

# 畳み込みニューラルネットワークを用いた 多数のパラメータによって特徴づけられる波形の抽出と パラメータ推定

森雅也<sup>†</sup> 中平勝子<sup>†</sup> 田中貴浩<sup>††</sup>

<sup>†</sup>長岡技術科学大学 <sup>††</sup>京都大学

## 1 はじめに

近年、自然科学における観測波形からの信号の抽出の研究が盛んに行われている [1] [2] [3]. 通常、観測波形の解析/信号抽出を行う場合、理論波形を用いて観測データから特定の観測波形を検出する. また、自然科学における理論的な波形の予測が困難な場合、多数の未知のパラメータを含む理論波形と観測波形の相関解析を行うことにより、その理論波形を特徴づけるパラメータを推定する. しかし、自然科学における観測データには、大小さまざまなノイズが含まれている. さらに、観測波形を形成するパラメータが多数になると、パラメータを推定するのに莫大な時間と計算コストが必要とされる. したがって、大小さまざまなノイズに影響されずに、特定の観測波形を取り出す方法と、多数のパラメータを効率よく推定する方法が必要である. この方法として、畳み込みニューラルネットワーク (CNN) を用いた、特定のクラスの波形の検出と観測波形を特徴づけるパラメータの推定を考える. CNN の入力通常画像データである点に加え、CNN の最適な構成は対象とする問題に依存する. 2つの問題がある中で、本稿では CNN の入力に適した波形データの前処理と、観測波形の検出に適した CNN の構成について検討する. より具体的には、CNN を用いたクラス分類を行うことで観測波形の検出精度を導出し、その有効性を検証する.

本稿の具体的な応用の可能性として、波形を特徴づけるパラメータセットが多数あり、今後予期せぬ発見も期待される重力波観測データへの適用を念頭に考える.

**Signal identification and extraction of waveform parameters from noisy data by using convolutional neural network**

Masaya Mori<sup>†</sup>, Kathuko Nakahira<sup>†</sup>, and Takahiro Tanaka<sup>††</sup>

<sup>†</sup>Nagaoka University of Technology

1603-1, Kamitomioka, Nagaoka, Niigata, 940-2188 Japan

<sup>††</sup>Kyoto University

Oiwake, Kitashirakawa, Sakyo, Kyoto, 606-8502 Japan

s183368@stn.nagaokaut.ac.jp

## 2 実験概要

本稿では、想定される重力波信号を単純化した波形モデルにノイズを付与した擬似データの波形検出を考える. 擬似データ波形を短い時間間隔で切り出したものをフーリエ変換することによりスペクトログラムを得ることで、1次元の波形データを2次元画像データに変換する. この画像データに CNN を適用することでクラス分類を行い、観測波形データの検出を行う.

### 2.1 擬似データの生成

はじめに、重力波観測波形を想定した擬似データの生成を行う. 重力波観測波形を想定した擬似データとして、緩やかに振動数が時間変化する波形  $S(t)$  を、

$$S(t) = A_{\text{signal}} \cdot \cos(\phi(t)), \quad (1)$$

$$\phi(t) = 2\pi\{\alpha f_0 t + \frac{1}{2}\beta(f_0 t)^2 + \frac{1}{3}\gamma(f_0 t)^3\}, \quad (2)$$

$$f(t) = f_0\{\alpha + \beta(f_0 t) + \gamma(f_0 t)^2\}, \quad (3)$$

に従って生成した. ここで  $A_{\text{signal}}$  は振幅,  $t$  は時間,  $f_0$  は基準となる周波数を表す. 今回は,  $f_0$  を 500Hz とし,  $t$  の範囲を  $-1$  から  $1$  までの 2 秒とした.  $\alpha$ ,  $\beta$ ,  $\gamma$  は周波数の時間変化  $f(t)$  を特徴づける無次元のパラメータとなっている. 各パラメータの値は、

$$\alpha = \frac{p+q}{2}, \quad (4)$$

$$\beta = \frac{p-q}{1000}, \quad (5)$$

$$\gamma < 8.0 \times 10^{-8}, \quad (6)$$

とし,  $p, q$  が  $0.1 < q < p < 1$  を満たす範囲から選んだ. これにより、時間  $t$  によって周波数  $f(t)$  がおよそ 50Hz~500Hz 間で緩やかに変化する波形  $S(t)$  が生成される. 次に、この擬似データにノイズを付加した波形を生成する. ノイズは、

$$n_i = A_{\text{noise}} \cdot X_i, \quad (7)$$

に従って生成する。ここで  $i$  は時刻のラベルで、各  $X_i$  は標準正規分布に従う独立な乱数を、 $A_{\text{noise}}$  はノイズの強度を表している。理論波形が完全にわかっているとされたとき、最適なフィルタリングを行うことで得られる信号/雑音比は、

$$\text{SNR} = \sqrt{\frac{8192}{2}} \left( \frac{A_{\text{signal}}}{A_{\text{noise}}} \right), \quad (8)$$

で与えられる。ここで、8192は時系列データの長さである。SNRは、 $A_{\text{signal}}:A_{\text{noise}} = 1:1$  の場合は64,  $A_{\text{signal}}:A_{\text{noise}} = 1:2$  の場合は32,  $A_{\text{signal}}:A_{\text{noise}} = 1:5$  の場合は12.8となる。今回は波形モデルにノイズ強度が異なる3つのノイズ付加した、3パターンのノイズ波形を用意した。最後に、3パターンのノイズ波形をフーリエ変換し、各ノイズ波形のスペクトログラムを獲得する。スペクトログラムは、サンプリング周波数を4096Hz、窓幅を512、スライド幅を120として、ノイズ波形を短時間フーリエ変換することで獲得した。ここでは、スペクトログラムの強度のみを使用した場合の結果を示す。

## 2.2 畳み込みニューラルネットワークの構築

本稿では、全結合層の層数の違いによる精度の変動を確認するため、モデルを3つ構築した。構造として、畳み込み層/プーリング層を2層ずつ用意した。全結合層は、1層/3層/5層の3つを用意した。具体的には、1層目の畳み込み層は、サイズを(25,10)としてフィルター数を16枚とした。プーリング層はmax poolingを採択し、サイズを(4,5)とした。2層目の畳み込み層は、サイズを(10,4)としてフィルター数を32枚とした。プーリング層はmax poolingを採択し、サイズを(4,1)とした。全結合層は、ノード数を1層の場合は3000, 3層の場合は4500,3000,1500, 5層の場合は4500,3500,2500,1500,500とした。各層の出力にはReLU関数を適用し、出力層にはシグモイド関数を適用した。また、過学習を抑えるため、全結合層と出力層の間にドロップアウト層を挿入し、学習の高速化を図るため、確率的勾配降下法によって重み/バイアスの更新を行った。損失関数として交差エントロピー誤差を採択した。

## 3 結果と考察

本稿では、 $f(t)$  が50Hz~500Hz間で緩やかに変化する波形をクラス1とし、10Hz~50Hz, 500Hz~1000Hz, 1000Hz~2048Hz間で変化する波形をクラス2として2クラス分類を行った。教師データは7000データ用意し、またテストデータとして2000データ用意した。CNN

表 1: 学習回数 2000 回における 2 クラス分類の結果

$A_{\text{signal}}:A_{\text{noise}}$	1:0	1:1	1:2	1:5
1 層	.999	.997	.997	.499
3 層	.998	.998	.998	.503
5 層	.998	.998	.998	.509

の学習回数は2000回とし、ミニバッチとしてデータを70データ毎に学習を行った。結果を表1に示す。ここで、表内の数値は精度を表している。表1から、層数に関係なく低ノイズの場合は、高い精度で波形を検出できることが確認できた。しかし、ノイズ強度が大きくなると検出精度が極端に低くなることが確認された。これは、ノイズ強度が大きくなると、スペクトログラムの強度だけでは検出したい波形特有の特徴を検出できなくなってしまうからだと考えられる。

## 4 おわりに

本稿では、想定される重力波信号を単純化した波形モデルにノイズを付与した擬似データに短時間フーリエ変換を行い、スペクトログラムを導出することで、観測波形検出に適した入力データ処理の検討を行った。また、スペクトログラムを入力とする、観測波形検出に適したCNNの構成について検討を行った。結果として、ノイズの強度が大きくなると、スペクトログラムの強度では波形の特徴が捉えられなくなることが確認できた。今後の展望として、ノイズ強度の影響を受けにくいCNNの構築の検討や、ノイズ強度に影響を受けない特徴を保有するような、波形の処理方法の検討が挙げられる。また波形検出だけでなく、観測波形のパラメータ推定に対するCNNの構築についても検討を行っていきたい。

## 参考文献

- [1] 田中裕士, 後藤由貴, 笠原禎也, 南保英孝, “あけぼの衛星の大規模データセットを用いた自然波動の分類に関する研究”, 電子情報通信学会論文誌 D, vol.J101-D, no.1, pp.225-234, 2018.
- [2] 真貝寿明, “重力波の直接検出とデータ解析”, システム制御情報学会誌, vol.62, no.9, pp.370-375, 2018.
- [3] 廣石恒二, 内山泰生, 山本 優, 高木政美, “現地地震計を用いた地震防災システムの開発と性能評価”, 日本建築学会技術報告集, vol.21, no.48, pp.487-492, 2015.