

機械学習を用いたノイズに埋もれた信号波候補の検出

Detection of Signal Wave Candidates Embedded in Noise Using Machine Learning

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

1 はじめに

ノイズに埋もれた信号波候補の有効な検出方法の一つとして、SNR とパラメータを機械学習により見積もり、信号波候補の絞り込みを行う方法が考えられる。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の典型である重力波データに適用することである。ノイズと疑似信号からなる模擬データを生成し、短時間フーリエ変換・ウェーブレット変換等を用いて信号変換を行ったデータを入力として学習させる。出力パラメータは信号波を特徴づけるパラメータと信号雑音比とする。本稿では、模擬テストデータを用いて、重力波検出における従来手法を使用した場合に予測される精度と比較し、作成した CNN モデルの性能を調べた。

2 実験方法

実験の手順は次の通りである。

1. 教師データセットの生成
2. 深層学習モデルの作成

教師データセットの生成は次の通り行う。

【予測波形群の生成】 本実験では教師データセットの信号波 $h(t)$ を次式によって算出する。次式は時系列データであり、時間 t は $-1.0 < t < 1.0$ の 2 秒間、標準化周波数は 4096[Hz] である。

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

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

$$f = \frac{f_1 + f_2}{2}$$

$$\alpha = \frac{f_2 - f_1}{4\Delta t}$$

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 α 、時間パラメータである t_0 と Δt を深層学習モデルの出力パラメータとする。上式の σ は $\sigma = 1.0$ 、 f_1 と f_2 は $20[\text{Hz}] < f_1, f_2 < 500[\text{Hz}]$ を満たす一様乱数、信号の開始時間 t_0 は $-0.95 < t_0 < 0.95$ を満たす一様乱数、信号の長さ Δt は $\log 0.1 < \log \Delta t < \log 2$ を満たす一様乱数によって決定する。

【雑音重畳】 本実験では標準正規分布に従う疑似乱数をメルセンヌ・ツイスタにて生成し、雑音として予測波形群に重畳する。尚、本実験における信号対雑音比 (Signal to Noise Ratio, 以降 SNR, ρ) については、 $0 < \rho < 64$ を満たす一様乱数によ

て決定したデータセット A と、 $k = 1.0, \theta = 5.0$ のガンマ分布に従う乱数によって SNR を決定したデータセット B を用意する。データセット B を用意した理由としては、適用する重力波データでは、雑音のみのデータが大半を占めるためである。今回は、SNR 毎のパラメータ推定誤差を比較するため、データセット B はテストデータセットのみデータセット A と同じ方法で決定する。次式のように ρ によって信号波の大きさを調整し、雑音 $n(t)$ を重畳して、教師データ $d(t)$ を生成する。教師データ $d(t)$ は、学習時の 1batch 毎に信号波と雑音 $n(t)$ をシャッフルして合成する。

$$d(t) = n(t) + \rho \frac{h(t)}{\int_{-1}^{+1} |h(t)| dt}$$

【信号変換】 時間周波数領域への変換を念頭に置き、次の信号変換方式を採用する。

- 短時間 Fourier 変換
- 連続 wavelet 変換

今回の予備実験では、STFT (tukey window), CWT (gabor wavelet), CWT (Mexican hat wavelet) を使用する。tukey window (以降 tk) は STFT の窓数の内で比較的、周波数分解能が高く、周波数パラメータの推定に適していると考え選択した。gabor wavelet (以降 gb) は CWT の mother wavelet の内で比較的、低周波における周波数分解能が高いため選択した。Mexican hat wavelet (以降 mh) は、周波数分解能が低く、時間分解能が高い mother wavelet であり、時間パラメータの推定に適している選択した。

3 深層学習モデルの作成

深層学習モデルの作成は次のように行った。

【CNN の設計】 実験では、雑音重畳した波形信号を時間-周波数領域へ変換し、このスペクトログラム行列を画像と見做して、CNN の入力データとする。今回は VGG-16 を使用した。出力は、 ρ 、信号波の周波数パラメータ f と α 、時間パラメータ t_0 と Δt 、計 5 つである。各パラメータの予測値を $'$ で表すと、損失関数は次のようになる。

$$\rho|f - f'| + \rho|\alpha - \alpha'| + \rho|t_0 - t_0'| + \rho|\Delta t - \Delta t'| + |\rho - \rho'|$$

と定義した損失関数 A と、

$$\rho|f - f'| \left(\frac{1 + \alpha^2 \Delta t^4}{2\pi^2 \Delta t^2} \right)^{-0.5} + \rho|\alpha - \alpha'| (8\Delta t^{-4})^{-0.5} + \rho|t_0 - t_0'| (2\Delta t^2)^{-0.5} + \rho|\Delta t - \Delta t'| + |\rho - \rho'|$$

と定義した損失関数 B を用意する。 ρ を掛けるのは、各パラメータの推定精度が SNR に依存するためである。更に損失関

* 長岡技術科学大学

† 京都大学

表1 テストデータセットを用いた精度比較

データセット	STFT(tukey) A (Uniform)		STFT(tukey) B (gamma)		CWT(gb) A		CWT(mh) A	
	A	B	A	B	A	A	A	A
損失関数								
freq	9.757E+04	2.348E+05	4.569E+05	2.908E+07	1.027E+05	1.827E+05		
CNNモデル	4.749E+03	4.749E+03	4.806E+03	4.806E+03	4.806E+03	4.806E+03		
MF								
alpha	8.983E+06	1.551E+07	2.072E+08	9.493E+08	8.736E+06	3.334E+07		
CNNモデル	6.670E+03	6.670E+03	6.683E+03	6.683E+03	6.683E+03	6.683E+03		
MF								
t0	1.823E+01	9.958E+01	9.067E+01	1.813E+03	2.032E+01	2.540E+01		
CNNモデル	2.608E+00	2.608E+00	2.706E+00	2.706E+00	2.706E+00	2.706E+00		
MF								
Δt	9.407E+01	4.036E+01	1.294E+02	2.196E+02	6.358E+01	7.021E+01		
CNNモデル	2.000E+00	2.000E+00	2.000E+00	2.000E+00	2.000E+00	2.000E+00		
MF								
SNR	1.951E+00	2.144E+00	4.957E+00	4.451E+00	1.881E+00	2.512E+00		
CNNモデル								




図1 テストデータセットの alpha 予測値と alpha 真値の相関

数 B は、後述する別手法で予測される各パラメータの推定誤差で重みを付けた。

【モデルの評価方法】 まずは標準的な信号変換方式である STFT を使用して、データセット AB と損失関数 AB の比較を行う。テストデータの推定誤差が小さい組み合わせで CWT を使用したモデルを作成する。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、

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

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

であり、これと CNN の推定精度を比較する。

4 実験結果

STFT を用いて信号変換を行った教師データセット A と教師データセット B について、損失関数 A とした CNN モデルと損失関数 B とした CNN モデルを作成して学習させ、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、損失関数 B は、MF で予測されるパラメータ精度により重みを付けたが、損失関数 A よりも精度が悪くなる傾向があることが分かった。また、データセット B の方が精度が悪くなる傾向があることが分かった。また、損失関数 A も、MF で予測されるパラメータ精度と比較して精度が悪く、特に周波数パラメータ: α の精度は、30 倍以上悪いことが分かった。次に、図 4 に、X 軸を α の予測値、Y 軸を α の真値として図示する。SNR < 11 では全く推定できていないデータが多いことが分かる。また、信号変換方式については、今回は大きな違いは見られなかった。

5 考察

損失関数 B の方が精度が悪くなる傾向が見られる理由としては、MF と CNN では各パラメータの推定精度の決まり方が異なる可能性が挙げられる。各パラメータに SNR 以外の重みをつけていない損失関数 A では、MF と比較して、時

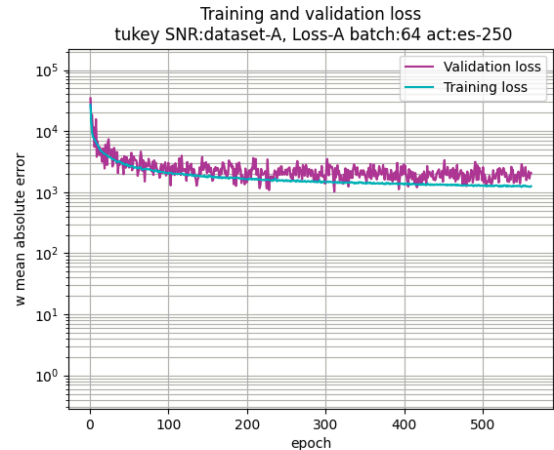


図2 学習曲線

間パラメータより周波数パラメータの推定精度が悪い傾向が見られるためである。データセット B の方が精度が悪くなる傾向がある理由としては、SNR < 11 では推定できないデータが多いため、また、今回は SNR 毎の精度を比較するためにデータセット A と同じように SNR の分布を設定したテストデータセットで評価を行ったためだと考えられる。また、信号変換方式について大きな違いが見られなかった理由としては、今回は STFT に周波数ビンと時間ビンを合わせたことが影響したと考えられる。MF よりパラメータの精度が悪い理由として、信号変換によって 128×256 の行列データへ変換したことで周波数ビン ($2048\text{Hz}/128=16\text{Hz}$) と時間ビン ($2.0\text{sec}/256=7.8125 \times 10^{-3}\text{sec}$) による影響を受けている可能性も考えられるが、それよりも誤差が大きいため、まだ精度を上げる余地はあると考えられる。しかし、図 2 に示す学習曲線から、このまま学習回数だけを増やしてもこれ以上はあまり精度が向上しないと予想される。ただし Validation Loss が不安定であるため、Validation data が不足している可能性は考えられる。

6 まとめと今後の課題

本稿では、模擬テストデータを用いて、重力波検出における従来手法を使用した場合に予測される精度と比較し、作成した CNN モデルの性能を調べた。現状では従来手法と比較して精度が悪いこと、パラメータ推定精度の決まり方が異なる可能性があることが分かった。今後の改善点としては、

- 教師データセットを増やして学習させる。
- 時間パラメータと周波数パラメータで損失関数の重みを調整する。
- CWT は特性によって周波数ビンと時間ビンを調整する。

以上 3 点が挙げられる。また、重力波データに対して適用し、データセット A で学習させたモデルとデータセット B で学習させたモデルを比較する。

謝辞

本研究は科研費 (20H04731) の助成を受けた。