

## ニューラルネットワークによる 静止軌道の電子フラックス予測

中村祐輔, 北村健太郎 (徳山工業高等専門学校),  
徳光政弘, 石田好輝 (豊橋技術科学大学),  
亘慎一 (情報通信研究機構)

### Prediction of High-Energy Electron Flux at Geosynchronous Orbit by using the Neural Network

Yusuke NAKAMURA, Kentarou KITAMURA, Masahiro TOKUMITU,  
Yoshiteru ISHIDA, Shinichi WATARI

It is important for spacecraft operation to make a forecast of high-energy electron flux at geosynchronous orbit. Because enhancement of high-energy electron flux often causes deep electrical charging. This study to predict a critical enhancement of high-energy electron flux at geosynchronous orbit using the neural network. The program of neural network is tested using the several kinds of input data and various numbers of middle layers. As a result, the prediction efficiency is improved by combining solar wind data and ground magnetic data as input data compared to that by only solar wind data or ground magnetic data. This result indicates that combining solar wind data and ground magnetic data is effective for improvement of the predictive efficiency.

**Key Words** : Neural network, High-energy electron flux, Deep electrical charging,

#### 1. 緒 論

衛星の帯電現象のために引き起こされる衛星の誤作動・故障の原因は、高エネルギー電子であることは知られている。そのような誤作動・故障を引き起こすプロセスは以下のとおりである。高エネルギー電子が宇宙機の外殻を通り抜け、宇宙機内部の回路や導体に帯電を起こしたり、宇宙機の外殻のケーブルシールドなどの絶縁物に入り込んで帯電を起こしたりする<sup>(1)</sup>。そして帯電した電子が放電することによって、回路内に異常な電流が流れ、誤作動・故障、さらには衛星の短寿命化を引き起こす<sup>(2)</sup>

<sup>(3)</sup>。そのような障害を防ぎ、衛星の運用を安全に行うために、高エネルギー電子フラックスが危険なレベルに達することをあらかじめ知り、必要な対策を練ることが重要となる。また、高エネルギー電子フラックスの増加は、太陽風速度の変化や、地磁気の変化と相関があることも知られている。そのため、高エネルギー電子の増加を予測する経験的予測モデルが必要となる。

これまでに、太陽風速度を入力として用いた線形フィルタによる予測研究等がされている<sup>(4)</sup>。この手法では、1日平均値の予測が行われた。また、Fukata他は、磁気嵐時における地上で観測された磁場データを入力として用いたニューラルネットによる予測を行った<sup>(5)</sup>。

本研究では、非線形であるニューラルネットワークを用い、地上データと太陽風データを組み合わせることで、予測精度を向上させることを目的とする。

#### 2. ニューラルネットワーク

ニューラルネットワークとは、認識・記憶・判断などの処理をコンピューター上で実現するために人間の脳の仕組みを模倣したシステムのことである<sup>(6)</sup>。本研究では、階層型ニューラルネットワークに対して教師ありの誤差逆伝播学習法を適用した。ここで学習とは、ある入力パターンが与えられたとき、その出力と理想的な出力である教師信号との誤差を減らすようにニューラルネットワークの各ニューロンの結合荷重の修正を行い、与えられている問

題に適応していくことである。誤差逆伝播学習法のプロセスを以下に示す。まず、ある入力パターンに対する教師信号を用意し、その入力パターンを-1から1に規格し、入力層に入力する。そして、中間層の出力は、すべての入力層からの出力の重み付け加算で表現される。他のニューロンも同様に計算され、最終的に1つの出力を得て、その出力と教師信号の比較を行い最も近い値になるように重み変更される。その後、同じように計算を繰り返し行われ、誤差が設定値以下になるまで繰り返される。図1に誤差逆伝播学習法のネットワーク構造を示す。

本研究では、教師信号のデータとして、実際に測定されている電子フラックスのデータを用い、計算終了条件となる設定値を  $10^2$  とした。この教師信号と設定値をもとに過去7年間のデータを学習させることにより、24時間後の高エネルギー電子フラックスを予測する。また、本研究では、予測精度を高めるために、誤差逆伝播学習法における入力データ・中間層について検討を行った。入力の種類については、次項にて記述する。

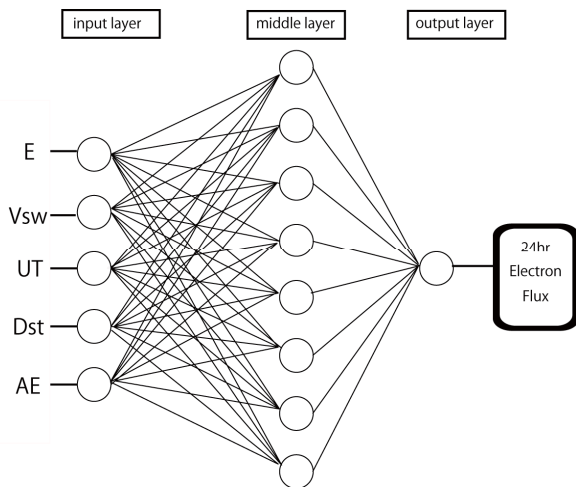


図1 ネットワーク構造

### 3. 入力データの説明

本研究で使用した入力データは、現在値の高エネルギー電子フラックス (E) , 太陽風速度 ( $V_{sw}$ ) , 磁場データ ( $B_x$ ,  $B_z$ ) , 太陽風の密度 ( $N_{sw}$ ) ,  $\Sigma\epsilon$ , Dst 指数,  $\Sigma Dst$ , AE 指数, 世界標準時間 (UT) の10個の1999年から2006年までのデータである。以下にデータが得られる環境別にそれぞれのデータについて述べる。

宇宙で測定されるデータのうち、高エネルギー電子フラックスは、衛星 GOES10 でローカルタイムに

観測されたデータを用いた。高エネルギー電子フラックスとは、2MeV以上のエネルギー帯の電子の流量のことである。また、太陽風速度、磁場データ、密度は NASA の OMNI 2 Data Base より提供いただいたデータを用いた。また、 $\Sigma\epsilon$  は、速度と磁場データによって次式で計算される地球磁気圏に流入する太陽風の電磁エネルギーである  $\epsilon$  を過去3日間足し合わせたものである。なお、衛星・探査機の位置関係・磁場の向きについては図2に示す。

$$\epsilon = V_{sw} |B|^2 f(t) (7 Re)^2 \quad [1]$$

$$f(t) = \sin^4\left(\frac{t}{2}\right) \quad [2]$$

$$t = \tan^{-1}\left(\frac{|B_y|}{|B_z|}\right) \quad (B_z < 0) \quad [3]$$

$$t = \pi - \tan^{-1}\left(\frac{|B_y|}{|B_z|}\right) \quad (B_z > 0) \quad [4]$$

地上で測定されたデータは、磁気嵐の強さを表す低緯度の地磁気指数である Dst 指数、オーロラ活動に伴って流れる極域オーロラジェット電流の大きさを表す高緯度の地磁気指数である AE 指数、世界標準時間 UT を用いた。これらの地磁気指数データは WDC Kyoto より提供いただいたデータを用いた。




図2 宇宙空間における座標系

### 4. 評価法

本研究では、予測モデルの検討を行うために相互相関係数(CC)、二乗誤差(MSE)、予測効率(PE)を用いて評価を行った。以下に式を示す。なお、Nは予

測値の数,  $f_i$ は予測値,  $x_i$ は予測値に対応する観測値を表す.

$$MSE = \frac{1}{N} \sum_{i=1}^N (f_i - x_i)^2 \quad [5]$$

$$VAR = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad [6]$$

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad [7]$$

$$PE = 1 - \frac{MSE}{VAR} \quad [8]$$

## 5. 結果および考察

ニューラルネットワークは初期値をランダムに与えるため, 出力は毎回異なる. そのため, それぞれのケースに対して 10 回ずつ試行し, その平均値を求めた.

まず, 入力データの違いによる予測効率の変化を見るために, 入力データは, 以下の 3 つに分けて実験を行った.

ケース 1: 太陽風データのみ

電子フラックス, 太陽風速度,  $B_z$ ,  $\Sigma_e$ , UT

ケース 2: 地上データのみ

電子フラックス, UT,  $D_{st}$ , AE,  $\Sigma_{D_{st}}$

ケース 3: 太陽風データと地上データの組み合わせ

電子フラックス, 太陽風速度, UT,  $D_{st}$ , AE

図 3, 図 4, 図 5 に入力を太陽風データのみ, 地上データのみ, 組み合わせデータとした中間層の層数とニューロン数の変化による PE の変化を示す. なお, これらの図において, 縦軸が中間層の層数, 横軸がニューロン数であり, 予測効率は図中の領域で表される. また, これらの図においては, 中間の値が直線補間されていることに注意が必要である. 図 6, 図 7, 図 8 にそれぞれの入力に対する予測効率が最高時の相関図を示す. 縦軸が実測値, 横軸が予測値として, プロットしたものである. 直線にプロットが一致すれば, 実測値と予測値が一致しているといえる.

ケース 1 のように入力に太陽風データのみを用いた場合, 図 3 においてニューロン数が 1 であれば中間層数が増えたとしても, およそ 0.520 と一定の値をとっている. それに対しニューロン数が 10 である場合には, 中間層が増えるにつれて効率は上がるのではなく上下している. この結果は, 単にニューロン数を増やしただけでは, 良い結果は得られないことを示している. また, ニューロン数が 5 付近の値であれば, この入力に対する比較的良い予想効率が得られている. なお, この入力に対する最も良い予測効率は, 0.561 でニューロン数が 5, 中間層数が 2 のときである. また, 図 6 では, 電子フラックスが高いほど, 相関係数が高くなる傾向が見られる.

ケース 2 のように入力に地上データのみを用いた場合, 図 4 において, どのニューロン数に対して層数を増加しても, 予測効率は変化していない. ケース 1 と比較すると, 予測効率は安定しているが, 効率は全体として低いと言える. なお, この入力に対する最も良い予測効率は, 0.526 でニューロン数が 4, 中間層数が 3 のときである. また, 図 7 より, ケース 1 と同様に電子フラックスが高いほど, 相関係数が高くなる傾向が見られるが, 太陽風データのみの場合ほど一致はしていない. これらの結果より, 入力に地上データのみを用いるだけでは, 高エネルギー電子を予測するのに不十分であると考えられる.

ケース 3 のように入力に太陽風データと地上データを組み合わせて用いた場合, 図 5 において, 入力データをそれぞれ組み合わせることで, 予測効率は急激に改善された. また, 層数が少ない場合においては, ニューロン数を増やすことにより予測効率は改善されていくが, 層数が多い場合はあまり改善されていない. 図 8 において, 電子フラックスが低い場合はあまり相関がないが, 高い場合は予測値と実測値がよく一致している. また, この入力に対する最も良い予測効率は 0.609 でニューロン数が 9, 中間層が 1 のときであるが, ニューロン数が 5 以上で, 層数が少なければ予測効率は大きく安定している. つまり, 24 時間後の予測をする際には, 入力として太陽風と地上のデータの組み合わせを用い, 中間層のパラメータは, ニューロン数が 5 以上で層数を少なくすることでより良い結果を期待できる.




図3 ケース1の層数・ニューロン数・PEの関係




図6 ケース1の相関図

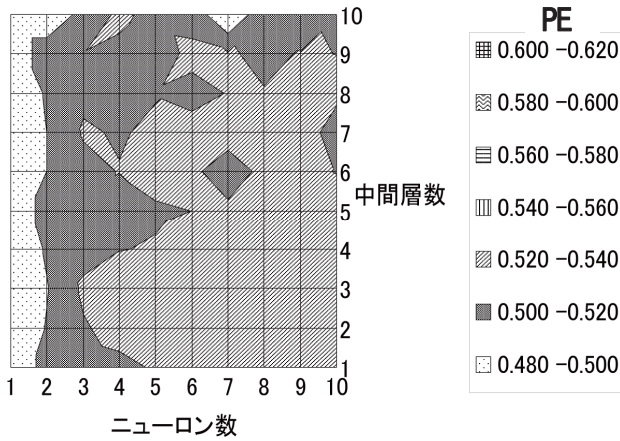


図4 ケース2の層数・ニューロン数・PEの関係

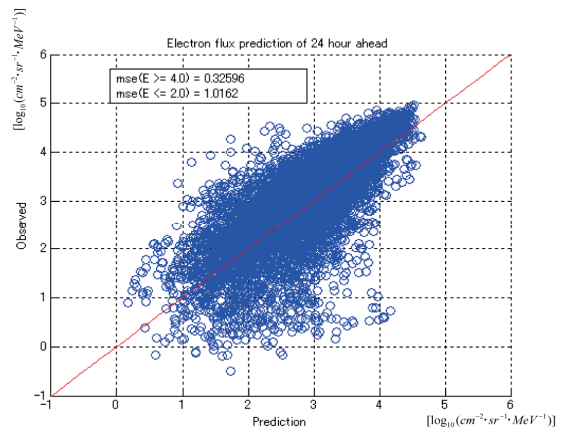


図7 ケース2の相関図

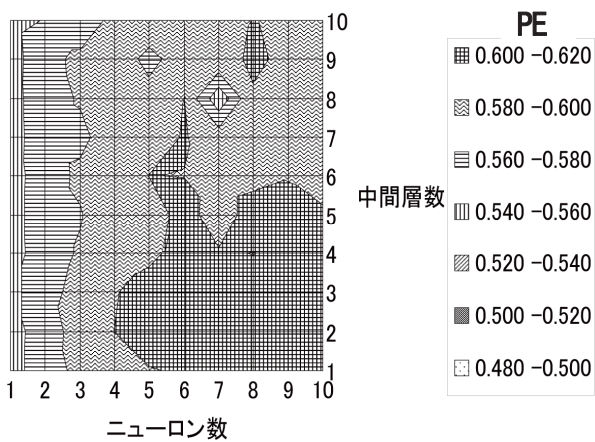


図5 ケース3の層数・ニューロン数・PEの関係




図8 ケース3の組み合わせたものを用いた相関図

以上より、予測効率を改善するためには、入力データとして電子フラックス、太陽風速度、UT、Dst、AEの5入力を用い、中間層数を4層以下、ニューロン数を5個以上にする必要がわかった。そこで、入力データの内、どのデータの影響が大きいのか明らかにすることで、物理過程解析の手助けになるのではないかと考えられるため、ニューラルネットワークの重み・閾値の視覚化を行った。解析を簡単にするために、中間層数を1、ニューロン数を6として解析を行った。ネットワーク構造を図9に示す。




図9 視覚化ネットワーク構造

まず、単純に視覚化した重みを図10に示す。各丸がニューロンを表し、その丸の中にかかれている値が閾値である。ニューロン間を結ぶ直線がそれぞれの重みを表している。また、線の色、線の種類により、重みの値を区別し、実線が正の値を示し、点線が負の値を示している。また、線の色は絶対値により分類され、1.0以上の値を赤、0.8~1.0の値をオレンジ、0.6~0.8を緑、0.4~0.6の値を青、0.2~0.4の値を紫、0.0~0.2の値を黒とした。なお、この図は、重み・閾値の初期値を0.5と設定した場合である。

図10からだけでは、ニューロン間の関係の解析が困難なため、1つのニューロンに対するそれぞれのシナプスの重みを規格化することによって、そのニューロンに対する寄与率を定義することで、ニューロン間の関係をより明確なものとするにことにした。ここで規格化とは、各ニューロンに対して入ってくる入力の重みの絶対値の合計を算出し、任意の重みに対して割ることで、順位付けを行うことをいう。そのように、規格化したものから、寄与率の高い上位3位までを抽出したものが、図11である。図11においても、各丸がニューロンを表し、丸の中の値が閾値を表している。図10と異なる点は、線の色により、規格化した場合

の重みの重要度を表している点である。重要度の高いものから順に、1番のものを赤、2番のものをオレンジ、3番のものを緑、4番のものを青、5番のものを黒、6番のものを線なしとして、分類した。

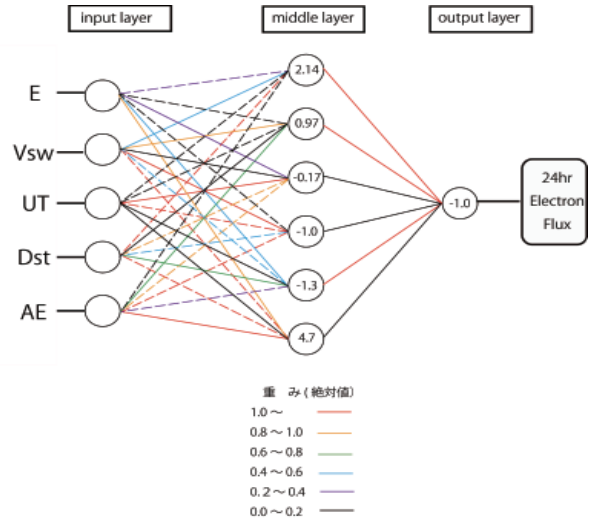


図10 生データの視覚化

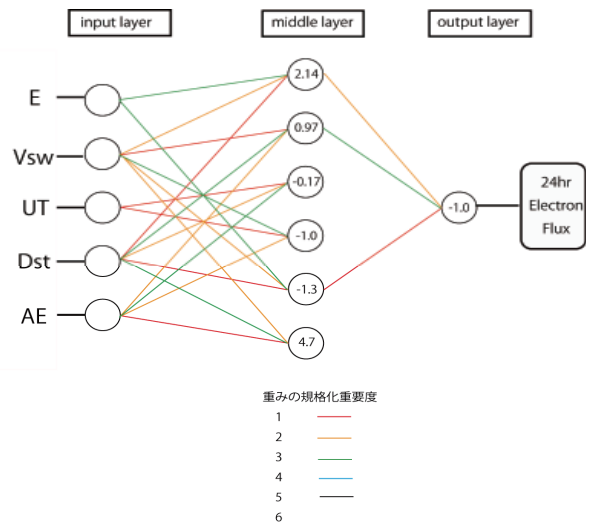


図11 規格化データの上位3位まで視覚化

図11より、出力に大きく影響しているのは、中間層1, 2, 5である。それぞれのニューロンを個別に見ていくと、ニューロン1ではDst, Vsw, Eの寄与が大きいことがわかる。また、ニューロン2であれば、Vsw, AE, Dst, ニューロン5であれば、Dst, Vsw, Eの寄与が大きい。よって、出力に大きく影響を与えているパラメータは、Dst, Vswであると考えられる。

## 6. 結 言

本研究では、ニューラルネットワークを用いた静止軌道における高エネルギー電子フラックスの予測精度の向上のため、入力データ、中間層のパラメータについて実験を行った。そして、そのようにして得られたネットワークに対し構造解析を行い、以下のような結果が得られた。

- (1) 太陽風データと地上データを組み合わせた入力を用いた場合、太陽風データのみや地上データのみを入力として用いた場合と比較して予測精度が向上した。本研究で用いた、電子フラックス、太陽風速度、UT、Dst、AE の組み合わせが良いことがわかった。
- (2) 入力として太陽風データと地上データの組み合わせを入力データとしたネットワークに対する中間層のパラメータとして、ニューロン数は 5 以上、中間層は 4 までの簡単な構造であれば高精度となることがわかった。また逆に複雑な構造であれば、予測精度は悪くなる。
- (3) 構造解析を行った結果、結果に大きく寄与しているパラメータは、Dst、Vsw であることがわかった。これにより、過去の研究より知られていた、太陽風速度が電子フラックスの増大に効いているということが確認でき、また、地上データの内、AE 指数よりも Dst 指数の方が、寄与が大きいこともわかった。

以上のことから、太陽風データと地上データの組み合わせることによって、太陽風データのみ、地上データのみを用いた場合と比較し、予測精度が大きく向上し、入力データの中で Dst、Vsw の寄与が大きいことが明らかになった。

今後、磁場データなどを加えた場合におけるデータの寄与について解析を行う予定である。

## 7. 謝 辞

アメリカ海洋大気局 (National Oceanic and Atmospheric Administration, NOAA) より、衛星 GOES10 で観測された高エネルギー電子フラックス (>2MeV) データ、NASA より太陽風データを提供いただいた。また、京都大学院理学研究科附属地磁気世界資料解析センターより、Dst 指数、AE 指数のデータを提供いただいた。

## 参考文献

- (1) 亘慎一・徳光正弘・北村健太郎・石田好輝, ニューラルネットワークによる静止軌道の高エネルギー電子フラックス予測について, 信学技報 SANE2007-83(2007)
- (2) 山田弘善・笠井鯉太郎・藤井治久, 人工衛星と帯電現象, 電気学会雑誌, (1984)
- (3) 恩藤忠典・丸橋克英, 宇宙環境科学, オーム社 (2000)
- (4) 古賀清一・越石英樹・松本晴久・五家建夫・小原隆博, 放射線帯電子の変動予測, 宇宙航空研究開発機構特別資料 JAXA-SP-05-024 (2006)
- (5) M. Fukata・S. Taguchi・T. Okuzawa・T. Obara, Neural network prediction of relativistic electrons at geosynchronous orbit during the storm recovery phase: effects of recurring substorms, Annales Geophysicae 20:947-951 (2002)
- (6) 吉富康成, ニューラルネットワーク, 朝倉書店 (2002)