

生体データ解析におけるGANを用いたデータ処理

住谷雄樹[†] 堀江和正[‡] 塩川浩昭[‡] 北川博之[‡][†]筑波大学情報学群情報科学類 [‡]筑波大学計算科学研究センター

1 序論

生体信号解析において、信号に含まれるノイズは精度悪化の要因になる。これまで多くのノイズ除去手法が提案されてきたが、これらの大部分はノイズの形状や性質といった事前知識を前提としている。例えば、YongらはDNNを用いたノイズ除去手法[1]を提案しているが、この手法ではクリアな信号とそれに対してノイズを乗せた信号のペアを学習サンプルとして用いている。このノイズの乗った信号サンプルは、ノイズの事前知識なしに作ることは困難である。

一方、実環境で計測した生体信号には、形状や性質がわからないノイズが含まれることが多々ある。センサの位置ずれ、発汗による基準電位の変化等、想定されるノイズの種類が多すぎて、そのすべてを事前に想定することは難しい。そこで本研究では、ノイズに関する事前知識がない場合であっても、それを除去、もしくは軽減することのできる手法の開発に取り組んだ。

我々は、Generative Adversarial Network[2] (GAN)に注目した。これは画像の自動生成や変換に利用されるネットワークであり、学習時に入出力の直接的な対応を必要としない。GANを用いることで、クリアな信号とノイズを含む信号のペアを使わずに、ノイズをキャンセルする手法を開発できるのではと考えた。

以上を踏まえ、本研究では、GANを用いたノイズ除去手法を開発、提案すること、その性能を実験を通じて検討することを目的とする。

2 提案手法

本稿で提案する手法は、ジェネレータ(以下G)とディスクリミネータ(以下D)という2つのニューラルネットワークで構成される。Gはノイズな信号をクリアな信号に変換する。DはGによって変換された信号なのかもとクリアな教師信号であるのかを判別

する。GはDが判別できないようなノイズ除去の方法を学習し、Dは二つの信号を正確に判別する方法を学習する。これらが交互に学習を進めると、Gは高精度なノイズ除去の方法を獲得する。提案手法のネットワークを図1に示し、記号の説明を表1に示す。Gの前半は入力信号から特徴を得る部分となっている。後半は得られた特徴から信号を生成する部分で、クリア出力部とノイズ出力部の二つに分かれている。G全体として入力信号のノイズ分離を行う構成になっている。




図1: 提案するノイズ除去手法

表1: 記号とその意味

記号	意味
G	ジェネレータ
D	ディスクリミネータ
X_S	教師信号
X_A	変換前のノイズな信号
$X'_S(G(X_A))$	X_A のクリア出力部分
X'_N	X_A のノイズ出力部分
X'_A	X'_S と X'_N の合成信号

2.1 損失関数

単純にノイズなし信号とノイズあり信号で学習したのでは、「入力とは関係ないがDが教師信号だと判別する」ような信号を出力することが想定される。きちんと入力に紐づいた出力を得るために、本手法はGの損失に $L_{gen} = L_{fit} + L_{rec} + L_{noise}$ を用いる。 L_{fit} は従来のGANと同様に、出力を教師信号に近づける方向に定義する。 L_{rec} は X'_S と X'_N が X_A を分離したものであることを保証している。 L_{noise} は X'_S が教師信号ドメインのある点に収束してしまうことを防いでいる。なお、 $D(x)$ は入力 x が教師信号である確率を表す。

$$L_{fit} = 1 - D(G(X_A)) \quad (1)$$

$$L_{rec} = (X'_A - X_A)^2 \quad (2)$$

$$L_{noise} = (X'_N)^2 \quad (3)$$

Data Processing Using GANs in Bio-data Analysis

Yuki SUMIYA[†], Kazumasa HORIE[‡],Hiroaki SIOKAWA[‡] and Hiroyuki KITAGAWA[‡][†]College of Information Science, University of Tsukuba[‡]Center for Computational Sciences, University of Tsukuba

3 評価実験

人工信号と生体信号に対して実験を行い、それぞれについてノイズ除去自体の性能と、ノイズ部分のみを選択的に除去する性能を評価した。

3.1 モデル

G の前半部は4つの畳み込み層、後半部のクリア出力部とノイズ出力部はそれぞれ4つの逆畳み込み層で構成されている。活性化関数は出力層に線形関数、それ以外では Relu を用いた。D は2層の畳み込み層と全結合層で構成されていて、活性化関数は Relu を用いた。

3.2 データセット

信号は250Hzでサンプリングされており、2500点を1サンプルとして扱う。それぞれの信号にS/N比5%ほどのガウシアンノイズを乗せている。人工信号は正弦波Xと正弦波Yの合成波を使用した。Xは周波数 f_X が10~13の4パターン、位相 α_X が0~359の360パターン、振幅 A_X が1~4の4パターンの合計5760パターンである。それぞれのXに合成するYが周波数 $f_Y = f_X + 5$ 、位相 $\alpha_Y = \alpha_X$ 、振幅 A_Y が1~4の4パターンの合計4パターンあるので、使用するのは23040サンプルとなる。生体信号はマウス1匹の1日分の脳波で、34560サンプルである。合成波の実験、脳波の実験共に、半分をトレーニングデータ、残り半分をテストデータに使用した。

3.3 評価指標

ノイズ除去性能は(4)で評価する。ノイズ部分のみを選択的に除去する性能は、(5)と(6)で評価する。なお、合成波の結果は脳波の振幅に対する比率でスケールしている。

$$\text{mean}((X_S - G(X_A))^2) \quad (4)$$

$$\text{mean}((X_S - G(X_S))^2) \quad (5)$$

$$\text{mean}((X_A - G(X_A))^2) \quad (6)$$

3.4 実験結果

30エポック学習したモデルの各性能指標の値を表2に、実際のノイズ除去の様子を図2、図3に示す。表2の(4)の結果から、合成波に対するノイズ除去に成功しているといえる。しかし表2の(5)、(6)の結果から、ノイズデータとクリアデータのどちらも同程度変化させてしまっていることがわかる。このことから、ノイズ部分のみを選択的に削減することはできていないといえる。この原因は二つ考えられる。一つはトレーニングサンプルの不足である。もう一つは、G

表 2: 各信号に対する評価

	式 (4)	式 (5)	式 (6)
合成波	2.07E-03	2.10E-03	2.09E-03
脳波	114.67	114.28	114.61




図 2: 合成波のノイズ除去




図 3: 脳波のノイズ除去

の活性化関数が保持しておくべき情報まで歪めるため、入力信号をそのまま出力することが困難になっていることである。また、生体信号に対するノイズ除去の結果(図3)では滑らかな信号が出力されているが、これは元信号の高周波成分も除去されている。このことから、現状のモデルでは脳波などの比較的複雑な波形に対して、高周波成分を保持できるだけの表現能力を持たないことが分かる。

4 まとめ

人工的なデータについては、ノイズ除去の方法を学習を通じて獲得できた。本提案手法によりノイズ、クリアの信号ペアを用いずにノイズを除去することができたが、課題も多く見つかった。例えば、生体信号に関しては高周波成分が落ちてしまった。これはサンプル数や表現能力の不足が原因だと考えられるので、Gの層数を増やすなどして対応する。また、クリアな生体信号を入力した場合でも、ノイズを含む場合と同程度信号を変化させてしまい、ノイズ部分のみを選択的に除去することはできなかった。これには、残差ネットのように入力された信号をそのまま出力できる機構を追加するなどして対処していく予定である。

謝辞 本研究の一部は、文部科学省・地域イノベーション・エコシステム形成プログラム、科学研究費補助金・新学術領域研究”宇宙に生きる”「超ストレス環境・宇宙を見据えた新規睡眠覚醒制御手法の開発」、ならびに企業共同研究によるものである。

参考文献

- [1] Yong Xu et al., "A Regression Approach to Speech Enhancement Based on Deep Neural Networks", IJHE/ACM TASLP, VOL.23, NO.1, 7-19, JANUARY 2015.
- [2] Ian J. Goodfellow et al., "Generative Adversarial Nets", Neural Information Processing Systems (NIPS), 2014.