

雑音入り模擬データに対する信号変換方式と機械学習モデルの関係分析

In Search of Appropriate Combinations of Signal Conversion Method and Machine Learning Model for Analyzing Simulated Data with Huge Amount of Noise

南雲 彩花[†]
Ayaka Nagumo中平 勝子[†]
Katsuko T. Nakahira山本 貴宏[‡]
Takahiro S. Yamamoto田中 貴浩[‡]
Takahiro Tanaka北島 宗雄[†]
Muneo Kitajima

1 はじめに

膨大なパラメータ空間を持つ波形信号を対象とするパラメータ推定において、計算量の増大を抑える目的で、データ前処理に信号変換を使用した機械学習の活用 [1] が注目されている。本稿では、雑音入り模擬データを用いて、特定の性質を持つ波形の特徴をより適切に捉える信号変換の適用可否と、深層学習モデルの適切な組み合わせの設計を見出す実験を行う。信号変換方式には、時間/周波数分解能の優先順位・最適化によって、短時間フーリエ変換、ウェーブレット変換、ヒルベルト・ファン変換を採用し、いくつかの代表的なニューラルネットワークとの組み合わせで、Loss 関数に閾値を設け学習が収束するまでに要する計算時間、あるいは Loss 関数が収束し始めた時点における Loss の値を評価指標として比較する。

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
3. 各信号変換方式と深層学習モデルの組み合わせ評価

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】瞬時周波数が $f'(t) = f_0\gamma t^2 + f_0\beta t + f_0\alpha$ の3次関数で表される波形 $S(t) = A\sin[2\pi f(t) + \theta_0]$ の位相 $\theta(t)$ を次式で表す。

$$\begin{aligned}\theta(t) &= 2\pi f(t) + \theta_0 \\ &= 2\pi \int_0^t f'(\tau) d\tau + \theta_0 \\ &= 2\pi f_0 \left(\frac{1}{3}\gamma t^3 + \frac{1}{2}\beta t^2 + \alpha t \right) + \theta_0\end{aligned}\quad (1)$$

ここで、周波数の時間変化を決定する係数: $\alpha, \beta, \gamma, f_0$, 初期位相: θ_0 , 最大振幅: A を設定して予測波形群を生成する。今回の予備実験では、 $f_0 = 500$, $\theta_0 = 0$, α, β, γ, A は次のように決定する。

$$\alpha = \frac{p+q}{2}, \beta = \frac{p-q}{1000}, \gamma = 8.0 \times 10^{-8} \times n, A = 10 \times m$$

[†] 長岡技術科学大学

[‡] 京都大学

ここで、 q, p は $0.1 < q < p < 1$ を満たす一様分布に従う乱数、 n は $0 < n < 1$ を満たす一様分布に従う乱数、 m は $0 < m < 1$ を満たす一様分布に従う乱数である。

【雑音重畳】平均 0, 分散 σ^2 とする正規分布に従う擬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) については、次式のように計算する。

$$SNR = \sqrt{\frac{N}{2}} \frac{A}{\sigma}$$

ここで、 N は予測波形のデータ長、 A は予測波形の最大振幅である。

【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 (STFT)
- 連続 wavelet 変換 (CWT)
- Hilbert-Huang 変換 (HHT)

今回の予備実験では、STFT (hamming window), CWT (gabor wavelet), CWT (Mexican hat wavelet) を使用する。参考画像を図 1 に示す。hamming window (以降 hm) は STFT の窓関数の内で比較的、周波数分解能が高く、パラメータ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、上記 2 つと大きく異なる性質を持つため選択した。




図 1 信号変換方式の参考画像

3 深層学習モデルの作成

深層学習モデルの作成は次の様に行った。使用したパッケージは Python 3.6, Keras 2.3.1, tensorflow-gpu 1.14.0 である。

【CNN の設計】畳み込みニューラルネットワーク(以降, CNN)への入力, 雑音を重畳した波形信号を時間-周波数領域へ変換した画像データとする。出力は, 今回の波形信号において周波数の時間変化を決定する係数である α, β, γ とする。 α, β, γ の各 mean absolute percentage error (以下 mape) の合計値を Loss 関数とする。また, 勾配法 (Keras optimizer) は Adam optimizer を使用した。図2に今回の予備実験で用いる CNN モデル構成を示す。今回の予備実験で使用するモデルは, 入力次元数を $256 \times 121 \times 3$, 層数 n を 4, filter 数を 16, 32, 64, 128, filter size を $5 \times 5, 3 \times 3, 3 \times 3, 3 \times 3$, pool size 及び strides を, $2 \times 2, 2 \times 2, 2 \times 1, 1 \times 1$, これを model A とした。Dense 層の活性化関数は全て sigmoid とした。 β, γ が非常に小さい値であるため, 0 近傍の入力刺激値で 0.5 前後の出力刺激値が得られる sigmoid の性質を重視して設定した。尚, α, β, γ は負の値を取らないことから ReLU も候補に挙げたが, dying ReLU[2] を起こしたため候補から除外した。




図2 CNN モデルの構成とパラメータ

【組み合わせ】縦軸の信号変換方式においては, STFT (hm), CWT (gb), CWT (mh) を使用する。横軸の深層学習モデルの設計では, 層数, filter size, filter 数など多くの設計可能箇所が存在するが, 今回の予備実験では batch 数のみ変更する。表1の*に該当する部分を対象とする。尚, まず信号変換方式

表1 組み合わせ表

model	A	A	A	A	B	...
batch 数	128	256	512	1024	128	...
optimizer	adam	adam	adam	adam	adam	...
STFT (hm)	* (表2)	* (表2)	-	-	-	
CWT (gb)	* (表2)	-	-	-	-	
CWT (mh)	* (表2)	* (表2)	-	-	-	
STFT (hm) SNR=64	-	-	-	-	-	
⋮						

表2 実験例

信号変換方式	batch 数	終了時の		学習時			テスト時			
		batch 数	Epoch	Loss	α mape[%]	β mape[%]	γ mape[%]	Loss	α mape[%]	β mape[%]
STFT (hm)	128	1230	168.6208	33.9061	98.9118	35.7451	155.6689	35.0739	99.0193	21.5196
CWT (gb)	128	3416	43.6136	0.3955	8.8489	34.3620	56.0599	0.6485	21.0981	34.1451
CWT (mh)	128	2411	57.2599	1.0493	16.4137	39.8400	62.8354	1.3447	22.0227	39.4501
STFT (hm)	256	1841	41.1808	1.1581	10.0877	29.8527	44.1784	1.2409	13.7408	29.1675
CWT (mh)	256	1820	41.2527	0.7890	7.4775	33.0981	52.3024	1.4260	16.8760	33.9935

の違いが深層学習の学習結果で違いを示すかを確認するため, 今回の予備実験では波形信号に雑音は付加しない。評価指標としては, 「 α, β, γ の各 mape 値に閾値を設け, 学習収束までに要した計算時間」, 「Validation Loss 関数が一定回数減らなくなった段階で停止し, 最小になった時点の Validation Loss」の2種が考えられるが, 今回の予備実験では後者を採用する。

4 予備実験および結果

今回の実験条件は, train data : 8500 個, test data : 1500 個, batch 数 : 128, 256, 雑音無しである。波形信号は3方式で同じデータセットを用いる。また, Loss 関数は α, β, γ における各 mape の合計値とする。今回は Validation Loss 関数が, 1000 回連続して減らなくなった段階で停止する。

Validation Loss 関数が最小になった epoch における, 学習時, テスト時の各 mape 値を表2に記載する。表2から, 信号変換方式の違いが CNN の学習結果で違いを示す可能性があることが分かった。

5 まとめと今後の課題

本稿では, 模擬データを用いて特定の性質を持つ波形の特徴をより適切に捉える信号変換の適用可否と, 深層学習モデルの適切な組み合わせの設計を見出す実験について, 実験方針の提示と, 予備実験を行った。予備実験の結果, 信号変換方式の違い, batch 数の調整で学習結果が変わる可能性を確認できた。今後, 今回変更しなかったモデルのパラメータ変更・追加, 雑音重畳の追加, を行う予定である。

謝辞

本研究の一部は科研費(新学術・公募研究 20H04731)の助成を受けて行われました。

参考文献

- [1] 森 雅也, 中平勝子, 田中貴浩: 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, 第81回全国大会講演論文集, vol.2019, pp.317-318, 2019.
- [2] Lu, Lu and Shin, Yeonjong and Su, Yanhui and Karniadakis, George: Dying ReLU and Initialization: Theory and Numerical Examples, arXiv:1903.06733, pp., 2019.