

Echo State Network を用いた電力需要予測に関する研究 A Study on Electricity Demand Forecasting by Using Echo State Network

羽山 昂伸[†]
Koshin Hayama

内保 光太郎[‡]
Kotaro Uchiho

西山 英治[‡]
Eiji Nishiyama

新谷 洋人[‡]
Hirohito Shintani

1. はじめに

電力需要予測とは小売電気事業者が日々の需要計画を立てるために翌日の電力の需要量を予測する重要な作業である。小売電気事業者は需要計画と供給実績に差が発生した場合、その差に比例した金額を一般送配電事業者に支払わなければならないため、より正確な予測が必要となる。

2016 年の電力自由化に伴い、小売電気事業に参入した新電力と呼ばれる事業者は、大手電力会社のような地域ごとの供給ではなく契約した一般家庭や施設ごとの供給を行うため、顧客ごとに需要変動のパターンが異なり予測が困難であった。また、顧客ごとに大量の過去のデータが必ずあるわけではないため少量データでの予測となる。以上のことから、少量データで顧客ごとの需要変動に対応した柔軟で正確な予測が望まれる。

本研究では、予測手法として Reservoir Computing に着目し、予測モデルとして Echo State Network^[1] (以下、ESN) を用いて、電力需要予測を行った。また、時系列データの周波数に注目し予測精度の向上を図った。

2. 予測モデル

2.1 Echo State Network

Echo State Network (以下、ESN) は入力層、Reservoir 層、出力層の 3 つで構成され、出力層につながる結合重みのみを学習し、それ以外の結合重みをランダムな値で固定することにより計算量を軽減したモデルである。Reservoir 層は結合重みを固定したリカレントニューラルネットワークになっており、ここに入力データの次元よりも十分大きい数の非線形ノード (tanh 関数) を用いることで時系列入力データを高次元の特徴空間に写像し、出力層で学習を行う。図 1 の実線の矢印は重み固定の結合で点線の矢印は固定されていない結合である。

離散時間 n における入力ベクトルを $\mathbf{u}(n)$ 、Reservoir 層のノード状態ベクトルを $\mathbf{x}(n)$ 、出力ベクトルを $\mathbf{y}(n)$ で表す。入力層と Reservoir 層の間の結合重み行列 (入力結合重み行列) を W^{in} 、Reservoir 層内の結合重み行列 (リカレント結合重み行列) を W 、Reservoir 層と出力層の間の結合重み行列 (出力結合重み行列) を W^{out} で表すとき、時刻 $(n+1)$ での Reservoir 層のノード状態ベクトル $\mathbf{x}(n+1)$ は式(1)で表すことができる。ここで $f(\cdot)$ は活性化関数 f を括弧内の要素ごとに施す操作を意味する。また、時刻 $(n+1)$ での出力ベクトル $\mathbf{y}(n+1)$ は式(1)の $\mathbf{x}(n+1)$ を用いて式(2)で表すことができる。

$$\mathbf{x}(n+1) = \mathbf{f} \left(W^{\text{in}} \mathbf{u}(n+1) + W \mathbf{x}(n) \right) \quad (1)$$

$$\mathbf{y}(n+1) = W^{\text{out}} \mathbf{x}(n+1) \quad (2)$$




図 1 Echo State Network

2.1.2 提案手法

本研究では、電力データを複数の周波数帯に分割し、分割したそれぞれの周波数帯のデータに対して ESN を一つずつ用意し、各周波数帯の ESN が予測した結果を全て足し合わせる手法を提案する。

この手法は ESN の、学習時を用いた教師データの周波数によって、より正確に予測できる時系列データの周波数が変わるといった性質^[2]に着目したものである。

3. 検証方法

3.1 データセット

検証データとして、関西電力のホームページで公開されている電力需要実績データ、顧客ごとの電力データの例として熊本高専における電力使用状況データ、以上の 2 つを用いた。データの期間は関西電力が 2015/1/1 から 2015/12/31 の 12 ヶ月間、熊本高専が 2020/9/1 から 2021/7/31 の 11 ヶ月間であり、電力の単位は関西電力が 10^4kW (万 kW)、熊本高専が kW である。データの間隔はともに 30 分毎である。少量データでの学習が目的であるため 1 ヶ月分を学習データに、翌月分を検証データに用いた (例: 1 月分学習 → 2 月分検証)。また月ごとの予測精度の違いを確認するためにこれを全ての月に対して行う。

3.2 周波数帯の分割

以下、提案手法のモデルを分割モデルと呼び、それに対して周波数の分割を行わないモデルを基本モデルと呼ぶ。入力データを分割する際の周波数は 1 年間を 1 秒間に見立てた場合のものとした (例: 1 日に一度の周期は 1 年間 365 回繰り返されるため 365Hz)。

分割モデルは [60Hz 以下], [60Hz-400Hz], [400Hz 以上] の 3 つに分割した。このように分割した理由は電力データにおいて、日中に電力需要が高まり夜に需要が低くなるという変動パターンや、平日は需要が高く土曜日と日曜日で需要が低くなるという変動パターンが 1 日や 1 週間の周期と同じためである。

4. 検証結果

4.1 基本モデルと分割モデルの結果

表 1 基本モデルと分割モデルの予測結果

モデル	MAPE 最小(%)	MAPE 最大(%)
関西電力		
基本モデル	5.008 (9月)	6.628 (2月)
分割モデル	4.302 (10月)	5.221 (2月)
熊本高専		
基本モデル	13.791 (10月)	26.184 (3月)
分割モデル	12.562 (10月)	20.249 (7月)

表 1 に 2 つのデータに対して、それぞれのモデルでの予測結果を示す。表 1 より、関西電力のデータにおいて、MAPE の最小と最大のどちらも分割モデルの方が基本モデルより 1%前後小さくなっていることが分かる。熊本高専のデータにおいても、MAPE の最小と最大は分割モデルの方が小さく、MAPE の最小では基本モデルと 1%程度の差がみられ、MAPE の最大では基本モデルと 6%程度の差がみられた。

基本モデルの 3 月の誤差が大きいのは春季休業の予測しづらい需要変動パターンによるものと考えられる。また、関西電力のデータを用いた予測に比べ、熊本高専のデータを用いた予測の方が精度は低くなった。これは関西電力のデータは広範囲の電力需要であるため、変動パターンがある程度決まっているのに対して、熊本高専のデータは 1 つの建物の電力需要であり、関西電力のデータに比べて変動パターンが不規則であるためだと考えられる。




図 2 関西電力データの 2 月のスペクトル




図 3 熊本高専データの 7 月のスペクトル

次に分割モデルでの MAPE が最大となった月の電力データのスペクトルを図 1 と図 2 に示す。図 1 より、100Hz や 730Hz 付近に強いスペクトルがみられる。分割モデルは周波数帯を 60Hz から 400Hz と 400Hz 以上のように分割したため、1 つの周波数帯に複数の強いスペクトルが立ち、この周波数帯を分割できていなかったため誤差が大きくなったと考える。図 2 より、730Hz 付近に強いスペクトルがみられる。分割モデルでは 730Hz 付近の周波数帯を分割できていなかったため誤差が大きくなったと考える。これらを踏まえて、関西電力の 2 月のデータと熊本高専の 7 月のデータに対しての予測精度を上げるために、電力データをさらに分割し周波数帯を追加したモデルをそれぞれのデータに対して用意した。

4.2 分割数を増やした場合

関西電力のデータに対しては[60Hz 以下], [60Hz-200Hz], [200Hz-400Hz], [400Hz-800Hz], [800Hz 以上]の 5 つに分割したモデル (以下, 5 分割モデル) を用い、熊本高専のデータに対しては[60Hz 以下], [60Hz-400Hz], [400Hz-800Hz], [800Hz 以上]の 4 つに分割したモデル (以下, 4 分割モデル) を用いた。これらのモデルによる予測結果と分割モデルでの予測結果との比較を表 2 に示す。

表 2 5 分割モデルと 4 分割モデルの予測結果

モデル	関西電力(2月)	熊本高専(7月)
分割モデル	5.221%	20.249%
5 分割モデル	4.882%	
4 分割モデル		17.486%

表 2 より、関西電力の 2 月の MAPE は分割モデルより 5 分割モデルの方が 0.3%程度小さくなっていることが分かる。また、熊本高専の 7 月の MAPE についても分割モデルより 4 分割モデルの方が 3%程度小さくなっていることが分かる。これにより、5 分割モデルと 4 分割モデルの周波数帯の分け方はそれぞれ関西電力の 2 月のデータと熊本高専の 7 月のデータに適したものであったと考えられる。

5. おわりに

本研究では電力需要予測において、ESN の性質に着目し入力データを周波数帯で分割し予測する分割モデルを提案した。検証結果から分割モデルの有効性を確認することはできたが、本研究の目的である顧客ごとの需要変動パターンへの対応については熊本高専のデータを用いた予測結果から分かるように問題点が残る形となった。このような需要変動パターンの変化への対応を少量データでの学習という条件を踏まえながら模索することを今後の展望とする。

参考文献

- [1] Herbert Jaeger, "The "echo state" approach to analysing and training recurrent neural networks - with an Erratum note", GMD Technical Report, (2001)
- [2] 田村 浩人, "Reservoir 層計算を用いた予測符号化モデル", (2019)

† 熊本高等専門学校 National Institute of Technology, Kumamoto College