

「DS クラウド[®]」を活用した 電力需要予測システムの開発 ～機械学習手法による高精度予測の実現～

Development of Electricity Demand Forecasting System on “DS Cloud[®]”
～Realization of High-Precision Demand Prediction by Machine Learning～

陳 立 Li CHEN
デジタル・トランスフォーメーションセンター
データサイエンス室
マネジャー 博士(工学)

銀島 孝一 Kouichi GINJIMA
日鉄プラント設計(株)
CAESOL部 データサイエンスチーム
チーフ

西山 裕樹 Yuuki NISHIYAMA
デジタル・トランスフォーメーションセンター
データサイエンス室
マネジャー

夏目 洋明 Hiroaki NATSUME
営業本部
電力ソリューション部 企画・需給管理室

土橋 浩朗 Hiroaki DOBASHI
日鉄エネルギーサービス(株)
操業本部 電力サービスセンター センター長

木村 継嗣 Keishi KIMURA
日鉄エネルギーサービス(株)
操業本部 電力サービスセンター

石井 義道 Yoshimichi ISHII
日鉄エネルギーサービス(株)
操業本部 電力サービスセンター

抄 録

電力自由化市場の「同時同量」制度の下で運営される小売電気事業において、電力需要予測の精度は小売電気事業者の収益に直接的な影響を与える。正確な需要予測が望まれているが、従来の予測精度は運用者の熟練度に大きく依存していた。その問題に対して、当社は独自のデータ解析プラットフォーム-「DS クラウド[®]」を活用し、複数の機械学習手法を用いて高精度な電力需要予測システムを開発した。その概念実証 (proof-of-concept, PoC) に基づき開発内容を紹介する。

Abstract

In electricity retail business, the profits of retailers are directly affected by the accuracy of demand prediction under the current electricity system of 30-min 3% “balancing rule”. Demand prediction with high accuracy is preferable, while it strongly depends on the skill level of the operator. In order to achieve the accurate demand prediction and reduce the requirements of skill level simultaneously, we developed the electricity demand forecasting system on original data analytics platform “DS Cloud[®]” by introducing several machine learning techniques. Here we introduce the details of the system and proof-of-concept (PoC) in our business activities.

1 緒言

小売電気事業とは、自前設備からの発電や、卸電力取引所などから仕入れした電気を、需要家へ供給する事業である。2016年の電力全面自由化以来、

様々なプレーヤーが小売電気事業へ参入してきた。電力会社の送配電網の安定的な運用を確保するため、小売電気事業者には、「同時同量」の義務が課される。「同時同量」とは、30分単位で電気の需要量と供給量の乖離を抑制することである。電力システム

の「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翌日需給計画を提出する必要がある。提出した需要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¹⁾。そのため、電力計画値、いわゆる需要予測値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、市場競争が激しくなっている今、その重要性が高まっている。

当社は電力自由化開始後間もない2001年に小売電気市場に参入し、千葉県君津市に需給調整機能を担う24時間体制の自社拠点(需給管理センター)を設け、現在に至っている。需給管理センターに配置されている運用者たちは、各需要家の電力使用パターンのデータを蓄積・分析し、需要量に影響を与える気温等の各要因に基づいて、日々の需給計画を策定している¹⁾。

一方、AI&IoT(Internet of Things)をはじめとするデジタル技術が目覚ましく発展している中、当社では、2018年から、独自のクラウド・解析基盤であるDSクラウド®を立ち上げ、プラント操業やビジネス分野においての全社横断的なデータ解析やAI技術導入に取り組んできている²⁾。本稿では、DSクラウド®の応用の一例として、機械学習を活用した電力需要予測システムの開発やその運用状況について述べる。

2 需要予測システムの導入目的

従来の当社需給管理センターにおける翌日需給計画作成業務のイメージについて、図1に示す。

翌日需給計画においては、基本的に需要家から電力需要計画を入手することが出来ない中で「同時同量」を達成するべく、調達電力量と需要家への供給電力量をバランスさせる必要がある。そこで、運用者は、天気情報、直近実績や工場需要家の生産計画を参照しながら、類似データの分析を行い、各需要家への供給すべき電力量を予測する。その予測結果の合計値に基づき、翌日電力需給計画を作成し、電力広域的運用機関に提出する。上記のフローにおいて、需要予測を自動化するべく、システム開発、導入を行った。その狙い主には以下の3点である。

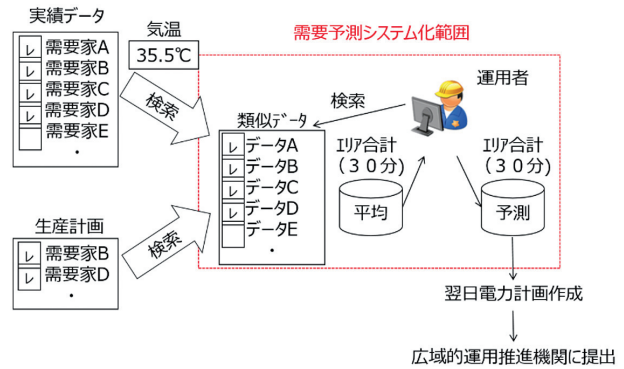


図1 翌日需給計画作成業務のイメージ。
Fig. 1 Work flow of supply and demand planning of next day.

1). 運用者熟練度の依存低減

当社と契約している需要家は、様々な業種で構成されており、それぞれの電力需要特性がある。需要予測する際に、運用者は各需要家の特性に対する経験則に基づいて予測している。特に、工場需要家の場合、曜日、気温や過去実績などの情報を加え、操業計画や生産計画などを基にして、総合的に電力需要量を判断する必要がある。そのため、運用者の熟練度による精度のバラつきが発生する。また、熟練度が高く、精密に予測できる運用者の減少も危惧されており、予測精度安定化の観点から需要予測のシステム化、自動化が望まれている。

2). 業務効率化

当社と契約している需要家数は数百件に上り、毎日の需要予測作業に数時間かかることもある。自動需要予測システムの導入は、業務の効率化、自動化に繋がる。

3). 予測精度の向上

AIや機械学習技術の進化により、大量の電力データと天気等の関連データを統合的に解析し、様々な学習方法によって高精度な電力需要予測を行う手法が提案、導入されている^{3), 4), 5)}。また、導入後のデータ蓄積により再学習することで、予測精度の向上も期待できる。それらの手法を活用した需要予測システムの導入は、長期ビジョンでの小売電気事業の安定運用や収益改善に繋がる。

そこで、当社はDSクラウド®に蓄積した長期間にわたる電力需要実績データや天気データなどを用い、機械学習手法による需要予測システムの開発を行った。

3 需要予測システムの仕組み

需要予測システムの全体構成を図2で示す。

①. 需要予測システムは、現地側の需給管理システムにある電力需要実績データや天気データを収集し、遠隔のDSクラウド®に送信してデータ蓄積を行う。②. DSクラウド®でデータ解析を行い、モデルを試作し、各モデルの予測精度の評価を行う。③. 評価結果に従い、最適な予測モデルを需要予測システムに導入、または更新する。④. 翌日需要予測を行う際に、運用者から需要予測システムへ指示を出すことで、予測プログラムが自動的に動作する。予測プログラムは、データ収集リンクにより最新の電力需要実績データや天気予報データを取得し、翌日における各需要家の電力需要を機械学習モデルベースで予測する。また、需要予測システムに可視化インターフェイスを実装しており、運用者は常に最新データやモデルを用いた予測結果の確認が可能になっている。

システム開発では、1). データ解析による高精度な需要予測モデルの構築と2). ユーザビリティが高い可視化インターフェイスの設計、開発が技術的なポイントであり、以下で詳述する。

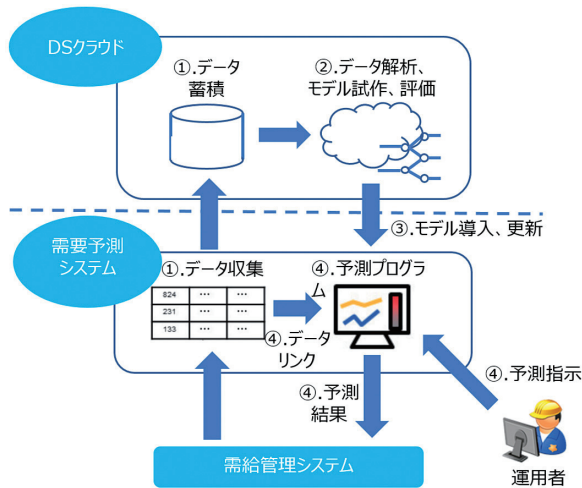


図2 需要予測システム全体構成。
Fig. 2 Overall structure of forecasting system.

3.1 需要予測モデルの構築

一般的な電力需要予測モデルは各需要家の特性を考慮せずに、纏めて合計電力を予測することが多いが、本開発システムにおいては、需要家の特性を重視して分類を実施し、その上で各分類に対して異なる

手法や特徴量でモデリングを行った。本稿では、全分類の中で最も電力需要割合が高いオフィスビル需要家と工場需要家に対して、詳細を述べる。

3.1.1 オフィスビル需要家

オフィスビルの電力需要量は、曜日の要素を除くと、空調による電力消費量の変動に大きく左右される。特に夏季のオフィスビルでは、電力需要量の約4～5割を空調の電力量が占めており⁶⁾、空調電力と相関が深い最高気温が電力需要量の変動に直接的に影響する。

図3は、2016年4月～2018年6月において、当社がAエリアで契約している約100件のオフィスビル需要家の平日における一日の電力需要量(実績値)と最高気温との相関を示している。電力需要量と最高気温の二次近似曲線回帰分析に従い、決定係数R²が高い水準(0.79)であるため、予測モデルの特徴量を最高気温の2乗値中心に検討した。ここでは、Aエリアのオフィスビル需要家に対し、以下のよう

モデル1：類似検索手法

類似検索手法(Similar Search, ES)は、予測対象日の最高気温と類似した過去日の電力実績検索値から予測する手法である。具体的には、過去60日の実績の中、対象日の最高気温がもっとも類似した3日を検索して抽出し、3日の実績平均値を予測値として出力する。(平日と休日はそれぞれで検索する)

モデル2：線形重回帰

線形重回帰(Linear Multiple Regression, LMR)は、目的変数に対して、線形方程式で複数の説明変

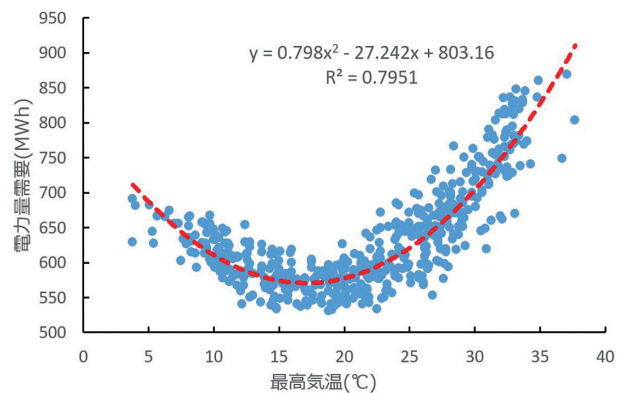


図3 Aエリアにおけるオフィスビルグループの電力需要量(実績値)と最高気温との相関関係。
Fig. 3 Correlation between the daily electricity demand and highest temperature of office group A.

数から予測する統計手法であり、従来から電力需要予測においての代表的な方法である。主要な説明変数は最高気温、最高気温2乗値、曜日や時刻である。

モデル3：ランダムフォレスト

ランダムフォレスト(Random Forest, RF)は、機械学習のアルゴリズムの一つであり、決定木による複数の弱学習器を統合させて汎化能力を向上させる学習アルゴリズムである⁷⁾。

モデル4：再帰型ニューラルネットワーク

再帰型ニューラルネットワーク(Recurrent Neural Network, RNN)は、ニューラルネットワーク(NN)の一種であり、近年では、時系列データ解析に最も使われている手法の一つである。図4に示すように、RNNは通常のNNと違い、中間層において過去の保存された情報をループさせる再帰的構造になっている。このような形となるRNNモデルは“記憶力”を持つことになり、傾向変化を反映しやすいため、時系列に対して高い精度で予測することができる。最近では、RNNによる電力需要予測の研究が増加する傾向にある^{8), 9)}。

モデル5：アンサンブル学習

アンサンブル学習(Ensemble Learning, EL)は、複数の解析手法の予測結果を統合して汎化能力や精度を高める手法である。ここでは、モデル3のRFとモデル4のRNNの結合によるアンサンブル学習を行い、その結果を評価する。

モデルの評価は、毎朝9時に翌日の電力需要を予測する条件で行い、2016年4月から2018年5月までのデータを各モデルで学習した後、2018年6月に対して予測し、誤差を評価した。誤差は以下のように平均絶対パーセント誤差(MAPE)で算出した。

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|$$




図4 NNとRNN構造的な違い。
Fig. 4 Difference of architecture between NN and RNN.

ここで、 n はデータ数、 A_t は時刻 t における実績値、 F_t は時刻 t における予測値を表す。

表1に各モデルの評価結果を示す。ESを除き、いずれのモデルでもMAPEは4%以下であった。また、EL(RFとRNNのアンサンブル学習)の誤差は2.33%と最も小さく、予測精度が一番高いことが判った。

表1 各モデルによる予測誤差の比較。
Table 1 Comparison of MAPE by various forecasting models.

No.	予測手法	MAPE(%)
モデル1	類似検索手法(ES)	4.61
モデル2	線形重回帰(LMR)	3.77
モデル3	ランダムフォレスト(RF)	3.36
モデル4	再帰型ニューラルネットワーク(RNN)	2.72
モデル5	アンサンブル学習(EL)	2.33

図5に、各モデルによる時刻ごとの誤差の比較を示す。各手法予測結果の特徴や評価は以下になる。

- 1). ESは、最もシンプルであり、今まで運用者による予測思想と似ているため、根拠が想定しやすい手法である。しかし、評価期間の6月においては、気温の上昇とともに、電力需要量が増加傾向であり、過去実績の検索だけでは増加傾向を反映できないため、特に昼間(6時~22時)の時間帯において、他の手法と比較して誤差が大きかった。一方で、夜間(22時~6時)の時間帯において、空調使用率の低下により電力使用量の変動が少ないため、ESは、ELを除き、誤差が最も小さい手法であることを確認できた。
- 2). LMRは、気温など説明変数の変動を予測結果に反映でき、昼間での誤差がESより改善されたが、夜間誤差が大きい結果であった。
- 3). RFとRNNは、LMRより全体的に誤差が小さく、良好な予測結果を得られた。特に、RNNは、夜間においてRFよりやや大きい誤差であったが、昼間での誤差がELを除き、もっとも小さく、電力需要量の増加傾向を学習できたと考える。
- 4). ELは、RFとRNNのアンサンブル学習であるため、各手法の誤差を打ち消しあうことができ、結果として最も小さい誤差を得られた。アンサンブル学習で全体の予測誤差の抑制効果を検証できた。

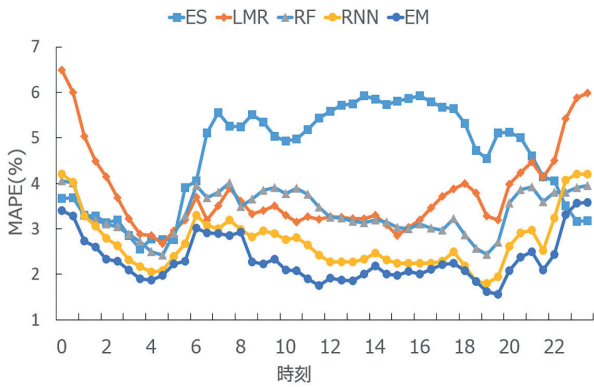


図5 各モデルによる時刻ごとの誤差の比較。
Fig. 5 Comparison of hourly MAPE by various forecasting models.

以上1)~4)の評価のように、アンサンブル学習手法は、他の手法と比較してモデル構築が複雑になるが、モデルの予測能力を大幅に向上させることができることと導かれた。本稿の検証では、このようなアンサンブル学習で構築したモデルを導入することで、オフィスビル需要家の需要予測精度向上に繋がることが確認できた。

3.1.2 工場需要家

オフィスビル需要とは違い、工場の電力需要変動は、それぞれの設備構成や生産計画で異なるため、本システムでは、需要家ごとにモデルを構築した。

図6に、工場需要家に対する需要予測の全体スキームを示す。オフィスビル需要で示したような天候、曜日、休日情報などの変動要因以上に、生産計画が電力需要量に直接影響することから、生産計画

を予測モデルの入力変数として活用するためのエンコーディング手法で前処理を実施した。高精度な予測モデルを構築するためには、適切なエンコーディング手法の導入が必要であり、図7を用いて、本システムで使用する3つのエンコーディング手法について説明して比較する。

① ラベルエンコーディング

ラベルエンコーディング(label encoding, LE)は、最も幅広く使われる手法であり、与えられたカテゴリ変数に数字を割り当てる手法である。

図7.(a)で、生産パターンがA, B, Cあった場合、LEを通して、 $A \Rightarrow 0$, $B \Rightarrow 1$, $C \Rightarrow 2$ のように連続に数字変換を行う。

LEは最もシンプルな手法である。ただし、回帰予測をする際に、変換数字の大きさに実質的な情報量がないため、予測精度に影響する場合がある。

② One-hot エンコーディング

One-hot エンコーディング(One-hot encoding, OE)は、カテゴリ変数の次元に対して新しい列を追加し、各行に含まれているカテゴリ変数に対応する次元を1に、それ以外を0にする手法である。

図7.(b)のように、生産パターンの次元に対応した「生産パターンA」、「生産パターンB」、「生産パターンC」の新しい列が追加される。例えば、1行目のように、生産パターンがAのデータに対して、「生産パターンA」列の数値が1になり、「生産パターンB」、「生産パターンC」列の数値が0になる。

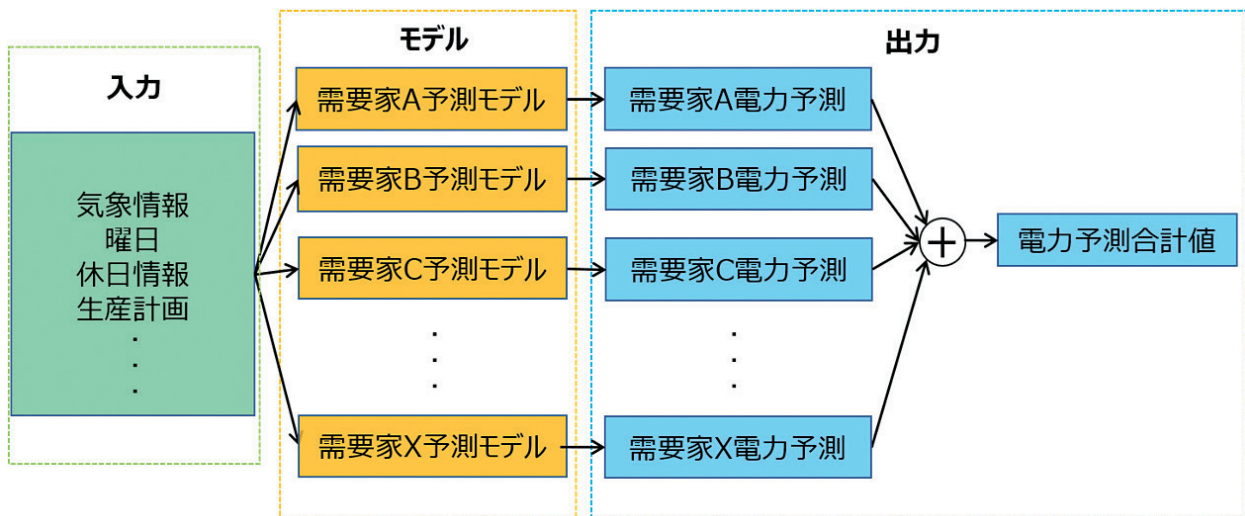


図6 工場需要家に対する需要予測の全体スキーム。
Fig. 6 Overall scheme of demand forecasting for factory users.

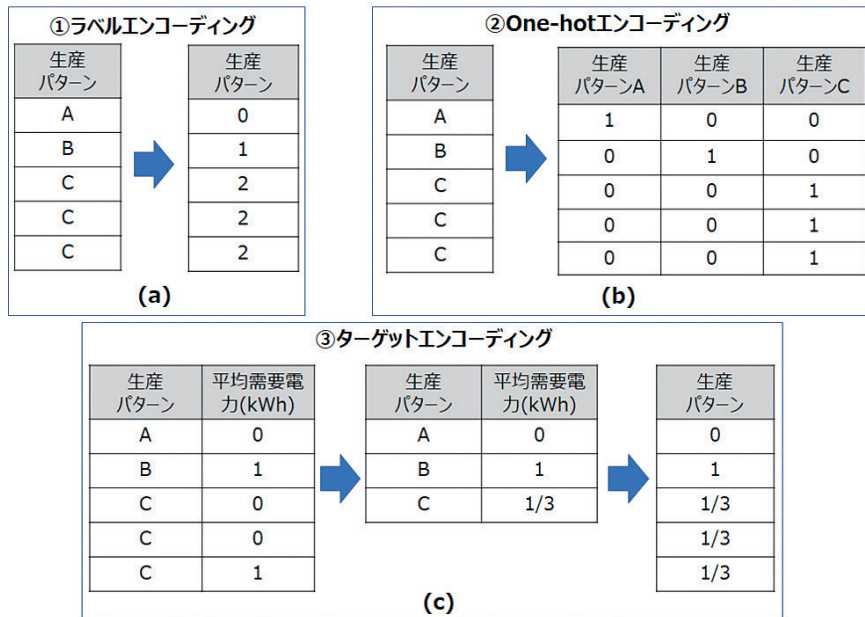


図7 生産計画におけるカテゴリ変数のエンコーディング手法。
Fig. 7 Encoding techniques of category data for production planning.

OEは、カテゴリ変数を単に連続する数ではなく、独立する値として扱うことができるため、回帰予測にとって適切な変換手法である。ただし、モデルの説明変数が増えることにより、計算量の増加やモデル自由度の低減に問題がある。

③ ターゲットエンコーディング

ターゲットエンコーディング(Target encoding, TE)は目的変数に対してカテゴリ変数を平均処理して数字変換を行う手法である。

図7.(c)のように、生産パターン A, B, C に対して、平均需要電力は A⇒0 kWh, B⇒1 kWh, C⇒1/3 kWh で算出する。そして、各データにおいて、生産パターンに対応した平均需要電力を置き換えるような数字変換を行う。

TEは、変換数字に目的変数の情報量を与えた上、モデルの説明変数の数も抑えることができるため、モデルの自由度向上に有益な手法である。

以上①～③の各手法の検証結果の代表例として、1日の需要電力が約200MWh、三交代体制で稼働している工場Bの予測結果を表2に示す。学習期間は2016年4月～2018年5月で、検証期間は2018年6月で、結果は以下の通りである。

- 1). 全体的に、OEとTEはLEより、誤差が小さい結果を得られた。
- 2). 稼働パターンが変動しやすい昼間においては、

OEとTEによる精度改善が明らかになった。
3). TEにより入力変数の数を抑えることができた。

上記以上1)～3)のように、当社の電力需要予測システムは、工場需要家に対して、生産計画データの特徴に適したエンコーディング手法で前処理を実施した上、機械学習を併用することで、需要予測性能を高めることができた。

表2 各モデルによる予測誤差の比較。
Table 2 Comparison of MAPE by various encoding techniques.

	MAPE(%)		
	①ラベルエンコーディング(LE)	②One-hotエンコーディング(OE)	③ターゲットエンコーディング(TE)
0時～8時	15.3	15.0	14.6
8時～16時	16.0	13.3	12.9
16時～24時	16.3	15.3	15.0
全体	15.9	14.5	14.2

3.2 可視化インターフェイス

予測結果を確認できる可視化インターフェイスは、需要予測システム上のWebサーバで構築しており、ユーザが場所を問わずにウェブブラウザからアクセスすることができる。また、複数関係者が同じ可視化画面に同時アクセスできるため、便利な情報共有ツールとしても活用している。

予測監視負荷低減を実現するために、ユーザビリ




図8 予測誤差ヒートマップ図。
Fig. 8 Heat map of prediction errors.

ティが高い可視化画面の設計，導入を行っている。図8はその一例の誤差ヒートマップ図である。各需要家に対しての予測誤差をタイムリーに把握できるように，縦軸が需要家単位で，横軸が格子毎に需要家の日単位の平均誤差を表示している。誤差は10%以上になった場合，格子色が緑から赤に変化し，ユーザが直観的に各需要家の予測状況を把握できる。

また，可視化インターフェイスは予測精度の監視だけでなく，予測モデルのメンテナンスにも活用している。機械学習モデルは，導入された直後がもっとも高精度であるが，後に入力されるデータに学習データと特徴上の差異が生じた場合，モデルの予測精度が劣化してしまうことになる。精度を維持するには，モデルのメンテナンス，いわゆる再学習が必要になる。この再学習タイミングの適正化を計るために，図9のモデル異常度評価画面を導入している。各需要家に対して，一定期間における実績と予測の相関や誤差率から異常度を算出し，一定の閾値を超えた場合，再学習を実施する。このような可視化画面を導入することにより，再学習の効率化を実現できた。

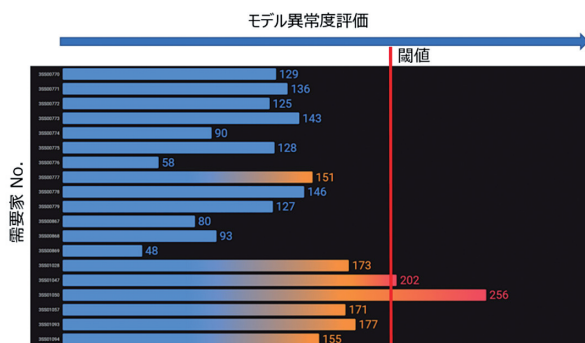


図9 モデル異常度評価画面。
Fig. 9 Dashboard of model abnormality evaluation.

4 社内検証の状況

2018年9月～2019年5月において，上記アンサンブル学習の手法を採用したモデルや可視化インターフェイスの開発を行い，2019年6月から当社グループにおける電力需給管理センターにシステムを導入し，実証運用を開始した。予測精度については，実用的なレベル(熟練者の手動予測精度と同等か，それ以上)に達成していることが確認できた。また，システム導入により，需給計画作業時間の短縮や熟練依存度の低減にも繋がった。今後，実証運用を通してDSクラウド®に運用データを蓄積し，モデルの再学習などでさらに改良を加え，より高精度のシステムで小売電気事業の安定性向上に貢献する。

5 結言

本稿では，当社のデータ解析プラットフォーム-DSクラウド®を活用し，電力の需要予測作業に対しての自動化システムを開発して社内実証を行った。異なる業種の需要家(オフィスビルや工場)に対して，機械学習手法のアンサンブル学習やエンコーディングを用いたデータの前処理手法を導入することにより，高い予測精度を実現できた。また，ユーザビリティが高い可視化画面を設計，導入することにより，予測誤差の監視やメンテナンスが容易になった。2019年6月以来の社内検証結果から，予測精度が実用的なレベルに達成し，運用者の負荷や熟練依存度の低減を実現できた。

電力システム改革が進んでいる中，需要予測のニーズ自体も多様化する傾向がある³⁾。例えば，ある工場に全電力需要をカバーできる自家発電設備を新設する場合，余剰電力は大電力会社の電力網に送り出すことになり，対象工場の電力需要予測が必要となる。このような電力需要予測の社内外ニーズに対して，最新のデータ解析や機械学習手法を用いて，本システムの適応範囲を拡大していく所存である。

参考文献

- 1) “当社の電力ビジネスについて”，新日鉄エンジニアリング技報，Vol. 7, 63-64, 2016年。

- 2) 阿部真晴, 陳立, 西山裕樹, 野中壮平, 富岡修一, 高田寛, “データ解析基盤「DSクラウド®」の構築と運用”, 新日鉄エンジニアリング技報, Vol. 10, 35-41, 2019年.
- 3) 進博正, 志賀慶明, 高田正彬, 柿元満, “機械学習を活用した電力需要予測”, エネルギーと動力, Vol. 68, 36-45, 2018年.
- 4) Tao Hong, Pierre Pinson, Shu Fan, Hamidreza Zareipour, Alberto Troccoli, Rob J.Hyndman, “Probabilistic energy forecasting: global energy forecasting competition 2014 and beyond”, International Journal of Forecasting, vol. 32(2016), 896-913.
- 5) 若杉一幸, 森田克明, 彌城祐亮, 池田龍司, 手島哲平, 榎本智之, “工場デマンドの高精度予測技術の開発”, 三菱重工技報, Vol. 55, No. 2, 1-4, 2018年.
- 6) 資源エネルギー庁: “夏期最大電力使用日の需要構造推計(東京電力管内)”, 2013年4月.
- 7) Leo Brieman, “Random forest”, Machine Learning, vol. 45(2001), 5-32.
- 8) Hyojoo Son, Changwan Kim, “A deep learning approach to forecasting monthly demand for residential-sector electricity”, Sustainability, vol. 12(2020), 1-16.
- 9) 亀井圭史, 大沢和暉, 石川眞澄, 高田寛, “電力需要予測のための気象データ活用”, 気象ビジネス推進コンソーシアム, 2019年12月.