

気象予測データと機械学習を用いた 高精度な電力需要予測手法

High-Precision Electricity Demand Forecasting Method Using Weather Prediction Data and Deep Learning

進 博正 SHIN Hiromasa 志賀 慶明 SHIGA Yoshiaki 市川 量一 ICHIKAWA Ryoichi

我が国では、気象条件に影響される再生可能エネルギー（以下、再エネと略記）電源の急増に伴い、その発電量を含めた電力の需給管理が求められている。また、電力システム改革による制度の下では、電力需要予測の精度は小売電気事業者の収益に直接的に影響を与えることから、予測精度の向上が望まれている。

東芝グループは、米国国立環境予測センター（NCEP）の予報データを基に国内全域のメッシュ気象予測データを作成し、スパースモデリングとアンサンブル学習の機械学習技法を併用したAIと組み合わせることで、電力需要量を高精度に予測する手法を開発した。従来手法に比べ、対象エリアの電力需要量の前日予測誤差を約1%抑制でき、小売電気事業者向けの需給管理システム製品や、東芝グループが推進する仮想発電所サービス事業などへの活用を目指している。

With the proliferation of renewable energy systems in Japan, which are affected by weather conditions, it has become necessary to make further efforts to maintain the electricity supply and demand balance as well as the amount of electricity generated. As the profits of electricity retailers are directly linked to the accuracy of demand prediction under the current electricity system, there is a strong requirement for highly precise forecasts of electricity demand.

The Toshiba Group has developed a high-precision electricity demand forecasting method using numerical weather prediction data and deep learning. This method provides customers with information on electricity demand through the following processes: (1) creation of meshed weather prediction data for all areas of the country based on numerical prediction data distributed by the U.S. National Centers for Environmental Prediction (NCEP), (2) feature extraction from a small amount of information by means of a sparse modeling method, and (3) reduction of prediction errors by means of an ensemble learning method. The use of this method has achieved a reduction in prediction errors of approximately 1% in calculations using the data of the targeted areas for the preceding day compared with the conventional forecasting methods. We are aiming to apply our new method to electricity management systems for electricity retailers and virtual power plant (VPP) services.

1. まえがき

需要予測とは、商品やサービスに関する将来の需要量を予想することである。電気や、ガス、水道などのインフラ分野において、需要予測は運用計画の起点となる。電力の需要予測は、供給計画、すなわち発電所の運転計画を作成するために日常的に用いられる⁽¹⁾⁻⁽³⁾。需要予測の精度が高ければ、発電所の待機運転を減らすことができ、発電コストや環境負荷を低減できる。近年、太陽光発電などの再エネ電源が世界的に急増しており、再エネ発電量を含めて電力の供給計画を作成するためには、再エネ発電量の予測も重要である。更に、卸電力市場を活用して需要と供給の均衡を図る場合には、市場価格の予測も必要である。国内では電力システム改革が進行中で、計画値同時同量制度の下で小売電気事業者は、事前に電力広域的運用推進機関に提出した需要の30分単位の計画値と、その実績値との差異（インバランス）に比例した金額を事後に精算する。こ

のため、需要予測の精度は小売電気事業者の収益に直接的に影響を与える要因となり、その重要性を増している。

東芝グループは、このような電力の需給管理で求められる電力需要量や、再エネ発電量、市場価格などの各予測に最新のAIを活用して精度を高める技術を開発している⁽³⁾。ここでは、このうちの電力需要予測手法について述べる。

2. エネルギー分野でのAIを活用した予測手法

電力需要量、再エネ発電量、及び市場価格の各予測は、AIの代表的な実現手段である機械学習の応用分野に含まれる。各種の実績値は、数値データで蓄積されており、気象条件（地表付近の気温や日射量など）との相関が知られている。例えば、電力需要量は、カレンダー条件（時間帯、曜日など）と気温や日射強度などの気象条件からおおむね推定できる。太陽光及び風力の発電量は、発電所周辺の日射量や風速といった気象条件から推定できる。市場価格は、電力需要量におおむね依存する。機械学習では、これらの実

表1. エネルギー分野における代表的な予測手法コンテスト

Examples of electricity demand forecasting contests

主催者	名称	予測対象	開催年
IEEE PES	Global Energy Forecasting Competition (GEFCOM)	電力需要量, 価格, 太陽光・風力発電量	2012, 2014, 2017
EWEA	Wind power forecasting	風力発電量	2013, 2015
電気学会	予測コンペ	太陽光・風力発電量	2014, 2015
東京電力HD(株)	電力需要予測コンテスト	電力需要量	2017
東京電力HD(株), 北海道電力(株)	太陽光発電量予測技術コンテスト	太陽光発電量	2019

IEEE PES : IEEE Power & Energy Society
EWEA : The European Wind Energy Association

績値と気象条件の定量的な関係をデータから学習する。学習済みの関係と気象機関から取得した気象予測データを組み合わせると、所望の電力需要量を予測できる。

表1に示すように、近年のオープンイノベーション活用を背景として、国内外の学会及び民間企業が、エネルギー分野の予測手法に関するコンテストを開催している⁽⁴⁾⁻⁽⁷⁾。開催者が公開する情報によれば、大部分の上位入賞者が機械学習に基づく予測手法を採用している。東芝グループも、予測の技術力を高めるために、継続的に各種コンテストに参加している。

3. 気象予測データの高精細度化

東芝グループは、AIを活用した予測手法の研究開発インフラとして、気象予測システムを社内運用している。気象予測システムは、NCEPの全球予報GFS (Global Forecast System) を数値気象モデルWRF (Weather Research and Forecasting) で力学的ダウンスケーリング(高精細度化)処理することで、国内全域の大気状態を9 km四方のメッシュごとに予測する。

4. 高精細度の気象予測データを活用するAI

高精細度化したメッシュ気象予測データと各種の実績データをAIに入力することで、AIが両者の関係を定量的に学習して、所望の電力需要量を予測する(図1)。予測に用いるAIは、メッシュ気象予測データを効果的に活用して予測精度を高めるように、スパースモデリング及びアンサンブル学習の機械学習技法を併用する。以下において、AIの構造上の特徴を順番に述べる。

4.1 入力変数を選別するスパースモデリング技法

従来の電力需要予測手法は、需要量へ強く影響する地点及び気象量を、人が手動で選んで機械学習を適用することが多い。例えば、供給エリア内の県庁所在地のような主

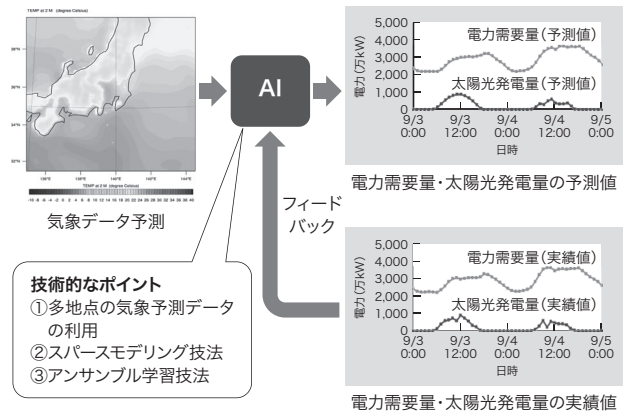


図1. 電力需要予測システムの概要

AIが、気象予測値と電力需要量の実績値の関係を学習した上で予測する。

Outline of electricity demand forecasting method

要都市の気温や、湿度、日射強度などを用いる。従来手法は、気象データの入手容易性、取得データ量や計算量の観点から合理的なものであり、簡便で良好な予測精度を実現できるが、地点及び気象量の選定には、人間の経験に基づいた判断が必要であった。

これに対して、東芝グループの電力需要予測は、高精細度のメッシュ気象予測データ(気温や、湿度、日射強度、風速などの気象要素)をAIへ入力して、予測に有効な地点や気象要素をAIが自動で選ぶ手法である。ただし、予測に用いる地点や気象要素といった説明変数の数を単純に増やした場合、必ずしも予測精度が改善するとは限らない。機械学習のいわゆる過学習によって予測精度がかえって悪化することが多い。このような過学習を避けながらメッシュ気象予測データを活用するため、スパースモデリング技法を採用した。この技法は、データから関係を学習する際に、需要予測に用いる説明変数の次元数を抑える効果を発揮する。

一例として、図2に、東京電力ホールディングス(株)(以下、東京電力HD(株)と略記)管内のアメダス地点の気象




図2. スパースモデリングによる気象地点の選択例

スパースモデリング技法は、需要予測に有効な気象地点を選択する。

Examples of weather points selected by sparse modeling method




図3. 一般化加法モデルによる気温や日射強度に対する感応度の学習例

一般化加法モデルは、気温や日射強度に対する感応度を学習するので、学習結果を解釈しやすい。

Examples of temperature sensitivity curves learned by generalized additive model

データを用いて需要予測モデルを学習した場合に、スパースモデリング技法によって選択される地点とその影響度を、円とそのサイズで示した。需要予測に強く影響する気象地点が時間帯で変化する結果となり、昼間は都心部の影響が強く、夜間は郊外部の影響も強いと解釈できる。この例のようにスパースモデリングを用いると、メッシュ気象予測データから需要予測に有効な地点と気象要素を自動で選別でき、需要予測の精度を高められる。予測精度に関する実際のスパースモデリングの効果は、アンサンブル学習の効果と併せて4.2節で述べる。

電力の需要予測は、予測結果の精度だけでなく説明性や解釈性も重要である。説明性や解釈性を高めるには、例えばデータから学習した電力需要量の気温感応度を明示することなどが有効である。一般化加法モデル(GAM: Generalized Additive Model)は、スパースモデリング技法と併用可能であり、需要予測で求められる説明性や解釈性に優れている。図3は、GAMを用いて学習した電力需要の気温及び日射強度に対する感応度の可視化例である。気温への需要応答は、約15℃付近で最小となり、そこから外れると増加することから、空調機由来の効果と解釈できる。日射強度への需要応答は、日射強度が増えると需要が減ることから太陽光発電の自家消費由来の効果と解釈できる。

このように東芝グループの電力需要予測システムは、メッシュ気象予測データを有効に活用するスパースモデリング技法を採用した上で、予測結果の説明性や解釈性を高める一般化加法モデルの技法も併用する。

4.2 予測結果の精度を高めるアンサンブル学習技法

複数の需要予測モデルを組み合わせることで予測誤差を減らすアンサンブル学習の技法について述べる。いくつかの異なる

予測値の集団(アンサンブル)を利用する際に、各予測値の誤差傾向が互いに似ている場合、組み合わせても予測誤差を減らせないが、逆に、各予測値の誤差傾向が互いに異なる場合、うまく各予測値を組み合わせると各誤差が打ち消し合い、結果として予測誤差を抑制できる。

例えば、公開されている東京エリアの需要実績値(1時間値)を、重線形回帰(MLR)、GAM回帰、人工ニューラルネット(ANN)回帰、及び各地点の一般化加法モデルをスパース回帰で組み合わせる方法(SPM)を用いて、それぞれ評価した結果では、需要予測の誤差は、予測手法に応じて時間帯ごとに傾向が異なる(図4)。この評価は、毎朝8時に翌日需要を予測する条件で行い、2012年から2014年までの3年間のデータを学習した後、2015年の1年間に対して予測誤差を評価した結果である。簡単のために気象データは、1地点で評価する場合は東京(大手町)




図4. 各需要予測手法による時間帯ごとの誤差の比較

アンサンブル学習(ENS)は、時間帯ごとに適切な予測手法を組み合わせるので、予測誤差を抑制できる。

Comparison of hourly averaged forecast errors obtained by various forecasting methods

表2. 各需要予測手法による年間予測誤差の比較

Comparison of annual averaged forecast errors obtained by various forecasting methods

予測手法	説明	MAPE (%)
MLR	気象1地点の重線形回帰	2.84
GAM	気象1地点のGAM回帰	2.46
ANN	気象9地点のANN回帰	2.97
SPM	気象9地点のスパース回帰	2.16
ENS	上記のアンサンブル学習	2.09

を、9地点で評価する場合はエリア内県庁所在地を選択した。各手法の予測誤差は、長さ T の評価対象時間範囲内で任意の時刻 t における予測値 \hat{L}_t と実績値 L_t から、平均絶対誤差率MAPEとして式(1)で求め、表2に示した。

$$MAPE = \sum_{t \in T} (|\hat{L}_t - L_t| / L_t) / |T| \times 100 \quad (1)$$

各予測手法の特徴は、次のとおりである。MLRは、手動で特徴量を選んで学習データを前処理すると良好な結果となる。ANNは、前処理不要で良好な結果が得られ、単体の予測精度は高くないが、他の予測手法と誤差傾向が異なる。GAMは、簡単な前処理で、良好な結果となる。GAMで気象地点を増やしたSPMは更に良好な結果となる。このように特徴が異なるこれらの予測値を時間帯ごとにデータを分割してアンサンブル学習すると、各時間帯で誤差の少ない予測手法を重視した予測値(図4中のENS)となり、全体の予測誤差を抑制でき、良い結果となる。

このように東芝グループの電力需要予測システムは、アンサンブル学習の技法を採用しており、複数の予測手法から予測値を求めた上で、これら予測値を組み合わせることで、従来手法に比べて0.37~0.88%精度を高めている。例えば、誤差が1.0%減ると電力供給コストは約0.1%下がると言われており、仮に供給コストを年間1兆円とすれば、10億円の削減が可能になる。

5. あとがき

将来の電力システムが直面する課題⁽⁸⁾に対応する上で、正確な需要予測(負荷予測)のニーズが高まるとともに、ニーズ自体も多様化すると考えられる。例えば、再エネ電源が増えると、火力発電などが分担すべき残余需要量の予測精度の向上がこれまで以上に求められる。需給調整のためのネガワット取引では、デマンドレスポンス時の応答量を推定(予測)することが求められる。また、電気自動車が普及すると、電力需要に影響を与える電気自動車の充電需要を予測することが求められる。

このように将来の電力システムで求められる需要予測の多様なニーズに応えるには、今後導入が進むスマートメーターから得られる需要ビッグデータと、WRFなどの数値気象予報モデルや気象衛星画像などから得られる気象ビッグデータとを、最新の機械学習を柔軟に組み合わせて活用する発想が求められる。将来の課題解決に向けて、ここで述べた機械学習を用いた需要予測手法を活用していく。

文献

- (1) Bunn, D. W. Forecasting loads and prices in competitive power markets. Proceedings of the IEEE, 2000, **88**, 2, p.163-169.
- (2) Hahn, H. et al. Electric load forecasting methods: Tools for decision making. European Journal of Operational Research, 2009, **199**, 3, p.902-907.
- (3) 進 博正, ほか. 機械学習を活用した電力需要予測技術. エネルギーと動力, 2018, **68**, 290, p.36-45.
- (4) Hong, T. et al. Probabilistic energy forecasting: Global Energy Forecasting Competition 2014 and beyond. International Journal of Forecasting, 2016, **32**, 3, p.896-913.
- (5) 加藤丈佳. “予測コンペの開催報告”. 平成28年電気学会電子・情報・システム部門大会講演論文集, 神戸, 2016-09, 電気学会, 2016, p.234-239. (CD-ROM).
- (6) 東京電力ホールディングス. “電力需要予測値の正確さを競う「第1回電力需要予測コンテスト」の結果について”. プレスリリース. <http://www.tepco.co.jp/press/release/2017/1463817_8706.html> (参照 2019-04-01).
- (7) 東京電力ホールディングス. “「太陽光発電量予測技術コンテスト『PV in HOKKAIDO』」の結果について”. プレスリリース. <http://www.tepco.co.jp/press/release/2019/1515677_8709.html> (参照 2019-06-28).
- (8) 竹内純子, ほか. エネルギー産業の2050年 Utility3.0へのゲームチェンジ. 日本経済新聞出版社, 2017, 160p.



進 博正 SHIN Hiromasa, D.Sci.
 研究開発本部 研究開発センター
 システム技術ラボラトリー
 博士(理学) 情報処理学会会員
 System Engineering Lab.



志賀 慶明 SHIGA Yoshiaki, D.Sci.
 研究開発本部 研究開発センター
 システム技術ラボラトリー
 博士(理学)
 System Engineering Lab.



市川 量一 ICHIKAWA Ryoichi
 東芝エネルギーシステムズ(株)
 グリッド・アグリゲーション事業部 電力システム技術部
 電気学会会員
 Toshiba Energy Systems & Solutions Corp.