

深層学習モデルを用いた重力波信号候補の探索：前処理の有効性検証

南雲 彩花[†]
Ayaka Nagumo中平 勝子[‡]
Katsuko T. Nakahira田中 貴浩[§]
Takahiro Tanaka

1 はじめに

重力波検出器の出力信号は時系列データとして記録される。取得されるデータはノイズが優勢であるので、有意な重力波信号を抽出するには適切なフィルターをかける必要がある。ターゲットとなる重力波信号を予測可能なものに限るならば、理論予測とデータの相関をとることで最適なフィルターを用意することが可能である。一方で、未知の現象を発見するには理論的な波形予測に依存しない単純なフィルターによる信号抽出が考えられる。単純なフィルターであっても、複数の検出器で同時に同じようなパラメータを持つ信号が検出されれば、ノイズと区別することが可能になる。このような解析は実際に行われてはいるが [1]、波形を特徴づけるパラメータの数を増やすと通常の相関解析では非常に大きな計算コストがかかってしまう。そこで、この特徴量抽出を機械学習で行おうというのが本研究の基本的な考え方である。CNN によるノイズに埋もれた時系列データから重力波信号の検出を行う試みは [2] でも行われているが、本研究では、これを拡張し、ノイズに埋もれた時系列データから重力波信号の候補を絞り込むため、深層学習モデルを用いた重力波検出器で取得された実データから信号の特徴量抽出の精度向上を検討する。

我々は [5] で、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 CNN で見積もることで重力波候補の絞り込みを行った。複数の検出器の出力から推定されるパラメータが誤差範囲内で一致することを要求することで大幅に誤検出率を下げることができる。それでも、検出限界を他の手法で通常採用される閾値に近い値である $\text{SNR} > 12$ と設定すると、誤検出発生頻度が高くなりすぎて実際の信号検出には使えないことが判明した。誤検出率が高くなる理由は、CNN モデルによるパラメータ推定精度が、テンプレートを用いた相関解析 (MF) によるものに比べ有意に低いためであった。本手法において特徴量の抽出精度が向上できれば、おのずと誤検出率が下がり、より微弱な信号検出が可能になる。先行研究では MF によるものと同程度のパラメータ推定精度を機械学習で実現できている [3] ことから、パラメータ推定の精度を上げる余地はあると思われる。それが実現できれば誤検出発生頻度が下がると考えられる。今回は、前処理の信号変換方式について検討し、さらなるパラメータ決定精度向上の可能性がないかの検証を行う。以下では、精度を向上させるために、深層学習モデルへの入力に対する様々な前処理の有効性について議論する。得られた特徴量の相関をもとに候補の抽出をおこない、候補の発生頻度のノイズによる期待値の有意な超過が存在するか否かを議論する。加えて、時間長に関してスケールした入力データを用意することで、様々な時間長の信号に対しても感度を持つ探索が

可能であるかどうかを検証する。

2 実験方法

2.1 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

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

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

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 $4096[\text{Hz}]$ とし、 j は虚数単位を表す。上式に含まれる周波数変化を特徴づけるパラメータである f と α 、時間パラメータである t_0 と Δt に加えて、信号のノイズに対する比 (SNR) を深層学習モデルの出力パラメータとする。信号の開始時刻 t_0 は $-0.24 < t_0 < 0.24$ を満たす一様乱数、信号の長さ Δt 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。この表式からわかるように、サインガウシアン波形に振動数の時間変化を加え、振幅を含めて 5 つのパラメータを持つ波形を考える。

本実験では、The Gravitational Wave Open Science Center (GWOSC) * で公表されている LIGO の観測データをノイズとして使用する。観測データはノイズのみであると断言できないが、異なる検出器に対するノイズとして全く異なる時刻のデータを用いることで、相関をもった実際の信号が混入する可能性は完全に排除される。2 台の検出器からなる 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を行うことで、ノイズを白色化し以下の解析に用いる。ノイズに信号波形を加える際に、信号対雑音比 (Signal to Noise Ratio) ρ は、 $0 < \rho < 32$ の範囲で一様乱数により与える。 ρ 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、 $\langle \rangle$ は時間ビンに関する単純な和を表す。ここで定義された ρ は通常のテン

* 株式会社 BSN アイネット

† 長岡技術科学大学

‡ 京都大学

* <https://www.gw-openscience.org/>




図 1 STFT (左図), CQT (右図) に時間-周波数空間でのスペクトログラム。色が青から赤の方向に信号強度、が強くなっている。位相の情報は落ととして表示している。上段はノイズが入っていない場合の図で、下段がノイズが入っている場合の図。

レートがわかっているものとした際の相関解析, MF, における信号対雑音比に対応している。本来は上記の信号波形にノイズを加えてから、ノイズの白色化をおこなうべきとも思われるが、そのようにすると計算時間が増大するため若干の単純化を行っている。

過学習を防ぐために、batch 毎に信号波とノイズ $n(t)$ 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、容易にノイズのみで生成されるため ρ の正解ラベルを全て 0 (ノイズ) に置き換えて CNN に入力する。

2.2 信号変換

ニューラルネットへの入力信号としては、1次元配列のまま行うことも考えられるが、ここでは時間周波数空間に変換して、2次元配列としての入力を考える。いくつかの例で試した結果、1次元配列での入力に比べて2次元配列に加工しての入力の方がパラメータ推定の成績がよかったというこれまでの実験結果にもとづいている。

以前の我々の研究では時間周波数領域への変換として短時間フーリエ変換 (STFT) によるものを中心に実験を行っていたが、今回は定 Q 変換 (CQT)[4] を採用し比較検討する。いずれの場合も、変換後の出力としては複素数の 2次元配列を得る。STFT では全周波数において窓幅が同じであるため、低周波数帯域では窓幅が十分でなく、十分な信号対雑音比が得られない、あるいは、周波数分解能が十分でないといった可能性が考えられる。定 Q 変換では、周波数によって窓幅を伸長させることで、各周波数に適したすべての周波数領域で適切な窓幅に設定されるためにパラメータ推定精度の向上が見込まれると予想し、採用した。しかしながら、逆に定 Q 変換では高振動数部分で振動数分解能が STFT に比べて低くなるというデメリットがあり、一長一短がある。

CNN モデルへ入力する際の形式としては、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する。一般的に STFT の計算結果を画像として可視化する際に使われるス




図 2 CQT (60, 129, 2) と、CQT (120, 129, 2) のスペクトログラムの比較。いずれもノイズなしの場合




図 3 CQT (120,129,2) に関して、様々なパラメータの信号に対するスペクトログラムの例を示している。

ペクトログラム図 1 は、この複素数の絶対値を取ったものであるが、位相の情報も有用であることが以前の実験で確かめられているので、ここでは位相情報を残した入力を採用する。

教師データセットの 0.5 秒の長さを持つ信号波を、window size を 256 (0.0625 秒に対応)、sift size を 16 とし、STFT を行った場合、CNN モデルへの入力サイズは、(129, 129, 2) となる。ここで STFT の周波数ビンには、教師データ中に信号波が存在しない周波数帯域も含まれるため、その帯域を削除した (64, 129, 2) も用意する。

一方で、周波数ビンの下限を 16 [Hz]、octave を 5, 1 octave あたりのビン数を 12 とし、CQT を行った場合、CNN モデルへの入力サイズは、(60, 129, 2) となる。図 3 に、教師データセットの信号に CQT を行ったあと、絶対値をとって可視化した図を示す。

CQT の周波数軸は対数周波数であるため、高周波帯域では、周波数分解能が粗くなる。そこで、1 octave あたりの周波数ビンを倍の 24 とし、周波数分解能を高めた CQT を行うことも試した、その場合、CNN モデルへの入力サイズ (120, 129, 2) のデータを用意する。図 2 に入力サイズ (60, 129, 2) および (120, 129, 2) の図を示す。

2.3 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 と EfficientNetB7 を使用した。事前学習は行わない。出力は、 ρ , f , α , t_0 , Δt

表 1 テストデータセット (N=30000, 0 < SNR < 32) を用いた VGG16 の精度比較

	STFT (129,129,2)	STFT (64,129,2)	CQT (60,129,2)	CQT (120,129,2)	MF
$\sum_{n=0}^N \frac{\rho_n f_n - f'_n }{N}$	2.59E+02	2.34E+02	2.55E+02	2.43E+02	6.96E+01
$\sum_{n=0}^N \frac{\rho_n \alpha_n - \alpha'_n }{N}$	1.27E+04	1.22E+04	1.28E+04	1.22E+04	1.31E+03
$\sum_{n=0}^N \frac{\rho_n t_{0n} - t'_{0n} }{N}$	6.90E-01	6.84E-01	6.94E-01	7.00E-01	4.08E-01
$\sum_{n=0}^N \frac{\rho_n \Delta t_n - \Delta t'_n }{N}$	5.38E+00	4.39E+00	4.56E+00	4.18E+00	1.41E+00
$\sum_{n=0}^N \frac{ \rho_n - \rho'_n }{N}$	1.39E+00	1.32E+00	1.39E+00	1.37E+00	1

表 2 テストデータセット (N=30000, 0 < SNR < 32) を用いた VGG16 と EfficientNetB7 の精度比較

	EfficientNetB7 - CQT (120,129,2)	VGG-16 - CQT (120,129,2)	MF
$\sum_{n=0}^N \frac{\rho_n f_n - f'_n }{N}$	2.41E+02	2.43E+02	6.96E+01
$\sum_{n=0}^N \frac{\rho_n \alpha_n - \alpha'_n }{N}$	1.26E+04	1.22E+04	1.31E+03
$\sum_{n=0}^N \frac{\rho_n t_{0n} - t'_{0n} }{N}$	6.95E-01	7.00E-01	4.08E-01
$\sum_{n=0}^N \frac{\rho_n \Delta t_n - \Delta t'_n }{N}$	5.12E+00	4.18E+00	1.41E+00
$\sum_{n=0}^N \frac{ \rho_n - \rho'_n }{N}$	1.38E+00	1.37E+00	1

の計 5 つである。入力データは最初に数層の畳み込み層を中心とするネットワークで変換され、数層の全結合層に引き渡される。畳み込み層に関してはすべてのパラメータに対して共通とし、全結合層に関してはパラメータ毎に異なるネットワークを準備した。

各パラメータの推定値を $'$ 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。推定値の誤差に ρ を掛けているのは、各パラメータの推定精度が SNR に反比例すると期待されるためである。 A_i は、各パラメータの規格化定数である。パラメータ毎に誤差の大きさは異なるので、適当な規格化を行わなければ、あるパラメータのみの推定の学習が進むことになる。先ず、 $A_i = 1$ とし、train dataset: 各 24000, validation dataset: 各 6000 のデータセットで学習を行った後、test dataset: 各 30000 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、train dataset: 各 48000, validation dataset: 各 12000 のデータセットで再度学習を行う。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 30 エポック経過しても損失関数のさらなる減少が見られない場合には学習を停止し、それまでで最も低い損失関数を与えた重みを採用する。

2.4 テストデータセットによる評価

表 1 に、テストデータを用いた各パラメータの推定誤差 (に信号対雑音比で重みをつけたもの) の平均値を示した。各欄は入力の違いを表す。最右端の MF はノイズが完全にガウシアンノイズである場合に、波形モデルを既知として相関解析によりパラメータを推定した場合 (MF) に予想される誤差の大きさである。MF は重力波検出において標準的に使用される手法である。

この表からわかることは、入力方法の違いによる大きな推定誤差の違いは見られないという点である。MF の場合に比べると、誤差は大きいのでさらに誤差を小さくする余地が十分にあるように思われるが、そうはなっていないことがわかる。細かく見ると、STFT の出力サイズでそのまま入力した (129, 129, 2) よりも、推論には無関係となる信号が存在しない周波数帯

域 (1024[Hz] 以上) を削除した (64, 129, 2) の方が推定精度がわずかに良いという傾向が見られた。これは学習にあたり無関係なデータが減少したためだと考えられる。

CQT との比較では、まず、STFT との大きな差はないことが確認される。一方で、CQT どうしの比較で、1 オクターブあたりのビン数を標準的な値である 12 とし出力した (60,129,2) の CQT よりも、1 オクターブあたりのビン数を増加させた (120,129,2) の方が推定精度がわずかに向上している傾向が見られた。これは周波数のビン数を増やし分解能が上がったことで、推定精度が上がったと考えられる。

また、表 1 で示した MF による各パラメータの推定誤差は、次のように算出したものである。

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

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

ここでは、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。

また、表 2 に、CQT (120, 129, 2) を入力とした場合の VGG-16 と EfficientNetB7 を比較した結果を示す。今回の結果では、ニューラルネットのモデルの違いによる優劣は見られなかった。

3 CNN モデルの評価

本稿のモデルは、最終的には観測データにおける重力波信号候補の有無判定を目的とする。本手法では地理的に遠距離にあるために互いのノイズに相関がないと考えられる 2 つの重力波検出器から得られた観測データが偶然近い値のパラメータを持つ事象を生成する確率を評価してやる必要がある。これにより、どの程度までの強度の信号を検出できるかが決定される。最後にその手法と、手法の有効性についての評価の方法をまとめておく。

我々が準備した信号波 $h(t)$ は単純な波形であるが、パラメータが少し異なるとほぼ独立した波形であるとみなせるため、互いに独立とみなせる波形の総数は非常に多数となる。たくさん

の独立な波形に当てはめて信号対雑音比を評価すれば、ノイズのみのデータに対しても容易にそのいずれかに対して高い信号対雑音比を持つイベントが出現する。しかし、ある程度高い信号対雑音比で実際の信号が検出される状況では、複数の検出器で推定誤差の範囲で同じパラメータを持ったイベントが同時に検出されるコインシデンス事象が起こることが期待される。推定誤差の範囲が十分に小さいならば、そのようなコインシデンス事象がノイズによってたまたま起こる確率は十分に少ない。

評価指標となるのは次の 2 つの点である。

1. ノイズデータを使用した False Alarm 発生確率の算出
2. 重力波イベントデータを使用した False Alarm 発生確率による比較

指標 1 では、ノイズのみの観測データ（時刻をずらした 2 検出器の観測データ）から、信号波候補を含む確率を計算し、False Alarm 発生確率と検出閾値を算出する。LIGO の 2 台の検出器は互いに約 3000 km 離れており、通常的环境雑音が同時刻に両方の検出器でパラメータが一致する可能性はきわめて低い。この 2 台の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、ノイズレベルを振動数ごとに規格化して得られた時系列データを、2 次元データへの変換を行ったのちに、それぞれ CNN へ入力する。2 台の検出器から得られたデータの時刻をずらすことで実際の重力波信号によって相関した信号が生成される可能性を排除する。そのようにして得られた推定されたパラメータが偶然一致している程度を表す指標として、ノイズのみによってそのようなパラメータが得られる確率 P と信号が存在する場合にそのようなパラメータが得られる確率 P_p の比を表す尤度比を用いる。このとき、ノイズはガウス分布に従うものと理想化して考える。まず、 $f, \alpha, \Delta t$ の変数は、扱いやすいように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、新しく定義した変数を θ^i とする。各パラメータの推定誤差の分散を σ_i として

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

$$Y = \rho_L^2 + \rho_H^2, \quad r = \frac{\rho_L^2}{\rho_H^2} \left(1 - 2X \frac{\rho_H^2 - \rho_L^2}{\rho_L^2 + \rho_H^2} \right),$$

を定義する。これらの変数を用いて、 P_p の分布に含まれる信号のパラメータについて周辺化を施すと、対数尤度比は

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

で与えられることがわかる。ここで、ノイズのみの場合に得られる ρ の分散を σ_ρ とした。変数に付与した L , および、 H の添字は LIGO の 2 台の重力波検出器 (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ノイズのみのデータを擬似したデータを使用し、各閾値以上の $\log \frac{P_p}{P}$ が出現する確率を計算することで、誤検出発生頻度と閾値の関係を決定する。

次に、実際に検出されている重力波イベントがこの方法によって誤検出が十分に低くなる閾値以上で検出できるかどうか手法の有効性のひとつの判断指標となる。実際に検出されている重力波イベントは波形の理論予測が正確になされている連星合体からの重力波信号であるので、すべてのイベントを高い

確からしさで検出できるとは考えていないが、信号対雑音比の高いイベントについては本手法でも検出できることを期待している。手法の確立ができれば、いよいよ未知の重力波源の探索に進むことができる。

4 まとめと今後の課題

本研究では、ノイズに埋もれた時系列データから重力波信号の候補を絞り込むため、深層学習モデルを用いて複数の重力波検出器で取得された実データから信号の特徴量抽出を行うことを目的とし、CNN モデルの精度を上げるため前処理の信号変換方式 (STFT, CQT) について比較を行った。今回の結果では、CQT は周波数ビンを更に増加させることで精度向上の余地がある可能性はわずかに見られるものの、ほぼ同規模の入力サイズにおいては CQT の STFT1 に対する優位性は見られなかった。

今後は、さらに CWT (連続ウェーブレット変換) の採用などを検討する。現段階では、MF において予測される各パラメータの推定誤差を大きく超えており、まだ最適化を行う余地がある可能性が考えられる。特に信号長が短い場合は十分な精度を出すことができているため、局在波の抽出に適した CWT の方がこのモデル波形の場合に適している可能性がある。現段階のパラメータ推定精度では、閾値をかなり高く設定せざるを得ず、既存の方法に及ばない。本手法を実用上有効なものにするためにはパラメータ推定精度の向上が必要不可欠な要素である。前処理の方法の改良以外の手法の修正として、学習に用いる波形やデータ長を変更する可能性も考えられる。

今回は教師データセットと同じように準備された信号波をテストデータセットとして用いて精度評価を行った段階で、パラメータ推定精度の改善が見られなかったため、この段階で解析を止めている。しかし、重力波検出器のデータを使用し、False Alarm 発生確率と閾値の指標を用いて、実際に重力波イベントの候補を探索するための準備はできており、パラメータ推定の精度改善が達成されれば、すぐに探索を行うことが可能である。

謝辞

本研究は科研費 (20H04731) の助成を受けた。

参考文献

- [1] R. Abbott, et al. All-sky search for short gravitational-wave bursts in the third Advanced LIGO and Advanced Virgo run. *Phys. Rev. D*, Vol. 104, No. 12, p. 122004, 2021.
- [2] Vincent Boudart and Maxime Fays. Machine learning algorithm for minute-long burst searches. *Phys. Rev. D*, Vol. 105, p. 083007, Apr 2022.
- [3] Daniel George and E. A. Huerta. Deep Learning for Real-time Gravitational Wave Detection and Parameter Estimation: Results with Advanced LIGO Data. *Phys. Lett. B*, Vol. 778, pp. 64–70, 2018.
- [4] C. Schokhuber and Anssi Klapuri. Constant-q transform toolbox for music processing. *7th Sound and Music Conference, 2010*, 2010.
- [5] 南雲彩花, 中平勝子, 田中貴浩. 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. 情報処理学会第 84 回全国大会予稿集, Vol. 1, pp. 165–166, 2022.