

การประชุมวิชาการทางวิศวกรรมไฟฟ้า ครั้งที่ 36

The 36th Electrical Engineering Conference (EECON 36)

11-13 ธันวาคม 2556

ณ เฟลิกซ์ ริเวอร์แคว รีสอร์ท จ.กาญจนบุรี



มหาวิทยาลัยเกษตรศาสตร์
Kasetsart University
พ.ศ. 2485-2558

Volume 1

(PW) ไฟฟ้ากำลัง

(PE) อิเล็กทรอนิกส์กำลัง

Electrical Engineering Dept.

Faculty of Engineering

Kasetsart University

50 Ngamwongwan Road-Latyaoo

Chatuchak Bangkok 10900

Tel: 02-797-0999 ext 1503, 1504

Fax: 02-579-7566



การพยากรณ์ค่าความต้องการใช้ไฟฟ้าสูงสุดของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทยโดยกระบวนการเกาส์เซียน

Forecasting Peak Electricity Demand of Electricity Generating Authority of Thailand by Gaussian Process

ทศนัย พลอยสุวรรณ และ ธนวันต์ ยลพัทธ์

ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสยาม

38 ถนนเพชรเกษม แขวงบางหว้า เขตภาษีเจริญ กรุงเทพมหานคร 10160 Email: tuchsanai@gmail.com, tanawan.yonlaphat@gmail.com

PW067

บทคัดย่อ

งานวิจัยนี้นำเสนอการพยากรณ์หาค่าความต้องการไฟฟ้าสูงสุด (Peak load) ระหว่างปี 2011-2012 ของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (EGAT) โดยใช้วิธีการกระบวนการเกาส์เซียน (Gaussian Process : GP) ซึ่งใช้ข้อมูลระหว่างปี 2000-2010 เป็นข้อมูลฝึกสอนโดยประกอบด้วย 4 ตัวแปรสำคัญได้แก่ เวลาเป็นรายเดือน, ค่า Peak load เป็นรายเดือน, ค่าผลิตภัณฑ์มวลรวมในประเทศ (GDP) และ ผลิตภัณฑ์ประชาชาติ (GNP), ตามลำดับ นอกจากนี้ยังนำเสนอวิธีคำนวณหาค่า Hyper-Parameters θ ซึ่งเป็นตัวแปรสำคัญที่ใช้ในการเพิ่มประสิทธิภาพการพยากรณ์ของ GP ที่นำเสนอ ผลการทดลองพบว่า การพยากรณ์โดยใช้วิธีการกระบวนการเกาส์เซียนให้ค่าความผิดพลาดที่น้อยกว่าและประสิทธิภาพที่ดีกว่า การใช้โครงข่ายประสาทเทียม (Neural Networks) ซึ่งเป็นวิธีที่ใช้กันอยู่อย่างแพร่หลายในปัจจุบัน

คำสำคัญ: กระบวนการเกาส์เซียน, การทำนายค่าโหลด, ค่าความต้องการพลังไฟฟ้าสูงสุด, โครงข่ายประสาทเทียม

Abstract

This paper presents the forecast of the peak electricity demand (peak load) during the 2011-2012 of the Electricity Generating Authority of Thailand (EGAT) by using Gaussian Process (GP), which was used training data set from the years 2000 to 2010. The training data set composed of four key variables, including time on a monthly, the monthly of electricity peak load, the gross domestic product (GDP), and finally gross national product (GNP) respectively. Moreover, the hyper-parameters θ are the key parameters using to optimize peak electricity demand of electricity. Simulation results show that the proposed forecasting method presents lower error and better performance than the artificial neural networks, which are forecasting methods that are widely used today.

Keywords: Gaussian Process, Load Forecasting, Peak Electricity Demand, Neural Network

1. คำนำ

ในแต่ละปีแนวโน้มความต้องการใช้ไฟฟ้าของประเทศเพิ่มขึ้นอย่างรวดเร็วสืบเนื่องมาจากการพัฒนาทางเศรษฐกิจและอุตสาหกรรมที่เพิ่มขึ้นอีกทั้งพลังงานไฟฟ้าเป็นปัจจัยพื้นฐานที่สำคัญต่อการขับเคลื่อนระบบเศรษฐกิจเพื่อไม่ให้กระทบต่อระบบเศรษฐกิจและความมั่นคงของประเทศการพยากรณ์ความต้องการใช้ไฟฟ้าซึ่งโดยทั่วไปจะใช้การทำนายค่าโหลด (Load Forecasting) [1-4] ซึ่งมีความสำคัญอย่างมากในการวางแผนระบบการผลิตไฟฟ้าและสำรองไฟฟ้า, การซื้อ-ขายไฟฟ้า, และการกำหนดอัตราค่าไฟฟ้าทั้งในปัจจุบันและอนาคตซึ่งการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (กฟผ.) ได้เก็บและเผยแพร่ข้อมูลค่าความต้องการพลังไฟฟ้าสูงสุด (Peak load) และค่าพลังงานไฟฟ้าสุทธิ (Energy load) ของแต่ละเดือนในรายงานประจำปี [5] ต่อเนื่องทุกปีตั้งแต่ปี 2000-2012 เพื่อใช้สำหรับ การวางแผนสร้างโรงไฟฟ้า, ระบบสายส่งและสายจำหน่าย, และเป็นข้อมูลให้นักลงทุนเพื่อใช้คาดการณ์แนวโน้มความต้องการพลังไฟฟ้าสูงสุดและความต้องการพลังงานไฟฟ้าสุทธิรายเดือนที่เพิ่มขึ้นในทุกปี

ค่า Peak load และ Energy load มีสัมพันธที่แบบไม่เป็นเชิงเส้น (Non-linear) กับหลายตัวแปรทั้งทางฟิสิกส์และเศรษฐศาสตร์โดยทาง Physics: เช่นสภาพอากาศ, อุณหภูมิ และทาง Economic: เช่นแนวโน้มการใช้พลังงานในอดีต, จำนวนประชากร (Population), ผลิตภัณฑ์ประชาชาติ (GNP), ผลิตภัณฑ์มวลรวมในประเทศ (GDP), ราคาน้ำมัน (Oil price), และราคาค่าไฟฟ้าต่อหน่วย (Electrical price per unit) [2, 3]. ซึ่งการพยากรณ์แบ่งได้เป็นระยะสั้น (Short-term : 15 นาทีถึง 1 สัปดาห์) และระยะยาว (Long-term : เดือน, ปี, หรือ 10 ปี) โดยเทคนิคทั่วไปในการพยากรณ์ได้แก่ Autoregressive moving average (ARMA) [6], โครงข่ายประสาทเทียม Neural Networks (NN) [3, 4], Support Vector Regression (SVR) [2]. ซึ่งตัวแปรที่ใช้ก็จะต่างกันไปตามประเภทของการพยากรณ์ เช่นพยากรณ์ Short-term ปัจจัยทาง Physics, ราคาน้ำมัน, ราคาไฟฟ้ามีผลต่อการคำนวณ แต่ในการคำนวณ Long-term ปัจจัยทาง Economic เช่น GDP, GNP มีผลมากกว่า [3]. อย่างไรก็ตามวิธีที่กล่าวมาถ้ามีข้อมูลฝึกสอน Training Data จำนวนน้อยก็มักจะประสบปัญหาภัยกับ Local Minimum [2] ในการหาค่าตอบเช่นกัน

Gaussian Process (GP) คือระบบ Stochastic Process ซึ่งปัจจุบันถูกยอมรับแล้วว่าเป็นเครื่องมือที่มีประสิทธิภาพในการแก้ปัญหาประเภท Regression, Classification, และ Decision ใน Machine learning สามารถทำงานได้ดีถึงแม้ว่ามี Training Data น้อยและมีประสิทธิภาพ และ Convergence rate ดีกว่า ARMA, NN และ SVR ตามลำดับ [7]

งานวิจัยนี้นำเสนอการใช้ GP เพื่อใช้ในการพยากรณ์ค่าความต้องการพลังไฟฟ้าสูงสุด Peak load โดยใช้ข้อมูลระหว่างปี 2000-2010 เป็นข้อมูลฝึกสอน (Training data set) ซึ่งประกอบไปด้วย 1.ค่าไฟฟ้าสูงสุดรายเดือน 2.เวลา (เดือน ปี) 3.ค่า GDP และ 4. ค่า GNP และใช้ข้อมูลระหว่างปี 2011-2012 เป็นข้อมูลทดสอบความสามารถของ Algorithm โดยจะใช้เพียงแค่ตัวแปรเวลา (ไม่ใช้ GDP และ GNP) นอกจากนี้ยังนำเสนอการ Optimization เพื่อหาค่า **Hyper-Parameters** θ ซึ่งเป็นตัวแปรสำคัญในการเพิ่มประสิทธิภาพการทำงานให้กับ GP

2. Gaussian Process (GP)

2.1 GP Fundamental

ความหมายของการกระจายแบบเกาส์เซียน หลายตัวแปร (Multivariable Gaussian distribution) ถูกนิยามโดยค่า Probability density function (pdf) : $\mathcal{N}(\mu, \Sigma)$ โดยที่

$$\mathcal{N}(\mu, \Sigma) = \frac{1}{(2\pi)^{\frac{d}{2}} \sqrt{|\Sigma|}} \exp\left(-\frac{1}{2}(X-\mu)\Sigma^{-1}(X-\mu)'\right) \quad (1)$$

ซึ่ง $X \sim \mathcal{N}(\mu, \Sigma)$ มีค่าเป็นการสุ่มบนเวกเตอร์ $X \in \mathbb{R}^d$ ที่มีค่า Mean : $\mu = E[X] \in \mathbb{R}^d$ และ Covariance : $\Sigma = E[(X-\mu)(X-\mu)'] \in \mathbb{R}^{d \times d}$.

Gaussian Process (GP) [7] คือ Probability density function (pdf) ที่มีการกระจายแบบเกาส์เซียนบน $f(x)$ ซึ่งนิยามโดย

$$f(x_i) \sim GP(m(x_i), k(x_i, x_j)) \quad (2)$$

$f: X \in \mathbb{R}^d \rightarrow \mathbb{R}$ ในทางทฤษฎีค่า d ของ GP สามารถมีค่ามากได้ถึง ∞ หรือ $X = \mathbb{R}$ โดยค่าของ $f(x)$ ถูกสุ่มโดยมีค่า Mean : $m(x_i)$ และ Covariance function $k(x_i, x_j)$ [ในบางครั้งเรียก $k(x_i, x_j)$ ว่า Kernel function ของ $f(x)$]

$$\begin{aligned} m(x_i) &= E[f(x_i)] \\ k(x_i, x_j) &= E[(f(x_i) - m(x_i))(f(x_j) - m(x_j))] \end{aligned} \quad (3)$$

เวกเตอร์ x_i และ $x_j \in \mathbb{R}^d$ มีค่าเช่น $x_i = [x_{i,1}, x_{i,2}, \dots, x_{i,d}]^T$. เพื่อให้ง่ายมักจะกำหนดให้ $m(x_i) = 0$ และในทางปฏิบัติการหาของ Kernel function $k(x_i, x_j)$ ใน (3) มีข้อจำกัดในเรื่องของ 1.จำนวนข้อมูลฝึกสอน x_i และ $f(x_i)$ และ 2.บางครั้งอาจจะมีการวัดข้อมูลที่ผิดพลาด เช่น $y_i = f(x_i) + \varepsilon_i$ โดยที่ ε_i คือค่า error ในการวัดทำให้ไม่สามารถประมาณค่าของ $E[\cdot]$ ใน (3) ได้ถูกต้องดังนั้นการหา Kernel function มักใช้ทางอ้อม โดยให้คิดในรูปของ θ เช่น Squared exponential [7]

$$k(x_i, x_j | \theta) = \sigma_{se}^2 \exp\left(-\frac{1}{2} \sum_{k=1}^d \frac{(x_{i,k} - x_{j,k})^2}{l_k}\right) \quad (4)$$

โดยนิยามให้ค่าพารามิเตอร์ $\theta = (\sigma_{se}^2, l_1, l_2, \dots, l_d)$ เรียกว่า **Hyper-Parameters** [ค่าพารามิเตอร์ใน Kernel function: $k(x_i, x_j)$]

2.2 GP Prior

พิจารณาระบบที่มีข้อมูลฝึกสอน (Training data) ความยาว (N) โดยนิยามค่าของเซต X และค่าของเซตฟังก์ชัน f ที่คู่กับ X เป็น

$$\begin{aligned} X &\in \mathbb{R}^{N \times d} = \{x'_i = [x_{i,1}, x_{i,2}, \dots, x_{i,d}]\}_{i=1}^N \\ f &\in \mathbb{R}^{N \times 1} = [f(x_1), f(x_2), \dots, f(x_N)] \\ D &= \{X, f\} \end{aligned} \quad (5)$$

โดยที่ D ใน (5) เรียกว่าเซตข้อมูลฝึกสอน (Training data set)

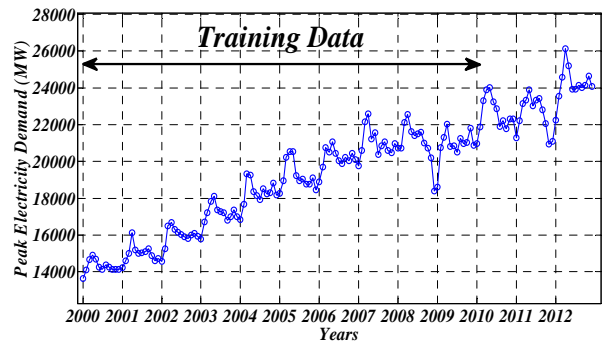
GP Prior เมื่อมี Training data ความยาว (N) ถูกนิยามโดย

$$P(f|X, \theta) = \mathcal{N}(0, K_{f,f}) \quad (6)$$

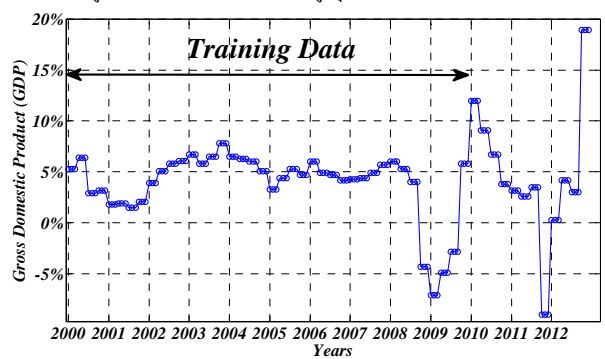
ค่าของ Covariance Matrix $K_{f,f} \in \mathbb{R}^{N \times N}$ สามารถถูกสร้างขึ้นโดยอาศัยสมการ (4) โดยที่ $K_{f,f}(i, j)$ เป็นสมาชิกของเมตริกซ์แถวที่ i หลักที่ j ของ Kernel เมตริกซ์ $K_{f,f}$ โดยที่

$$K_{f,f}(i, j) = k(x_i, x_j | \theta) \quad (7)$$

3. การออกแบบโมเดลพยากรณ์ Peak load ด้วย GP



รูปที่ 1. ความต้องการพลังไฟฟ้าสูงสุดรายเดือนระหว่างปี 2000-2012 [5]



รูปที่ 2. ค่า GDP ระหว่างปี 2000-2012[8]

เนื่องจากงานวิจัยนี้ใช้ค่าข้อมูล Peak load [5] เป็นรายเดือนระหว่างปี 2000-2010 ดังนั้นข้อมูลฝึกสอน $N = 11 \times 12 = 132$ ดังแสดงในรูปที่ 1. (โดยใช้ระยะเวลาเก็บข้อมูล 11 ปี). กำหนดให้ $i \in \{1, 2, \dots, N\}$ โดย t_i เป็นเวลาที่เก็บข้อมูล Peak load เช่น $i = 3$ คือข้อมูลของเดือน March 2000 [5] ดังนั้น $t_i = \text{datenum}(2000, 3, 1) = 730546$ โดย Code คำสั่ง datenum เป็นการแปลงค่า [ปีเดือนวันเวลา]

เป็นค่า Time index ซึ่งเป็นค่าตั้งอยู่ในโปรแกรม MATLAB ดังนั้น
 เวกเตอร์ $x_i \in \mathbb{R}^3 = [t_i, GDP(t_i), GNP(t_i)]^T$ และค่าไฟฟ้าสูงสุด $f(x_i)$
 คู่กับ $f: X_i \in \mathbb{R}^3 \rightarrow \mathbb{R}$ โดยเซตข้อมูลฝึกสอน $D = \{X, f\}$ ถูกนิยาม
 ตามสมการ (5) และค่า GP Prior สามารถหาได้โดย (6),(7) ตามลำดับ
 งานวิจัยนี้คือการพยากรณ์ค่า Peak load หรือ $f(x_j^*)$ ของ
 ข้อมูลระหว่างปี $t_j \in [2011 \ 2012]: j \in \{1, 2, \dots, M\}: M = 24$ โดยให้
 $x_j^* = (t_j, 0, 0)$, $X^* = \{x_j^*\}_{j=1}^M$, $f^* = [f(x_1^*), f(x_2^*), \dots, f(x_M^*)]^T$ ดังนั้น
 Joint Gaussian pdf ของแปร latent f และ f^* คือ

$$P\left(\begin{bmatrix} f \\ f^* \end{bmatrix} | X, X^*, \theta\right) = \mathcal{N}\left(0, \begin{bmatrix} \mathbf{K}_{f,f} & \mathbf{K}_{f,f^*} \\ \mathbf{K}_{f,f^*}^T & \mathbf{K}_{f^*,f^*} \end{bmatrix}\right) \quad (8)$$

โดยค่า $\mathbf{K}_{f,f} \in \mathbb{R}^{N \times N} = k(X, X | \theta)$, $\mathbf{K}_{f,f^*} \in \mathbb{R}^{N \times M} = k(X, X^* | \theta)$ และ
 $\mathbf{K}_{f^*,f^*} \in \mathbb{R}^{M \times M} = k(X^*, X^* | \theta)$ อาศัย **ภาคผนวก.ก** ใน (8) ได้

$$P(f^* | X, X^*, \theta) = \mathcal{N}(m(X^* | \theta), \mathbf{K}(X^* | \theta)) \quad (9)$$

หรือ $f^* | X, X^*, \theta \sim \mathcal{N}(m(X^* | \theta), \mathbf{K}(X^* | \theta))$ ดังนั้น GP ของการ
 พยากรณ์ความต้องการใช้ไฟฟ้าสูงสุดคือ

$$f^* \sim \mathcal{GP}(m(X^* | \theta), \mathbf{K}(X^* | \theta)) \quad (10)$$

ค่า Mean และ Covariance (Kernel matrix) ของ GP ใน (10) คือ

$$\begin{aligned} m(X^* | \theta) &= \mathbf{K}_{f,f^*}^T \mathbf{K}_{f,f}^{-1} f \\ \mathbf{K}(X^* | \theta) &= \mathbf{K}_{f^*,f^*} - \mathbf{K}_{f^*,f}^T \mathbf{K}_{f,f}^{-1} \mathbf{K}_{f,f^*} \end{aligned} \quad (11)$$

Peak load ระหว่างปี 2011-2012 ถูกแทนค่าโดย Conditional mean

$$f^* \in \mathbb{R}^M = m(X^* | \theta) = [m(x_1^* | \theta), m(x_2^* | \theta), \dots, m(x_M^* | \theta)]^T$$

จากนั้นทำการจัดรูป (11) ใหม่ในรูปของ kernel linear combination

$$f(x_j^*) \cong m(x_j^* | \theta) = \sum_{i=1}^N \alpha_i k(x_j^*, x_i | \theta) \quad (12)$$

$$\text{where } \alpha \in \mathbb{R}^N = \mathbf{K}_{f,f}^{-1} f$$

โดยที่เวกเตอร์ $\alpha = [\alpha_1 \ \alpha_2 \ \dots \ \alpha_N]^T$ และ $j \in \{1, 2, \dots, M\}$

3.การคำนวณหาค่า Hyper-Parameters θ

ค่า Hyper-Parameters $\theta = (\sigma_{se}^2, l_1, l_2, \dots, l_d)$ เป็นตัวแปรสำคัญ
 ที่อยู่ใน Kernel function $k(x_i, x_j | \theta)$ ใน (4). โดยเป็นส่วนหนึ่งของ
 คำตอบของการพยากรณ์ค่า Peak load $f(x_j^*) \cong m(x_j^* | \theta)$ โดยใช้
 Gaussian Process GP ในสมการที่ (12) ดังนั้นประสิทธิภาพในการ
 พยากรณ์จึงขึ้นอยู่กับหาค่า θ ที่ถูกต้องเมื่อมีความยาวข้อมูลฝึกสอน
 จำกัดโดยการหาค่า θ จะใช้ความรู้จากข้อมูลฝึกสอน x_i และ $f(x_i)$
 อาศัยสมมุติฐานว่าค่าไฟฟ้าสูงสุดที่วัดได้ (ข้อมูลจาก กฟผ.) [5] มี
 ความคลาดเคลื่อน (error) จากการวัดเป็น $\varepsilon_i \sim \mathcal{N}(0, \sigma^2)$ ดังนั้นค่าข้อมูล
 ฝึกสอน Peak load ถูก (model) เป็น

$$y_i = f(x_i) + \varepsilon_i \quad (13)$$

และให้เวกเตอร์ $Y = [y_1 \ y_2 \ \dots \ y_N]^T$ โดยถ้ากำหนดให้ $\sigma^2 \rightarrow 0$
 หมายถึงข้อมูลที่วัดได้มีความน่าเชื่อถือสูงดังนั้นเราจะพบว่าค่าการ
 marginal likelihood ของตัวแปร f ใน (13) สามารถ model ได้เป็น

$$P(Y | X, \theta, \sigma^2) = \int P(Y | f, X, \theta, \sigma^2) P(f | X, \theta, \sigma^2) df \quad (14)$$

โดยอาศัย GP Prior ใน (6) และ likelihood function ใน (13) มีค่าเป็น

$$\begin{aligned} P(f | X, \theta, \sigma^2) &= P(f | X, \theta) = \mathcal{N}(f | 0, \mathbf{K}_{f,f}) \\ P(Y | f, X, \theta, \sigma^2) &= \prod_{i=1}^N \mathcal{N}(y_i | f(x_i), \sigma^2) \end{aligned} \quad (15)$$

นำ (15) แทนใน (14) และอินทิเกรตและโดยอาศัย **ภาคผนวก.ข** ได้

$$P(Y | X, \theta, \sigma^2) = \mathcal{N}(Y | 0, \mathbf{K}_{f,f} + \sigma^2 \mathbf{I}_{N \times N}) \quad (16)$$

ดังนั้นค่า log marginal likelihood ของ Hyper-Parameters θ มีค่าเป็น

$$\begin{aligned} L' &= \log P(Y | X, \theta, \sigma^2) \\ &= -\frac{1}{2} Y^T (\mathbf{K}_{f,f} + \sigma^2 \mathbf{I})^{-1} Y - \frac{1}{2} \log |\mathbf{K}_{f,f} + \sigma^2 \mathbf{I}_N| - \frac{N}{2} \log 2\pi \end{aligned} \quad (17)$$

ให้ negative log likelihood ของสมการ (17) มีค่าประมาณเป็น

$$L(\theta, \sigma^2) \cong \frac{1}{2} Y^T (\mathbf{K}_{f,f} + \sigma^2 \mathbf{I})^{-1} Y + \frac{1}{2} \log |\mathbf{K}_{f,f} + \sigma^2 \mathbf{I}_N| \quad (18)$$

เรากำหนดหา θ และ σ^2 ได้โดยการหาค่าการ MAP (Maximum a
 posterior) estimation และโดยอาศัย Bayes' theorem จะได้ว่า

$$\begin{aligned} \{\theta, \sigma^2\} &= \arg \max_{\theta, \sigma^2} \log P(\theta, \sigma^2 | X, Y) \\ &\propto \arg \max \log \frac{P(Y | X, \theta, \sigma^2) P(\theta) P(\sigma^2)}{P(X, Y)} \\ &\propto \arg \max \log P(Y | X, \theta, \sigma^2) P(\theta) P(\sigma^2) \end{aligned} \quad (19)$$

ค่า $P(X, Y)$ ไม่มีผลกับ Maximization ใน (19) ดังนั้นเพื่อให้ง่ายและ
 สะดวกในการหา $\{\theta, \sigma^2\}$ ปัญหา Maximization จะสมมูลกับ

$$\{\theta, \sigma^2\} = \arg \min L(\theta, \sigma^2) - \log P(\theta) - \log P(\sigma^2) \quad (20)$$

ดังนั้นการหาค่า $\{\theta, \sigma^2\}$ สามารถหาได้จาก numerical method โดยการ
 Minimization สมการ (20) (ใช้คำสั่ง fminsearch ใน MATLAB) โดยที่
 เลือก Prior Probability $\{\theta, \sigma^2\}$ เป็น Inverse-Gamma priori

$$P(l_i) = \frac{\beta^\alpha}{\Gamma(\alpha)} l_i^{-(\alpha+1)} \exp\left(-\frac{\beta}{l_i}\right) \quad i = 1, 2 \quad (21)$$

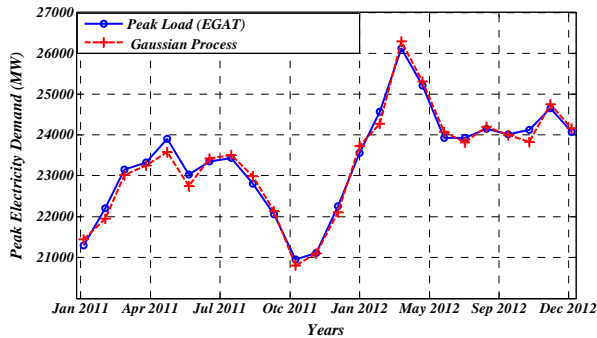
$$P(\theta) = P(l_1) P(l_2)$$

ให้ $\beta = 10, \alpha = 0.5$ เพื่อใช้สำหรับเป็นค่า initial conditions และค่า
 Prior Probability density function ของค่าความคลาดเคลื่อนจากการ
 วัด $\varepsilon_i \sim \mathcal{N}(0, \sigma^2)$ กำหนดให้เป็น Inverse-chi-squared distribution


$$P(\sigma^2) = \left(\frac{1}{\sigma^2}\right)^{(\alpha-1)} \exp\left(-\frac{\beta}{\sigma^2}\right) \quad (22)$$

ให้ค่า initial conditions ใน (22) เป็น $\beta = 0.01, \alpha = 5$ ตามลำดับโดยใน
 งานวิจัยนี้กำหนดให้ค่า $\sigma_{se}^2 = 1$ เพื่อลดความซับซ้อนในการ
 Minimization หาคำตอบในสมการที่ (20)

4. ผลการทดลอง



รูปที่ 3. ผลการพยากรณ์ Peak load ระหว่างปี 2011-2012 โดยใช้ Gaussian Process



รูปที่ 4. ผลการพยากรณ์ Peak load โดยใช้โครงข่ายประสาทเทียม [3]

ผลการพยากรณ์แนวโน้มค่าความต้องการความต้องการไฟฟ้าสูงสุด (Peak load) ระยะยาวระหว่างปี 2011-2012 (ทั้งหมด 24 เดือน) $f(x_j^*)$ ในสมการที่ (12) โดยใช้กระบวนการเกาส์เซียน (Gaussian Process : GP) ซึ่งรวมถึงการคำนวณค่า Hyper-Parameters θ ตามสมการที่ (20) ถูกนำเสนอในรูปที่ 3. และผลการทดลองเปรียบเทียบโดยใช้วิธีของโครงข่ายประสาทเทียม (Neural Networks) [3] ถูกนำเสนอในรูปที่ 4. ซึ่งทั้งหมดใช้ข้อมูลระหว่างปี 2000-2010 เป็นข้อมูลฝึกสอนโดยใช้ 4 ตัวแปร คือ เวลาเป็นรายเดือน, ค่า Peak load รายเดือน, GDP และ GNP ตามลำดับ

4. สรุป

บทความนี้นำเสนอการพยากรณ์ค่าความต้องการไฟฟ้าสูงสุด (Peak load) ระยะยาวระหว่างปี 2011-2012 โดยใช้ Gaussian Process (GP) ซึ่งผลการพยากรณ์ที่ดีกว่าเมื่อเปรียบเทียบกับการใช้โครงข่ายประสาทเทียม (Neural Networks)

5. กิตติกรรมประกาศ

ขอขอบคุณ มหาวิทยาลัยสยามที่สนับสนุนงบประมาณในการทำโครงการวิจัยอย่างต่อเนื่อง ตลอดระยะเวลาทำโครงการวิจัยนี้

6. ภาคผนวก ก. Marginal Gaussian Probability

$$P(x, y) = \mathcal{N}\left(\begin{bmatrix} a \\ b \end{bmatrix}, \begin{bmatrix} A & B \\ B^T & C \end{bmatrix}\right) \rightarrow P(x|y) = \mathcal{N}(a + BC^{-1}(y-b), A - BC^{-1}B^T)$$

7. ภาคผนวก ข. ผลคูณของ Gaussian Probability

$$\mathcal{N}(X|a, A)\mathcal{N}(X|b, B) \rightarrow Z^{-1}\mathcal{N}(X|c, C)$$

โดยที่ $c = C(A^{-1}a + B^{-1}b)$, $C = (A^{-1} + B^{-1})^{-1}$ และ Z^{-1} คือค่าคงที่

8. เอกสารอ้างอิง

- [1] M. Chanza, P. Ramjith, and G. Van Harmelen, "Forecasting domestic hourly load profiles using vector regressions," in *Domestic Use of Energy Conference (DUE), 2013 Proceedings of the 21st*, 2013, pp. 1-5.
- [2] L. Ghelardoni, A. Ghio, and D. Anguita, "Energy Load Forecasting Using Empirical Mode Decomposition and Support Vector Regression," *Smart Grid, IEEE Transactions on*, vol. 4, pp. 549-556, 2013.
- [3] M. A. Mamun and K. Nagasaka, "Artificial neural networks applied to long-term electricity demand forecasting," in *Hybrid Intelligent Systems, 2004. HIS '04. Fourth International Conference on*, 2004, pp. 204-209.
- [4] Y. Zhang, Q. Zhou, C. Sun, S. Lei, Y. Liu, and Y. Song, "RBF Neural Network and ANFIS-Based Short-Term Load Forecasting Approach in Real-Time Price Environment," *Power Systems, IEEE Transactions on*, vol. 23, pp. 853-858, 2008.
- [5] "Annual Report " Electricity Generating Authority of Thailand (EGAT) 2001-2012.
- [6] J.-j. Wang, D.-X. Niu, and L. Li, "An ARMA Cooperate with Artificial Neural Network Approach in Short-Term Load Forecasting," in *Natural Computation, 2009. ICNC '09. Fifth International Conference on*, 2009, pp. 60-64.
- [7] C. E. Rasmussen and C. K. I. Williams, *Gaussian processes for machine learning*. Cambridge, Mass.: MIT Press, 2006.
- [8] *Office of the National Economic and Social Development Board Thailand*. Available: <http://eng.nesdb.go.th/>