

## 深層学習を用いた未知の重力波信号候補検出手法の構築

A New Method for Detecting Unknown Gravitational Wave Signal Candidates Using Deep Learning

南雲 彩花<sup>†</sup>  
Ayaka Nagumo中平 勝子<sup>‡</sup>  
Katsuko T. Nakahira田中 貴浩<sup>§</sup>  
Takahiro Tanaka

## 1 はじめに

本研究の目的は、信号波候補の検出を行うニューラルネットを構築し、ノイズに埋もれた時系列データである重力波データの信号雑音比と信号波形を特徴づけるパラメータを同時に見積もることで、重力波候補の絞り込みを行うことである。ノイズを含む擬似データを信号変換して時間周波数空間で表現した二次元画像を訓練データとしてCNNを学習させる。信号波の中心周波数・振動数変化率・中心時刻・時間幅・信号雑音比を出力パラメータとする。複数の重力波検出器で取得された実データに適用し、推定されたパラメータ間の一致の程度を指標にした尤度比を用いて波形検出の判定基準を定める。この手法における誤検出の発生頻度と検出限界を評価する。

## 2 実験方法

**【教師データセットの生成】** 本実験では教師データセットの信号波  $h(t)$  として

$$h(t) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(t-t_0)^2}{2\Delta t^2}\right) e^{j\phi},$$

$$\phi = 2\pi ft + \frac{\alpha}{2}(t-t_0)^2$$

を考える。  $h(t)$  は時系列データであり、時間  $t$  は  $-0.25 < t < 0.25$  の 0.5 秒間、標準化周波数は 4096[Hz]、 $j$  は虚数単位である。上式の周波数パラメータである  $f$  と  $\alpha$ 、時間パラメータである  $t_0$  と  $\Delta t$  を深層学習モデルの出力パラメータとする。信号の開始時間  $t_0$  は  $-0.24 < t_0 < 0.24$  を満たす一様乱数、信号の長さ  $\Delta t$  は  $\log 0.025 < \log \Delta t < \log 0.5$  を満たす一様乱数によって決定する。振動数  $f = \frac{f_1+f_2}{2}$ 、および、変化率  $\alpha = \frac{f_2-f_1}{4\Delta t}$  は  $f_1, f_2$  を  $20[\text{Hz}] < f_1, f_2 < 500[\text{Hz}]$  の区間で一様乱数を与えることにより指定する。

本実験では、The Gravitational Wave Open Science Center(GWOSC)で公表されているLIGOの観測データを雑音として使用する。LIGOの観測データを0.25秒刻み0.5秒間のデータへ分割し、前後2048個のデータを使用して振動数ごとに規格化する。信号対雑音比(Signal to Noise Ratio) $\rho$ は、 $0 < \rho < 32$ の範囲で一様乱数により与える。 $\rho$ に応じて信号波の大きさを調整し、雑音  $n(t)$  を重畳して、

$$d(t) = n(t) + \rho \frac{h(t)}{\sqrt{\langle |h(t)|^2 \rangle}}$$

のように教師データ  $d(t)$  を生成する。ここで、 $\langle \rangle$  は時間平均を表す。過学習を防ぐために、batch毎に信号波と雑音  $n(t)$  の組み合わせをシャッフルして教師データを合成する。また、 $0 < \rho < 5$  に該当するデータについては、容易に雑音のみで

表1 テストデータセット ( $5 < \rho < 32$ ,  $N = 25376$ )  
を用いたVGG16の精度比較

	2次元信号	レインボー	MF
$\sum_{n=0}^N \frac{\rho_n  f_n - f'_n }{N}$	2.18E+02	2.30E+02	6.89E+01
$\sum_{n=0}^N \frac{\rho_n  \alpha_n - \alpha'_n }{N}$	1.02E+04	1.02E+04	1.30E+03
$\sum_{n=0}^N \frac{\rho_n  t_{0n} - t'_{0n} }{N}$	7.21E-01	7.49E-01	4.04E-01
$\sum_{n=0}^N \frac{\rho_n  \Delta t_n - \Delta t'_n }{N}$	4.32E+00	4.69E+00	1.41E+00
$\sum_{n=0}^N \frac{ \rho_n - \rho'_n }{N}$	1.69E+00	1.68E+00	-
epoch (es=250)	929	1389	-

生成されるため  $\rho$  の正解ラベルを全て0(雑音)に置き換えてCNNに入力する。

**【信号変換】** 時間周波数領域への変換として短時間フーリエ変換を採用し、出力として複素数の2次元配列を得る。CNNモデルへ入力する際の形式として、1) レインボーグラム(129, 129, 3)と2) 2次元信号の実数部と虚数部を分け、双方とも実数値として入力(129, 129, 2)の2つを比較する。一般的に短時間フーリエ変換の計算結果を画像として可視化する際に使われるスペクトログラムは、この複素数の絶対値を取ったものである。

**【深層学習モデルの作成】** 深層学習モデルとして今回はVGG-16を使用した。事前学習は行わない。train datasetのデータ数は各24000、validation datasetのデータ数は各6000とする。出力は、 $\rho, f, \alpha, t_0, \Delta t$ の計5つである。各パラメータの予測値を'をつけて表し、損失関数を

$$\rho \frac{|f - f'|}{A_f} + \rho \frac{|\alpha - \alpha'|}{A_\alpha} + \rho \frac{|t_0 - t'_0|}{A_{t_0}} + \rho \frac{|\Delta t - \Delta t'|}{A_{\Delta t}} + |\rho - \rho'|$$

のように与える。 $\rho$ を掛けるのは、各パラメータの推定精度がSNRに依存すると期待されるためである。 $A_i$ は、各パラメータの正規化定数である。まず、 $A_i = 1$ として学習を行った後、テストデータセット(データ数  $N=25376$ )を用いて  $A_i$ の値を更新する。例えば、 $A_f$ としては  $\rho |f - f'|$ の平均値を用いる。更新後の  $A_i$ を用いて損失関数を再定義した後、再度学習を行う。その後、別のテストデータセットを用いて評価を行う。いずれもEarly Stopping 250回で学習を止める。

**【CNNモデルの評価方法】** 重力波検出において標準的に使用される手法であるMatched Filtering(以下MF)において予測される各パラメータの推定誤差は、

$$\rho^2 (f - f')^2 \approx \frac{1 + \alpha^2 \Delta t^4}{2\pi^2 \Delta t^2}, \quad \rho^2 (\alpha - \alpha')^2 \approx 8\Delta t^{-4},$$

$$\rho^2 (t_0 - t'_0)^2 \approx 2\Delta t^2, \quad \rho^2 \left( \frac{\Delta t}{\Delta t'} - 1 \right)^2 \approx 2$$

である。但し、信号がデータの範囲内( $-0.25 < t < 0.25$ )に収まっていないデータも、全て収まっているものと理想化して算出している。

**【CNNモデルの評価】** VGG16モデルについて、テストデータセットを使用してMFとの精度比較を行った結果を表1に示す。表1より、2次元信号の実数部と虚数部を分け、双方と

\* 株式会社BSN アイネット

† 長岡技術科学大学

‡ 京都大学

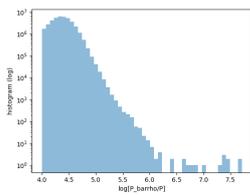


図1 約 58.23 年分; N=3672917202 のノイズデータにおける  $\log[\frac{P_p}{P}]$  のヒストグラム ( $\log[\frac{P_p}{P}] > 4, n = 39259119$ )

表2 ノイズデータ N=3672917202 における  $\frac{P_p}{P}$  のパーセンタイル

percentile	$\frac{P_p}{P}$	誤検出発生頻度 [回/年]
$1 - 10^{-1}$	0.00	-
$1 - 10^{-2}$	4.10	$6.31 \times 10^5$
$1 - 10^{-3}$	4.61	$6.31 \times 10^4$
$1 - 10^{-4}$	4.82	$6.31 \times 10^3$
$1 - 10^{-5}$	5.04	$6.31 \times 10^2$
$1 - 10^{-6}$	5.27	$6.31 \times 10^1$
$1 - 10^{-7}$	5.62	$6.30 \times 10^0$

も実数値として入力した場合の方がわずかに推定精度が良いことがわかる。MFで期待される精度と比較した場合、 $\alpha$ は約10倍の誤差、他のパラメータはいずれも数倍の誤差があり、さらに手法改善の余地があることが示唆される。次節では、入力形式を2次元信号として学習させたVGG16を使用する。

### 3 重力波データへの適用

今回使用するデータは2台の重力波検出器で同時に観測されたものを用いる。とする。この2検出器の観測データを、それぞれ0.25秒刻み0.5秒間のデータに分割し、前後2048個のデータを使用して、雑音レベルを振動数ごとに規格化する。このデータをそれぞれCNNへ入力し、2台のデータから推定されたパラメータの一致の程度を指標にした尤度比を用いて波形検出の判定基準を定める。そして、この手法における誤検出の発生頻度と検出限界を評価する。まず、 $f, \alpha, \Delta t$ は、模擬データのパラメータ分布が一様分布に近くなるように変換し、新しい変数を $\theta^i$ とする。各変数の推定誤差を $\sigma_i$ として

$$X = \sum_{i=1}^2 (\theta_L^i - \theta_H^i)^2 / \sigma_i^2$$

$$Y = \rho_L^2 + \rho_H^2, \quad r = \frac{\rho_L^2}{\rho_H^2} \left( 1.0 - 2X \frac{\rho_H^2 - \rho_L^2}{\rho_L^2 + \rho_H^2} \right)$$

を定義すると、尤度比は

$$\frac{P_p}{P} \propto \log \left[ \left( \frac{2Xr}{(1+r)^2} \right)^{-1/2} Y \right]$$

で与えられる。ここで $P_p$ は信号が存在するとして観測データが実現される確率、 $P$ は雑音のみにより、観測データが実現される確率を表す。 $L$ 、および、 $H$ の記号は2台の検出器(LivingstonとHanford)を識別するラベルである。閾値を決定するために、異なる時間のデータを対にすることで擬似的に作成したノイズのみの約58.23年分のデータを使用し、閾値以上の $\frac{P_p}{P}$ が出現する確率を計算することで、誤検出発生頻度と

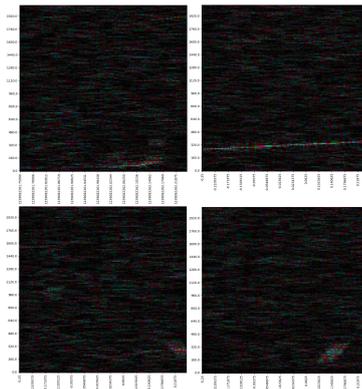


図2 GW190814 (左上)と教師データセット(右上, 右下, 左下)のレイノグラム画像例

閾値の関係を決定する。計算結果のヒストグラムを図1に示す。次に、全データにおける $\frac{P_p}{P}$ のパーセンタイルを表2に示す。表2より、閾値を5.04とした場合の誤検出発生頻度は630.7[回/年]、閾値を5.27とした場合は63.1[回/年]、閾値を5.62とした場合は6.3[回/年]と算出した。図1と表2から、波形検出の判定基準の閾値を5.04, 5.27, 5.62として、この手法における検出限界を評価する。

**【手法評価】**今回は重力波イベントとして、すでに同定されているイベントが検出できるかどうかを調べた。これらは波形が理論的によく理解されているコンパクト連星合体からの重力波である。ただし、本稿の目的は未知の重力波に対して感度を持つかどうかを調べることであるため、CNNの教師データとして用意した波形群 $h(t)$ は、コンパクト連星合体からの重力波のために最適化はされていない(図2参照)。各重力波の前後3072秒間のデータを使用し、 $\frac{P_p}{P}$ を計算した。表3に、前節で決定した閾値を用いた波形検出判定結果をまとめた。

閾値5.27(誤検出発生頻度:63.1[回/年])では、2台合わせたSNRが15程度以上の重力波イベントしか検出できていない。閾値を4.61まで下げれば、SNR13前後の重力波データも一部検出できているが、誤検出回数が63072[回/年]と非常に多い。ただし、現在用いているCNNモデルによるパラメータ推定が、MFで予測されるパラメータ推定精度にははるかに及ばないことから、さらなる工夫と改良の余地はあると考えられる。

### 4 まとめと今後の課題

本研究では、複数の重力波検出器で取得された実データにおいて、CNNで推定されたパラメータ間の一致の程度を指標にした尤度比を用いて波形検出の判定基準を定め、この手法における誤検出の発生頻度と検出限界の評価を行うことで、未知の重力波イベントの検出にも利用可能であることを実証した。

### 謝辞

本研究は科研費(20H04731)の助成を受けた。

表3 GW 検出テスト結果

	GW150914	GW151012	GW170104	GW170608	GW170729	GW170809	GW170823	GW190412
$\frac{P_p}{P}$	5.58453 5.50475	0	4.681156 4.628086	5.451775 5.503841	4.753947 4.743708	4.616628 0	-5.829974 0	5.715248 5.768622
検出閾値: 5.6182	×	×	×	×	×	×	×	○
検出閾値: 5.2695	○	×	×	○	×	×	×	○
検出閾値: 5.0358	○	×	×	○	×	×	×	○
参照 閾値: 4.6095	○	×	○	○	○	○	×	○
重力波データのSNR	24.4	10	13	14.9	10.2	12.4	11.5	18.9