

電力需要予測に対する モデルベース時点クラスタリングの応用

白瀧 豪^{1,a)} 今井 貴史¹ 河本 薫¹ 國政 秀太郎²

概要: 電力事業において、電力需要を予測して需要と供給のバランスを整えることが必要になる。電力消費は祝祭日や生活習慣の変化などの影響を受けることから時間経過によって需要パターンが変わると考えられる。そこで各時点に対してクラスターが変化するようなモデルを適用して、需要パターンの時間変化を取り込むことで予測精度を向上させられると考えた。本研究では予測精度をあげることを目的とし、モデルにスイッチング線形動的システムを仮定して、各時点におけるクラスタリングとクラスターごとのモデル推定を同時に行う。その結果、需要パターンの時間変化を考慮しない場合と比較して予測精度の改善が見られた。

キーワード: 電力需要予測, 時系列解析, 時系列クラスタリング

Application of Model-Based Time point Clustering to Electricity Demand Forecasting

GO SHIRATAKI^{1,a)} TAKASHI IMAI¹ KAORU KAWAMOTO¹ SHUTARO KUNIMASA²

Abstract: In the electric power business, it is necessary to forecast electric power demand to balance supply and demand. For the electric power demand, consumers usually change their demand patterns over time due to, for example, holidays and changes in family composition. Therefore, it may improve the forecast accuracy to incorporate the temporal changes in demand patterns using a model that assigns time points to clusters. In this study, we adopted a switching linear dynamic system model to perform time-point clustering and model estimation simultaneously. This improved the forecast accuracy compared to the case of no switching.

Keywords: Electricity Demand Forecasting, Time Series Analysis, Time Series Clustering

1. 序論

1.1 背景と目的

これまで家庭や商店向けの電気は、各地域の大手電力会社だけが販売しており、電気をどの会社から買うかを選ぶことはできなかった。しかし、2016年4月の電力小売全面自由化を背景に、様々な分野の企業が電力事業に新規参

入できるようになった。実際、電力販売企業が10社に独占されていたのが、令和3年11月26日現在で733もの事業者が小売電気事業者として登録されている。これによって、競争力が高まるためコストの削減が求められている。一方、電力事業者には、顧客に販売する電力量と発電する電力量をバランスさせることを義務付けられており、両者に差が生じると罰金を課せられる。そのため、時刻別に電力を予測して、需要と供給のバランスを保たなければならない。

これまで、時系列データ集合に対してクラスタリングを行うモデルベース時系列クラスタリングを試みてきた [8]。今回は、同じ時系列クラスタリングでも前回と違って、各

¹ 滋賀大学

Shiga University

² 大阪ガス(株)情報通信部

Information/Communication Systems Dept., Osaka Gas Co., Ltd.

a) g.shirataki4@gmail.com

時点に対してクラスタリングを行うという視点で取り組んだ。

1.2 課題とアプローチ

電力の使用量は時間経過で傾向が変わることが考えられる。主要な要因としては、気温や湿度などの外生変数や家族が増えたことによる影響がある。また近年ではリモートワークなども影響を与えると考えられる。そこで各時点に対してクラスターが変化するようなモデルを適用し、顧客の活用の使用傾向を取り込むことで予測精度が向上するのではないかと考えた。また同時に顧客の変化を把握できることで様々な解釈性が生まれ、さらなる事業や予測精度の向上に貢献できる可能性がある。

本研究では、電力使用量のダイナミクスをスイッチング線形動的システム (Switching Linear Dynamical System:SLDS) としてモデル化し、各時点でのクラスタリングとクラスターごとのパラメータ推定を同時に行う。

2. スイッチング線形動的システム

スイッチング線形動的システムとは、隠れマルコフモデルと線形動的システムを組み合わせたモデルである。そこで、この節では隠れマルコフモデルと線形動的システムについて述べた後、スイッチング線形動的システムについて説明する。

2.1 隠れマルコフモデル

隠れマルコフモデルとは、観測変数 $X = \{x_1, x_2, \dots, x_T\}$ の背後にある潜在変数 $Z = \{z_1, z_2, \dots, z_T\}$ ($z_t = \{z_{t1}, \dots, z_{tK}\}$) の K 次元の離散的な時系列変化を仮定したモデルである。また $z_{tk} \in \{0, 1\}$ かつ $\sum_{k=1}^K z_{tk} = 1$ を満たす。今回は、 z_t が 1 時点前の z_{t-1} のみに依存する 1 次マルコフモデルを仮定する。つまり、 z_t を与えたとき z_{t-1} と z_{t+1} が独立であるという条件付き独立性を満たす。

$$z_{t+1} \perp z_{t-1} \mid z_t.$$

このモデルの同時分布は以下で与えられる。

$$p(x_1, \dots, x_T, z_1, \dots, z_T) = p(z_1) \left[\prod_{t=2}^T p(z_t \mid z_{t-1}) \right] \times \prod_{t=1}^T p(x_t \mid z_t).$$

グラフィカルモデルで表すと図 1 のようになる。線形動的システムも同じグラフィカルモデルになる。詳細は 2.2 で後述する。

ここで離散的な潜在変数 z_t の確率分布は、条件付き分布 $p(z_t \mid z_{t-1})$ を通して直前の潜在変数 z_{t-1} の状態に依存する。この条件付き分布の遷移確率を要素にもつ行列を A とする。ここで任意の $k \in \{1, 2, \dots, K\}$ に対して遷移確




図 1: 隠れマルコフモデルと線形動的システムのグラフィカルモデル

率は $A_{jk} = p(z_{tj} = 1 \mid z_{t-1k})$ で定義される。確率なので、 $0 \leq A_{jk} \leq 1$ かつ $\sum_k A_{jk} = 1$ を満たす。このとき、条件付き分布は以下のように書ける。

$$p(z_t \mid z_{t-1}, A) = \prod_{k=1}^K \prod_{j=1}^K A_{jk}^{z_{t-1j} z_{tk}}.$$

また最初の潜在変数 z_1 は、初期パラメータ π で表される周辺分布 $p(z_1)$ を持つ。

$$p(z_1 \mid \pi) = \prod_{k=1}^K \pi_k^{z_1^k}.$$

ここで、 $\sum_k \pi_k = 1$ を満たす。

次に、観測変数の条件付き分布のパラメータ集合を $\phi = \{\phi_k\}_{k=1}^K$ として以下のように定義する。

$$p(x_t \mid z_t, \phi) = \prod_{k=1}^K p(x_t \mid \phi_k)^{z_{tk}}.$$

この時、潜在変数と観測変数の同時分布は以下のようになる。

$$p(X, Z \mid \theta) = p(z_1 \mid \pi) \left[\prod_{t=2}^T p(z_t \mid z_{t-1}, A) \right] \times \prod_{t=1}^T p(x_t \mid z_t, \phi). \quad (1)$$

ここで $\theta = \{\pi, A, \phi\}$ は隠れマルコフモデルのパラメータ集合となる。これらは EM アルゴリズムを用いた最尤法で推定でき、効率的な計算をするためにフォワードバックワードアルゴリズムを用いることが一般的である。

2.2 線形動的システム

線形動的システムは隠れマルコフモデルと似た構造を持つモデルである。線形動的システムでは、隠れマルコフモデルの潜在変数と観測変数の両方が正規分布に従うと仮定する。構造は隠れマルコフモデルと同様のためグラフィカルモデルは図 1 である。また遷移確率分布と出力分布はそれぞれ以下のように書ける。

$$\begin{aligned} z_t &= Az_{t-1} + w_t, \\ x_t &= Cz_t + v_t, \\ z_1 &= \mu_0 + u. \end{aligned} \quad (2)$$

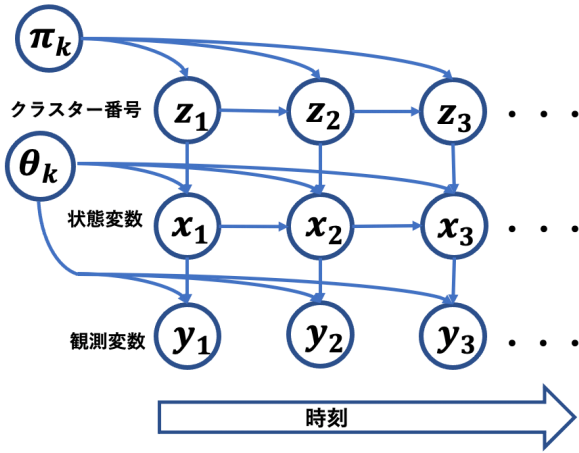


図 2: SLDS のグラフィカルモデル

ただし、ノイズ項は任意の t に対して $w_t \sim N(0, \Gamma), v_t \sim N(0, \Sigma), u \sim N(0, P_0)$ である。したがって、線形動的システムのモデルパラメータ $\theta = \{A, \Gamma, C, \Sigma, \mu_0, P_0\}$ を持ち、これらは EM アルゴリズムを用いた最尤法で推定できる。この推論では、隠れマルコフモデルのフォワードバックワードアルゴリズムと類似しているカルマンフィルタとカルマンスムーザという手法がよく知られている。

2.3 スイッチング線形動的システム

クラスター番号にあたる潜在変数を $Z = \{z_1, z_2, \dots, z_T\}$ 、状態変数にあたる潜在変数を $X = \{x_1, x_2, \dots, x_T\}$ 、観測変数を $Y = \{y_1, y_2, \dots, y_T\}$ とし、任意の $t \in \{1, 2, \dots, T\}$ に対してそれぞれ $z_t \in \{1, 2, \dots, K\}, x_t \in \mathbb{R}^m, y_t \in \mathbb{R}^n$ とする。これらの変数の時間発展を次式のようにモデル化するとき、そのモデルを SLDS とよぶ。

$$\begin{aligned} x_t &= A^{(z_t)} x_{t-1} + e_t^{(z_t)}, \\ y_t &= C x_t + \omega_t. \end{aligned} \quad (3)$$

ただし、 $e_t^{(z_t)} \sim N(0, \Sigma^{(z_t)}), \omega_t \sim N(0, R)$ である。状態変数 X の遷移行列 $A^{(z_t)}$ は z_t に依存する。また潜在変数 Z は以下のマルコフ過程に従うとする。

$$z_{t+1} | z_t, \{\pi_k\}_{k=1}^K \sim \pi_{z_t}. \quad (4)$$

ただし、 $\{\pi_k\}_{k=1}^K$ は遷移行列であり、 $\pi_k \in [0, 1]^K$ は第 k 行成分を表す。モデルパラメータを $\theta_k = \{A^{(k)}, \Sigma^{(k)}, C, R\}$ とすると、グラフィカルモデルは図 2 のように表せる。

いま、潜在変数 Z と状態変数 X の事後分布を観測変数 Y から推定することを考える。ここでは平均場近似に基づいて事後分布を近似することで計算を行う。事後分布を近似した $Q(X, Z)$ とすると、以下のような分離を仮定する。

$$p(X, Z | Y) \approx Q(X, Z) = Q(X)Q(Z). \quad (5)$$

近似分布 $Q(X, Z)$ を用いて対数尤度を以下のように計算

する。

$$\begin{aligned} \log p(Y) &= \log \int_{X, Z} p(Y, X, Z) dX dZ \\ &= \log \int_{X, Z} Q(X, Z) \frac{p(Y, X, Z)}{Q(X, Z)} dX dZ \\ &= \log \int_{X, Z} Q(X)Q(Z) \frac{p(Y, X, Z)}{Q(X)Q(Z)} dX dZ. \end{aligned}$$

ここで、イェンセンの不等式を用いると以下のような下限 $\mathcal{L}(Q)$ を持つ。

$$\begin{aligned} \log p(Y) &\geq \int_{X, Z} Q(X)Q(Z) \log \frac{p(Y, X, Z)}{Q(X)Q(Z)} dX dZ \\ &= \int_{X, Z} Q(X)Q(Z) \log p(Y, X, Z) dX dZ \\ &\quad - \int_{X, Z} Q(X)Q(Z) \log Q(X)Q(Z) dX dZ \\ &= \int_X Q(X) \mathbb{E}_{Q(Z)} [\log p(Y, X, Z)] dX \\ &\quad + \int_Z Q(Z) \mathbb{E}_{Q(X)} [\log p(Y, X, Z)] dZ \\ &\quad - \int_Z Q(Z) \log Q(Z) dZ \\ &\quad - \int_X Q(X) \log Q(X) dX \\ &= \mathcal{L}(Q). \end{aligned}$$

したがって、変数 X, Z ごとに更新を行うことで尤度の下限の最大化ができる。

$$\begin{aligned} Q(X) &\propto \exp\{\mathbb{E}_{Q(Z)} [\log p(Y, X, Z)]\}, \\ Q(Z) &\propto \exp\{\mathbb{E}_{Q(X)} [\log p(Y, X, Z)]\}. \end{aligned}$$

具体的なこれらの計算には、フォワードバックワードアルゴリズムとカルマンフィルタを用いて潜在変数 X, Z の更新をする。

さらに各クラスターのモデルパラメータの更新を考える。ここでのモデルパラメータとは、式 (3) のパラメータ $\{(A^{(k)}, \Sigma^{(k)})\}_{k=1}^K, C, R$ と潜在変数 Z の遷移行列 $\{\pi_k\}_{k=1}^K$ を指す。これらのパラメータを MAP 推定によって更新するため、それぞれ事前分布を以下のように設定する。

$$\begin{aligned} \pi_k &| \alpha \sim \text{Dir}(\alpha), \\ (A^{(k)}, \Sigma^{(k)}) &| \lambda \sim \text{MNIW}(\lambda), \\ (C, R) &| \eta \sim \text{NIW}(\eta). \end{aligned} \quad (6)$$

$\text{Dir}(\cdot)$ はディリクレ分布、 $\text{MNIW}(\cdot)$ は行列正規逆ウィシャート分布、 $\text{NIW}(\cdot)$ は正規逆ウィシャート分布を指す。

ここまで述べてきた潜在変数とパラメータの更新を対数尤度の下限 $\mathcal{L}(Q)$ が収束するまで繰り返し実行する。整理すると、アルゴリズム 1 のようになる。

Algorithm 1 スイッチング線形動的システムのアルゴリズム

Input: 初期値 x_0, Σ_0, z_0 , クラスター数 K

- 1: **while** $|\mathcal{L}(Q)^{new} - \mathcal{L}(Q)^{old}| / \mathcal{L}(Q)^{old} > \epsilon$ **do**
- 2: カルマンフィルタによる状態変数 X を推定
- 3: フォワードバックワードアルゴリズムによる潜在変数 Z を推定
- 4: MAP 推定により $\{\{A^{(k)}, \Sigma^{(k)}\}_{k=1}^K, C, R\}, \{\pi_k\}_{k=1}^K$ を推定
- 5: $\mathcal{L}(Q)^{old} \leftarrow \mathcal{L}(Q)^{new}$, $\mathcal{L}(Q)^{new}$ を計算
- 6: **end while**
- 7: **return** X, Z, θ




図 3: 電力消費量の時系列データ

3. 使用データの詳細

3.1 データ内容

本研究では、大阪ガスから提供された電力消費データを使用する。このデータは 100 ユーザーを対象に 1 時間ごとに計測した電力消費量データを 1 年間 (2019/1/1 0:00~2019/12/31 23:00) 分使用した。計測時点数は 8760 である。時系列データ X をユーザー i の電力消費時系列を x_i とすると $X = \{x_1, \dots, x_{100}\}$ と表す。また、任意の時系列データ $x_i \in X$ は、時刻 t におけるユーザー i の電力消費量を $x_{i,t}$ とすると $x_i = \{x_{i,1}, \dots, x_{i,8760}\}$ と表すことができる。時系列データの一例は図 3 のようになる。

3.2 前処理

電力需要のデータは週による周期があると考えられるため、その周期性を排除するために前処理として 1 週間 (7 日間) 前の同曜日同時間の差分をとる。差分をとった時系列データを $Y = \{y_1, \dots, y_{100}\}$ とすると任意の $y_i = \{y_{i,1}, \dots, y_{i,8592}\} \in Y$ は以下のように表せる。

$$y_{i,t-24 \times 7} = x_{i,t} - x_{i,t-24 \times 7}.$$

ただし、 $t \in \{24 \times 7 + 1, \dots, 8760\}$ とし、初週のデータは差分をとることができないため使用しない。前処理をしたデータの推移を可視化すると図 4 のようになる。全時系列データに対して有意水準 1% で単位根検定を行った結果、定常性を確認できた。また、前処理前後での比較した図 5




図 4: 図 3 のデータ差分




図 5: 前処理前後での比較 (色の変化は週の変化, 上図が前処理前, 下図が前処理後を表す.)

から、周期性の影響が小さくなっていることを目視でも確認した。

また任意の $j \in \{1, \dots, 8592\}$ に対して、 $y_{i,j} = 0$ となるような時系列データ y_i は本研究では対象外とする。この理由は、電力を全く消費しない顧客であることを確認したためである。

さらに、学習データと検証データを以下のように分割する。

学習データ

前半 11 ヶ月分 (2019/1/1 0:00~2019/11/30 23:00).

任意のユーザー i に対して、 $\{y_{i,1}, \dots, y_{i,7872}\}$ を学習データとする。

検証データ

後半 1 ヶ月分 (2019/12/1 0:00~2019/12/31 23:00).

任意のユーザー i に対して、 $\{y_{i,7872}, \dots, y_{i,8592}\}$ を検証データとする。

3.3 予測方法と評価指標

本研究での予測は常に 4 時間先を行うこととする。4 時間前までに需要量を予測することで、発電機の運転計画を調整することができるためである。使用データは 1 時間おきにデータが取れているため 4 時点先の予測と同義になる。

本研究での予測における評価指標は平均絶対誤差 (Mean Absolute Error: MAE) を用いる。任意のユーザー i の予測値を $\{\hat{y}_{i,t}\}_{t=1}^T$ とし、MAE を算出する対象となるユーザー数を n としたときの MAE を以下のように定義する。




図 6: 時系列データ例に対する実測値 (青) と再現値 (赤) の推移. 上図はクラスター番号のカラーマップを表し, 色が変わっているとクラスタのスイッチングが起きていることを意味する.

表 1: 各手法ごとの結果

	MAE[kWh]
各時系列データに適用した場合	6.574
全時系列を合計したデータに適用した場合	6.856
混合 AR モデル (以前の研究結果 [8])	7.039

$$MAE = \frac{1}{T} \sum_{t=1}^T \left| \sum_{i=1}^n (y_{i,t} - \hat{y}_{i,t}) \right|. \quad (7)$$

本研究での関心はユーザー全体での誤差にあるため, ユーザー全体での総和をとった後に絶対値をとっている. すなわち, 各時点に対して全体重要量と予測量の平均的な誤差を表している.


4. 結果と考察

4.1 結果

上記のデータを用いてスイッチング線形動的システムの同定を行った. まずは再現値, すなわち学習データに対して推定された状態から観測方程式を用いて算出された値について確認しよう. 時系列データ例に対する実測値と再現値を図 6 に示す. この結果から学習データの再現ができていることを確認できる.

次に, 予測精度を確認する. ここで, 以前の研究手法 [8](混合 AR モデルとよぶ) と比較するため, 本研究手法と違う点を簡単に説明する. 混合 AR モデルは, 本研究手法と同じ時系列クラスタリングであるが, 本研究手法は 1 つの時系列データを時間軸方向に分割してクラスタリング (図 7b) したのに対して, 混合 AR モデルでは複数の時系列データを系列単位でクラスタリング (図 7a) している. また, AR モデルをベースとした手法であることが主な違いである. ここで, 全時系列データを合計したデータに対して適用した結果と混合 AR モデル (以前の研究結果) と比較した結果を表 1 にまとめた. 表 1 の結果から各時系列データにスイッチング線形動的システムを適用した結果が最も高い予測精度を示したことがわかる.

さらに, 全時系列データを合計したときの実測値と予測値の推移を図 8 に示す. 上図は全時系列データを合計した



(a) 全体時系列クラスタリング



(b) 時点クラスタリング (背景色がクラスターを表す)

図 7: 時系列クラスタリングの分類




図 8: 全時系列データ合計の推移. 上図は実測値 (黒) と予測値 (赤) の推移を表し, 下図は実測値と予測値の絶対誤差の推移 (緑) とその平均絶対誤差 (紫) を表す.

実測値と予測値の推移を表し, 下図は実測値と予測値の各時点に対する絶対誤差の推移を表している. また点線は平均絶対誤差を表している.

4.2 考察

表 1 の結果から, 本研究は以前の結果よりも高い精度を示した. これは電力の需要予測においてモデルの柔軟性を増したことで, 時間経過でクラスターがスイッチングするようなモデルを選択することで予測精度が向上することを示した.

また, 図 6 のカラーマップ (上図) に注目すると, クラスタがこまめにスイッチングしていることがわかる. 特に, 観測値がスパイク的に上がるもしくは下がる時にクラスターがスイッチングしている. これは, 黄色のクラスターのモデルでは表現が困難な部分をその他のクラスターで表現している. つまり全時刻を一つの線形動的システムで表現するのではなく, 各時点でクラスタリングしたことで一時的な挙動の変化をクラスターのスイッチングで対応したことが予測精度の向上につながったと考える.

4.3 課題点

クラスターのスイッチングを顧客の需要パターンが変化したときにクラスターがスイッチングすることを想定した。つまり、1日や1週間などのある一定周期ごとにクラスターが変化することを期待したが、図6の上部カラーマップに注目すると、クラスターのスイッチングが頻繁に起きていることが確認できる。このようにあまりにも小刻みにクラスターが変わることを、顧客の使用パターンが頻繁に変化していると考えるのは現実的ではなく、解釈が難しくなる。

5. 結論と今後の課題

5.1 結論

本研究では、電力需要予測に対してスイッチング線形動的システムを適用した。全顧客のデータを合計した一つの時系列データに適用した場合、以前の研究で行ったARモデルを用いたモデルベースの全体時系列クラスタリングの結果と比較して、各時系列データに適用した方が予測精度が向上する結果が得られた。この結果からモデルの柔軟性を増し、時間経過でクラスターがスイッチングするようなモデルを採用することで予測精度が向上することを示した。しかし、クラスターのスイッチングが激しく、顧客の電力活用の変化を解釈することが困難であった。

5.2 今後の課題

スイッチング線形動的システムを使用することで予測精度は向上したが、クラスターがあまりにも小刻みにスイッチングしてしまい、クラスターの解釈が困難になった。この問題は、クラスターが一定期間スイッチングしないように隠れマルコフモデルから隠れセミマルコフモデルにモデルを拡張することで解決できると考えられる。また、電力消費量は気温や湿度などに大きく影響されるため、それらの因子を外生変数としてモデルに組み込むことでさらに予測精度を向上させられるだろう。

また、以前の研究手法である全体時系列クラスタリングのモデルをARモデルからより柔軟性の高い状態空間モデルにすることで、前述した外生変数をモデルに組み込むことのできるため、予測精度の向上が見込めると考える。

参考文献

- [1] Wilcox, A.B. and Hamano, F.: Kalman's Expanding Influence in the Econometrics Discipline, *IFAC-PapersOnLine*, Vol.50, No.1, pp.637-644 (2017).
- [2] Wilcox, A.B. and Hamano, F.: Model-Based Clustering of Time Series Based on State Space Generative Models, *Lecture Notes in Electrical Engineering*, Vol.465, pp.447-456 (2018).
- [3] Johnson, M.J., Duvenaud, D., Wiltchko, A. B., Datta, S. R. and Adams, R.P.: Composing graphical models with neural networks for structured representations and fast

- inference. *arXiv1603.06277*, Ver.5 (2017).
- [4] Linderman, S. W., Johnson M. J., Miller, A. C., Adams, R. P., Blei, D. M. and Paninski, L.: Bayesian Learning and Inference in Recurrent Switching Linear Dynamical Systems. *arXiv:1610.08466*, Ver.1 (2016).
 - [5] Ghahramani, Z. and Hinton, G. E.: Variational Learning for Switching State-Space Models. *Neural Computation*, Vol.12, Issue.4, pp.831-864 (2000).
 - [6] Oka, A., Kawahara, Y. and Washio, T.: Stochastic Variational Inference for Big Scale Switching Linear Dynamical System. *Conference of the Japanese Society for Artificial Intelligence*, 1F45 (2016).
 - [7] Bishop, C. M.: Pattern recognition and machine learning. Springer, (2006). 元田 浩, 栗田 多喜夫, 樋口 知之ほか (訳): パターン認識と機械学習 下, 丸善出版, pp.323-370 (2012).
 - [8] 白瀧 豪, 今井 貴史, 河本 薫, 國政 秀太郎: 電力需要予測に対するモデルベース時系列クラスタリングの応用. 研究報告数理モデル化と問題解決 (MPS), 2021-MPS-132, Vol.18, pp.1-6, (2021).