


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

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

อัตรศหสัมพันธ์ที่ซ้อนเร้น:

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

ข้อมูลศคปกค:

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


ค่าคคหวังของผลรวมของข้อมูลนุกรมเวลา:

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

ผลรวมของข้อมูลนุกรมเวลาท้งหคคในช่วงเวลาที่ศคษา:

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

ล้าหรัลโครงสร้างของค้วเบบเบย้ในงานวจยนี้ล้าหรัลแสดงได้ล้าภาพที่ 4



ภาพที่ 4 โครงสร้างของค้วเบบเบย้ในงานวจยนี้

สำหรับสมการพยากรณ์ของตัวแบบเบย์ในงานวิจัยนี้แสดงดังข้างล่าง

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

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

จากสมการที่ 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 $(\gamma, \alpha, \delta, A_i, \zeta_i, \mu_\alpha)$ 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

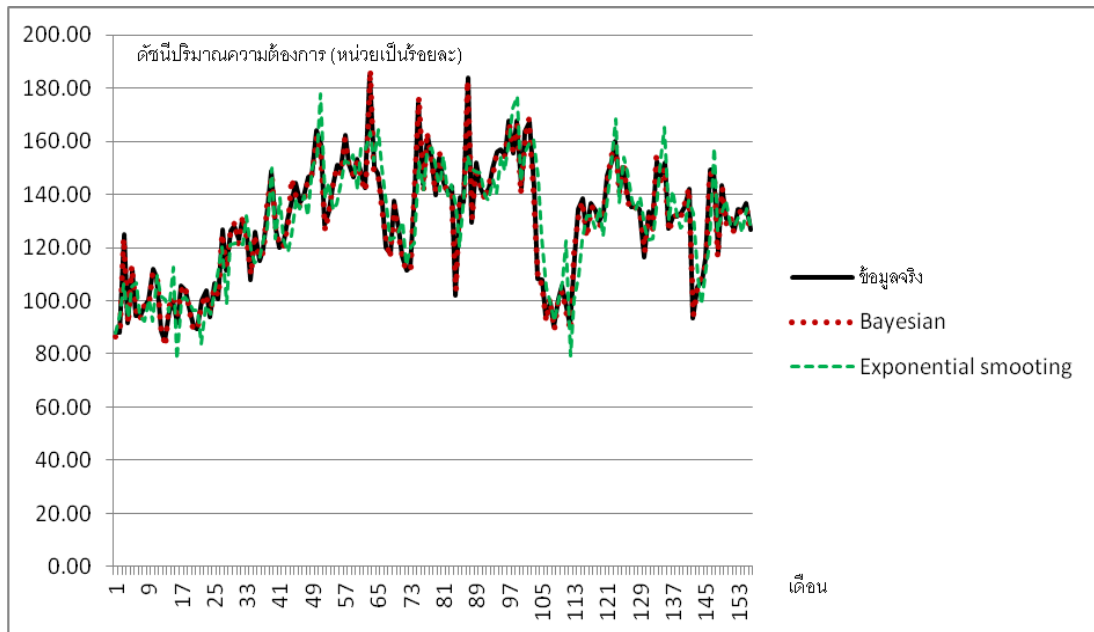
เมื่อได้ตัวแบบที่เหมาะสมแล้วจึงเลือกใช้ค่าพารามิเตอร์ที่ประมาณได้จากข้อมูลจริงจำนวน 13 ปี หรือ 153 เดือน มาเปรียบเทียบกับวิธีการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียลเพื่อหาตัวแบบที่เหมาะสม (Fitting Model) และเปรียบเทียบเพื่อตรวจสอบความถูกต้อง ของตัวแบบ (Validation Model) พยากรณ์ที่เสนอกับวิธีการพยากรณ์ปรับเรียบแบบเอ็กซ์โปเนนเชียล 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