

## 決定木分類を用いた電力需要予測の検討 Study of Electric Power Demand Prediction Using a Decision Tree Classification

佐々木 秀彰<sup>†</sup> 浦野 昌一<sup>†</sup>  
Hideaki Sasaki Shoichi Urano

### 1. はじめに

私達の日常生活は電力で成り立っている。その電力は、需要と供給の均衡が崩れると発電機の停止に繋がり、電力系統全体の停電に陥る可能性がある。近年、再生可能エネルギーである太陽光発電や風力発電の増加により、気象条件による発電量の変動や余剰電力が問題になっている。電力は貯めることが出来ないため、余剰電力が発生すると発電コストが無駄になる。また、再生可能エネルギーによる発電量と需要予測を高精度に行うことができれば、再生可能エネルギーを最大限に有効活用でき、火力発電量を減らせると考えられる。これにより、二酸化炭素排出量を削減することができ、地球温暖化を防ぐことへ繋がる。さらに、電力は需要量と供給量のバランスを保つことが必要で、需要が供給を上回ると最悪の場合には電力系統全体が停電に陥る可能性があり、信頼が下がる。すなわち、高精度な電力需要予測をすることで、余剰電力を減らすことは、経済的、環境的、信頼度的に重要である。

電力需要予測では、高精度な予測の実現のために季節を考慮した研究が行われている。季節を考慮した先行研究では、構造化ニューラルネットワークを春の電力需要予測に適用した研究<sup>[1]</sup>や季節を 2 分割し、タグチの T 法を適用した短期電力需要予測の研究<sup>[2]</sup>が報告されている。しかし、電力需要予測における季節の定義には検討の余地がある。

筆者らは、これまで気象庁の定義による季節に分類をした後に、ニューラルネットワークを適用して最大電力需要予測を行ってきた<sup>[3]</sup>。そこで、本稿では決定木により電力需要を季節のように分類し、ニューラルネットワークを適用することで、最大電力需要予測の高精度化を目指す。

### 2. 電力需要予測

本稿では、予測対象として、1 日の最大電力需要量を予測する。電力は日々の需要に対して、火力発電、水力発電といった発電によって供給を行う必要がある。一般的に、電力需要は社会要因である平日や休日に、気象要因である気温、湿度等に左右されることが知られている。例えば、夏は気温が高くなるにつれて快適に過ごせるようにエアコンによって室温調整を行うために冷房需要が増加することなどが一因となって電力需要量が多くなる。

### 3. 予測手法

筆者らは先行研究<sup>[3]</sup>において予測手法としてランダムフォレストやニューラルネットワークを用いた予測を行ってきた。本稿では、季節の分類に決定木を用い、予測にニューラルネットワークを用いる。

### 3.1 決定木

決定木は機械学習の 1 つで教師あり学習に分類され、回帰、分類をすることができる。標準化や正規化といったデータの前処理が不要で、木構造なので分割基準や入力変数の重要度が視覚的に捉えやすい特徴を持つ。

### 3.2 ニューラルネットワーク

ニューラルネットワークは機械学習の 1 つで、回帰と分類をすることができる。人間の脳の構造を数理化したものである。一般的に用いられる階層型ニューラルネットワークを図 1 に示す。階層型ニューラルネットワークは入力層、隠れ層、出力層の 3 層から構成される。それぞれの層にニューロンがあり、各層の間にはニューロン同士の繋がり強さである結合重みが存在する。この結合重みの違いで電気信号が変化する。結合重みの学習は一般的に誤差逆伝播法が用いられる。

### 4. シミュレーション

本稿では、学習データに対し、データの前処理として気象条件ごとに決定木で分類を行い、その分類結果に基づき、学習データを分割し、ニューラルネットワークを適用して予測を行う。図 1 にシミュレーションの流れを示す。図 1 内の NN はニューラルネットワークを示す。

#### 4.1 シミュレーション条件

##### 4.1.1 入力変数について

入力変数は電力データとして需要実績値で以下の 8 つを扱う。

火力、風力、太陽光、バイオマス  
揚水、水力、連系線、1 日の需要量平均

また、気象データとして気象実績値は平均気温、平均日射量、平均風速、平均湿度、最高気温、最低気温の 6 つを

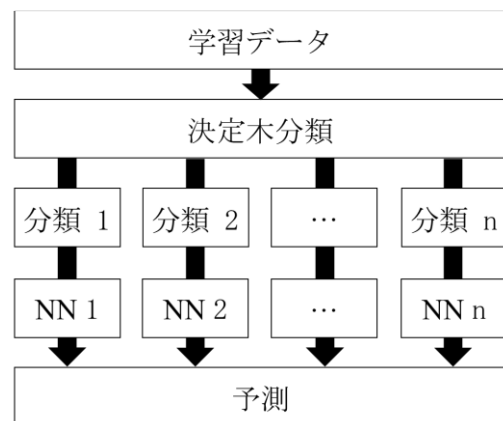


図 1. シミュレーションの流れ

<sup>†</sup> 明治大学先端数理科学研究科 Meiji University  
Advanced Mathematical Sciences

扱う。その際に用いるデータとして東京電力管轄内エリアの以下の 10 地点とする。

東京、横浜、千葉、さいたま、宇都宮

前橋、水戸、三島、甲府、八王子

上記 10 地点の平均を平均気温、平均湿度等とする。また、10 地点の中で 1 番気温が低い地点を最低気温、1 番気温が高い地点を最高気温とする。

#### 4.1.2 モデル化期間について

1 日の最大電力需要予測を行う際に、今回は 2016 年 4 月～2019 年 4 月までをモデル化期間とし、2019 年 4 月～2020 年 3 月までを予測対象とする。

また、本稿のシミュレーションでは、社会的要因の影響が高い土曜、日曜、祝日、GW や年末年始といった祝日相当を除いた平日のみの最大電力需要予測とする。1 ヶ月の平日の日数が約 20 日となるため、モデル化期間は 20 日区切りとし、分類した結果を用いてモデル化を行う。

#### 4.1.3 手法のパラメータ設定

分類には決定木、予測にはニューラルネットワークを用いる。その際の条件を以下に示す。

<決定木>

最大の葉の数：4

<ニューラルネットワーク>

学習回数：5000

入力層のニューロン数：14

隠れ層のニューロン数：14

出力層のニューロン数：1

決定木における葉の数は、季節が四季に分類されることから、シミュレーションにおける分類の数を 4 としたことから葉の数は 4 となる。

## 4.2 シミュレーション結果

### 4.2.1 決定木による分類結果

決定木は目的変数として、最大電力需要量、入力変数として、気象データの 6 つを用いた。シミュレーション条件に従い、モデル化期間 20 日区切りで 20 日から 700 日の分類を行った。そのモデル化期間のうち最大誤差率が一番小さかったモデル化期間 180 日の分類結果を図 2 に示す。

図 2 の左から分類 1、分類 2、分類 3、分類 4 とする。分類 1 は冬のような傾向があり、分類 2 は春と秋が一緒になっているような傾向がある。また、分類 3 は季節という夏、分類 4 は夏の中で猛暑日のような傾向があることが確認できた。上記の分類に従いデータを分割すると、学習期間、予測期間は以下のとおりに分割される。

分類 1：学習期間 217 日、予測期間 44 日

分類 2：学習期間 589 日、予測期間 162 日

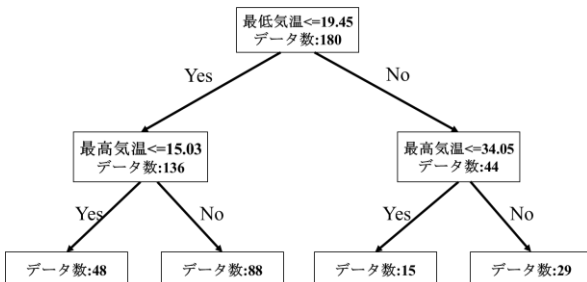


図 2. 決定木分類の結果

表 1. ニューラルネットワークの予測結果

	分類 1	分類 2	分類 3	分類 4
モデル化期間	120 日	80 日	20 日	20 日
最大絶対誤差率[%]	8.15	10.76	4.05	6.09
最小絶対誤差率[%]	0.24	0.09	0.35	0.54
平均絶対誤差率[%]	3.22	3.78	2.08	2.89
標準偏差[%]	2.20	2.50	1.24	1.98

分類 3：学習期間 93 日、予測期間 17 日

分類 4：学習期間 48 日、予測期間 12 日

### 4.2.2 ニューラルネットワークによる予測結果

決定木による分類を用いて分類 1~4 に分けてモデルを作成し、20 日ごとにモデル化期間を設定し、ニューラルネットワークで学習、予測を行った。分類 1~4 で最大誤差率が最小となったモデル化期間の結果を表 1 に示す。最大誤差率が比較的抑えられた分類 3,4 に着目すると、先行研究<sup>[1]</sup>の気象庁のカレンダーで季節を分類した夏モデルでは最大誤差率 8.87% だったが、分類 3,4 と比較をすると、最大誤差率が分類 3 では 4.05%、分類 4 では 6.09% と最大誤差率の低減が確認できた。他の季節においても最大誤差率の低減が確認できた。このように最大誤差率の低減できた理由として、データの分類が気象庁のカレンダーで分類する四季よりもデータの特徴を捉える分類とするほうが予測精度を向上できたと考えられる。一例にはなるが、春にもかかわらず、夏のように暑い日が存在するため、今回の決定木分類によって特徴の近い分類ができたのではないかと考える。しかし、本稿のシミュレーションにおいて、分類 2 は最大誤差率が大きく、改善の余地がある。

## 5. まとめ

本稿では、決定木で季節的な分類をした後に、ニューラルネットワークで最大電力需要量予測を行った。季節を四季による分類ではなく、気象要因により分類をすることで予測精度の向上を確認した。

今後の課題としては、シミュレーション結果の分類 2 における最大誤差率が大きいため、分類 2 のさらなる特徴を捉える分類をすることで予測精度を向上する必要があると考える。また、予測手法単体の精度向上につながる有効な入力変数の検討をする必要があると考える。

### 参考文献

- [1] 飯坂 達也, 松井 哲郎, 福山 良和, “構造化ニューラルネットワークの新しい学習法と最大電力需要予測への適用”, 電気学会論文誌 B (電力・エネルギー部門誌), 124 巻 3 号, p.347-354 (2004)
- [2] 根岸 信太郎, 森本 裕介, 高山 聡志, 石亀 篤司, “タグチの T 法を用いた翌日最大電力需要予測”, 電気学会論文誌 C (電子・情報・システム部門誌), 136 巻 6 号, p.794-801 (2016).
- [3] 佐々木 秀彰, 浦野 昌一, “複数手法を組み合わせた最大電力需要予測における妥当性の検討”, 2021 年度人工知能学会全国大会 (第 35 回), No. 2G3-GS-2e (2021)