟ (Autocorrelation function) ACF และ Partial autocorrelation function (PACF) (Montgomery,2008)

5. Autocorrelation Function (ACF)

เป็นฟังก์ชันของการวัดสหสัมพันธ์ระหว่างข้อมูล ณ เวลา t (x_t) และ ข้อมูล ณ เวลา $t-k$ (x_{t-k}) ของช่วงเวลาห่างกัน k หน่วย ซึ่งแทนด้วยสัญลักษณ์ ρ_k หรือ r_k ในกรณีสหสัมพันธ์ในตัวเองของตัวอย่าง ซึ่งสามารถคำนวณได้ดังนี้

$$\rho_k \text{ หรือ } r_k = \frac{\sum_{t=k+1}^n (x_t - \bar{x})(x_{t-k} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2} \quad (34)$$

เมื่อ $\bar{x} = \frac{1}{n} \sum_{t=1}^n x_t$ และ $k = 0, 1, 2, 3, \dots$

โดยความคลาดเคลื่อนมาตรฐานของ r_k (Standard Error of r_k) ซึ่งมีสูตรในการคำนวณดังนี้

$$se_{r_k} = \frac{1}{\sqrt{n}} \quad (35)$$

สหสัมพันธ์ในตัวเองของข้อมูลสุ่ม (random data) มีการแจกแจงเชิงตัวอย่างที่สามารถประมาณได้ โดยการแจกแจงปกติด้วยค่าเฉลี่ย (mean) เท่ากับศูนย์ และความคลาดเคลื่อนมาตรฐานเท่ากับ $\frac{1}{\sqrt{n}}$

ในการศึกษาจะใช้สหสัมพันธ์ในตัวเองเป็นเครื่องมือที่สำคัญสำหรับสืบค้นคุณสมบัติของข้อมูลอนุกรมเวลาเชิงประจักษ์ โดยมี 2 วิธีสำหรับทดสอบว่าค่า r_k มีค่าแตกต่างไปจากศูนย์หรือไม่โดยใช้การแจกแจงปกติมาตรฐาน (Standard Normal Distribution) หรือ ใช้ค่าสถิติ Box-Pierce Q statistic ซึ่งมีรูปแบบดังนี้

การแจกแจงปกติมาตรฐาน (Standard Normal Distribution)

$$r_k \sim N\left(0, \frac{1}{\sqrt{n}}\right)$$

ค่าสถิติ Box-Pierce Q statistic

$$Q = n \sum_{k=1}^m r^2 \sim \chi^2(m - p - q)$$

โดยที่ m คือค่าล่าหรือค่าล่าหลังสูงสุด (Maximum Lag) ที่พิจารณา

6. Partial Autocorrelation Function (PACF)

เป็นการพิจารณาสหสัมพันธ์ระหว่างตัวแปร x_t กับ x_{t-k} อาจเป็นไปได้ว่าสหสัมพันธ์ดังกล่าวเป็นผลเนื่องมาจากสหสัมพันธ์ระหว่าง 2 ตัวแปรนี้กับตัวแปร $x_{t-1}, \dots, x_{t-k+1}$ ดังนั้น

เพื่อที่จะได้สหสัมพันธ์ระหว่าง x_t กับ x_{t-k} ที่ได้ขจัดความเกี่ยวข้องระหว่างตัวแปรทั้งสองตัวนี้ กับตัวแปร $x_{t-1}, \dots, x_{t-k+1}$ ดังกล่าว จึงต้องทำการวัดสหสัมพันธ์ของทั้งสองตัวแปรในรูปแบบของการสหสัมพันธ์แบบมีเงื่อนไข $Corr(x_t, x_{t-k} | x_{t-1}, \dots, x_{t-k+1})$ ซึ่งเรียกว่า Partial Autocorrelation โดยแทนด้วยสัญลักษณ์ ϕ_{kk} แต่ถ้านำสหสัมพันธ์ในตัวเองบางส่วนมาพิจารณาในรูปแบบฟังก์ชัน จะเรียกว่า Partial Autocorrelation Function (PACF) ซึ่ง ϕ_{kk} สามารถคำนวณได้ดังนี้

$$\phi_{kk} = \frac{Cov[(x_t - \hat{x}_t), (x_{t-k} - \hat{x}_{t-k})]}{\sqrt{Var(x_t - \hat{x}_t)}\sqrt{Var(x_{t-k} - \hat{x}_{t-k})}} \quad (36)$$

$$\text{โดยที่} \quad \hat{x}_t = \beta_1 x_{t-1} + \beta_2 x_{t-2} + \dots + \beta_k x_{t-k+1} \quad (37)$$

6) วิธีการพยากรณ์แบบ Seasonal Autoregressive Integrated Moving Average Model (SARIMA) (Montgomery,2008), (Bisgaard,2011)

วิธีการพยากรณ์แบบ SARIMA ถูกพัฒนามาจากวิธีการพยากรณ์ ARIMA (p,d,q) โดยได้เพิ่ม (P,D,Q) ของ Seasonal เข้าไปอีก SARIMA หรือ Seasonal ARIMA แทนด้วย ARIMA (p,d,q)(P,D,Q) และถ้ามีตัวแปรร่วม (covariate) X_{1t} และ X_{2t} สามารถนิยามได้ดังต่อไปนี้

$$\varnothing(\beta)[\Delta(Y_t - c_1 X_{1t} - c_2 X_{2t}) - \mu] = \Theta(\beta)\varepsilon_t \quad (38)$$

เมื่อ c_1 และ c_2 คือสัมประสิทธิ์การถดถอย

$\varnothing(\beta) = \phi_p(\beta)\varnothing_p(\beta^s)$ และ $\Theta(\beta) = \theta_q(\beta)\Theta_q(\beta^s)$ โดยที่

$\phi_p(\beta) = 1 - \phi_1\beta - \dots - \phi_p\beta^p$, $\theta_q(\beta) = 1 - \theta_1\beta - \dots - \theta_q\beta^q$,

$\varnothing_p(\beta^s) = 1 - \varnothing_1\beta^s - \dots - \varnothing_p\beta^{sp}$, และ $\Theta_q(\beta^s) = 1 - \Theta_1\beta^s - \dots - \Theta_q\beta^{sq}$. Δ คือ differencing

operator, $\Delta = (1 - \beta)^d(1 - \beta^s)^D$. β คือ backshift operator และ $\beta Y_t = Y_{t-1}$, $\beta^2 Y_t = Y_{t-2}$ เป็น

แบบนี้ต่อไป s คือ seasonal lag และ ε_t คือ ความผิดพลาด (error)ที่มีการแจกแจงแบบปกติมี

ค่าเฉลี่ยเป็น 0 และความแปรปรวน σ^2 . \varnothing 's และ ϕ 's คือพารามิเตอร์ autoregressive แบบ

seasonal และ non-seasonal ตามลำดับ Θ 's และ θ 's คือพารามิเตอร์ moving average แบบ

seasonal และ non-seasonal ตามลำดับ p และ q คือลำดับ (order) ของพารามิเตอร์

autoregressive แบบ non-seasonal และ พารามิเตอร์ moving average แบบ non-seasonal

ตามลำดับโดยที่ P และ Q คือ ลำดับ (order) ของพารามิเตอร์ autoregressive แบบ seasonal และ พารามิเตอร์ moving average แบบ seasonal ตามลำดับ d และ D แทน non-seasonal และ seasonal differencesตามลำดับ

7) วิธีการใช้วิจารณ์ (Judgment Method) (Bisgaard,2011)

เป็นวิธีการที่ใช้เมื่อไม่มีข้อมูลในอดีตเพียงพอที่จะใช้พยากรณ์ เช่น ต้องการพยากรณ์ยอดขายของสินค้าใหม่ หรือเมื่อมีความก้าวหน้าทางเทคโนโลยีเกิดขึ้น การพยากรณ์แบบนี้วิธีมีส่วนใหญ่ด้วยกันคือ

1. การประมาณการของพนักงานขาย (Sale Force Estimates) ใช้การประมาณการของพนักงานขายซึ่งเป็นผู้ที่ได้สัมผัสกับสภาพของตลาดมากที่สุด ใกล้ชิดกับลูกค้ามากที่สุด พนักงานขายจะพยากรณ์โดยรวบรวมยอดขายแต่ละเขตพื้นที่ซึ่งตนรับผิดชอบเท่านั้น แล้วส่งมายังสำนักงานใหญ่ แต่วิธีนี้ก็มิมีข้อผิดพลาดได้เนื่องจากพนักงานขายบางคนเป็นผู้มองโลกแง่ดีเกินไป หรือพนักงานขายมักจะรู้ว่ายอดขายของการพยากรณ์จะถูกใช้ในการกำหนดโควตาการขายจึงประมาทการไว้ต่ำเพื่อเอายอดขายเกินเป้าได้

2. ความคิดเห็นของผู้บริหาร (Executive Opinion) ใช้พยากรณ์ผลิตภัณฑ์ใหม่ที่ยังไม่ออกสู่ท้องตลาดมาก่อน จึงใช้ความคิดเห็นของผู้บริหารที่มีประสบการณ์คนหนึ่งหรือหลายคนมาช่วยพยากรณ์และกำหนดกลยุทธ์ให้เหมาะสมกับสภาพแวดล้อม เช่น การนำผลิตภัณฑ์สู่ตลาดต่างประเทศ ข้อจำกัดของวิธีนี้ คือ มักใช้เวลาของกลุ่มผู้บริหารในการประชุมสรุปการพยากรณ์มากจึงเป็นวิธีที่มีค่าใช้จ่ายสูงและไม่ควรใช้ผู้บริหารฝ่ายใดฝ่ายหนึ่งพยากรณ์ตามลำพังโดยไม่ได้สรุปร่วมกับผู้บริหารฝ่ายอื่น เพราะผลของการพยากรณ์กระทบทุกฝ่ายขององค์กร

3. การวิจัยตลาด (Market Research) เป็นวิธีที่ต้องกระทำอย่างมีระบบโดยสร้างสมมติฐานแล้วเก็บรวบรวมข้อมูลจากผู้ผลิตผลิตภัณฑ์เพื่อทำการพยากรณ์ การวิจัยตลาดต้องประกอบด้วย การออกแบบสอบถาม กำหนดวิธีการเก็บข้อมูล สุ่มตัวอย่างมาสัมภาษณ์ รวบรวมข้อมูลมาประมวลผลและเคราะห์ตามลำดับ วิธีนี้ใช้กับการพยากรณ์ในระยะสั้น ระยะปานกลาง และระยะยาวได้ แต่เป็นวิธีที่เสียค่าใช้จ่ายสูงและต้องพิถีพิถันในการปฏิบัติหลายขั้นตอน

4. วิธีเดลฟาย (Delphi Method) เป็นวิธีที่ประชุมกลุ่มผู้เชี่ยวชาญเฉพาะทางที่มีความรู้เกี่ยวกับผลิตภัณฑ์นั้น วิธีนี้จะใช้ได้ดีเมื่อมีข้อมูลจะใช้พยากรณ์ได้และผู้บริหารขององค์กรไม่มีประสบการณ์ในผลิตภัณฑ์นั้นเพียงพอ วิธีนี้จะเริ่มจากการส่งคำถามเวียนไปยัง

ผู้เชี่ยวชาญหลายคนให้ตอบกลับมาแล้วทำเป็นรายงานส่งให้ผู้เชี่ยวชาญทุกคนได้อ่าน
 ข้อคิดเห็นของทุกคน เพื่อให้ทุกคนปรับปรุงแนวความคิดใหม่ แล้วส่งกลับมาอีกทำซ้ำๆหลาย
 รอบจนได้ข้อสรุปยุติจากทุกคน ข้อเสียของวิธีนี้คือเสียเวลานานมาก (อาจเป็นปี) ผู้เชี่ยวชาญ
 บางคนอาจยึดมั่นในความคิดของตนจนไม่สรุปกับข้อคิดเห็นของคนอื่น คำถามหรือ
 แบบสอบถามที่มีดีทำให้สรุปยาก จึงใช้วิธีนี้กับผลิตภัณฑ์ใหม่ที่ไม่สามารถใช้วิธีอื่นได้

8) ตัวแบบการพยากรณ์แบบโครงข่ายประสาทเทียม (Artificial Neural Network=ANN)

(Anderson,1997), (Hagan,1996)

โครงข่ายประสาทเทียม หรือเรียกสั้นๆว่าข่ายงานประสาท (Neural Network) คือ การ
 ใช้ตัวแบบทางคณิตศาสตร์ในการประมวลผลสารสนเทศแบบเดียวกับสมองของมนุษย์ ANN
 เป็น Nonlinear model เป้าหมายของ ANN เหมือนกับตัวแบบ Regression คือต้องการประมาณ
 ค่าพารามิเตอร์เพื่อให้เกิดค่าความผิดพลาด (error) น้อยที่สุด สำหรับการหาคำตอบของตัวแบบ
 ANN นั้นจะใช้การวนซ้ำ

ANN โครงข่ายแบบป้อนไปข้างหน้า (Feed Forward Network) คือสารสนเทศ หรือ
 ข้อมูลจะถูกส่งผ่านจากชั้นที่ซ่อนอยู่ (Hidden Layer) หนึ่ง ไปยังชั้นที่ซ่อนอยู่ต่อไป (ซึ่งใน
 หนึ่งโครงข่ายจะมีชั้นที่ซ่อนอยู่กี่ชั้นก็ได้แต่โดยปกติจะมีชั้นที่ซ่อนอยู่ประมาณ 2-5 ชั้น ตัว
 แบบนี้ถึงจะทำงานให้ผลที่ดี) สำหรับการส่งข้อมูลจะถูกส่งผ่านไปทิศทางเดียวกัน ไม่มีการ
 ส่งย้อนกลับ โดยกระบวนการ (Process) จะเริ่มจาก ตัวแปรพยากรณ์ (Predictive Variables)
 ในชั้นของ input ตัวแปรนี้คือข้อมูลที่เรารวบรวมได้ เช่น ราคาสินค้า ปริมาณผลผลิต เป็นต้น
 โดยข้อมูลนี้ก็จะถูกส่งต่อไปยังชั้นที่ซ่อนอยู่ (Hidden Layer) ซึ่งชั้นนี้จะบรรจุเครื่องมือที่ใช้
 ทำงานของ ANN โดยจะเรียกว่า activation function คือฟังก์ชันที่แสดงความสัมพันธ์ของ input
 ที่เข้ามากับ Output ที่จะออกไป เช่นฟังก์ชัน logistic หรือฟังก์ชัน Nonlinear อื่นๆ

สำหรับวิธีการประมาณค่าพารามิเตอร์นั้นมีได้หลายวิธี แต่จะขอยกตัวอย่างวิธีที่ได้รับ
 ความนิยมน้อยอย่างแพร่หลายคือวิธีการแพร่กระจายแบบย้อนกลับ (Back-propagation) ซึ่งเป็น
 วิธีการใช้อัลกอริทึมการแพร่กระจายแบบย้อนกลับ โดยจะทำการปรับปรุงน้ำหนักคะแนนของ
 เครือข่ายเพื่อให้ได้ผลรวมมากกว่าค่าที่ตั้งเป้าไว้ (Threshold) หลังจากนั้นจึงจะสามารถส่ง

ข้อมูลไปยังชั้นขาออก (Output layer) ได้ แล้วจึงทำการคำนวณหาค่าความผิดพลาด ซึ่งค่าความผิดพลาดนี้ก็จะถูกส่งกลับเข้าสู่เครือข่ายเพื่อใช้แก้ไขค่าน้ำหนักคะแนนต่อไป จนได้ค่าความผิดพลาดต่ำที่สุด

9) วิธีการพยากรณ์แบบ เบย์ (Bayesian) (Robert, 2001), (Congdon, 2006), (West, 1997)

ตัวแบบเบย์สร้างจาก Likelihood, $p(\mathbf{Y} | \boldsymbol{\theta})$, และ Prior, $\pi(\boldsymbol{\theta})$, เมื่อ \mathbf{Y} คือตัวแปรสุ่มที่สังเกตค่าได้ และ $\boldsymbol{\theta}$ คือค่าพารามิเตอร์ที่สังเกตค่าไม่ได้

การแจกแจงร่วม (Joint Distribution) ของ $\boldsymbol{\theta}$ กับ \mathbf{Y} สามารถเขียนอยู่ในรูป

$$\pi(\boldsymbol{\theta}, \mathbf{Y}) = p(\mathbf{Y} | \boldsymbol{\theta})\pi(\boldsymbol{\theta}) \text{ และ Posterior ที่สร้างจากกฎของเบย์คือ}$$

$$\pi(\boldsymbol{\theta} | \mathbf{Y}) = \frac{p(\boldsymbol{\theta}, \mathbf{Y})}{p(\mathbf{Y})} = \frac{p(\mathbf{Y} | \boldsymbol{\theta})\pi(\boldsymbol{\theta})}{p(\mathbf{Y})} \quad (39)$$

โดยที่

$$p(\mathbf{Y}) = \sum_{\boldsymbol{\theta}} p(\mathbf{Y} | \boldsymbol{\theta})\pi(\boldsymbol{\theta}) \text{ เมื่อ } \boldsymbol{\theta} \text{ เป็นตัวแปรสุ่มชนิดไม่ต่อเนื่อง (Discrete) และ}$$

$$p(\mathbf{Y}) = \int p(\mathbf{Y} | \boldsymbol{\theta})\pi(\boldsymbol{\theta})d\boldsymbol{\theta} \text{ เมื่อ } \boldsymbol{\theta} \text{ เป็นตัวแปรสุ่มชนิดต่อเนื่อง (Continuous)}$$

เนื่องจาก $p(\mathbf{Y})$ เป็นฟังก์ชันของ \mathbf{Y} ซึ่งไม่ขึ้นอยู่กับ $\boldsymbol{\theta}$ จึงถูกพิจารณาว่าเป็นค่าคงที่ และสามารถเขียน $\pi(\boldsymbol{\theta} | \mathbf{Y})$ อยู่ในรูป $\pi(\boldsymbol{\theta} | \mathbf{Y}) \propto p(\mathbf{Y} | \boldsymbol{\theta})\pi(\boldsymbol{\theta})$ นั่นคือ $\pi(\boldsymbol{\theta} | \mathbf{Y})$ เป็นสัดส่วนกับผลคูณของ จาก Likelihood กับ Prior

ตัวแบบที่ซับซ้อนสามารถใช้ตัวแบบเบย์แก้ปัญหาได้ เช่น ใช้ตัวแบบเบย์ที่มี 3 ชั้น ได้แก่ ชั้นตอนที่ 1 ระบุการแจกแจงของตัวแปรสุ่มที่สังเกตค่าได้เมื่อกำหนดพารามิเตอร์ให้ ชั้นตอนที่ 2 ระบุการแจกแจงของพารามิเตอร์เมื่อกำหนดไฮเปอร์พารามิเตอร์ให้ และชั้นตอนที่ 3 ระบุการแจกแจงของไฮเปอร์พารามิเตอร์ในทำนองเดียวกัน จำนวนชั้นตอนอาจมีมากกว่า 3 ได้

ตัวแบบเบย์สามารถเพิ่มความแกร่ง (Robustness) ให้กับตัวประมาณแบบเบย์ได้ เนื่องจากความไม่แน่นอน (Uncertainty) ถูกนำมาคิดไว้ในขั้นตอนของการแจกแจงของ Prior นอกจากนี้วิธีการของเบย์ยังทำให้การประมาณค่าพารามิเตอร์ใน Posterior ง่ายขึ้น โดยใช้การจำลองสถานการณ์ (Simulation) การจำลองสถานการณ์ที่ใช้กันอย่างแพร่หลายคือ วิธีเชิงตัวเลข Markov Chain Monte Carlo (MCMC)

สำหรับตัวอย่างเพื่อให้เห็นภาพรวมของวิธีเบย์ จะขอยกตัวอย่างตัวแบบที่มีความซับซ้อน
จึงใช้วิธีการของเบย์ในการแก้ปัญหา ตัวแบบคือ

$$Y_{it} = \beta_0 + \beta_1 Z_{it.1} + \beta_2 Z_{it.2} + \dots + \beta_p Z_{it.p} + \gamma_i \Delta W(t | \alpha_i, \delta_i) + \gamma_i X_{it} + \varepsilon_{it}$$

เมื่อ Y_{it} แทนราคา หรือปริมาณผลผลิตของพืชชนิดที่ i ในช่วงเวลา t , $i=1, \dots, m$ และ
 $t=1, \dots, T_i$

โดยที่

$$\varepsilon_{it} \sim N\left(0, [\gamma_i(1+3\zeta_{it})\sigma_\varepsilon]^2\right)$$

$$Y_{it} \sim N\left(\beta_0 + \beta_1 Z_{it.1} + \beta_2 Z_{it.2} + \dots + \beta_p Z_{it.p} + \gamma_i \Delta W(t | \alpha_i, \delta_i) + \gamma_i X_{it}, [\gamma_i(1+3\zeta_{it})\sigma_\varepsilon]^2\right)$$

Prior (มีหลายระดับ) คือ

1. $p(\sigma_\varepsilon) \propto Unif(0, \infty)$, $p(\beta_i) \propto \text{constant}$

2. ข้อมูลผิดปกติ (Outliners)

$$\zeta_{it} \sim \text{Bern}(0.05)$$

3. ราคาหรือปริมาณผลผลิตรวมทุกช่วงเวลา

$$\gamma_i \sim N(g_i, \sigma_\gamma^2), p(\sigma_\gamma) \propto Unif(0, \infty)$$

$$g_j \sim N(\mu_g, \sigma_g^2), p(\mu_g) \propto 1, p(\sigma_g) \propto Unif(0, \infty)$$

$$S_i \sim N(\gamma_i, [0.2\gamma_i]^2)$$

4. Autoregression ที่ซ่อนเร้นอยู่ (Latent Autoregression)

$$X_{it} \sim N(\lambda_{i1} X_{i,t-1} + \lambda_{i2} X_{i,t-2}, \sigma_x^2), \sigma_x = 0.8\sigma_\varepsilon$$

$$(\lambda_{i1}, \lambda_{i2})^T \sim N(\boldsymbol{\mu}_\lambda, \boldsymbol{\Sigma}_\lambda), p(\boldsymbol{\mu}_\lambda, \boldsymbol{\Sigma}_\lambda) \propto |\boldsymbol{\Sigma}_\lambda|^{-2}$$

$$(X_{i0}, X_{i,-1})^T \sim N(\boldsymbol{\mu}_{x_0}, \boldsymbol{\Sigma}_{x_0}), \boldsymbol{\mu}_{x_0} = (0, 0)^T, \boldsymbol{\Sigma}_{x_0} = \text{diag}(2, 2).$$

5. พารามิเตอร์อื่นๆ

$$\alpha_i \sim N(a_i, \sigma_\alpha^2), p(\sigma_\alpha) \propto Unif(0, \infty)$$

$$\delta_i \sim N(d_i, \sigma_\delta^2), p(\sigma_\delta) \propto Unif(0, \infty)$$

$$a_j \sim N(\mu_a, \sigma_a^2), p(\mu_a) \propto 1, p(\sigma_a) \propto Unif(0, \infty)$$

$$d_j \sim N(\mu_d, \sigma_d^2), p(\mu_d) \propto 1, p(\sigma_d) \propto \text{Unif}(0, \infty)$$

การประมาณค่าพารามิเตอร์ในตัวแบบดังกล่าวมีขั้นตอนดังนี้

- ก. สร้าง Likelihood จากการแจกแจงของ Y_{it}
- ข. สร้าง Posterior จากผลคูณของ Likelihood กับ prior ทุกตัว
- ค. จำลองสถานการณ์ด้วยวิธีการ MCMC โดยใช้การเขียนโปรแกรม ใน Open bugs และ R หรือ โปรแกรมคณิตศาสตร์ต่างๆ

10) Markov Chain Monte Carlo (MCMC) และ Gibbs sampling (Robert, 2004)

MCMC เป็นวิธีเชิงตัวเลขที่ใช้สำหรับสร้างข้อมูลจากการแจกแจงที่มีมิติขนาดใหญ่ในตัวแบบเบย์ เป้าหมายหลักคือการสร้าง $\theta^{(0)}, \theta^{(1)}, \theta^{(2)}, \dots$ ของ Posterior จากห่วงโซ่มาร์คอฟ (Markov Chain) โดยเริ่มจาก Initial state $\theta^{(0)}$ และเมื่อห่วงโซ่คงที่ในการวนซ้ำรอบที่ T เซตของ $\theta^{(0)}, \dots, \theta^{(T)}$ จะถูกตัดทิ้ง เรียกว่า ช่วงของการ burn-in และ $\theta^{(T+1)}, \theta^{(T+2)}, \theta^{(T+3)}, \dots$ เป็นห่วงโซ่ที่คงที่ (Stationary) แล้ว ที่สร้างมาจาก Posterior มีหลายวิธีในการสร้าง MCMC แต่วิธีที่ใช้กันอย่างแพร่หลายคือ Gibbs sampling

Gibbs sampling (Geman and Geman, 1984)

เป็นวิธีการสร้าง MCMC จากการสุ่มตัวอย่างแบบวนซ้ำจากการแจกแจงแบบมีเงื่อนไขของแต่ละพารามิเตอร์เมื่อรู้พารามิเตอร์ที่เหลือทั้งหมดและข้อมูล สมมติว่า Posterior คือ $\pi(\theta | \mathbf{Y})$ ที่มีมิติขนาด k โดยที่ \mathbf{Y} แทนข้อมูลที่สังเกตค่าได้ และสำหรับแต่ละ θ_i ของ θ การแจกแจงแบบมีเงื่อนไขของแต่ละพารามิเตอร์เมื่อรู้พารามิเตอร์ที่เหลือทั้งหมดและข้อมูลคือ $\pi(\theta_i | \theta_1, \dots, \theta_{i-1}, \theta_{i+1}, \dots, \theta_k, \mathbf{Y}) = \pi(\theta_i | \theta_{-i}, \mathbf{Y})$ Gibbs sampling เป็นกระบวนการวนซ้ำมีขั้นตอนดังนี้

$$\text{- กำหนดค่าเริ่มต้น } \theta^{(0)} = (\theta_1^{(0)}, \theta_2^{(0)}, \dots, \theta_k^{(0)}) \quad (40)$$

- รอบที่ i จะเป็นการเปลี่ยนสถานะจาก $\theta^{(i-1)}$ ไปเป็น $\theta^{(i)}$ มีขั้นตอนดังนี้

$$1. \text{ สุ่ม } \theta_1^{(i)} \text{ จาก } \pi(\theta_1 | \theta_2^{(i-1)}, \theta_3^{(i-1)}, \dots, \theta_k^{(i-1)}, \mathbf{Y})$$

$$2. \text{ สุ่ม } \theta_2^{(i)} \text{ จาก } \pi(\theta_2 | \theta_1^{(i)}, \theta_3^{(i-1)}, \dots, \theta_k^{(i-1)}, \mathbf{Y})$$

⋮

⋮

3. สุ่ม $\theta_k^{(i)}$ จาก $\pi(\theta_k | \theta_1^{(i)}, \theta_2^{(i)}, \dots, \theta_{k-1}^{(i)}, \mathbf{Y})$

ลำดับของการสุ่ม $\theta_1^{(1)}, \theta_2^{(2)}, \dots, \theta^{(T)}$ เป็นสถานะต่อเนื่องกันของ Markov Chain

11) การวัดความถูกต้องแม่นยำของการพยากรณ์ (Najafi and Tarazkar, 2006), (Yelland, 2010)

การวัดความถูกต้องแม่นยำของการพยากรณ์นั้นเป็นการเลือกวิธีการพยากรณ์ที่เหมาะสมกับข้อมูลอนุกรมเวลาในแต่ละชุด วิธีวัดความถูกต้องแม่นยำของการพยากรณ์นั้นมีหลายวิธีแต่วิธีที่ใช้กันมากที่สุดคือ เราจะใช้การพิจารณาจากค่าวัดความถูกต้อง ซึ่งต่างเป็นฟังก์ชันของค่าความคลาดเคลื่อน e_t โดยที่ e_t เป็นผลต่างของค่าจริง (Y_t) กับค่าพยากรณ์ (\hat{Y}_t) ณ เวลา t ดังนี้

1. Mean Squared Error (MSE)

$$\frac{\sum_{t=1}^n e_t^2}{n} = \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n} \quad (41)$$

วิธี MSE เป็นวิธีที่ใช้กันทั่วไป ข้อเสียของวิธีนี้คือไม่มีฐานการเปรียบเทียบ และถ้า MSE มีค่าสูงอาจเป็นเพราะมีความคลาดเคลื่อนสูง หรือขึ้นอยู่กับขนาดของข้อมูล

2. Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{\sum_{t=1}^n |e_t / Y_t|}{n} \times 100 \quad (42)$$

วิธี MAPE เป็นหนึ่งในวิธีที่ถูกยอมรับ และที่ใช้ในการเปรียบเทียบมากที่สุดสำหรับอนุกรมเวลา

3. Mean Absolute Error (MAE)


$$MAE = \frac{\sum_{t=1}^n |e_t|}{n} = \frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{n} \quad (43)$$

เมื่อค่า MSE (Mean Squared Error) MAPE (Mean Absolute Percentage Error) และ MAE (Mean Absolute Error) มีค่าต่ำ แสดงถึง วิธีการพยากรณ์นั้นมีความถูกต้องมาก

12) การตรวจสอบการลู่เข้าของ MCMC โดยดูที่ Trace plots

Trace plots เป็นตัวชี้วัดตัวหนึ่งที่สามารถตรวจสอบการลู่เข้าของ MCMC ซึ่งมันจะช่วยบอกว่า chain ของพารามิเตอร์แต่ละตัวหรือไม่ลู่เข้าสู่ stationary distribution และมันยังเป็นตัวช่วยบอกว่าอีกนานเท่าไรมันถึงจะลู่เข้า trace plots ยังสามารถบอกเราว่ามันลู่เข้าดีหรือ

ยังไม่ดีอีกด้วย ดังตัวอย่างในภาพที่ 1 ที่แสดง trace plots ที่ลู่เข้าสู่ stationary distribution ที่ดี (SAS, 2011)



ภาพที่ 1 Trace plots ที่ลู่เข้าสู่ stationary distribution ที่ดีของ gamma

13) การจำลองสถานการณ์สำหรับประเมินประสิทธิภาพของตัวแบบ (Bernd, 2004)

ประสิทธิภาพของตัวประมาณจะถูกประเมินจาก 3 ตัว ที่นิยมใช้กันอยู่ทั่วไปซึ่งได้แก่ Relative Bias (RB) Mean Squared Error (MSE) และ the coverage probability (CP) ซึ่งตัวประเมินแต่ละตัวจะคำนวณจากเซตของข้อมูลที่เป็นอิสระกันจากการจำลองสถานการณ์ที่มาจากกระบวนการของ MCMC โดยที่มี T เซต โดยที่ $T = T_1, \dots, T_B$ และ S มีจำนวนที่ใหญ่พอ สามารถแสดงสูตรของตัวประเมินแต่ละตัวดังสมการข้างล่าง

$$\bar{mean} = S^{-1} \sum_{s=1}^S T_s^{(k)} = \bar{T}^{(k)}, \quad (44)$$

$$\bar{bias} = \bar{T}^{(k)} - \mu \quad (45)$$

$$\bar{SD} = \sqrt{(S-1)^{-1} \sum_{s=1}^S (T_s^{(k)} - \bar{T}^{(k)})^2}, \quad (46)$$

$$\bar{MSE} = S^{-1} \sum_{s=1}^S (T_s^{(k)} - \mu)^2 \approx \bar{SD}^2 + \bar{bias}^2 \quad (47)$$

$$RB(\hat{\mu}_Y) = \frac{1}{B} \sum_{b=1}^B \frac{\hat{\mu}_Y^{(b)} - \mu}{\mu} \quad (48)$$

$$MSE(\hat{\mu}_Y) = \frac{1}{B} \sum_{b=1}^B (\hat{\mu}_Y^{(b)} - \mu)^2 \quad (49)$$

$$CP(\hat{\mu}_Y) = \frac{1}{B} \sum_{b=1}^B I(\hat{\mu}_L^{(b)} < \mu < \hat{\mu}_U^{(b)}) \quad (50)$$

2.1 ทฤษฎีที่เกี่ยวข้องกับอุตสาหกรรมเหล็กและเหล็กกล้าของไทย

อุตสาหกรรมเหล็กและเหล็กกล้าแบ่งออกเป็น อุตสาหกรรมต้นน้ำ อุตสาหกรรมกลางน้ำ และ อุตสาหกรรมปลายน้ำ ได้ดังนี้

- อุตสาหกรรมต้นน้ำ คือ อุตสาหกรรมเหล็กถลุง (Pig Iron) และเหล็กพูน (Sponge Iron) ซึ่งจัดได้ว่าเป็นกระบวนการเริ่มต้นของอุตสาหกรรมเหล็กที่มีความสำคัญอย่างมากต่อศักยภาพในการพัฒนาอุตสาหกรรมเหล็กและอุตสาหกรรมต่อเนื่อง สำหรับประเทศไทยในปัจจุบันยังไม่มีการจัดตั้งโรงงานผลิตเหล็กต้นน้ำ ซึ่งแต่เดิมนั้นแนวทางการพัฒนาถูกกำหนดโดยความต้องการของตลาดในประเทศมากกว่าจากนโยบายของภาครัฐ จึงทำให้อุตสาหกรรมเหล็กเริ่มต้นพัฒนาจากปลายน้ำเพื่อทดแทนการนำเข้าจากต่างประเทศมากกว่าการเริ่มต้นพัฒนาจากอุตสาหกรรมต้นน้ำ

- อุตสาหกรรมกลางน้ำ เป็นขั้นที่นำผลิตภัณฑ์จากการผลิตเหล็กขั้นต้นทั้งที่เป็นของเหลวและของแข็งรวมถึงเศษเหล็ก (Scrap) มาหลอมปรับปรุงคุณสมบัติและส่วนผสมทางเคมีให้ได้เป็นเหล็กกล้า (Steelmaking) สำหรับประเทศไทยผู้ผลิตขั้นกลางทุกรายจะผลิตด้วยเตาอาร์ตไฟฟ้าโดยใช้เศษเหล็กเป็นวัตถุดิบในการผลิต นอกจากการผลิตเหล็กกล้าแล้วอุตสาหกรรมขั้นกลางยังรวมถึงการหล่อเหล็กกล้าให้เป็นผลิตภัณฑ์สำเร็จรูปที่มีอยู่ 3 ประเภท ได้แก่ เหล็กแท่งยาว (Billet) เหล็กแท่งแบน (Slab) และเหล็กแท่งใหญ่ (Bloom)

- อุตสาหกรรมปลายน้ำ เป็นขั้นของการแปรรูปผลิตภัณฑ์สำเร็จรูปด้วยกระบวนการต่าง ๆ ได้แก่ การรีดร้อน การรีดเย็น การเคลือบผิว การผลิตท่อเหล็ก การตีเหล็กขึ้นรูปรวมไปถึงการหล่อเหล็ก

เช่น เหล็กเส้น เหล็กทวด เหล็กแผ่นรีดร้อน เหล็กแผ่นรีดเย็น เหล็กแผ่นเคลือบ เหล็กโครงสร้าง
รูปพรรณรีดร้อน เป็นต้น ซึ่งจะนำไปใช้เป็นตัวตั้งในการผลิตในอุตสาหกรรมต่าง ๆ ที่ต่อเนื่อง เช่น
อุตสาหกรรมก่อสร้าง อุตสาหกรรมยานยนต์ อุตสาหกรรมเครื่องใช้ไฟฟ้า อุตสาหกรรมเฟอร์นิเจอร์
และอุตสาหกรรมบรรจุภัณฑ์ เป็นต้น ในประเทศไทย การผลิตเหล็กและเหล็กกล้าจะเริ่มจากชั้นกลาง
คือ การหลอมและการหล่อ

2.1.1 กระบวนการผลิตเหล็กและเหล็กกล้า

การผลิตเหล็กและเหล็กกล้าประกอบด้วยขั้นตอนดังนี้

1. การแต่งแร่และการถลุง

การแต่งแร่ คือ การแปรสภาพสินแร่ให้ได้ขนาดและคุณสมบัติที่เหมาะสมต่อการถลุง
เช่น การบดแร่ให้ละเอียดเพื่อแยกเหล็กจากมลทินแล้ว อาจแยกโดยอาศัยความถ่วงเฉพาะที่
ต่างกัน (Float) หรือใช้การแยกด้วยแม่เหล็ก (Magnetic separation) ซึ่งแร่ที่ได้จะละเอียด
เกินไป ต้องทำให้เป็นก้อน (Agglomeration) ก่อนป้อนเข้าเตาถลุง

การถลุงเหล็ก คือ การแปรสภาพแร่เหล็กให้มีความบริสุทธิ์เพิ่มขึ้น (%เหล็กเพิ่มขึ้น)
โดยการขจัดสิ่งเจือปนต่างๆ ออกจากแร่เหล็ก

2. การหลอมและการปรับปรุงส่วนผสม

การหลอมเหล็ก คือ การให้ความร้อนแก่ เหล็กถลุง (Pig iron) เหล็กพูน หรือเศษ
เหล็ก ทำให้เหล็กหลอมเหลวที่อุณหภูมิสูง (ประมาณ 1600 °C)

สำหรับการผลิตเหล็กกล้า ในขั้นตอนการหลอมนี้ จะมีการปรับปรุงส่วนผสมทางเคมี
ของเหล็กโดยการทำออกซิเดชันเพื่อลดปริมาณคาร์บอนและฟอสฟอรัส การเติมสารประกอบ
ต่างๆ เพื่อลดปริมาณสารเจือปนและทำให้ผลิตภัณฑ์เหล็กมีคุณสมบัติตามที่ต้องการในขั้นตอน
นี้ สิ่งเจือปนซึ่งส่วนใหญ่เป็นสารประกอบออกไซด์ ซิลิเกตของธาตุต่างๆ จะแยกตัวจากน้ำ
โลหะ ซึ่งเราเรียกสิ่งเจือปนที่แยกออกมาว่า Slag

3. การหล่อ

การหล่อเหล็ก คือ การนำเหล็กหลอมเหลวที่ได้ปรุงแต่งส่วนผสมแล้วเทลงในแบบ เพื่อให้เกิดการแข็งตัวตามรูปร่างที่ต้องการการหล่อสามารถแบ่งได้แบ่ง 2 แบบ

- Ingot casting คือ การหล่อแบบที่น้ำเหล็กกล้าถูกเทลงสู่แบบหล่อที่ไม่เคลื่อนไหว (Stationary mold) เพื่อหล่อเป็นแท่งโลหะ (Ingot)
- การหล่อแบบต่อเนื่อง (Continuous casting) คือ การที่น้ำเหล็กหลอมเหลวได้ไหลผ่านแบบหล่อ (Mold) อย่างต่อเนื่องและแข็งตัวเป็น “ผลิตภัณฑ์กึ่งสำเร็จ” คือ Billet, Bloom หรือ Slab ซึ่งสามารถตัดและนำไปผ่านขบวนการแปรรูปต่อไป

ปัจจุบัน การหล่อแบบต่อเนื่องเป็นที่นิยม เนื่องจากนำมาสู่การเพิ่มสัดส่วนผลผลิตที่ได้รับ (Yield), ปรับปรุงคุณภาพ, เพิ่มความสามารถในการผลิตและประสิทธิภาพของการลงทุน

4. การแปรรูป

คือ การแปรรูปเหล็กกล้าที่ได้หลอมเพื่อให้ได้รูปร่างและขนาดที่ต้องการ นอกจากนี้ยังเป็นการปรับปรุงคุณสมบัติเชิงกลของผลิตภัณฑ์เหล็กกล้าอีกด้วย การแปรรูปประกอบด้วย การแปรรูปร้อนและการแปรรูปเย็น

สำหรับเหล็กแผ่นเมื่อผ่านการรีดร้อนแล้วสามารถนำไปใช้งานบางอย่างได้โดยตรง แต่สำหรับเหล็กแผ่นบางจะถูกลดขนาดด้วยการรีดเย็นต่อ เพื่อให้ได้ความหนาตามที่ต้องการและด้วยเหตุผลอื่นๆ ดังนี้

- เพื่อปรับปรุงคุณภาพผิว
- เพื่อให้ได้คุณสมบัติเชิงกลที่ต้องการ
- เพื่อให้ได้ความหนาที่ต่ำกว่าเหล็กแผ่นรีดร้อน

-เพื่อความคุมให้ความคลาดเคลื่อนของความหนาต่ำ

เนื่องจากการรีดร้อนจะประหยัดกว่าการรีดเย็น ดังนั้นในการผลิตเหล็กแผ่นบางจึงเริ่มจากการรีดร้อนให้ได้ขนาดค่าหนึ่งก่อน จากนั้นจึงทำการรีดเย็นต่อ

ผลิตภัณฑ์ที่ผ่านขั้นตอนที่ 4 คือการแปรรูปแล้ว สามารถนำไปผ่านขบวนการต่างๆ ของอุตสาหกรรมต่อเนื่อง เพื่อผลิตผลิตภัณฑ์ที่หลากหลายตามประเภทการใช้งาน เช่น วัสดุก่อสร้าง ท่อ คอนเทนเนอร์ ถึงความดัน ชิ้นส่วนยานยนต์ ไฟฟ้าและเครื่องจักรกล เป็นต้น

งานวิจัยที่เกี่ยวข้อง

ตัวแบบการพยากรณ์ของไทยในปัจจุบันใช้ตัวแบบการพยากรณ์ส่วนใหญ่ยังใช้ตัวแบบการพยากรณ์แบบดั้งเดิม ทั่วๆ ไป (Classical model) เช่น Multiple Regression, Moving Average (MA), Exponential Smoothing (EXPS), ARIMA และ Seasonal ARIMA เป็นต้น ตัวแบบโครงข่ายประสาทเทียม (Artificial Neural Network) ตัวแบบ Semiparametric Multiple Regression เป็นต้น ตัวแบบที่มีความซับซ้อนมากขึ้น เช่นตัวแบบที่มีการนำความสัมพันธ์ของข้อมูลอนุกรมเวลามาคิดคำนวณด้วย และตัวแบบที่กำหนดให้พารามิเตอร์ในตัวแบบมีความไม่แน่นอน (uncertainty) ยังมีน้อยมาก ส่วนใหญ่จะอยู่ในต่างประเทศ สำหรับในงานวิจัยนี้ได้ศึกษางานวิจัยที่เกี่ยวข้องที่ใช้ตัวแบบการพยากรณ์ที่นำมาใช้กับด้านอุตสาหกรรม และนำไปใช้กับงานด้านอื่นๆ ดังนี้

ตัวแบบการพยากรณ์แบบดั้งเดิม (Classical Models) ในการพยากรณ์ผลลัพธ์ที่จะเกิดขึ้นในอนาคตของเหตุการณ์ด้านต่างๆ นั้น Wright (1986) นำตัวแบบ Simple Exponential และ Holt ไปใช้กับข้อมูลอนุกรมเวลาที่ไม่สม่ำเสมอ (Irregular) Deetae (1991) ประยุกต์ใช้ตัวแบบ Box Jenkins (ARIMA) ในการพยากรณ์ราคาข้าว พบว่าตัวแบบนี้มีประสิทธิภาพอย่างเห็นได้ชัด และดีกว่าตัวแบบ Decomposition เช่นเดียวกันกับที่ Kerdsoomboon (1999) พบว่า ตัวแบบ Box Jenkins พยากรณ์ราคาข้าวได้ดีกว่าตัวแบบสถิติเบื้องต้น Cipraและคณะ (1995) ใช้ตัวแบบ Holt-Winter กับข้อมูลอนุกรมเวลาที่มีข้อมูลสูญหาย (Missing) Hyndman (2002) พบว่าการใช้ตัวแบบ Single Exponential Smoothing ในกรอบการทำงาน (Framework) ของตัวแบบ State-space มีประสิทธิภาพสูง โดยนำไปใช้กับข้อมูลอนุกรมเวลา M-

Competition ซึ่งเป็นข้อมูลทางด้านเศรษฐศาสตร์ การเงิน อุตสาหกรรม ประชากรศาสตร์ และอื่นๆ ในขณะ ที่ Sangpattaranate (2005) ที่พบว่า Box Jenkins เป็นตัวแบบที่ใช้ในการพยากรณ์ราคาข้าวได้ดีกว่าตัวแบบ Holt-Winter และตัวแบบการถดถอย Iqbal และคณะ (2005) ใช้ตัวแบบ ARIMA พยากรณ์ผลผลิตและพื้นที่เพราะปลูกข้าวสาลีในประเทศปากีสถานเพื่อใช้เป็นข้อมูลให้กับรัฐบาลในการกำหนดนโยบาย Mishra และ Desai (2005) ใช้ตัวแบบ SARIMA ในการพยากรณ์ภัยแล้ง (Drought) โดยใช้ข้อมูลอนุกรมเวลาเป็นค่าดัชนีมาตรฐานของหยาดน้ำที่ตกมาจากชั้นบรรยากาศ (Precipitation) สำหรับตัวแบบการพยากรณ์แบบ exponential smoothing นั้นมีการนำไปใช้อย่างแพร่หลายนั้น และมีการยืดขยายเป็น Simple exponential smoothing, Holt, Holt-Winters และ double exponential smoothing Cipra (2006) ใช้ตัวแบบ double exponential smoothing กับข้อมูลอนุกรมเวลาที่ไม่สม่ำเสมอ boosarawongse และคณะ (2007) ได้ใช้วิธีการพยากรณ์ Box-Jenkins (ARIMA) กับ Artificial Neural Network สำหรับพยากรณ์ commodity prices การส่งออกข้าวของไทย 4 ชนิด ผลพบว่าวิธีการพยากรณ์ทั้งสองให้ผลที่ดี แต่วิธีการพยากรณ์ Artificial Neural Network ให้ผลการพยากรณ์ที่แม่นยำกว่า 3 ชนิด โดยเปรียบเทียบจากค่าความคลาดเคลื่อนต่างๆ Sumer และคณะ (2009) ศึกษาการใช้ตัวแบบ ARIMA, SARIMA และ ตัวแบบการถดถอย (Regression Model) ที่มีฤดูกาล (Seasonal) เป็นตัวแปรซ่อนเร้น (Latent variable) ในการพยากรณ์ ปริมาณความต้องการกระแสไฟฟ้าพบว่าตัวแบบการถดถอยที่มีฤดูกาลเป็นตัวแปรซ่อนเร้นพยากรณ์ได้แม่นยำกว่า ARIMA และ SARIMA Kahforoushan, Zarif and Mashahir (2010) ศึกษาการพยากรณ์ผลผลิตทางการเกษตร ซึ่งได้แก่ การปลูกพืช การเลี้ยงสัตว์ การประมง และการปลูกป่า โดยใช้วิธีการพยากรณ์ 4 วิธี ได้แก่ วิธีปรับเรียบเอ็กโปเนนเชียลโดยวิธี Holt-Winters แบบไม่มีฤดูกาล (Holt-Winters (no seasonal) Exponential Smoothing Model) วิธีบ็อกซ์-เจนกินส์ (Box-Jenkins Model) วิธีโครงข่ายประสาทเทียม (Artificial Neural Network Model) และ วิธี ARIMA (ARIMA Model) และใช้ ค่า MAE MSE และ MAPE เปรียบเทียบผลการพยากรณ์แต่ละวิธี ผลการศึกษาพบว่า วิธีโครงข่ายประสาทเทียมเหมาะสมในการประมาณค่าพารามิเตอร์ในตัวแบบ (Learn Stage) วิธีบ็อกซ์-เจนกินส์เหมาะสมในการประเมินความถูกต้องในตัวแบบ (Model Validation) แต่วิธีปรับเรียบเอ็กโปเนนเชียลโดยวิธี Holt-Winters แบบไม่มีฤดูกาล ให้ค่า MAPE ต่ำสุดในการประมาณค่าพารามิเตอร์ในตัวแบบ (Model Fitting) และการประเมินความถูกต้องในตัวแบบ

นอกจากตัวแบบการพยากรณ์แบบเดิมที่กล่าวมาแล้วนั้น ยังมีอีกตัวแบบหนึ่งที่กำลังได้รับความนิยมเพิ่มมากขึ้นเรื่อยๆ คือตัวแบบการพยากรณ์แบบเบย์ ตัวแบบนี้เหมาะสำหรับกรณีที่กำหนดให้พารามิเตอร์ในตัวแบบมีความไม่แน่นอน (Uncertainty) และยังสามารถนำความสัมพันธ์ของข้อมูล

อนุกรมเวลามาคิดคำนวณได้ด้วย ดังปรากฏในงานของ Monahan (1983) ใช้วิธีของเบย์ในการประมาณค่าพารามิเตอร์ในตัวแบบ ARMA และ Broemeling และ Land (1984) ใช้วิธีของเบย์ในการประมาณค่าพารามิเตอร์ในตัวแบบ AR(p) Liu (1994) ใช้วิธีของเบย์ในการประมาณค่าพารามิเตอร์ในตัวแบบ AR(p) ที่มีตัวแปรภายนอก (Exogenous) รวมอยู่ด้วย Neelamegham และ Chintagunta (1999) ประยุกต์ใช้ตัวแบบเบย์ในการพยากรณ์การจำนวนผู้เข้าชมภาพยนตร์ใหม่ ที่เข้าฉายในโรงภาพยนตร์ในสัปดาห์แรกทั้งภายในประเทศและบางประเทศในต่างประเทศ ซึ่งมีประโยชน์ต่อผู้ที่เกี่ยวข้องเช่นเจ้าของโรงภาพยนตร์ ผู้แทนจำหน่าย และผู้จัดทำโฆษณา เป็นต้น จำนวนผู้เข้าชมภาพยนตร์เป็นจำนวนนับ ที่มีการแจกแจงแบบปัวซอง ผลการศึกษาพบว่า ตัวแบบเบย์พยากรณ์ได้แม่นยำในระดับประเทศ และเมื่อพิจารณาค่ารากที่สองของค่าเฉลี่ยกำลังสองของค่าความผิดพลาด (Root Mean Square Error) และค่าเฉลี่ยความผิดพลาดสัมบูรณ์ (Mean Absolute Error) พบว่ามีค่าต่ำกว่าตัวแบบของผู้วิจัยอื่นๆ คือ ตัวแบบของ Sawhney และ Eliashberg (1996) Fourth และ Woodlock (1960) และตัวแบบ Naïve (Logged) OLS และ Poisson Maximum Likelihood de Alba และ Mendoza (2006) ศึกษาการพยากรณ์โดยใช้วิธีเบย์ เมื่อมีข้อมูลจำนวนน้อย ค่าที่พยากรณ์เป็นค่าสะสมของตัวแปรต่อเนื่องที่เป็นค่าบวกโดยทราบค่าสะสมของข้อมูลมาส่วนหนึ่งแล้ว ตัวแบบที่ถูกรับรองเป็นการอธิบายความสัมพันธ์ระหว่างค่ารวมทั้งหมดกับค่ารวมมาแล้วบางส่วนของตัวแปรภายใต้อิทธิพลของฤดูกาลแบบคงที่ (Stable Seasonality) ผลการศึกษาพบว่าตัวแบบที่นำเสนอเหมาะสมเมื่อมีข้อมูลจำนวนน้อย และตัวแบบมาตรฐานทั่วไปไม่เหมาะสม Pedroza (2006) ใช้ตัวแบบเบย์ในการพยากรณ์อัตราการเสียชีวิต ของชายชาวสหรัฐอเมริกา ใช้ MCMC ในการประมาณค่าพารามิเตอร์ และใช้ Gibbs sampling ในการสุ่มตัวอย่างจาก Posterior กลุ่มตัวอย่างเป็นข้อมูลการเสียชีวิตของชายชาวสหรัฐอเมริกา เป็นการพยากรณ์อัตราการเสียชีวิตในช่วงปี 1990-1999 โดยใช้ข้อมูลปี 1959-1989 การพยากรณ์นี้เมื่อนำไปเปรียบเทียบกับค่าสังเกตจริง และวิธีการของ Lee-Carter พบว่าวิธีการของเบย์เหมาะสมกว่า de Alba และ Mendoza (2007) ที่นำตัวแบบการพยากรณ์แบบเบย์ไปใช้กับข้อมูลอนุกรมเวลาที่มีอิทธิพลของฤดูกาลรวมอยู่ด้วย Yelland (2009) ใช้วิธีของเบย์ประมาณค่าพารามิเตอร์ในตัวแบบ state-space 3 ประเภทคือ Adjusted Gaussian Dynamic Linear Model (AG), Poisson Dynamic Log-Linear Model (PL) และ Gamma-Poisson Local Level Model (GP) รวมทั้ง ตัวแบบ Climatological Baseline Model (Cm) กับข้อมูลปริมาณความต้องการซื้อสินค้า พบว่า ตัวแบบ GP ดีที่สุด Yelland (2010) นำเสนอมีความเหมาะสมกับข้อมูลปริมาณความต้องการซื้อชิ้นส่วนอุปกรณ์คอมพิวเตอร์ และเมื่อเปรียบเทียบกับตัวแบบมาตรฐานอื่นๆ ได้แก่

Exponential smoothing (ExpS) และ Judgmental Methods (Judg) พบว่าวิธีเบย์ มีความเหมาะสมมากกว่า จากที่กล่าวมาทั้งหมดนั้น



บทที่ 3

วิธีการดำเนินงานวิจัย

ในการศึกษาตัวแบบการพยากรณ์ความต้องการเหล็กภายใต้ความไม่แน่นอนโดยวิธีเบย์นี้ผู้ศึกษาได้กำหนดวิธีการศึกษาไว้ตามขั้นตอนดังนี้

- 3.1 ประชากรและกลุ่มตัวอย่าง
- 3.2 เครื่องมือที่ใช้ในการศึกษา
- 3.3 วิธีดำเนินการศึกษา
- 3.4 สถิติที่ใช้ในการวิเคราะห์ข้อมูล
- 3.5 การสร้างตัวแบบพยากรณ์ด้วยวิธีของเบย์
- 3.6 ประเมินผลและข้อเสนอแนะ

3.1 ประชากรและกลุ่มตัวอย่าง

3.1.1 ประชากร

ประชากรคือ ดัชนีปริมาณความต้องการเหล็กและเหล็กกล้าของประเทศไทยกรณีส่งออกไปต่างประเทศ จากสำนักงานสถิติอุตสาหกรรม

3.1.2 กลุ่มตัวอย่าง

ดัชนีปริมาณความต้องการเหล็กและเหล็กกล้าของประเทศไทยจากสำนักงานสถิติอุตสาหกรรม กระทรวงอุตสาหกรรม รายเดือน ตั้งแต่เดือนมกราคม 2543 ถึง ธันวาคม 2555

3.2 เครื่องมือที่ใช้ในการศึกษา

3.2.1 เครื่องคอมพิวเตอร์ Notebook

3.2.2 โปรแกรมสำเร็จรูปทางสถิติ SPSS สำหรับวิเคราะห์ข้อมูล

3.2.3 โปรแกรมคอมพิวเตอร์ OpenBUGS และ R สำหรับสร้าง และวิเคราะห์ตัวแบบในงานวิจัยนี้

3.3 วิธีการดำเนินการศึกษา

3.3.1 เก็บรวบรวมข้อมูล

เก็บรวบรวมข้อมูลดัชนีปริมาณความต้องการเหล็กและเหล็กกล้าของประเทศไทยกรณี ส่งออกไปต่างประเทศรายเดือน จากสำนักงานสถิติอุตสาหกรรมจำนวน 13 ปี ตั้งแต่ปีพ.ศ. 2543-2555 และ ปีพ.ศ. 2556 ตั้งแต่เดือนมกราคมถึงเดือน สิงหาคม

3.3.2 วิเคราะห์ข้อมูล

นำข้อมูลข้างต้นที่รวบรวมมาได้มาวิเคราะห์คุณลักษณะของข้อมูลว่ามีส่วนประกอบอะไรบ้าง เช่น แนวโน้ม (Trend) อัตตสหสัมพันธ์ (Autocorrelation) ข้อมูลผิดปกติ (Outlier) เป็นต้น และพยากรณ์ข้อมูลด้วยวิธี Exponential smoothing โดยใช้โปรแกรม Spss

3.4 สร้างตัวแบบด้วยวิธีของเบย์

นำข้อมูลที่ได้จากการวิเคราะห์นำข้อมูลที่ได้จากการวิเคราะห์ในหัวข้อ 3.3.1 และ 3.3.2 ไปสร้างตัวแบบของด้วยวิธีของเบย์โดยมีรายละเอียดของตัวแบบดังต่อไปนี้

$$Y_t \sim N(\gamma(\Delta W(t|\alpha, \delta) + A_t), [\gamma(3 + \zeta_t)\sigma_Y]^2)$$

เมื่อค่าเฉลี่ยของ Y_t คือ

$$E(Y_t) = \gamma(\Delta W(t|\alpha, \delta) + A_t) \quad (44)$$

ค่าความแปรปรวนของ Y_t คือ

$$Var(Y_t) = [\gamma(3 + \zeta_t)\sigma_Y]^2 \quad (45)$$

เมื่อ γ คือค่าคาดหวังของ Z และ Z ก็คือผลรวมของข้อมูลอนุกรมเวลาทั้งหมดในช่วงเวลาที่ศึกษา หรือวิเคราะห์ $W(t|\alpha, \delta)$ คือฟังก์ชันการแจกแจงความน่าจะเป็นสะสมของ Weibull A_t อัตต

สหสัมพันธ์ที่ซ่อนเร้นอยู่ในช่วงเวลา t ζ_t คือข้อมูลผิดปกติในช่วงเวลา t และ σ_Y^2 ความแปรปรวนของ Y_t

สำหรับ prior distribution ของตัวแบบเบย์ในงานวิจัยนี้คือ

$$\omega_1, \omega_2, \dots, \omega_{s-1} \sim N(0, 1.0E09)$$

$$p(\sigma_Y^2) \sim \text{InvGamma}(0.1, 0.0001)$$

แนวโน้ม

$$\Delta W(t | \alpha, \delta) = W(t | \alpha, \delta) - W(t-1 | \alpha, \delta)$$

เมื่อ

$$\alpha \sim N_{[0, \infty)}(\mu_\alpha, \sigma_\alpha^2), p(\mu_\alpha) \sim N(0, 1.0E09),$$

$$p(\sigma_\alpha^2) \sim \text{InvGamma}(0.1, 0.001)$$

$$\delta \sim N_{[0, \infty)}(\mu_\delta, \sigma_\delta^2), p(\mu_\delta) \sim N(0, 1.0E09),$$

$$p(\sigma_\delta^2) \sim \text{InvGamma}(0.1, 0.0001)$$

อัตรสหสัมพันธ์ที่ซ่อนเร้น: AR(1):

$$A_t \sim N(\lambda A_{t-1}, \sigma_A^2), p(\sigma_A^2) \sim \text{InvGamma}(0.1, 0.0001)$$

$$\lambda \sim N(0, 1.0E09), A_0 = 0$$

ข้อมูลผิดปกติ:

$$\zeta_t \sim \text{Bern}(0.05)$$

ค่าคาดหวังของผลรวมของข้อมูลอนุกรมเวลา:

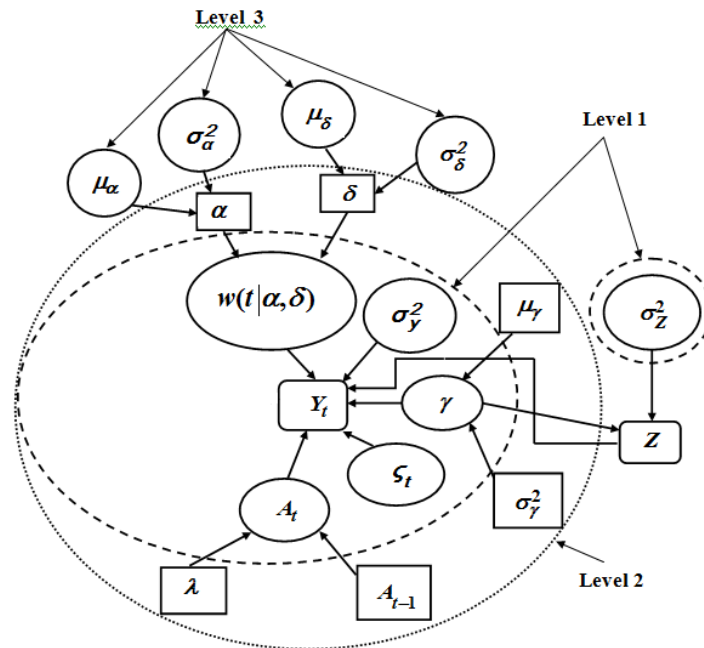
$$\gamma \sim N_{[0, \infty)}(\mu_\gamma, \sigma_\gamma^2), p(\mu_\gamma) \sim N(0, 1.0E09)$$

$$p(\sigma_\gamma^2) \sim \text{InvGamma}(0.1, 0.0001)$$

ผลรวมของข้อมูลอนุกรมเวลาทั้งหมดในช่วงเวลาที่ศึกษา:

$$Z \sim N(\gamma, \sigma_Z^2), p(\sigma_Z^2) \sim \text{InvGamma}(0.1, 0.0001)$$

สำหรับโครงสร้างของตัวแบบในงานวิจัยนี้สามารถแสดงได้ในภาพที่ 1



ภาพที่ 1 โครงสร้างของตัวแบบเบย์ในงานวิจัยนี้

สำหรับสมการพยากรณ์ของตัวแบบเบย์ในงานวิจัยนี้แสดงดังข้างล่าง

$$p(\hat{Y}_{t+1} | Y_t, Y_{t-1}, \dots, Y_1) = \int \dots \int p(\hat{Y}_{t+1} | \boldsymbol{\theta}) p(\boldsymbol{\theta} | Y_t, Y_{t-1}, \dots, Y_1) d\boldsymbol{\theta} \quad (46)$$

$$p(\hat{Y}_{t+1} / Y_t, Y_{t-1}, \dots, Y_1) \propto \int \dots \int p(\hat{Y}_{t+1} / \boldsymbol{\theta}) p(Y_t, Y_{t-1}, \dots, Y_1 / \boldsymbol{\theta}) p(\boldsymbol{\theta}) d\boldsymbol{\theta}$$

จากสมการที่ 46 เราสามารถประมาณวิธีการหาคำตอบได้โดยใช้การสุ่มตัวอย่างแบบ Gibbs

ตามสมการเพื่อประมาณค่า \hat{Y}_{t+1}

1.2.1 การประมาณค่าพารามิเตอร์โดยวิธี MCMC

จากตัวแบบข้างต้น และกำหนด priors ให้กับพารามิเตอร์ทั้งหมดแล้ว เราจะใช้วิธี Markov Chain Monte Carlo (MCMC) สำหรับประมาณค่าพารามิเตอร์ โดยใช้วิธีการสุ่มตัวอย่างแบบ Gibbs ซึ่งวิธีการสุ่มตัวอย่างแบบ Gibbs นี้จะเหมาะสมกับฟังก์ชันการแจกแจงแบบมีเงื่อนไข เมื่อจำนวน

รอบของการสุ่มตัวอย่างหลายๆ มันก็จะลู่เข้าสู่ฟังก์ชันการแจกแจงความน่าจะเป็นร่วมของ posterior ใดๆ (joint posterior distribution) สามารถเขียน likelihood ของตัวแบบเบย์ได้ดังนี้

$$\begin{aligned} & f(Y_1, \dots, Y_n | \gamma, w(t), \alpha, \delta, A_1, \dots, A_n, \omega_1, \dots, \omega_{s-1}, \xi_1, \dots, \xi_n, \sigma_Y^2, \\ & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) \\ &= \prod_{t=1}^n f(Y_t | \gamma, w(t), \alpha, \delta, A_t, \omega_1, \dots, \omega_{s-1}, \xi_t, \sigma_Y^2, \lambda, \mu_\alpha, \sigma_\alpha^2, \\ & \quad \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) \end{aligned} \quad (47)$$

สามารถเขียนผลคูณ prior distributions ของพารามิเตอร์ทั้งหมดได้ดังนี้

$$\begin{aligned} & [p(\gamma | \mu_\gamma, \sigma_\gamma^2) p(\mu_\gamma) p(\sigma_\gamma^2) p(w(t) | \alpha, \delta) p(\alpha | \mu_\alpha, \sigma_\alpha^2) p(\mu_\alpha) p(\sigma_\alpha^2) p(\delta | \mu_\delta, \sigma_\delta^2) p(\mu_\delta) \\ & p(\sigma_\delta^2) p(A_1, \dots, A_n | \lambda, \sigma_A^2) p(\lambda) p(\sigma_A^2), p(\omega_1), \dots, p(\omega_{s-1}) p(\xi_1), \dots, p(\xi_n) \\ & p(\sigma_Y^2)] \end{aligned}$$

สามารถเขียน posterior distribution ซึ่งเกิดจากผลคูณของ likelihood กับ ผลคูณ prior distributions ของพารามิเตอร์ทั้งหมด ได้ดังนี้

$$\begin{aligned} & p(\gamma, w(t), \alpha, \delta, A_1, \dots, A_n, \omega_1, \dots, \omega_{s-1}, \xi_1, \dots, \xi_n, \sigma_Y^2, \lambda, \mu_\alpha, \\ & \quad \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2 | Y_1, \dots, Y_n) \\ &= \prod_{t=1}^n f(Y_t | \gamma, w(t), \alpha, \delta, A_t, \omega_1, \dots, \omega_{s-1}, \xi_t, \sigma_Y^2, \lambda, \mu_\alpha, \\ & \quad \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) [p(\gamma | \mu_\gamma, \sigma_\gamma^2) p(\mu_\gamma) p(\sigma_\gamma^2) p(w(t) | \alpha, \delta) \\ & \quad p(\alpha | \mu_\alpha, \sigma_\alpha^2) p(\mu_\alpha) p(\sigma_\alpha^2) p(\delta | \mu_\delta, \sigma_\delta^2) p(\mu_\delta) p(\sigma_\delta^2) p(A_1, \dots, A_n | \lambda, \sigma_A^2) \\ & \quad p(\lambda) p(\sigma_A^2) p(\omega_1), \dots, p(\omega_{s-1}) p(\xi_1), \dots, p(\xi_n) p(\sigma_Y^2)] \end{aligned} \quad (48)$$

สำหรับวิธีการประมาณค่าพารามิเตอร์ด้วยวิธี MCMC โดยอัลกอริทึมของการสุ่มตัวอย่างแบบ Gibbs จะทำการสร้าง The full conditional distributions ให้กับพารามิเตอร์แต่ละตัว ซึ่ง The full conditional distribution ของพารามิเตอร์แต่ละตัว เกิดจาก ผลคูณของ the likelihood กับ all priors ที่เกี่ยวข้องกับพารามิเตอร์ของตัวเอง ตัวอย่างเช่น the full conditional distributions ของพารามิเตอร์หลักๆ $(\gamma, \alpha, \delta, A_t, \xi_t, \mu_\alpha)$ แสดงดังต่อไปนี้

The full conditional distribution ของ γ คือ

$$\begin{aligned}
 & p(\gamma | w(t), \alpha, \delta, A_1, \dots, A_n, \omega_1, \dots, \omega_{s-1}, \xi_1, \dots, \xi_n, \sigma_Y^2, \\
 & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\
 &= \prod_{i=1}^n f(Y_i | \gamma, w(t), \alpha, \delta, A_i, \omega_1, \dots, \omega_{s-1}, \xi_i, \sigma_Y^2, \\
 & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) \\
 & \quad [p(\gamma | \mu_\gamma, \sigma_\gamma^2) p(\mu_\gamma) p(\sigma_\gamma^2)]
 \end{aligned} \tag{49}$$

The full conditional distribution for α is

$$\begin{aligned}
 & p(\alpha | w(t), \gamma, \delta, A_1, \dots, A_n, \omega_1, \dots, \omega_{s-1}, \xi_1, \dots, \xi_n, \sigma_Y^2, \\
 & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\
 &= \prod_{i=1}^n f(Y_i | \gamma, w(t), \alpha, \delta, A_i, \omega_1, \dots, \omega_{s-1}, \xi_i, \sigma_Y^2, \\
 & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) \\
 & \quad [p(\alpha | \mu_\alpha, \sigma_\alpha^2) p(\mu_\alpha) p(\sigma_\alpha^2)]
 \end{aligned} \tag{50}$$

The full conditional distribution ของ δ คือ

$$\begin{aligned}
 & p(\delta | w(t), \gamma, \alpha, A_1, \dots, A_n, \omega_1, \dots, \omega_{s-1}, \xi_1, \dots, \xi_n, \sigma_Y^2, \\
 & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\
 &= \prod_{i=1}^n f(Y_i | \gamma, w(t), \alpha, \delta, A_i, \omega_1, \dots, \omega_{s-1}, \xi_i, \sigma_Y^2, \\
 & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) [p(\delta | \mu_\delta, \sigma_\delta^2) p(\mu_\delta) p(\sigma_\delta^2)]
 \end{aligned} \tag{51}$$

The full conditional distribution ของ A_t คือ

$$\begin{aligned}
 & p(A_t | w(t), \alpha, \delta, A_{-t}, \omega_1, \dots, \omega_{s-1}, \xi_1, \dots, \xi_n, \sigma_Y^2, \\
 & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\
 &= \prod_{i=1}^n f(Y_i | \gamma, w(t), \alpha, \delta, A_t, \beta_0, \beta_1, \dots, \beta_p, \omega_1, \dots, \omega_{s-1}, \xi_i, \sigma_Y^2, \lambda, \mu_\alpha, \\
 & \quad \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) [p(A_t | \lambda A_{t-1}, \sigma_A^2) p(\lambda) p(A_{-t} | \lambda A_{t-1}, \\
 & \quad \sigma_A^2) p(\sigma_A^2)]
 \end{aligned} \tag{52}$$

เมื่อ $A_{-t} = A_1, \dots, A_{t-1}, A_{t+1}, \dots, A_n$.

The full conditional distribution ของ ξ_t คือ

$$\begin{aligned} & p(\xi_t | w(t), \alpha, \delta, A_1, \dots, A_n, \omega_1, \dots, \omega_{s-1}, \xi_{-t}, \sigma_Y^2, \\ & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\ &= \prod_{t=1}^n f(Y_t | \gamma, w(t), \alpha, \delta, A_t, \omega_1, \dots, \omega_{s-1}, \xi_{-t}, \sigma_Y^2, \\ & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) [p(\xi_t)] \end{aligned} \quad (53)$$

เมื่อ $\xi_{-t} = \xi_1, \dots, \xi_{t-1}, \xi_{t+1}, \dots, \xi_n$.

The full conditional distribution ของ μ_α คือ

$$\begin{aligned} & p(\mu_\alpha | w(t), \alpha, \delta, A_1, \dots, A_n, \omega_1, \dots, \omega_{s-1}, \xi_1, \dots, \xi_n, \sigma_Y^2, \\ & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\ &= \prod_{t=1}^n f(Y_t | \gamma, w(t), \alpha, \delta, A_t, \omega_1, \dots, \omega_{s-1}, \xi_t, \sigma_Y^2, \\ & \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) [p(\mu_\alpha)] \end{aligned} \quad (53)$$

และวิธีการประมาณค่าพารามิเตอร์ด้วยวิธี MCMC โดยใช้อัลกอริทึมของการสุ่มตัวอย่างแบบ Gibbs จะทำการเขียนโปรแกรม ใน OpenBUGS และประเมินประสิทธิภาพของตัวแบบด้วยการเขียนโปรแกรมใน R และเปรียบเทียบวิธีการพยากรณ์ในงานวิจัยนี้กับวิธีการพยากรณ์ที่นิยมใช้กันอยู่ทั่วไปที่ทำให้ค่าพยากรณ์ที่มีค่าผิดพลาดต่ำ ได้แก่ วิธีการพยากรณ์แบบปรับเรียบเอ็กซ์โปเนนเชียล (Yelland, 2010)

3.5 ประเมินผลการวิจัย

นำผลการวิจัยที่ได้มาวิเคราะห์ และพิจารณาเพื่อหาข้อสรุป และข้อเสนอแนะ
สถานที่เก็บรวบรวมข้อมูล

สำนักงานสถิติอุตสาหกรรม กระทรวงอุตสาหกรรม

สถานที่ใช้ในการทำวิจัย

สาขาวิชาวิศวกรรมอุตสาหกรรม คณะวิศวกรรมศาสตร์ ซึ่งตั้งอยู่ที่วิทยาเขตพระนครเหนือ
มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร

ระยะเวลาในการวิจัย

เริ่มตั้งแต่ 1 ตุลาคม 2555 สิ้นสุดการวิจัย 30 กันยายน 2556

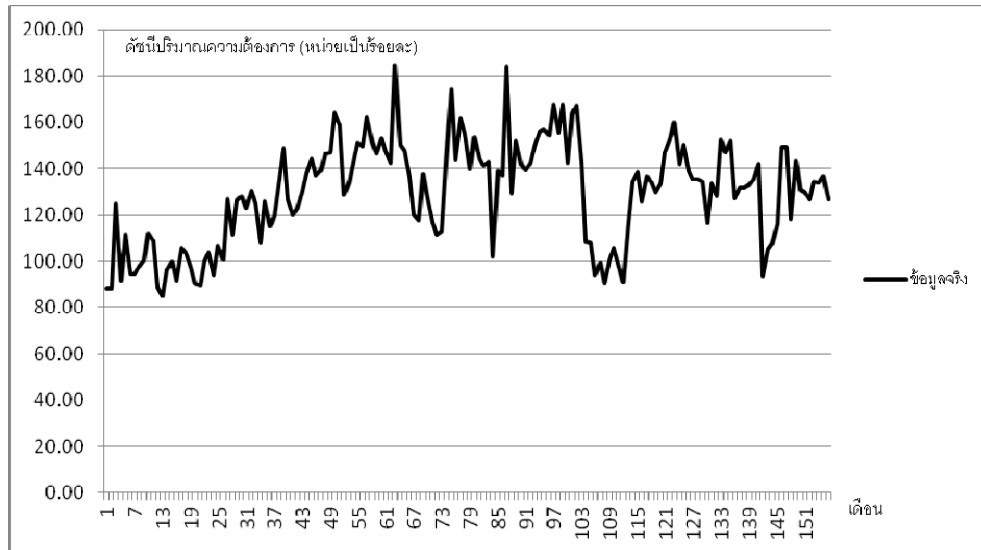
บทที่ 4

ผลการวิจัย

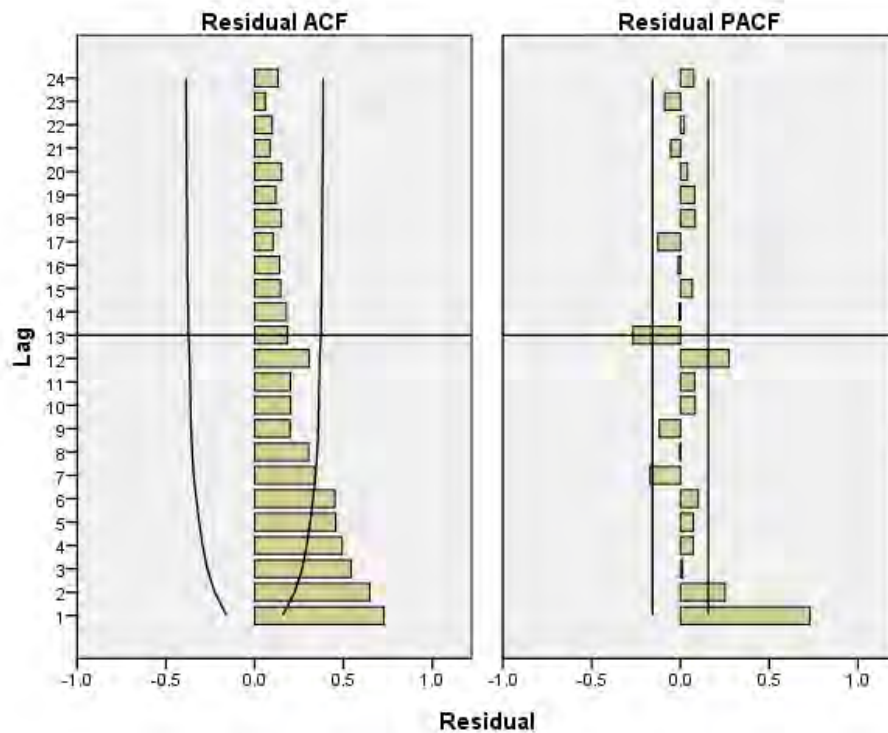
ผลการศึกษาตัวแบบการพยากรณ์ความต้องการเหล็กภายใต้ความไม่แน่นอนโดยวิธีเบย์ ในงานวิจัยนี้ได้ศึกษาข้อมูลเฉพาะดัชนีของปริมาณความต้องการเหล็ก และเหล็กกล้ากรณีการส่งออกจากสำนักงานสถิติอุตสาหกรรม กระทรวงอุตสาหกรรม โดยเก็บข้อมูลรายเดือน ตั้งแต่เดือน มกราคม พ.ศ. 2543 ถึงเดือน กันยายน 2556 โดยแบ่งข้อมูลออกเป็น 2 ชุด ได้แก่ข้อมูลชุดที่ 1 ตั้งแต่เดือน มกราคม พ.ศ. 2543 ถึงเดือน ธันวาคม 2555 ซึ่งจะนำมาใช้ในการวิเคราะห์เพื่อสร้างตัวพยากรณ์เพื่อประมาณค่าพารามิเตอร์ต่างๆที่ทำให้ตัวแบบเหมาะสม ทดสอบประสิทธิภาพของตัวแบบ และเปรียบเทียบกับวิธีการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียลเพื่อหาตัวแบบที่เหมาะสม ส่วนข้อมูลชุดที่ 2 ตั้งแต่เดือน มกราคม พ.ศ. 2556 ถึงเดือน กันยายน 2556 เพื่อนำมาใช้พยากรณ์ไปข้างหน้าเปรียบเทียบกับข้อมูลจริง และวิธีการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียลเพื่อตรวจสอบความถูกต้องของตัวแบบพยากรณ์มีรายละเอียดดังนี้

4.3 ผลการวิเคราะห์ลักษณะของข้อมูล

ภาพที่ 2 แสดงลักษณะของข้อมูลชุดที่ 1 ตั้งแต่เดือน มกราคม พ.ศ. 2543 ถึงเดือน ธันวาคม พ.ศ. 2555 ภาพที่ 3 แสดงการวัดสหสัมพันธ์ระหว่างข้อมูล ด้วยกราฟ Autocorrelation Function (ACF) และ Partial Autocorrelation Function (PACF)



ภาพที่ 2 ลักษณะของข้อมูลชุดที่ 1



ภาพที่ 3 แสดงการวัดสหสัมพันธ์ระหว่างข้อมูล

จากภาพที่ 2 และภาพที่ 3 สามารถวิเคราะห์ลักษณะส่วนประกอบของข้อมูล แสดงให้เห็นว่าข้อมูลมีแนวโน้ม มีข้อมูลบางตัวสูง และต่ำผิดปกติจากตัวอื่นๆ แสดงว่าข้อมูลมีบางตัวผิดปกติ

โดยดูจากภาพที่ 2 ส่วนภาพที่ 3 แสดงให้เห็นว่าข้อมูลมีความสัมพันธ์กันอย่างน้อย 1 lag แต่เลือกใช้ที่ 1 lag เพราะมีอยู่ 1 แห่งที่สูงกว่าแห่งอื่น หลังจากนั้นเมื่อวิเคราะห์ลักษณะของข้อมูลได้แล้วจึงนำลักษณะของข้อมูลไปสร้างตัวแบบและได้ตัวแบบในหัวข้อต่อไป

4.2 ผลของสร้างตัวแบบ

นำข้อมูลที่ได้จากการวิเคราะห์นำข้อมูลที่ได้จากการวิเคราะห์เพื่อสร้างตัวแบบของด้วยวิธีของเบย์โดยมีรายละเอียดของตัวแบบดังต่อไปนี้

$$Y_t \sim N\left(\gamma(\Delta W(t|\alpha, \delta) + A_t), [\gamma(3 + \zeta_t)\sigma_Y]^2\right)$$

เมื่อค่าเฉลี่ยของ Y_t คือ

$$E(Y_t) = \gamma(\Delta W(t|\alpha, \delta) + A_t) \quad (51)$$

ค่าความแปรปรวนของ Y_t คือ

$$\text{Var}(Y_t) = [\gamma(3 + \zeta_t)\sigma_Y]^2 \quad (52)$$

เมื่อ γ คือค่าคาดหวังของ Z และ Z ก็คือผลรวมของข้อมูลอนุกรมเวลาทั้งหมดในช่วงเวลาที่ศึกษา หรือวิเคราะห์ $W(t|\alpha, \delta)$ คือฟังก์ชันการแจกแจงความน่าจะเป็นสะสมของ Weibull A_t อัตราสัมพันธ์ที่ซ่อนเร้นอยู่ในช่วงเวลา t และ ζ_t คือข้อมูลผิดปกติในช่วงเวลา t

สำหรับ prior distribution ของตัวแบบเบย์ในงานวิจัยนี้คือ

$$p(\sigma_Y^2) \sim \text{InvGamma}(0.1, 0.0001)$$

แนวนอน

$$\Delta W(t|\alpha, \delta) = W(t|\alpha, \delta) - W(t-1|\alpha, \delta)$$

เมื่อ

$$\begin{aligned}\alpha &\sim N_{[0,\infty)}(\mu_\alpha, \sigma_\alpha^2), p(\mu_\alpha) \sim N(0, 1.0E09), \\ p(\sigma_\alpha^2) &\sim \text{InvGamma}(0.1, 0.001) \\ \delta &\sim N_{[0,\infty)}(\mu_\delta, \sigma_\delta^2), p(\mu_\delta) \sim N(0, 1.0E09), \\ p(\sigma_\delta^2) &\sim \text{InvGamma}(0.1, 0.0001)\end{aligned}$$

อัตรศาสตร์สัมพันธ์ที่ซ่อนเร้น:

$$\begin{aligned}A_t &\sim N(\lambda A_{t-1}, \sigma_A^2), p(\sigma_A^2) \sim \text{InvGamma}(0.1, 0.0001) \\ \lambda &\sim N(0, 1.0E09), A_0 = 0\end{aligned}$$

ข้อมูลผิดพลาด:

$$\zeta_t \sim \text{Bern}(0.05)$$

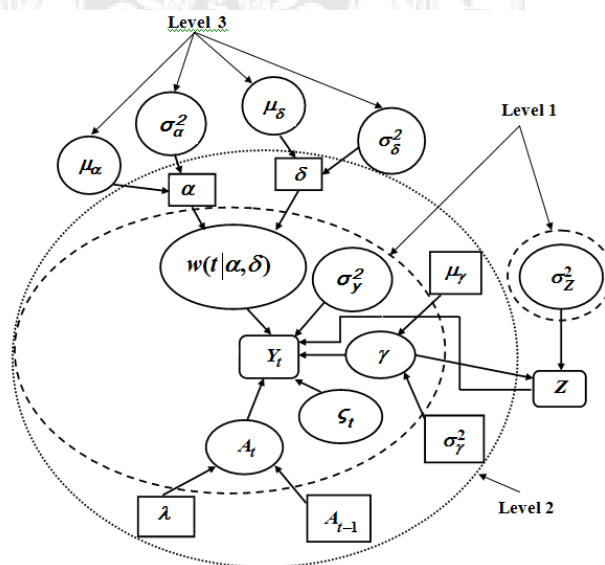
ค่าคาดหวังของผลรวมของข้อมูลอนุกรมเวลา:

$$\begin{aligned}\gamma &\sim N_{[0,\infty)}(\mu_\gamma, \sigma_\gamma^2), p(\mu_\gamma) \sim N(0, 1.0E09) \\ p(\sigma_\gamma^2) &\sim \text{InvGamma}(0.1, 0.0001)\end{aligned}$$

ผลรวมของข้อมูลอนุกรมเวลาทั้งหมดในช่วงเวลาที่ศึกษา:

$$Z \sim N(\gamma, \sigma_Z^2), p(\sigma_Z^2) \sim \text{InvGamma}(0.1, 0.0001)$$

สำหรับโครงสร้างของตัวแบบในงานวิจัยนี้สามารถแสดงได้ในภาพที่ 4



ภาพที่ 4 โครงสร้างของตัวแบบเบย์ในงานวิจัยนี้

สำหรับสมการพยากรณ์ของตัวแบบเบย์ในงานวิจัยนี้แสดงดังข้างล่าง

$$p(\hat{Y}_{t+1} | Y_t, Y_{t-1}, \dots, Y_1) = \int \dots \int p(\hat{Y}_{t+1} | \theta) p(\theta | Y_t, Y_{t-1}, \dots, Y_1) d\theta \quad (53)$$

$$p(\hat{Y}_{t+1} | Y_t, Y_{t-1}, \dots, Y_1) \propto \int \dots \int p(\hat{Y}_{t+1} / \theta) p(Y_t, Y_{t-1}, \dots, Y_1 / \theta) p(\theta) d\theta$$

จากสมการที่ 53 เราสามารถประมาณวิธีการหาคำตอบได้โดยใช้การสุ่มตัวอย่างแบบ Gibbs ตามสมการเพื่อประมาณค่า \hat{Y}_{t+1}

4.2.1 การประมาณค่าพารามิเตอร์โดยวิธี MCMC

จากตัวแบบข้างต้น และกำหนด priors ให้กับพารามิเตอร์ทั้งหมดแล้ว เราจะใช้วิธี Markov Chain Monte Carlo (MCMC) สำหรับประมาณค่าพารามิเตอร์ โดยใช้วิธีการสุ่มตัวอย่างแบบ Gibbs ซึ่งวิธีการสุ่มตัวอย่างแบบ Gibbs นี้จะเหมาะสมกับฟังก์ชันการแจกแจงแบบมีเงื่อนไข เมื่อจำนวนรอบของการสุ่มตัวอย่างมากๆ มันก็จะเข้าสู่ฟังก์ชันการแจกแจงความน่าจะเป็นร่วมของ posterior ใดๆ (joint posterior distribution) สามารถเขียน likelihood ของตัวแบบเบย์ได้ดังนี้

$$\begin{aligned} & f(Y_1, \dots, Y_n | \gamma, w(t), \alpha, \delta, A_1, \dots, A_n, \xi_1, \dots, \xi_n, \sigma_Y^2, \\ & \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) \\ & = \prod_{t=1}^n f(Y_t | \gamma, w(t), \alpha, \delta, A_t, \xi_t, \sigma_Y^2, \lambda, \mu_\alpha, \sigma_\alpha^2, \\ & \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) \end{aligned} \quad (54)$$

สามารถเขียนผลคูณ prior distributions ของพารามิเตอร์ทั้งหมดได้ดังนี้

$$\begin{aligned} & [p(\gamma | \mu_\gamma, \sigma_\gamma^2) p(\mu_\gamma) p(\sigma_\gamma^2) p(w(t) | \alpha, \delta) p(\alpha | \mu_\alpha, \sigma_\alpha^2) p(\mu_\alpha) p(\sigma_\alpha^2) p(\delta | \mu_\delta, \sigma_\delta^2) p(\mu_\delta) \\ & p(\sigma_\delta^2) p(A_1, \dots, A_n | \lambda, \sigma_A^2) p(\lambda) p(\sigma_A^2), p(\xi_1), \dots, p(\xi_n) \\ & p(\sigma_Y^2)] \end{aligned}$$

สามารถเขียน posterior distribution ซึ่งเกิดจากผลคูณของ likelihood กับ ผลคูณ prior distributions ของพารามิเตอร์ทั้งหมด ได้ดังนี้

$$\begin{aligned}
& p(\gamma, w(t), \alpha, \delta, A_1, \dots, A_n, \xi_1, \dots, \xi_n, \sigma_Y^2, \lambda, \mu_\alpha, \\
& \quad \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2 | Y_1, \dots, Y_n) \\
& = \prod_{t=1}^n f(Y_t | \gamma, w(t), \alpha, \delta, A_t, \xi_t, \sigma_Y^2, \lambda, \mu_\alpha, \\
& \quad \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) [p(\gamma | \mu_\gamma, \sigma_\gamma^2) p(\mu_\gamma) p(\sigma_\gamma^2) p(w(t) | \alpha, \delta) \\
& \quad p(\alpha | \mu_\alpha, \sigma_\alpha^2) p(\mu_\alpha) p(\sigma_\alpha^2) p(\delta | \mu_\delta, \sigma_\delta^2) p(\mu_\delta) p(\sigma_\delta^2) p(A_1, \dots, A_n | \lambda, \sigma_A^2) \\
& \quad p(\lambda) p(\sigma_A^2) p(\xi_1), \dots, p(\xi_n) p(\sigma_Y^2)] \tag{55}
\end{aligned}$$

สำหรับวิธีการประมาณค่าพารามิเตอร์ด้วยวิธี MCMC โดยอัลกอริทึมของการสุ่มตัวอย่างแบบ Gibbs จะทำการสร้าง The full conditional distributions ให้กับพารามิเตอร์แต่ละตัว ซึ่ง The full conditional distribution ของพารามิเตอร์แต่ละตัว เกิดจาก ผลคูณของ the likelihood กับ all priors ที่เกี่ยวข้องกับพารามิเตอร์ของตัวเอง ตัวอย่างเช่น the full conditional distributions ของพารามิเตอร์หลักๆ $(\gamma, \alpha, \delta, A_t, \xi_t, \mu_\alpha)$ แสดงดังต่อไปนี้

The full conditional distribution ของ γ คือ

$$\begin{aligned}
& p(\gamma | w(t), \alpha, \delta, A_1, \dots, A_n, \xi_1, \dots, \xi_n, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\
& = \prod_{t=1}^n f(Y_t | \gamma, w(t), \alpha, \delta, A_t, \xi_t, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) \\
& \quad [p(\gamma | \mu_\gamma, \sigma_\gamma^2) p(\mu_\gamma) p(\sigma_\gamma^2)] \tag{56}
\end{aligned}$$

The full conditional distribution for α is

$$\begin{aligned}
& p(\alpha | w(t), \gamma, \delta, A_1, \dots, A_n, \xi_1, \dots, \xi_n, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\
& = \prod_{t=1}^n f(Y_t | \gamma, w(t), \alpha, \delta, A_t, \xi_t, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) \\
& \quad [p(\alpha | \mu_\alpha, \sigma_\alpha^2) p(\mu_\alpha) p(\sigma_\alpha^2)] \tag{57}
\end{aligned}$$

The full conditional distribution ของ δ คือ

$$\begin{aligned}
& p(\delta | w(t), \gamma, \alpha, A_1, \dots, A_n, \xi_1, \dots, \xi_n, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\
& = \prod_{i=1}^n f(Y_i | \gamma, w(t), \alpha, \delta, A_i, \xi_i, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) [p(\delta | \mu_\delta, \sigma_\delta^2) p(\mu_\delta) p(\sigma_\delta^2)]
\end{aligned} \tag{58}$$

The full conditional distribution ของ A_t คือ

$$\begin{aligned}
& p(A_t | w(t), \alpha, \delta, A_{-t}, \xi_1, \dots, \xi_n, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\
& = \prod_{i=1}^n f(Y_i | \gamma, w(t), \alpha, \delta, A_t, \beta_0, \beta_1, \dots, \beta_p, \xi_i, \sigma_Y^2, \lambda, \mu_\alpha, \\
& \quad \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) [p(A_t | \lambda A_{t-1}, \sigma_A^2) p(\lambda) p(A_{-t} | \lambda A_{t-1}, \\
& \quad \sigma_A^2) p(\sigma_A^2)]
\end{aligned} \tag{59}$$

เมื่อ $A_{-t} = A_1, \dots, A_{t-1}, A_{t+1}, \dots, A_n$.

The full conditional distribution ของ ξ_t คือ

$$\begin{aligned}
& p(\xi_t | w(t), \alpha, \delta, A_1, \dots, A_n, \omega_1, \dots, \omega_{s-1}, \xi_{-t}, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\
& = \prod_{i=1}^n f(Y_i | \gamma, w(t), \alpha, \delta, A_i, \omega_1, \dots, \omega_{s-1}, \xi_{-t}, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) [p(\xi_t)]
\end{aligned} \tag{60}$$

เมื่อ $\xi_{-t} = \xi_1, \dots, \xi_{t-1}, \xi_{t+1}, \dots, \xi_n$.

The full conditional distribution ของ μ_α คือ

$$\begin{aligned}
& p(\mu_\alpha | w(t), \alpha, \delta, A_1, \dots, A_n, \omega_1, \dots, \omega_{s-1}, \xi_1, \dots, \xi_n, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2, Y_1, \dots, Y_n) \\
& = \prod_{i=1}^n f(Y_i | \gamma, w(t), \alpha, \delta, A_i, \omega_1, \dots, \omega_{s-1}, \xi_i, \sigma_Y^2, \\
& \quad \lambda, \mu_\alpha, \sigma_\alpha^2, \mu_\delta, \sigma_\delta^2, \mu_\gamma, \sigma_\gamma^2, \sigma_Z^2) [p(\mu_\alpha)]
\end{aligned} \tag{61}$$

4.3 ผลของการประเมินประสิทธิภาพของตัวแบบ

การประมาณค่าพารามิเตอร์ด้วยวิธี MCMC โดยใช้อัลกอริทึมของการสุ่มตัวอย่างแบบ

Gibbs โดยทำการเขียนอัลกอริทึมในโปรแกรม OpenBUGS เมื่อได้ค่าพารามิเตอร์ที่ประมาณได้จากข้อมูลจริงมาแล้ว หลังจากนั้นจะใช้ค่าพารามิเตอร์ทุกตัวมาทำการจำลองสถานการณ์สร้างชุดข้อมูลมาใหม่อีก 1000 ชุดซึ่งจะถูกเขียนอัลกอริทึมในโปรแกรม R และประเมินประสิทธิภาพของตัวแบบโดยการประเมินจากพารามิเตอร์แต่ละตัวได้ผลดังตารางที่ 1

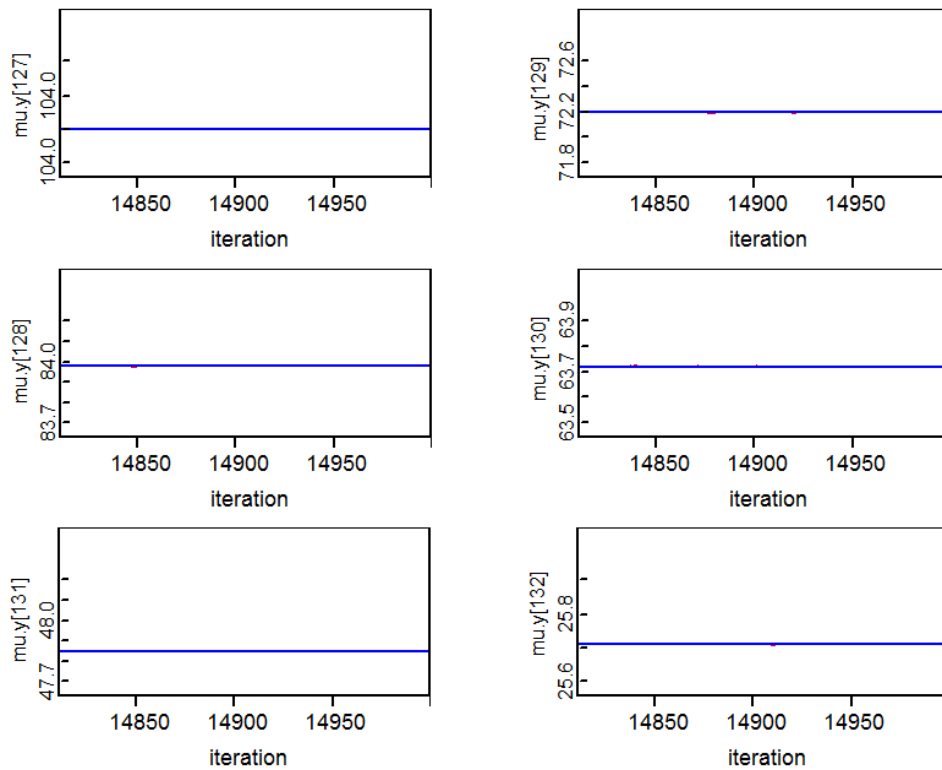
ตารางที่ 1 ประสิทธิภาพของตัวแบบโดยการประเมินพารามิเตอร์

| P | RB | MSE | CP | P | RB | MSE | CP |
|--------------|-------|-------|-------|-------------------|-------|-------|-------|
| σ_Y^2 | 0.011 | 0.446 | 0.949 | μ_γ | 0.012 | 0.216 | 0.971 |
| σ_z^2 | 0.013 | 0.549 | 0.960 | σ_γ^2 | 0.021 | 0.329 | 0.973 |
| γ | 0.009 | 0.156 | 0.962 | μ_α | 0.011 | 0.126 | 0.965 |
| λ | 0.011 | 0.824 | 0.967 | σ_α^2 | 0.017 | 0.364 | 0.969 |
| α | 0.019 | 0.817 | 0.956 | μ_δ | 0.015 | 0.597 | 0.979 |
| δ | 0.018 | 0.793 | 0.954 | σ_δ^2 | 0.015 | 0.483 | 0.978 |

จากตารางที่ 1 พบว่าค่า RB และค่า MSE ของพารามิเตอร์แต่ละตัวมีค่าต่ำมาก และพบว่าค่า CP ของพารามิเตอร์แต่ละตัวมีค่าสูงมาก จึงสรุปได้ว่าประสิทธิภาพของตัวแบบในงานวิจัยนี้อยู่ในเกณฑ์ที่ดีมาก

4.4 ผลของการประมาณพารามิเตอร์

เมื่อได้ตัวแบบที่เหมาะสมแล้วจึงเลือกใช้ค่าพารามิเตอร์ที่ประมาณได้จากข้อมูลจริงจำนวน 13 ปี หรือ 153 เดือน ผลของ trace plot แสดงการการลู่เข้าสู่ stationary distribution ของพารามิเตอร์บางตัวแสดงได้ดังภาพที่ 5 และผลการประมาณค่าพารามิเตอร์แสดงได้ดังตารางที่ 2



ภาพที่ 5 trace plot แสดงการการลู่เข้าสู่ stationary distribution ของพารามิเตอร์บางตัว

ตารางที่ 2 ค่าพารามิเตอร์ที่ประมาณได้

| Parameter | Value | Parameter | Value |
|--------------|--------|-------------------|---------|
| α | 149.50 | μ_γ | 1083.00 |
| λ | 10.59 | σ_Y^2 | 10.19 |
| δ | 240.31 | σ_α^2 | 33.60 |
| γ | 515.00 | σ_δ^2 | 41.35 |
| μ_α | 57.44 | σ_γ^2 | 30.48 |
| μ_δ | 88.63 | σ_z^2 | 4400.00 |

จากภาพที่ 5 เป็นภาพที่แสดงถึงตัวอย่างของค่าพารามิเตอร์บางตัวที่ลู่เข้าสู่ stationary distribution ซึ่งไม่ได้แสดงการลู่เข้าของค่าพารามิเตอร์ ทุกตัว แต่ค่าพารามิเตอร์ตัวอื่นๆที่ไม่ได้แสดงในงานวิจัยนี้ trace plot ก็ลู่เข้าสู่ stationary distribution เหมือนอย่างในภาพที่ 5 ที่ประมาณ 10000 รอบขึ้นไป เช่นกัน ซึ่งสรุปได้ว่าค่าพารามิเตอร์แต่ละตัวจะมีค่าที่ไม่เปลี่ยนแปลงแล้วจึงยอมรับผลของการค่าพารามิเตอร์ที่ได้ในตารางที่ 2 เพื่อนำไปใช้พยากรณ์ค่า y แต่ละตัว

4.5 ผลของการเปรียบเทียบตัวแบบพยากรณ์


เมื่อได้ตัวแบบที่เหมาะสมแล้วจึงเลือกใช้ค่าพารามิเตอร์ที่เหมาะสมได้จากข้อมูลจริงจำนวน 13 ปี หรือ 153 เดือน มาเปรียบเทียบกับวิธีการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียลเพื่อหาตัวแบบที่เหมาะสม (Fitting Model) และเปรียบเทียบเพื่อตรวจสอบความถูกต้อง ของตัวแบบ (Validation Model) พยากรณ์ที่เสนอกับวิธีการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล จากข้อมูลที่เหลือ อีก 9 เดือน คือข้อมูลเดือน มกราคม 2556 ถึงเดือนกันยายน 2556 แสดงได้ดังตารางที่ 3-4 และภาพที่ 6 – 7

ตารางที่ 3 การเปรียบเทียบเพื่อหาตัวแบบที่เหมาะสม (Fitting Model)


| ข้อมูล | วิธีการพยากรณ์ | การวัดค่าความผิดพลาด | | |
|-----------------|--|----------------------|--------------|--------------|
| | | RMSE | MAPE | MAE |
| จากข้อมูล 13 ปี | 1. เบย์ (Bayesian) | 1.011 | 5.244 | 1.119 |
| | 2. Exponential Smoothing (Simple Seasonal) | 11.596 | 6.932 | 8.732 |

ตารางที่ 4 การเปรียบเทียบเพื่อตรวจสอบความถูกต้องของตัวแบบ (Validation Model)

| ข้อมูล | วิธีการพยากรณ์ | การวัดค่าความผิดพลาด | | |
|-------------------|--|----------------------|--------------|--------------|
| | | RMSE | MAPE | MAE |
| จากข้อมูล 9 เดือน | 1. เบย์ (Bayesian) | 7.919 | 5.104 | 6.629 |
| | 2. Exponential Smoothing (Simple Seasonal) | 8.511 | 5.939 | 7.365 |



ภาพที่ 6 แสดงการเปรียบเทียบเพื่อหาตัวแบบที่เหมาะสม (Fitting Model) แต่ละตัวกับข้อมูลจริง



ภาพที่ 7 แสดงการเปรียบเทียบเพื่อตรวจสอบความถูกต้องของตัวแบบ (Validation Model) แต่ละตัวกับข้อมูลจริง

จากตารางที่ 3 และภาพที่ 6 ได้จากการที่นำข้อมูลจริง จำนวน 13 ปี หรือ 153 เดือน มาประมาณค่าพารามิเตอร์เพื่อการเปรียบเทียบหาตัวแบบที่เหมาะสม (Fitting Model) จากค่าพยากรณ์ของ

ทั้งสองวิธี ได้แก่วิธีการพยากรณ์ที่นำเสนอโดยวิธีแบบเบย์ และวิธีการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล ที่มีเทรน และฤดูกาล แบบ Winter's additive กับข้อมูลจริง พบว่าวิธีที่นำเสนอมีค่า error ทั้งสามตัวต่ำกว่า วิธีของการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล ที่มีเทรน และฤดูกาล แบบ Winter's additive ซึ่งถูกเลือกค่าพยากรณ์ที่ให้ค่า error มาจากวิธีของการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียลทั้งหมด โดยมีค่า RMSE เท่ากับ **1.011** MAPE เท่ากับ **5.244** และ MAE เท่ากับ **1.119** และเมื่อดูจากกราฟในภาพที่ 6 พบว่าวิธีที่นำเสนอมีค่าพยากรณ์ส่วนใหญ่ใกล้เคียงมากกว่าวิธีของการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล ที่มีเทรน และฤดูกาล แบบ Winter's additive เช่นกัน

จากตารางที่ 4 และภาพที่ 7 ได้จากการที่นำข้อมูลจริง จำนวน 9 เดือน มาประมาณค่าพารามิเตอร์ เพื่อเปรียบเทียบการตรวจสอบความถูกต้องของตัวแบบ (Validation Model) จากค่าพยากรณ์ของทั้งสองวิธี ได้แก่วิธีการพยากรณ์ที่นำเสนอโดยวิธีแบบเบย์ และวิธีการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล ที่มีเทรน และฤดูกาล แบบ Winter's additive กับข้อมูลจริง พบว่าวิธีที่นำเสนอมีค่า error ทั้งสามตัวต่ำกว่า วิธีของการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล ที่มีเทรน และฤดูกาล แบบ Winter's additive ซึ่งถูกเลือกค่าพยากรณ์ที่ให้ค่า error มาจากวิธีของการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียลทั้งหมด โดยมีค่า RMSE เท่ากับ **7.919** MAPE เท่ากับ **5.104** และ MAE เท่ากับ **6.629** และเมื่อดูจากกราฟในภาพที่ 7 พบว่าวิธีที่นำเสนอมีค่าพยากรณ์ส่วนใหญ่ใกล้เคียงมากกว่าวิธีของการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล ที่มีเทรน และฤดูกาล แบบ Winter's additive เช่นกัน

บทที่ 5

สรุปผลการวิจัย และข้อเสนอแนะ

การศึกษาตัวแบบการพยากรณ์ความต้องการเหล็กกล้าภายใต้ความไม่แน่นอนโดยวิธีเบย์สามารถสรุปผลการวิจัย และข้อเสนอแนะได้ดังนี้

สรุปผลการวิจัย

5.1 ลักษณะทั่วไปของประชากร และกลุ่มตัวอย่าง

ประชากร และกลุ่มตัวอย่างคือ ข้อมูลเฉพาะดัชนีของปริมาณความต้องการเหล็ก และเหล็กกล้ากรณีการส่งออก จากสำนักงานสถิติอุตสาหกรรม กระทรวงอุตสาหกรรม โดยเก็บข้อมูลรายเดือน ตั้งแต่เดือน มกราคม พ.ศ. 2543 ถึงเดือน กันยายน 2556 โดยแบ่งข้อมูลออกเป็น 2 ชุด ได้แก่ข้อมูลชุดที่ 1 ตั้งแต่เดือน มกราคม พ.ศ. 2543 ถึงเดือน ธันวาคม 2555 ซึ่งจะนำมาใช้ในการวิเคราะห์เพื่อสร้างตัว พยากรณ์เพื่อประมาณค่าพารามิเตอร์ต่างๆที่ทำให้ตัวแบบเหมาะสม ส่วนข้อมูลชุดที่ 2 ตั้งแต่เดือน มกราคม พ.ศ. 2556 ถึงเดือน กันยายน 2556 เพื่อนำมาใช้พยากรณ์ไปข้างหน้าเปรียบเทียบกับข้อมูลจริง

5.2 การสร้างตัวแบบการพยากรณ์โดยวิธีของเบย์

การสร้างตัวแบบในงานวิจัยนี้เริ่มจากตรวจสอบลักษณะของข้อมูลจากการพล็อตกราฟ ดังภาพที่ 2 และการวัดสหสัมพันธ์ระหว่างข้อมูล ด้วยกราฟ Autocorrelation Function (ACF) และ Partial Autocorrelation Function (PACF) เพื่อทราบส่วนประกอบต่างๆของประชากร และกลุ่มตัวอย่างคือ ข้อมูลเฉพาะดัชนีของปริมาณความต้องการเหล็ก และเหล็กกล้ากรณีการส่งออก ซึ่งก็คือมีในส่วนของ แนวโน้ม มีค่าผิดปกติ และมีความสัมพันธ์กัน หลังจากนั้นนำส่วนประกอบต่างๆที่ไปไปออกแบบสร้างตัวแบบโดยวิธีของเบย์

ตัวแบบที่ได้คือ $Y_t \sim N(\gamma(\Delta W(t|\alpha, \delta) + A_t), [\gamma(3 + \zeta_t)\sigma_Y]^2)$ เมื่อค่าเฉลี่ยของ Y_t คือ $E(Y_t) = \gamma(\Delta W(t|\alpha, \delta) + A_t)$ ค่าความแปรปรวนของ Y_t คือ $Var(Y_t) = [\gamma(3 + \zeta_t)\sigma_Y]^2$

γ คือค่าคาดหวังของ Z และ Z ก็คือผลรวมของข้อมูลอนุกรมเวลาทั้งหมดในช่วงเวลาที่ศึกษา หรือวิเคราะห์ $W(t|\alpha, \delta)$ คือฟังก์ชันการแจกแจงความน่าจะเป็นสะสมของ Weibull A_t

อัตราส่วนที่ซ่อนเร้นอยู่ในช่วงเวลา t ζ_t คือข้อมูลผิดปกติในช่วงเวลา t และสมการพยากรณ์ได้แก่ $p(\hat{Y}_{t+1} | Y_t, Y_{t-1}, \dots, Y_1) = \int \dots \int p(\hat{Y}_{t+1} | \theta) p(\theta | Y_t, Y_{t-1}, \dots, Y_1) d\theta$

5.3 การประเมินประสิทธิภาพของตัวแบบ

จากประมาณค่าพารามิเตอร์ด้วยวิธี MCMC โดยใช้อัลกอริทึมของการสุ่มตัวอย่างแบบ Gibbs โดยทำการเขียนอัลกอริทึมในโปรแกรม OpenBUGS เมื่อได้ค่าพารามิเตอร์ที่ประมาณได้จากข้อมูลจริงมาแล้ว หลังจากนั้นจะใช้ค่าพารามิเตอร์ทุกตัวมาทำการจำลองสถานการณ์สร้างชุดข้อมูลมาใหม่อีก 1000 ชุดซึ่งจะถูกเขียนอัลกอริทึมในโปรแกรม R และประเมินประสิทธิภาพของตัวแบบโดยดูจากค่า RB ค่า MSE และค่า CP ของพารามิเตอร์แต่ละตัว ซึ่งค่า RB และค่า MSE มีค่าต่ำมาก และค่า CP ของพารามิเตอร์แต่ละตัวมีค่าสูงมาก สรุปได้ว่าประสิทธิภาพของตัวแบบในงานวิจัยนี้อยู่ในเกณฑ์ที่ดีมาก

5.4 การประมาณพารามิเตอร์

สำหรับการประมาณค่าพารามิเตอร์จะพิจารณาจาก กราฟ trace plot ของพารามิเตอร์แต่ละตัวว่าเข้าสู่ stationary distribution หรือยัง สำหรับค่าพารามิเตอร์ ทุกตัว ในงานวิจัยนี้เข้าสู่ stationary distribution ที่ประมาณ 10000 รอบขึ้นไป โดยค่าพารามิเตอร์ที่ประมาณได้แสดงดังตารางที่ 2

5.5 การประมาณพารามิเตอร์

ในงานวิจัยนี้จะเลือกวิธีการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล ที่มีเทรน และฤดูกาล แบบ Winter's additive ซึ่งถูกเลือกค่าพยากรณ์ที่ให้ค่า error มาจากวิธีการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียลทั้งหมด มาเปรียบเทียบกับตัวแบบที่เสนอในงานวิจัยนี้ โดยเปรียบเทียบจากค่า RMSE MAPE และ MAE โดยทำการเปรียบเทียบสองส่วนคือ ส่วนที่ 1 นำข้อมูลจริง จำนวน 13 ปี หรือ 153 เดือน มาประมาณค่าพารามิเตอร์เพื่อเปรียบเทียบหาตัวแบบที่เหมาะสม (Fitting Model) จากค่าพยากรณ์ของทั้งสองวิธี ส่วนที่ 2 นำข้อมูลจริง จำนวน 9 เดือน มาประมาณค่าพารามิเตอร์เพื่อเปรียบเทียบการตรวจสอบความถูกต้องของตัวแบบ (Validation Model) จากค่าพยากรณ์ของทั้งสองวิธี ผลการวิจัยพบว่า การเปรียบเทียบในส่วนของหาตัวแบบที่เหมาะสม (Fitting Model) และการตรวจสอบความถูกต้องของตัวแบบ (Validation

Model) ของงานวิจัยนี้ให้ค่า error ต่ำสุดทั้งหมด จึงสรุปได้ว่าตัวแบบที่สร้างมาได้จากงานวิจัยนี้ มีความเหมาะสมมากกว่า และสามารถนำไปใช้ในการพยากรณ์ข้อมูลอนุกรมเวลาต่างๆ ได้อย่าง ดี

ข้อเสนอแนะในการวิจัยครั้งต่อไป

1. ในการวิจัยครั้งต่อไป วิธีการของเบย์สามารถเพิ่มส่วน หรือลดประกอบต่างๆ ในข้อมูล อนุกรมเวลาได้เพื่อให้เหมาะสมกับการวิเคราะห์ข้อมูลเพิ่มขึ้น
2. ในส่วนของการหาตัวแบบที่เหมาะสม (Fitting Model) จะให้ค่า error ต่ำมาก แต่ในส่วน ของ การตรวจสอบความถูกต้องของตัวแบบ (Validation Model) มีค่า error สูง ซึ่งจาก การศึกษางานวิจัยในต่างประเทศพบว่าเกิด over fitting ดังนั้นควรจะมีการศึกษาในส่วน ของ over fitting นี้ต่อไปเพื่อให้ได้ค่าพยากรณ์ที่มีความแม่นยำมากขึ้น
3. สามารถนำวิธีการวิเคราะห์ไปประยุกต์ใช้งานข้อมูลอนุกรมเวลาอื่นๆกับอุตสาหกรรม ทางด้านอื่นๆ และงานทางด้านอื่นๆ ได้
4. ใช้เป็นพื้นฐานในการพัฒนาตัวแบบให้วิเคราะห์กับข้อมูลใกล้เคียงกับ โลกแห่งความเป็น จริตมากที่สุด

บรรณานุกรม

- สำนักงานเศรษฐกิจอุตสาหกรรม.2556. ข้อมูลการผลิตเหล็ก และเหล็กกล้าพื้นฐาน.
<http://www.oie.go.th/academic/index>. เข้าถึง 29 กันยายน 2556
- Anderson, J. A.1997. **An Introduction to Neural Networks** ,MIT Press. Chapter 1-17: 1-585
- Berger,D.E. **Introduction to Multiple Regression**.Claremont Graduate University.
- Bernd A. Berg. 2004. **Markov Chain Monte Carlo Simulations and Their Statistical Analysis**. Singapore, World Scientific.
- Bisgaard.S., Kulahci,M.2011. **Time Series Analysis and Forecasting by Example**. John Wiley & Sons. Inc.
- Boonsarawongse, R. and H.C. Co. 2007. Forecasting Thailand's rice export: Statistical techniques vs artificial neural network. **Computers & industrial engineering**. 53:610-627.
- Box, George E.P.,G.M.Jenkins and G. C. Reinsel.1994.**Time Series Analysis Forecasting and Control**. 3rd ed.,Prentice-Hall,Inc,USA.
- Brace,N., Kemp,R., Snelgar,R.,2006. **Spss for Psychologists: A Guide to Data Analysis Using Spss for Windows**.Palgrave Macmillan, Houndmills, UK
- Broemeling, L. and M. Land. 1984. On forecasting with univariate autoregressive process: A Bayesian approach. **Comm. Statist. Theory Methods**. 13:1305-1320.
- Cipra, T., J. Trujillo and A. Rubio. 1995. Holt-Winters method with missing observations. **Manag. Sci**. 41:174-78.
- Cipra, T. 2006. Exponential smoothing for irregular data. **Appl. Math**. 51:597-604.
- Congdon, P. 2006. **Bayesian Statistical Modelling**, 2nd ed., John Wiley & Sons: New York, pp. 1-56.
- Deetae, N.1991. **A comparative study of forecasting techniques on rice, cassava and mungbean. Farm Gate Prices**. Master Thesis, Kasetsart University, Thailand.63-64.
- Evans, M., N. Hastings and J.B. Peacock. 2000. **Statistical Distribution**.3rd ed., John Wiley and Sons, Inc., New York.

- Fourth, L.A. and J.W. Woodlock. 1960. Early prediction of market success for grocery products. **Journal of Marketing**. 61: 68-78.
- Fundamentals of Neural Networks**, blog, 10 May, 2012, www.myreaders.info/html/artificial_intelligence.html.
- Gnanadesikan, R. and J.R. Kettenring. 1972. Robust Estimates, Residuals, and Outlier Detection with Multiresponse Data. **Biometrics**. 28: 81-124.
- Hagan, M.T., Demuth, H.B., and Beale, M.H. 1996. **Neural Network Design**, PWS Publ. Company.
- Haykin, S. S. 1999. **Neural Networks: A Comprehensive Foundation**. Prentice Hall, Chapter 1-15:1-889.
- Hyndman, R.J., Koehle, A.B., Snyder, R.D. and Grose, S. 2002. A state space framework for automatic forecasting using exponential smoothing methods. **Int. J. Forecasting**. 18: 439-454.
- Iqbal, N., K. Bakhsh, A. Maqbool and A.S. Ahmad. 2005. Use of the ARIM Model for Forecasting What Area and Production in Pakistan. **Journal of Agriculture & Social Sciences**. 1(2):120-122.
- Kahforoushan, E., Zarif, M., and Mashahir, E.B. 2010. Prediction of added value of agricultural subsections using artificial neural networks: Box-Jenkins and Holt-Winters methods. **Journal of Development and Agricultural Economics**. 2(4):115-121.
- Kerdsomboon, M. 1999. **Forecasting of agricultural products and prices**. Master Thesis, Chulalongkorn University, Thailand. 197-200.
- Lee, R.D. and L.R. Carter. 1992. Modeling and forecasting U.S. mortality (discussion 671-675). **Journal of the American Statistician Association**. 87: 659-671.
- Lui, S. 1994. Mutiperiod Bayesian forecasts for AR models. **Ann. Inst. Statist. Mat.** 46(3):429-452.
- Mishra, A.K. and V.R. Desai. 2005. Drought forecasting using stochastic models. **Stochastic Environmental Research and Risk Assessment**. 19(5): 326-339.
- Monahan, J.F. 1983. Fully Bayesian analysis of ARMA time series models. **J. Econometrics**. 21:307-3631.
- Montgomery, D.C., Jennings, C.L., Kulahci, M. 2008. **Introduction to Time Series Analysis and**

- Forecasting**. John Wiley & Sons. Inc.
- National News Bureau of Thailand. **Thai agricultural area and path towards the kitchen of the world**. blog, 3 Jan, 2011, <http://thainews.prd.go.th/view>
- Neelamegham, R. and P. Chintagunta. 1999. A Bayesian model to forecast new product performance in domestic and international markets. **Marketing science**. 18(2): 115-136.
- Pedroza, C. 2006. A Bayesian forecasting model: predicting U.S. male mortality. **Biostatistics**. 7(4): 530-550.
- Pena, D. and F.J. Prieto. 2001. Multivariate Outlier Detection and Robust Covariance Matrix Estimation. **Technometrics**. 43: 286-300.
- Rencher, A.C. 1998. **Multivariate Statistical Inference and Applications**. John Wiley & Sons, Inc., New York.
- Robert, C. 2001. **The Bayesian Choice: From Decision-Theoretic Foundation**, 2nd ed., Springer: New York, pp. 8-31.
- Robert, C.P. and G. Casella. 2004. **Monte Carlo Statistical Methods**, 2nd ed., Springer: New York, pp. 267-291.
- Sangpattaranate, P. 2005. **Forecasting of rice prices in Thailand**. Master Thesis, Kasetsart University, Thailand. 149-153.
- SAS. 2011. SAS/STAT®9.3 User's Guide. SAS Institute Inc., North Carolina.
- Sumer, K.K., O. Goktas and A. Hepsag. 2009. The application of seasonal latent variable in forecasting electricity demand as an alternative method. **Energy Policy**. 37(4): 1317-1322.
- Tsay, R. S. **TSMODEL Algorithms**. The University of Chicago, USA.
- West, M., Harrison, J. 1997. **Bayesian forecasting and dynamic models**, 2nd ed., Springer. New York
- Wright, D.J. 1986. Forecasting data published at irregular time intervals using extension of Holt's method. **Manag. Sci.** 32: 499-510.
- Yan, X., and Su, X.G. 2009. **Linear Regression Analysis Theory and Computing**. World Scientific Publishing Company.

- Yelland, P. 2009. Bayesian forecasting for low-count time series using stat-space models: An empiricalevaluation for inventory management. **International Journal of Production Economics**. 118: 95-103.
- Yelland, P.M. 2010. Bayesian Forecasting of Part Demand. **International Journal of Forecasting**. 26: 374-396.



ภาคผนวก

ตัวอย่างชุดคำสั่งของโปรแกรม

```
Model{
for (i in 2:60)
{
y[i]~dnorm(mu.y[i],var.y.inv[i])
mu.y[i]<-gamma*diff.w[i]

w2[i]<-1-1/exp(pow((i/alpha.w),delta.w))
w1[i]<-1-1/exp(pow(((i-1)/alpha.w),delta.w))

diff.w[i]<-w2[i]-w1[i]

var.y.inv[i]<-1/var.y[i]
var.y[i]<-pow(psi[i]+1,2)*pow(gamma,2)*pow(sigma.y,2)
psi[i]~dbern(0.05)
E[i]<-abs(mu.y[i]-y[i])
}
sigma.y~dgamma(0.1,.001)
s~dnorm(gamma,var.inv.s)
var.inv.s<-1/var.s
var.s<-pow(gamma,2)

alpha.w~dnorm(mu.alpha.w,var.alpha.w)I(0,)
mu.alpha.w~dnorm(0,.00001)
var.alpha.w~dgamma(0.1,.001)

delta.w~dnorm(mu.delta.w,var.delta.w)I(0,)
mu.delta.w~dnorm(0,.00001)
var.delta.w~dgamma(0.1,.001)

gamma~dnorm(mu.gamma,var.gamma)I(0,)
var.gamma~dgamma(0.1,0.001)
mu.mu.gamma~dnorm(mu.mu.gamma,var.var.gamma)
var.var.gamma~dgamma(0.1,.001)

alpha1~dnorm(0,.00001)
mu.mu.gamma~dnorm(0,.00001)
}
Data
list(y=c(88.49...,
',
120.64
),s=12000)
Initial
list(gamma=1,sigma.y=1, var.gamma=0.1,mu.gamma=0,var.var.gamma=0.1,
```

$\mu.\mu.\gamma=0, \alpha.w=1, \mu.\alpha.w=0, \text{var}.\alpha.w=0.1, \delta.w=1, \mu.\delta.w=0, \text{var}.\delta.w=0.1)$



ประวัติผู้วิจัย

ชื่อ-สกุล: นางสาววัชรินทร์ แสงมา

(Miss Watcharin Sangma)

ตำแหน่ง: ผู้ช่วยศาสตราจารย์ มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร
สาขาวิศวกรรมอุตสาหกรรม คณะวิศวกรรมศาสตร์

การศึกษา: อ.บ. เทคโนโลยีขนถ่ายวัสดุ สถาบันเทคโนโลยีพระจอมเกล้าพระนคร
เหนือ

ว.ม. วิศวกรรมการจัดการอุตสาหกรรม สถาบันเทคโนโลยีพระจอม
เกล้าพระนครเหนือ

ชื่อ-สกุล: นายพิชญ์ ทองขาว

(Mr. Pitsanu Tongkhaw)

ตำแหน่ง: อาจารย์ มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร
สาขาวิศวกรรมอุตสาหกรรม คณะวิศวกรรมศาสตร์

การศึกษา: ค.อ.บ. วิศวกรรมอุตสาหกรรม-ออกแบบการผลิต สถาบันเทคโนโลยีราชม
งคล

ว.ศ.ม. วิศวกรรมอุตสาหกรรม สถาบันเทคโนโลยีพระจอมเกล้าพระนคร
เหนือ

ว.ศ.ด. วิศวกรรมอุตสาหกรรม มหาวิทยาลัยเกษตรศาสตร์

ชื่อ-สกุล: นางสาวอรศิริ จันทร์เมือง

(Miss. Onsiri Chanmuang)

ตำแหน่ง: อาจารย์ มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร
สาขาวิศวกรรมอุตสาหกรรม คณะวิศวกรรมศาสตร์

การศึกษา: ค.อ.บ. วิศวกรรมอุตสาหกรรม สถาบันเทคโนโลยีราชมงคล

ว.ศ.ม. วิศวกรรมการจัดการอุตสาหกรรม สถาบันเทคโนโลยีพระจอม
เกล้าพระนครเหนือ