

1D CNN と Siamese Network を用いたポリグラフ検査における刺激の弁別 Stimulus Discrimination in the Polygraph Test Using 1D CNN and Siamese Network

細江 麻梨子[†]
Mariko Hosoe

1. はじめに

犯罪捜査におけるポリグラフ検査は、被検査者が事件に関して認識を有するか否かを質問項目に対する生理反応から推定する検査であり、生理心理学に基づく捜査の一手法として行われている。日本で行われているポリグラフ検査パラダイムである隠匿情報検査 (Concealed Information Test; CIT) [1, 2] では、被検査者が「特定の質問項目」と「その他の質問項目」を弁別しているか否かの判定が重要となる。複数の質問項目 (質問刺激) を提示したときに、特定の項目に弁別的な反応が生起しているか否かをデジタルポリグラフ装置により記録される生体信号の変化から捉える。判定にあたり、生体信号は個人差が大きく、各被検査者でどの生理指標に弁別的な生理反応が発現されやすいかを考慮した弁別モデルの構築が重要となる。本研究では、実験場面で収集された大規模なポリグラフ検査 (CIT) データ [2] を用い、1次元の生体信号に対して 1 Dimensional Convolutional Neural Network (1D CNN) [3] と Siamese Network [4] による各質問刺激に対する生理反応の違いに着目する弁別モデルを構築し、提案モデルの CIT への有用性を検討した。

2. 研究背景

2.1 CIT における生体信号の弁別的反応

現在の日本のポリグラフ検査では、皮膚電導度反応 (Skin Conductance Response; SCR), 皮膚電導度水準 (Skin Conductance Level; SCL), 呼吸運動 (Respiration; Resp), 心拍数 (Heart Rate; HR), 規準化脈波容積

(Normalized Pulse Volume; NPV) [5] を計測している。文献 [2, 6] では、CIT の枠組みにおける裁決項目 (関連項目) に対する生理反応と非裁決項目 (非関連項目) に対する生理反応を比較、検討している。関連項目に認識を有する被検査者では、関連項目が提示されたときには、非関連項目が提示されたときと比較して、SCR と SCL の増大、Resp の抑制、HR と NPV の減少という弁別的反応パターンが一般的にみられることが確認されている。

2.2 生体信号処理への深層学習技術の応用

心電図 (Electrocardiogram; ECG) から不整脈波形の分類や心臓活動の異常検知を行う研究では、深層学習を用いたアプローチが数々提案されており、従来の Handcrafted な特徴抽出を用いる手法よりも高い精度を示している [7]。また、ECG 波形と呼吸運動信号からの心的なストレス状態の検出 [8]、光電式容積脈波 (Photoplethysmogram; PPG) 波形から感情の推定 [9]、装着した加速度センサー等からの人間の行動認識 [10] においても 1D CNN を用いた手法が提案されており、生体信号処理の分野では深層学習技術に応用した研究が盛んに行われている。ポリグラフ検査研究においては、文献 [11] でニューラルネットワークを用いた手法が提案されているが、当時の計算環境や計算手法等の問題によりモデルが過学習し、高い正判定率が得られないことが示されている。本研究では、生体信号を扱う CIT においても深層学習技術の応用が有用であると考え、図 1 に示す 1D CNN による特徴抽出と Siamese Network 構造による学習で過学習を抑制した精度の高い生理反応の弁別モデルを構築した。

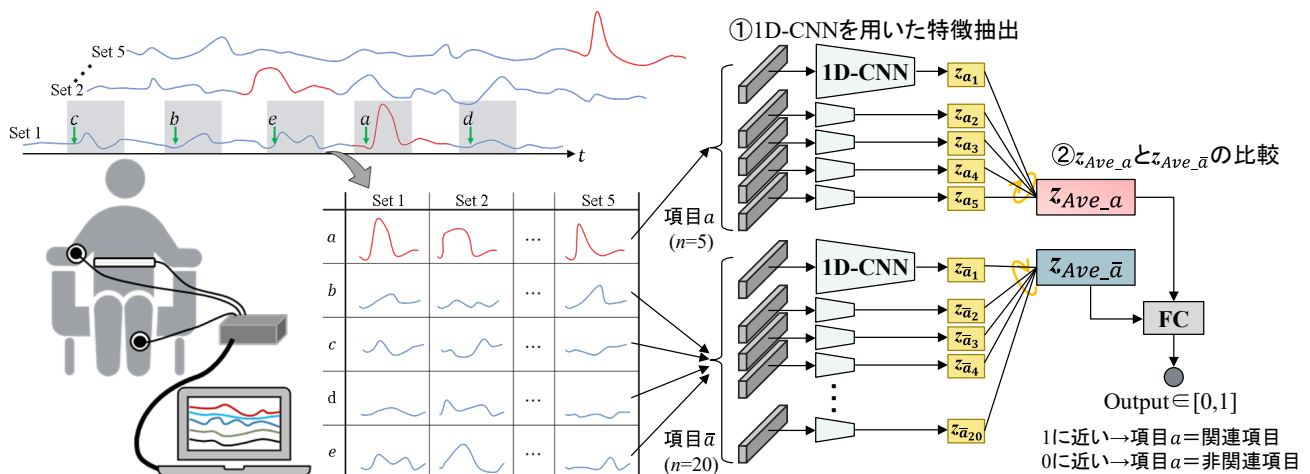


図 1 提案手法の概要

[†] 岐阜県警察本部刑事部科学捜査研究所
Forensic Science Laboratory, Gifu Prefectural Police
Headquarters

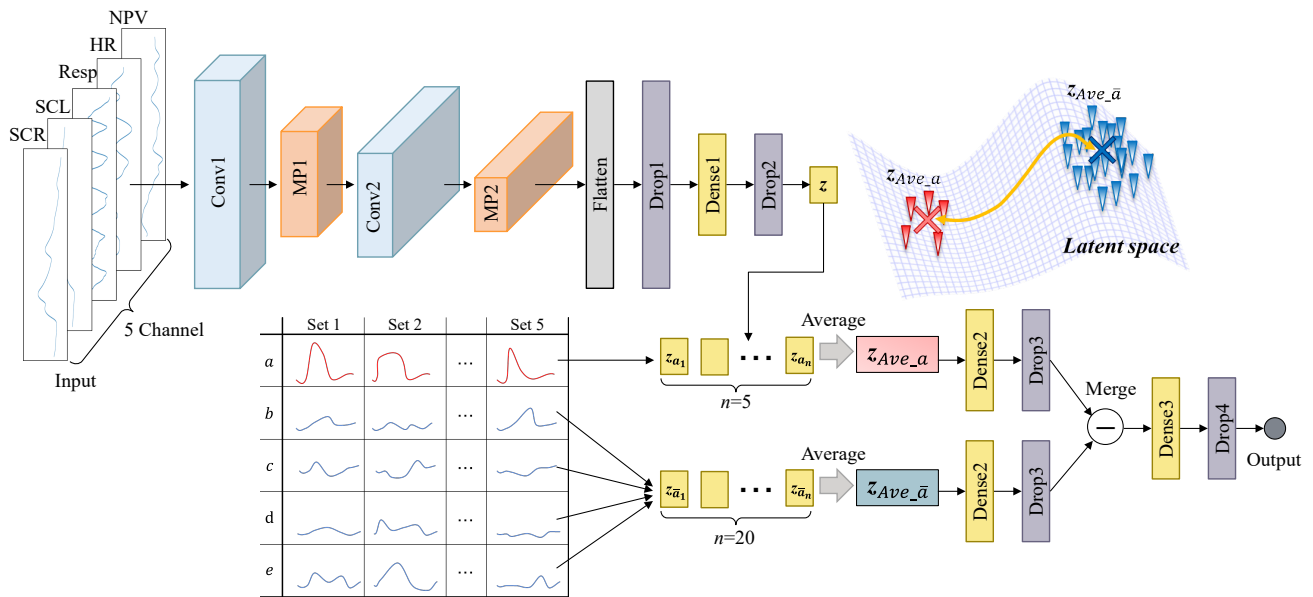


図 2 1D CNN と Siamese Network による弁別モデルのネットワーク構造

3. 提案手法

刺激に対する生理反応は、その刺激に対して認識を有する場合とそうでない場合では異なり、その相異を生体信号の変化パターンとして捉えるために、1D CNN による特徴抽出と Siamese Network による特徴比較を組み合わせた End-to-End の弁別モデルを構築した。CIT においては、複数項目からなる質問表を、提示順序を変えながら複数回（セット）提示する。図 1 には、5 項目からなる質問表を一定の刺激提示間隔で提示する場合、1 セットあたり 5 個の生理反応が得られ、5 セット測定をすることで各項目の反応が 5 回分記録される状況を示す。各項目の生理反応について、他の項目とは異なる生理反応パターンであるか否かを調べることで、特定の項目を他の項目と弁別しているか否かの推定を行う。図 2 および表 1 には、構築した弁別モデルのネットワーク構造と各層の詳細を示す。以下では、構築した弁別モデルのネットワークと学習方法について述べる。

3.1 1D CNN による特徴抽出

1 次元の生体信号から、特定の信号パターンを検出するために 1D CNN を用いた研究が多くみられる。本研究では、1D CNN により弁別の推定に寄与する変化パターンの特徴を抽出（特徴表現）するために、ポリグラフ装置で測定される 5 種類の生体信号の相互の変化パターンが弁別の推定に重要と考え、各生体信号を個別に扱うのではなく、同期した複数チャンネルの信号として 1D CNN への入力とする。

3.2 Siamese Network による弁別モデル

1D-CNN により、各刺激に対する生体信号から弁別に有用な特徴が表現可能な潜在空間が求められる。この潜在空間上において、「特定の項目の 5 個の生理反応の平均ベクトル」と「特定の項目以外の 4 項目の計 20 個の生理反応の平均ベクトル」を求め、同一セット内における刺激の提示位置や異なるセット間における生体信号のバラつきを抑

表 1 モデルの各層の詳細

Layer name	Layer type	Output shape	Parameters
Input	Input	250 × 5	-
Conv1	Convolution	250 × 32	Activation=ReLU Kernel=5, Stride=1
MP1	MaxPooling	125 × 32	Kernel=2, Stride=1
Conv2	Convolution	125 × 64	Activation=ReLU, Kernel=3, Stride=1
MP2	MaxPooling	62 × 64	Kernel=2, Stride=2
Flatten	Flatten	3,968	-
Drop1	Dropout	-	Dropout rate=0.5
Dense1	Dense	512	Activation=ReLU, L2 regularization ($\lambda=0.01$)
Drop2	Dropout	-	Dropout rate=0.5
z	Dense	z dim	-
Dense2	Dense	z dim	Activation=ReLU L2 regularization ($\lambda=0.01$)
Drop3	Dropout	-	Dropout rate=0.5
Merge	Merge	z dim	Absolute subtraction
Dense3	Dense	z dim	Activation=ReLU L2 regularization ($\lambda=0.01$)
Drop4	Dropout	-	Dropout rate=0.5
Output	Dense	1	Activation=Sigmoid

制する。各平均ベクトルについて、その類似性を評価するネットワークを通して、特定項目がその他の項目とは異なる生理反応分布から生成されたものか否かの推定値(0~1)を出力する。特定の項目が関連項目である場合は 1、非関連項目である場合は 0 とした教師データ $T=(t_0, t_1, \dots, t_N \in \{0,1\})$ と出力値 $O=(o_0, o_1, \dots, o_N \in [0,1])$ の間の誤差を Binary Cross Entropy により求め、誤差逆伝搬に用いる誤差関数と

する。出力値が 0.5 よりも大きい場合には、対象とする特定項目の生理反応がその他の項目の生理反応とは異なる分布から生成された可能性が高く、特定項目を他の項目と弁別している可能性が高いと推定することができる。一方、出力値が 0.5 よりも小さい場合には、特定項目をその他の項目とは弁別していない可能性が高いと推定することができる。

4. 実験

実験場面での大規模な CIT データ[2]を用いて、生体信号の質問項目に対する弁別モデルを構築し、提案手法の CIT における刺激弁別への有用性を検証した。

4.1 実験データ

文献[2]では、日本の犯罪捜査における CIT の正確性を調査するために、実務に沿った手続きのもので実験場面での CIT のデータを収集している。実験参加者 167 名 (男 88 名, 女 79 名, $M=37.1$ 歳, $SD=11.6$ 歳) のうち, 86 名は模擬窃盗課題を行うことで盗品を記憶させる記銘群とし, 残りの 81 名は模擬窃盗課題を行わない非記銘群に割り振られた。実験者は, 実務と同様の手続きで, 事前検査と盗品についての CIT を実施した。事前検査は, 実験参加者に数字が記載された 5 枚カードから 1 枚のカードを選択してもらい, そのカードの数字を記憶させたうえで, 数字を質問項目とした検査を行ったものであり, 全実験参加者は 1 個の数字に対して認識を有する状態での CIT のデータが収集されたものである。一方, 盗品を質問項目とした検査は, 記銘群の実験参加者については 1 個の盗品に対して認識を有する状態の CIT データが収集され, 非記銘群の実験参加者からは全ての盗品に対して認識を有さない状態の CIT データが収集された。

本実験では, 手続き上の問題及び測定上の問題が確認された 5 名のデータを除いた 162 名の 2 種類 (数字, 盗品) の質問表による CIT データを実験に用いた。各実験参加者における 2 種類の質問表についてのデータは, 質問表の種類によって認識の有無による弁別の反応に違いはないと考え, 質問の種類でデータを分割することなく一括の CIT データとして学習に用い, 質問の種類に依存しないモデルの構築を行った。また, 実務への応用を考えた場合には, 特定の被検査者に特化した弁別モデルを構築することは実用的ではないため, 新規の被検査者に対しても弁別可能な被検査者非依存型のモデルとしての学習と評価を行った。

4.2 前処理

各質問刺激について, 刺激提示前 5 秒から刺激提示後 25 秒までの 30 秒間のデータを刺激に対して生じた生理反応を捉えるための対象区間として切出し, 各質問表について得られる 5 項目の 5 セット分の生理反応 (計 25 個) が弁別モデルへの入力データとなる。各生理反応データについて, 文献[2]の分析に用いられている指標を参考に, デジタルポリグラフ装置で記録された ECG から HR, PPG の直流成分と交流成分から NPV を算出し, SCR, SCL, Resp, HR, NPV の 5 種類の生理指標を実験に用いる。1000Hz で収集された各生理指標のデータについて 10Hz にダウンサンプリングした後, 各指標を同一セット内で標準化する。

本研究では, 時系列データの変動パターンに関わる情報

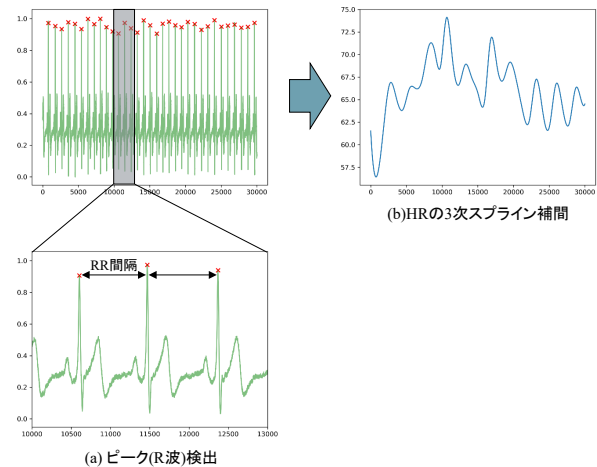


図 3 HR の算出

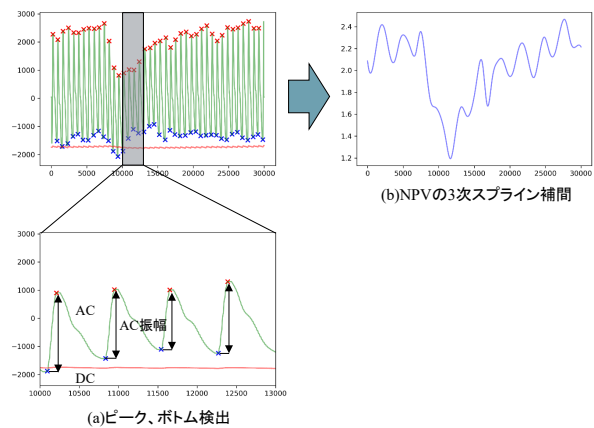


図 4 NPV の算出

の損失を避けるために必要以上の前処理は行わず, ポリグラフ検査における各生理指標の反応発現の順序等の時系列的な特徴の重要性も考慮した。

4.2.1 HR の算出

ECG に関する研究[12]の前処理手法を参考に, 図 3 に示すように, ECG 信号についてノイズ除去と平滑化微分法により自動で検出したピーク (R 波) の間隔 (RR 間隔) から瞬時心拍率 ($=60,000/RR$ 間隔) を求め, 拍動ごとに算出される瞬時心拍率を 3 次スプライン関数により補間したものを HR として用いる。

4.2.2 NPV の算出

ポリグラフ検査において有用性が確認されている NPV は, 指先に装着した透過型指尖容積脈波の交流成分 (AC) と直流成分 (DC) から算出される。図 4 に NPV 算出の流れを示す。AC 信号についてノイズ除去と平滑化微分法により自動でピークと波形の立ち上がり点 (ボトム) を検出し, AC 振幅を対応するボトム-ピーク間の DC 平均で除すことで NPV を算出する。拍動ごとに算出される NPV について 3 次スプライン関数により補間したものをを用いる。

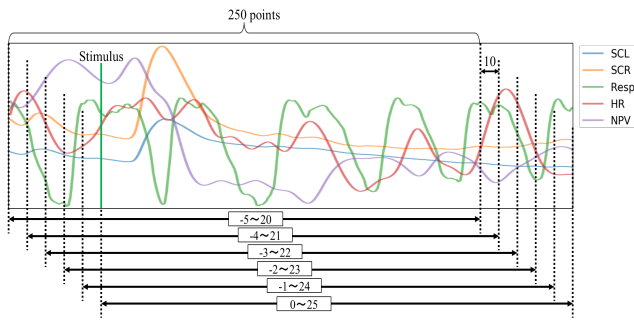


図 5 スライド窓によるデータ拡張

4.2.3 セット内標準化

本実験で用いる CIT データは、各セットで質問の刺激呈示間隔を最低 25 秒とり、1 セットについて 5 項目の刺激を断続的に提示することで得られる生理反応から成る。生理反応には、新規の刺激に対して大きく生起する性質、複数回同一もしくは類似性の高い刺激が提示された場合には生理反応が徐々に低下する性質がある。CIT においても同一セット内における順序による生理反応の違い、1 セット目と 5 セット目の時間経過に伴う生理反応の違い等として現れることが示唆されている。生理反応以外の要因であるセット内の生体信号におけるトレンド信号を抑制すること、複数の指標を統合して扱うために、同一セット内における全データポイントの平均と標準偏差から標準化を行う処理を各セットで行うセット内標準化により標準化値を求める。求められた 5 指標の標準化値を 5 チャンルの信号としてモデルへの入力とする。

4.3 データ拡張

質問刺激に対して何らかの生理反応が生起するタイミングを計測するため、実験者は口頭及び視覚提示により質問刺激の提示を開始するタイミングをボタン押しで入力し、その時点を基準として分析を行う。反応発現のタイミングと刺激提示時点を表すボタン押しのタイミングには、実験参加者及び実験者による変動の存在は否定できない。本研究では、それらの変動を想定し、刺激提示前 5 秒から刺激提示後 25 秒までの 30 秒間のデータ（ダウンサンプリング後にデータにおける 300 ポイント分に相当）について図 5 に示すようにウィンドウ窓を 25 秒、スライド幅を 1 秒として、刺激提示時点を基準時点 0 秒とした -5 秒～20 秒、-4 秒～21 秒、-3 秒～22 秒、-2 秒～23 秒、-1 秒～24 秒、0 秒～25 秒の 6 区間で切出した 25 秒間のデータ（200 ポイント分に相当）を作成することで学習データの拡張を行う。

4.4 学習データ対の作成

数字を質問項目とした事前検査については、全実験参加

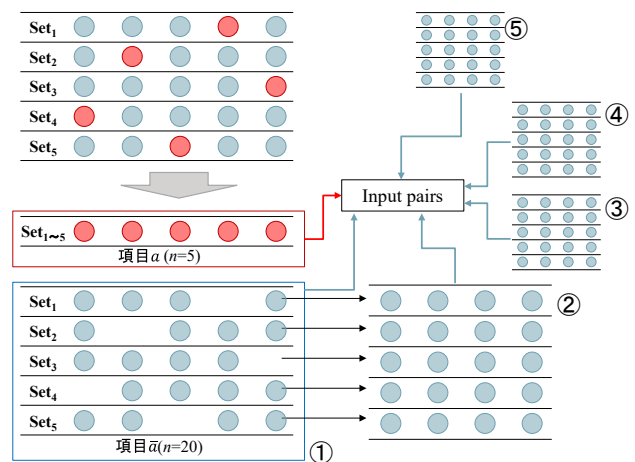


図 6 学習データ対の作成

者の質問表は、1 個の関連項目（認識を有する項目）と 4 個の非関連項目（認識を有さない項目）から成る。盗品に関する検査では、記銘群の実験参加者の質問表は、事前検査と同様に 1 個の関連項目と 4 個の非関連項目から成り、非記銘群では 5 個の非関連項目から成る。各質問表について、特定の項目 5 個とそれ以外の項目 20 個を対とした学習データを作成した場合、特定の項目が非関連項目である場合の学習データ対よりも、特定の項目が関連項目である場合の学習データ対が少なく、学習にあたってはデータの偏りにより適切なモデルの学習が困難となることが考えられる。

このデータクラスの不均衡問題に対しては、図 6 に示すオーバーサンプリングにより関連項目の学習データ対の数を増やすことで対応した。特定項目が関連項目である場合、残りの 20 個の非関連項目との学習データ対①に加え、非関連項目については、各セットから重複を許してランダムに 4 項目を選択することで非関連項目のデータを 4 個作成し②～⑤、それらと関連項目とのデータ対も学習データとすることで、学習データ対における特定の項目が関連項目である数と非関連項目である数が同程度となるように学習データ対を作成する。

4.5 実験条件

実験データの詳細を表 2 に示す。実験参加者単位でモデル学習用とテスト用に分割した。提案モデルにおける 1D CNN からの出力ベクトルの次元数 z dim は 100 に設定し、前処理の方法、学習時のバッチサイズ、評価時の 30 秒間のテストデータからの 25 秒のデータの切出し方を変えて、ROC 曲線下面積 (Area Under the ROC Curve; AUC) から各モデルのテストデータに対する弁別性能を評価し、提案手法の有用性について検討した。

表 2 実験データの詳細
(*はスライド窓により拡張されたデータをもと作成されたモデル学習用のデータ対の数を表す)

	Subjects	Encode	No Encode	Critical Items	Non Critical Items	Critical Pairs	Non Critical Pairs
Train	120	60	60	180	1,020	*5,400	*6,120
Test	42	23	19	65	355	65	355




図 7 5分割交差検証におけるデータの内訳

4.5.1 比較実験

提案手法では、データの前処理として CIT 研究において一般的なセット内標準化を行っている。深層学習の前処理として、データの最大値を 1, 最小値を 0 とする正規化が用いられることも多いため、標準化と正規化の前処理手法の違いによる精度比較を行った。また、生体信号には個人差が大きいことから、学習にあたっての誤差の更新のタイミングも重要になると考え、バッチサイズを 32,64,128,256,512 とした 5 パターンでのモデルの学習を行い、バッチサイズによる評価結果を比較した。モデル学習の最適化手法には Adam を $\alpha=0.0001$, $\beta_1=0.9$, $\beta_2=0.999$ に設定して用いた。300 エポックを上限として検証用データの誤差が連続して 10 エポック減少しなくなった時点で学習を終了することとした。

4.5.2 学習・評価方法

生体信号は個人差が大きいことから、どのデータを用いて学習したモデルであるかによってテストデータに対する精度の違いがみられることが想定されるため、図 7 に示すように 5 分割交差検証法で 5 つのモデルを学習し、各モデルのテストデータに対する精度を求め、その平均精度から提案手法を評価した。

テストデータを用いた評価にあたっては、30 秒間のデータのうち、提案モデルによる刺激の弁別に適した入力データ区間について検討するため、6 パターン（刺激提示前 5 秒～刺激提示後 20 秒、刺激提示前 4 秒～刺激提示後 21 秒、刺激提示前 3 秒～刺激提示後 22 秒、刺激提示前 2 秒～刺激提示後 23 秒、刺激提示前 1 秒～刺激提示後 24 秒、刺激

提示前 0 秒～刺激提示後 25 秒）で切出した 25 秒のデータについて結果を比較した。

4.6 結果

弁別性能を評価した結果を表 3 に示す。全モデル中、前処理はセット内標準化とし、バッチサイズを 256、刺激提示前 2 秒から刺激提示後 23 秒までの 25 秒間を入力とした場合に最も弁別性能が高く、 $AUC=0.8890$ となった。また、バッチサイズ及び入力データの区間による性能の差と比較して、前処理による性能の差が大きいことが確認された。

5. 考察

項目単位の生理反応の比較を行う弁別モデルを構築し、テストデータによる評価を行ったところ、CIT の先行研究において行われている前処理であるセット内標準化を行ったほうが、0 から 1 の正規化よりも弁別性能が高いことが確認された。この理由としては、各セットにおける刺激提示位置のセット間の生体信号の変動を考慮したセット内標準化が CIT パラダイムにおける前処理として弁別的反応を推定するために有効であることを示している。また、バッチサイズと入力データ区間の違いによる精度の差はあまり大きくはないが、実験パラメータ中の最小バッチサイズである 32 と比較して 256 としたときの精度が高いことから、生体信号の個人差を考慮した学習においては、バッチサイズはある程度の大きさが必要と考える。入力データ区間については、刺激提示前の情報を含んだものの性能が高いことから、刺激提示前の生体信号をベースラインとした変化として生理反応を捉えることが、弁別的反応の推定に重要と考える。

提案モデルについて、1D CNN のフィルタサイズやカーネルサイズ、正則化手法、ドロップアウト率、 z dim の次元数等のハイパーパラメータ設定には検討の余地がある。また、深層化や残差ネットワーク、時系列データ処理に対応したモデルを併用することによる改善も可能と考えられる。

本研究では、刺激のセット内における提示位置や、何番目のセットの生理反応であるかについての情報を付与せずにモデルの学習を行った。同一セット内における生理反応の変動にも認識の有無で差が現れることが示唆されており

表 3 評価結果(AUC)

(太字部分は各 Input window における最大値、青色背景部分は各前処理手法における最大値を表す)

Preprocessing	Input window	Batch size				
		32	64	128	256	512
Standardization N(0,1)	-5~20	0.8773	0.8736	0.8623	0.8817	0.8713
	-4~21	0.8764	0.8770	0.8559	0.8815	0.8654
	-3~22	0.8743	0.8839	0.8603	0.8834	0.8676
	-2~23	0.8778	0.8796	0.8674	0.8890	0.8678
	-1~24	0.8736	0.8790	0.8693	0.8857	0.8674
	0~25	0.8780	0.8816	0.8701	0.8853	0.8712
Min-Max Normalization [0,1]	-5~20	0.8300	0.8391	0.8351	0.8300	0.8254
	-4~21	0.8337	0.8340	0.8316	0.8250	0.8291
	-3~22	0.8294	0.8332	0.8346	0.8270	0.8302
	-2~23	0.8377	0.8390	0.8432	0.8478	0.8395
	-1~24	0.8405	0.8438	0.8492	0.8449	0.8433
	0~25	0.8224	0.8254	0.8260	0.8253	0.8183

[13], CITにおける生体信号の特性を踏まえたモデルの構築が弁別性能の向上にあたり必要と考える。

6. むすび

本研究では、記憶検査の一種であるポリグラフ検査における生体信号の刺激に対する弁別的反応を推定する深層学習モデルを提案した。個人差の大きな人を対象としたデータではあるが、被検査者に依存することなく、高い精度で弁別可能なモデルが構築できた。生理心理学領域における研究により示されている記憶の有無に伴う生理反応の違いを考慮したモデルの構築による精度向上やモデルの解釈可能性を高めることにより、医療分野におけるコンピュータ支援診断システムのような実応用に向けた研究を今後の課題とする。

参考文献

- [1] I. Matsuda, T. Ogawa, and M. Tsuneoka “Broadening the use of the concealed information test in the field”, *frontiers in Psychiatry*, Vol.10 (2019).
- [2] 小川時洋, 松田いづみ, 常岡充子, “隠匿情報検査の妥当性: 記憶検出技法としての正確性の実験的検証”, *日本法科学技術学会誌*, Vol.18, No.1, pp.35-44 (2013).
- [3] H. P. Martinez, Y. Bengio, and G. N. Yannakakis, “Learning deep physiological models of affect,” *IEEE Computational Intelligence Magazine*, Vol.8, No.2, pp.20-33 (2013).
- [4] J. Bromley, I. Guyon, and Y. LeCun, “Signature verification using a “Siamese” time delay neural network,” *Proc. Advances in Neural Information Processing Systems (NIPS)*, Vol.7, No.4, pp.669-688 (1993).
- [5] 澤田幸展, “指尖容積脈波再訪,” *生理心理学と精神生理学*, Vol.17, No.1, pp.33-46 (1999).
- [6] 廣田昭久, 小川時洋, 松田いづみ, 高澤則美, “隠匿情報検査時に生じる自律神経系反応の生理機序モデル”, *生理心理学と精神生理学*, Vol.27, No.1, pp.17-34 (2009).
- [7] F. Murat, O. Yildirim, M. Talo, U. B. Baloglu, Y. Demir, and U. R. Acharya, “Application of deep learning techniques for heartbeats detection using ECG signals-analysis and review,” *Computers in Biology and Medicine*, Vol.120, 103726 (2020).
- [8] W. Seo, N. Kim, S. Kim, C. Lee, and S. -M. Park, “Deep ECG-respiration network (DeepER Net) for recognizing mental stress,” *Sensors*, Vol.9, No.13, 3021 (2019).
- [9] M. S. Lee, Y. K. Lee, D. S. Pae, M. T. Lim, D. W. Kim, and T. K. Kang, “Fast emotion recognition based on single pulse PPG signal with convolutional neural network,” *Applied Sciences*, Vol.9, No.16, 3355 (2019).
- [10] C. A. Ronao and S.-B. Cho, “Human activity recognition with smartphone sensors using deep learning neural networks,” *Expert Systems with Applications*, Vol.59, pp.235-244 (2016).
- [11] 足立浩平, 鈴木昭弘, “ポリグラフ検査へのニューラルネットワークの応用”, *科学警察研究所報告 法科学編*, Vol.48, No.1, pp.36-39 (1995).
- [12] S. K. Berkaya, A. K. Uysal, E. S. Gunal, S. Ergin, S. Gunal, and M. B. Gulmezoglu, “A survey on ECG analysis,” *Biomedical Signal Processing and Control*, Vol.43, pp.216-235 (2018).
- [13] 小川時洋, 松田いづみ, 常岡充子, “隠匿情報検査時の生理変化の系列内変動,” *心理学研究*, Vol.90, No.4, pp.426-432 (2019).