

# データサイエンスを用いた都市ガス販売量の予測精度比較

## - アルゴリズム変更や部門別の予測による精度向上 -

計量分析ユニット エネルギー・経済分析グループ | 寄田 保夫

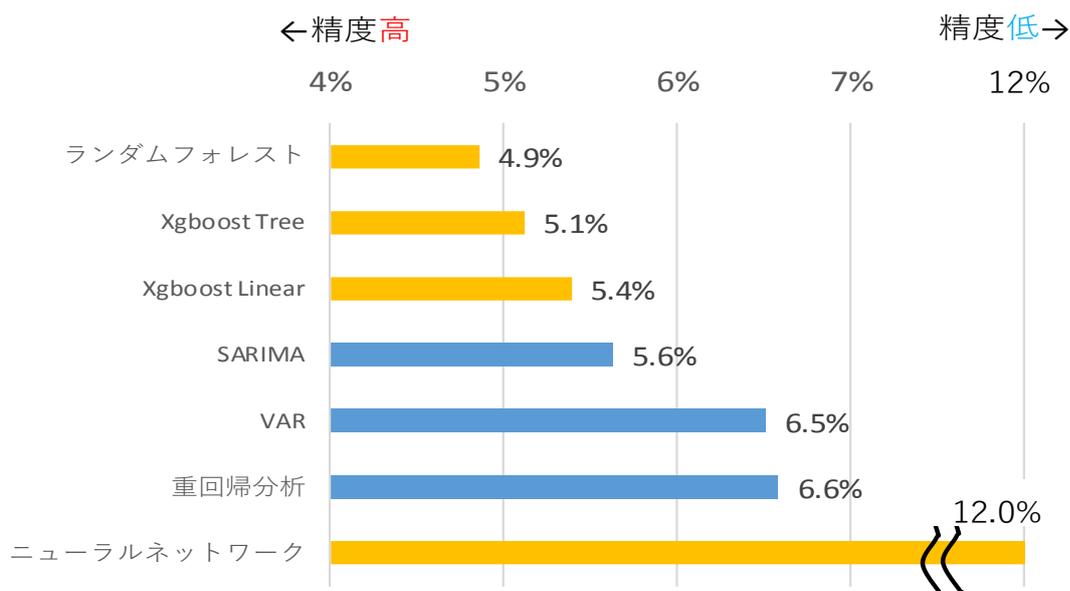
### 要旨

本稿では都市ガス販売量予測における高精度なアルゴリズムを検討するとともに、予測モデルの精度向上の検討を行う。1990年4月-2017年9月までの330か月間を学習期間、2017年10月-2018年9月までの12か月間を予測期間とし、全国での都市ガス販売量を予測する。

まず、第1ステップとして全体の販売量を予測し有効なアルゴリズムを検討した(要旨-図1)。ここでは、予測を導く構造の説明や解析に重きを置く統計学的手法と、データを活用した予測精度に重きを置く機械学習的手法の代表的なものを対象とした。具体的には、統計学的手法からは「重回帰分析」「ベクトル自己回帰モデル(VAR)」「季節調整済時系列モデル(SARIMA)」を、機械学習的手法からは「ランダムフォレスト」「Xgboost Tree」「Xgboost Linear」「ニューラルネットワーク」といった7つの代表的な手法を用いることとした(【参考】参照)。次に第2ステップとして部門別に予測を行うことで予測精度の向上を図った(要旨-図2)。なお、比較に用いる精度指標としては、平均絶対誤差率(各月誤差率における絶対値の平均をとったもの。以下、MAPE)を用いた。

全体の販売量の予測では、ニューラルネットワークを除き、全般に統計学的手法よりも、機械学習的手法のほうが予測精度が高くなった(要旨-図1)。特に、ランダムフォレストが最良となった。一方で、機械学習的手法のなかでもニューラルネットワークはデータ数が少なく、適切に予測できなかった。昨今、注目を集めるニューラルネットワークであるが、大量のデータを用いた分析に強く、今回のような330か月間の学習データ数では力を発揮することができなかった。

要旨-図1 | 都市ガスマ月別販売量のアルゴリズム別予測精度(MAPE)



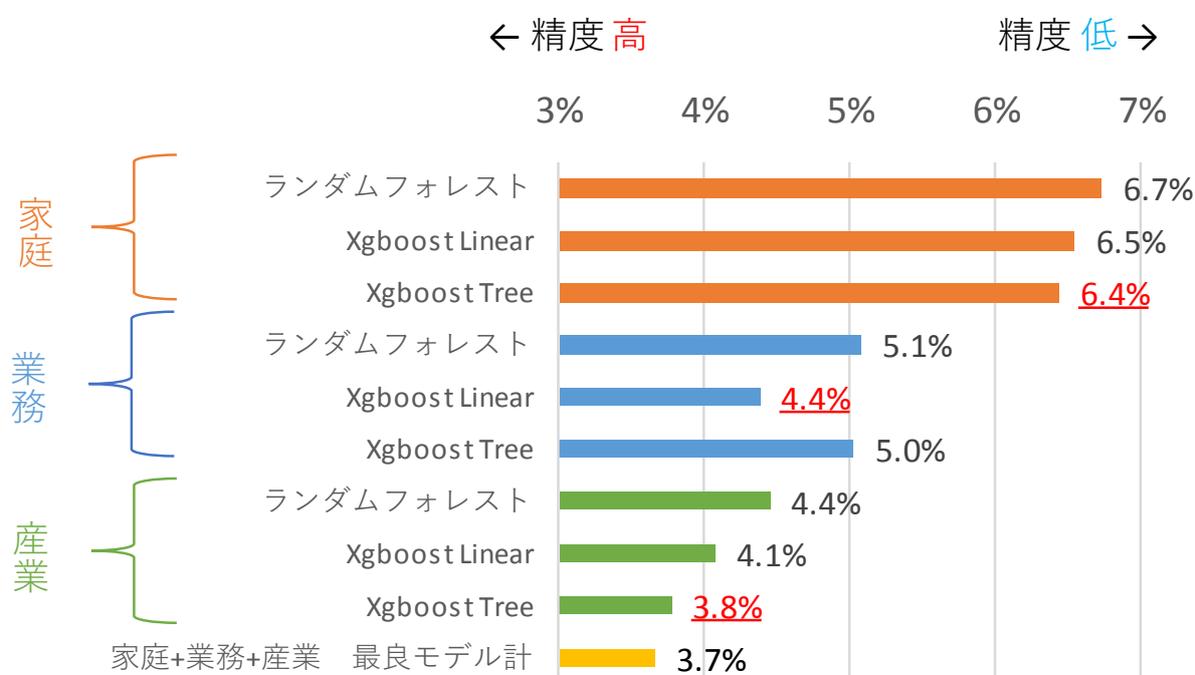
出所:筆者算出。

(注) 黄色グラフは機械学習的手法、青色グラフは統計学的手法。

部門別の販売量の予測では、全体の販売量の予測で精度の高かった3つのアルゴリズム(ランダムフォレスト、Xgboost Tree、Xgboost Linear)に絞り検討した結果、Xgboost LinearやXgboost Treeのほうがランダムフォレストよりも予測精度が高い場合が多数を占めた(要旨-図2)。最も予測精度の高いアルゴリズムは、家庭部門ではXgboost Tree、業務部門ではXgboost Linear、産業部門(発電用除く)ではXgboost Treeとなっている。このように、アルゴリズムは適用課題次第で結果の精度が変わるため、工学的に試す必要がある。

最終的な結果となる家庭+業務+産業のそれぞれの最良モデルを合計した場合のMAPEは3.7%まで改善した。部門別よりも合計したモデルのほうが精度が良いのは、誤差が正と負で打ち消しあうためである。なお、SARIMAモデルも部門別に積み上げる形で予測をしたが、こちらのMAPEは5.7%となり、全体販売量予測の5.6%から悪化した。部門別の積み上げでは、説明変数がより直接的に予測に寄与できることから、説明変数を用いたモデルのほうが適しているということだろう。

要旨-図2 | 都市ガス月別販売量の部門毎のアルゴリズム別予測精度(MAPE)



出所: 筆者算出。

(注) 産業は一般工業用のみ(発電用を除く)。「最良モデル計」は、家庭・業務・産業で最も精度の高かったモデル(赤字で表示)を合計したもの。

今回の予測精度比較では機械学習的手法が上回ったが、統計学的手法は構造の説明や解析に優れている。それぞれのアルゴリズムの長所と短所を把握し、状況に応じて統計学的手法と機械学習的手法を使い分けることが重要である。

## 本稿の目的と予測対象

原子力の再稼働や、再エネの普及などで長期的にはわが国のLNG輸入量は暫減していくと見られている。また、エネルギー各社においては電力・ガスの全面自由化で各社における需要の先行きが見えづらくなる中、精度の高い需要予測に基づいた、LNG契約のポートフォリオ構築や機動的なスポット調達などが重要性を増している。

予測の手法に目を移してみれば、ビジネス全般においても経験や勘による予測から、ニューラルネットワークなどのモデリング手法を用いた予測へと時代は移りつつある。その中で、電力の需要予測はしばしば見かけられるものの、(ピーク量を予測して備えるインセンティブが電力に比べて相対的に低いことから、)都市ガスの先行研究は少ない。しかし、先述の通り都市ガスについても適時適切なLNG調達に向けた需要予測は重要である。

また、予測などのモデリングの中で用いられるアルゴリズムは、予測を導く構造の説明や解析に重きを置く統計学的手法<sup>1</sup>とデータを活用した予測精度に重きを置く機械学習的手法<sup>2</sup>に大きく分類されると筆者は考える。しかし、数多ある手法の中でこういった場合にどのような手法を用いると精度が高まるのかは実際に算出してみなければわからない。

そこで、本稿では都市ガス販売量予測における高精度なアルゴリズムを検討するとともに、予測モデルの精度向上の検討を通じて、効率的なLNG調達への一助としたい。

1990年4月-2017年9月までの330か月間を学習期間、2017年10月-2018年9月までの12か月間を予測期間とし、全国での都市ガス販売量を予測する(図1)。

まず、第1ステップとして全体の販売量を予測し有効なアルゴリズムを検討した後に、第2ステップとしてそのアルゴリズムを用いて部門別に予測を行うことで予測精度の向上を図っていく。

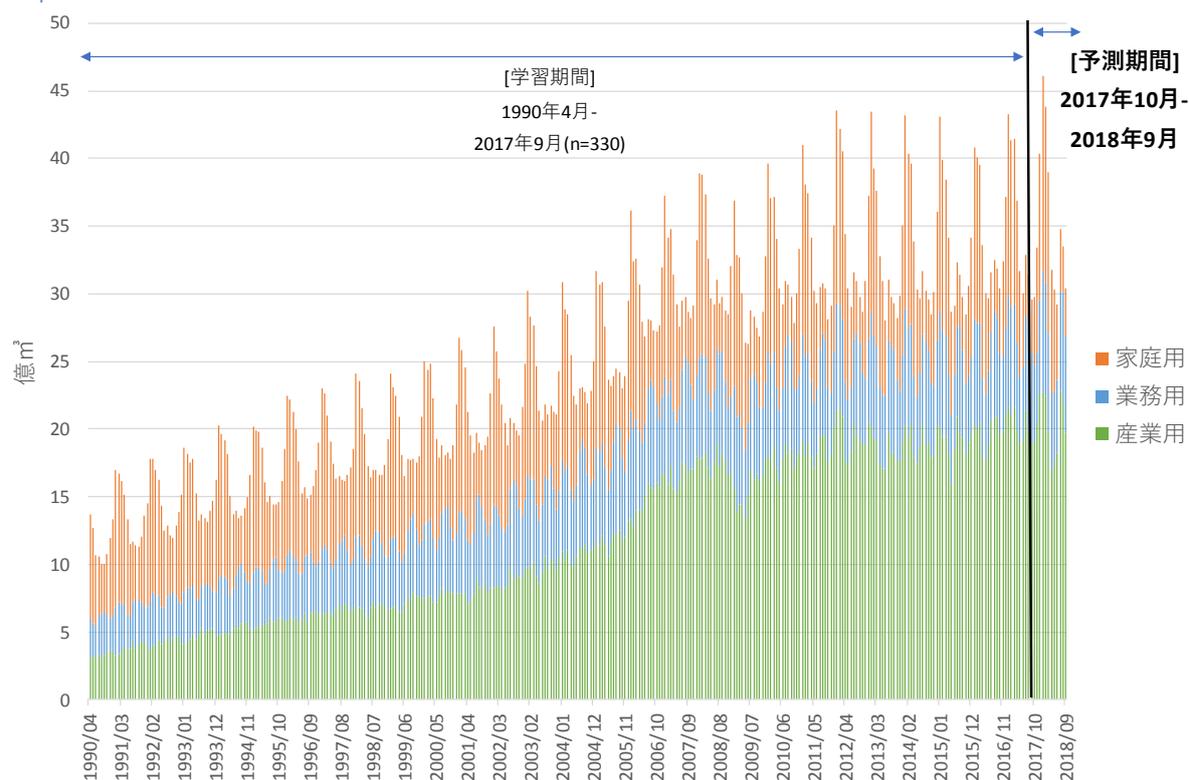
なお、当該予測期間は、2017年12月-2018年2月が記録的な厳冬であったことにより、販売量は2017年12月・2018年1月には2か月連続で当該月における過去最高を記録し、2018年2月も当該月で過去2番目に高いガス販売量となった。結果、2017年10月-2018年9月は、同期間累計で過去最高の販売量となっている。一方で、2018年4月は当該月において東日本大震災以降で最も販売量が少なくなるなど、販売量のボラティリティが大きく、当該予測期間は予測の難易度が高いことが推察される。

---

<sup>1</sup> 一般に統計学は、確率分布による仮定を置く。確率分布による仮定を置くことでデータからの示唆は得やすいが、予測の際の制約(確率分布の仮定を満たすこと、多重共線性、自己相関など)が多いとされる。

<sup>2</sup> 一般に機械学習は、確率分布による仮定を置かない。確率分布による仮定を置かないことで、予測の際の制約は少ないものの、データからの示唆は得にくいとされる。

図1 | 予測対象データ(全国の都市ガス月別販売量)



出所: 経済産業省「ガス事業生産動態統計」

## 検討・比較するアルゴリズム

本稿で取り上げるアルゴリズムは、統計学的手法からは「重回帰分析」「ベクトル自己回帰モデル (VAR)」「季節調整済時系列モデル (SARIMA)」を、機械学習的手法からは「ランダムフォレスト」「Xgboost Tree」「Xgboost Linear」「ニューラルネット」といった7つの代表的な手法を用いることとした(表1)。本稿では区別のために統計学的手法、機械学習的手法と仕分けしているが、各アルゴリズムには明確な線引きはなく、一般的に言われる区別を踏まえ、筆者なりに選別している。また、機械学習的手法は点推定(1点のみの推定)しかできないのに対して、統計学的手法は点推定に加えて区間推定(任意の確率での予測範囲の推定)ができるといった特徴がある。

なお、機械学習手法は一般的にブラックボックス化しやすいと言われるが、(統計学的手法ほどではないものの)ランダムフォレストやXgboostのように予測手法によってはモデルの構造を示唆することができる。一方で、ニューラルネットワークはこういった示唆を得にくい。本稿では予測精度の高さを追求しているが、状況に応じて予測手法を使い分ける必要があるだろう。

表1 | 検討するアルゴリズム

	アルゴリズム名	概要
統計学	重回帰分析	残差(誤差の推定量)が正規分布に従うという仮定を置いた線形モデル。回帰係数から、説明変数ごとの被説明変数への影響度を示すことができる。また、決定係数から、説明変数が被説明変数をどれほど説明できているかを示すことができる。
	ベクトル自己回帰モデル (VAR)	自己回帰モデル <sup>3</sup> を多変量に拡張したもの。予測に説明変数の将来値を必要としない(被説明変数と同期間の説明変数で予測する)。ある時系列データに変動があった場合に、以後その他の時系列データにどの程度影響するかを示すことができる。
	季節調整済時系列モデル (SARIMA)	自己回帰和分移動平均モデル <sup>4</sup> に季節変動を取り入れたモデル。予測に説明変数を必要としない。
機械学習	ランダムフォレスト	データの一部を抽出し決定木 <sup>5</sup> という機械学習手法で多様な弱学習器を作り、それぞれの弱学習器のアウトプットの多数決をとる手法 <sup>6</sup> 。説明変数の重要度(説明変数の予測への寄与度)などを示すことができる。
	Xgboost Tree	データの一部を抽出し弱学習器を作り、繰り返し学習させ、それを最終的な学習器に追加する手法 <sup>7</sup> 。弱学習器は決定木。決定木と同様、樹状の示唆(下記イメージ図)を示すことができる。
	Xgboost Linear	Xgboost Treeの弱学習器が線型モデルのもの。
	ニューラルネットワーク	入力層・中間層・出力層から成り、入力データに対する適切な重みと勾配を調整する手法。

(注) 統計学、機械学習の明確な区別はなく、筆者による選別。VAR、SARIMA以外は将来値を含む説明変数が必要。

<sup>3</sup> ARモデル。直前、あるいは任意の以前の期までの自己の観測値が影響を与えるモデル。

<sup>4</sup> ARIMAモデル。ARモデルと移動平均(MA)モデルを統合した自己回帰移動平均(ARMA)モデルに、差分系列を加えたものの。

<sup>5</sup> 木構造を用いて分類や回帰を行う機械学習の手法の一つ。木の深さにより予測精度が影響を受ける。一般に、木が深いほど予測精度が上がるが、深すぎると過学習となり学習データ以外のデータに対する予測精度が落ちる。

<sup>6</sup> アンサンブル学習のバギングと言われる手法。

<sup>7</sup> アンサンブル学習のブースティングと言われる手法。

## 第1ステップ:全体の都市ガス販売量の予測

まず、各アルゴリズムにおける説明変数の予測期間における値を推計した(表2)。説明変数の選択にあたっては、都市ガス販売量の全体を表現できるものとなるよう、留意した。予測精度は、暖房度日は記録的な厳冬により、2017年12月-2018年2月では9-13%過小に予測している。冷房度日は、2018年7月-8月では11-13%過小に予測している。他の説明変数は平均絶対誤差率(各月誤差率における絶対値の平均をとったもの。以下、MAPE)において、エコジョーズ出荷台数(累計)は0.6%、業務部門延床面積は0.1%、メーター数(累計)は0.004%、鉱工業生産指数(IIP)は2.3%、第3次産業活動指数は0.9%となった。

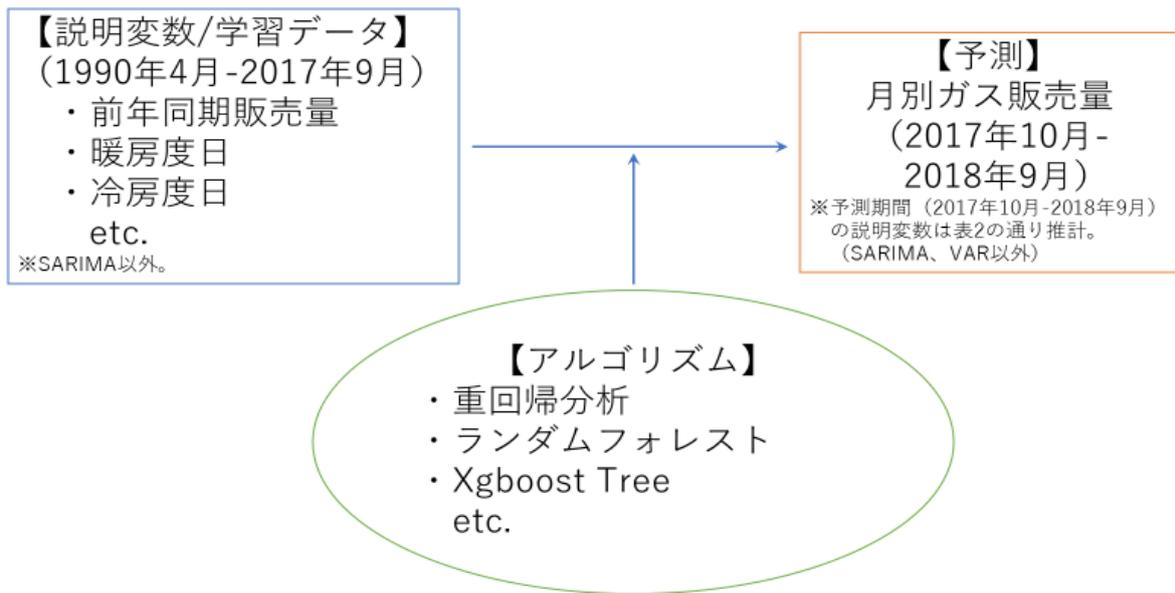
表2 | 都市ガス販売量(全体)予測における説明変数と推計方法

	前年同期販売量、スライド影響(LNG CIF価格3か月平均)	暖房度日、冷房度日	エコジョーズ出荷台数(累計)、業務部門延床面積、メーター数(累計)	鉱工業生産指数(IIP)	第3次産業活動指数	タイムトレンド、月ダミー
重回帰分析、ランダムフォレスト、Xgboost Tree、Xgboost Linear、ニューラルネット	実績	気象庁の3か月予報から推計	過去実績傾向から線形近似で推計	製造工業生産予測指数と2か月前IIPから推計	VARモデルより推計	入力
VAR	実績(将来値は不要)	同左	同左	同左	同左	同左
SARIMA	不要	同左	同左	同左	同左	同左

出所: 経済産業省「ガス事業生産動態統計」「鉱工業生産指数」「第3次産業活動指数」、日本ガス協会HP等より収集。

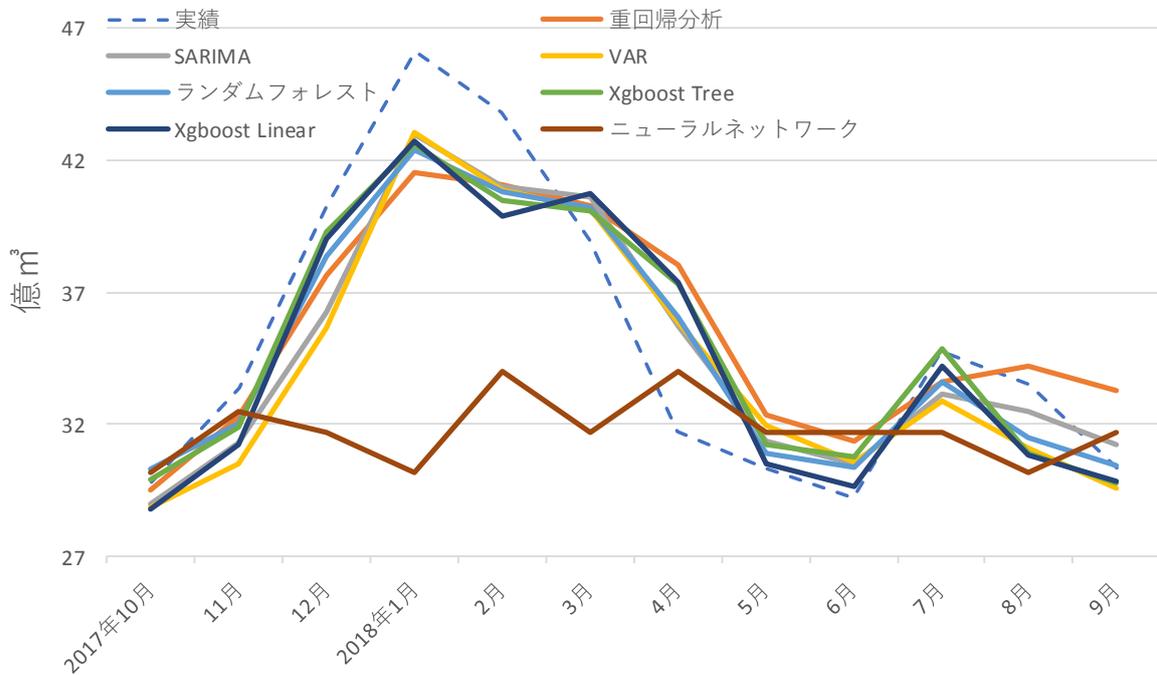
表2の説明変数と先述の7つのアルゴリズムを用いて、1990年4月-2017年9月までの330か月間を学習データとして用い、2017年10月-2018年9月までの12か月間の都市ガス販売量を予測するイメージを示した(図2)。

図2 | 全体販売量の予測イメージ図



各アルゴリズムによる2017年10月-2018年9月までの12か月間の都市ガス販売量の予測結果を図3に示す。結果は、概ね2017年12月-2018年2月と2018年4月に誤差が拡大した。外れが大きかったニューラルネットワークを除いて平均すると、2017年12月-2018年2月は7%程度過小に予測し、2018年4月は16%程度過大に予測した。また、ニューラルネットワークを除き、実績に追随を示しているが、各アルゴリズムごとに予測精度が異なっている。

図3 | 都市ガス販売量(全体)の予測と実績



出所: 筆者算出。

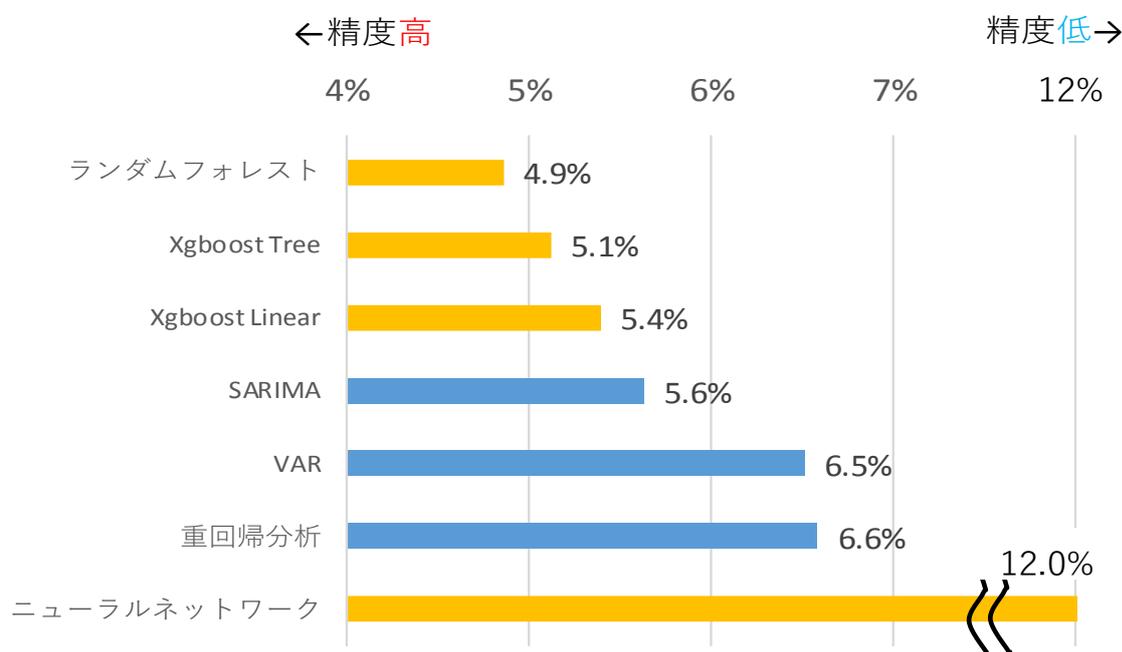
次にその予測精度を比較するため、図3のアルゴリズム別のMAPEを表示した(図4)。なお、他の精度評価指標である平均二乗誤差(誤差の二乗の平均に対し、平方根をとったもの。以下、RMSE)や平均絶対誤差(誤差の絶対値の平均。以下、MAE)も類似した精度の傾向となっている。結果は、ニューラルネットワークを除き、全般に機械学習的手法のほうが、統計学的手法よりも予測精度が高くなった。特に、ランダムフォレストが最良となった。

一方で、機械学習的手法のなかでもニューラルネットワークは、適切に予測できなかった。昨今、注目を集めるニューラルネットワークであるが、大量のデータを用いた分析に強く、今回のような330か月間の学習データ数ではデータ数が少なく力を発揮することができなかった。過学習が起きていることも考えられるだろう。

ニューラルネットワークを除き、各アルゴリズムの精度の違いはゼロコンマ数%-2%弱の違いであるが、LNG調達は金額規模が大きく、各ガス事業者の売上に対する比率が高い重要事項であることを考えると、わずかな予測の違いが重要となる可能性があるだろう。

なお、ランダムフォレスト、Xgboost、ニューラルネットワークといった機械学習手法は、学習する木の深さなどのハイパーパラメータ<sup>8</sup>の調整や、クロスバリデーション法<sup>9</sup>などによる精度向上のためのアルゴリズムのチューニングを実施している。また、重回帰分析はステップワイズ法<sup>10</sup>を用いて説明変数を選択した結果、説明変数の被説明変数への説明力を表す決定係数は0.9982と非常に高いが、予測では図4に示す誤差が生まれている。

図4 | 都市ガス月別販売量のアルゴリズム別予測精度(MAPE)



出所:筆者算出。

(注) 黄色グラフは機械学習的手法、青色グラフは統計学的手法。

<sup>8</sup> 機械学習アルゴリズムの挙動を制御するパラメータのこと。

<sup>9</sup> 標本データを分割し、その一部をまず解析して、残る部分でその解析のテストを行い、解析自身の妥当性の検証・確認に当てる手法。

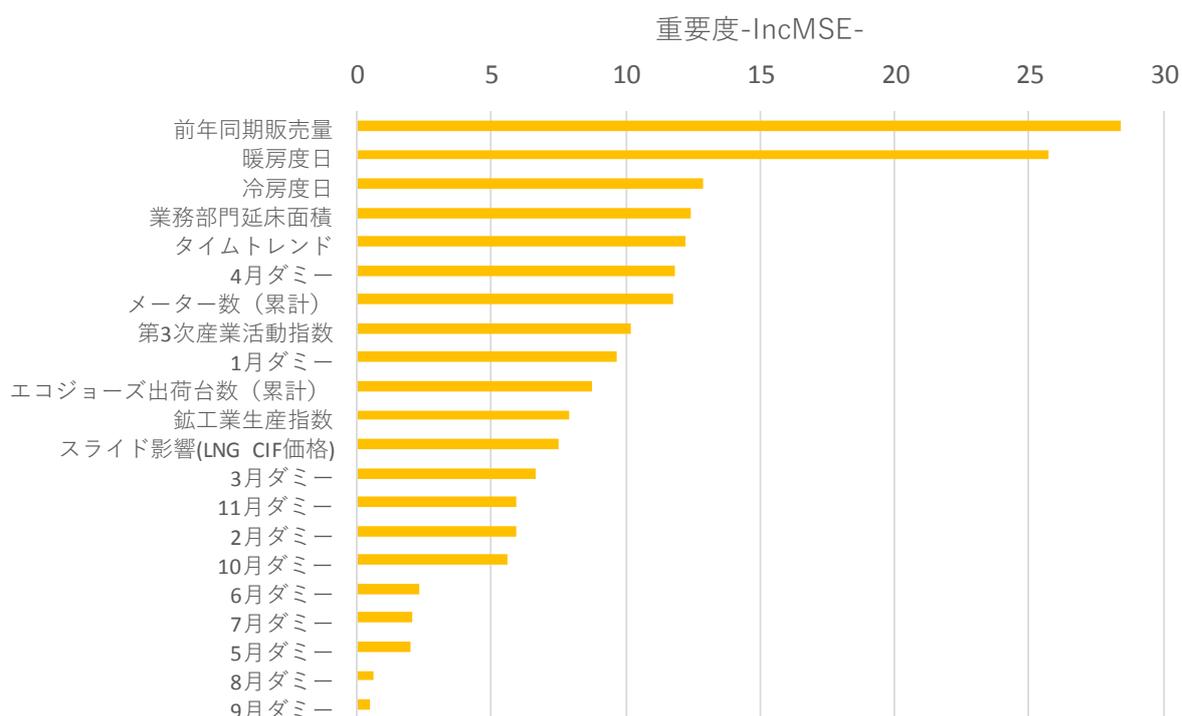
<sup>10</sup> 有意な説明変数を1つずつ取り込んだり取り除いたりしながら、有意な回帰モデルを作成する方法。

ここで、最も予測精度の高かったランダムフォレストモデルにおいて、説明変数の重要度(説明変数の予測への寄与度)を通して、予測の誤差が発生した原因を考察する(図5)。

最も寄与度が高いのは、「前年同期販売量」である。都市ガス販売量は季節性が強いいため、1年前の当該月の値が予測に強く寄与している。2番目に寄与度が高いのは、「暖房度日」である。都市ガス販売量の月毎の変動は、暖房や給湯需要によるところが大きいと考えられるため、自然な結果であろう。これら2つの寄与度が特に高い。なお、「暖房度日」の影響度は「冷房度日」の2倍程度あり、冬季における度日予測の重要性が示唆されている。

ここから、予測の誤差が生まれた主な原因は、まず2017年12月-2018年2月の暖房度日が記録的な厳冬により平均10%程度の過小予測となり、それに伴い販売量の予測も平均で7%程度の過小予測となったことが考えられる。また、厳冬を受けて都市ガス販売量は2017年12月、2018年1月に2か月連続で過去最高を記録し、2018年2月も過去2番目に高いガス販売量となったこと、一方で、2018年4月は当該月において東日本大震災以降で最も販売量が少なくなるなど、販売量のボラティリティが大きくなり、「前年同期販売量」では十分に説明しきれなかったことが考えられる。

図5 | ランダムフォレストモデルにおける説明変数(特徴量)の予測への寄与度



出所:筆者算出。

(注)各月ダミーは、各月ごとの影響度を示したもの。

## 第2ステップ:部門別の都市ガス販売量の予測

次に、より精度を高めるため、部門別に予測モデルを構築する。家庭・業務・産業といった部門別に販売量を予測することで、説明変数の予測に対するより直接的な寄与が期待できるためである。なお、産業用のうち発電用(産業用の2割程度に相当)は、対象となる会社数が限定的であり、また説明変数の収集が難しいことが想定されるため、以降の検討からは除外し、一般工業用のみを対象とした。

また、全体の販売量の予測で精度の高かった3つのアルゴリズム(ランダムフォレスト、Xgboost Tree、Xgboost Linear)に絞り、部門別に寄与度が高いと考えられる説明変数を検討、推計した(表3)。推計した説明変数の予測精度は、MAPEにおいて、家庭部門の世帯構成人数は0.1%、家庭用メーター数(累計)は0.004%、業務部門の業務用メーター数(累計)は0.003%、産業部門の産業用メーター数(累計)は0.04%となった。なお、実質ガス価格(企業物価指数ベース)、各産業(粗鋼、エチレン、セメント、紙/板紙、自動車)の生産量は実績値を用いた。また、表2と共通の説明変数は同じ値を用いた。

表3 | 都市ガス販売量(部門別)予測における説明変数と推計方法

### 【家庭部門】

前年同期販売量、 スライド影響(LNG CIF価格 3か月平均)	暖房度日、冷房度日	エコジョーズ出荷台数(累計)、 世帯構成人数、 家庭用メーター数(累計)	タイムトレンド、 月ダミー
実績	気象庁3か月予報から推計	過去実績傾向から線形近似で推計	入力

### 【業務部門】

前年同期販売量、 スライド影響(LNG CIF 価格 3か月平均)	暖房度日、 冷房度日	業務部門延床 面積、業務用メ ーター数(累計)	第3次 産業活 動指数	実質ガス価格 (企業物価指 数ベース)	タイムトレンド、 月ダミー
実績	気象庁の3 か月予報 から推計	過去実績傾向 から線形近似で 推計	VARモ デルより 推計	実績(将来値 として参照)	入力

### 【産業部門(発電用除く)】

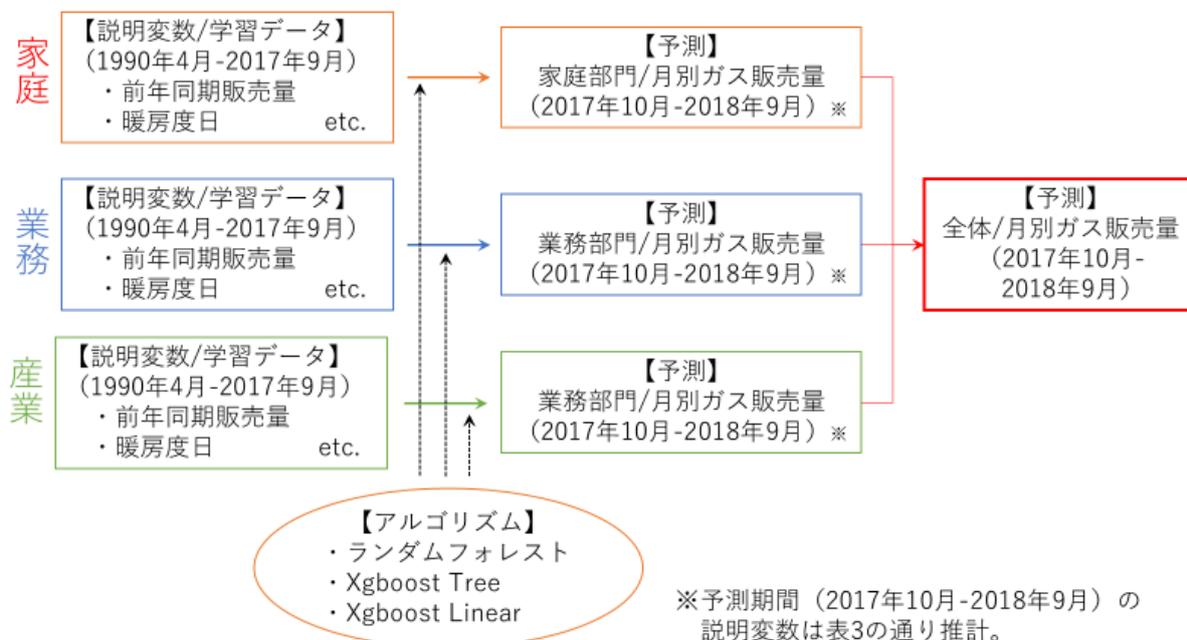
前年同期販売 量、スライド影 響(LNG CIF価 格 3か月平均)	暖房度日、 冷房度日	産業用メ ーター数(累 計)	鉱工業生産指数 (IIP)	実質ガス価格(企 業物価指数ベース)、 各産業(※)の生 産量	タイム トレンド、月 ダミー
実績	気象庁の3 か月予報 から推計	過去実績傾 向から線形 近似で推計	製造工業生産予 測指数と2か月前 IIPから推計	実績(将来値とし て参照)	入力

※対象は、粗鋼、エチレン、セメント、紙/板紙、自動車。

出所: 経済産業省「ガス事業生産動態統計」「鉱工業生産指数」「第3次産業活動指数」、日本ガス協会HP等より収集。

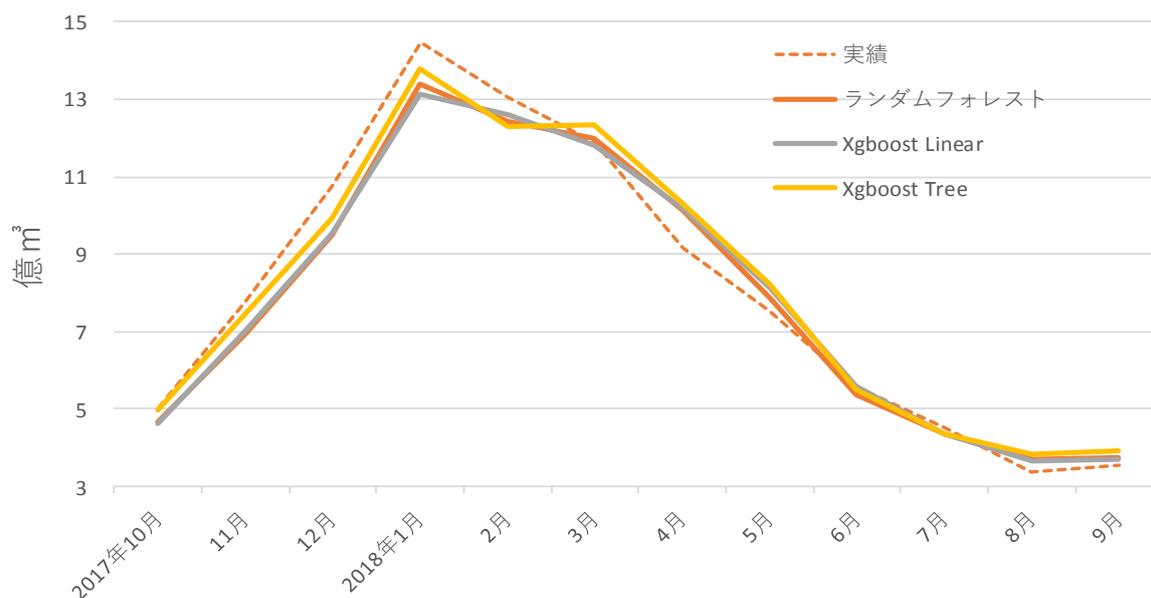
表3の説明変数と全体の販売量の予測で精度の高かった3つのアルゴリズムにおいて、1990年4月-2017年9月までの330か月間を学習データとして用い、2017年10月-2018年9月までの12か月間の都市ガス販売量を部門別に予測するイメージを示した(図6)。

図6 | 部門別販売量による予測イメージ図



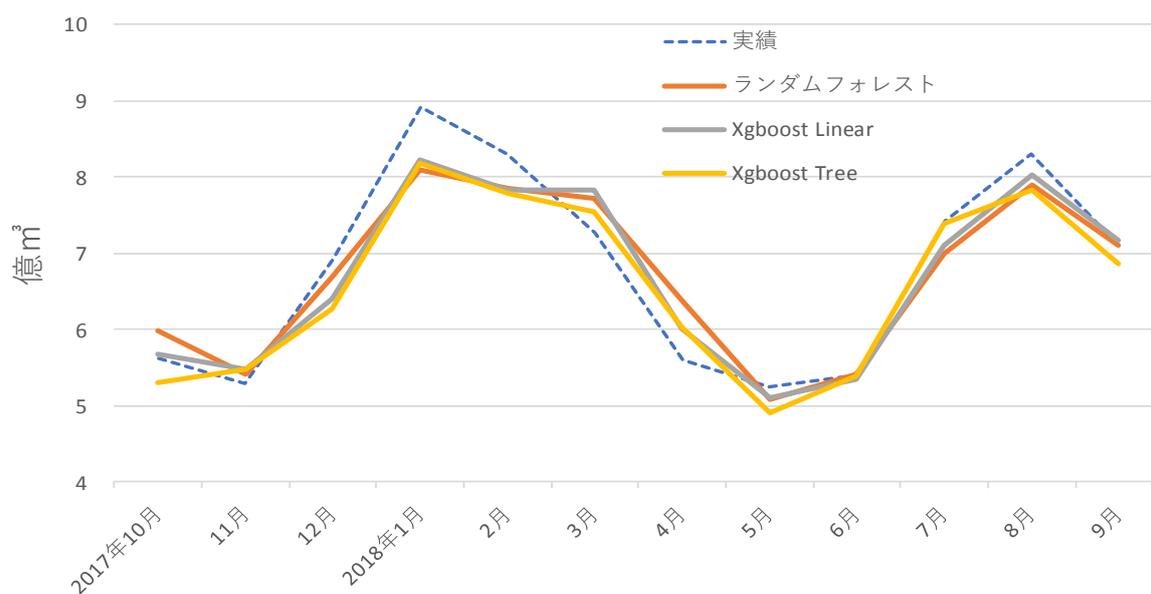
2017年10月-2018年9月までの12か月間の部門別都市ガス販売量の予測結果を示した(図7、8、9)。結果は、家庭部門は2017年12月-2018年2月の誤差率が平均5-11%程度の過小予測となったが、2018年8月における誤差率も平均11%と大きくなった(図7)。夏季の販売量は冬季の2-3割となるため、小さい誤差が夏季では大きな誤差率となるためである。また2018年4月には誤差率が11%程度の過大予測となった。業務部門は冬季に6-8%程度の過小予測と誤差率が大きくなり、2018年4月は約10%の過大予測となった。産業部門は2017年11月-2018年2月における誤差率が5-8%程度の過小予測と最も大きくなった(図9)。2018年4月は約5%の過大予測、2018年7月は約6%の過小予測となり、それ以外の期間は概ね良好な予測となった。

図7 | 都市ガス販売量(家庭部門)の予測と実績



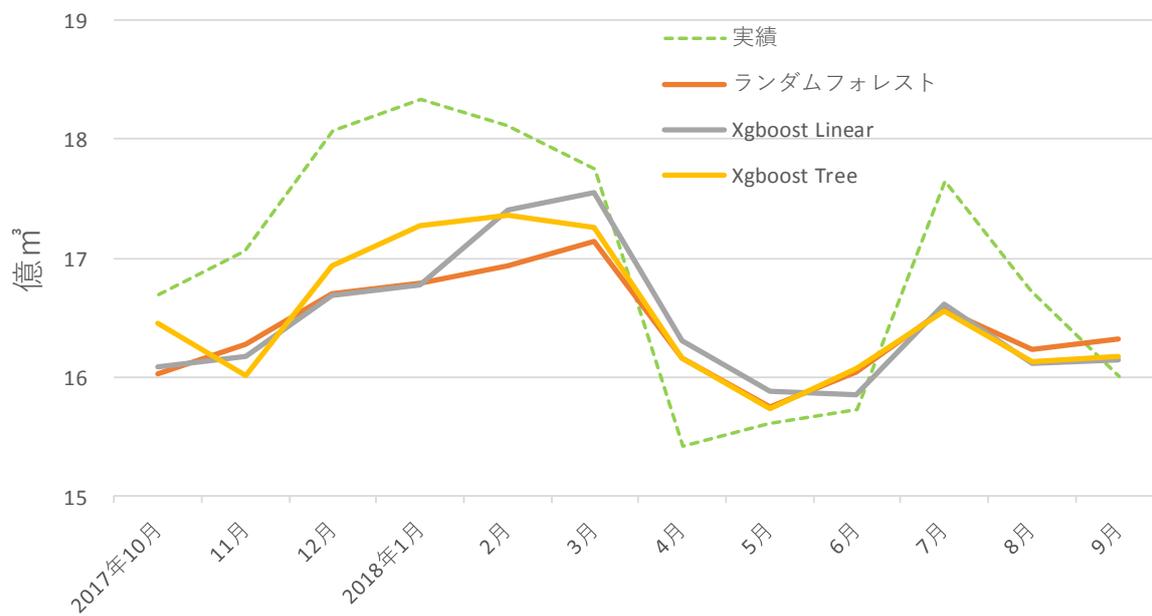
出所: 筆者算出。

図8 | 都市ガス販売量(業務部門)の予測と実績



出所: 筆者算出。

図9 | 都市ガス販売量(産業部門)の予測と実績

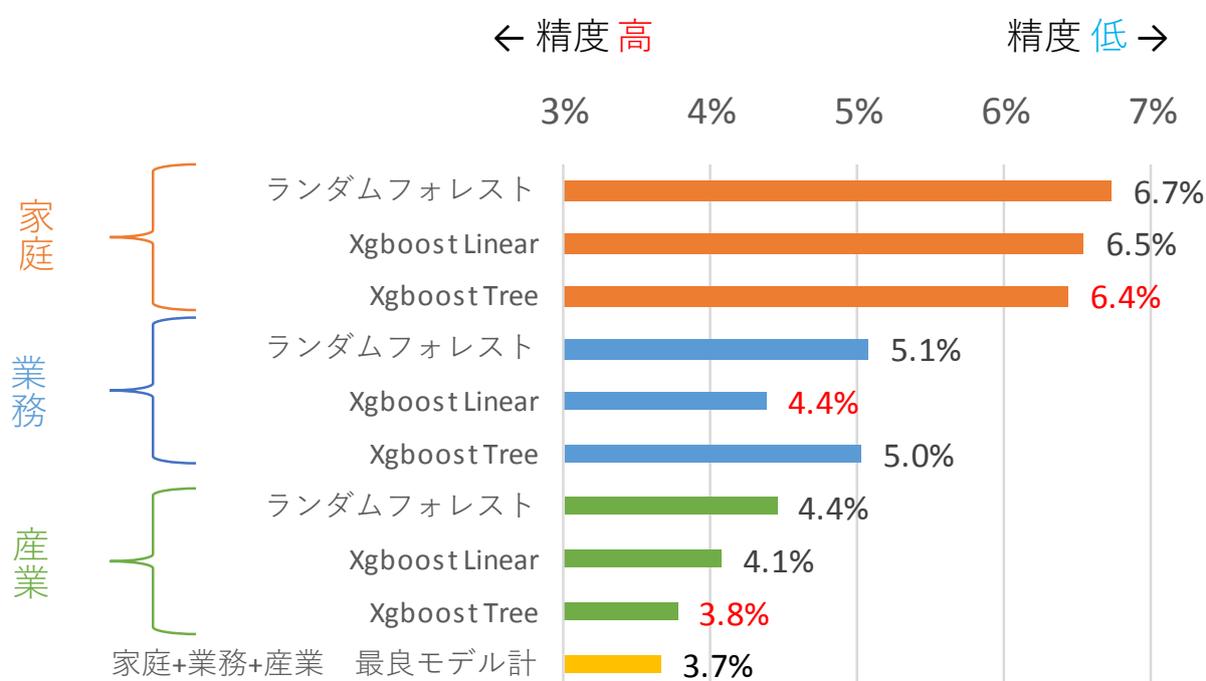


出所: 筆者算出。  
 (注)発電用を除く。

次にアルゴリズム別のMAPEを示した(図10)。なお、他の精度評価指標であるRMSEやMAEも類似した精度の傾向となっている。部門別の場合、Xgboost LinearやXgboost Treeの方がランダムフォレストよりも予測精度が高い場合が多数を占めた。最も予測精度の高いアルゴリズムは、家庭部門ではXgboost Tree、業務部門ではXgboost Linear、産業部門(発電用除く)ではXgboost Treeとなった。このように、適用課題次第で各アルゴリズムの予測精度が変わるため、工学的に試す必要がある。

最終的な結果となる家庭+業務+産業のそれぞれの最良モデルを合計した場合のMAPEは3.7%まで改善した。部門別よりも合計したモデルのほうが精度が良いのは、誤差が正と負で打ち消しあうためである。なお、SARIMAモデルも部門別に積み上げる形で予測をしたが、こちらのMAPEは5.7%となり、全体販売量予測の5.6%から悪化した。部門別の積み上げでは、説明変数がより直接的に予測に寄与できることから、説明変数を用いたモデルのほうが適しているということだろう。

図10 | 都市ガス月別販売量の部門毎のアルゴリズム別予測精度(MAPE)

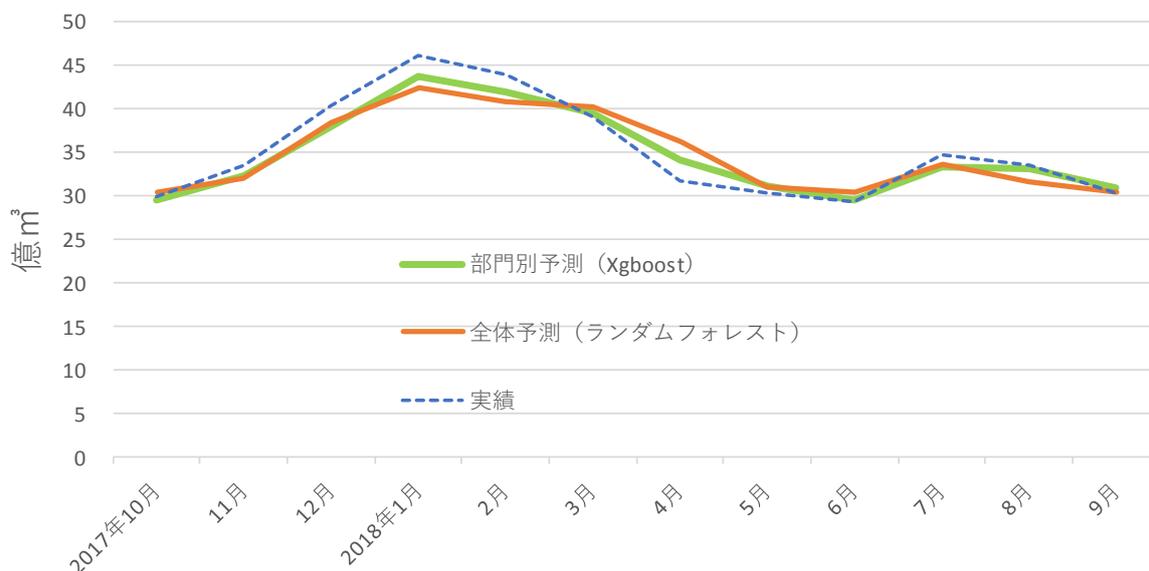


出所: 筆者算出。

(注) 産業は一般工業用のみ(発電用を除く)。「最良モデル計」は、家庭・業務・産業で最も精度の高かったモデル(赤字で表示)を合計したものの。

部門別での最良モデル計による予測と、全体販売量の予測で最も精度の高かったランダムフォレストモデル予測、および実績を比較した(図11)。部門別予測は全体予測と比較した際、特に2018年1月、2月、4月において、予測精度が改善していることが確認できる。但し、予測精度は改善したものの、それらの月における予測誤差は依然として残っている。

図11 | 都市ガス販売量(全体)の予測と実績



出所: 筆者算出。

(注)部門別予測の発電用は実績値。

## モデルの改善点

本稿ではモデルの改善を行ってきたが、よりモデルの精度をあげるため、以下3つの改善点が考えられる。

1つ目は、残差の予測である。アンサンブル学習を行うアルゴリズムは、複数のモデル(弱学習器)を作成し多数決を取るという仕組みから、通常時の予測には強いものの、極端に高い値や低い値への追従性能は高くないと言われる。今後は、実績と予測の差である残差の予測を加えることで、予測精度を上げていける可能性があると考えられる。

2つ目は、日次もしくは時間帯別データの取得である。電力需要などはオープンデータでも時間帯別にデータを取得できる一方、都市ガス販売量は月次でしか取得できない。日時もしくは時間帯別データを取得することで、天候や曜日データなどを説明変数として加えることができ、より精度の高い予測ができる可能性がある。各旧一般ガス事業者は送出量という形で日次もしくは時間帯別データを保有していると思われる。但し、各事業者が保有する送出量データは、管内の全体送出量のみとなり、スイッチング影響を含めた自社顧客の日次データは保有していないかもしれず、その際は推計が必要となるだろう。

3つ目は、説明変数の予測方法である。部門別の予測に説明変数として用いた「企業物価指数」や「各産業の生産量」は、実績値を将来予測として使用しており、推計に置き換える必要がある。また、影響の大きい暖房度日は記録的な厳冬であった本予測期間では予測が10%程度外れたこともあり、精度を向上させる必要があるだろう。

また、実際の運用で活用するためには、以下2つの改善点が考えられる。

1つ目は、各事業者別の予測である。今回は全国値での予測としたが、実際にLNGの調達を行うのは各ガス事業者であるため、実運用では事業者別に予測をする必要がある。

2つ目は、部門別の予測における発電用の予測である。今回は第2ステップにあたる部門別の予測において対象外としたが、ガス事業者によっては含めていく必要がある。また、LNG調達という観点からは、事業者によっては都市ガス用発電だけでなく、LNG発電のモデリングも必要だろう。

これらにより都市ガス販売量の予測精度を高め、また実運用に活用できる形とし、その予測アルゴリズムを最適化モデルに組み込みオペレーションを回すことで、より効率的なLNGサプライチェーンの構築につながる可能性があるだろう。

## 今後への示唆 -人間に求められる能力-

本稿では、都市ガス販売量の予測モデルの精度改善を通じて、アルゴリズムの比較検討を行った。しかし、アルゴリズムに優劣をつけるのがその目的では断じてない。今回の課題では、予測精度において機械学習的手法が統計学的手法を概ね上回ったが、統計学的手法が劣るというわけでは決していない。それぞれの手法に長所と短所があり、機械学習的手法は点推定(1点のみの推定)しかできないのに対して、統計学的手法は点推定に加えて区間推定(任意の確率での予測範囲の推定)ができる。また、統計学的手法はSARIMAモデルのように被説明変数のみでモデリングができる、VARモデルのように説明変数の将来予測が必要ない、重回帰分析のように回帰係数から説明変数ごとの影響度がわかるといった利点がある。

もし仮に筆者が実務に活用するとした場合、例えば全体販売量の予測においてランダムフォレストとの精度の違いが0.7%であり、説明変数の準備が必要ないSARIMAモデルを選択する可能性は十分考えられる。しかし、その精度の比較検討には、実際に他アルゴリズムによる試算をしなくてはならない。それぞれのアルゴリズムの長所と短所を把握し、状況に応じて統計学的手法と機械学習的手法を使い分けることが重要だろう。

また、先述の通りモデリングの精度は、工学的に試してみないとわからない。今回のモデリングが最善とは言い切ることはできず、求める精度に達したときに完了するというアプローチになる。モデリングを自動で最適化してくれるツールもあり、今回の機械学習的手法におけるアルゴリズムのチューニングも、統計分析プログラミング言語「R」の自動チューニング機能であるCARETパッケージを用いた。また、DataRobot社などが提供する自動モデリングツールを用いれば、より精度が改善される可能性もあるだろう。

今後は、予測アルゴリズムの更なる精度向上と、そのアルゴリズムを自動で最適化モデリングするツールの発達と価格低下が予想される。それらを用いればモデリングに精通せずとも、精度を上げや

すくなることが想定され、精度を上げるためのモデリングは、人間の仕事としては重要度が相対的に低くなる可能性がある。一方で今後より重要度を増す能力としては、①データ取得に向けた仕組みを総合的に設計・構築する能力、②統計学や機械学習など各分析手法の特性や長所・短所を理解した上で、それを用いてビジネスや研究に適用させる(適用領域を検討する)スキル、つまりデータサイエンスを用いて解決すべき課題を設定する目利き能力がより重要になるだろう。

本稿で扱うデータサイエンスとは一般に言う「AI<sup>11</sup>」のことであるが、観や経験といった帰納的な思考はAIが代替していく中、人間には哲学的ともいえる演繹的な思考も必要になる。現在の統計学や機械学習によって構成されるAIの予測は、どんなに複雑なモデルも過去傾向からの予測に過ぎず、不確実性が高まる世の中における将来予測においては、数値だけでなく、現在のAIにはできない「意味を理解した」演繹的な思考を人間は同時にすることで、様々な事象への予測・対応ができるだろう。

お問い合わせ: report@tky.ieej.or.jp

---

<sup>11</sup> 世界はテクノロジーの時代へ突入している。エネルギーもその例外ではなく、パリ協定の2°C目標の達成は既存技術の積み上げでは難しい中、日本政府も2050年におけるエネルギーシナリオにおいてテクノロジーの開発動向を最大限取り込めるよう複線シナリオを設定した。今後はエネルギーにおいても、テクノロジーを含めた研究の必要性が高まるだろう。1つの技術の可能性として、将来的には巨大なバーチャルパワープラントのようにエネルギーシステム全体が情報通信技術によって結ばれ、AIによって最適制御される日が訪れるかもしれない。エネルギーにおいて、これまでAIはシミュレーションに用いられることが多かったように感じるが、今後は実際に最適制御などの形で実運用に用いられることが増え、より直接的に経済合理性や安定供給、温暖化対策といった3Eへの貢献が増えていくのではないだろうか。