

事業所タイプにおける需要予測手法の評価

紺野剛史^{†1} 高橋悟^{†1} 北島弘伸^{†1} 寺西佑太^{†1} 園田俊浩^{†1}

概要: 東日本大震災の影響による電力供給力不足に対し、省エネ規制が総電力量からピーク電力量の削減に見直され、太陽光発電や蓄電池の活用が注目されている。様々な情報を都市全体で管理し、電力やエネルギーの有効活用を行う環境配慮型都市（以後、スマートシティ）においては、ビルや家庭などに多数の蓄電池が分散配置され、電力需要が小さいときに蓄電池に充電し、大きいときに放電することによって、ピーク電力の削減や電力需要の平準化を実現する仕組みが重要になってくる。スマートシティでこのような仕組みを実現するには、ビル（事業所）や住宅街、商業地といったコミュニティ単位で、その中に配置された蓄電池の充放電を制御し、スマートシティ全体でピーク電力を削減する必要がある。従来、電力会社は膨大に蓄積された消費電力情報をもとに、大数の法則が担保される全体の電力需要予測を行ってきた。しかし、それより規模が小さなコミュニティ単位の需要予測では、大数の法則が効きにくくなる恐れがある。そこで、本稿では弊社事業所の消費電力情報を利用し、需要パターンによる事業所のタイプ分類、及び、需要予測手法の評価を行った。その結果、事業所に適した予測手法は需要パターンによるタイプ分析と関係しており、オフィス型事業所では周期性を考慮した時系列解析、工場型事業所では立ち上がり電力を考慮した組み合わせ手法が適していることが分かった。

キーワード: 消費電力, 需要予測, タイプ分類, 回帰分析, 時系列解析

Evaluation of the demand forecasting methods in a facility type

TAKESHI KONNO^{†1} SATORU TAKAHASHI^{†1} HIRONOBU KITAJIMA^{†1}
YUTA TERANISHI^{†1} and TOSHIHIRO SONODA^{†1}

Abstract: In smart cities of the future, it is thought that numerous energy storage devices will be placed in a wide range of locations, such as communities like buildings and households. At the same time, it is anticipated that there will be greater need for a mechanism to enable peak power demand reduction by charging energy storage devices during times of low power utilization and utilizing the stored energy when power demand is high. In this paper, we introduce the demand forecasting technology such as regression analysis and time series analysis in the smart cities.

Keywords: demand forecasting, regression analysis, time series analysis

1. はじめに

東日本大震災の影響による電力供給力不足に対し、省エネ規制が総電力量からピーク電力量の削減に見直され、太陽光発電や蓄電池の活用が注目されている。様々な情報を都市全体で管理し、電力やエネルギーの有効活用を行う環境配慮型都市（以後、スマートシティ）においては、ビルや家庭などに多数の蓄電池が分散配置され、電力需要が小さいときに蓄電池に充電し、大きいときに放電することによって、ピーク電力の削減や電力需要の平準化を実現する仕組みが重要になってくる。

スマートシティでこのような仕組みを実現するには、ビル（事業所）や住宅街、商業地といったコミュニティ単位で、その中に配置された蓄電池の充放電を制御し、スマートシティ全体でピーク電力を削減する必要がある。

従来、電力会社は膨大に蓄積された消費電力情報をもとに、大数の法則が担保される全体の電力需要予測を行ってきた[1]。しかし、それより規模が小さなコミュニティ単位の需要予測では、大数の法則が効きにくくなる恐れがある。

本稿では、コミュニティ単位の需要予測の評価を行うた

め、弊社事業所の消費電力情報を利用し、需要パターンによる事業所のタイプ分類、及び、需要予測手法の評価を行ったので報告する。

2. 従来技術

これまで様々な統計的手法を活用した需要予測技術が開発されてきた。例えば、消費電力情報と気温情報を用いた重回帰[2]やサポートベクター回帰[3]などの回帰分析を用いた手法や、ARMAモデル[4]やSARIMAモデル[5]などの時系列解析を用いた手法などがある。これらの報告は発電所などの大規模な施設に対して行われてきた。

事業所のような小規模な施設に対しては、k近傍法と重回帰を組み合わせた予測手法における報告がある[6]。しかし、複数の小規模な施設に対してタイプ別に分類し、複数の予測手法を用いて評価した報告は行われていない。

3. 事業所のタイプ分類

弊社事業所は様々な形態のビルがある。例えば、従業員の勤務時間に規則性があり日周期の消費電力が安定している事業所（オフィス型と呼ぶ）や製造ラインの稼働・非稼働によって消費電力が変化する事業所（工場型と呼ぶ）が

^{†1}(株)富士通研究所
Fujitsu Laboratories LTD., Kanagawa 211-8588, Japan.

ある。まず、どのようなタイプの事業所が存在するか調べるために、28 事業所の消費電力パターンからタイプ分類を行う。

3.1 分類手法

土日祝日も含む 2011 年 10 月 1 日から 11 月 30 日までの消費電力情報を最大値で正規化した後、クラスタリング手法として最も広く用いられている手法の一つである k-means 法を用いて分類を行う。

3.2 分類結果

28 の事業所をタイプ分類した結果を表 1 に示す。

表 1 タイプ分類の結果

Table 1 Result of type classifications.

タイプ	事業所数	内容
オフィス型	12	勤務時間に消費電力が変動するパターン
オフィス&工場型	11	オフィス型より消費電力のバラツキが大きいパターン
工場型	5	製造ラインによって消費電力が変動するパターン

タイプ分類された代表的な事業所の消費電力パターンを図 1, 2, 3 に示す。図には土日祝日を含む 2011 年 11 月 1 日から 30 日までの消費電力情報をプロットした。図の縦軸は最大値で正規化した消費電力情報を示す。横軸には時刻を示す。

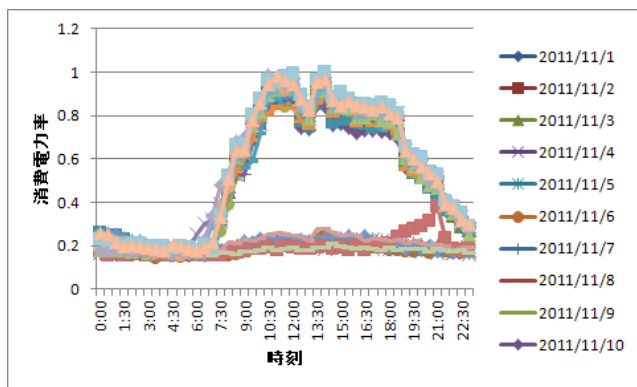


図 1 オフィス型の事業所

Figure 1 Facility of office type.




図 2 オフィス&工場型の事業所

Figure 2 Facility of office & factory type.

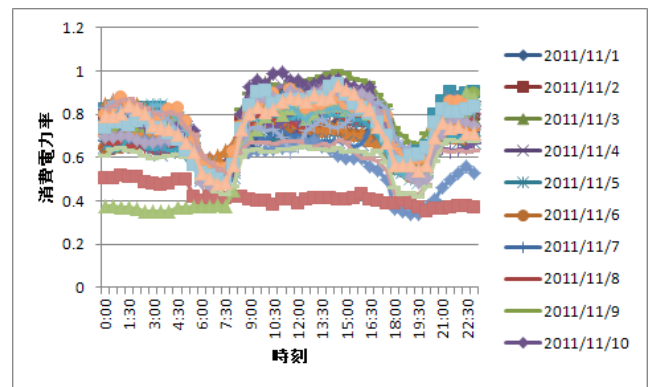


図 3 工場型の事業所

Figure 3 Facility of factory type.

4. 予測条件と手法

4.1 予測条件

本稿で行う電力需要予測は、30 分単位の学習データ（消費電力、気温情報）が入手可能であり、予測日の当日 9:00 までの学習データを用いて当日 10:00 から 20:00 までの消費電力を予測することを目的とする。これは、ピーク電力が昼近辺に発生すると仮定し、当日の 10:00 までに需要予測結果がわかれば施設管理者はピークカットの計画が行えると考えたためである。

学習データは予測日の当日 9:00 までの消費電力情報と予測当日以前の土日祝日を除く消費電力情報および各事業所の近隣気温情報とする。消費電力情報は 28 事業所から 30 分間隔で収集を行う。気温情報は予報値を収集、実績値を購入しており予測当日の気温情報には予報値、それ以外には実績値を用いる。ただし、気温情報は 1 時間単位でしか入手できないため平均することで 30 分単位に変換する。

学習期間は 15, 30, 60 日間の 3 パターンとし、評価期間は 2011 年 11 月 1 日から 2012 年 4 月 26 日までとする(図 4 参照)。




図 4 需要予測方法

Figure 4 Demand forecasting method

4.2 予測対象の分析

タイプ分類された代表的な事業所の偏自己相関分析の結果を図 5, 6, 7 に示す. 偏自己相関分析とは現時点と過去との関係を知ることができる手法であり, 2011 年 11 月 7 日 (月曜) から 11 日 (金曜) までの消費電力情報を使用した. 図の縦軸は偏自己相関係数, プロット内の青い点線は信頼限界を意味する. 横軸は日を示す. 例えば, Lag1 は 1 日前のデータを意味し, 右に行くほど古いデータとなる. いずれのタイプにおいても, 以下のことがわかった.

- ・前日までの幾つかの時刻の消費電力による影響を強く受ける
- ・過去数日間の同時刻の消費電力による影響を強く受ける




図 5 偏自己相関 (オフィス型)

Figure 5 Partial autocorrelation(office type).

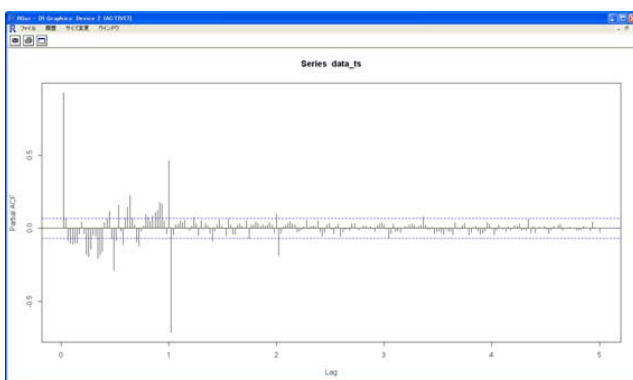


図 6 偏自己相関 (オフィス型&工場型)

Figure 6 Partial autocorrelation(office & factory).




図 7 偏自己相関 (工場型事業所)

Figure 7 Partial autocorrelation(factory type).

4.3 予測技術の検討

4.2 の結果からどのタイプの消費電力情報にも周期性があることがわかった. そのため, 周期的に発生する立ち上がり電力を利用する k 近傍法+重回帰, k-means 法+平均の評価を行うことにする. また, 周期性が考慮できる時系列モデルである SARIMA も評価することにする. さらに, 消費電力情報と気温情報が用いた重回帰分析は一般的に良く行われているため, 重回帰分析も評価することにする[2].

表 2 に本システムで評価する需要予測手法, 図 8 にシステム構成を示す.

表 2 需要予測手法の一覧

Table 2 List of the demand forecasting techniques.

手法の分類	予測手法
組み合わせ手法	k 近傍法+重回帰
	k-means 法+平均
時系列解析	SARIMA
回帰分析	重回帰

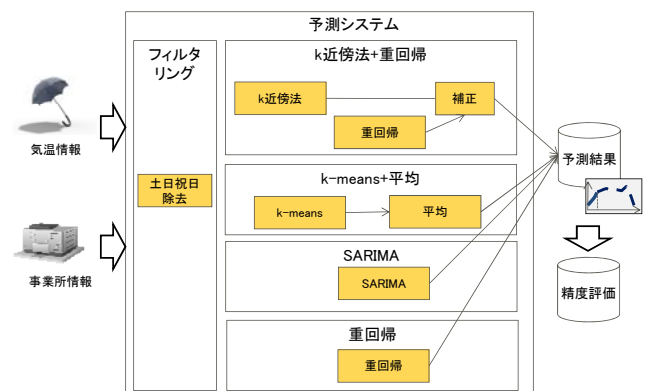


図 8 システム構成図

Figure 8 System Configuration Diagram.

4.4 k 近傍法+重回帰

ピーク電力予測を重回帰, 需要予測を k 近傍法で予測し, それぞれの結果を組み合わせた手法である[6]. 予測日の当日の立ち上がり電力から似ている過去情報を選別することで精度向上を図っている. なお, この手法の詳細なアルゴリズムは付録に記載している.

学習データには消費電力情報と気象情報を使う. まず, 当日 9:00 の消費電力と当日 6:00 の気温情報を重回帰によりピーク電力を求める. その後, 予測対象日の予想最高気温と, 最高気温に近い過去情報を k 近傍法によって選出する. 2つのデータを合成することで需要予測値とする.

4.5 k-means 法+平均

コミュニティ単位の需要予測技術として新しく考案した手法である. 4.4 と同じく, 予測日の当日の立ち上がり電力から似ている過去情報を選別することで精度向上を図っている. 4.4 と比べると本手法は k-means 法を用いることで極端な外れ値を選別しないように改良している. この手法の説明を以下に示す. なお, k-means 法のアルゴリズムは付録に記載している.

1. 学習データの 10:00 から 20:00 までの消費電力情報を用いて k-means 法にて 4 つのグループに分割する
2. 予測当日の 6:00 から 9:00 までの消費電力情報を用いてユークリッド距離を計算し, 各グループから距離が近い上位 3 件の消費電力情報を選出する
3. 選出した消費電力情報の平均値を需要予測値とする

4.6 SARIMA

学習データには消費電力情報のみを使う. 消費電力情報は本来 0:00 から 23:30 までの 48 ポイントを使うべきだが, 計算時間の問題で 10:00 から 20:00 までの 21 ポイントを用いる. モデル作成に使用するパラメータは以下の手順により決定する. なお, SARIMA モデルの説明は付録に記載している.

1. 次数 d, D を単位根検定により決定する
2. 単位根検定により決定した d', D' を用い $(0, d', 0) \times (0, D', 0)_{21}$ から $(4, d', 1) \times (1, D', 1)_{21}$ までの組み合わせを作成する
3. 全ての組み合わせについて AIC を計算し, 最小の AIC が得られた $(p, d, q) \times (P, D, Q)_{21}$ を最適なパラメータとする

4.7 重回帰

学習データには過去の消費電力情報と気象情報を使う. それぞれ 10:00 から 20:00 までの 21 ポイントを使う. 当日

の需要予測のモデルを以下に示す.

$$P_i = a_0 + a_1 \times T + a_2 \times T^2 + \sum_{i=1}^n b_i \times C_i + \varepsilon_i$$

ただし

n = データ数

$(1 = 10:00, 2 = 10:30, 3 = 11:00, \dots, 21 = 20:00)$

P_i = 時刻毎の消費電力予測値

C_i = 時刻毎の消費電力

T = 気温

$a_0, a_1, a_2, b_1, \dots, b_n$ = 推定する回帰係数

5. 評価

5.1 評価指標

予測精度の評価は 10:00 から 20:00 までの MAPE を用いる. 1日あたりの MAPE は以下の式より算出し, 評価データの平均 MAPE を用いて各予測手法の評価を行う. MAPE は 0 に近づくほど予測精度が高いことを意味する.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{D_i - M_i}{M_i} \right|$$

ただし,

n = データ数

$(1 = 10:00, 2 = 10:30, 3 = 11:00, \dots, 21 = 20:00)$

D_i = 時刻毎の予測値

M_i = 時刻毎の実測値

5.2 評価結果

学習データの期間は最も予測精度が良い期間を採用した. 全ての需要予測手法で MAPE を計算した結果, SARIMA, k 近傍法+重回帰, k-means 法の 3 手法が良いことがわかった. また, 学習期間は SARIMA が 15 日, k 近傍法+重回帰が 15 日, k-means 法が 30 日のとき最も良い予測精度になった. 表 3 にタイプ毎に最も MAPE が良くなった事業所数を示す.

表 3 最も MAPE が良い事業所数

Table 3 Number of facilities with best MAPE.

タイプ	SARIMA	k 近傍法 +重回帰	k-means 法 +平均	重回帰
オフィス型	8	3	1	0
オフィス& 工場型	5	4	2	0
工場型	0	2	3	0

タイプ分類毎に 3 つの需要予測手法の MAPE を図 9, 10, 11 に示す. 縦軸に MAPE, 横軸に事業所名を示す. 事業所名はオフィス型事業所を ID1, オフィス&工場型事業所を

ID2, 工場型事業所を ID3 としている。ただし、重回帰は他の手法の MAPE より精度が悪いため図から省略した。




図 9 オフィス型事業所
 Figure 9 Facilities of office type.




図 10 オフィス&工場型事業所
 Figure 10 Facilities of office & factory type.




図 11 工場型事業所
 Figure 11 Facilities of factory type.

6. 考察

まず、タイプ分類毎の需要予測の結果を考察する。オフィス型事業所は SARIMA が良く、工場型事業所は組み合わせ手法が良かった。オフィス型事業所の需要予測手法は SARIMA が適していることから、需要予測には 1 日の周期

性を考慮する必要があることがわかった。一方、工場型事業所の需要予測手法は組み合わせ手法が適していることから、需要予測には当日の立ち上がり電力を考慮する必要があることがわかった。オフィス&工場型事業所は SARIMA もしくは k 近傍法+重回帰が良かった。これはオフィスの傾向が強い事業所は SARIMA、工場の傾向が強い事業所では k 近傍法+重回帰に適した可能と考えられる。

次に、MAPE のばらつきについて考察する。どの事業所タイプにおいても MAPE にばらつきがあった。例えば、オフィス型事業所では MAPE が 1 から 14 と幅が広い。MAPE が悪くなる原因はわかっていないが、事業所の規模が小さいために社員の増減や定時退社日などの要因が影響し、本稿の手法をそのまま適用しても高い精度の需要予測が行えていない可能性がある。そのため、入力情報の平滑化処理や事業所に合った需要予測手法の改良が必要かもしれない。

7. おわりに

本稿では、従来の報告[2][3][4][5]より小規模な複数事業所に対してタイプ分類し、複数の需要予測手法による比較検討を行った。その結果、タイプ毎（オフィス型、工場型など）に最適な需要予測手法を推定することができた。

本稿の研究成果は、弊社製品であるクラウド型エネルギー管理サービス「Enetune」の需要予測技術の開発に活用する予定である。

謝辞 本論文の作成にあたり、終始適切な助言を賜り、また丁寧に指導して下さいました富士通研究所の吉田由紀子研究員、菊地英幸主任研究員および竹林知善首席研究員に感謝いたします。

参考文献

- 1) 灰田武史, 武藤 昭一.: 重回帰手法に基づいた最大需要予測支援システムの開発, OR, Vol.41, No.9(1996).
- 2) A. D. Papalexopoulos and T. Hesterberg.: A Regression-based approach to short-term system load forecasting, IEEE Transactions on Power Systems, Vol.5, pp.1535-1550, Nov (1990).
- 3) B. J. Chen, M. W. Chang, and C. J. Lin.: Load forecasting using support vector machines: A study on eunite competition 2001, IEEE Trans. Power Syst., vol.19, No.4, pp.1821-1830, Nov (2004).
- 4) CHEN, J.F., WANG, W.M., and HUANG, C.M.: Analysis of an adaptive time-series autoregressive moving-average (ARMA) model for short-term load forecasting, Electr. Power Syst. Res., Vol.34, Issue3, pp. 187-196 (1995).
- 5) Ismail, Z. and K.A. Mahpol.: SARIMA model for forecasting Malaysian electricity generated. Matematika, Vol.21, Issue2, pp. 143-152 (2005).
- 6) 高橋悟, 山根昌平.: スマートシティのエネルギー管理における需要予測技術, 計測自動制御学会制御大会 SICE2011.

付録

付録 1:k 近傍法+重回帰

(1) 重回帰法 (ピーク電力予測)

当日のピーク電力予測のモデルを以下に示す.

$$P_{today} = a_0 + a_1 \times T_{today} + a_2 \times C_{today} + \varepsilon_{today}$$

ただし

$$P_{today} = \text{当日のピーク電力予測値}$$

$$T_{today} = \text{当日6:00の気温}$$

$$C_{today} = \text{当日9:00の消費電力}$$

$$a_0, a_1, a_2 = \text{推定する回帰係数}$$

(2) k 近傍法 (需要予測) と合成方法

以下の手順で需要予測を行う.

- 過去の消費電力情報から予測対象日の特徴に類似する消費電力情報を選出する. 類似性は, 予測対象日の予想最高気温と, 観測最高気温に近い過去のデータを選出する
- 上記で選出した各類似消費電力データのピーク電力値で正規化し, 類似消費電力情報の各時間の平均値をとる正規化合成を行う
- 正規化合成で得られた時系列について, 6:00 の値が予測対象日の 6:00 の実績値に, 時系列の最大値が予測対象日のピーク電力予測値に揃うように補正したものを需要予測値としている

付録 2: k-means 法

k-means 法は非階層型クラスタリングの一種であり, クラスタリング手法として最も広く使われる手法の一つである. この手法のアルゴリズムを以下に示す.

- 任意の k 個のクラスタ中心 c_i を一様ランダムに選択する
- 全てのデータを, 各データ点 $x_j, j \in \{1, \dots, n\}$ から最も近いクラスタ i に割り当てる
- クラスタごとに, 以下の式にしたがってクラスタ中心を求める

$$c_i = \frac{1}{\#C_i} \sum_{x_j \in C_i} x_j$$

ただし

$$C_i = \text{クラスタ } i \text{ に含まれるデータの集合}$$

$$\#C_i = \text{クラスタ } C_i \text{ に含まれるデータ数}$$

- クラスタに変化がなくなるまで, ステップ 2, 3 を繰り返す

付録 3: SARIMA

定常時系列 X_n を過去の観測値 X_{n-p} と白色雑音 ε_n の現在の値の線形和で表現したモデルは以下の式を満たす.

$$X_n = \sum_{i=1}^p a_i X_{n-i} + \varepsilon_n - \sum_{i=1}^q b_i \varepsilon_{n-i}$$

これを次数 (p, q) の ARMA(自己回帰移動平均)モデルと呼ぶ. しかし, トレンド性がある時系列は非定常時系列になるため, トレンド性を取り除き定常時系列にした後, ARMA モデルを適用する必要がある. 非定常時系列 Y_n を d 次の階差を取った後に ARMA モデルを適用した場合, ラグ演算子 B を用いることで以下の式が得られる.

$$\varphi_p(B)(1-B)^d Y_n = \theta_q(B)\varepsilon_n$$

ただし

$$\varphi_p(B) = 1 - \varphi_1 B - \dots - \varphi_p B^p$$

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$$

これを次数 (p, d, q) の ARIMA (自己回帰和分移動平均) モデルと呼ぶ.

ARIMA モデルに周期的な変動 (季節変動など) を加味したモデルを SARIMA (季節自己回帰和分移動平均) モデルと呼ぶ. 季節性がある時系列は, 非定常時系列となるため周期性を取り除き定常時系列にした後, ARIMA モデルを適用する必要がある. 非定常時系列 Z_n を D 次の季節階差を取った後に ARIMA モデルを適用した場合, 以下の式が得られる.

$$\varphi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D Z_n = \theta_q(B)\Theta_Q(B^s)\varepsilon_n$$

ただし

$$\varphi_p(B) = 1 - \varphi_1 B - \dots - \varphi_p B^p$$

$$\Phi_P(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_P B^{Ps}$$

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$$

$$\Theta_Q(B^s) = 1 - \Theta_1 B^s - \dots - \Theta_Q B^{Qs}$$

これを次数 $(p, d, q) \times (P, D, Q)$ の SARIMA モデルと呼ぶ.