

ニューラルネットワークによる太陽風物理量を用いた 地磁気擾乱指数の予測

北島 良三^{*1}, 野和田 基晴^{*2}, 上村 龍太郎^{*3}

Prediction for Geomagnetic Disturbances with the Solar Wind Parameters
Based on Neural Computational Technique

Ryozo Kitajima^{*1}, Motoharu Nowada^{*2}, Ryotaro Kamimura^{*3}

ABSTRACT : We try to determine what solar wind parameter has an impact on the geomagnetic disturbance based on neural computational method “potential learning (PL)”. In our previous study, using the PL method, the clock angle, which is the angle between the dawn – dusk (B_y) and north – south (B_z) components of solar wind magnetic field, was extracted as the most significant parameter to disturb the geomagnetic field. However, that result included a little uncertainty due to redundancy of parameters. Therefore, we scrutinize the solar wind parameters to evaluate with the PL method, and retry to extract the parameters to provide an impact on geomagnetic disturbances. We could find that the clock angle, solar wind dynamic pressure and number density impinged on magnetospheric disturbances. These parameters are important in considering geomagnetic disturbances. Our result suggests that the potential learning method is very useful tool to study the solar wind-driven geomagnetic disturbances.

Keywords : geomagnetic disturbances, solar wind, space weather, potential learning, neural networks.

(Received October 31, 2017)

1. はじめに

本研究はニューラルネットワークを用いて地磁気擾乱指数の予測を試みたものである。地球には常に太陽から「太陽風」と称される高エネルギープラズマ流が吹き付けている。太陽風は太陽表面で起こる爆発現象である「太陽フレア」に伴って発生することがあるが、この場合、人工衛星の搭載機器に影響を与えるだけでなく、地上電力網といったインフラ設備にも甚大な影響を与えてしまう脅威を有している。しかし、太陽風によって常に設備損傷の危機に曝されている訳ではない。これは地球を取り巻く磁気圏が太陽風エネルギーの流入を阻止しているからであ

る。

地球を磁石に見立てた場合、北極側にS極、南極側にN極が存在していると言えるが、これにより北向きの磁場が地球を取り囲むことになる。この磁場の範囲は太陽風が吹き付けてくる昼側で地球半径の約 10 倍、夜側に至っては 1000 倍近くにまで達しており、広大な範囲で太陽風の脅威から地球を保護している。しかし、太陽風エネルギーの 100%を流入阻止することは不可能であり、太陽風が磁気圏内に流入する過程あるいはその結果として地球磁場が乱される（磁気擾乱）。極地方でオーロラが広がるのが観測されるのはこのためである。記録によると 1770 年には京都でオーロラが観測されたというが、近年の研究でこれは史上最大規模の太陽フレアの影響であったことが報告されている [1]。

太陽風により引き起こされる磁気擾乱（「磁気嵐」と呼ばれる現象）であるが、大規模なものでなければ地上設備に特に影響は発生しない。ところが大規模太陽フレア

*1 : 情報科学科 助教 (r-kitajima@st.seikei.ac.jp)

*2 : 山東大学 威海校 空間科学研究院
空間天気物理と探測研究中心

*3 : 東海大学 情報教育センター

によって発生した太陽風が地球を直撃した場合、地球磁場を大きく乱し、地上施設に影響が起きてしまう。1989年にはカナダのケベック州で大規模な停電が生じたが、これは磁気擾乱により引き起こされたものである [2]。最近では 2017 年 9 月 6 日の大規模太陽フレアが記憶に新しい。この太陽フレアは大規模であり、GPSや無線通信に影響を及ぼす可能性が警戒され [3]、実際GPSの誤差が増大していたことが国土地理院より報告されている [4]。

このように磁気擾乱は地上の電磁場環境に影響を与えるため、太陽フレアの規模から擾乱の度合いを予測することは重要な研究である。磁気擾乱に関する研究はこれまでにいくつも行われており、Balan らは地上磁場の変動から推定した地磁気変動データと、人工衛星で計測された太陽風磁場、太陽風速度、そしてプラズマ数密度のデータを用いて、どの程度の太陽風磁場およびプラズマ変動が、どのくらいの規模の地磁気擾乱を引き起こすのか予測している [5]。また近年は機械学習の手法も取り入れられており、Shin らは静止軌道衛星が常に晒されている高エネルギープラズマ粒子の増減を、太陽風データと静止衛星が観測した電子エネルギーデータを基にニューラルネットワークを用いて予測している [6]。

また、宇宙空間物理の分野だけではなく地球超高層の電離層物理分野でもニューラルネットワークを用いた解析が行われ始めている [7][8]。このように知的情報処理手法が解析に取り入れられてきているのは、データが複雑で従来の手法では対応が困難であるためと考えられる。著者らも以前の研究 [9] で統計的手法による予測結果がニューラルネットワークによる予測結果と比較して高くないことを確認している。しかし、一般的にニューラルネットワークは複雑データの解析が可能でも、モデルの解釈が困難であることが知られており、予測根拠の抽出を要する解析での使用は困難である。

本研究では磁気擾乱度合いの予測に加え、擾乱に影響を及ぼす太陽風パラメータを特定することも目的としている。そこで解析手法には、解釈が可能な「潜在学習」と呼ばれるニューラルネットワークを用いた。著者らの以前の研究 [9] においても潜在学習は採用され、予測精度、解釈結果ともに従来手法による結果よりも良い結果を得た。しかし、この研究で使用したデータには冗長性があり、解釈を詳細に実施することができなかった。そこで本研究では解析変数を見直し解析を行った。また、前回結果との差異も確認し解釈結果の安定性も調査した。

2. 解析データと解析手法

2.1 解析データ

本研究で解析対象としたデータは、人工衛星「ACE」と「WIND」によって観測された太陽風磁場データとプラズマデータであり、座標系はGSE座標系である。この2つのデータを用いて地球磁気圏擾乱指数 (AL指数) の予測を行う。データは全てアメリカ航空宇宙局 (National Aeronautics and Space Administration, NASA) Goddard Space Flight CenterのWebページ [10] より入手した。

入手したデータはSt. Patrick Stormと呼ばれる大規模磁気嵐が発生した 2015 年 3 月 17 日 0 時 00 分 (Universal Time, UT (日本標準時-9 時間)) から 23 時 59 分の 1 分値データである。研究ではこのデータのうち、特に磁場が乱れた 12 時 30 分から 23 時 59 分を解析対象とした。解析対象区間のAL指数を図 1 に、これを予測するのに使用した太陽風パラメータを表 1 に示す。以前の研究 [9] を実施した際は表 1 に「 M_A (太陽風アルフベンマッハ数)」、「 θ_{Cone} (太陽風コーン角)」、「 θ_{Clock} (太陽風クロック角)」の 3 変数を加えた合計 10 変数を用いていた。しかしこれらは表 1 の変数より算出できる項目であり、今回それらを取り除き表 1 記載の 7 変数による解析を行

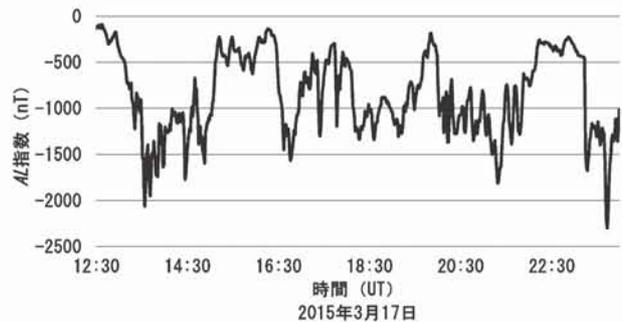


図 1 解析対象区間のAL指数

表 1 使用した太陽風パラメータ

変数番号	変数名	単位
1	Bx (磁場X (太陽地球) 成分)	nT
2	By (磁場Y (朝夕) 成分)	nT
3	Bz (磁場Z (南北) 成分)	nT
4	Vx (太陽風速度)	km/s
5	Np (プラズマ数密度)	/cm ³
6	Pdyn (太陽風動圧**)	nPa
7	Ey (太陽風電場***)	mV/m

*近似的に東西成分

** $p_{dyn} = mN_p V_x^2$

*** $E_y = -V_x B_z$

った（太陽風動圧、太陽風電場も算出できる項目であるが、磁気擾乱を理解するうえで重要な項目であるため解析に取り入れている）。

2. 2 解析手法

本研究ではAL指数の予測に加え、予測に使用した太陽風パラメータのどの項目が予測に影響を与えているのか解釈を行っていく。そのため一般的なニューラルネットワーク手法ではモデル解釈が困難 [11] であるため、潜在学習 (Potential Learning, PL) と名付けられた新しいニューラルネットワーク [12] を解析に用いる。

潜在学習の概要を図 2 に示す。潜在学習には多数のバリエーションがあるが、本研究で使用する潜在学習は、知識獲得段階（自己組織化マップが基となっている）と予測段階（多層パーセプトロンが基となっている）の二段階の学習より構築されている。一段階目の学習はデータから知識を獲得する段階であり、ここで潜在性（後述する）を算出し、予測に向けた事前学習を行う。二段階目の予測段階は、一段階目で得た知識を初期重みとして用いターゲットを予測する。初期重みに一段階目の知識を使用することで、データに基づいた学習を期待している。

潜在性とは分散を基に算出される値であり、潜在性の高いニューロンとは学習時に活発に活動するニューロンと定義されている。活発に活動するとはすなわち、重要なニューロンの意味である。入力層k番目のニューロンの潜在性 ϕ_k^r は(rについては後述する)、k番目ニューロンの分散 V_k を用いて

$$\phi_k^r = \left(\frac{V_k}{\max_{k=1, \dots, K} V_k} \right)^r$$

により求められる。ここでパラメータrは算出される潜在性を強調する働きを持ったパラメータである。算出された潜在性は知識獲得段階で活用されるが、この段階は自己組織化マップが基となった学習段階である。自己組織化マップはその学習過程で、入力層のニューロンと出力層j番目ニューロンとの距離 d_j をj番目ニューロンとk番目ニューロン間の重みである $w_{j,k}$ を用いて

$$d_j = \sqrt{\sum_{k=1}^K (x_k - w_{j,k})^2}$$

により求める過程があるが、潜在学習ではこの過程に潜在性を組み込み

$$d_j = \sqrt{\sum_{k=1}^K \phi_k^r (x_k - w_{j,k})^2}$$

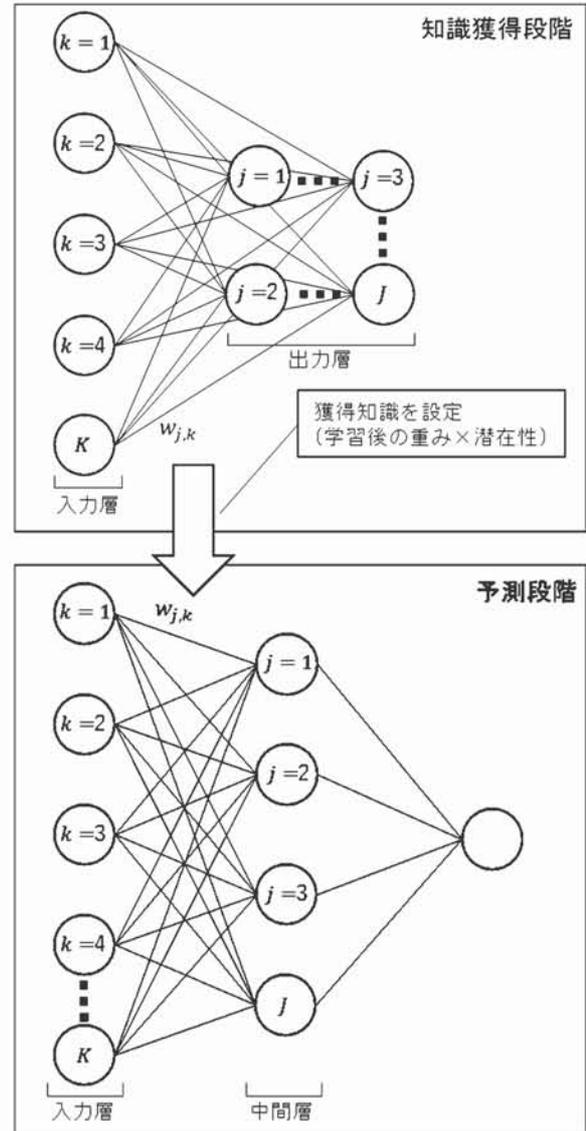


図 2 潜在学習概要

により距離を求めている。すなわち潜在性によって重み付けて距離を算出する。これにより、潜在性が高い（重要な）ニューロンを積極的に取り込み学習をおこなっていく。

潜在学習はこれまで、スーパーマーケットのPOSデータに対する適用 [13]、災害発生時のTweetに対する適用 [14]、などでクラス分け問題に使用され、高精度な分類予測やモデル解釈結果の妥当性が確認されてきたが、以前の研究 [9] そして本研究では数値予測に適用し、予測精度、解釈結果について調査している。

3. 結果と考察

3. 1 AL指数の予測

本研究では潜在学習を用いて磁気擾乱指数 (AL指数) を予測した。予測には前述した 2015 年 3 月 17 日 12 時

30分から23時59分のデータ(690サンプル)を使用しているが、このデータより異常値を取り除いた498サンプルが実際の解析対象となった。またモデル作成にはこの498サンプルの85%にあたる数が使用され(うち15%は予測段階の早期停止用に使用)、のこり15%がモデル精度確認用に使用されている。さらに、偶然良いサンプルがモデル作成に使用されることを防ぐ目的で、各用途の比率はそのまま、サンプルがランダムに異なる10パターンのデータを作成、それぞれでモデル作成と精度確認を行った。後述する予測精度はこの10個のモデルによる精度の平均値である。また予測精度の評価には実測値と予測値の相関係数を用いた。

潜在学習によりAL指数を予測したところ、予測精度0.8433の精度で予測ができた(前述のパラメータrは1)。また、本研究では比較のために潜在学習による予測に加え、回帰分析、一般的なニューラルネットワークによる予測も行った。その結果、回帰分析は予測精度0.5582、一般的なニューラルネットワークは予測精度0.8152という結果であり、「回帰分析ではAL指数の予測は困難である」という結果を、「一般的なニューラルネットワークよりも潜在学習の方が高精度である」という結果をそれぞれ得た。これは潜在性の高い入力ニューロンを重視して学習する知識獲得段階と、予測段階の初期重みに獲得知識を用いることが期待通り作用している結果と考えられる。

3.2 モデル解釈

3.2.1 潜在学習による予測結果の解釈

続いてAL指数の予測に用いた太陽風パラメータのうち、どの項目が予測に影響を与えているのかモデル解釈を行った。図3は潜在性を示したものである。この図より潜在性の高い変数上位5つを見ると、最も潜在性の高い変数はBy(磁場Y成分)であること、続いてPdyn(太陽風動圧)、Np(プラズマ数密度)、Bz(磁場Z成分)、そしてVx(太陽風速度)であることが分かる。これらのパラメータ値についてモデル作成用データ10パターンそれぞれで平均値を求め、さらにそれらの平均値を求めたところ表2に示す結果を得た。これらの値であるが、By成分の大きさ(絶対値)はBz成分のそれに比べて小さく、PdynおよびNpは平均的な太陽風動圧(1.0 nPa~2.0 nPa程度)、平均的な数密度(2.0/cm³~5.0/cm³)より高いことが分かる。また、平均的な太陽風速度が400 km/sから500 km/sであることを考慮するとVxの値は特別速い速度ではないことをそれぞれ得た。

モデル解釈はByが重要度1位となっていることから、

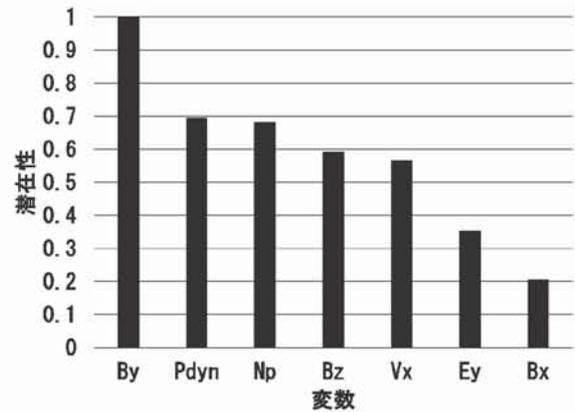


図3 潜在学習によるモデル解釈

表2 重要変数の平均的な値

変数	平均値	単位
By	0.4430	(nT)
Pdyn	6.5648	(nPa)
Np	12.2990	(/cm ³)
Bz	-16.2771	(nT)
Vx	-556.9299	(km/s)

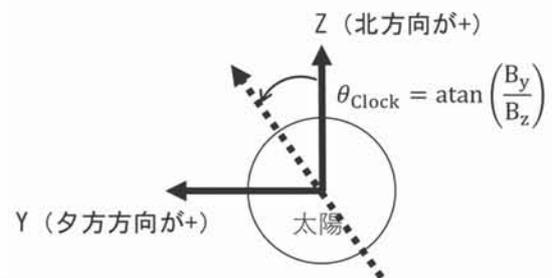


図4 クロック角(単位: deg.)

磁場データから行っていく。太陽風の磁場がどの角度で地球に到達しているのかを調べるため、クロック角(θ_{Clock})を求めた。図4に示すように θ_{Clock} は磁場のBz成分(南北成分)とBy成分(朝夕成分)のなす角である。これはクロック角が0度であると、真北を向く磁力線を意味している。表2を求めた際と同様にクロック角の10パターン平均の平均を求めたところ、 θ_{Clock} は184.8222度という結果であった。これはすなわち、ほぼ南向きの磁力線が地球と邂逅していたことを意味している。

続いてプラズマデータの解釈を行う。太陽風動圧は表1に示すとおり、プラズマ数密度(Np)と太陽風速度(Vx)、そして陽子の質量(m)を用いて算出される。表2より、今回観測された太陽風は平均的な太陽風より高い数密度と、ほぼ平常的な太陽風速度であることが確認されている。したがって動圧が高くなっている理由は数密度にあ

ると判断される。このことより、磁気擾乱には太陽風速度よりも数密度が影響を及ぼしていることを示唆しており、それを裏付けるかのようにVxの重要度は第5位に留まっている。

最後に磁気データがプラズマデータよりも重要であるという結果の解釈を行う。今回得られた結果であるが、これは磁気擾乱が磁気リコネクション [15] [16] [17] [18] により発生していることを示唆している。太陽エネルギーが地球磁気圏に流入するためには磁気バリアを破る必要があるが、その主な機構は「磁気リコネクション」である。

磁気リコネクションとは2つ以上の異なる磁場配位にある磁力線が互いに結びつく現象である。エネルギーを有しているプラズマ粒子は通常、磁力線の周りを運動している。そして通常、太陽風磁場と地球磁場が接触または近づいたとしてもプラズマが互いの磁力線に移動することはない。したがって太陽風エネルギーを有するプラズマが地球磁気圏に侵入する（あるいは地球磁気圏のプラズマが太陽風へ逃げ出す）ことは通常できない（磁場凍結の原理）。しかしひとたび磁気リコネクションが発生するとこの磁場凍結の原理が破れ、太陽風磁場と地球磁場が結びつき、プラズマが互いの領域に磁力線を伝い移動することができるようになる。その結果、太陽風エネルギーの地球磁気圏への流入が生じる。この磁気リコネクションの発生には互いの磁場配位が異なる必要があり、地球磁気圏の磁力線がほぼ南向きであることを考えると、太陽風磁場が南向きかそれに近い方向であれば磁気リコネクションが生じやすい状況になることが期待される。今回解析した大規模磁気擾乱の発生に対応する太陽風磁力線の向きは強い南向き（184.8222度）であることから、磁気リコネクションを生じさせる条件を満たしていることになる。

以上の解釈より、磁場およびプラズマデータから擾乱予想を行った結果、重要変数として磁場に関する変数が重要度1位で抽出できた本結果は妥当性のある結果と言える。しかし、磁気擾乱を生じさせる太陽風磁場配位の第一条件が「南向きの磁力線」である点を考えるならばBz成分がBy成分よりも重要となるのではないかと考えられる。ところが解析結果はByの方が重要であることを示していた。また成分を詳細に追うことによりByが弱くBzが強いということが分かったが、これは潜在学習がByが弱いことを重要視して学習を行っているという表現で、興味深い動作である。このことはすなわち、Bzは強い南向きを示しており磁気擾乱をもたらす本質的な太陽風パラメータであることを表す一方、By成分もまた地球

磁気圏擾乱をもたらす重要な太陽風パラメータの1つであると解釈することができる。

また今回は重要度5位までを解釈したため、解釈対象とならなかったが、太陽風電場の解釈も今後の課題である。太陽風電場は太陽風の磁気エネルギーの輸送率を示すものである。したがって解析前の予想として重要変数は、太陽風の向き、太陽風電場、プラズマ、の順となることが予想されたが、解析により、太陽風の向き、プラズマ、太陽風電場、の順という結果を得た。磁気エネルギーの輸送率はダイポール双極子軸の傾きによる依存性を考慮する必要があると考えられ、太陽風電場の解釈は今後の課題である。

3. 2. 2 回帰分析による予測の解釈

最後に潜在学習との比較で実施した回帰分析による擾乱予測の解釈を行う。図5は10個の回帰モデルの偏回帰係数の平均を示したものである。これによると最もAL指数に影響を及ぼしている変数はPdyn（太陽風動圧）続いてNp（プラズマ数密度）であることが分かる。Vx（太陽風速度）やEy（太陽風電場）などは小さい係数となっていることから、今回PdynとNpを解釈の対象とした。

PdynとNp、すなわち太陽風プラズマデータが磁場データと比べると大きな係数を持っていることは、プラズマデータの方が重要であることを示している。たしかに、太陽風の動圧が大きい場合、あるいはプラズマ数密度が大きい場合（結果として動圧が増大する場合）でも磁気圏擾乱が起こりえる。しかし解析対象のSt. Patrick Stormで観測されたような大規模な磁気圏の擾乱を引き起こしたのは、太陽風磁場と地球磁気圏磁場の磁場がほぼ真反対な磁場配位から考えて、昼側磁気圏境界域で発生した磁気リコネクションが優勢であると考えられる。したがって、磁場成分よりもプラズマデータが重要であるという解釈結果は物理的に妥当性がないと言える結果であった。

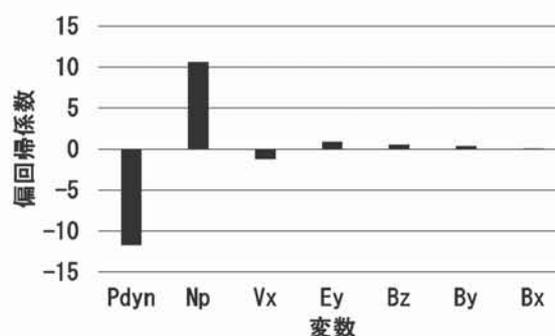


図5 回帰分析によるモデル解釈

4. まとめ

本研究では、太陽風磁場とプラズマデータから成るデータを入力とし、磁気擾乱の指数であるAL指数を出力するモデルの作成を潜在学習により試みた。潜在学習による磁気擾乱指数の予測精度は実測値と予測値の相関係数で評価し、0.8433の精度であった。またモデル解釈の結果、擾乱には太陽風磁場の向き、プラズマ動圧、プラズマ数密度が特に影響しているという結果を得た。この結果は物理的に妥当性のある結果であり、太陽風による磁気擾乱という複雑なデータの解析に潜在学習が適用できることを確認した。

しかし解析に使用した太陽風パラメータのうち、太陽風電場の解釈について課題が残り、継続した研究が必要である。引き続き研究を行うとともに、また、得られた解釈結果が2015年の大規模擾乱イベント以外でも得られるのか調査し、磁気擾乱の理解を深めていく。

参考文献

- [1] Ryuho Kataoka and Kiyomi Iwahashi, "Inclined Zenith Aurora over Kyoto on 17 September 1770: Graphical Evidence of Extreme Magnetic Storm", Space Weather, Online Version of Record published before inclusion in an issue, 2017, DOI: 10.1002/2017SW001690
- [2] 一政祐行, "ブラックアウト事態に至る電磁パルス (EMP) 脅威の諸相とその展望", 防衛研究所紀要, Vol.18, No.2, pp.1-21, 2016.
- [3] 情報通信研究機構, "通常の 1000 倍の大型太陽フレアを観測", 2017 年 9 月 7 日プレスリリース, <http://www.nict.go.jp/press/2017/09/07-1.html> (閲覧日:2017 年 10 月 24 日)
- [4] 国土地理院, "9 月 6 日に発生した太陽フレアの GPS 測位への影響 (速報)", 2017 年 9 月 11 日報道発表資料, <http://www.gsi.go.jp/denshi/denshi40001.html> (閲覧日:2017 年 10 月 24 日)
- [5] N. Balan, Y. Ebihara, R. Skoug, K. Shiokawa, I. S. Batista, S. Tulasi Ram, Y. Omura, T. Nakamura and M. - C. Fok "A scheme for forecasting severe space weather", Journal of Geophysical Research: Space Physics, Vol. 122, Issue 3, pp. 2824-2835, 2017.
- [6] Dae - Kyu Shin, Dae - Young Lee, Kyung - Chan Kim, Junga Hwang and Jaehun Kim "Artificial neural network prediction model for geosynchronous electron fluxes: Dependence on satellite position and particle energy", Space Weather, Vol. 14, Issue 4, pp. 313-321, 2016.
- [7] R. Athieno, P. T. Jayachandran and D. R. Themens "A Neural Network based foF2 model for a single station in the polar cap", Radio Science, Vol.52, Issue 6, pp.784-796, 2017, DOI: 10.1002/2016RS006192
- [8] D. Sur, S. Haldar, S. Ray, A. Paul "Response of data driven Artificial Neural Network based TEC models to neutral wind for different locations, seasons and solar activity levels from the Indian longitude sector", Space Physics, Vol.122, Issue 7, pp.7713-7733, 2017, DOI: 10.1002/2016JA023678
- [9] 北島良三, 野和田基晴, 上村龍太郎, "ニューラルネットワークによる太陽風物理量を用いた地磁気擾乱指数の予測 (第一報)", 第 33 回ファジィシステムシンポジウム講演論文集, pp.743-748, 2017.
- [10] Coordinated Data Analysis Web (CDAWeb), Space Physics Data Facility, Goddard Space Flight Center, National Aeronautics and Space Administration, <https://cdaweb.sci.gsfc.nasa.gov/index.html/> (閲覧日:2017 年 3 月 20 日)
- [11] 岩崎学, "データマイニングと知識発見 -統計学の視点から-", 行動計量学, Vol.26, No.1, pp.46-58, 1999.
- [12] Kamimura Ryotaro, "Collective mutual information maximization to unify passive and positive approaches for improving interpretation and generalization", Neural Networks, Vol. 90, pp. 56-71, 2017.
- [13] 北島良三, 遠藤啓太, 上村龍太郎 "入力ニューロンの潜在性に着目した小売店店舗の非継続来店顧客検知モデルの作成", オペレーションズ・リサーチ, Vol.61, No.2, pp.88-96, 2016.
- [14] Ryozo Kitajima, Ryotaro Kamimura, Osamu Uchida and Fujio Toriumi "Identifying Important Tweets by Considering the Potentiality of Neurons", IEICE TRANSACTIONS on Fundamentals of Electronics, Communications and Computer Sciences, Vol.E99-A, No.8, pp.1555-1559, 2016.
- [15] E. N. Parker, "Sweet's Mechanism for Merging Magnetic Fields in Conducting Fluids", Journal of Geophysical Research, Vol.62, No.4, pp.509-520, 1957.
- [16] P. A. Sweet, "The Neutral Point Theory of Solar Flares", The International Astronomical Union (IAU) Symposium, Vol.6, pp.123-134, 1958.

- [17] J. W. Dungey, "Interplanetary Magnetic Field and the Auroral Zones", PHYSICAL REVIEW LETTERS. Vol.6, No.47, 1961,
DOI: <https://doi.org/10.1103/PhysRevLett.6.47>
- [18] H. E. Petschek, "Magnetic Field Annihilation", Proceedings of the AAS-NASA Symposium, pp.425-439, 1964.