

CS 調整型ガウシアンプロセスモデルによる 九州地区の電力需要予測

奥屋 貴宏 八野 知博
(鹿児島大学)

1 はじめに

本稿ではガウシアンプロセス (GP) モデル^[1]に基づく短期電力需要予測を提案する。ニューラルネットワークや RBF モデルなど従来の予測法と比べ、GP モデルは決定すべきパラメータ数が少なく、予測値のみならずその信頼性の尺度までも与えることができる。2014 年の九州地区の月毎の電力需要を予測するシミュレーションにより、本手法の有効性を確認した。

2 問題設定

j 時間先の電力需要予測器は次のように表されると仮定する。

$$y(k+j) = f_j(\mathbf{x}(k)) + \epsilon_j(k) \quad (j = 1, 2, \dots, 24) \quad (1)$$

$$\mathbf{x}(k) = [y(k), y(k-1), \dots, y(k-23)]^T$$

ここで、 $y(k+j)$ は時刻 k から j 時間先の電力需要を表す。 $\epsilon_j(k)$ は平均 0、分散 σ_j^2 の正規性雑音とする。本稿では、多段先予測のための (2) 式の確率分布を構築し、GP モデルの枠組みで 24 時間先までの電力需要予測を行う。

$$y(k+j)|\mathbf{x}(k) \sim \mathcal{N}(\hat{y}_*(k+j), \hat{\sigma}_*^2(k+j)) \quad (j = 1, 2, \dots, 24) \quad (2)$$

3 GP モデルによる予測

(1) 式において、 $k = k_s, k_s + 1, \dots, k_s + N - 1$ とおくことにより、(3) 式の GP 事前モデルを得る。

$$\mathbf{w}_j \sim \mathcal{N}(\mathbf{m}_j(\mathbf{X}), \mathbf{S}_j(\mathbf{X}, \mathbf{X}) + \sigma_j^2 \mathbf{I}_N) \quad (3)$$

ここで、

$$\mathbf{w}_j = [y(k_s + j), y(k_s + j + 1), \dots, y(k_s + j + N - 1)]^T$$

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T$$

$$= [\mathbf{x}(k_s), \mathbf{x}(k_s + 1), \dots, \mathbf{x}(k_s + N - 1)]^T \quad (4)$$

$$= \begin{bmatrix} y(k_s) & \dots & y(k_s + N - 1) \\ \vdots & \ddots & \vdots \\ y(k_s - 23) & \dots & y(k_s + N - 24) \end{bmatrix}^T$$

であり、 $\mathbf{m}_j(\mathbf{X})$ は平均関数ベクトル、 $\mathbf{S}_j(\mathbf{X}, \mathbf{X}) + \sigma_j^2 \mathbf{I}_N$ は共分散行列を表す。本稿では、平均関数ベクトル $\mathbf{m}_j(\mathbf{X})$ を入力 \mathbf{X} の線形結合：

$$\mathbf{m}_j(\mathbf{X}) = [m_j(\mathbf{x}_1), m_j(\mathbf{x}_2), \dots, m_j(\mathbf{x}_N)]^T$$

$$= \tilde{\mathbf{X}} \boldsymbol{\theta}_j \quad (5)$$

$$\tilde{\mathbf{X}} = [\mathbf{X}, \mathbf{e}], \quad \mathbf{e} = [1, 1, \dots, 1]^T$$

で表す。また、共分散行列の要素 $S_{j(p,q)}$ を決める共分散関数として、次のガウシアンカーネルを用いる。

$$S_{j(p,q)} = s_j(\mathbf{x}_p, \mathbf{x}_q)$$

$$= \rho_j^2 \exp\left(-\frac{\|\mathbf{x}_p - \mathbf{x}_q\|^2}{2\ell_j^2}\right) \quad (6)$$

平均関数の重みパラメータ $\boldsymbol{\theta}_j$ と共分散関数のハイパーパラメータ $\mathbf{h}_j = [\rho_j, \ell_j, \sigma_j]^T$ は、 N 個の入出力データに対する周辺尤度を評価とし、最小二乗法とカックウ探索アルゴリズム (CS) との組合せにより学習する。

新たなテスト入力 $\mathbf{x}_* = \mathbf{x}_*(k) = [y_*(k), y_*(k-1), \dots, y_*(k-23)]^T$ に対するテスト出力 $y_*(k+j)$ ($j = 1, 2, \dots, 24$) の事後分布は、

$$y_*(k+j)|\mathbf{X}, \mathbf{w}_j, \mathbf{x}_* \sim \mathcal{N}(\hat{y}_*(k+j), \hat{\sigma}_*^2(k+j)) \quad (7)$$

$$\hat{y}_*(k+j) = m_j(\mathbf{x}_*)$$

$$+ \mathbf{S}_j(\mathbf{x}_*, \mathbf{X}) \mathbf{K}_j^{-1} (\mathbf{w}_j - \mathbf{m}_j(\mathbf{X}))$$

$$\hat{\sigma}_*^2(k+j) = s_j(\mathbf{x}_*, \mathbf{x}_*)$$

$$- \mathbf{S}_j(\mathbf{x}_*, \mathbf{X}) \mathbf{K}_j^{-1} \mathbf{S}_j(\mathbf{X}, \mathbf{x}_*) + \sigma_{j[best]}^2 \quad (8)$$

となる。 $\hat{y}_*(k+j)$ と $\hat{\sigma}_*^2(k+j)$ はそれぞれ j 時間先の電力需要予測値とその予測分散である。

4 予測シミュレーション

2014 年の九州地区の短期電力需要予測を月毎に行う。学習用データとして、九州電力 (株) の「でんき予報」^[2] より入手した 2013 年の電力需要実績値を用いた。図 1 に 1, 4, 7, 10 月の本手法による電力需要予測結果を示す。

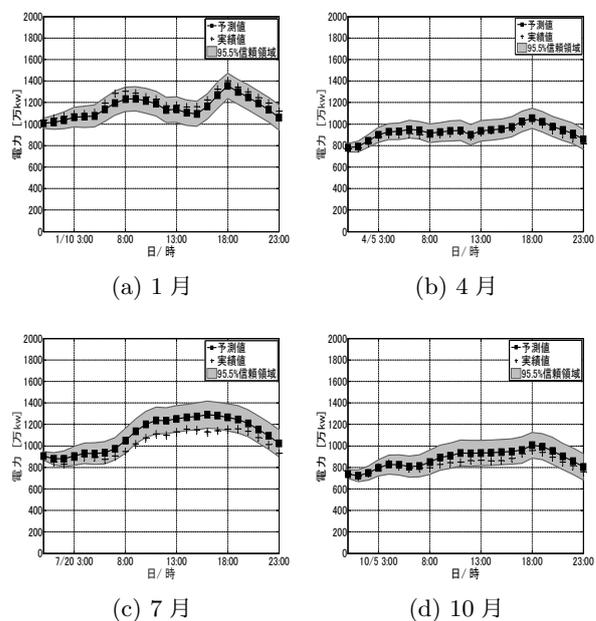


図 1 電力需要予測結果

謝辞

本研究は JSPS 科研費 15K06113 の助成を受けたものである。

参考文献

- [1] C. E. Rasmussen and C. K. I. Williams, *Gaussian Processes for Machine Learning*, MIT Press, 2006.
- [2] 九州電力 (株) でんき予報, http://www.kyuden.co.jp/power_usages/pc.html