

論 文

機械学習による簡易負荷予測機能開発

立岩 一真

気象予報と実測空調負荷データのみを活用し、定期的に機械学習を行うことで、気象予報に基づく負荷を予測し、WEB監視システム上に表示する機能を開発した。

1. はじめに

近年、建物運用最適化を目的として、AI技術を活用したエネルギー需給を統合管理するエネルギーマネジメントシステム¹⁾などを活用し、空調負荷予測と運転計画立案を連携させる取り組みが数多く報告されている。また、電力自由化の進展により、時間単位で電気料金が変動するリアルタイムプライシングプランの事例²⁾も増えている。従来の「深夜料金が安い」といった単純な料金プランと比較すると、熱源機器などの最適運転が可能になり自由度はさらに高まるが、一方で運用上の複雑性も増している。

このような状況下で最適な運転計画を立案するためには、まず負荷をリアルタイムで常時学習・予測できる体制を整えることが重要である。

当社ではこれまでローカルマシンによる空調負荷予測の研究開発³⁾を行ってきたが、今回クラウドに蓄積されたデータを活用し、任意の物件とポイントに対して常時学習および予測を行う機能を開発した。予測したデータは当社開発のWEB監視システム⁴⁾上にも表示可能(図1)にしている。本稿ではその学習および予測手法について報告する。

2. システム構成概要

図2に、負荷予測を行い、その結果を表示する全体システム構成を示す。従来のWEB監視システムは、現場からのデータをHTTPプロトコルによりクラウド上



図1 予測データ表示画面




図2 システム構成

のデータベースに蓄積し、ユーザーがPCブラウザを介してWEB監視サーバにアクセスすることで、当該データを閲覧可能とする仕組みであった。

今回はこの従来の仕組みに対して、別システムで運用していた気象予報取得機能を統合している。気象予報は6時間ごとに、日本気象のFTPサーバから当社技術研究所のマシン(GPC)へCSV形式で送られる。GPC上でそのCSVファイルを解析し、WEB監視データベースへ必要な地点に限定したデータをHTTP送信するプログラムを新たに実装している。

さらに、WEB監視データベースに保存している現場データおよび気象予報データを自動的に取得し、定期的に機械学習するプログラム、および気象予報を学習

モデルに入力して負荷を予測し、その結果をWEB監視データベースに保存するプログラムを開発した。これらはローカルマシンおよびクラウドのいずれにも設置可能であり、常時動作することで定期的な学習と予測を行う仕様としている。

3. 機械学習と予測

機械学習には、単純なニューラルネットワーク（NN）モデルを活用した。表1に、NNモデルの設定を示す。CASE1の入力層（説明変数）は、気象予報から得られる「天気」「気圧」「降水量」「風向」「風速」「気温」「湿度」「雲量」の8項目に、「時間」「曜日」「祝日情報」を加えた合計11項目としている。CASE2の説明変数は、CASE1に加えて「前の時間の目的変数」を含め、合計12項目としている。なお、物件によっては用途情報や設備稼働スケジュールなどを取得できない場合もあるため、本研究では「気象予報データ」および「負荷実績データ」といった全物件で共通に入手可能な情報のみに着目した。これにより、同じプログラムをどの物件でも汎用的に適用できる構成としている。出力層（目的変数）は、任意に設定可能なポイント（負荷など）である。

図3に、NNモデルを活用した機械学習および予測のフローを示す。このバッチ処理は、1時間ごとに1回実行して、そのタイミングが「学習を行う時間」に該当する場合は学習フローを実行する。学習処理では、まず学習対象となる過去の実績データおよび過去の気象データを取得し、時刻情報を用いてマージ（結合）する。続いて、学習精度向上のため、各データを0～1の範囲に正規化する。なお、正規化は単純なリニアスケールリングを用い、説明変数の最大・最小値には表2に示す値を適用した。目的変数は対象ポイントによって値のレンジが異なるため、取得した目的変数の最小値および最大値を使って正規化を行う。次に、表1で設定したNNモデルを用いて学習を行い、その学習済みモデルを機械学習サーバ内に保存する。

一方、予測フローにおいても、バッチ処理を1時間ごとに1回実行する。まず、予測結果と比較するための実績データおよび気象予報データを取得する。学習フローと同様に表2に示す値を使って気象予報データを正規化し、保存していた学習済みモデルを用いて目的変数の予測を行う。予測結果はWEB監視データベースに保存することで、閲覧者がいつでも予測結果を確認可能としている。

表1 NNモデルの設定

入力層数	隠れ層数	出力層数	活性化関数	重み初期化	最適化関数	評価指標
CASE1 : 11	3層	1	ReLU	HeUniform	Adam	MSE
CASE2 : 12	(20,20,20)					




図3 学習と予測のフロー

表2 正規化のスケールリング

データ	単位	最小値	最大値	備考
時間	-	0	23	
祝日	-	0	1	祝日 : 1
曜日	-	0	6	日曜:0～土曜:6
天気	-	0	3	0:晴、1:曇、2:雨、3:雪
気圧	hPa	900	1100	
降水量	mm	0	50	
風向	-	0	15	16方位、北:0～北北西:15
風速	m/s	0	20	
気温	℃	-20	40	
湿度	%	0	100	
雲量	-	0	9	0 : 少ない～9 : 多い

4. 予測結果

学習済みNNモデルによる予測性能を評価するため、物件A（製薬工場）、B（製薬工場）、C（事務所）、D（病院）、E（ホテル）の冷水負荷熱量を対象とした。予測精度の評価指標には、式（1）に示す二乗平均平方根誤差（RMSE）を百分率で表した値を用いた。RMSEは、予測モデルがどの程度実測データに適合しているかを示す指標である。特に時刻別データの評価においては、RMSEが±30%以内に収まる場合は「モデルがキャリブレーションされた」とみなせることが多い。

$$RMSE=100\times\frac{\left(\frac{\sum (y_i-\hat{y}_i)^2}{n-p}\right)^{\frac{1}{2}}}{\bar{y}}\cdot\cdot\cdot(1)$$

学習日数による差異を比較するため、学習期間は2025年2月28日までの1,2,4,8,16,64,128,256日間の8通りとし、評価期間は2025年3月1日～3月15日の2週間とした。

結果を表3に示す。CASE1と比較して、CASE2はすべての物件でRMSEが低下しており、「前の時間の目的変数」を説明変数に加えることで予測精度が向上することが確認できる。また、学習期間によるRMSEの差異が小さいことから、比較的短期間の学習であっても予測が可能であると推察される。ただし、8通りすべてにおいて「予測期間の直前のデータ」を用いて学習しているため、直前のデータを学習に含めることが予測精度の確保において重要であると考えられる。したがって自動学習は頻繁に行うことが望ましいと推察される。

一方、物件BではCASE1およびCASE2ともに、学習期間64日間とするよりも128日間とする方が予測精度が低下している。これは、学習期間に季節の変わり目を含むことで、気象条件などの変動が大きくなり、かえって精度が低下する場合もあると推察される。

物件Aおよび物件Cにおいては、CASE2でもRMSEが±30%以内に収まることはなかった。図4に物件Aの負荷傾向を示すが、2月22日を境にベース負荷や負荷傾向が変化しており、さらに別期間においても類似した変化が見られた。これにより傾向が変わり、予測精度が低下したと推察される。図5に物件Cの負荷傾向を示すが、評価期間中に、平日にもかかわらず負荷が0となる期間が続いており、これが予測精度の低下に影響したと考えられる。別期間を評価すれば精度が向上する可能性もある。図6および図7に評価期間中の物件Aおよび物件Cの負荷実績と予測のトレンドグラフを示

表3 結果RMSE[%]

学習期間		1日	2日	4日	8日	16日	32日	64日	128日
物件A	case1	62.6	63.2	63.7	64.8	68.0	62.6	63.1	60.9
	case2	34.5	36.8	33.8	35.5	34.0	34.1	33.8	33.7
物件B	case1	28.0	27.9	22.9	28.2	22.4	20.3	21.2	27.4
	case2	9.6	8.5	9.0	10.5	9.5	10.2	9.8	9.9
物件C	case1	198.8	189.8	164.6	164.9	179.3	176.9	181.9	187.2
	case2	86.3	74.7	73.6	72.9	72.9	71.0	72.1	70.1
物件D	case1	44.0	46.4	47.3	35.6	44.7	38.4	46.6	33.7
	case2	12.7	16.3	12.3	13.0	16.0	13.6	12.6	16.9
物件E	case1	52.7	40.7	47.3	48.0	45.8	46.9	47.5	51.7
	case2	32.0	26.2	26.8	27.5	25.9	28.0	28.1	26.1

す。両物件ともRMSEの数値は±30%を超過しているが、実績値から大きく乖離しているわけではなく、制御の目安として活用するには十分な精度を有していると考えられる。

5. おわりに

- ・「前の時間の目的変数」を説明変数に加えることで、予測精度を向上させることが確認できた。
- ・「気象予報データ」および「負荷実績データ」のみを説明変数とすることで、すべての物件で汎用的に学習および予測が可能となり、負荷傾向が安定している物件であればRMSEが±30%以内の予測精度を確保できることがわかった。
- ・RMSEが±30%を超過する物件であっても、実績値との絶対的な乖離が大きいわけではないため、運用の目安としては活用可能と考えられる。
- ・学習期間が短い場合でも、一定の予測精度を得られることが確認できた。
- ・CASE2の方法で自動学習を行うプログラムを構築し、WEB監視システム上に予測結果を表示する機能を開発した。
- ・さらなる予測精度の向上や、予測結果を用いた運転計画立案などの研究が今後の課題である。

参考文献

- 1) 凌ら：熱と電力の連携を行うエネルギープラントの最適運用に向けた実績・性能評価（第3報）AI技術を活用したエネルギーマネジメントシステムの実証試験、空気調和・衛生工学会学術講演会講演論文集2023年9月,pp.49-52
- 2) 野村総合研究所：次世代分散型電力システムに関する検討会、2023年8月
- 3) 金原ら：状態空間モデルによる空調負荷予測、空気調和・衛生工学会学術講演会講演論文集1997年8月,pp.525-528
- 4) 深見、永池、立岩：WEB監視システムを利用した現場試運転とコミショニングへの展開、東熱技報No.96,2021年2月,pp.43-50
- 5) ASHRAE. (2014). ASHRAE Guideline 14-2014: Measurement of Energy, Demand, and Water Savings




図4 物件A負荷傾向




図5 物件C負荷傾向




図6 物件A負荷実績と予測




図7 物件C負荷実績と予測