

パッチ切り取りを用いた宇宙自然電波の特性周波数検出の改善 Improvement of Characteristic Frequency Detection of Natural Plasma Waves Using Patch Cutout

益本 英明[†]
Hideaki Masumoto

長谷川 達人[†]
Tatsuhito Hasegawa

松田 昇也[‡]
Shoya Matsuda

1. はじめに

宇宙惑星科学の分野では、宇宙の自然電磁波計測を通じて惑星環境を理解する取り組みが進められている。宇宙環境の中でもプラズマ密度は重要な特性の一つであり、広域混成共鳴放射周波数 (UHR 周波数) の測定により、定量的にプラズマ密度を算出する手法が用いられている。そのため、観測データから UHR 周波数を精度よく決定することが重要となる。

UHR 周波数は観測されたプラズマ波動のパワースペクトルから検出することができる。UHR 周波数検出は目視でも行うことができるが、例えばあらせ衛星で観測される電界パワースペクトルの時間分解能は 8 秒~1 分程度であり、数年間に渡って連続観測されたデータをすべて処理するためには莫大な時間を要する。また、観測されたパワースペクトルには人工的なノイズが加わり、目視での検出が困難になる場合がある。図 1 に、あらせ衛星のプラズマ波動・電場観測器 (PWE) [1] の高周波分析器 (HFA) [2] によって観測された 2 つのパワースペクトルと UHR 周波数の例を示す。図のパワースペクトルはそれぞれ縦軸が周波数、横軸が時間であり、色で観測された電界パワースペクトル密度を表している。例えば、図 1 左は比較的目的で検出しやすい例であり、図 1 中央の UHR 周波数を図 1 左から目視で判別しやすい。一方、図 1 右では、様々なプラズマを同時観測していることや計測ノイズの影響により、目視での UHR 周波数検出が困難となる。このような、ノイズを含み、推定が困難なデータに対しても推定を行い UHR 周波数の導出を行う必要がある。上の問題から UHR 周波数検出では、膨大なデータに対する効率的な検出とノイズへの頑健性が求められる。本研究では、既存の深層学習を用いた UHR 周波数検出アルゴリズムを改良し、入力データに対する窓関数を用いた重み付け処理およびパッチ切り取りを用いた UHR 周波数検出モデルを提案する。パッチ切り取りでは、元データであるプラズマ波動のパワースペクトルに対し、時間軸、周波数軸の双方で領域分割を




図 1 目視による検出が可能なデータ (左),
左図の UHR 周波数 (中央),
目視による検出が困難なデータ (右)

行ったものを入力データとする。入力のパッチ化により、従来手法と比べ狭い時間周波数空間の情報から UHR 周波数の推定を行うことになる。したがって、推定難易度は高くなるが、時間周波数方向にゆらぎを持った訓練データを構築できる事になり、ノイズや未知のデータに対する頑健性が向上する効果を期待する。本研究の貢献は以下 2 点である。

1. 窓関数を導入することによる推定精度の向上
2. パッチ切り取りの導入によるノイズなどによって検出が困難であるデータに対する検出の実現

2. 先行研究

UHR 周波数の検出手法は数多く提案されている。熊本ら[2] は人の目視検査による補正を伴う UHR 周波数の半自動検出アルゴリズムを提案した。このアルゴリズムの問題点として、人間の作業量が多い点が挙げられる。そのため、UHR 周波数の検出をより効率的に行うことが求められる。より効率的な UHR 周波数の検出手法として、近年様々な分野で応用されている深層学習を用いたものがいくつも提案されている。Kurth ら[3] は UHR 周波数を自動的に決定する広域混成共鳴検出アルゴリズム (AURA) を提案した。また、Zhelavskaya ら[4] はニューラルネットワークの一つである Multi Layer Perceptron (MLP) による UHR 周波数の自動決定アルゴリズムを提案した。このモデルでは、プラズマ波動のパワースペクトルと 5 つの特徴量を用いて UHR 周波数の検出を行っている。長谷川ら[5] はコンピュータビジョンの分野で高い成果を挙げている Convolutional Neural Network (CNN) による UHR 周波数の自動決定アルゴリズム提案し、先行事例の MLP モデルよりも高い精度を達成した。近藤ら[6] は UHR 周波数の時間連続性に着目し、連続した時間幅を用いた 2 次元 CNN モデルを提案している。このモデルでは、複数時刻を入力として用い、その区間の中心に存在する UHR 周波数を推定している。連続した時間幅を用いたことで検出箇所の前後の情報も獲得し、それらを検出に用いることで Zhelavskaya ら[4] や長谷川ら[5] のモデルよりも高い精度を達成した。

近藤ら[6] のモデルの問題点として、時間連続性によるデータの重要度を考慮できていないことが挙げられる。複数時刻を入力としてその区間の中心に存在する UHR 周波数を推定する場合、データの中心に存在するデータは両端に存在するデータに比べて推定への影響度が大きいはずである。したがって、該当時刻に近い時刻の情報を強調するようなフィルタ処理により、推定精度の向上が期待できる。

また、いずれの先行研究も周波数軸方向では全てを入力データとして用いているため、訓練データ内に類似したデータが含まれていない場合、UHR 周波数の推定ができないという問題がある。これに対し、周波数方向にも一定幅

[†] 福井大学大学院 工学研究科
Graduate School of Engineering, University of Fukui
[‡] 金沢大学大学院 自然科学研究科
Graduate School of Natural Science and Technology,
Kanazawa University

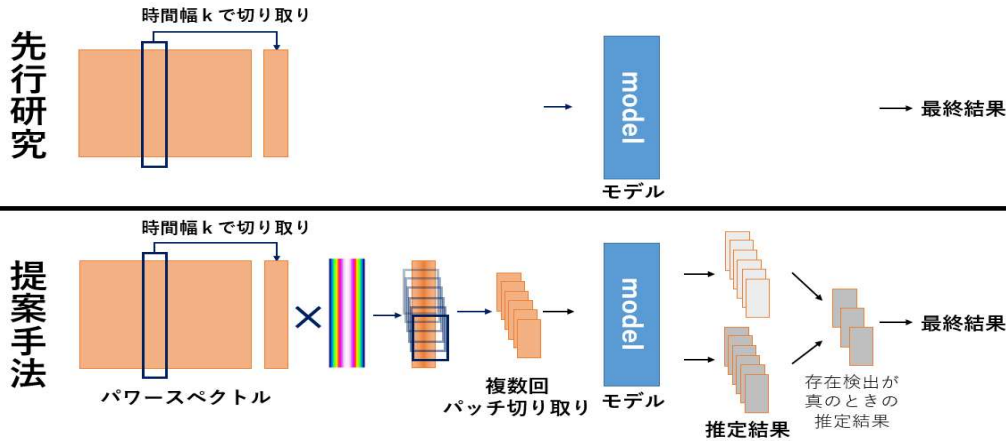


図 2 先行研究と提案手法の概略図

で切り取ることによって、未知の特徴の影響を緩和し、柔軟な UHR 周波数推定が実現できる可能性がある。

3. 提案手法

3.1 提案手法概要

本研究では、入力データに対する窓関数を用いた重み付け処理とパッチ切り取りを用いた UHR 周波数検出手法を提案する。図 2 に先行研究と提案手法の違いを示す。

窓関数による処理では、入力データに対して窓関数をかけ、重み付けを行う。この処理を行うことで、入力データの中心の重要度は大きく、両端の重要度は小さくすることができる。窓関数処理を導入することによって、データの時間関係性を考慮した推定を実現し、精度向上を図る。

パッチ切り取りでは、図 1 のような縦軸が周波数、横軸が時間のパワースペクトルに対して、周波数軸、時間軸の双方に一定幅で切り取りを行う。パッチ切り取りを行うことでより狭い範囲での特徴獲得を行い、入力データに未知のデータが発生した場合に、訓練データに存在する特徴からの特徴転用を行いやすくする。この手法を用いる場合、切り取りを行った際に UHR 周波数が切り取った範囲内に存在しない場合が考えられる。よってパッチ切り取り後のデータに対して検出を行う場合、従来モデルで行っている UHR 周波数の値の推定だけでなく UHR 周波数の存在検出も行う必要がある。そのため、本研究では先行研究のモデルに加え、存在検出と UHR 推定を同時に行うマルチタスクモデルを実装する。図 2 下部にマルチタスクモデルの概略を示す。存在検出では、対象データに UHR 周波数が存在するかどうかを推定する。そして UHR 推定では、対象となるデータのどこに UHR 周波数が存在するかを推論する。

訓練時の Loss はどちらのモデルも共通であり、存在検出時の Loss に Binary Cross-Entropy, UHR 推定時の Loss に Mean Square Error (MSE) として、以下の式を用いる。

$$Loss_{ex} = \frac{1}{B} \sum_{i=0}^B \{y_i \log \hat{p}_{ex} + (1 - y_i) \log(1 - \hat{p}_{ex})\} \quad (1)$$

$$Loss_{uhr} = \frac{1}{b} \sum_{i=0}^b \mathbf{1}_{\{y_i=1\}} (u_i - \hat{p}_{uhr})^2 \quad (2)$$

ここで $Loss_{ex}$, $Loss_{uhr}$ はそれぞれ存在検出, UHR 推定の loss である。 B はバッチサイズ, y_i , u_i はそれぞれ存在検出,

UHR 推定の正解ラベルである。 \hat{p}_{ex} , \hat{p}_{uhr} はそれぞれモデルによる存在検出, UHR 推定の予測値であり, b は B の中で $y_i=1$ を満たすデータの数である。 $Loss_{uhr}$ 内の $\mathbf{1}$ は指示関数である。存在検出時の正解ラベルが真となる入力データに対応する UHR 推定の値のみ, Loss の計算を行うことを示している。この処理により, 入力データ内に UHR 周波数が存在しない場合においても, 正しく Loss を伝播させることができる。

3.2 マルチタスクモデル

このモデルでは、単一モデルの全結合層部に対し新たに全結合層を並列に追加し、特徴検出器を共有しながら存在検出と UHR 推定の 2 つのタスクを解き、UHR 周波数の推定を行う。特徴抽出器を共有して推定を行うことで、それぞれのタスクは他タスクでの特徴を考慮した推定を行うことができる。一般に、訓練時のマルチタスク学習では、各タスクによって導出された複数の Loss を合計したものを最終的な Loss とする。また、マルチタスク学習では複数存在する Loss に対し、重み付けや重みのスケジューリングを適切に行うことで精度が向上することが示されている。よって、本研究では Loss の重みが均一な場合、一方に偏らせる場合、Loss の重みのスケジューリングを行った場合の 3 種類の実装を行う。最終的な Loss の式を式 3 に示す。

$$Loss = \lambda_1 Loss_{ex} + \lambda_2 Loss_{uhr} \quad (3)$$

λ_1 , λ_2 を変更することで 3 種類の Loss の重み付けを実装できる。本実験では、各 Loss の重みが均一であるとき $\lambda_1 = 1$, $\lambda_2 = 1$ とする。各 Loss を偏らせる場合には、難易度の高いタスクである UHR 推定を重視して学習を行うため、 $\lambda_1 = 1$, $\lambda_2 = 3$ とする。スケジューリングを行った場合の λ_1 , λ_2 を式 4 に示す。

$$\lambda_1 = \left(\frac{2\omega_1}{\omega_1 + \omega_2} \right), \quad \lambda_2 = \left(\frac{2\omega_2}{\omega_1 + \omega_2} \right). \quad (4)$$

ここで、 ω_1 , ω_2 は以下である。

$$\omega_1(n) = \left\{ \frac{1}{1 + \exp\left(\frac{4-n}{2}\right)} \right\}, \quad (5)$$

$$\omega_2(n) = \left\{ \frac{1}{1 + \exp\left(\frac{10-n}{2}\right)} \right\}. \quad (6)$$




図 4 エポック毎の Loss の重み

スケジューリングを行った場合の Loss の重みの変化を図 4 に示す。スケジュール関数は蓮本ら[7] の手法を参考にしている。学習初期は存在検出が重視され、10 エポック目で重みが逆転し、最終的に存在検出と UHR 推定の各 Loss の重みの比が 1:3 となるように設定している。

4. 検証実験

4.1 検証実験概要

今回使用したデータは、ジオスペース観測衛星「あらせ」に搭載されたプラズマ波動観測器 PWE(Plasma Wave Experiment)/HFA(High Frequency analyzer) が 2017 年 4 月から 12 月の期間に観測した電界スペクトルである。データには人間の目視によって UHR 周波数の値がラベル付けがなされている。検証実験では各月の 1, 11, 26 日のデータを訓練に各月の 5, 18 日のデータを検証に用いる。データ数は訓練時 30602 インスタンス、検証時 19537 インスタンスである。このデータに対して、ウィンドウサイズを時間幅 k 、ストライド幅を 1 として切り取りを行ったものを入力データとする。入力データのデータ形式は $\mathbf{X} \in \mathbb{R}^{B \times 1 \times 479 \times k}$ である。ここで、 B はバッチサイズであり、時間幅 k はハイパーパラメータである。使用するモデルでは k 時刻分のスペクトルデータから、その区間の中心に対応する UHR 周波数を検出するため、使用する各日の全時刻のデータに対して時間幅 k の中心のスペクトルデータと対応する正解データを作成した。本研究では、先行研究に倣い時間幅 k を変動させた場合の精度検証を行う。モデルの精度評価は平均絶対誤差 (MAE) を用いる。本研究では、先行研究に倣い、ResNet50 をベースとして出力層の直前にバッチ正規化層を接続した CNN モデルをベースラインとする。本研究で使用するマルチタスクモデルでは、ResNet50 の出力層である全結合層に対し、新たに全結合層を並列に追加することでマルチタスクな推論を可能にしている。学習率を 1.0×10^{-4} 、最適化手法は Adam とし、3 回検証した中央値を最終的な結果とする。

4.1.1 窓関数による重み付けの精度検証

窓関数は最大値が 1、最小値が 0.5 となるように設定し、最大値が推定対象となる時刻に、最小値がデータの両端となるように設定する。図 5 に窓関数による処理の概略図を示す。本研究では、窓関数としてガウス窓、三角窓、デルタ窓の 3 つを使用する。エポック数は 1000 とする。

4.1.2 パッチ切り取りの精度検証

パッチ切り取りでの検証では、訓練時の入力データに、窓関数での検証の際に入力データに行った処理に加えて周波数軸方向に対してウィンドウサイズ 1 で切り取りを行う。

訓練時の入力データのデータ形式は $\mathbf{X} \in \mathbb{R}^{B \times 1 \times l \times k}$ である。ここで、切り取り幅 1 はハイパーパラメータである。本研究では、1 を 200 と設定した。更に、訓練時の入力データには周波数軸方向に対して切り取りを行うため、切り取り後のデータに UHR 周波数が存在するかどうかを表すラベルも付与している。訓練データでは周波数軸方向に切り取りを行う際、UHR 周波数がデータに含まれるデータと含まれないデータの二つのデータができるように、時間幅 k で切り取ったデータ一つにつき 2 回切り取りを行っている。エポック数は 500 とする。

パッチ切り取りでは、近藤ら[5] の先行研究との比較を行うため、元データに対して時間軸方向にのみ切り取りを行ったものを入力データとする。入力データのデータ形式は $\mathbf{X} \in \mathbb{R}^{B \times 1 \times 479 \times k}$ である。図 2 下部に検証時の流れを示す。検証時には、時間軸方向に対して切り取りが行われた入力データに対し、周波数軸方向に 20 回、データ全体を網羅するように切り取りを行う。その後、周波数軸方向に切り取りを行った入力データに対してモデルによる推論を行う。得られた出力の中から存在検出の値が真となる切り取り後データに対応する UHR 推定の値を暫定的な UHR 推定の結果とする。このようにして得られた複数の暫定的な UHR 推定の値から、中央値を最終的な UHR 推定の結果とする。

4.2 結果と考察

4.2.1 窓関数の検証結果

検証結果を表 1 に示す。表 1 より、デルタ窓以外の窓関数を用いた提案手法が先行研究の手法の精度を上回った。これは、窓関数を導入することによって、時系列データの連続性を上手く捉えながら推定を行うことができたためであると考えられる。この結果から、推定時刻近傍のデータは推定に対する影響度が大きく、推定時刻から離れたデータは推定に対する影響度が小さいことという仮説が正しいことが示された。一方、デルタ窓での検証結果は先行研究と同程度、もしくは低下している。これは、デルタ窓では時系列データの連続性を捉えることができないためであると考えられる。窓関数同士を比較すると、UHR 周波数推定では、窓関数として三角窓が適していると考えられる。

4.2.2 パッチ切り取りの検証結果

検証結果を表 2 に示す。先行研究と比較すると、パッチ




図 5 窓関数による処理の概略図

表 1 先行研究[5] と窓関数による提案手法との精度の比較

| 時間幅 k | 11 | 21 | 31 | 41 | 51 |
|---------|--------------|--------------|--------------|--------------|--------------|
| 先行研究 | 4.019 | 3.560 | 3.725 | 3.652 | 3.598 |
| ガウス窓 | 3.658 | 3.627 | 3.699 | 3.449 | 3.433 |
| 三角窓 | 3.692 | 3.479 | 3.471 | 3.416 | 3.445 |
| デルタ窓 | 3.908 | 3.645 | 3.632 | 4.117 | 3.499 |

表 2 先行研究とマルチタスクモデルの各 Loss の重み変更時の精度の比較

| 時間幅 k | 11 | 21 | 31 | 41 | 51 |
|---------------------|--------------|--------------|--------------|--------------|--------------|
| 先行研究 | 4.019 | 3.560 | 3.725 | 3.652 | 3.598 |
| 1:1 | 4.336 | 4.158 | 4.155 | 4.600 | 3.954 |
| 1:3 | 4.642 | 4.342 | 4.368 | 4.915 | 4.258 |
| scheduling | 4.332 | 4.036 | 3.979 | 3.871 | 3.728 |
| 1:1 + window | 4.303 | 4.036 | 4.071 | 4.002 | 4.188 |
| 1:3 + window | 4.796 | 4.474 | 4.202 | 5.133 | 4.127 |
| scheduling + window | 4.587 | 4.400 | 3.857 | 3.791 | 3.778 |

切り取りの提案手法は精度が低下している。これはデータを切り取ったことによる参照できる入力領域が狭まったこと、および UHR 推定のシングルタスクから存在検出と UHR 推定のマルチタスクへとタスクの難易度が高くなったことが原因だと考えられる。また、バッチ切り取りを行った場合の精度の比較では時間幅が $k=11, 21, 51$ の場合は窓関数による重み付けなしの Loss スケジューリング、 $k=31, 41$ の場合は窓関数による重み付けありの Loss スケジューリングが最も精度が高かった。これは難易度が低いタスクを学習初期に、難易度が高いタスクを学習後期に重点的に学習したことによって学習効率が上がったためであると考えられる。バッチ切り取りを行った場合、窓関数による入力データの重み付けの有無では精度に大きな影響が見られなかった。これは、バッチ切り取りでは周波数軸方向に切り取りを行っているため、重み付けによって時間連続性による関係性が示されたデータの数が少なくなるためであると考えられる。

4.3 目視による推定が困難なデータに対する検証

目視による重み付けが困難なデータに対する検証結果を図 5, 6 に示す。本検証では、推定時の時間幅を $k=51$ とし、先行研究のモデル、窓関数によって重み付けされたデータで学習したシングルタスクモデル、窓関数によって重み付けされたデータで学習したマルチタスクモデルの 3 つを使用している。図 5 より、ノイズが軽度の場合にはマルチタスクモデルでの検証結果が最も尤もらしい結果となった。しかし、図 6 に示すように、ノイズが過度である場合、マルチタスクモデルでは UHR 周波数の連続性を維持した推定を行うことができなかった。実運用をする場合には、更なる改善が必要である。

5. おわりに

本研究では、宇宙自然電波のパワースペクトルからの UHR 周波数検出において、窓関数を用いた入力データの重み付けによる精度の改善を行った。またバッチ切り取りによる狭範囲での特徴獲得を行うことで、推定の頑健性の向上を図った。

窓関数による重み付けに関しては、窓関数による重み付け処理を行ったデータと行っていないデータをモデルに入力した場合の精度を比較した。ほとんどの場合において、提案手法は先行研究[6] よりも高い精度を達成することができた。ガウス窓、デルタ窓、三角窓の異なる三つの窓関数での精度を比較した場合、UHR 推定には三角窓が最も有用であると考えられる。検証の結果から、窓関数を適切に選ぶことで、UHR 周波数の時間連続性を考慮したデータの処理を行うことができ、先行研究[6] よりも高い精度が望めることが示された。




図 5 ノイズが軽度なデータに対する推定結果

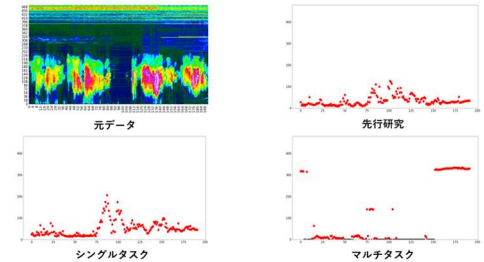


図 6 ノイズが過度なデータに対する推定結果

バッチ切り取りによる推定では、データに対して周波数軸方向、時間軸方向に切り取りを行った。バッチ切り取りを行った場合、推定目標である UHR 周波数が切り取り後のデータに存在しない場合があるため、先行研究[6] のモデルをマルチタスク学習ができるように変更した。検証の結果、先行研究と比べて精度は落ちたが、ノイズが入ったデータの推定に対しては、窓関数による前処理を用いたモデルよりも有効性を確認することができた。しかし、ノイズが大きくなってしまうと推定結果の連続性が維持できず、推定が上手くいかない傾向があり、改善の余地が見受けられる。また、Loss の重みのスケジューリングを行った場合には、行わない場合よりも精度が向上した。

謝辞

本研究の一部は、JSPS 科学研究費助成事業基盤研究 B(22H01282)の助成によるものである。ここに謝意を表す。

参考文献

- [1] Kasahara, Y., Kasaba, Y., Kojima, H. et al. The Plasma Wave Experiment (PWE) on board the Arase (ERG) satellite. *Earth Planets Space* **70**, 86 (2018). <https://doi.org/10.1186/s40623-018-0842-4>
- [2] Kumamoto, A., Tsuchiya, F., Kasahara, Y. et al. High Frequency Analyzer (HFA) of Plasma Wave Experiment (PWE) onboard the Arase spacecraft. *Earth Planets Space* **70**, 82 (2018). <https://doi.org/10.1186/s40623-018-0854-0>
- [3] Kurth, W. S., De Pascuale, S., Faden, J. B., Kletzing, C. A., Hospodarsky, G. B., Thaller, S. and Wygant, J. R. (2015), Electron densities inferred from plasma wave spectra obtained by the Waves instrument on Van Allen Probes. *J. Geophys. Res. Space Physics*, **120**: 904–914. doi: 10.1002/2014JA020857.
- [4] Zhelavskaya, I. S., Spasojevic, M., Shprits, Y. Y., and Kurth, W. S. (2016), Automated determination of electron density from electric field measurements on the Van Allen Probes spacecraft, *J. Geophys. Res. Space Physics*, **121**, 4611–4625, doi:10.1002/2015JA022132.
- [5] T. Hasegawa et al., "Automatic Electron Density Determination by Using a Convolutional Neural Network," in *IEEE Access*, vol. 7, pp. 163384–163394, 2019, doi: 10.1109/ACCESS.2019.2951916.
- [6] 近藤和真, 長谷川達人, 松田昇也, 熊本篤志, 他. CNN による時系列連続性を考慮した宇宙自然電波の特性周波数検出. 第 2020 巻, pp. 291–292, 02 2020
- [7] 運本恭輔, 後藤正幸. 多層ニューラルネットワークを用いたマルチタスク学習による顧客購買行動予測. 情報処理学会論文誌, Vol. 63, No. 6, pp. 1276–1286, jun 2022