

## Echo State Network を用いた電力需要予測手法の検討 A Study of Electricity Demand Forecasting Method Using Echo State Network

羽山 昂伸<sup>†</sup>  
Koshin Hayama

内保 光太郎<sup>‡</sup>  
Kotaro Uchihō

西山 英治<sup>†</sup>  
Eiji Nishiyama

新谷 洋人<sup>†</sup>  
Hirohito Shintani

### 1. はじめに

電力自由化後に小売電気事業に参入した新電力と呼ばれる事業者は、大手電力会社に比べ需要家数が少ないため、需要家数の変動や各需要家の生活環境の変化などによる需要変動の影響が大きく、予測が困難である。対策の一つとして需要家ごとで予測を行う場合、需要家ごとに大量の過去のデータが必ずあるわけではなく、各需要家に割く計算リソースも限られるため、少量データで需要家ごとの需要変動に対応した計算リソースの少ない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<sup>[1]</sup> (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と ESN のハイパーパラメータであるスペクトル半径に注目し、予測精度の向上を図った。

### 2. 予測モデル

#### 2.1 Echo State Network

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を  $W^{\text{in}}$ , Reservoir 層内の結合重み行列を  $W$ , Reservoir 層と出力層の間の結合重み行列を  $W^{\text{out}}$  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。

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

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

#### 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。

<sup>†</sup> 熊本高等専門学校 National Institute of Technology,  
Kumamoto College

<sup>‡</sup> 日本経済大学 Japan University of Economics




図 1 Echo State Network

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う性質<sup>[2]</sup>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 HP で公開されている電力需要実績データ、需要家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  $10^4\text{kW}$  (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)。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、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。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 年間で見ると 365Hz)。

分割モデルは [60Hz 以下], [60Hz-400Hz], [400Hz 以上] の 3 つに分割した。これは、日中に電力需要が高まるという変動パターンや、平日は需要が高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。

#### 3.3 スペクトル半径の調整

ESN の予測性能はハイパーパラメータの一つであるリカレント結合重み行列  $W$  のスペクトル半径  $\rho$  に強く依存するため、電力需要予測においてどれだけ精度に影響するのか確かめる。スペクトル半径  $\rho$  とは行列の固有値の絶対値の最大値であり、 $\rho$  を 1 に近いかつ  $\rho < 1$  とすると予測精度が良くなることが経験的に知られており、今回はまず  $\rho = 0.9$  として予測を行い、次に各 ESN において  $0.40 \leq \rho \leq 1.95$  として  $\rho$  を 0.05 ずつ変化させて予測精度の違いを確認する。

## 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同様の結果となり、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。

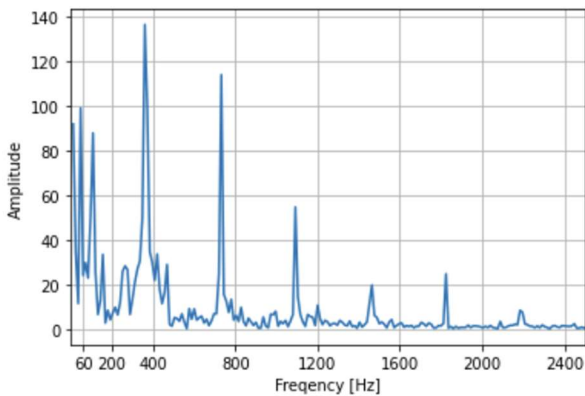


図2 関西電力データの2月のスペクトル

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2に示す。図2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。熊本高専の7月のデータでも同様に誤差が大きくなったと考える。これらを踏まえて、この2つのデータに対しての予測精度を上げるために、分割する周波数帯を増やしたモデルをそれぞれのデータで用意した。

### 4.2 分割数を増やした場合

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%

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。

### 4.3 スペクトル半径による精度差

表3  $\rho$ 最適化による精度比較

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%
分割 $\rho$ 最適化	4.707%	17.385%
5分割 $\rho$ 最適化	3.325%	
4分割 $\rho$ 最適化		16.667%

表2での2つのデータに対して5分割モデルと4分割モデルで $\rho$ を最も精度が良くなるよう設定し予測した結果と表2との比較を表3に示す。どのモデルも精度の向上が見られ、特に5分割モデルでは比較的低い誤差から1.5%程度改善し3.325%という結果になった。

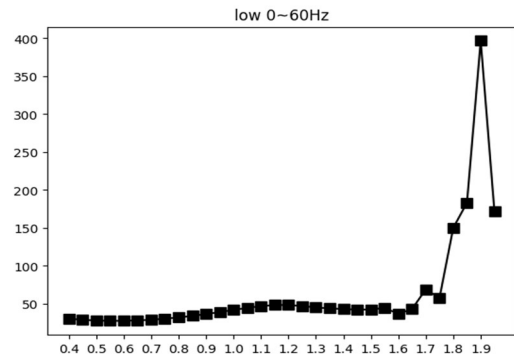


図3 関西電力データ2月の $\rho$ によるMAEの推移

次に関西電力2月のデータでの60Hz以下のMAEの推移を図3に示す。縦軸はMAEで横軸は $\rho$ である。どの周波数帯も最も誤差が低くなる $\rho$ は0.85から1.0程度であったが、60Hz以下においては0.6付近が最も小さいものとなり、他の月でも同様の傾向がみられた。これにより、低周波帯ではより小さいスペクトル半径の方が適している可能性が考えられる。

## 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モデルを提案した。検証結果から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需要家ごとの需要変動パターンへの対応については問題点が残る形となった。このような需要変動パターンへの対応をスペクトル半径の調整をはじめ、様々な手法で模索していきたい。

### 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)