

# 深層学習を用いた検出器間相関による信号検出法の改良と 重力波データへの適用

Improvement of deep learning detection method using inter-detector correlation and its application to gravitational wave data

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

本研究では、重力波データ解析を想定し、振幅や振動数が滑らかに変化する信号をノイズに埋もれたデータから抽出する手法を確立する。信号雑音比と波形パラメータ(中心周波数・振動数変化率・中心時刻・時間幅)を深層学習モデルにより推定し、推定値の複数検出器間の一致の程度を指標とした閾値を定め信号候補の抽出を行う。誤検出発生頻度の低減による検出限界改善を目指し、損失関数の選定の工夫や、信号雑音比に基づく Curriculum Learning などの様々な試行を行い、それらの有効性を検証する。さらに、ノイズが非ガウス性を持つ実観測データにも適用し、誤検出発生頻度と検出限界が実際にどれだけ改善されるかを示す。

## 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  $-0.135 < t_0 < 0.135$  を満たす一様乱数、信号の長さ  $\Delta t$  は  $\log 0.025 < \log \Delta t < \log 0.200$  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。

\* 株式会社 BSN アイネット

† 長岡技術科学大学

‡ 京都大学

**【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 (STFT) を採用し、出力として複素数の 2 次元配列を得る。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。検出対象外の周波数領域を除外し、入力形状は (128, 64, 2) とする。

**【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 48000, validation dataset のデータ数は各 12000 とする。出力は、 $\rho, f, \alpha, t_0, \Delta t$  の計 5 つである。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。各パラメータの予測値には ' を付すものとし、損失関数は、パラメータの一致の程度に基づき定義した次式

$$Loss_X = \frac{1}{2}\rho \left[ \frac{|t'_0 - t_0|}{\Delta t} + \Delta t |(t'_0 - t_0)\alpha - 2\pi(f' - f)| \right. \\ \left. + \left| 1 - \frac{\Delta t'}{\Delta t} \right| + \frac{1}{2}\Delta t |\alpha' - \alpha| \right]$$

と  $\rho$  の Mean Absolute Error (MAE) の和とする。次セクション以降のモデルの評価式、及び、重力波のデータへ適用する  $X$  では各パラメータの真値と推定値の 2 乗誤差で算出しているが、 $Loss_X$  は外れ値の影響を軽減して学習させるために、絶対誤差としている。 $Loss_X$  は信号雑音比  $\rho$  の推定値に依存せず、 $\rho$  の損失が計算されないため、 $\rho$  のみ MAE による損失関数を定義する。

損失関数  $Loss_X$  はパラメータが複数あるため、局所解に陥りやすくなる可能性があると考えられる。より良い局所最適解へ収束しやすくすることを狙いとして、本稿では、学習手法として以下のような信号雑音比  $\rho$  に基づく Curriculum Learning を採用する。

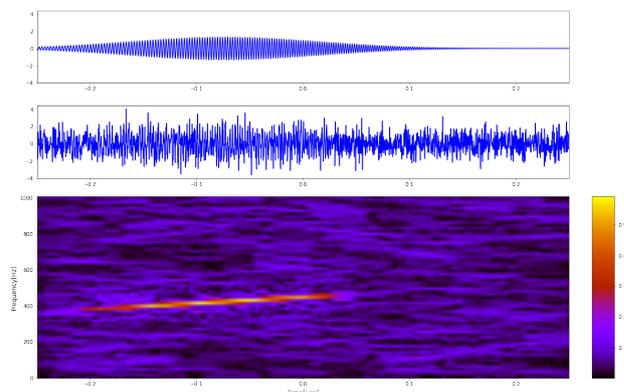


図 1 上段: 信号データ例図, 中段: ノイズ重畳データ例図, 下段: STFT 後のスペクトログラム例図 (信号雑音比  $\rho \approx 24$ )

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.  $E$  は epoch,  $\bar{E}$  は epoch 平均, CL は curriculum learning, ES は early stopping, MF は matched filter の平方根を示す.

評価式	CL ( $E:500$ )	ES ( $\bar{E}:186$ )	( $E:500$ )	MF
$\frac{1}{N} \sqrt{\sum_{n=1}^N \rho_n^2 (f_n - f'_n)^2}$	$1.55 \times 10^2 \pm 2.98$	$1.77 \times 10^2 \pm 30.3$	$1.46 \times 10^2 \pm 2.66$	69.6
$\frac{1}{N} \sqrt{\sum_{n=1}^N \rho_n^2 (\alpha_n - \alpha'_n)^2}$	$1.06 \times 10^4 \pm 5.30 \times 10^2$	$1.57 \times 10^4 \pm 1.04 \times 10^3$	$9.73 \times 10^3 \pm 4.06 \times 10^2$	$1.51 \times 10^3$
$\frac{1}{N} \sqrt{\sum_{n=1}^N \rho_n^2 (t_{0n} - t'_{0n})^2}$	$0.236 \pm 4.98 \times 10^{-3}$	$0.322 \pm 8.28 \times 10^{-2}$	$0.211 \pm 1.23 \times 10^{-2}$	0.195
$\frac{1}{N} \sqrt{\sum_{n=1}^N \rho_n^2 (\Delta t_n - \Delta t'_n)^2}$	$2.26 \pm 9.53 \times 10^{-2}$	$1.78 \times 10^2 \pm 2.89 \times 10^2$	$8.21 \times 10^2 \pm 1.42 \times 10^3$	1.41
$\frac{1}{N} \sqrt{\sum_{n=1}^N (\rho_n - \rho'_n)^2}$	$2.46 \pm 1.38$	$1.79 \pm 0.355$	$1.70 \pm 0.249$	1
$\frac{1}{\sum_{n=1}^N \frac{X_n}{N}}$	$1.80 \times 10^3 \pm 48.9$	$2.42 \times 10^4 \pm 3.82 \times 10^4$	$5.05 \times 10^5 \pm 8.71 \times 10^5$	

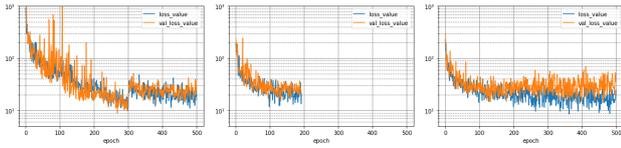


図2 学習曲線 (左図・CL E:500, 中央・ES E:183, 右図 E:500)

$24 < \rho < 32$	1 ~ 100 epoch
$16 < \rho < 32$	101 ~ 200 epoch
$8 < \rho < 32$	201 ~ 300 epoch
$0 < \rho < 32$	301 ~ 500 epoch

上記のように、教師データの信号雑音比を epoch に応じて変更する Curriculum Learning を用いて 500epoch 学習させたモデル,  $0 < \rho < 32$  の教師データを一樣に用いて 500epoch 学習させたモデル,  $0 < \rho < 32$  の教師データで Early Stopping(patience=60) で早期停止を行ったモデル, を生成し精度比較を行う。

#### 【CNN モデルの評価方法】

上記 3 つの学習手法でそれぞれ複数回学習を行う。評価式は、パラメータの一致の程度に基づき定義した次式

$$X = \frac{1}{4} \rho^2 \left[ \frac{(t'_0 - t_0)^2}{(\Delta t)^2} + (\Delta t)^2 \{(t'_0 - t_0)\alpha - 2\pi(f' - f)\}^2 + \left(1 - \frac{\Delta t'}{\Delta t}\right)^2 + \frac{\Delta t^4}{4} (\alpha' - \alpha)^2 \right]$$

とする。また、各パラメータ個別の推定精度を、信号雑音比  $\rho$  で正規化を行った各パラメータの Root Mean Squared Error (RMSE) で検証する。

また、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、以下の通りである。

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

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

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。なお、各パラメータの RMSE と次数を合わせるため、MF は全て平方根を取った値で比較を行う。

【CNN モデルの評価】 テストデータセットを使用し、Curriculum Learning を用いて 500epoch 学習させたモデル、

$0 < \rho < 32$  の教師データで 500epoch 学習させたモデル、 $0 < \rho < 32$  の教師データで Early Stopping(patience=60) で早

期停止を行ったモデル、及び MF との精度比較を行った結果を表 1 に示す。それぞれのモデルについて 3 回学習を行い、評価式の平均値と標準偏差を示す。また、図 2 に、1 回目の学習時における学習曲線を示す。

表 1 より、評価式  $X$  においては、Curriculum Learning を用いて学習させたモデルが最も良い結果となっていることが分かる。各パラメータ毎の精度の内訳より、Curriculum Learning を用いていないモデルでは、 $\Delta t$  の推定誤差が大きいことが  $X$  の評価式へ影響したと見られる。 $\Delta t$  の推定誤差が大きい要因は、 $\Delta t$  の真値の値域よりも極端に大きな値を、 $\Delta t$  の推定値として出力したテストデータが少数含まれていたためであった。入力データの僅かな変動で各パラメータの真値の値域から大きく外れた出力してしまう安定していない解を学習した可能性があると考えられる。図 2 の右図より、500Epoch 学習させたモデルでは過学習が始まっているが、中央図の Early Stopping で早期停止を行ったモデルでは過学習が始まる前に停止できていることが分かる。しかし、テストデータセットによる評価では、Early Stopping で早期停止を行ったモデルは  $\Delta t$  以外が 500Epoch 学習させたモデルより成績が悪く、未学習の傾向にあると見られる。Curriculum Learning を用いて学習させたモデルでは、テストデータセットにおいて真値の値域から極端に外れた値は出力されず、入力データの僅かな振動で出力が真値の値域から極端に外れる局所解で学習してしまうことを回避した可能性があると考えられる。

一方、信号雑音比  $\rho$  は、Curriculum Learning を使用しないモデルの方が良い結果となっており、必ずしも最適解に近い学習結果が得られるわけではないことを示しており、改善の余地があると考えられる。

### 3 まとめと今後の課題

本研究では、重力波データ解析を想定し、振幅や振動数が滑らかに変化する信号をノイズに埋もれたデータから抽出することを念頭に手法の開発を進めた。この手法における誤検出発生頻度の低減による検出限界改善を目指し、損失関数の選定の工夫や、信号雑音比に基づく Curriculum Learning などの試行を行った。Curriculum Learning の採用により、入力データの僅かな振動で各パラメータの真値の値域から大きく外れた出力してしまう安定していない解で学習することを回避した可能性があると考えられる。しかし、信号雑音比  $\rho$  は、Curriculum Learning を使用しないモデルの方が良い結果となっており、信号雑音比  $\rho$  の損失関数に適切な重み付けを行うことや、複数回の学習結果から最適なものを選ぶなどの方法による改善の余地があると考えられる。今後は試行回数を増やして同様の傾向が見られるかを確認し、各学習方法で作成したモデルが誤検出発生頻度に影響を与えるか検証を行う。

#### 謝辞

本研究は科研費 (20H04731) の助成を受けた。