

ニューラルネットワークを用いた時系列波形分析手法の実験的検討 An Experimental Study on Time Series Waveform Analysis Method Using Neural Network

讃岐 純平[†] 弘中 哲夫[†] 窪田 昌史[†]

Junpei SANUKI Tetsuo HIRONAKA Atsushi KUBOTA

1. はじめに

今日多様な IoT センサが使われるようになってきた。しかし、多くの IoT センサから情報を集約して利用する場合、通信データ量や集約サーバの計算負荷を考えると、IoT センサからのデータは時系列波形ではなく、時系列波形から推測される情報に変換してから送信することが望ましい。例えば、加速度センサを搭載する機器からの単なる加速度の時系列の変化量波形ではなく、加速度の変化から読み取れる機器の状態に変換してから送信するような機構である。さらに、IoT センサで得られる時系列信号に対して信号処理することを考えると、従来行っていた FFT, FIR や IIR などのデジタルフィルタに加えて、曖昧な時系列波形の分類が行えるニューラルネットワークの活用が期待される。このような時系列信号に対するニューラルネットワークの研究として [1][2][3] を始めとする多くの研究が行われているが、比較的規模の大きいニューラルネットワークを用いており、非力な IoT センサに向かない。

そこで、IoT センサに搭載が容易な比較的小規模なニューラルネットワークを用いることを検討している。しかし、ニューラルネットワークを用いて生体信号のような時系列波形を分類するとき、なにが分類可能であるかという点をはっきりしない。そこで、本研究では、比較的小規模なニューラルネットワークを用い、性質が既知である時系列信号をどの程度正しく分類できるかを確認する。特に本稿では、振幅、位相の組み合わせに対して波形のラベル付けを行い、それらのゆらぎに注目して実験的に評価した結果について報告する。

2. 評価方法

2.1 時系列波形の生成

本研究では問題を簡単にするため、基準となる正弦波と、それに対して 2 倍の周波数を持つ正弦波を用意した。実験では、2 倍の周波数を持つ正弦波の位相変化、および、振幅変化がニューラルネットワークで分類可能かを

実験で確認した。なお、この実験のため作成した時系列波形は次式で表される。

$$f(t) = (A + \Delta A)(\sin((w + \Delta w)t) + (B + \Delta B) \sin(2(w + \Delta w)t + \theta + \Delta \theta)) \quad (1)$$

ここで、 A は基準となる振幅であり、 B は 2 倍の周波数をもつ正弦波の振幅である。また、 w は周波数成分であり、 θ は位相である。 ΔA , ΔB , Δw , $\Delta \theta$ は IoT センサから得られる時系列信号のゆらぎを想定している。

なお、式 (1) で得られる波形は生体から得られる生体信号を簡略化したものを想定し、基準となる波形に対してほしい情報が乗っている測定対象の 2 倍周波数正弦波 (高調波) の変化を検知しようとするものである。現実の生体信号波形では基準周波数に対する高調波は、この式のように単一の高調波ではないが分析の容易性を優先し、この実験では単一高調波とした。

2.2 ラベル付学習データの生成

時系列波形を分類する能力を評価するために、前節で示した式で生成した波形にラベルを付けた。式 (1) の第 2 項の正弦波の位相値 (θ)、振幅値 (B) の組み合わせに対し、表 1 のように L0~L15 のラベルを付ける。なお、ラベル付けされた各時系列波形は、 ΔA , ΔB , Δw , $\Delta \theta$ を用いて A , B , w , θ に対してゆらぎを持つ。 A , B , w , θ に対するゆらぎ成分はそれぞれ正規分布で与え、 σ_A , σ_B , σ_w , σ_θ の標準偏差を持つように与えて、各ラベルに対応するゆらぎ成分をもたせた時系列波形をサンプリング周波数 $w=8[\text{Hz}]$ を用いて生成した。なお、学習データは初期位相の影響を受けないように時系列波形データの採取位置をランダムに変更し、10 秒分 (80 サンプル) づつ切り出したものを 4800 組用意し、その 8 割を学習データ、2 割をテストデータとしてニューラルネットワークに与えた。

2.3 ニューラルネットワーク

本研究では、IoT センサに搭載が容易な比較的小規模なニューラルネットワークを対象としている。そこで、

[†] 広島市立大学 大学院 情報科学研究科

表1 分類のためのラベル付

		theta			
		0	90	180	270
B	3	L0	L1	L2	L3
	6	L4	L5	L6	L7
	9	L8	L9	L10	L11
	12	L12	L13	L14	L15

※ただし, $A = 5$, $w = 2\pi[\text{rad/sec}](f = 1[\text{Hz}])$ と固定した.





図1 Bのゆらぎと正解率

※ $\sigma_A = 0.1$, $\sigma_w = 0.1$, $\sigma_\theta = 0.05$ と固定

図2 θ のゆらぎと正解率

※ $\sigma_A = 0.1$, $\sigma_B = 0.1$, $\sigma_w = 0.1$ と固定

比較的小規模な入力層 80 ノード, 出力層を 16 ノードとしたニューラルネットワークモデルを用いる. 今回は時系列波形の分類問題に用いるので出力層に softmax 関数を用いた. また, 各層の活性化関数は ReLU を用いている.

本稿ではニューラルネットワークの中間ノード数が 20 と 10 のニューラルネットワークを評価に用いた.

3. 評価結果

時系列波形の各パラメータに与えるゆらぎは正規分布とし, その標準偏差を σ_A , σ_B , σ_w , σ_θ とした. なお, σ_A , σ_B , σ_w , σ_θ がそれぞれ 0.1, 0.1, 0.1, 0.05 のときの学習率, 正解率はともに 100% であった. これを基準として波形の形状のゆらぎが学習率, 正解率に与える影響を評価する. 標準偏差 σ_B , σ_θ を変化させたときの学習率, 正解率の変化を図 1, 図 2 に示す. なお, 正解率と学習率は, 表 1 の位相条件により分類された 16 状態を時系列波形から予測したときの正解率と学習率である.

3.1 ゆらぎの影響

図 1 から, 振幅のゆらぎが大きくなっても正しく分類出来ることが確認できる. また, σ_B の値を大きくすると, $\sigma_B = 0.8$ あたりで正解率が 95% 程度となる. $\sigma_B = 0.8$ において基準振幅 $\pm 2\sigma_B$ (95% 信頼区間) をみると, $2\sigma_B = 1.6$ となり, B の振幅差分 3 を考えると差分の真中でも 95% 程度の分類正解率が得られることが分かった. しかし, 図 2 のように, 位相の揺らぎを大きくすると学習率は大きく減少する傾向が確認できた. $\sigma_\theta = 20^\circ$ で, 正解率が 95% 程度になっている. $2\sigma_\theta = 40^\circ$ でありまた, ラベル間の位相差は 90° であるのでラベル間に 10° のいずれのラベルとも判断できない位相領域があることが分かった. 上述の結果より, 振幅のゆらぎに比べ, 位相のゆらぎの方が正解率を低下させやすいことが分かる. ニューラルネットワークにおける波形パターン分類は, 振幅のゆらぎにはある程度対応可能だが, 位相に揺らぎが生じると別の波形パターンだと誤認する場合があると考えられる.

4. 結論

本研究では, 簡単な時系列波形を作成し, 正弦波の位相値と振幅値の組み合わせに対してラベル付けを行い, ニューラルネットワークでの分類を行った. その結果, 振幅が大きくゆらいでも波形パターンの認識は出来たが, 位相のゆらぎに対するニューラルネットワークの許容範囲が比較的狭いことが分かった.

今後の課題として生体用 IoT センサへの応用が考えられるが, センサからの生データには位相のゆらぎも多くある. そのため, ニューラルネットワークでの解析にあたっては, 位相に大きく影響されるような波形変換ではなく, スペクトログラム変換のような位相情報の影響を受けにくいデータの変換を行うとニューラルネットワークでより効果的な波形パターン分類が実現できると考えられる.

参考文献

- [1] 山室 冨, 松原 靖子, 川畑 光希, 井手 優介, 梅田 裕平, 古川 忠延, 大川 佳寛, 丸橋 弘治, 稲越 宏弥, 櫻井 保志: 深層学習を用いた時系列データの要約と分類, 第 10 回データ工学と情報マネジメントに関するフォーラム (DEIM2018), C3-3, 2018.
- [2] 山部 剛士, 堀江 和正, 塩川 浩昭, 柳沢 正史, 北川 博之: ディープラーニングによる脳波/筋電データを用いたマウスの睡眠ステージ判定, 第 10 回データ工学と情報マネジメントに関するフォーラム (DEIM2018), C3-5, 2018.
- [3] Gfeller, Beat and Frank, Christian and Roblek, Dominik and Sharifi, Matt and Tagliasacchi, Marco and Velimirovic, Miha: *SPICE: Self-Supervised Pitch Estimation*, IEEE/ACM Transactions on Audio, Speech and Language Processing, Vol.28, pp.1118–1128, 2020.