

# ニューラルネットワークを用いた J-PARC 使用電力量に気象が与える影響の調査

## APPLYING NEURAL NETWORKS TO INVESTIGATIONS OF THE INFLUENCE OF WEATHER CONDITIONS ON THE POWER CONSUMPTION OF J-PARC

野村昌弘 \*<sup>A)</sup>、田村文彦 <sup>A)</sup>、島田太平 \*<sup>A)</sup>、山本昌亘 <sup>A)</sup>、  
古澤将司 <sup>B)</sup>、杉山泰之 <sup>B)</sup>、原圭吾 <sup>B)</sup>、長谷川豪志 <sup>B)</sup>、大森千広 <sup>B)</sup>、吉井正人 <sup>B)</sup>

Masahiro Nomurai\*<sup>A)</sup>, Fumihiko Tamura<sup>A)</sup>, Taihei Shimada<sup>A)</sup>, Masanobu Yamamoto<sup>A)</sup>,  
Furusawa Masashi<sup>B)</sup>, Yasuyuki Sugiyama<sup>B)</sup>, Keigo Hara<sup>B)</sup>, Katsushi Hasegawa<sup>B)</sup>, Chihiro Ohmori<sup>B)</sup>, Masahito Yoshii<sup>B)</sup>

<sup>A)</sup>Japan Atomic Energy Agency, JAEA

<sup>B)</sup>High Energy Accelerator Research Organization, KEK

### Abstract

The amount of electric power used in the operation of accelerators tends to increase in summer due to rising temperature. In recent years, summer temperatures have tended to increase, so understanding the amount of power usage in summer from weather information has become important in terms of contract power and power saving measures. The relation between the amount of power usage and weather conditions is that the accelerator facility has many cooling facilities, so it can be thought that the amount of power used to cool each device increases as the temperature and humidity increase. It seems that it has not been investigated specifically what kind of dependence there is. Therefore, considering the neural network as a kind of fitting function or a model of calculation, we investigated the influence of weather conditions on the power usage. Specifically, we let the neural network learn the temperature and humidity information as input data and the power usage of the accelerators as teaching data, and investigate the influence of the weather conditions on the power usage using the learned neural network.

## 1. はじめに

加速器の運転における使用電力量は、気温の上昇等により夏場は常に増加傾向にある。近年、夏場の気温はより高まる傾向を示していることから、気象情報から夏場の使用電力量を把握することは、契約電力の観点や節電対策を行う上でも重要になってきている。加速器施設での使用電力量と気象との関係は、気温や湿度が高くなれば各機器を冷却する為に使用電力量が増加することは想像できるが、具体的にどのような依存性があるかは調べられていないと思われる。そこで、本研究ではニューラルネットワークを用いて気象条件と使用電力量の関係を学習させ、その学習したニューラルネットワークにより気象条件が使用電力量に与える影響を調べる。今回初めてニューラルネットワークを構築するにあたっては、参考文献 [1] を参考にした。

## 2. ニューラルネットワーク概要

まず初めに、今回のニューラルネットワークの構成を Fig. 1 に示す。入力データである気温と相対湿度は、誰でも簡単に知ることのできる水戸の気温と相対湿度を採用した [2]。理由は、多くの人を知ることのできる気象情報から使用電力量の増加を予測し、周知することは節電対策を進める上で重要だからである。しかし、水戸と J-PARC のある東海村と

では約 15 km 離れており、気象条件の違いはある種の誤差として存在することとなる。もう一つの入力データは MLF へのビームパワーである。これは、加速器の運転状況を示し、使用電力量の大部分を決定するものである。これらの入力データから学習する教師データとしては、MLF へビームを入射する Linac と RCS の二つの加速器の使用電力量を採用した。




Figure 1: Structure of neural network.

Figure 2 に今回使用したデータ、平成 29 年と平成 30 年の 6 月の MLF 共用運転時の 1 時間毎のデータを示す。但し、メンテナンスや加速器スタディー等により使用電力量が変動した場合のデータは取り除いてある。共用運転時に於ける平成 29 年 6 月の MLF へのビームパワーは 156 kW、平成 30 年 6 月は 526 kW であった。また、実際にニューラルネットワークにより学習する際は、それぞれのデータの大きさをそろえる為に、最大値で規格化した値を使用した。

\* masahiro.nomura@j-parc.jp

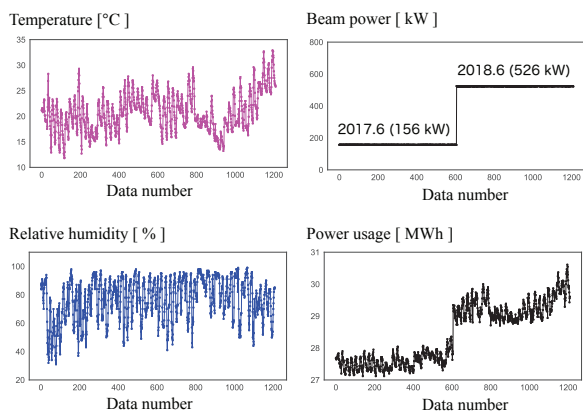


Figure 2: Input and teacher data.

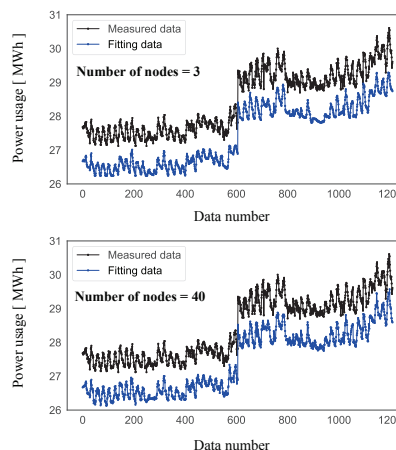


Figure 3: Measured and fitting data of power usage in the case of number of nodes = 3 and 40.

### 3. ニューラルネットワークの設定

適切なニューラルネットワークを設定し、学習させることにより、その学習したニューラルネットワークから気象の使用電力量に与える影響は知ることができる。この節と次の節ではニューラルネットワークの設定について議論する。

#### 3.1 ノード数

ニューラルネットワークは、ある種のフィッティング関数として考えることができる。この節ではフィッティング関数の次元に対応すると考えられるノード数について議論する。ノード数の違いの影響がはっきりと分かる様に、ノード数の大きく違うノード数3と40のニューラルネットワークを用いて、その影響について調べた。その他のパラメータとしては、レイヤー数は3、活性化関数としてはRectified Linear Unit (relu)を採用した。また、学習の際には、全データの80%をフィッティングのパラメータを最適化するためのデータ(訓練データ)として用い、残り20%を検証するためのデータ(テストデータ)として使用した。

Figure 3にノード数3と40のニューラルネットワークのそれぞれの学習結果、つまりフィッティングによる結果と実測値の使用電力量を示す。黒が実測値を示し、青がニューラルネットワークにより求めた使用電力量である。両者を比較しやすいように、ニューラルネットワークにより求めた使用電力量は1MWh低く表示してある。Figure 3を見ると、どちらのニューラルネットワークによる使用電力量も実測値を良く再現しているが、ノード数40のニューラルネットワークによる使用電力量はより細かなところまで実測値を再現していることが分かる。このノード数を40に増やした影響を詳しく調べる為に、訓練データとテストデータそれぞれの実測値とニューラルネットワークによる使用電力量との誤差分布を両方のニューラルネットワークで比較してみる。

Figure 4に、両方のニューラルネットワークのそれぞれの誤差分布を示す。青色が訓練データの誤差分布を示し、赤色がテストデータの誤差分布を示す。

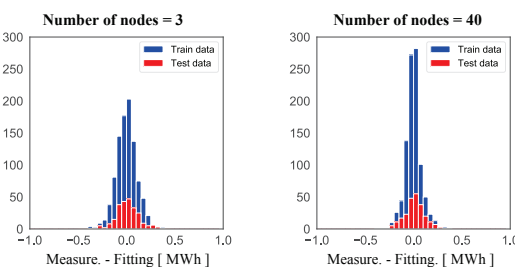


Figure 4: Error distributions in the case of number of nodes = 3 and 40.

ノード数の違う両者を比較すると、ノード数40の青の訓練データの誤差は小さく、より実測値を再現していることになる。一方、赤のテストデータの誤差分布に関しては、訓練データほどは改善されていない。これはノード数、つまりフィッティングのパラメータ数が増えることにより訓練データの精度は高まっているが、パラメータの増えたニューラルネットワークを用いてフィッティングしてもテストデータの精度は同様には高まっていないことを表している。つまり、ノード数40のニューラルネットワークは、データ全体を適切に表現するニューラルネットワークにはなっていないことを示している。これは、パラメータが増えたことによる合わせすぎであり、ディープラーニングで言うところのOver fittingと考えられる。このOver fittingの影響は、使用電力量の気温依存性にも現れている。

Figure 5に、ノード数3と40のニューラルネットワークにより得られた使用電力量の気温依存性を示す。Figure 5を見ると、ノード数40を持つニューラルネットワークは細かな変動が見られる。使用電力量の気温依存性を考えた場合に、このような細かな変動が起きるとは考えにくく、Over fittingの影響によるものと考えられる。以上の議論より、ノード数の少ない3でも使用電力量の実測値を再現でき、適切に気温依存性も示していることから、ノード数は




Figure 5: Temperature dependence of power usage.

3の方が適切と考えられる。

### 3.2 活性化関数

この節では、フィッティング関数の関数形に対応すると思われる活性化関数について議論する。Figure 6に、ニューラルネットワークではよく用いられ、今回議論する Rectified Linear Unit (relu) と Hyperbolic tangent (tanh) 関数を示す。




Figure 6: Rectified Linear Unit and Hyperbolic tangent.

Figure 7に relu と tanh を活性化関数としたニューラルネットワークにより得られたビームパワー依存性を示す。そもそもビームパワーは2点だけなので、




Figure 7: Beam power dependence of power usage.

どちらの活性化関数が適切かの議論は無理がありここでは行わないが、Fig. 7からは、フィッティングの様子、当たり前ではあるがどちらの活性化関数を用いても、温度と相対湿度を再現しつつビームパワーの2点を通る様にフィッティングされていることが分かる。また、Fig. 7は気象条件に依存しない使用電力量を表しており、この図からビームパワーを100 kW 増やした時には使用電力が約0.4 MW 増えることが計算できる。この増加分は、ほぼRCSの加速空洞のビーム負荷によるものである。

Figure 8に relu と tanh を活性化関数としたニューラルネットワークにより得られた温度依存性を示

す。Figure 8を見ると、相対湿度65%で気温のデー




Figure 8: Temperature dependence of power usage.

タが存在する15°Cから30°Cの領域ではどちらの活性化関数を用いても大差がない。どこまで外挿して予測できるかは議論のあるところではあるが、活性化関数として tanh を用いた場合には、関数の性質上外挿すると頭打ちとなってしまふ。気温の使用電力量に与える影響を考えた場合には、単純にそのまま外挿する方が自然と思われるので、今回は relu の方が活性化関数として適切であると考えられる。

## 4. 気象条件が使用電力量に与える影響

この節では、気象条件から使用電力量を学習したニューラルネットワークを用いて、使用電力量の気温と相対湿度依存性を新たに見てみる。前節での議論を踏まえて、ニューラルネットワークのノード数は3に、活性化関数はreluに設定している。

Figure 9に使用電力量の気温依存性を Fig. 10には相対湿度依存性を示す。Figure 9を見ると、予想通




Figure 9: Temperature dependence of power usage.




Figure 10: Relative humidity dependence of power usage.

り、気温の上昇に伴い、使用電力量が増えることが分かる。一方、Fig. 10を見ると、相対湿度の依存性はほとんど見られない。これは、J-PARCが海沿いに

ある為、水戸と J-PARC での相対湿度との間に因果関係が少ないからかもしれない。

使用電力量に相対湿度依存性が見られないことから、使用電力の増加は単純に気温の上昇から予測することができる。例えば、朝の気温が 22℃であり、「日中は最高気温 32℃まで上昇することが予想されます。」との気象情報があれば、使用電力は約 1 MW 増えることが予測できる。

## 5. 令和元年に適用

ここまでは、平成 29 年と平成 30 年の 6 月のデータを用いてニューラルネットワークを学習させ、気象の使用電力量に与える影響を調べてきた。ここでは、この学習したニューラルネットワークを用いて、令和元年 6 月の使用電力量を予測してみる。令和元年 6 月の MLF 共用運転時のビームパワーは平成 30 年 6 月とほぼ同様の 538 kW である。

Figure 11 に平成 30 年 6 月と令和元年 6 月の気象条件を示す。やはり、平成 30 年 6 月の後半数日間の気温が高いことが分かる。




Figure 11: Temperature and relative humidity in June 2018 and 2019.

Figure 12 に平成 29 と平成 30 年の 6 月のデータを学習したニューラルネットワークを用いて予測した、令和元年 6 月の使用電力量を示し、Fig. 13 に実測値と予測値の差を示す。Figure 13 から実測値が全




Figure 12: Measured and predicted power usage.

体的に予測値よりも約 0.2 MWh 程度大きいことが分かる。この差は、使用電力量全体の約 0.7% と非常に小さい値であり、原因としては、ビームパワーの測定精度やビームパワー 2 点のみによるフィッティングの誤差、MLF 以外の Main Ring へのビーム供給の影響等によるものではないかと推測される。

実測値と予測値には僅かな差はあるものの、その差が全体に均一の場合には、気温上昇から使用電力量の増加は予測は可能である。Figure 14 に平成 29 年




Figure 13: Difference between measured and predicted power usage.

と平成 30 年の予測値と実測値との誤差分布と令和元年の誤差分布を示す。中心値はズレているものの、学習に用いた平成 29 年と平成 30 年の誤差分布と令和元年の誤差分布がほぼ同様であることから、令和元年の場合でも、ほぼ同等の精度で使用電力量の予測が可能と考えられる。




Figure 14: Error distributions.

## 6. まとめ

今回ニューラルネットワークを用いて、気象が使用電力量に与える影響について調べた。通常ニューラルネットワークを用いて画像認識等を行う場合はその正解率が最も重要とされる。当然今回も、使用電力量の実測値を再現することは重要であり大前提ではあるが、今回は、その学習したニューラルネットワークから気象の使用電力量に与える影響を調べることが目的なので、よりニューラルネットワーク自身が重要となってくる。その為、ニューラルネットワークの重要なパラメータであるノード数に関して Over fitting の議論や、活性化関数の違いによる影響についての議論を行った。その結果、適切なニューラルネットワークを設定し、学習させることにより、そのニューラルネットワークから使用電力量の気温や相対湿度依存性を求めることができた。さらに、平成 29 年と平成 30 年のデータを学習したニューラルネットワークを用いて、令和元年の電力使用量が予測でき、構築したニューラルネットワークの有効性も確認することができた。

### 参考文献

- [1] 斎藤康毅, ゼロから作る Deep Learning —Python で学ぶディープラーニングの理論と実装, オライリー・ジャパン, オーム社, ISBN978-4-87311-758-4.
- [2] <https://www.data.jma.go.jp/gmd/risk/obsd1/index.php>