

16th SICE Symposium on Computational Intelligence

December 19-22, 2019, Osaka

第16回コンピューターショナル・インテリジェンス研究会

講演論文集

期 日：2019年12月19日(木)，20日(金)

会 場：近畿大学 東大阪キャンパス

SICE[®]

主 催：計測自動制御学会 システム・情報部門

企 画：コンピューターショナル・インテリジェンス部会，知能工学部会

協 賛：システム制御情報学会，日本知能情報ファジィ学会，進化計算学会，電気学会，
情報処理学会，日本神経回路学会，日本機械学会，人工知能学会，ヒューマン
インタフェース学会，電子情報通信学会，IEEE Computational Intelligence
Society Japan Chapter (CISJ)，IEEE Systems, Man, and Cybernetics Society Japan
Chapter

カタログ番号 19PG 0012

第 16 回コンピューテーショナル・インテリジェンス研究会

講演論文集

カタログ番号 19PG0012

日時 : 2019 年 12 月 19 日 (木) 15:30~16:50, 20 日 (金) 9:30~14:45

会場 : 近畿大学 東大阪キャンパス ブロッサムカフェ

プログラム

12月19日(木)

15:30~16:50 (4 件) 司会 半田 久志 (近畿大学)

- 1 [構造適応型 DBN の物体検出法におけるパラメタ自動調整と建築設備図面における図面記号への適用](#) 1
市村 匠, ○鎌田 真(県立広島大学 地域基盤研究機構),
多羅尾 直, 山口 亮 (株式会社 中電工)
- 2 [KL 情報量に基づく学習後の構造適応型 DBN におけるニューロン付加手法の提案と顔表情画像への適用](#) 7
○鎌田 真, 市村 匠(県立広島大学 地域基盤研究機構)
- 3 [拡張 Floyd-Warshall 法を用いたゴール条件付き強化学習](#) 13
○谷口 明日斗, 佐々木 史紘, 山科 亮太 (株式会社リコー)
- 4 [四元数表現を持つ量子ビットニューラルネットワークの時系列予測への適用](#) 21
○手操 卓也, 磯川 悌次郎, 松井 伸之, 上浦 尚武 (兵庫県立大学)

12月20日(金)

9:30~10:10 (2 件) 司会 深井 寛修 (株式会社明電舎)

- 5 [制限ボルツマンマシンによる倒立振子の状態推定](#) 25
○橋本 尚典, 松井 伸之, 伊丹 哲郎, 磯川 悌次郎 (兵庫県立大学)
- 6 [四元数畳み込みニューラルネットワークの構築と性能評価](#) 30
○本郷 嵩人, 磯川 悌次郎, 松井 伸之, 上浦 尚武 (兵庫県立大学)

10:20~12:20 CIFS 特別企画 : CI とモデリング

第1部 講演

統計数理研究所 相吉英太郎先生

第2部 パネル討論

モデレータ 九州大学 村田純一先生

パネリスト 東北大学 本間経康先生、広島県立大学 市村匠先生、関西大学/京都工芸繊維大学 黒江康明先生

13:30~14:45 (4件) 司会 小川 愛実 (慶應義塾大学)

- | | | | |
|--------|---|--------------------------------------|----|
| 7 | 住宅内温熱環境が呼吸機能・脳機能に与える影響の解析 | ○渡邊 秀斗, 満倉 靖恵 (慶應義塾大学) | 34 |
| 8 | 心弾道図を用いた外乱に頑健な心拍推定手法 | ○中井川 隼也, 満倉 靖恵 (慶應義塾大学) | 38 |
| 9 | γ帯域の脳神経活動を増大させる聴覚刺激の確立手法の提案 | ○宮沢 遼平, 石川 智愛, 満倉 靖恵, 安井 正人 (慶應義塾大学) | 42 |
| 1
0 | 長時間連続計測によるステロイドホルモン投与マウスの行動意欲推定 | ○葛西凜々子, 満倉靖恵 (慶應義塾大学) | 46 |

構造適応型 DBN の物体検出法におけるパラメタ自動調整と 建築設備図面における図面記号への適用

市村 匠 ○鎌田 真 (県立広島大学 地域基盤研究機構)
多羅尾 直 山口 亮 (株式会社 中電工)

Automatic Parameter Tuning of Object Detection Method by Adaptive Structural Deep Belief Network and Its Application to Symbol Recognition on Building Facilities Drawings

*S. Kamada, T. Ichimura (Research Organization of Regional Oriented Studies,
Prefectural University of Hiroshima)
T. Tarao, and R. Yamaguchi (Chudenko Corporation)

Abstract— Deep Learning has a hierarchical network architecture to represent the complicated feature of input patterns. We have developed the adaptive structure learning method of Deep Belief Network (DBN) that can discover an optimal number of hidden neurons for given input data in a Restricted Boltzmann Machine (RBM) by neuron generation-annihilation algorithm, and can obtain appropriate number of hidden layers in DBN. Moreover, an object detection method for the DBN architecture was proposed for localization and category of objects. In this paper, the object detection method is applied to symbol recognition on building facilities drawings. The parameters of the object detection method are automatically determined and the method can reach 98.5% of the detection accuracy for the dataset.

Key Words: Deep Learning; Deep Belief Network; Restricted Boltzmann Machine, Adaptive Structure Learning; Symbol Detection on Building Facilities Drawings

1 はじめに

近年, Deep Learning(深層学習)^{1, 2)} が人工知能の理論的な研究だけでなく, 産業を中心とした様々な場面で利用され始めている。ILSVRC と呼ばれる画像認識の世界大会では, GoogleNet³⁾ や ResNet⁴⁾ で知られるように, 人間の認識能力を大きく上回る Deep Learning モデルが発表されている。従来の階層型ニューラルネットワークとは異なり, Deep Learning では事前学習が行われることが大きな特徴の一つである。各層ごとに学習を行うことで入力データに含まれる特徴を事前学習し, それらの複数の特徴を階層的に組み合わせることで, データ全体の特徴を高い精度で表現することができる。

確率モデルである Restricted Boltzmann Machine(RBM)⁵⁾ を事前学習し, その RBM を階層化することで, 高度な分類性能をもつ Deep Belief Network(DBN)⁶⁾ がある。我々は, 入力データ空間に応じて適切と考えられる隠れニューロン数及び隠れ層数を学習中に自動で求める構造適応型学習法を提案している^{7, 8)}。提案手法は, 画像ベンチマークデータセット⁹⁾ に対して従来手法よりも高い分類精度を示している^{10, 11)}。また, 学習済みの構造適応型 DBN のネットワーク構造を用いて, 画像の中の特定の部位を矩形として検出する物体検出法を開発し, CXR8 などの胸部レントゲン写真のベンチマークデータセットに対して高い検出精度を示した¹²⁾。

本論文では, 開発した物体検出法を建築設備図面画像に適用し, 画像内に含まれる図面記号の検出を行った。しかし, 検出アルゴリズムで使われているパラメタの設定によっては, 一部の部品に対して検出精度が下がることが問題であった。これは, 部品ごとの画像

のサイズや特徴が異なることや, 部品の出現頻度が図面によって異なるためである。このため, 開発した物体検出法における検出パラメタを図面記号の重要度(出現頻度)や希少度(出現頻度の逆数)に応じて自動調整する方法を提案し, 適用したところ従来手法より高い精度で検出できたので, 報告する。

2 構造適応型 Deep Belief Network による学習手法

2.1 Restricted Boltzmann Machine

RBM⁵⁾ は, 可視層と隠れ層の2層から構成されるネットワーク構造を持ち, 確率分布に基づいて入力データに含まれる特徴を隠れニューロン上で学習することができる。RBMの学習では, 与えられた入力データに対して, 式(1)のエネルギー関数を最小にするパラメタ $\theta = \{b, c, W\}$ が最尤推定により求められる。

$$E(\mathbf{v}, \mathbf{h}) = -\sum_i b_i v_i - \sum_j c_j h_j - \sum_i \sum_j v_i W_{ij} h_j, \quad (1)$$

$$p(\mathbf{v}, \mathbf{h}) = \frac{1}{Z} \exp(-E(\mathbf{v}, \mathbf{h})), \quad (2)$$

$$Z = \sum_{\mathbf{v}} \sum_{\mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h})) \quad (3)$$

ここで, v_i は i 番目の可視ニューロン, h_j は j 番目の隠れニューロンである。 b_i は v_i に対するパラメタ, c_j は h_j に対するパラメタ, W_{ij} は v_i と h_j 間の重みである。 $\mathbf{v} \in \{0, 1\}^I$ と $\mathbf{h} \in \{0, 1\}^J$ はそれぞれ可視層と隠れ層のベクトルであり, I と J は可視ニューロン数, 隠れニューロン数である。式(2)は入力 \mathbf{v} と \mathbf{h} の確率分布である。式(3)の Z は分配関数(partition function)であり, \mathbf{v} と \mathbf{h} の全ての2値のパターンの組み合わせ

に対するエネルギーを示す. 一般的に, RBM では計算量の観点から Contrastive Divergence(CD) 法¹³⁾ による学習が行われる.

2.2 Deep Belief Network

Deep Belief Network(DBN) は, 事前学習を行った RBM を複数積み重ねることで, 入力データの特徴を階層的に学習することができる Deep Learning 手法である⁶⁾. DBN 自体は RBM を積み重ねたモデルであるため教師なし学習モデルであるが, 最上位層に出力層を加え, ソフトマック法等により計算された出力値と教師信号との誤差を最小化することで, 教師あり学習に適用できる.

2.3 ニューロン生成/消滅アルゴリズム

我々は, RBM の学習中において最適な隠れニューロン数を自動で求めるニューロン生成/消滅アルゴリズムによる構造適応型学習手法を提案している⁷⁾. ニューロン生成は, 学習中におけるパラメタの変分に基づいて行われる. 例えば, 学習データに対して十分な数の隠れニューロンがあれば, 一般的に学習が進むにつれて重みベクトルの変分は小さな値になる. 一方で, パラメタの変分が収束しない場合は, 学習データに対するネットワークの表現能力が不足しており, データが持つ特徴(確率分布)を隠れニューロン上で分離できていないことが原因だと考えられる. このような場合, 関連する位置に隠れニューロンを挿入することで, 多くの次元でデータを表現できると考えられ, 学習が収束する. 我々の調査では, RBM の3つのパラメタ $\theta = \{b, c, W\}$ のうち, CD 法による学習の収束に関係しているパラメタは c と W とした. この2つのパラメタの関連性から, ニューロン生成条件を式(4)に示すように定義した¹⁴⁾.

$$WD_{c_j} \cdot WD_{W_j} > \theta_G \quad (4)$$

ここで, WD_{c_j} , WD_{W_j} はそれぞれ j 番目の隠れニューロンのパラメタと重みに関する WD である. θ_G は閾値で予め与えられる. 学習中に式(4)を満たす隠れニューロンが存在する場合, Fig. 1(a)のように, 該当する隠れニューロンの近傍に新しいニューロンがその属性(パラメタや重みの値)を継承するように挿入される.

一方, 入力データに対して十分な数の隠れニューロンが生成された後, そのうち出力に寄与していない, すなわち冗長な値を出力する隠れニューロンが存在する場合がある. 構造適応型 RBM では, 一定の学習の後, 式(5)を満たす隠れニューロンが存在すれば, ニューロン消滅アルゴリズムを適用し, 該当する隠れニューロンを Fig. 1(b)のように消去する. 式(5)では, すべての入力データに対する隠れニューロンの出力値の平均を観察し, その値が一定の閾値以下のニューロンを冗長なニューロンとし, これを削除する.

$$\frac{1}{N} \sum_{n=1}^N p(h_j = 1 | \mathbf{v}_n) < \theta_A, \quad (5)$$

$$p(h_j = 1 | \mathbf{v}_n) = \sigma(b_j + \sum_i W_{ij} v_i) \quad (6)$$

ここで, \mathbf{v}_n は N 個の入力データセットに含まれる入力データである. $p(h_j = 1 | \mathbf{v}_n)$ は RBM の可視層に入

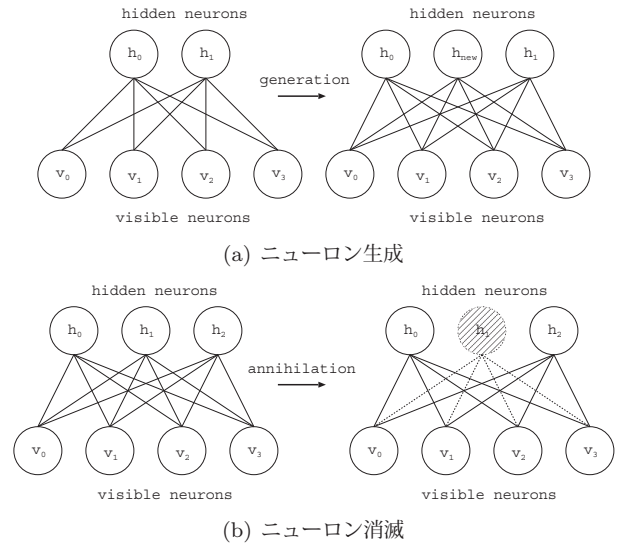


Fig. 1: 構造適応型 RBM

力データ \mathbf{v}_n が与えられたときの隠れニューロン $h_j \in \{0, 1\}$ の発火確率を示している. ここで, $\sigma()$ はシグモイド関数で $[0, 1]$ を出力する関数である. θ_A は, 予備実験における分類精度と削除するニューロンの活性値をもとに閾値として予め与えた.

2.4 層の生成条件

構造適応型 RBM におけるニューロン生成アルゴリズムでは, 学習中の WD(パラメタ c と W の変分)を観察したが, 構造適応型 DBN¹⁰⁾ では, 個々の RBM ではなく, ネットワーク全体の WD とエネルギーを式(7)と式(8)で観察した.

$$\sum_{l=1}^k (\alpha_{WD} \cdot WD^l) > \theta_{L1}, \quad (7)$$

$$\sum_{l=1}^k (\alpha_E \cdot E^l) > \theta_{L2} \quad (8)$$

ここで, $WD^l = \sum_{j=1}^J (WD_{c_j}^l \cdot WD_{W_j}^l)$ であり, $WD_{c_j}^l$ と $WD_{W_j}^l$ はそれぞれ l 層目の RBM における c_j と W_j^l に関する WD を示している. E^l はエネルギー関数である. θ_{L1} , θ_{L2} は閾値で, 予め与えられる. ある k 層の RBM においてに式(7)及び式(8)を同時に満たす場合, 入力データに対するネットワーク全体の表現能力が不足していると考え, k 層の学習が終了した時点で, $k+1$ 層の RBM を生成し, 学習を行う.

3 構造適応型深層学習法による物体検出アルゴリズム

3.1 物体検出アルゴリズム

深層学習(CNN)による物体検出法として, R-CNN¹⁵⁾, YOLO¹⁶⁾, SSD¹⁷⁾ が知られている. これらは, 画像の中の物体の箇所を矩形(Bounding Box; B-Box)として検出する手法である. R-CNN では, まず画像から対象となる物体の画像のみを切り出し, これを分類できる CNN モデルを構築する. 分類モデル構築後, 画像中の特定の箇所を物体の候補として抽出し, これを構築したモデルに与え, 出力層における可能性

Algorithm 1 構造適応型 DBN による検出アルゴリズム

- 1: $Image$ を $w \times h$ ピクセルの入力画像とする.
- 2: 入力画像 $Image$ を N 個の領域 $V = \{v_1, \dots, v_i, \dots, v_N\}$ に分割する. v_i は各領域を示す. ここでは各領域 v_i を離散ポロノイ図に基づいて求めた. 各ポロノイ領域 v_i は, 式 (9) を満たす.
$$v_i = \{p | d(p, p_j) \leq d(p, p_k), k \neq j\}, \quad (9)$$

ここで $d()$ は距離関数である. 本論文では, ポロノイ領域の母点は, ランダムに定めた.
- 3: 手順 2. で抽出した各領域 v_i に対して, 入力画像 $Image$ から領域 v_i を抽出し, 学習済みの構造適応型 DBN に与え, 出力結果を各クラスの確率とする. ここで, クラスの確率が一定の閾値 $T_1 (0 < T_1 < 1)$ より高いクラスを抽出する. なお, 各領域の大きさはそれぞれ異なるが, 大きさが均一になるように拡大, 縮小して構造適応型 DBN に与える.
- 4: 手順 3. で抽出した各クラスに対して, 領域 v_i の母点を中心とした $n \times m$ の領域画像を抽出する. ここで, n と m は, それぞれ $N = \{N_{min}, \dots, n, \dots, N_{max}\}$, $M = \{M_{min}, \dots, m, \dots, M_{max}\}$ の範囲の中で, 領域 v_i の縦 (列), 横 (行) 方向のピクセルを1つずつずらすことで求める.
- 5: 手順 4. で抽出した各領域画像を学習済みの構造適応型 DBN に与え, 出力結果を各クラスの確率とする. このとき, クラスの確率が一定の閾値 $T_2 (0 < T_1 < T_2 < 1)$ より高い場合, その領域を検出したと見なし, 該当するクラスの B-Box とする. なお, 各領域において検出される B-Box の数は, 各クラスに対して最大1つとする.

が高い場合, 検出したとみなす手法である. YOLO や SSD では, 画像中の物体の候補の抽出方法として, 画像全体を一定の大きさのグリッドに分割し, 各グリッドの領域の大きさを変更しながら候補を抽出する方法が提案されている.

本研究では, 上記の手法の考えを構造適応型 DBN に適用した物体検出法を開発した¹²⁾. Algorithm 1 に開発した物体検出法のアルゴリズムを示す. アルゴリズムでは, 画像全体を複数の小領域に分割し, 各領域を学習済み構造適応型 DBN のネットワークに与え, 出力 (ソフトマックス) 層の確率が高い場合に検出したと判定する. ここでは, T_1 と T_2 の2つのパラメータを用いて, 2段階に分けて検出判定が行われている. T_1 は1段階目において使用され, 候補領域に対する矩形の一致度を判定する閾値である. T_2 は, 2段階目において使用され, T_1 を用いた条件により抽出された矩形のサイズを微調整した後の物体検出の最終判定を行う閾値である.

3.2 検出パラメータの自動調整法

適切なパラメータを与えた場合, 開発した物体検出法は胸部 X 線画像ベンチマークデータセット ChestX-ray8(CXR8)¹⁸⁾ に対し既存の CNN 手法よりも高い検

出精度を示した. 建築設備図面記号に対しても同様に高い検出精度を示している. しかし, 4.3 節の実験でも述べるが, 検出アルゴリズムで使われている T_1 や T_2 のパラメータの設定によっては, 一部の部品に対して検出精度が下がる問題があった. これは, 部品ごとの画像のサイズや特徴が異なることや, 部品の出現頻度が図面によって異なるためである. 例えば, 全体の図面の中で出現頻度は低い, 特定の図面のみによく出現する部品は, 重要度や希少度が高い. つまり, 検出の過程で, 重要度かつ希少度が高い部品を特定することができれば, 最良の検出パラメータを設定でき, 検出精度を向上できる. 例えば, T_1 と T_2 の値を元の値より少し小さくすることで, 検出領域が広がり, 重要度及び希少度の高い部品を検出しやすくなる.

部品の重要度及び希少度を求めるため, 本研究では, 式 (10) に示す指標を提案する.

$$z_{ij} = x_{ij} \times y_i \quad (10)$$

$$x_{ij} = \frac{n_{ij}}{\sum_k n_{kj}} \quad (11)$$

$$y_i = \log \frac{|D|}{|\{d : d \in t_i\}|} \quad (12)$$

ここで, x_{ij} は図面 j における部品 i の出現頻度であり, 重要度を示す. n_{kj} は図面 j に出現する部品 k の数である. $|D|$ は全図面数, $|\{d : d \in t_i\}|$ は全図面中部品 t_i を含む図面数であり, y_i は全図面において部品 i が出現する図面の頻度の逆数に対数をとった値であり, 希少度を示す. つまり, z_{ij} は特定の図面のみによく出現する希少度が高い部品の場合に高くなり, 逆に, 出現頻度は高くても全ての図面に出現するような一般的な部品の場合は低くなる. 本論文では, この指標を用いて, 式 (13), 式 (14) のように, 検出パラメータの T_1 , T_2 の微調整を行う.

$$T_{1,ij} = T_1 \times \alpha_1 \times z_{ij} \quad (13)$$

$$T_{2,ij} = T_2 \times \alpha_2 \times z_{ij} \quad (14)$$

ここで, α_1 及び α_2 は, 自動調整された T_1 及び T_2 の値を調整するために使用する定数であり, 0 以上の値で, 通常は 1.0 の値をとる. これにより, 希少度が低い一般的な部品に対しては, 通常の T_1 及び T_2 の値を使用し, 一方, 重要度かつ希少度が高い部品に対しては, T_1 及び T_2 の値を下げることで, 検出領域を広げ, より検出がされるように調整する.

4 実験

4.1 データセット

本論文では, 図面画像 300 枚を用いて, 図面に含まれる「衛生」, 「電灯」, 「コンセント」, 「非常灯・誘導灯」, 「インターホン」の 5 種類の記号を分類し検出する深層学習システムを構築した. 図面記号とは, 図 2 に示されるような建築設備図面に含まれる器具や記号等の画像である. 図 3 は 5 種類の器具・記号のサンプルを示している.

開発した物体検出法では, まず 2.4 節の構造適応型 DBN により器具・記号の分類モデルを構築し, その後, 3 節のアルゴリズムにより物体検出を行う. 分類モデルの構築では, 上記の図面画像から 5 種類の記号を抽





Fig. 2: 図面データのサンプル



(a) 衛生

(b) 電灯



(c) コンセント (d) 非常灯・誘導灯 (e) インターホン

Fig. 3: 器具・記号画像のサンプル

出し、データセットを作成した。深層学習では大容量の学習データを必要とするため、Data Augmentationによるデータ数の増強を行った。Data Augmentationとは、元の学習データから擬似的なデータを生成する方法である。ここでは、各画像に対して、反転（上下、左右）、回転（90度、180度）、平行移動、拡大縮小の操作を行った。平行移動は、中心から3ピクセル上下・左右にずらす操作を行った。拡大縮小は、-10%から10%の範囲で5%刻みの組み合わせで拡大縮小の操作を行った。Table 1は作成したデータセットにおける訓練データとテストデータ数を示している。訓練データを構造適応型DBNで学習し、テストデータを用いて分類精度を評価した。

4.2 分類モデルの構築

構造適応型DBNを用いて、Table 1の器具・記号画像の学習を行った。Table 2は、各カテゴリに対する訓練データとテストデータの数及び分類精度(%)を示している。括弧の値は、分類できなかったデータ数

Table 1: データセット

カテゴリ名	訓練データ	テストデータ
衛生	9,394	240
電灯	7,403	324
コンセント	12,744	546
非常灯・誘導	5,977	546
インターホン	7,496	417

Table 2: 図面記号に対する分類精度

カテゴリ名	訓練データ	テストデータ
衛生器具	100.0%	95.6% (10)
電灯	100.0%	99.1% (4)
コンセント	100.0%	95.8% (22)
非常灯・誘導	100.0%	98.0% (10)
インターホン	100.0%	97.0% (12)

を示している。訓練データに対する正答率は、全てのカテゴリに対して100.0%となった。一方、テストデータに対しては、95.6%以上となった。また、文献¹⁹⁾のFine Tuning法により、分類精度の改善を試みた。Fine Tuning法とは、学習後のネットワークの各層の入出力パタンの頻度に応じて、誤って分類された事例が正しく分類されるようにネットワークの重みを修正する手法である。Fine Tuning法を適用することで、全てのカテゴリに対して100%分類可能となり、誤分類が生じていたデータを正しく分類できるようになった。

4.3 物体検出アルゴリズムの評価

4.2節で構築した分類モデルを用いて、Table 1の図面データに対して物体検出を行った。Algorithm 1の物体検出アルゴリズムには、パラメタとして T_1 、 T_2 がある。アルゴリズムでは、 T_1 と T_2 の2つのパラメタを用いて、2段階に分けて物体検出を行っているが、 T_1 は1段階目において使用され、候補領域に対する矩形の一致度を判定する閾値である。 T_2 は、2段階目において使用され、 T_1 を用いた条件により抽出された矩形のサイズを微調整した後の物体検出の最終判定を行う閾値である。本実験では、 $T_1 = \{0.4, 0.5, 0.6, 0.7\}$ 、 $T_2 = \{0.6, 0.7, 0.8, 0.9\}$ の組み合わせで検証を行った。さらに、提案するパラメタ自動調整法を適用し、精度の比較を行った。検出の正解判定は、正解として与えられたB-Boxに対して、検出されたB-Boxとの領域の交わりの割合を示すIoU(Intersection over Union)が75%以上であるものを正しく検出できたと判定した。

Table 3は図面データに対する検出精度を示している。ここでTable 3の「通常」は T_1 と T_2 を手動で定めた場合、「パラメタ自動調整法」は提案手法より T_1 と T_2 の自動調整を行った場合の検出精度を示している。パラメタを手動で定めた場合では、検出精度に差が見られ、例えば $T_1 = 0.65, T_2 = 0.80$ では最良の精度であった98.5%が得られたが、 $T_1 = 0.65, T_2 = 0.80$ では85.4%となり、検出精度が悪くなる場合が見られた。一方、パラメタ自動調整法では、 $T_1 = 0.50, T_2 = 0.70, \alpha_1 = 1.0, \alpha_2 = 1.0$ の場合と、 $T_1 = 0.40, T_2 = 0.70, \alpha_1 = 1.3, \alpha_2 = 0.9$ の場合を記載しているが、どちらも部品ごとに最適な T_1 と T_2 が自動で調整され、最良の検出精度98.5%が得られた。

Table 4は、パラメタ自動調整法($T_1 = 0.40, T_2 = 0.70, \alpha_1 = 1.3, \alpha_2 = 0.9$)における各部品に対する検出精度を示している。Table 4から、部品間における検出精度について大きな偏りは見られなかった。一方で、検出できなかったものが数個見られた。この原因は、検出対象の画像の上に他の器具等の画像が重ねて描画されているためで、特にコンセントに見られた。Fig. 4

Table 3: 検出精度の比較

手法	検出精度
通常 ($T_1 = 0.40, T_2 = 0.70$)	85.4%
通常 ($T_1 = 0.50, T_2 = 0.70$)	90.1%
通常 ($T_1 = 0.50, T_2 = 0.90$)	94.8%
通常 ($T_1 = 0.65, T_2 = 0.80$)	98.5%
パラメタ自動調整法 ($T_1 = 0.50, T_2 = 0.70, \alpha_1 = 1.0, \alpha_2 = 1.0$)	98.5%
パラメタ自動調整法 ($T_1 = 0.40, T_2 = 0.70, \alpha_1 = 1.3, \alpha_2 = 0.9$)	98.5%

は、検出できなかった電灯とコンセントの事例を示している。図の中で青色で囲まれている図形が対象となる器具である。Case1は右2つの図形は検出でき、左上の電灯の図形(扉の線と重複している)を検出できなかった。Case2は左の電灯の図形を検出できなかった。Case3からCase5は、検出できなかった4つのコンセントの事例を示している。Case3では右2つの図形は検出でき、一番左の図形(“消”のラベルと重複している)は検出できなかった。Case4では、左2つは検出でき、右側端の図形は検出できなかった。Case5では、上下2つの図形は検出でき、真ん中の2つの図形は検出できなかった。図形が重なった場合は、その合成画像が1つの部品として認識されてしまう。今後は、このような場合の判別方法について検討を行う必要がある。

5 おわりに

尤度の概念を用いた統計的なモデルであるRBM, DBNに着目し、学習中にニューロンの生成/消滅及び階層化を行うことで最適な構造を求める構造適型DBNを提案し、建築設備図面における記号の自動検出を行った。従来では、検出パラメタの設定によっては検出精度が下がるケースが見られたが、複数のパラメタの組み合わせを実験し、全ての器具に対して上手く検出できる設定の指標を見つけた。また、重要度かつ希少度が高い部品を抽出する方法及びこれを用いたパラメタの自動調整法を提案した。今後は、より多くのデータを用いて手法を検証する。

謝辞

本研究開発はJSPS 科研費(課題番号: 19K12142, 19K24365), 独立行政法人情報通信研究機構(NICT)の委託研究(課題番号: 21405)の助成を受けたものです。

参考文献

- 1) Y.Bengio: *Learning Deep Architectures for AI*, Foundations and Trends in Machine Learning archive, vol.2, no.1, 1/127 (2009)
- 2) V.Le.Quoc, R.Marc's Aurelio, et.al.: *Building high-level features using large scale unsupervised learn-*

Table 4: パラメタ自動調整法による各記号に対する検出精度 ($T_1 = 0.40, T_2 = 0.70, \alpha_1 = 1.3, \alpha_2 = 0.9$)

カテゴリ名	検出精度
衛生器具	98.8%
電灯	98.5%
コンセント	98.0%
非常灯・誘導	98.9%
インターホン	98.3%

- ing, Proc. of 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, 8595/8598 (2013)
- 3) C.Szegedy, W.Liu, et.al.: *Going Deeper with Convolutions*, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1/9 (2015)
- 4) K.He, X.Zhang, S.R en, J.Sun: *Deep residual learning for image recognition*, Proc. of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770/778 (2016)
- 5) G.E.Hinton: *A Practical Guide to Training Restricted Boltzmann Machines*, Neural Networks, Tricks of the Trade, Lecture Notes in Computer Science (LNCS, vol.7700), 599/619 (2012)
- 6) G.E.Hinton, S.Osindero and Y.Teh: *A fast learning algorithm for deep belief nets*, Neural Computation, vol.18, no.7, 1527/1554 (2006)
- 7) S.Kamada and T.Ichimura: *An Adaptive Learning Method of Restricted Boltzmann Machine by Neuron*

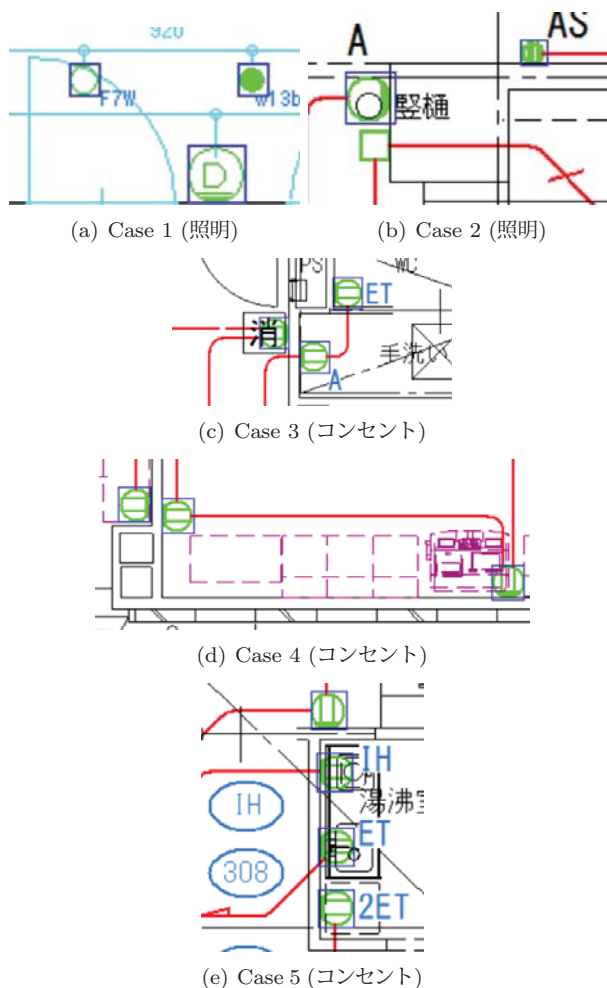


Fig. 4: 検出できなかった事例

- Generation and Annihilation Algorithm*, Proc. of 2016 IEEE International Conference on Systems, Man, and Cybernetics (IEEE SMC 2016), 1273/1278 (2016)
- 8) S.Kamada and T.Ichimura: *A Structural Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Neural Information Processing, vol.9950 of the series Lecture Notes in Computer Science, 372/380 (2016)
 - 9) A.Krizhevsky: *Learning Multiple Layers of Features from Tiny Images*, Master of thesis, University of Toronto (2009)
 - 10) 鎌田真, 市村匠: *忘却機能を持った Deep Belief Network による構造適応型学習*, 計測自動制御学会第9回コンピューターショナル・インテリジェンス研究会講演論文集, 92/97 (2016)
 - 11) S.Kamada and T.Ichimura: *An Adaptive Learning Method of Deep Belief Network by Layer Generation Algorithm*, Proc. of IEEE TENCON2016, 2971/2974 (2016)
 - 12) 市村匠, 鎌田真: *ChestX-ray8 を用いた構造適応型 Deep Belief Network による胸部疾患位置検出システム*, 計測自動制御学会システム・情報部門学術講演会 2018 講演論文集 (SSI2018), SS10-08 (2018)
 - 13) G.E.Hinton: *Training products of experts by minimizing contrastive divergence*, Neural Computation, vol.14, no.8, 1771/1800 (2002)
 - 14) S.Kamada, T.Ichimura, Akira Hara, and Kenneth J. Mackin: *Adaptive Structure Learning Method of Deep Belief Network using Neuron Generation-Annihilation and Layer Generation*, Neural Computing and Applications, doi.org/10.1007/s00521-018-3622-y, 1/15 (2018)
 - 15) R.Girshick, et al., *Rich feature hierarchies for accurate object detection and semantic segmentation*, Proc. of IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 580/587 (2014)
 - 16) J.Redmon, S.Divvala, R.Girshick, and A.Farhadi, *You Only Look Once: Unified, Real-Time Object Detection*, Proc. of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 779/788 (2016)
 - 17) W.Liu, et al., *SSD: Single Shot MultiBox Detector*, arXiv:1512.02325 [cs.CV] (2015)
 - 18) X.Wang, Y.Peng, L.Lu, Z.Lu, M.Bagheri, and R.M.Summers, *ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases*, Proc. of IEEE Computer Vision and Pattern Recognition, 3462/3471 (2017)
 - 19) S.Kamada and T.Ichimura, *Fine Tuning of Adaptive Learning of Deep Belief Network for Misclassification and its Knowledge Acquisition*, International Journal Computational Intelligence Studies, Vol.6, No.4, 333/348 (2017)

KL情報量に基づく学習後の構造適応型DBNにおける ニューロン付加手法の提案と顔表情画像への適用

○鎌田 真 市村 匠 (県立広島大学 地域基盤研究機構)

Re-learning Method of Adaptive Structural Deep Belief Network by Neuron Generation based on KL-Divergence and Its Application to Facial Expression Image

*S. Kamada and T. Ichimura (Research Organization of Regional Oriented Studies,
Prefectural University of Hiroshima)

Abstract– Deep Learning has a hierarchical network architecture to represent the complicated feature of input patterns. We have developed the adaptive structure learning method of Deep Belief Network (DBN) that can discover an optimal number of hidden neurons for given input data in a Restricted Boltzmann Machine (RBM) by neuron generation-annihilation algorithm, and can obtain appropriate number of hidden layers in DBN. In this paper, our model is applied to a facial expression image dataset, Affectnet. The system has higher classification capability on some benchmark data sets. However, the model was not able to classify some test cases correctly because human emotions contain many ambiguous features or patterns leading wrong answer and two or more annotators answer different subjective judgment for an image. In order to represent such cases, this paper investigated a re-learning model of Adaptive DBN with two or more child models, where the original trained model can be seen as a parent model and new child models are constructed for some misclassified cases. The difference between two models is calculated by KL divergence and some appropriate new neurons are generated according to KL divergence to improve classification accuracy.

Key Words: Deep Learning; Deep Belief Network; Restricted Boltzmann Machine, Adaptive Structure Learning; AffectNet

1 はじめに

近年, Deep Learning(深層学習)^{1, 2)}が人工知能の理論的な研究だけでなく, 産業を中心とした様々な場面で利用され始めている。ILSVRC と呼ばれる画像認識の世界大会では, GoogleNet³⁾ や ResNet⁴⁾ で知られるように, 人間の認識能力を大きく上回る Deep Learning モデルが発表されている。従来の階層型ニューラルネットワークとは異なり, Deep Learning では事前学習が行われることが大きな特徴の一つである。各層ごとに学習を行うことで入力データに含まれる特徴を事前学習し, それらの複数の特徴を階層的に組み合わせることで, データ全体の特徴を高い精度で表現することができる。

確率モデルである Restricted Boltzmann Machine(RBM)⁵⁾ を事前学習し, その RBM を階層化することで, 高度な分類性能をもつ Deep Belief Network(DBN)⁶⁾ がある。我々は, 入力データ空間に応じて適切と考えられる隠れニューロン数及び隠れ層数を学習中に自動で求める構造適応型学習法を提案している^{7, 8)}。提案手法は, 画像ベンチマークデータセット⁹⁾ に対して従来手法よりも高い分類精度を示している^{10, 11)}。他にも CXR8 などの胸部レントゲン写真のベンチマークデータセットに対しても, 高い分類能力と疾患部位検出結果を示すことができている¹²⁾。

本論文では, 構造適応型 DBN を顔表情データベース AffectNet¹³⁾ に適用した。AffectNet は, 自然な感情表情, 快/不快, 好感度のデータベースとして Mahoor らが公開しているもので, インターネット上から収集された顔画像に対して, 8種類の感情が人によってラベル付けされている。構造適応型 DBN を AffectNet に適用したところ, 学習結果として, 訓練データに対し

てほぼ 100%の分類精度を示した。テストデータに対しても, 既存の手法よりも高い分類精度を示せたものの(87.4%), 一部のラベルには, 複数の感情や曖昧な特徴が含まれており, 正しい分類ができなかった。

誤分類した原因として, これはラベル付けした人の主観によって分類されたデータを用いているため, 感情の判定が難しい事例が含まれていると考えられる。これらは, 入力パターンが同じであるが, 出力カテゴリが異なるデータを取り扱う時に生じると考えられる。モデルの学習時に与えるデータがデータクレンジングが行われていない場合や, 学習後に収集されたデータに矛盾が発見される場合など見られる現象で, 通常は該当するデータに対して何らかの手段で再学習を促すか, もしくはモデルを再度学習し直すなどの方法により解決できる。しかしながら, AffectNet や医療情報のように, 主観的な情報が含まれていたり, 与えられた情報だけでは判定しきれずに他の情報を加味して判断しなければならない状態は現実世界に多く存在している。このような場合, アンサンブル学習のように, 複数のモデルを用いた学習法が効果的であると考えられる。また, 2つのモデルの確率分布の違いを表現する方法として, KL 情報量が知られている。このようなモデルの実現のために, 既存の学習した親モデルに対して, 誤った結果を生じたデータを分類するための子モデルを構築し, KL 情報量を用いてアノデータによる違いを表現した¹⁴⁾。本論文では, KL 情報量より得られた親モデルと子モデルの違いをもとに, 新たなニューロン生成を行う再学習法を提案する。学習の結果, 特定のカテゴリについて分類精度の改善が見られた。

2 構造適応型 Deep Belief Network による学習手法

2.1 Restricted Boltzmann Machine

RBM⁵⁾ は、可視層と隠れ層の2層から構成されるネットワーク構造を持ち、確率分布に基づいて入力データに含まれる特徴を隠れニューロン上で学習することができる。RBMの学習では、与えられた入力データに対して、式(1)のエネルギー関数を最小にするパラメタ $\theta = \{b, c, W\}$ が最尤推定により求められる。

$$E(\mathbf{v}, \mathbf{h}) = -\sum_i b_i v_i - \sum_j c_j h_j - \sum_i \sum_j v_i W_{ij} h_j, \quad (1)$$

$$p(\mathbf{v}, \mathbf{h}) = \frac{1}{Z} \exp(-E(\mathbf{v}, \mathbf{h})), \quad (2)$$

$$Z = \sum_{\mathbf{v}} \sum_{\mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h})) \quad (3)$$

ここで、 v_i は i 番目の可視ニューロン、 h_j は j 番目の隠れニューロンである。 b_i は v_i に対するパラメタ、 c_j は h_j に対するパラメタ、 W_{ij} は v_i と h_j 間の重みである。 $\mathbf{v} \in \{0, 1\}^I$ と $\mathbf{h} \in \{0, 1\}^J$ はそれぞれ可視層と隠れ層のベクトルであり、 I と J は可視ニューロン数、隠れニューロン数である。式(2)は入力 \mathbf{v} と \mathbf{h} の確率分布である。式(3)の Z は分配関数 (partition function) であり、 \mathbf{v} と \mathbf{h} の全ての2値のパターンの組み合わせに対するエネルギーを示す。一般的に、RBMでは計算量の観点から Contrastive Divergence(CD)法¹⁵⁾による学習が行われる。

2.2 Deep Belief Network

Deep Belief Network(DBN)は、事前学習を行ったRBMを複数積み重ねることで、入力データの特徴を階層的に学習することができる Deep Learning 手法である⁶⁾。DBN自体はRBMを積み重ねたモデルであるため教師なし学習モデルであるが、最上位層に出力層を加え、ソフトマック法等により計算された出力値と教師信号との誤差を最小化することで、教師あり学習に適用できる。

2.3 ニューロン生成/消滅アルゴリズム

我々は、RBMの学習中において最適な隠れニューロン数を自動で求めるニューロン生成/消滅アルゴリズムによる構造適応型学習手法を提案している⁷⁾。ニューロン生成は、学習中におけるパラメタの変分に基づいて行われる。例えば、学習データに対して十分な数の隠れニューロンがあれば、一般的に学習が進むにつれて重みベクトルの変分は小さな値になる。一方で、パラメタの変分が収束しない場合は、学習データに対するネットワークの表現能力が不足しており、データが持つ特徴(確率分布)を隠れニューロン上で分離できていないことが原因だと考えられる。このような場合、関連する位置に隠れニューロンを挿入することで、多くの次元でデータを表現できると考えられ、学習が収束する。我々の調査では、RBMの3つのパラメタ $\theta = \{b, c, W\}$ のうち、CD法による学習の収束に関係しているパラメタは c と W とした。この2つのパラメタの関連性から、ニューロン生成条件を式(4)に示すように定義した¹⁶⁾。

$$WD_{c_j} \cdot WD_{W_j} > \theta_G \quad (4)$$

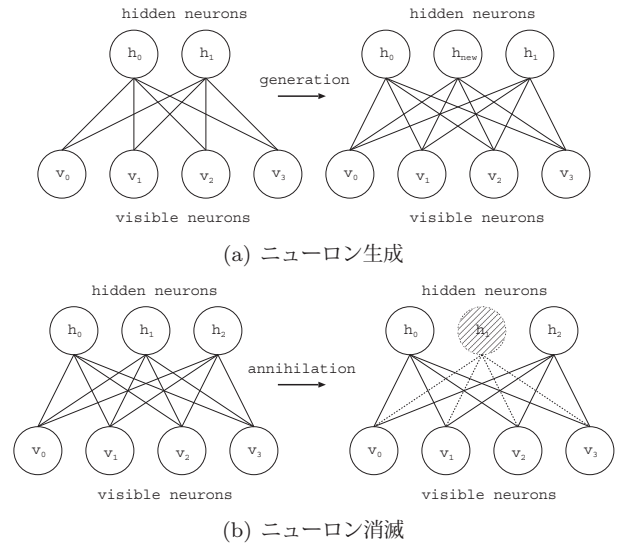


Fig. 1: 構造適応型 RBM

ここで、 WD_{c_j} 、 WD_{W_j} はそれぞれ j 番目の隠れニューロンのパラメタと重みに関する WD である。 θ_G は閾値で予め与えられる。学習中に式(4)を満たす隠れニューロンが存在する場合、Fig. 1(a)のように、該当する隠れニューロンの近傍に新しいニューロンがその属性(パラメタや重みの値)を継承するように挿入される。

一方、入力データに対して十分な数の隠れニューロンが生成された後、そのうち出力に寄与していない、すなわち冗長な値を出力する隠れニューロンが存在する場合がある。構造適応型 RBM では、一定の学習の後、式(5)を満たす隠れニューロンが存在すれば、ニューロン消滅アルゴリズムを適用し、該当する隠れニューロンを Fig. 1(b)のように消去する。式(5)では、すべての入力データに対する隠れニューロンの出力値の平均を観察し、その値が一定の閾値以下のニューロンを冗長なニューロンとし、これを削除する。

$$\frac{1}{N} \sum_{n=1}^N p(h_j = 1 | \mathbf{v}_n) < \theta_A, \quad (5)$$

$$p(h_j = 1 | \mathbf{v}_n) = \sigma(b_j + \sum_i W_{ij} v_i) \quad (6)$$

ここで、 \mathbf{v}_n は N 個の入力データセットに含まれる入力データである。 $p(h_j = 1 | \mathbf{v}_n)$ は RBM の可視層に入力データ \mathbf{v}_n が与えられたときの隠れニューロン $h_j \in \{0, 1\}$ の発火確率を示している。ここで、 $\sigma()$ はシグモイド関数で $[0, 1]$ を出力する関数である。 θ_A は、予備実験における分類精度と削除するニューロンの活性化をもとに閾値として予め与えた。

2.4 層の生成条件

構造適応型 RBM におけるニューロン生成アルゴリズムでは、学習中の WD(パラメタ c と W の変分)を観察したが、構造適応型 DBN¹⁰⁾では、個々の RBM ではなく、ネットワーク全体の WD とエネルギーを式(7)と式(8)で観察した。

$$\sum_{l=1}^k (\alpha_{WD} \cdot WD^l) > \theta_{L1}, \quad (7)$$

Table 1: AffectNet のカテゴリ

カテゴリ名	訓練データ数	テストデータ数
Neutral (中立)	74,874	500
Happy (幸せ)	134,415	500
Sad (悲しみ)	25,459	500
Surprise (驚き)	14,090	500
Fear (恐怖)	6,378	500
Disgust (嫌悪)	3,803	500
Anger (怒り)	24,882	500
Contempt (軽蔑)	3,750	500
None (なし)	33,088	500
Uncertain (不確実)	11,645	500
Non-Face (顔なし)	82,414	500
合計	414,798	5500

$$\sum_{l=1}^k (\alpha_E \cdot E^l) > \theta_{L2} \quad (8)$$

ここで, $WD^l = \sum_{j=1}^J (WD_{c_j}^l \cdot WD_{W_j}^l)$ であり, $WD_{c_j}^l$ と $WD_{W_j}^l$ はそれぞれ l 層目の RBM における c_j と W_j^l に関する WD を示している. E^l はエネルギー関数である. θ_{L1} , θ_{L2} は閾値で, 予め与えられる. ある k 層の RBM においてに式 (7) 及び式 (8) を同時に満たす場合, 入力データに対するネットワーク全体の表現能力が不足していると考え, k 層の学習が終了した時点で, $k+1$ 層の RBM を生成し, 学習を行う.

3 AffectNet

AffectNet は, 文献¹³⁾ によって作成された人間の感情を含む顔画像データベースである. Table 1 に示すように, 11 種類のカテゴリが与えられており, 訓練データとテストデータに分割されている. Fig. 2 は, 11 種類のカテゴリの画像サンプルを示している. これらのカテゴリは, インターネット上から収集された画像に対して, 快/不快を表す Valence と感情の起伏度を表す Arousal に基づいて人の主観によってラベル付けされたものである. Fig. 3 は Valence と Arousal に対する感情のラベルの分布を示している. 文献¹³⁾ では, Table 2 に示すように, 同じ画像に対して 2 人のアノテーター (画像に対して感情の種類を付与する人) の分類結果が一致する割合を各カテゴリに対して示しているが, 人の感情には曖昧な特徴が多く含まれていることから, アノテーターの精度は高くない. 特に, インターネット上で収集される有名人等の顔画像に対しては, 画像以外に対する個人の好みもラベル付けの判断材料に含まれるだろう. このため, このようなデータをシステムで分類するためには, 画像以外の複数種類の情報を総合的に判断したうえで推論を行うマルチモーダル深層学習の仕組みが必要になるだろう¹⁷⁾. なお, “None”, “Uncertain”, “Non-Face” の 3 種類のカテゴリは, 顔の感情に関するカテゴリではなく, 文献¹³⁾ でも学習では取り扱っておらず, 本論文でも同様に, これらを 3 種類を除く, 8 種類のデータを構造適応型 DBN で学習した.

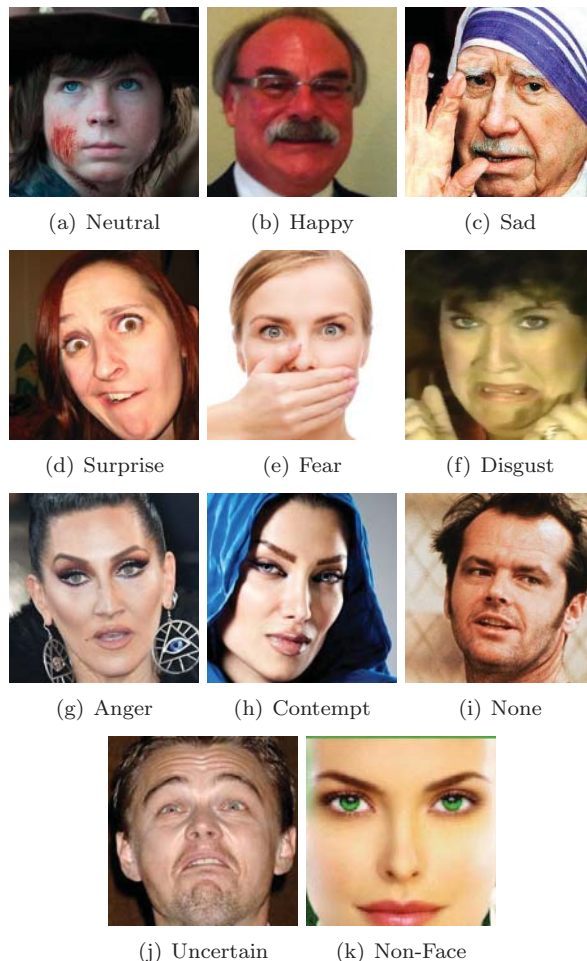


Fig. 2: AffectNet の画像サンプル




Fig. 3: Valence と Arousal

4 構造適応型 DBN による AffectNet の分類

4.1 分類精度

Table 3 は, 構造適応型 DBN の AffectNet に対する分類結果を示している. 文献¹³⁾ に記載されている

Table 2: 文献¹³⁾ 引用「TABLE 6 Category of AffectNetAgreement Between Two Annotators in Categorical Model of Affect (%)」

	Neutral	Happy	Sad	Surprise	Fear	Disgust	Anger	Contempt	None	Uncertain	Non-Face
Neutral	50.8	7	9.1	2.8	1.1	1	4.8	5.3	11.1	1.9	5.1
Happy	6.3	79.6	0.6	1.7	0.3	0.4	0.5	3	4.6	1	2.2
Sad	11.8	0.9	69.7	1.2	3.4	1.3	4	0.3	3.5	1.2	2.6
Surprise	2	3.8	1.6	66.5	14	0.8	1.9	0.6	4.2	1.9	2.7
Fear	3.1	1.5	3.8	15.3	61.1	2.5	7.2	0	1.9	0.4	3.3
Disgust	1.5	0.8	3.6	1.2	3.5	67.6	13.1	1.7	2.7	2.3	2.1
Anger	8.1	1.2	7.5	1.7	2.9	4.4	62.3	1.3	5.5	1.9	3.3
Contempt	10.2	7.5	2.1	0.5	0.5	4.4	2.1	66.9	3.7	1.5	0.6
None	22.6	12	14.5	8	6	2.3	16.9	1.3	9.6	4.3	2.6
Uncertain	13.5	12.1	7.8	7.3	4	4.5	6.2	2.6	12.3	20.6	8.9
Non-Face	3.7	3.8	1.7	1.1	0.9	0.4	1.7	0.4	1.2	1.4	83.9

CNN(AlexNet)では、テストデータに対して60%程度であった(訓練データの記載はなし)。一方、構造適型DBNでは、訓練データに対しては概ね100%の分類精度を示した。テストデータに対しては、平均87.4%の分類精度となった。最も分類できたカテゴリは“Happy”であり、一方、最も分類できなかったカテゴリは“Anger”であった。また90%の分類精度を下回ったカテゴリは、“Neutral”, “Sad”, “Surprise”, “Anger”, “Contempt”であった。

誤って分類された事例が、どのカテゴリに分類されているかを調査した。Table 4は、Table 3の分類結果に対する混合行列(Confusion Matrix)を示している。混合行列とは、8種類のカテゴリがどのカテゴリに予測されたかを示すものである。数値はサンプル数である。Table 4から、“Anger”が“Disgust”と誤って分類されている事例が多いことが分かった。Fig. 4は誤分類した事例の一部を示している。

人の感情には1つ以上の複数の感情が含まれていることが多く、非常に曖昧である。AffectNetでは、1枚の画像に対して1種類の感情ラベルが与えられ、ラベル付けは複数のアノテータにより実施されているが、4.1節で誤って分類された理由として、アノテータを行う人の主観によってラベル付けの結果が異なることが原因であると考えている。文献¹³⁾では、参考情報として、1枚の画像に対して2人のアノテータのラベル付けの結果が一致する割合が、各カテゴリに対して示されている。これを見ると、2人のラベル付けが一致する割合は決して高くなく、最も高いものでHappyの79.6%、一方、Neutral, Contempt, Angerでは、50.8%, 66.9%, 62.3%と低く、この傾向は、Table 4の結果にも現れている。つまり、データセットの中に、複数の人の主観が含まれている。このような場合、アンサンブル学習のように、複数のモデルを用いてデータを表現する方法は有効であると考えられる。

文献¹⁴⁾では、AngerとDisgustに着目し、誤分類したデータと正答したデータに対する子モデルを構築し、元の親モデルとのKL情報量を測定した。具体的には、Table 5に示すように、AngerとDisgustについて、親モデルPで正しく分類できたデータをSet 1、誤って分類されたデータをSet 2とし、Set 1に対する子モデルをQ1、Set 2に対する子モデルQ2を構築した。Table 6は親モデルPと子モデルQ1, Q2のKL情報量を示している。Table 6から、PとQ1のKL情報量に比べて、PとQ2のKL情報量が大きな値となり、モデル間に違

Table 3: AffectNet に対する分類精度

カテゴリ名	CNN(文献 ¹³⁾)	Adaptive DBN	
	テストデータ	訓練データ	テストデータ
Neutral	63.0%	99.3%	87.8%
Happy	88.0%	99.9%	92.4%
Sad	63.0%	99.2%	84.2%
Surprise	61.0%	99.4%	85.8%
Fear	52.0%	99.5%	90.4%
Disgust	52.0%	99.3%	92.4%
Anger	65.0%	98.2%	78.4%
Contempt	8.0%	98.8%	87.6%



Fig. 4: 誤分類した事例

いが見られた。また、PとQ2の各サンプルごとのKL情報量を測定したところ、その範囲は0から0.0025の範囲でばらつきが見られた。この範囲の中で、データを3通りの閾値 $\theta_{KL} = \{0.0010, 0.0015, 0.0020\}$ で分割し、それぞれ子モデルで学習した。この結果、分類精度は上記の3通りの閾値に対して順に95.8%, 97.2%, 95.2%となり、 $\theta_{KL} = 0.0015$ でデータを分割した際、最も精度が高くなった。本論文では、このようなKL情報量が表す親モデルと子モデルの違いに基づき、親モデルにおいて不足していると考えられる新たなニューロンを生成する手法を4.2節で提案し、分類精度の向上を試みる。

Table 4: 分類結果に対する混合行列

		予測されたカテゴリ							
		Neutral	Happy	Sad	Surprise	Fear	Disgust	Anger	Contempt
実際のカテゴリ	Neutral	439	2	7	5	8	16	4	19
	Happy	7	462	2	0	4	12	1	12
	Sad	12	3	421	13	11	20	5	15
	Surprise	15	4	10	429	11	22	0	9
	Fear	10	2	10	10	452	8	3	5
	Disgust	8	2	3	5	8	462	5	7
	Anger	14	4	8	10	9	47	392	16
	Contempt	17	8	6	3	2	21	5	438

Table 5: 子モデルの学習データ¹⁴⁾

セット名	説明	データ数
Set 0	Anger と Disgust の全データ	1,000
Set 1	Set 0 で正しく分類できたデータ	854
Set 2	Set 0 で誤って分類されたデータ	146

Table 6: KL 情報量¹⁴⁾

モデル	KL 情報量
$D_{KL}(P, Q1)$	0.188
$D_{KL}(P, Q2)$	0.660

4.2 KL 情報量に基づくニューロン生成方法の提案

本論文では, P を 4.1 節で学習した親モデルとし, Q を P の重みを含むネットワーク構造をコピーすることで初期化した子モデルとし, P で誤分類した Anger と Disgust を再学習した. 再学習の結果, 子モデル Q は上記の Anger と Disgust に対して 100% 正答するようになった. また, このデータに対し, 親モデル P と子モデル Q の KL 情報量を測定した. KL 情報量は 2 つの確率分布の違いを測る指標であり, 式 (9) により計算される.

$$D_{KL}(P, Q) = \sum_i P(x_i) \log \frac{P(x_i)}{Q(x_i)}, \quad (9)$$

ここで, x_i は入力である. 親モデル P と子モデル Q の KL 情報量は 0.660 となった. Fig. 5 は KL 情報量のサンプルごとの分布を示している. Fig. 5 から, 誤って分類されたデータの中でも, KL 情報量が 0 から 0.0025 の範囲内ではばらつきが見られた. なお, この KL 情報量の値やばらつきは, 子モデルが取り扱うデータによって変化する.

次に, KL 情報量が示す出力の違いだけでなく, 入力層から出力層に至るまでの各層のニューロンの発火パターン (パス) を求め, ネットワーク全体のどこの部分で親モデル P と子モデル Q が異なるのか調査した. 両モデルとも, 入力に近い下位層では, パスに大きな違いはなかったが, 出力に近い上位層では, Fig. 6 に示すような特徴的な違いが見られた. Fig. 6(a) と Fig. 6(b) はそれぞれ親モデルと子モデルの 5 層から出力層のパスを示している. ノードはニューロン, ノード間の線は重みを示し, 太線が実際に発火したパス, 点線が発火しなかったパスを示している. Fig. 6 において, 親モデルでは, 5 層から出力層にかけて, 1, 2, 4 番のニュー




Fig. 5: KL(P, Q) のヒストグラム

ロンを通過し, Disgust と誤って出力された例を示している. 一方, 子モデルでも, 親モデルと同様のパスを通っているが, 親モデルのパスに加えて, 1 番から 3 番のパスも発火し (親モデルでは発火していない), 最終的に, これらの発火パターンの組み合わせによって, 子モデルでは, Disgust ではなく, Anger と出力された.

上記のパスの違いは, 親モデルと子モデルの特徴の違いを表していると考えられる. Fig. 5 の子モデルで発火したニューロンが親モデルにもあれば, 親モデルにおいても, 子モデルと同様の推論が可能になると考えられる. さらに, このようなパスの違いは, Fig. 5 において KL 情報量が多いほど見られた. このことから, 本論文では, KL 情報量が一定の値 θ_{KL} 以上のデータを用いて, Fig. 6 のように親モデルと子モデルで異なるパスがあれば, 子モデルで該当するニューロンを親モデルにコピーする. コピーする際, 重みの値は継承する. 新たなニューロンがコピーされた後, 親モデルで再学習する.

Table 7 は再学習の結果を示している. 本論文では, 文献¹⁴⁾の結果をもとに, $\theta_{KL} = 0.0015$ とした. 再学習前は, Disgust と Anger の正答率がそれぞれ 92.4% と 78.4% であったが, 再学習により, 94.7% と 91.3% に向上した. Table 7 では, 該当する Disgust と Anger の結果しか記載していないが, 今回の実験では, 他のカテゴリの分類精度が変化することはなかった.

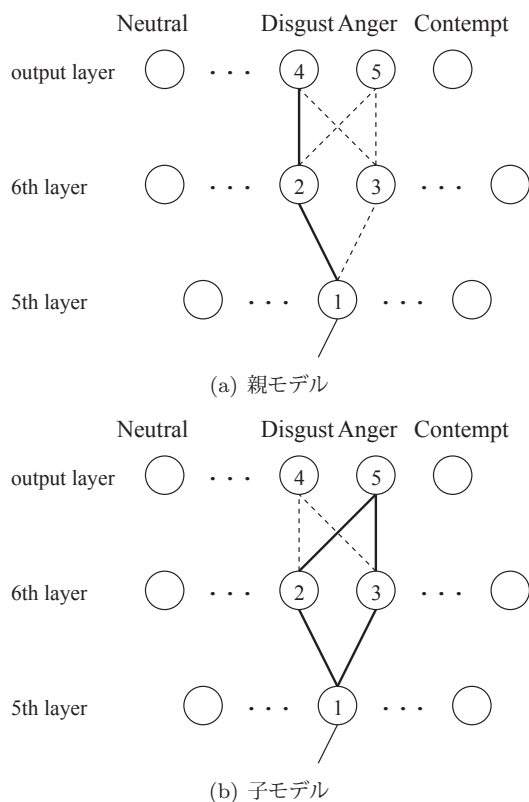


Fig. 6: 入力パス

Table 7: 再学習の結果

カテゴリ名	再学習前	再学習後
Disgust	92.4%	94.7%
Anger	78.4%	91.3%

5 おわりに

本研究では尤度の概念を用いた統計的なモデルであるRBM, DBNに着目し, 学習中にニューロンの生成/消滅及び階層化を行うことで最適な構造を求める構造適応型DBNを提案している. 本論文では, 提案したモデルを顔表情データベースAffectNetに適用した. 人の感情には複雑で曖昧な特徴が多く含まれ, 人の主観によってラベル付けの結果が異なることから, 特定のカテゴリに対しては分類できなかった. このために, 親モデルとは異なる特徴を持つ子モデルを構築し, 両者の違いをKL情報量により表現した. さらに, KL情報量に基づき新たなニューロンを生成し, 再学習することで, 分類精度が向上した. 今後は, 適切なKL情報量の閾値設定について調査を行う. また, 画像のみを用いた推論だけでなく, 画像やその他の情報から固有の情報を抽出し, 複数種類の処理結果を統合して最終的な推論を行うマルチモーダル深層学習の開発を行う.

謝辞

本研究開発はJSPS 科研費(課題番号: 19K12142, 19K24365), 独立行政法人情報通信研究機構(NICT)の委託研究(課題番号: 21405)の助成を受けたものです.

参考文献

1) Y.Bengio: *Learning Deep Architectures for AI*, Foundations and Trends in Machine Learning archive, vol.2, no.1, 1/127 (2009)

2) V.Le.Quoc, R.Marc's Aurelio, et.al.: *Building high-level features using large scale unsupervised learning*, Proc. of 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, 8595/8598 (2013)

3) C.Szegedy, W.Liu, et.al.: *Going Deeper with Convolutions*, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1/9 (2015)

4) K.He, X.Zhang, S.R en, J.Sun: *Deep residual learning for image recognition*, Proc. of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770/778 (2016)

5) G.E.Hinton: *A Practical Guide to Training Restricted Boltzmann Machines*, Neural Networks, Tricks of the Trade, Lecture Notes in Computer Science (LNCS, vol.7700), 599/619 (2012)

6) G.E.Hinton, S.Osindero and Y.Teh: *A fast learning algorithm for deep belief nets*, Neural Computation, vol.18, no.7, 1527/1554 (2006)

7) S.Kamada and T.Ichimura: *An Adaptive Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Proc. of 2016 IEEE International Conference on Systems, Man, and Cybernetics (IEEE SMC 2016), 1273/1278 (2016)

8) S.Kamada and T.Ichimura: *A Structural Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Neural Information Processing, vol.9950 of the series Lecture Notes in Computer Science, 372/380 (2016)

9) A.Krizhevsky: *Learning Multiple Layers of Features from Tiny Images*, Master of thesis, University of Toronto (2009)

10) 鎌田真, 市村匠: **忘却機能を持った Deep Belief Network による構造適応型学習**, 計測自動制御学会第9回コンピュータ・ビジョン・インテリジェンス研究会講演論文集, 92/97 (2016)

11) S.Kamada and T.Ichimura: *An Adaptive Learning Method of Deep Belief Network by Layer Generation Algorithm*, Proc. of IEEE TENCON2016, 2971/2974 (2016)

12) 市村匠, 鎌田真: *ChestX-ray8を用いた構造適応型 Deep Belief Network による胸部疾患位置検出システム*, 計測自動制御学会システム・情報部門学術講演会 2018 講演論文集 (SSI2018), SS10-08 (2018)

13) A.Mollahosseini, B.Hasani, M.H.Mahoor: *AffectNet: A Database for Facial Expression, Valence, and Arousal Computing in the Wild*, IEEE Transactions on Affective Computing, vol.pp, no. 99, 18/31 (2017)

14) T.Ichimura, S.Kamada: *Re-learning of Child Model for Misclassified data by using KL Divergence in AffectNet: A Database for Facial Expression*, Proc. of 2019 IEEE 11th International Workshop on Computational Intelligence and Applications (IWCIA 2019), 15/20 (2019)

15) G.E.Hinton: *Training products of experts by minimizing contrastive divergence*, Neural Computation, vol.14, no.8, 1771/1800 (2002)

16) S.Kamada, T.Ichimura, A.Hara, and K.J.Mackin: *Adaptive Structure Learning Method of Deep Belief Network using Neuron Generation-Annihilation and Layer Generation*, Neural Computing and Applications, doi.org/10.1007/s00521-018-3622-y, 1/15 (2018)

17) T.Baltruaitis et al: *Multimodal Machine Learning: A Survey and Taxonomy*, arXiv:1705.09406 (2017)

拡張 lo d-Warshall法を用いたゴール条件付き強化学習

谷口明日斗 佐々木史紘 山科亮太 (株式会社リコー)

Goal-Conditioned Reinforcement Learning with Extended lo d-Warshall method

*A. anig chi F. asaki and R. amashina Ricoh ompan Ltd.

Abstract— In this paper we extend the concept of lo d arshall method so that it can e applied to al e f nctions and propose a new reinforcement learning method that com ines this with deep reinforcement learning. he proposed method is effecti e for sparse reward reinforcement learning in which the reward f nction is expressed a inar f nction and goal conditioned reinforcement learning which is for the p rpose of achie ing m ltiple goals. he contri tion of the proposed method is that a al e f nction for achie ing a goal can e linked to a al e f nction for achie ing another goal. his concept is not fo nd in con entional reinforcement learning methods. e cond cted experiments in the rid en ironment and showed that the proposed method has higher learning performance than ind insight xperience Repla which is known as an effecti e method for sparse reward reinforcement learning and goal conditioned reinforcement learning.

Key Words: Reinforcement learning Deep Network lo d arshall method

1 導入

エージェントが環境と相互作用するような場合における意思決定問題に対して、強化学習は多くの成功を納めている。例えば Atari や 碁などのゲーム環境で人間のエキスパートに勝利したり^{1, 2)}, また近年はヘリコプターの自律制御³⁾ やロボットアームのマニピュレーション^{4, 5, 6)} など、ロボット分野においても強化学習の研究が進められている。

通常の強化学習ではエージェントが達成したいゴールは一つであり、エージェントの目的は現在の状態に対して価値を最大化する行動を選択する方策を獲得することである。ここで価値は一般にエージェントが将来的に獲得するであろう累積報酬和の期待値を用いる。これに対して、ゴールが複数存在しエピソードごとに達成したいゴールが変化するような場合には、現在の状態に加えて達成したいゴールを入力としたゴール条件付き方策を学習する必要がある。このような強化学習はゴール条件付き強化学習と呼ばれ、機械学習やロボット分野でも注目を集めている^{7, 8, 9, 6, 10, 11)}。本論文ではゴール条件付き強化学習に注目する。ゴール条件付き強化学習に対する有力な手法の一つに ind insight E perience Repla ER^{6, 10)}がある。ERは、エージェントが各エピソードで到達した状態を疑似ゴールと仮定して学習することで、ゴール条件付き方策を効率的に学習することを可能にした。ゴール条件付きタスクに関連して、グラフ理論の全点間最短路問題を解く手法に lo d arshall法がある。lo d arshall法は、あるノード A から別のノード に移動するときに、様々な経路地点 B を通った時の経路を比較して AB 間の距離と B 間の距離の和が最短となる経路を見つける手法である。

本論文では報酬関数が例えばタスクを達成したら 1, それ以外なら を返すような 2 値関数で表されることを仮定することで、lo d arshall法の概念を強化学習にも適用できるように拡張する。本論文ではこれを拡張 lo d arshall法と呼ぶ。そして、拡張 lo d arshall法と ERを組み合わせることでより高い学習性能を持つ新しい強化学習手法を提案する。提案手法は強化学習における価値とグラフ理論におけるノ

ド間距離が類似した概念であることに注目した手法である。提案手法は次のような効果をもたらす。ある初期状態 A を出発してゴール B に到達したエピソードと、そのゴール B を初期状態として出発して別のゴール に到達したエピソードがあったときに、エージェントは二つのエピソードから学習した方策を連結して、A から に行くための方策を学習することができる。この考え方は従来の強化学習手法にはなかったものである。

lo d arshall法は i 隣接するノード間の距離は既知であり、ii 隣接していないノード間の距離の初期推定を ∞ としてから最短距離を求める。一方強化学習は状態間に隣接という概念はなく、またグラフ理論での距離に相当する価値が未知な状態から始まる。これに対して提案手法では、ある状態から別の状態に到達したことがあるかどうかをグラフ理論における隣接の概念と類似すると考え、拡張 lo d arshall法に適用する経路状態やゴールを、実際に経験したエピソード内からサンプリングすることで i の概念を導入する。また未経験の状態・ゴールの組に対する価値の初期推定を、累積報酬和の取りうる最小値にすることで ii の概念を導入する。

2 関連研究

ゴール条件付き強化学習については数多く研究されている。ael ling⁷⁾は強化学習の代表的手法である learningを複数のゴールや動的なゴールを持つタスクに拡張した。一方、近年畳み込みニューラルネットワークを用いた深層学習技術が発展し、強化学習の分野でも Deep Network D N¹⁾をはじめニューラルネットワークを用いた深層強化学習が多く研究されている。ゴール条件付き強化学習の分野においては、cha l et al.⁹⁾が ni ersal al e nction Appro imators A という手法を提案した。D Nは現在状態を取る行動の良さを表す価値関数をニューラルネットワークで表現するが、Aはニューラルネットワークの入力にゴールを追加する。価値関数の入力にゴールを追加する考え方は ael lingの手法でも用いられていたが、Aはこれを深層強化学習で実現した。

A はゴール条件付き強化学習で数多く用いられてきた (6, 10, 12, 11, 13) .

一方, 長期タスクを複数のサブタスク オプションに分解して, 各オプションを達成するローレベル方策と長期タスク達成のために現在状態で達成すべきオプションを選択するハイレベル方策の 2 つの方策を学習する階層強化学習 (14, 15, 16) は, オプションをゴールのようにみなせることからゴール条件付き強化学習と関わりが深い. 本論文で提案する手法も, 暗示的に階層強化学習と近い概念が用いられている.

同じゴール条件付きタスクを対象とした研究に, グラフ理論における最短経路問題がある. グラフ理論における最短経路問題は, ノードとノード間を結ぶエッジから構成されるグラフに対して, あるノードから別のノードへの最短経路を求める問題である. 特に, 全点間最短経路問題を解くための代表的な手法に Floyd-Warshall 法がある. Daeling⁷⁾ は learning と Floyd-Warshall 法の組み合わせについて, learning は価値を過大評価しているときに機能する傾向にあるのに対し, Floyd-Warshall 法は価値を過小評価しているときに機能するという 2 手法の性質の違いのため, これらの組み合わせは難しいと述べている. これについて提案手法は Floyd-Warshall 法で未経験の状態・ゴールの組み合わせに関する価値の初期推定を過小評価することで, この問題に対処した.

スパース報酬強化学習はゴール条件付き強化学習と関連性が高い研究対象である. スパース報酬強化学習とは, 例えばエージェントが目標を達成したら 1, それ以外は 0, のような 2 値報酬関数を持つタスク, すなわちスパース報酬タスクに対する強化学習手法である. スパース報酬強化学習は, 報酬設計が簡単である一方で, エージェントが成功報酬を得る経験が少なく学習が進みにくい性質がある. ゴール条件付き強化学習に用いられる insight Experience Replay (ER)⁶⁾ や階層強化学習はスパース報酬タスクに対して有効な手法として知られる. スパース報酬タスクについてはこれらの他に, カリキュラム強化学習¹⁷⁾ や好奇心・内発的動機付けを用いた強化学習手法^{18, 19, 20)} なども解決策として研究されている.

3 研究背景

3.1 ゴール条件付き強化学習

状態空間 S , 行動空間 A , ゴール空間 G , 遷移確率 $T(s, a, s' | p_{s_{t+1}} | s_t, s, a_t, a)$, 報酬関数 $r: S \times A \times G \rightarrow \mathbb{R}$, 割引率 γ から構成されるゴール条件付きマルコフ決定過程を考える²¹⁾. ただし, s_t, a_t はそれぞれ離散時刻 t における状態と行動を表し, また割引率 γ は $0 < \gamma \leq 1$ を満たす. また本論文ではゴール空間 G は状態空間 S に一致しているものとする. ゴール条件付き強化学習とは, エージェントが将来的に得られる累積報酬 $R_t = \sum_{i=t}^{\infty} \gamma^{i-t} r(s_i, \pi(s_i, g), g)$ の期待値が最大になるような方策 $\pi: S \times G \rightarrow A$ を獲得するための学習手法である. $V^\pi(s_t, g) = \mathbb{E} R_t | s_t, g, \pi$ は状態価値関数, $Q^\pi(s_t, a_t, g) = \mathbb{E} R_t | s_t, a_t, g, \pi$ は状態行動価値関数あるいは関数と呼ばれる. π^*, V^*, Q^* はそれぞれ最適方策, 最適状態価値関

数, 最適関数と呼ばれ, 次式を満たす.

$$\pi^*(s_t, g) = \underset{a}{\operatorname{argmax}} Q^*(s_t, a, g) \quad 1$$

$$V^*(s_t, g) = \max_a Q^*(s_{t+1}, a, g) \quad 2$$

$$Q^*(s_t, a_t, g) = \mathbb{E} r(s_t, a_t, g) + \gamma V^*(s_{t+1}, g) \quad 3$$

特に式 3 を Bellman 方程式と呼ぶ.

3.2 Deep Q-Network

Deep Network DQN¹⁾ は最適な関数 Q^* をニューラルネットワーク Q_θ を用いて近似するモデルフリー強化学習手法である. 本節では, ゴール条件付き強化学習に対して neural network Approximators (A)⁹⁾ を導入したときの DQN の概要を述べる. エージェントは現在のニューラルネットワーク Q_θ をもとに確率 $1 - \epsilon$ で行動 $a_t = \underset{a}{\operatorname{argmax}} Q_\theta(s_t, a, g)$, 確率 ϵ でランダムに行動を選択する方策に従う. この方策は ϵ -greedy 方策と呼ばれる. このときのエージェントの遷移 $(s_t, a_t, s_{t+1}, r_t, g)$ はリプレイバッファ B に蓄積される.

3.1 節で述べたように最適関数 Q^* は式 3 を満たすが, ニューラルネットワーク Q_θ は式 3 を満たすとは限らない. $\mathbb{E} r(s_t, a_t, g) + \gamma \max_{a'} Q_\theta(s_{t+1}, a', g) - Q_\theta(s_t, a_t, g)$ は D 誤差と呼ばれ, DQN では D 誤差が小さくなるようにニューラルネットワーク Q_θ を学習する. 具体的には, リプレイバッファ B からサンプリングされたミニバッチを用いて, 次式で定義される損失関数 L_{TD} を最小化させる.

$$L_{TD} = \mathbb{E} r_t + \gamma \max_{a'} Q_\theta(s_{t+1}, a', g) - Q_\theta(s_t, a_t, g) \quad 4$$

ここで $Q_{\theta'}$ はターゲットネットワークと呼ばれる. ターゲットネットワークは Q_θ の学習を安定化するために導入されたもので, 一定期間ごとにネットワーク Q_θ をコピーし, 学習の間パラメータを固定したものである.

3.3 Hindsight Experience Replay

insight Experience Replay (ER) はあるエピソードにおいて状態が s_1, s_2, \dots, s_T のように遷移したときに, 仮に s_T がゴール状態であったならばそのエピソードで成功報酬が得られた, という考え方を利用する強化学習手法である. 具体的には, g' をそのエピソードで到達した最終状態 s_T として, リプレイバッファ B_{HER} に $(s_t, a_t, s_{t+1}, r_t, g')$ を蓄積する. そして B からサンプリングした遷移 $(s_t, a_t, s_{t+1}, r_t, g)$ と B_{HER} からサンプリングした遷移 $(s_t, a_t, s_{t+1}, r_t, g')$ の両方に対して式 4 を最小化するように Q_θ を学習する.

ER の優れている点は, そのエピソードで与えられたゴールに対してはエージェントが失敗に終わったとしても, その経験を活用できることである. エージェントがある方策に従って状態 s_T に到達したのであれば, その方策はゴールが s_T で与えられた時の方策として優れていたと考えることができ, これはゴール条件付き強化学習において効率的な方策学習を実現する¹⁰⁾. また, 学習時に複数のゴールを目指すことでさらに高い性能が得られることが示されている⁶⁾.

また, ER の失敗からも学習できるという性質はスパース報酬タスクに対して大きな優位性を発揮する. 一

般に強化学習において報酬関数 r の設計には専門知識が必要であったり、タスクに合わせて試行錯誤を繰り返しながら形を変えたりする必要がある。一方で2値報酬関数は、特にエージェントの探索空間が大きい場合にはエージェントが成功報酬が得られることが少なく学習が進みにくいという欠点があるものの、設計にあたって専門的な知識が必要なくタスク依存性がない。

ER は2値報酬関数を持つスパース報酬タスクに対して高い学習性能を持ち、近年の強化学習研究において重要な役割を果たしている。

3.4 Floyd-Warshall 法

loyd arshall 法はグラフ理論における全点間最短経路問題を解くための手法である。loyd arshall 法の概要を述べる。 n 個のノード $s_i, i = 1, \dots, n$ を考える。 s_i, s_j 間の最短距離 D_{ij} は任意の $k = 1, \dots, n$ に対して次式を満たす。

$$D_{ij} \leq D_{ik} + D_{kj}$$

これに基づいて、次のように D を更新すれば任意のノード間の最短距離を求めることができる。

$$\begin{aligned} & \text{for } i = 1 \dots n \\ & \quad \text{for } j = 1 \dots n \\ & \quad \quad \text{for } k = 1 \dots n \\ & \quad \quad \quad D_{jk} = \min(D_{jk}, D_{ji} + D_{ik}) \end{aligned}$$

本論文では s_k を経由状態と呼ぶ。

ael ling⁷⁾ は loyd arshall 法と強化学習の組み合わせは困難であると主張している。彼はその要因として、強化学習の最も基礎的なアルゴリズムのひとつである learning は Q の初期推定が真値より過大評価しているときに上手くいく傾向があり、一方 loyd arshall 法は初期推定を過小評価しているときに上手くいくという、2手法の性質の違いを提唱している。

4 拡張 loyd-Warshall 法と強化学習への応用

4.1 2値報酬関数と終了条件

本論文では報酬関数 $r: S \times G \rightarrow \mathbb{R}$ が次式のような2値関数で与えられるとする。

$$r(s_t, g) = \begin{cases} r_g & \text{if } f(s_t, g) = 1 \\ r_{ng} & \text{otherwise} \end{cases}$$

ただし $r_g > r_{ng}$ かつ $r_{ng} < 0$ 。 $f(s_t, g): S \times G \rightarrow \{0, 1\}$ はゴール条件を示す関数で、例えば s_t と g の距離 $\|s_t - g\|$ と正数 δ を用いた次のような関数が考えられる。

$$f(s_t, g) = \begin{cases} 1 & \text{if } \|s_t - g\| < \delta \\ 0 & \text{otherwise} \end{cases}$$

エージェントがゴール条件を満たすとそのエピソードは終了とする。

4.2 拡張 Floyd-Warshall 法

本節では loyd arshall 法を価値関数の学習に適用できるように拡張した拡張 loyd arshall 法について述べる。最適 関数 Q^* について、次の定理が成り立つ。

Theorem 1. 報酬関数が式 (6) で表され、エージェントがゴール条件を満たすとそのエピソードは終了とする。このとき、最適 Q 関数 $Q^*_{s, a, g}$ は任意の $s' \in S$ に対して次式を満たす。

$$Q^*_{s, a, g} \geq Q^*_{s, a, s'} + \frac{1 - \gamma}{1 - \gamma r_g - r_{ng}} \left(\max_{a'} Q^*_{s', a', g} - r_g \right)$$

Proof. ゴール条件が満たされるまでにかかる時間を T とする。このときの累積報酬和を R^T とすると、 R^T は次式で表される。

$$R^T = \sum_{t=0}^{T-1} \gamma^t r_{s_t, g} + \frac{1 - \gamma^T}{1 - \gamma} r_{ng} + \gamma^T r_g$$

式 (1) は、 $T_1, T_2 \leq T$ を満たす $T_1, T_2 \geq 0$ を用いて次のように分解できる。

$$R^T = R^{T_1} + \gamma^{T_1} R^{T_2} - r_g \quad (1)$$

また、エージェントがゴール g に到達するための最適な方策を $\pi_g^*: s \mapsto \arg \max_a Q^*_{s, a, g}$ とする。このとき最適 関数 Q^* は次のように表される。

$$Q^*_{s, a, g} = \mathbb{E} [R^T | s, a, \pi_g^*] = \sum_{T=1}^{\infty} p_{s_T = g | s_0 = s, a_0 = a, \pi_g^*} R^T \quad (11)$$

以降では現在状態 s に対して行動 a を取り、その後方策 π に従うときにエージェントが T ステップ後に g を達成する確率を $p_{s_T = g | s, a, \pi} = p_{s_T = g | s_0 = s, a_0 = a, \pi}$ と略記する。ここで、 Q^* は任意の方策 π に対して次式を満たす。

$$Q^*_{s, a, g} \geq Q^\pi_{s, a, g} \quad (12)$$

いま、状態 $s' \in S$ を用意して、次のような方策を考える。

$$\pi_{s, g} = \begin{cases} \pi_{s'}^* & \text{before achieving } s' \\ \pi_g^* & \text{after achieving } s' \end{cases} \quad (13)$$

エージェントがこの方策に従う時の 関数は次式のよ

うに表される .

$$\begin{aligned}
 & Q^\pi s, a, g \\
 & \sum_{T=1}^{\infty} p_{sT} g|s, a, \pi R^T \quad 14 \\
 & \sum_{T=1}^{\infty} \sum_{T_1=1}^T \left\{ p_{sT_2} g|s', \pi_g^* p_{sT_1} s'|s, a, \pi_{s'}^* \right. \\
 & \quad \left. \times (R^{T_1} \gamma^{T_1} R^{T_2} - r_g) \right\} \quad 1 \\
 & \sum_{T_1=1}^{\infty} \left\{ p_{sT_1} s'|s, a, \pi_{s'}^* \right. \\
 & \quad \left. \times \sum_{T_2=1}^{\infty} p_{sT_2} g|s', \pi_g^* (R^{T_1} \gamma^{T_1} (R^{T_2} - r_g)) \right\} \quad 1 \\
 & \sum_{T_1=1}^{\infty} p_{sT_1} s'|s, a, \pi_{s'}^* \\
 & \quad \times \left\{ R^{T_1} \gamma^{T_1} \left(\sum_{T_2=1}^{\infty} p_{sT_2} g|s', \pi_g^* R^{T_2} - r_g \right) \right\} \quad 1 \\
 & \sum_{T_1=1}^{\infty} p_{sT_1} s'|s, a, \pi_{s'}^* R^{T_1} \\
 & \quad \sum_{T_1=1}^{\infty} \left\{ p_{sT_1} s'|s, a, \pi_{s'}^* \frac{1 - \gamma R^{T_1} - r_{ng}}{1 - \gamma r_g - r_{ng}} \right. \\
 & \quad \left. \times \left(\sum_{T_2=1}^{\infty} p_{sT_2} g|s', \pi_g^* R^{T_2} - r_g \right) \right\} \quad 1 \\
 & Q^* s, a, s' \frac{1 - \gamma Q^* s, a, s' - r_{ng}}{1 - \gamma r_g - r_{ng}} \\
 & \quad \times V^* s', g - r_g \quad 1 \\
 & Q^* s, a, s' \frac{1 - \gamma Q^* s, a, s' - r_{ng}}{1 - \gamma r_g - r_{ng}} \\
 & \quad \times \left(\max_{a'} Q^* s', a', g - r_g \right) \quad 2
 \end{aligned}$$

ただし, 式 1 から 1 への変形は $\sum_{T_2=1}^{\infty} p_{sT_2} g|s', \pi_g^* 1$ を利用した . また式 1 から 1 への式変形は, 式 を γ^T について解いた結果を利用した . 従って, 式 12 より次式が成り立つ .

$$\begin{aligned}
 & Q^* s, a, g \geq Q^* s, a, s' \\
 & \quad \frac{1 - \gamma Q^* s, a, s' - r_{ng}}{1 - \gamma r_g - r_{ng}} \left(\max_{a'} Q^* s', a', g - r_g \right) \quad 21
 \end{aligned}$$

以上より, 題意は示された . \square

関数 EFW を次式のように定義する .

$$EFW x, y \quad x \frac{1 - \gamma x - r_{ng}}{1 - \gamma r_g - r_{ng}} y - r_g \quad 22$$

これを用いると式 は次のように表すことができる .

$$Q^* s, a, g \geq EFW Q^* s, a, s', \max_{a'} Q^* s', a', g \quad 23$$

本論文では s' を経由状態と呼ぶ .

式 23 について, 特に $r_g = r_{ng} - 1, \gamma = 1$ のときには

$$\begin{aligned}
 & Q^* s, a, g = -T, \\
 & EFW Q^* s, a, s', \max_{a'} Q^* s', a', g \\
 & \quad Q^* s, a, s' = \max_{a'} Q^* s', a', g
 \end{aligned}$$

となり, $D_{ij} = -Q^* s_i, a_i, s_j$ とすれば式 と同値となる . 以上より, 次のような更新則が得られる .

$$\begin{aligned}
 & \text{for } s' \in \mathcal{S} \\
 & \quad \text{for } s, a \in \mathcal{S} \times \mathcal{A} \\
 & \quad \quad \text{for } g \in \mathcal{S} \\
 & \quad \quad Q s, a, g = \max \left(Q s, a, g, \right. \\
 & \quad \quad \quad \left. EFW Q s, a, s', \max_{a'} Q s', a', g \right) \quad 24
 \end{aligned}$$

本論文ではこれを拡張 lo d arshall 法と呼ぶ .

4.3 DQN への拡張 Floyd-Warshall 法の応用

本論文では 4.2 節で述べた拡張 lo d arshall 法と $D \times N$ を組み合わせた新しい強化学習手法を提案する . 式 24 は, learning のように 関数がテーブル状で表現され, 各 s, a, g について独立である場合にはそのまま使えるが, $D \times N$ のように 関数がパラメタライズされている場合には使えない . そこで提案手法では拡張 lo d arshall 法 24 で導いた $Q s, a, g$ をターゲット $\hat{Q} s, a, g$ として 次式に示す損失関数 L_{EFW} を最小化するように Q_θ を学習する .

$$L_{EFW} = \mathbb{E} \hat{Q} s, a, g - Q_\theta s, a, g^2 \quad 2$$

lo d arshall 法は隣接するノード間の距離は既知である, すなわち D_{ij} の一部は既知であるという前提に基づく手法である . これに対して強化学習においてはすべての s, a, g について最適な 関数 $Q^* s, a, g$ は未知である状態から始まり, 拡張 lo d arshall 法における最適 関数への収束は保障されていない . そこで提案手法では拡張 lo d arshall 法を Bellman 方程式 3 に基づいた学習手法と並行して行う .

一方で, 強化学習に拡張 lo d arshall 法を組み合わせることには, 次のような利点がある . 例えばエージェントがあるエピソードで状態 s から状態 s' に到達し, 別のエピソードで s' から g へ到達したとする . このとき ER は s から s' への到達方法と s' から g への到達方法を学習することはできるが, s から g への到達方法は学習できない . 一方提案手法では ER で学習した s から s' への到達方法と s' から g への到達方法を連結させ, s から g への到達方法も学習することができる . 従って, 通常の強化学習と比較して高い学習性能が得られる . Algorithm 1 に提案手法のアルゴリズムの概要を示す .

Algorithm 1 D N with E tended lo d arshall method

Given: Binar reward f nction $r : \mathcal{S} \times \mathcal{G} \rightarrow \mathbb{R}$ e pressed as Eq. where state space and goal space is eq al $\mathcal{S} = \mathcal{G}$.

Ensure:

```

initialize replaffer  $\mathcal{B}$  and  $\mathcal{B}_{HER}$ 
for episode  $1, \dots, M$  do
  et a goal  $g$  and an initial state  $s_0$ .
  for  $t = 1, \dots, T$  do
    ample an action  $a_t$  from  $\epsilon$  greed pollic  $\pi$ .
     $a_t \sim \pi(s_t, g)$ 
    E ec te the action  $a_t$  and o ser e a ne t state  $s_{t+1}$ 
    for learning step  $1, \dots, N$  do
      ample a mini atch  $B$  from  $\mathcal{B}$  and  $\mathcal{B}_{HER}$ .
      erform an optimization step for  $L_{TD}$  sing  $B$ .
    end for
  end for
  for  $t = 1, \dots, T$  do
     $r_t = r(s_t, g), r'_t = r(s_t, s_T)$ 
    tore the transition  $(s_t, a_t, s_{t+1}, r_t, g)$  in  $\mathcal{B}$ .
    tore the transition  $(s_t, a_t, s_{t+1}, r'_t, s_T)$  in  $\mathcal{B}_{HER}$ .
  end for
  ample states set  $S$  actions set  $A$  wa points set  $S'$  and goals set  $G$  see s section 4.4.
  nitialize  $\hat{Q}$  see s section 4. .
  for  $s' \in S'$  do
    for  $s, a \in S \times A$  do
      for  $g \in G$  do
         $\hat{Q}(s, a, g) = \max \left( \hat{Q}(s, a, g), \right.$ 
           $\left. EFW \hat{Q}(s_0, a_0, s'), \max_{a'} \hat{Q}(s', a', g) \right)$ 
      end for
    end for
  end for
  for learning step  $1, \dots, N'$  do
    erform an optimization step for  $L_{EFW}$ 
  end for
end for

```

4.4 状態のサンプリング

提案手法において、状態空間が大きい場合、式 24 のように s, s', g を状態空間 \mathcal{S} やゴール空間 \mathcal{G} 全体から抽出することが難しくなる。そこで、提案手法では s, s', g を抽出する集合 S, S', G を \mathcal{S}, \mathcal{G} からサンプリングする。本節では S, S', G をサンプリングするべきかを考える。グラフ理論における lo d arshall 法は、隣接するノード間の距離 D が既知であることを前提とした手法である。一方、強化学習には隣接という概念はなく、またグラフ理論での距離に相当する価値 Q^* が未知である。提案手法ではエージェントがある状態・行動の組 s, a から別の状態 s' に到達した経験があることが、グラフ理論における隣接の概念に近いと考えて、経由状態 s' およびゴール状態 g を次のようにリプレイバッファ \mathcal{B}_{HER} からサンプリングする。

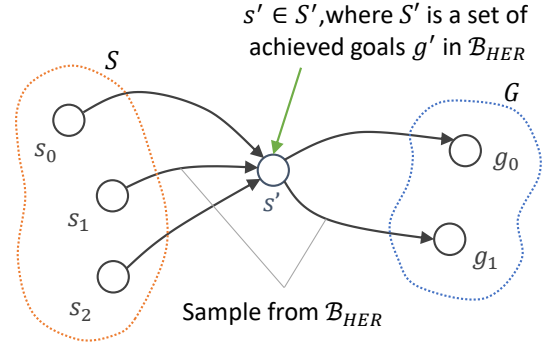


Fig. 1 Sampling method of states set S wa points set S' and goals set G for E tended lo d arshall method.

1. リプレイバッファ \mathcal{B}_{HER} から g' をランダムにサンプリングし、これを経由状態の集合 S' と定義する。
2. 各経由状態 $s' \in S'$ について、 \mathcal{B}_{HER} から $g' = s'$ を満たす遷移 $(s_t, a_t, s_{t+1}, r_t, g')$ を抽出し、得られた s_t, a_t の集合をそれぞれ状態の集合 S 、行動の集合 A とする。
3. 各経由状態 $s' \in S'$ について、 \mathcal{B}_{HER} から $s_t = s'$ を満たす遷移 $(s_t, a_t, s_{t+1}, r_t, g')$ を抽出し、得られた g の集合をゴール状態の集合 G とする。

サンプリング手法の概略図を Fig. 1 に示す。

4.5 拡張 Floyd-Warshall 法の \hat{Q} の初期値

lo d arshall 法において、最短距離の推定値 D が真値より小さいと更新が行われなくなってしまう。これを防ぐために、隣接していないノード間の距離の初期推定を $D = \infty$ とする。拡張 lo d arshall 法においても同様の問題が発生しうる。これを考慮せずに式 2 を最小化するように Q_θ を更新すると、式 4 の最小化を妨害しうる。ael ling⁷⁾ が指摘した問題点もこの lo d arshall 法の性質に起因するものである。これに対して本論文では、拡張 lo d arshall 法の \hat{Q} の初期値に価値関数 Q の取りうる最小値 Q_{min} を導入する。 Q_{min} は報酬関数が式 で表されるとき次のように求められる。

$$Q_{min} = \sum_{t=0}^{\infty} \gamma^t r_{ng} \begin{cases} \frac{r_{ng}}{1-\gamma} & \text{if } \gamma < 1 \\ -\infty & \text{if } \gamma = 1, r_{ng} < 0 \\ r_{ng} & \text{if } \gamma = 1, r_{ng} \geq 0 \end{cases}$$

4.4 節と同様、リプレイバッファ \mathcal{B}_{HER} からサンプリングした s, a, g' の組はグラフ理論における隣接に相当すると考え、初期値を $\hat{Q}(s, a, g') = Q_\theta(s, a, g')$ とし、それ以外の s, a, g' の組に関しては非隣接に相当すると考え、初期値を $\hat{Q}(s, a, g') = Q_{min}$ とする。

ael ling が指摘したように、learning は Q の推定を過大評価しているときに機能する傾向にあり、逆に lo d arshall 法は Q を過小評価しないと適切に機能しない。提案手法は Q_θ と別に \hat{Q} を作成し、 \hat{Q} に Q_{min} を導入することで、拡張 lo d arshall 法の部分では過小評価された価値関数を用いる。これによ




fig. 2 4 rooms environment. The red circle is an agent and the green square is a goal.

discount rate γ	0.9
hidden neuron size	32×1 layer
batch size	4
learning rate	0.001
sampling number of wa point s'	1

table 1 simulation conditions.

と学習とロードシャッフル法を持つ相反する性質の競合を回避することができる。

実験

5.1 シミュレーション環境

fig. 2 に示すような 4 rooms^{22, 23)} という grid 迷路環境で実験を行った。赤色の円と緑色の正方形はそれぞれエージェントとゴールを表す。グレーのマスは壁を表しておりエージェントはこれを通り抜けることはできないが、隣接する部屋間には 1 マスずつ通路がありこれは通過できる。また通路の位置は変化しないものとする。状態はエージェントの座標とし、エージェントは上下左右に 1 マスずつ移動できるものとする。報酬はエージェントがゴールに到達したら r_g 、それ以外は $r_{ng} = -1$ とする。エージェントとゴールの初期位置はランダムとし、エージェントがゴールに到達するか 1 ステップ経過したらエピソード終了とする。

5.2 実験結果

5.2.1 提案手法の効果の検証

提案手法の効果を検証するために、DQN, DQN-ER に ER を適用したもの (DQN-ER), DQN に提案手法である拡張 load-shuffle 法を適用したもの (DQN-proposed) の 3 手法を比較した。シミュレーション条件を table 1 に示す。累積報酬の推移を fig. 3 に示す。ここで、青線は DQN-proposed, 橙線は DQN-ER, 緑線は DQN を表す。図から分かるように、提案手法は ER と比較しておよそ 4 episode までは学習が遅いが、最終的には ER より累積報酬の値が高くなった。

5.2.2 状態のサンプリングと Q_{min} の導入の効果

状態のサンプリングの仕方による効果および拡張 load-shuffle 法における初期推定に Q_{min} を用いる効果を検証する。状態のサンプリングの仕方について、状態およびゴールに関しては S, G をそれぞれリプレイバッファ B_{HER} から独立にランダムサンプリングし、また経路状態に関しては S' を状態空間 S 内からランダムサンプリングする手法を wa-points random と呼ぶこ




fig. 3 learning curves for DQN, DQN-ER and DQN with proposed method.

とにする。また、 Q の初期値について 4. 節で述べた Q_{min} を導入しないものを with-out Q_{min} と呼ぶことにする。本論文では、以下の 4 パターンで実験を行った。

- 4.4 節に従って S, S', G をサンプリングかつ Q_{min} を導入 (提案手法)
- 4.4 節に従って S, S', G をサンプリングかつ with-out Q_{min}
- wa-points random かつ Q_{min} を導入
- wa-points random かつ with-out Q_{min}

a は 2.1 節で示した提案手法と同一である。このときの累積報酬の推移を fig. 4 に示す。ここで、青線は a, 橙線は b, 緑線は c, 赤線は d を表す。図から分かるように、 Q_{min} を導入していないときにサンプリングの方法によっては結果はあまり変わらなかったが、 Q_{min} を導入すると経路状態を状態空間からランダムにサンプリングした場合 (wa-points random) では累積報酬の値は低くなり、一方 4.4 節に従って S, S', G をサンプリングした場合には高い累積報酬を得られる方策を獲得した。以上より、4.4 節で述べた状態のサンプリング手法と 4. 節で述べた Q_{min} の両方を導入することで提案手法は高い学習性能を持つことが分かった。

6 結論

本論文では拡張 load-shuffle 法を用いたゴール条件付き強化学習手法を提案した。load-shuffle 法はグラフ理論の全点間最短経路問題を解くための手法であるが、本論文では報酬関数が 2 値関数で表されると仮定して load-shuffle 法を価値関数の学習に適用できるように拡張した拡張 load-shuffle 法を示した。提案手法は拡張 load-shuffle 法をゴール条件付き強化学習に対して有効な手法として知られる insight Experience Replay と組み合わせた新しい強化学習手法である。load-shuffle 法は隣接するノード間の距離が既知という前提に基づく手法であるが、強化学習には隣接の概念はなく、またグラフ理論での距離に相当する最適価値関数の値はすべての状態間で未知である。本論文ではこれに対し、ある状態・行動の組からあるゴール状態に到達した経験があるとき、これらの組がグラフ理論における隣接の概念に近いと考え、状態・行動・経路状態の組および経路状態・ゴール状態の組を ER で得られたリプレイバッファからサンプリングし

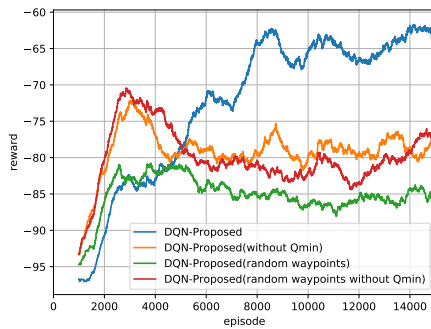


Fig. 4 Learning curves for four cases of the proposed method – a DON proposed both sampling method mentioned in 4.4 and Q_{min} mentioned in 4. are introduced. This one is same as DON proposed. DON proposed with Q_{min} although Q_{min} mentioned isn't introduced states waypoints are sampled the procedure expressed in 4.4. DON proposed random waypoints states and goals are randomly sampled from replaffer \mathcal{B}_{HER} and waypoints are randomly sampled from state space \mathcal{S} and Q_{min} is introduced and DON proposed random waypoints with Q_{min} states and goals are randomly sampled \mathcal{B}_{HER} and waypoints are randomly sampled from \mathcal{S} and Q_{min} isn't introduced.

た。さらに、ロードマッシュ法は隣接しないノード間の距離の初期推定を ∞ とするのに対し、提案手法では未経験の状態・行動・ゴール状態の組に関しては価値関数の初期値を累積報酬の取りうる最小値とした。ゴール条件付き強化学習にロードマッシュ法概念を取り入れることには、エージェントが二つのエピソードから学習した方策を連結することができる、という利点がある。これは従来の強化学習手法にはなかった考え方である。提案手法の有効性を示すために 4 rooms という迷路環境で実験を行った。結果として、提案手法は経路状態・ゴール状態のサンプリングの仕方および拡張ロードマッシュ法の初期値の工夫を加えた場合に従来手法より高い学習性能を示した。

参考文献

1. Mnih, A., Badre, D., Silver, D., Graves, A., & Sutton, R. S. (2015). Human-level control through deep reinforcement learning. *Nature*, **518**(4), 284–292. / 33 2 1
2. Deiliger, A., Wang, Z., Maddison, A., Szepesvári, C., Denzler, D., Schrittwieser, J., Antonoglou, B., Schrittwieser, J., Dieleman, D., Grewe, D., Nham, N., Alsharhan, M., Tschech, M., Lillicrap, M., Hadojić, A., Badre, D., Silver, D., Sutton, R. S., & Schrittwieser, J. (2019). Mastering the game of Go with deep neural networks and tree search. *Nature*, **529**(4), 484–490.

3. A. Ng, A. Jordan, and S. Russell. Autonomous helicopter flight via reinforcement learning. In *Advances in Neural Information Processing Systems*, / 2 4
4. Levine, S., Finn, C., Darrell, T., & Abbeel, P. End-to-end training of deep visuomotor policies. *ICML*, 2016.
5. Heitar, M., Balakrishnan, A., Shah, A., & Singh, S. Path integral guided policy search. In *Proceedings - IEEE International Conference on Robotics and Automation*, 331–337. 2016.
6. Andrzejowski, M., Raia, B., Schneider, R., Ong, S., & McRee, B. A deep reinforcement learning approach to achieve goals. In *Advances in Neural Information Processing Systems*, 2017-December, 4–11. 2017.
7. Deisenroth, M., Engelert, S., & Peters, D. Multi-task policy search for robotics. In *Proceedings - IEEE International Conference on Robotics and Automation*, 3–13. 2014.
8. Chal, D., Morgan, J., Regor, D., & Ilie, R. Neural network approximation. In *32nd International Conference on Machine Learning, ICML 2015*, 1312/1322. 2015.
9. M. Lappert, M. Andrzejowski, A. Raia, B. McRee, B. Baker, S. Howell, S. Schneider, S. Ong, M. Hocij, S. Elinder, S. Mar, and S. Zarema. Multi-goal Reinforcement Learning: Challenging Robotics Environments and Request for Research. *arXiv preprint arXiv:1802.09464*, 1/1. 2018.
10. Zhong, R., Mottaghi, E., & Singh, S. A. Path planning and action selection in indoor scenes using deep reinforcement learning. In *Proceedings - IEEE International Conference on Robotics and Automation*, 331–337. 2016.
11. Raia, B., Maddison, J., Metz, M., & Schmidhuber, J. Insight policy gradients. *arXiv preprint arXiv:1711.06006*, 2017.
12. Eeriah, S., & Singh, S. Multi-goal Reinforcement Learning. *arXiv preprint arXiv:1806.09605*, 2018.

- 14 . D. lkarni . R. Narasimhan A. eedi and . B. enen a m ierarchical deep reinforcement learning ntegrating temporal a straction and intrinsic moti ation n *Advances in Neural Information Processing Systems* 3 2/3 2 1
- 1 A. . ezhnets . sindero . cha l N. eess M. ader erg D. il er and . a kc ogl e dal networks for hierarchical reinforcement learning n *34th International Conference on Machine Learning, ICML 2017* 7 4 / 41 2 1
- 1 . . Bacon . ar and D. rec p he option critic architect re n *31st AAAI Conference on Artificial Intelligence, AAAI 2017* 1 2 /1 34 2 1
- 1 . lorensa D. eld M. lfmeier M. Zhang and . A eel Re erse rric l m eneration for Reinforcement earning 2 1
- 1 R. Zhao and . resp riosit Dri en E peri ence rioritization ia Densit Estimation *arXiv preprint arXiv:1902.08039* 2 1
- 1 . olas . o rnier . iga d M. heto ani and . . de er R ntrinsi call Moti ated Mod lar M lti oal Reinforce ment earning *arXiv preprint arXiv:1810.06284* 2 1
- 2 D. athak . Agrawal A. A. Efros and . Dar rell riosit dri en E ploration elf s per ised rediction n *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops* 1 /1 2 1
- 21 . Nasirian . . ong . in and . e ine lanning with oal onditioned olicies n *Advances in Neural Information Processing Systems* 14 14/14 2 2 1
- 22 R. . tton D. rec p and . ingh Between MD s and semi MD s A framework for tempo ral a straction in reinforcement learning *Artificial Intelligence* 112 1 1 1/211 1
- 23 M. he alier Bois ert . illems and . al Minimalistic ridworld En ironment for penA m <https://github.com/maximecb/gym-minigrid> 2 1

四元数表現を持つ量子ビットニューラルネットワークの 時系列予測への適用

○手操卓也 磯川悌次郎 松井伸之 上浦尚武 (兵庫県立大学)

Quantum Neural Networks with Quaternionic Representation

* Takahito Tsuruta, Tetsuro Isoyama, N. Matsui and N. Kamiyama, University of Hyogo

Abstract— We propose a neural network model based on quantum information processing with quaternionic representation called quaternionic Quantum Neural Network (QNN). The state of a neuron is represented as a point on the Bloch sphere using a quaternion. The operations for this neuron also follow the operations of quaternions. The proposed networks are evaluated through numerical experiments for predicting time series produced by a Lorenz system. They have better performances in predicting long term series as compared to real-valued neural networks.

Key Words: quaternion, Bloch sphere

1 はじめに

近年、量子情報処理とソフトコンピューティング技術を融合した新たな計算モデル、すなわち量子計算知能に関する研究が盛んに展開されている¹⁾。この一つとして、ニューラルネットワーク (Neural Network, NN) における状態表現と操作を量子力学に基づいて記述したモデルとして、量子ビット NN が提案されている²⁾。量子ビット NN はこれまでに時系列予測問題や倒立振子の制御問題などに適用され^{3, 4)}、従来の実数型 NN と比較して優れた性能を有することが示されている。

従来の量子ビット NN においては、ニューロン状態を複素数の確率振幅により表現しているが、そのうちの位相角のみが操作可能であるため、取りうる状態に制限があるという問題がある。量子情報における量子ビットでは、その状態は Bloch 球上の 1 点として表現されており、より高い自由度を有している。また、この状態は unitary 行列を用いたユニタリ変換により操作することができるが、この操作と超複素数の一つである四元数の演算規則の間には同等性が認められる。Bloch 球表現に基づく量子ビット表現と操作を量子ビット NN に取り入れることにより、ニューロン状態の表現能力の向上や効率的な状態操作が期待できるが、これまでにそのような試みはほとんどなされていない。

そこで本研究では、四元数を用いて Bloch 球表現を行ったニューロンモデルを構成し、これに基づいた階層型量子ビット NN (Quaternionic Quantum Neural Network, QNN) モデルを提案する。この QNN について誤差逆伝播法 (Backpropagation, BP) に基づいた学習アルゴリズムを定義した。この QNN と実数型 NN について、カオス系列の予測という課題に対して性能比較を行う。

2 四元数と量子ビット

2.1 四元数の基本的性質

四元数とは複素数を拡張した数体系であり、実数と 3 つの虚数からなる。基底単位を i, j, k として、四元数 x は

$$x = x^{(e)} + x^{(i)}i + x^{(j)}j + x^{(k)}k \quad (1)$$

と表される。ここで $x^{(e)}, x^{(i)}, x^{(j)}, x^{(k)}$ は実数で四元数 x の各成分を表す。基底間の乗法には以下のような規則がある。

$$\begin{aligned} i^2 &= j^2 = k^2 = ijk = -1 \\ ij &= -ji, \quad jk = -kj, \quad ki = -ik \end{aligned} \quad (2)$$

ここで、 ij / ji より乗法について可換ではない。

2.2 量子ビット

量子ビットは、古典ビットの $0, 1$ に対応する $|0\rangle, |1\rangle$ の状態を有する。これは任意の重ね合わせ状態を表現することが可能であり、より高い自由度が得られるものである。この時、任意の重ね合わせ状態は

$$|\phi\rangle = a|0\rangle + b|1\rangle \quad (3)$$

で表すことができる。それぞれの係数 a, b は確率振幅と呼ばれる複素数であり、量子ビット状態 $|\phi\rangle$ を観測したときの $|0\rangle, |1\rangle$ が観測される確率を表す。量子力学の確率解釈に基づき、確率振幅は

$$|a|^2 + |b|^2 = 1 \quad (4)$$

の関係を満たす。

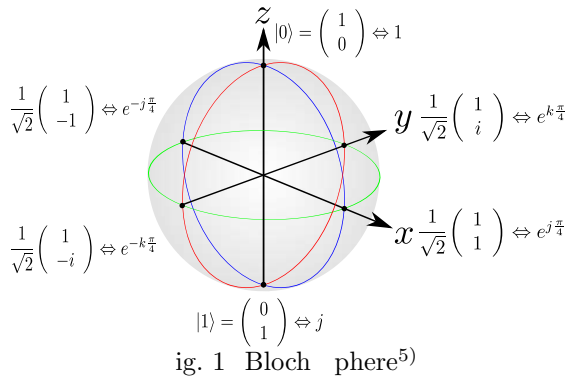
2.3 量子ビットの四元数表現

量子ビットの状態は Bloch 球と呼ばれる球上の点として表現することができる (Fig. 1)。Bloch 球上において式 (3) の確率振幅 a, b は

$$\begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} e^{-i\varphi/2} \cos \theta/2 \\ e^{i\varphi/2} \sin \theta/2 \end{pmatrix}$$

と表される複素数であり、2 つの複素数の実部と虚部を用いて式 (5) で表される⁵⁾。

$$q = \text{Re } a + \text{Im } a i + \text{Re } b j + \text{Im } b k$$



ig. 1 Bloch sphere⁵⁾

3 四元数量子ビットニューラルネットワーク

3.1 QQNN モデルの定義

量子回路による演算は 1 it 回転ゲート及び 2 it 制御 N ゲートと呼ばれる 2 つの基本量子論理ゲートの組み合わせによって行われる。それぞれの四元数による表現を $q = a + bi + cj + dk$ として式 (1) に示す。

$$f(q) = \frac{q \cdot u}{|q|} \cos(\omega) + \frac{q \times u}{|q|} \sin(\omega)$$


$$g(q, \delta) = \frac{\sin(1 - \delta)\lambda}{\sin \lambda} q + \frac{\sin \delta \lambda}{\sin \lambda} q_{not}$$

1 it 回転ゲートは位相を変換する役割を持っており、四元数による表現は回転軸 u と回転角 ω を決めた四元数を右からかけることによって表される。また、回転軸 u は x で表される純虚四元数をそのノルムで規格化したものである。2 it 制御 N ゲートは確率振幅の変換を行う役割を持っており、その疑似的な表現のために四元数の球面線形補間 (ig.2) を用いて元の四元数 q と、確率振幅 a, b を入れ替えた四元数 q_{not} の間の四元数を補間している。また、式 (2) 中の δ は反転度パラメータと呼ばれる変数であり、このパラメータに従って確率振幅の計算が行われる。本来、反転度パラメータは q から q_{not} への直接変換のために $q \cdot q_{not} = 1$ の値のみが得られる必要があるためステップ関数による変換が必要である。ステップ関数は微分不可能であるため、B を導出するために微分可能な sigmoid 関数や、lippedRe 関数を用いる。ここで lippedRe 関数とは、通常の Re 関数の上限を 1 とした関数である。


これらのゲートを組み合わせて四元数量子ビットニューラルネットワークのニューロンモデルを ig.3 のように表現できる。ig.3 中の関数 f が 1 it 回転ゲートであり、式 (1) に対応し、関数 g が 2 it 制御 N ゲートであり、式 (2) に対応している。関数 h は反転度パラメータの変換に用いる関数である。

3.2 BP の導出

B を導出するためには合成関数に四元数が含まれる場合の四元数による微分の計算を行う必要がある、式



ig. 2aternion spherical linear interpolation



ig. 3 NN Neuron Model

のように表され、すべての基底単位についても同様の計算を行う。

$$\frac{\partial E}{\partial q} = \frac{\partial E}{\partial q_e} \frac{\partial E}{\partial q_i} \frac{\partial E}{\partial q_j} \frac{\partial E}{\partial q_k}$$

$$\frac{\partial E}{\partial q_e} = \frac{\partial E}{\partial p_e} \frac{\partial p_e}{\partial q_e} \quad \frac{\partial E}{\partial q_i} = \frac{\partial E}{\partial p_i} \frac{\partial p_i}{\partial q_e} \quad \frac{\partial E}{\partial q_j} = \frac{\partial E}{\partial p_j} \frac{\partial p_j}{\partial q_e} \quad \frac{\partial E}{\partial q_k} = \frac{\partial E}{\partial p_k} \frac{\partial p_k}{\partial q_e}$$

ここで、 E は実数関数、 p, q は四元数を表す。この計算を式 (3), (4) にそれぞれ適用することで B の導出が行える。

4 実験

NN の評価をするためにローレンツアトラクタを用いたカオス時系列予測を行い、実数 NN と比較をして NN の性能を評価する。

4.1 ローレンツアトラクタ

ローレンツアトラクタはローレンツ方程式に基づいて状態が遷移するカオス系列モデルである。ローレンツ方程式は式 (1), (11), (12) で表される。

$$\frac{dx}{dt} = \sigma(y - x) \tag{1}$$

$$\frac{dy}{dt} = x(\rho - z) - y \tag{11}$$

$$\frac{dz}{dt} = xy - \beta z \tag{12}$$

この x, y, z は時刻 t におけるローレンツアトラクタの状態を表す。また、 σ, ρ, β はローレンツ方程式のパラメータであり、一般的に用いられるパラメータとして $\sigma = 10, \rho = 28, \beta = 8/3$ を今回は使用した。

4.2 実験条件

式 (1), (11), (12) により構成したローレンツアトラクタを用いて、ローレンツアトラクタの初期状態を $x, y, z = 1, 1, 1$ と設定する。この条件におい

Table 1 Network conditions

	NN	NN
Network structure	1 3	3
Number of parameters	3	
optimizer	Adam	
loss function	MSE	
Number of learning	1	

てデータとして時刻 $t \in [0, 3]$ を微小時間 $dt = 0.1$ で区切った 3 ステップ分を x, y, z それぞれについて作成する. ネットワークに入力する際のデータの範囲を $[-1, 1]$ にするため求めたデータについて正規化を行う.

作成した 3 ステップの内 $t \in [0, 2]$ を訓練データ, $t \in [2, 3]$ をテストデータとして用いる. ネットワークを学習させる際には時刻 $t-2, t-1, t$ の 3 ステップ分を入力データとし, 教師データとしては時刻 $t - \Delta t$ を用いる. この時, 教師データを作成できないデータについては訓練データ, テストデータから除外している. この Δt は何ステップ先のデータを予測するかを決めるためのパラメータであり, 今回 Δt は 1 から 10 までを 1 ステップ刻みで計 10 パターンについて実験を行った.

実験に用いるネットワークとして NN 及び実数 NN を構成する. 構成したネットワークの構造, 条件を Table 1 に示す. この時, 実数 NN について活性化関数として ReLU 関数を用い, それぞれのネットワークについてパラメータの総数が同程度となるように構成した.

4.3 実験結果

NN, 実数 NN それぞれのネットワークによって得られたテストデータに対する推論データを元にローレンツアトラクタを再構築し元のデータとの比較を行う. 得られた x, y, z を 3次元座標として, 10 パターンの Δt の内 $\Delta t = 1, 3$ の 2 パターンについて再構築したものを Fig. 4, Fig. 5, Fig. 6, Fig. 7 に示す. Fig. 4, Fig. 5 より, NN と実数 NN の結果は NN の再構築はうまくいっているが, 実数 NN の再構築はこの条件でもずれが生じていることが分かる.

次に, Fig. 6, Fig. 7 より, 実数 NN の再構築は完全にずれた値が得られているのに対して, NN の結果はローレンツアトラクタの形を再現することができていることが分かる. 得られた 10 パターン分の結果についてテストデータに対する損失の最小値を Fig. 8 に示す. Fig. 8 から実数 NN と比較して NN の損失が各 Δt においてすべて低く, カオス時系列であるローレンツアトラクタの予測がうまく行えていることが分かる.

まとめ


本研究では, NN の B 導出による定式化及び, ローレンツアトラクタを用いたカオス時系列予測を行った. その結果, カオス時系列予測において NN は実数 NN と比べてローレンツアトラクタの再構築がより

離れたステップについても軌跡を外れずに予測できている, 時系列問題に対して有効に働くことが示された.


今後の課題として, 現段階において NN では中間層の出力において活性化関数は定義されていないため, 四元数量子ビットに対する非線形変換の検討, 畳み込みニューラルネットワークへの四元数量子ビットの拡張などが挙げられる.

参考文献

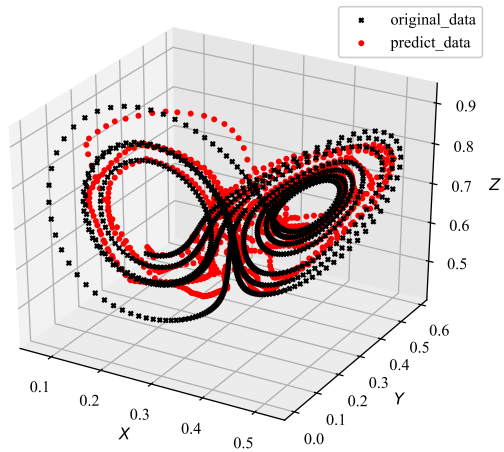
- 1 A. Man and M. Nigam. Application of quantum inspired computational intelligence as a regression Artificial intelligence Review **42** 1 1 2 14
- 2 N. Oda, N. Matsui and Y. Nishimura. A multi-layered feed forward network based on quantum model. International Journal of Quantum Information Science **35** 13 43 1 2 4
- 3 Y. Eguchi, N. Matsui and T. Hirokawa. Performance of a quantum neural network in chaotic time series forecasting. Neural Information Processing **23** 2 2 1
- 4 N. Oda, N. Matsui, Y. Nishimura and Y. Iwano. An examination of a quantum neural network in controlling an inverted pendulum. Neural Process. Lett. **22** 3 2 2 2
- 5 B. Hartono and D. Koch. Unit quaternions and the Bloch sphere. Journal of Physics A: Mathematical and Theoretical **48** 23 23 3 2 2 1




ig. 4 rajector reconstructed from NN
 $\Delta t = 1$




ig. rajector reconstructed from NN
 $\Delta t = 1$



ig. rajector reconstructed from NN
 $\Delta t = 3$



ig. rajector reconstructed from NN
 $\Delta t = 3$



ig. Minimum loss with respect to Δt

制限ボルツマンマシンによる倒立振子の状態推定

○橋本尚典 松井伸之 伊丹哲郎 磯川悌次郎 (兵庫県立大学)

State Estimation of Inverted Pendulum with RBM

* . ashimoto N.Matsui . tamii . sokawa . ni ersit of ogo

Abstract— Estimating internal states is an important task for autonomous systems such as mobile robots. This paper proposes a state estimation method based on Restricted Boltzmann Machine (RBM). Estimation can be conducted only by calculating conditional probabilities on the output units in RBM network leading to take prompt responses for irregular states. The proposed method is evaluated through the estimation of a system with inverted pendulum compared with long short term Memory (LSTM) network. Experimental results show that the proposed method is comparable to LSTM for the detection accuracy but the computational speed is faster than LSTM.

Key Words: state estimation, statistical machine learning, Boltzmann machine

1 はじめに

自律ロボットにおいて、自らが正常な状態にあるか判断することは重要である。異常な状態にあることを早期に判断できれば、問題が起こる前に対処することが可能となる。類似した試みとして、時系列データから異常なデータを判断する異常検知の手法がある。教師なしで時系列データの異常検知をおこなう手法として代表的なものに、自己回帰モデルである AR MA^{1, 2)} によるものや、LSTMによるもの^{3, 4, 5)} がある。一般的にこれらの方法では、予測値と実測値の差が大きいものを異常だと判定するという方法がとられる。この例のように機械学習モデルに時系列データを学習させることによりロボットの状態を判断することが可能である。

本稿では、条件付きボルツマンマシンを用いた状態推定の手法を提案する。LSTMを用いた方法では、予測値と実測値の差の分布を用いて状態の判定が行われる。制限ボルツマンマシンでは特定の実測値が得られる確率を評価できるので、予測値を求めること無く状態の判定を行うことが可能である。本研究では、倒立振子を用いて制限ボルツマンマシンによる状態推定について検証する。また、時系列データ予測によく用いられるLSTMによる手法との比較を行う。まず使用したモデルである条件付きボルツマンマシンについて要約したのち、実験方法と結果について述べ、提案手法の有効性を示す。

2 条件付き制限ボルツマンマシン

はじめに、ボルツマン機械学習モデルのなかで、時系列データを扱うことが可能な条件付き制限ボルツマンマシン (conditional Restricted Boltzmann Machine (CRBM)、特に本研究で用いた入出力層にガウシアンユニットを導入したモデル^{6, 7, 8)} について必要事項を述べる。RBMはfig. 1に示すような確率的学習モデルである。入力層、出力層、隠れ層から構成されており、同じ層に属するユニット間に接続はないが、異なる層に属するユニットは互いに接続される。入力層の値 x と出力層の値 y は実数値をとり、隠れ層の値 h は $\{0, 1\}$ の二値をとる。本稿では、各層のユニットの番号を表すために添え字として入力層には k 、隠れ層には j 、出力層には i を用いた。例えば、入力層の i

番目のユニットと隠れ層の j 番目のユニット間の重みは $W_{i,j}$ と表される。エネルギーは次式で定義される。

$$E_{\theta}(\mathbf{y}, \mathbf{h} | \mathbf{x}) \equiv \sum_i \frac{(y_i - \hat{b}_i)^2}{2\sigma_i^2} - \sum_j \hat{c}_j h_j - \sum_i \sum_j y_i \frac{W_{i,j}}{\sigma_i} h_j \quad (1)$$

ここで、 b_i, c_j は出力層、隠れ層のバイアス、 $W_{i,j}, A_{k,i}, B_{k,j}$ はそれぞれ、出力層と隠れ層、入力層と出力層、入力層と隠れ層間の重みである。また、 σ_i は出力層の分散に関するパラメータであり、通常 $\sigma_i = 1$ とする⁹⁾。これらのパラメータをまとめて $\theta = \{b, c, W, A, B, \sigma\}$ と示す。そして、

$$\hat{b}_i = b_i + \sum_k A_{k,i} x_k \quad (2)$$

$$\hat{c}_j = c_j + \sum_k B_{k,j} x_k \quad (3)$$

である。

エネルギーを用いて以下の条件付き確率が定まる。

$$\mathbb{P}_{\theta}(\mathbf{y}, \mathbf{h} | \mathbf{x}) = \frac{1}{Z_{\theta}} \exp(-E_{\theta}(\mathbf{y}, \mathbf{h} | \mathbf{x})) \quad (4)$$

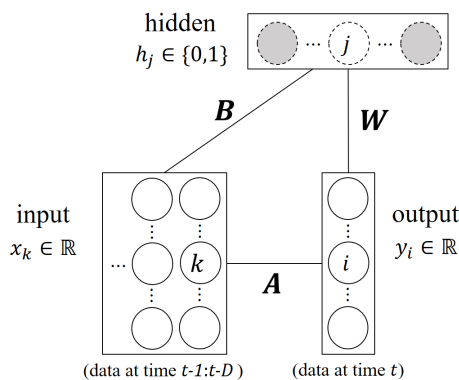


fig. 1 Architecture of RBM

Z_{θ} は分配関数であり、

$$Z_{\theta} \equiv \int_{-\infty}^{\infty} \sum_{\tilde{\mathbf{h}}} e^{-E_{\theta}(\mathbf{y}, \tilde{\mathbf{h}} | \mathbf{x})} d\mathbf{y}$$

で定義される。ここで、 $\int_{-\infty}^{\infty} \dots d\mathbf{y}$ は \mathbf{y} に関する多重積分を表しており、 $\sum_{\tilde{\mathbf{h}}}$ は \mathbf{h} の取りうる値のすべての組み合わせについての多重和である。分配関数についての計算量はノード数に対して指数関数的に増加するため一般的に評価するのが困難である。

RBM は入力層の値を所与としたときに、出力層と隠れ層を制限ボルツマンマシン Restricted Boltzmann Machine RBM とみなして学習させることができる。RBM は一方の層の値が与えられたときに、他方の層の値が互いに条件付き独立となる性質をもつ。このことから以下の条件付き確率が求まる。

$$\mathbb{P}_{\theta}(\mathbf{y} | \mathbf{x}, \mathbf{h}) = \prod_i \mathcal{N}\left(y_i \mid \left(\hat{b}_i + \sigma_i \sum_j W_{i,j} h_j\right), \sigma_i^2\right)$$

$$\mathbb{P}_{\theta}(\mathbf{h} | \mathbf{x}, \mathbf{y}) = \prod_j \frac{e^{-\left(\hat{c}_j + \sum_i y_i \frac{W_{i,j}}{\sigma_i}\right) h_j}}{1 + e^{-\left(\hat{c}_j + \sum_i y_i \frac{W_{i,j}}{\sigma_i}\right) h_j}}$$


ここで、 $\mathcal{N}(y | \mu, \sigma^2)$ は平均値が μ 、分散が σ^2 である正規分布を表している。また、隠れ層は ± 1 の二値をとることから 式を変形して、

$$\mathbb{P}_{\theta}(h_j = 1 | \mathbf{x}, \mathbf{y}) = \frac{1}{1 + e^{-\left(\hat{c}_j + \sum_i y_i \frac{W_{i,j}}{\sigma_i}\right) h_j}} = \text{sigmoid}\left(\hat{c}_j + \sum_i y_i \frac{W_{i,j}}{\sigma_i}\right)$$

と表すことができる。

RBM の学習方法として Contrastive Divergence (CD) 法¹⁰⁾がある。特に本研究で用いた CD₁ 法の手順を簡単に説明する。

1. 学習データからサンプル \mathbf{X}, \mathbf{Y}_0 を選択
 2. 入出力層の値を所与としたときに 式より隠れユニットの値が ± 1 をとる確率が求まるので、その確率値に従って \mathbf{H}_0 を決める。
 3. 式から出力ユニットの値が従う正規分布の平均値が求まるので、その値を \mathbf{Y}_1 とする。
 4. 2. と同様にして \mathbf{H}_1 を決める。
- 以上の手順を通じて取得した、 $\mathbf{Y}_0, \mathbf{H}_0, \mathbf{Y}_1, \mathbf{H}_1$ を用いてパラメータの更新を行う。



ig. 2 cart pole

3 実験環境

本研究では、倒立振子を用いて実験を行う。そのため、まず倒立振子のシミュレーション環境についての説明を行う。倒立振子のシミュレーションには、penA社開発の g m ライブラリを用いた。倒立振子は、ig. 2 に示すように台車 cart と棒 pole で構成されており台車を左右に押すことにより棒を立てる。倒立振子の状態は、台車の位置 m、台車の速度 m/s、棒の角度 rad、棒の角速度 rad/s で決まり、倒立振子への操作は 2 ms 毎に一定の強さで台車を左か右に押すことが許される。倒立振子への操作を行う毎に、倒立振子の状態が得られる。倒立振子の初期状態はそれぞれ、

- 台車の位置 . m から . m
- 台車の速度 . m/s から . m/s
- 棒の角度 . rad から . rad
- 棒の角速度 . rad/s から . rad/s

の範囲でランダムに決定される。本稿では倒立振子に対する操作の回数を step、倒立振子を初期状態からスタートさせてから数 step の操作を行いリセットするまでの期間を Epoch、倒立振子进行操作するコントローラをシステムと呼ぶ。倒立振子の初期状態がランダムに定まるため、システムが同じであっても Epoch 毎に得られる倒立振子の状態は異なる。


本研究における正常なシステムとは D 制御により台車を操作し、棒を立て続けるように制御するシステムである。それに対し、異常のあるシステムとは一定の確率で正常なシステムの操作と異なる操作をするシステムのことを指す。ig. 3 に正常なシステムと、一定の確率で誤動作を起こす異常なシステムを 2 step の間、動かした場合における棒の角度を示した。

4 実験方法

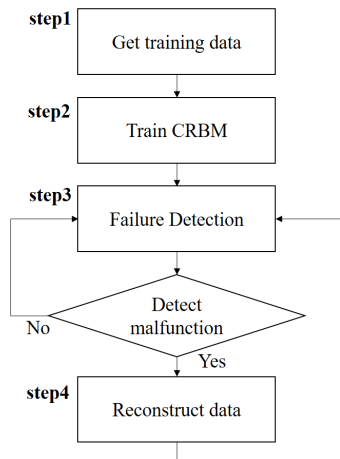
本研究では、倒立振子を用いた状態推定を行う。具体的な、台車の速度を観測することによりシステムの状態を捉える。ig. 4 に提案手法の一連の流れを示した。以降の節で詳細を述べる。

4.1 学習データの取得

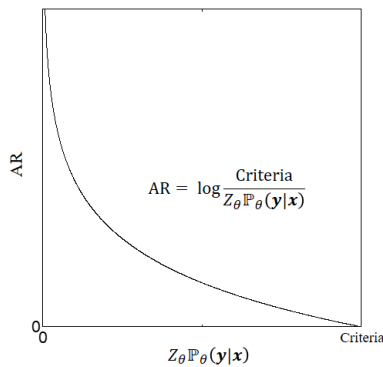
正常なシステムにより、倒立振子进行操作したときの台車の速度の時系列データを学習データとする。1Epoch あたり 1 step の観測を行い、それを Epoch 行うことで学習データ $\mathbf{D} = \{d_1, d_2, \dots, d_t, \dots\}$ を取得した。



ig. 3 Pole Angle



ig. 4 Flow of the failure reconstruction



ig. 5 Anomalous Rate

4.2 CRBMの学習

RBMの出力ユニットに時点 t における学習データ d_t 、入力ユニットに時点 t から $step$ 手前までの学習データ $d_{t-5:t-1}$ を入力してD₁法により学習を行った。各パラメータの初期値は -0.1 から 0.1 の範囲の一様分布から取得し、隠れ層のユニット数は1、ミニバッチサイズは1、エポック数2、学習率は 10^{-5} とした。

4.3 異常の検出

以下の式から、現時点のデータ y の条件付き確率が求まる。

$$P_{\theta}(y | x) = \frac{1}{Z_{\theta}} \sum_{\mathbf{h}} e^{-E_{\theta}(y, \mathbf{h} | x)}$$

先に述べたとおり、 Z_{θ} を評価するのは困難である。そこで、式(1)の Z_{θ} を左辺に移項して右辺を計算して得られた $Z_{\theta} P_{\theta}(y | x)$ の値を状態推定に用いる。 Z_{θ} は θ の更新がないときには定数として考えることができる。

式(1)に式(2)を代入し式変形することで以下の式が得られる。

$$Z_{\theta} P_{\theta}(y | x) = \prod_i e^{-\frac{(y_i - \hat{b}_i)^2}{2\sigma_i^2}} \prod_j \left(1 - e^{-\left(\hat{c}_j - \sum_i y_i \frac{w_{i,j}}{\sigma_i}\right)} \right) \quad (1)$$

正常なシステムにおける $step$ 分の時系列データから、それぞれの時点における $Z_{\theta} P_{\theta}(y | x)$ の値を求めその最小値を $criteria$ とする。誤動作が起これば $Z_{\theta} P_{\theta}(y | x)$ の値は $criteria$ よりも小さくなることを考慮して、異常度合いを表すAnomalous Rate ARの式を以下の式で定義する。

$$AR \equiv \begin{cases} \log \frac{Criteria}{Z_{\theta} P_{\theta}(y | x)} & Z_{\theta} P_{\theta}(y | x) < criteria \\ 0 & Z_{\theta} P_{\theta}(y | x) \geq criteria \end{cases} \quad (11)$$

式(11)とig. 5から分かるように、 $Z_{\theta} P_{\theta}(y | x)$ が $criteria$ に近づく、つまり正常なシステムでの制御において経験したことのない値をとるとARは大きくなる。ARの値が0.3を超えるとシステムは誤動作を行ったと判断する。ARが0.3となるとき $Z_{\theta} P_{\theta}(y | x)$ の値は $criteria$ のおよそ半分


4.4 データの補正

異常値と判断された時点のデータをRBMから生成し異常値と置き換え先の時点の予測に用いることで、異常値が出た時点以降の予測への影響を軽減する。異常値と判断された時点のデータの生成は以下の手順で行われる。RBMからのデータの生成には入力ユニットの値を所与として隠れユニットと出力ユニットの間でギブスサンプリング¹¹⁾を行い、サンプリングされた出力ユニットの値を生成データとした。


実験結果

5.1 提案手法の検証

まず提案手法を用いて、2.2の確率で誤動作を起こす異常のあるシステムにおける時系列データからARを計算することで状態推定を行った結果を示す。ig. 6aに異常なシステムで倒立振子を制御したときの棒の角



ig. ail re Rate



ig. Res lt of Reconst rct

度、ig. に異常なシステムでの台車の速度の時系列データからARを計算した結果を示した。ig. 右端の黒丸の時点において倒立振子は倒れた。ig. から、システムが異常な動作をして倒立振子のバランスが崩れた付近でARの値が大きくなっていることが確認できる。また、倒立振子が倒れる直前にARの値が最大値をとることが分かる。

ig. に異常のあるシステムで倒立振子を制御したときに得られた台車の速度を示した。ig. 中の破線は倒立振子から得られたそのままのデータで、実線はRが.3より大きくなった時点での補正を行ったデータである。データの補正を行うことによって誤動作が起きたときの異常なデータが正常なデータに置き換えられていることが分かる。

以上の実験結果から、観測データの条件付き確率を計算することで倒立振子の状態推定を行えることが検証できた。

5.2 従来手法との比較

の確率で誤動作を起こすシステムを用いて、提案手法と従来手法であるMを用いた方法との比較を行った。

まず、状態推定の精度について比較した。このとき、状態推定を行う時点からstep手前までのデータをもとに状態推定を行うものとする。また、Mは隠れ層を1層もち、RBM、Mともに隠れユニット数

は2とした。状態推定の精度の比較には受信者操作特性ROC曲線を用いた。ここでのROC曲線は、状態推定モデルの閾値を変化させたときに、正常な状態を異常だと判断した割合false positive rateを横軸に、異常な状態を正しく異常だと判断した割合true positive rate縦軸に表したものである。また、ROC曲線と軸に囲まれた下部の面積は曲線下部面積Aとよばれ、Aが大きいほど精度の良い状態推定能力をもつとみなせる。ig. にそれぞれの手法における状態推定についてのROC曲線を示した。それぞれのAについて、RBMがA、MがA、MがA、1であり提案手法はMを用いる場合とほぼ同程度の状態推定能力をもつことが分かる。

次に、状態推定に必要な時間について比較した。

table. 1 に、Dstep手前までのデータを用いた状態推定にかかる時間を示した。ただし、D=1のときのRBMの状態推定に必要な時間を1.として評価した。

table. 1 から、RBMを用いた状態推定は長期のデータをもとに状態推定を行う場合にMと比較して有効であることが分かる。

6 おわりに

本稿では、条件付き制限ボルツマンマシンを用いて観測データの条件付き確率を求めることにより状態推

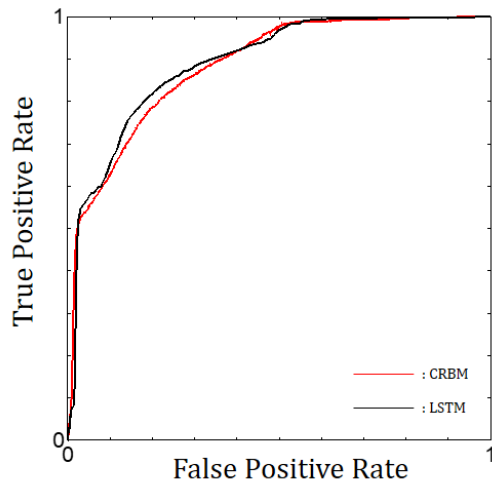


Fig. 1. ROC curve for anomaly detection in time series data

D	RBM	M
1	1.	1.
1	1.	1.34
1	1.	2.1
2	1.11	4.3

定を行う手法を提案し、状態推定に必要な時間が短く有効であることを示した。提案手法を実ロボットに適用する上で、動的に変化する環境に対応可能な状態推定を考える必要がある。そこで、オンラインでの学習が可能なボルツマン機械学習モデルでの検証を今後の課題としたい。

参考文献

- 1 A.B. harma . ol chik and R. o indan . Sensor Alerts Detection Methods and Relevance in Real World Datasets A M Trans on SensorNetworks **6** 3 13 2 1
- 2 M.M nir .A. iddiq i M.A. hattha A.Dengel and .Ahmed .ns per ised Anomal Detection in Streaming Sensors Data Using Statistical and Deep Learning Models Sensors **19** 11 2 1
- 3 .Malhotra . ig . hroff and .Agarwal . Long Short Term Memor Networks for Anomal Detection in Time Series ANN 23rd European mposition on Artificial Neural Networks Computational Intelligence and Machine Learning 2 1
- 4 M. oelch .Ba er M. dersdorfer and . magt . Variational Inference for Online Anomal Detection in High Dimensional Time Series arXiv:1812.11232 2 1
- M. .Al Dosari .ns per ised Anomal Detection in Sequences Using Long Short Term Memor Recurrent Neural Networks
恐神 貴行 .ボルツマンマシン コロナ社 2 1
- . . a lor and . . inton . Modeling Human Motion Using Binary Latent Variables Advances in Neural Information Processing Systems 1 13 4 13 2
M .ress 2
- . . a lor and . . inton . Factored Conditional Restricted Boltzmann Machines for Modeling Motion
Title M 2 1 2 1 32 2
- . . inton . A practical guide to training restricted Boltzmann machines Technical report 2 1 3
Machine Learning Report University of Toronto 2 1
- 1 . . inton . Training Rodents of Experts: Minimizing Contrastive Divergence Neural Computation **14** 1 1 1 2 2
- 11 .M. ビショップ .パターン認識と機械学習 下 丸善出版 2 12

四元数畳み込みニューラルネットワークの構築と性能評価

○本郷嵩人 磯川悌次郎 松井伸之 上浦尚武 (兵庫県立大学)

Quaternionic Convolutional Neural Networks for Color Image Processing

* T. Hongo, T. Isohara, N. Matsui and N. Kamiyama, University of

Abstract— This paper proposes a convolutional neural network based on quaternionic algebra called quaternionic convolutional neural network (QCNN). The neuron model in this network adopts three-dimensional geometric transformations driven by quaternionic operators. Thus, this network deals with three-dimensional signals such as color images. The performances of the proposed network are investigated through classifications of color images in the AR1 and AR1 datasets. The experimental results show that the proposed network has better classification abilities as compared to the real-valued convolutional neural network.

Key Words: quaternion convolutional neural networks, image classification

1 はじめに

近年、様々な画像認識分野において超多層構造のニューラルネットワーク (NN) が適用されており¹⁾, 様々なタスクにおいてその有効性が示されている. いわゆる深層学習と呼ばれる大規模 NN における性能向上に寄与する要素の一つは畳み込み層, プーリング層と呼ばれる層の導入であり²⁾, これらにより位置不変な画像特徴の抽出が可能となっている.

カラー画像をはじめとする多チャネルの入力情報に対して畳み込み層やプーリング層による処理を行う場合には, この入力情報はチャンネル毎に分割されそれぞれを畳み込み演算や平均化などを行う必要がある. このような多次元情報をそのまま取り扱うことができれば, より効率的な信号処理が期待できる. このような多次元情報を取り扱う方法としては, 複素数や超複素数により状態の記述や操作を行うということが挙げられ, このような考え方に基づく NN は, 複素 NN としてこれまでに数多く提案されている³⁾. しかしながら, 畳み込み層などの操作を取り入れた複素 NN・超複素 NN は数少なく⁴⁾, 現状ではほとんど検討されていない. そこで本研究では, 超複素数の一つである四元数に基づく NN である四元数 NN⁵⁾ に基づき, 畳み込み演算などを導入した四元数畳み込み NN (Quaternionic Convolutional Neural Network (QCNN)) を提案する. さらに, AR1 および AR1 データセットにおける画像識別問題を通して CNN の有効性を評価する.

2 四元数ニューラルネットワーク


2.1 四元数

四元数は実数成分および三虚数成分を持つ超複素数であり 四元数 x は虚数単位をそれぞれ i, j, k とすると

$$x = x^{(e)} + x^{(i)}i + x^{(j)}j + x^{(k)}k \quad (1)$$

と表される. ここで $x^{(e)}, x^{(i)}, x^{(j)}, x^{(k)}$ は実数で 四元数 x の各成分を表す. したがって, 四元数全体の集合 \mathbf{K}^4 は $1, i, j, k$ を基底とする四元数ベクトル空間を構成する. また 実数成分 $x^{(e)}$ の四元数を純虚四元数と呼び, 純虚四元数の集合を \mathbf{I} とする.

四元数の乗法は 実数である四元数の成分と虚数単位



ig. 1 Rotation r in the space \mathbf{I} .

を交換可能と考え 虚数単位間の掛け合わせの規則には amilton の関係が成立し

$$\begin{matrix} i^2 & j^2 & k^2 & ijk & -1 \\ ij & -ji & k, jk & -kj & i, ki & -ki & j \end{matrix} \quad (2)$$

と定義される. ここで ij / ji より明らかな様に 乗法について可換ではない.

これらの定義より, 四元数 q と p の積は以下の様に表される.

$$\begin{matrix} qp & q^{(e)}p^{(e)} - q^{(i)}p^{(i)} - q^{(j)}p^{(j)} - q^{(k)}p^{(k)} \\ & q^{(i)}p^{(e)} + q^{(e)}p^{(i)} - q^{(k)}p^{(j)} + q^{(j)}p^{(k)} & i \\ & q^{(j)}p^{(e)} + q^{(k)}p^{(i)} + q^{(e)}p^{(j)} - q^{(i)}p^{(k)} & j \\ & q^{(k)}p^{(e)} - q^{(j)}p^{(i)} + q^{(i)}p^{(j)} + q^{(e)}p^{(k)} & k \end{matrix} \quad (3)$$


また四元数 x の共役およびノルムは以下の様に定義される.

$$\begin{matrix} x^* & x^{(e)} - x^{(i)}i - x^{(j)}j - x^{(k)}k \\ |x| & \sqrt{xx^*} = \sqrt{x^{(e)2} + x^{(i)2} + x^{(j)2} + x^{(k)2}} \end{matrix} \quad (4)$$


四元数における平行移動と相似変換は x, y, u を 3次元ベクトル空間座標の点を表す純虚四元数とする時 2次元ベクトル空間と同様に記述される. すなわち ベクトル x を y だけ平行移動させたベクトルは $x + y$ となり ベクトル x の相似変換はスカラー値 a を用いて ax と記述される.

四元数の ig. 1 に示すような回転変換は以下の式によって表すことができる.

$$y = p x p^*$$



a lassification accuracy.



lassification loss.

fig. 2 Test accuracies and losses on MNIST and MNIST using AR 1 dataset.

ここで \mathbf{p} は $|\mathbf{p}| = 1$ の四元数である。四元数 \mathbf{p} は $|\mathbf{u}| = 1$ を満たす純虚四元数 \mathbf{p} と $|\alpha| < \pi$ を満たす角 α を用いて

$$\mathbf{p} = \cos \alpha + \sin \alpha \cdot \mathbf{u}$$

と記述することができる。この式を用いると式 (1) は

$$\mathbf{y} = \cos 2\alpha \cdot \mathbf{x} + \sin 2\alpha \cdot \mathbf{u} \times \mathbf{x}$$

と変換することができ、 \mathbf{x} をベクトル \mathbf{u} 周りに角度 2α だけ変換させていることを表している。

2.2 四元数ニューロンモデル

四元数ニューロンモデルには四元数の幾何学変換作用を取り入れたモデル⁵⁾を用いる。このモデルでは四元数ニューロンユニットの入出力データはすべて純虚四元数 (三次元) となっている。

四元数ニューロンユニットの出力 \mathbf{y}_j は

$$\mathbf{s}_j = \sum_{i=1}^N \frac{\mathbf{w}_{ji} \mathbf{x}_i \mathbf{w}_{ji}^*}{|\mathbf{w}_{ji}|} \theta_j$$

$$\mathbf{y}_j = h(s_j^{(i)}) \mathbf{i} + h(s_j^{(j)}) \mathbf{j} + h(s_j^{(k)}) \mathbf{k} \quad (1)$$

で表される。ここで N は前段のニューロン数、 $\mathbf{x}, \mathbf{w}, \theta, \mathbf{s}$ はそれぞれ入力、結合荷重、閾値、内部ポテンシャルを表し、 $\mathbf{x}, \mathbf{w}, \theta, \mathbf{s} \in \mathbf{I}, \mathbf{w} \in \mathbf{K}^4$ である。また、活性化関数 $h \cdot$ は実非線形関数であり、各虚数成分ごとに split 型で適用する。本研究では活性化関数として ReLU 関数を用いる。

2.3 四元数畳み込みニューロンモデル

本研究では前節の四元数ニューロンモデルを基に畳み込みの要素を追加したニューロンモデルを導入する。このニューロンモデルにおいても前節と同様に入出力データはすべて純虚四元数である。

四元数畳み込みニューロンユニットの出力 \mathbf{y}_{ijk} は

$$\mathbf{s}_{ijk} = \sum_{s=1}^m \sum_{t=1}^m \frac{\mathbf{w}_{stk} \mathbf{x}_{i+s, j+t} \mathbf{w}_{stk}^*}{|\mathbf{w}_{stk}|} \theta_k \quad (11)$$

$$\mathbf{y}_{ijk} = h(s_{ijk}^{(i)}) \mathbf{i} + h(s_{ijk}^{(j)}) \mathbf{j} + h(s_{ijk}^{(k)}) \mathbf{k} \quad (12)$$

で表される。ここで m はカーネルサイズ、 $\mathbf{x}, \mathbf{w}, \theta, \mathbf{s}$ はそれぞれ入力、結合荷重、閾値、内部ポテンシャルを表し、 $\mathbf{x}, \mathbf{w}, \theta, \mathbf{s} \in \mathbf{I}, \mathbf{w} \in \mathbf{K}^4$ である。また、活性化関数 $h \cdot$ は実非線形関数であり、各虚数成分ごとに split 型で適用する。本研究では活性化関数として ReLU 関数を用いる。

プーリングは活性化関数同様に各虚数成分ごとに適用し、最大プーリングを用いる。

2.4 四元数バッチ正規化

バッチ正規化⁶⁾は各ニューロンユニットの出力をミニバッチごとに正規化を行うことで内部共変量シフトが大きく変わることを防ぐため学習を安定させることができ、層が深い構造において学習を早めることができる。

バッチ正規化は以下の式で定義されている。

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (13)$$

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (14)$$

$$\text{BN } x_i = \frac{x_i - \mu}{\sqrt{\sigma^2 + \epsilon}} \quad (1)$$

$$y_i = \gamma \text{BN } x_i + \beta \quad (1)$$

ここで、 x, N はそれぞれ入力、バッチサイズを表し、 γ, β は学習可能なパラメータである。

四元数においても層を深くした場合に学習を早めるためにバッチ正規化を定義する必要がある。そこで四元数によるバッチ正規化は以下のように定義する。

$$\mathbf{y} = \text{BN } x^{(i)} \mathbf{i} + \text{BN } x^{(j)} \mathbf{j} + \text{BN } x^{(k)} \mathbf{k} \quad (1)$$

$$\mathbf{z} = \frac{\gamma \mathbf{y} \gamma^*}{|\gamma|} + \beta \quad (1)$$

ここで、 γ, β は学習可能なパラメータであり、 $\beta \in \mathbf{I}, \gamma \in \mathbf{K}^4$ である。バッチ正規化は活性化関数やプーリング同様に split 型を使用し、その後のスケールリングについては四元数を用いて行う。

Table 1. Performances and complexities for NN and NN using AR1 dataset.

Model	Accuracy %	Cross Entropy	params
NN	0.2	1.2	1,222
NN	0.4	0.1	1,432




Fig. 3. Residual Block.

3 実験

最初に単純な構造において NN の性能を検証する。実験には AR1 データセットを使用する。

AR1 は 32×32 画素のカラー画像であり, airplane, automobile, bird, cat, deer, dog, frog, horse, ship, truck の 10 クラスにラベル付けされている。また訓練データは 100 枚, テストデータは 10 枚で構成されている。ネットワーク構成は, 畳み込み層とプーリング層 2 層ずつで構成し, 平坦化を行った後, 全結合層 2 層で分類を行う。最適化法には Adam を使用し, ミニバッチサイズは 12 とした。また, 訓練データに対して上下左右シフト 2%, 左右反転, 回転 ± 2 度の変換を行ってデータの増強を行った。以上の条件で実験を行った結果を Fig. 2 および Table 1 に示す。

NN は NN と比較すると, Accuracy が 1.1% 高く, Cross Entropy は 0.2 低い結果が得られた。

次に, ResNet34⁷⁾ を構成し NN の性能を検証する。ResNet は層の深いモデルにおいて勾配消失により精度が向上しない問題に対して, Residual Block と呼ばれる shortcut connection を有した構造を取ることによって解決したモデルである。実験で使用する Residual Block は Fig. 3 を用いる。実験で使用する ResNet34 の構成を Table 2 に示す。Table 2 に示す角括弧は Residual Block を表し, con 2~ は Residual Block を複数個含んでいる。また, con 3~ の最初の畳み込みにおいてストライドを 2 にすることでダウンサンプリングを行い, Global Average Pooling により平坦化を行った後, 10% の Dropout を行い, 全結合層において分類を行う。

まず, データセットとして AR1 を用いて実験を行う。最適化法には Adam を使用し, ミニバッチサイズを 12, 学習係数は 1 epoch と 22 epoch で 0.1 倍に設定した。また, 訓練データに対して上下左右シフト 2%, 左右反転, 回転 ± 2 度の変換を行ってデータの増強を行った。以上の条件で実験を行った結果を Fig. 4 および Table 3 に示す。NN は NN と比較すると, Accuracy が 0.4% 高く, Cross Entropy は 0.4 低い結果が得られた。

次に, データセットとして AR1 を用いて実験を行う。AR1 は AR1 同様に 32×32 画素のカラー画像であり, 10 クラスにラベル付けがされている。また訓練データは 100 枚, テストデータは 10 枚で構成されている。最適化法には Adam を使用

Table 2. Network architectures for ResNet34 based on NN and NN. Building blocks are shown in brackets with the number of blocks stacked.

layer name	optimal size	NN	NN
con 1	32×32	$3 \times 3, 1$	$3 \times 3, 32$
con 2	32×32	$\begin{bmatrix} 3 \times 3, 1 \\ 3 \times 3, 1 \end{bmatrix} \times 3$	$\begin{bmatrix} 3 \times 3, 32 \\ 3 \times 3, 32 \end{bmatrix} \times 3$
con 3	1×1	$\begin{bmatrix} 3 \times 3, 32 \\ 3 \times 3, 32 \end{bmatrix} \times 4$	$\begin{bmatrix} 3 \times 3, 4 \\ 3 \times 3, 4 \end{bmatrix} \times 4$
con 4	\times	$\begin{bmatrix} 3 \times 3, 4 \\ 3 \times 3, 4 \end{bmatrix} \times$	$\begin{bmatrix} 3 \times 3, 12 \\ 3 \times 3, 12 \end{bmatrix} \times$
con 5	4×4	$\begin{bmatrix} 3 \times 3, 12 \\ 3 \times 3, 12 \end{bmatrix} \times 3$	$\begin{bmatrix} 3 \times 3, 2 \\ 3 \times 3, 2 \end{bmatrix} \times 3$
flatten	1×1	global average pooling	dropout
fully connected	1000	softmax	

し, ミニバッチサイズを 12, 学習係数は 1 epoch と 22 epoch で 0.1 倍に設定した。また, AR1 同様に訓練データに対して上下左右シフト 2%, 左右反転, 回転 ± 2 度の変換を行ってデータの増強を行った。以上の条件で実験を行った結果を Fig. 5 および Table 3 に示す。NN は NN と比較すると, Accuracy が 2.3% 高く, Cross Entropy は 0.1 低い結果が得られた。

4 まとめ

本研究では, NN のパラメータを四元数に拡張したモデルである NN を提案し, その性能評価を単純な構造と ResNet34 を用いて行った。いずれの構造においても NN は NN よりも良い精度が得られたことから, カラー画像に対する識別問題のタスクにおいて NN は効果的であることが確認できた。今後の課題としては カラー画像の識別問題以外のタスクでの比較や四元数に相当する活性化関数の検討などが挙げられる。

参考文献

1. Alex Krizhevsky, Ilya Sutskever and Geoffrey Hinton. ImageNet classification with deep convolutional neural networks. Advances in neural information processing systems 1, 11-20, 2012.
2. Jeff Dean. Gradient-based learning applied to document recognition. Proceedings of the 2001 IEEE Conference on Document Analysis and Recognition, 7-11, 2001.
3. Alex Krizhevsky, Ilya Sutskever, and Geoffrey Hinton. ImageNet Classification with Deep Convolutional Neural Networks. Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition, 1-9, 2012.
4. Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770-778, 2016.
5. Yoshitaka Ueda, Takashi Yamashita, and Masahito Sasaki. Quaternion-based deep learning for image recognition. Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition, 1-9, 2018.
6. Ilya Sutskever, James Hensman, and Alex Krizhevsky. Softplus. Proceedings of the 32nd International Conference on Machine Learning, 1-5, 2015.
7. Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770-778, 2016.




Fig. 4. Test accuracies and losses on ResNet34 used on NN and NN single AR(1) dataset.

Table 3. Performances and complexities for ResNet34 used on NN and NN single AR(1) dataset.

Model	Accuracy %	Cross Entropy	params
NN	4.1	0.24	332,314
NN	3.2	0.331	32,42




Fig. 5. Test accuracies and losses on ResNet34 used on NN and NN single AR(1) dataset.

Table 4. Performances and complexities for ResNet34 used on NN and NN single AR(1) dataset.

Model	Accuracy %	Cross Entropy	params
NN	1.	1.4	3,4
NN	0.4	1.22	34,2

住宅内温熱環境が呼吸機能・脳機能に与える影響の解析

○渡邊秀斗 満倉靖恵 (慶應義塾大学)

Analysis of Respiratory and Brain Function under the Indoor Thermal Environment

* Hideto Watanabe, Yasue Mitsukura (Keio University)

Abstract— Dementia is broadly divided into Alzheimer type dementia and vascular type dementia, and it has been pointed out that both are related to cerebral arteriosclerosis as a risk factor. Hypertension is cited as a risk factor for arteriosclerosis, and daily measures against hypertension are required. Since blood pressure is influenced by the thermal environment in the house in winter, it is already known that the thermal environment in the house affects brain function. On the other hand, exposure to cold is known to affect respiratory function. Chronic obstructive pulmonary disease (COPD), one of the respiratory diseases, is associated with not only respiratory dysfunction but also cognitive decline. However, the relationship between the influence on respiratory function and brain function by living in a cold house and the influence on brain function by respiratory function decline has not been clarified. In previous studies, we have investigated the effects of thermal environment in the house on respiratory function and brain function, and the effects of reduced respiratory function on brain function. The purpose of this study is to clarify the causal relationship between the thermal environment in the house, respiratory function and brain function, and to consider the effects of other factors such as age. Achieving this objective will lead to a proposal for a thermal environment in the house that prevents the deterioration of brain and respiratory functions.

Key Words: EEG, MRI, Indoor thermal environment, Respiratory function

1 はじめに

近年、日本では高齢化が進展しており、2040年には5人に1人が65歳以上の高齢者であると予想されている。高齢化に伴い認知症が社会問題化していることも指摘されている。認知症高齢者の数は2012年には462万人、65歳以上高齢者の約7人に1人と推計されており、2025年には約700万人、65歳以上高齢者の約5人に1人が罹患していると見込まれている[1]。認知症はアルツハイマー型認知症と血管性型認知症の2つに大別され、ともに危険因子として脳の動脈硬化が関係していることが指摘されている[2]。動脈硬化の危険因子としては高血圧が挙げられており、日常的な高血圧対策が必要とされている。血圧は冬季の住宅内温熱環境が影響していることから、住宅内温熱環境が脳機能に影響していることが既に分かっている[3]。一方、寒冷暴露は呼吸機能に影響があることが知られている。呼吸器疾患の一つである慢性閉塞性肺疾患(COPD: Chronic Obstructive Pulmonary Disease)は呼吸機能障害だけではなく認知機能低下にも関係がある[4]。しかしながら、寒冷な住宅に住むことによる呼吸機能・脳機能への影響と呼吸機能低下による脳機能への影響の関係について明らかになっていない。これまでの研究では、住宅内温熱環境が呼吸機能・脳機能それぞれに与える影響と、呼吸機能低下が脳機能に与える影響についての調査を進めてきた。本研究では、住宅内温熱環境、呼吸機能及び脳機能のそれぞれの因果関係について明らかにし、年齢などの他因子の影響についても考慮することを目的とする。この目的を達成する事で、脳機能及び呼吸機能の低下を防止する住宅内温熱環境の提案につながると考えている。

認知症のなかでも最も一般的なアルツハイマー病では、健常者と比較して脳の萎縮が確認されている。中でも視床及び大脳基底核の灰白質密度との違いが α 波と θ 波/ γ 波の増加に関係があると報告されている[5]。一方で、これまでの脳機能の調査では、大規模なMRI測定は人的、金銭的及び時間的コストがかかるために実施が困難であった。そこでMRI測定に比べて、簡便で安価な測定方法

Table.1 梶原の実測調査の概要

対象地		高知県梶原町		山口県長門市
実施期間	1年目調査	2016年 10月	2017年 10月	2018年 2月
	追跡調査	2018年 9月	2019年 10月	2020年 (予定)
対象者		59名	31名	60名
調査項目		アンケート 住環境、個人属性、生活習慣 (期間中1回) 実測調査 温湿度、血圧、活動量、測定日誌 (15日間) 脳ドック MRI検査、検診(期間中1回) 身体測定 脳波、歩行課題、呼吸機能 (期間中1回)		

によって脳機能を推定することが求められている。脳波測定は近年、単極のみを使用した簡易脳波計が主流となって用いられており、安価に測定することが可能となっている。そこで本研究ではシングルチャンネルの脳波計を用いて、脳全体の灰白質量の推定が可能であるかについての検討も行った。この推定方法が確立されることで、簡易的に脳機能の推定が可能となり、今後の住環境と脳機能の関係性の研究のデータ収集に利用できる。

2 調査概要

本研究では、アンケート、実測調査、脳ドック及び身体測定に分けて行った。アンケート調査と身体測定は各被験者に応じて複数日程を提示し、1日にて実施した。また実測調査はTable.1に示した期間内の2週間にて実施した。最後に脳ドックは実測調査の期間にて被験者ごとに実施された。

2.1 対象地

調査の対象地は高知県高岡郡梶原町と山口県長門市が選ばれた。梶原町が選ばれた理由は以下の2点理由である。1)2010年に梶原町は高齢人口率が39%の地域であり、日本がこれから迎える超高齢社会のモデルと考えられること、2)行政が健康政策に積極的であり、アンケートや検査機器の配布回収が行いやすいことである。行政が主体となり地域活性化に向けた取り組みを多く実施しており、2009年環境モデル都市に指定されている。一方で、長門市は日本海側に面した都市であり、山間部の梶原町との比較に有用であると考え採用した。

2.2 調査期間

梶原町の2016年10月に59名と2017年9月に31名を対象として合計90名の横断的調査を行った。追跡調査は1年目調査を終えた90名を対象としており、その2年後の59名に対しては2018年9月、31名に対しては2019年9月に行われた。長門市の調査は1年目調査が2017年2月に行われ、2年後調査は来年中に予定されている。

2.3 対象者

調査の対象者は梶原町在住の男女90名と、長門市在住の男女60名の合計150名を対象としている。これらの対象者は事前に調査の同意書に同意している。

2.4 調査項目

調査項目として、アンケート調査では住環境、個人属性及び生活習慣に関する質問を行った。住環境のアンケートでは、窓サッシの種類・窓ガラスの枚数・居住年数・暖房機器の使用状況の質問、及びCASBEEすまいの健康チェックリストを実施した[6]。個人属性のアンケートでは、年齢・性別・BMI(Body Mass Index)・個人年収・既往歴の質問を実施した。生活習慣のアンケートでは、飲酒頻度・喫煙頻度・食習慣・運動習慣・睡眠習慣及び社会活動の参加状況についての質問を実施した。

実測調査として、住宅の室温を居間と寝室の床上1.1mと床上0.1m、脱衣所の計5項目に関して10分ごとに取得した。また湿度は居間の床上1.1mの場所で測定した。使用した機器はTR-72wf, TR-72Ui, TR51i(T&D社)を使用した。血圧は15日間毎日、起床後と就寝前の2回測定した。機器はHEM-7080IT(OMRON社)を使用した。活動量は歩数、活動強度、EX量、消費カロリー、装着時間の側手を目的として15日間計測された。使用した機器はActive Style Pro HJA-750C(OMRON社)である。測定日誌を毎日記入しその日の外出時間や睡眠時間についての把握も行った。脳ドック検査として、3TのMRI機器を使用して計測した。構造MRI画像の取得には高速3次元T1強調法の1種であるMPRAGE(Magnetization Prepared Rapid Acquisition with Gradient Echo)法が用いられ、T1強調画像を取得した。また検査の際に医師による検診を行った。身体測定として、脳波計測、認知タスク評価、歩行課題計測、呼吸機能計測を実施した。脳波計測は100秒間の安静閉眼状態にて計測し、計測機器にはMindWave Mobileを使用し、サンプリング周波数512Hzであった。電極は左前頭前野部位の国際10-20法におけるFp1のみから取得した。認知タスク評価にはMMSE(Mini-Mental State Examination)を使用した。MMSEは認知症の診断に使われる30点満点のテストであり、23点以下では認知症の疑いがあり、18点以下にて軽度認知障害の疑いがある[7]。歩行課題計測では、二重課題



Fig.1 温湿度計



Fig.2 活動量計



Fig.3 血圧計



Fig.4 MindWave MobileII




Fig.5 国際 10-20 法




Fig.6 二重課題歩行



Fig.7 MRI 計測機器

歩行を行った。二重課題歩行とは、歩行する間に複数読み上げられる数字を逆順に復唱するという課題である。歩行能力が低下している高齢者は自身の歩行への注意量が減少するため歩行速度が遅くなることが知られている[8]。呼吸機能計測は2年後調査から実施され、スパイロメータを用いて努力性肺活量を計測した。計測手順としては、鼻をクリップなどでつまみ空気が漏れないようにした後に、スパイロメータのマウスピースを口にくわえる。続いて最大限に息を吸った後にマウスピースにできるだけ早く、勢いよく息を吐き出す。一人の被験者につき数回計測した後、一番良い結果だったものをその被験者の結果とした。

3 解析手順

MRI 画像から灰白質の(GM: Gray Matter)量の算出を行い、住宅内温熱環境と脳機能及び呼吸機能の関係を分散構造解析の利用によって明らかにした。

3.1 GM 量算出

GM 量は T1 強調画像(T1WI: T1 Weighted Image)から算出される。まず GM 量は VBM(Voxel-Based Morphometry)と呼ばれる脳体積解析手法を用いて算出される。VBM は Matlab の標準的な解析ツールである SPM(Statistical Parametric Mapping)を用いて解析した。SPM のバージョンは 12 である。VBM は大きく前処理の段階と統計処理の段階に分けられる。前処理として、1)分割化、2)標準化、3)平滑化を実施し、統計処理により GM 量を算出した。前処理ではまず各 MPRAGE 画像が事前確率画像に基づいて灰白質、白質(WM: White Matter)、脳脊髄液(CSF)に分割化された。続いて、非線形変換手法の DARTEL(Different Anatomical Registration using Exponentiated Lie Algebra)法によって解剖学的に標準化された。最後に、半値全幅が 8mm のガウシアンフィルタで平滑化された。GM, WM, CSF の体積はボクセル総数にボクセルサイズを掛けたものとして推定した。頭蓋内容積(ICV)は各被験者の GM, WM,

CSF の体積の合計値として算出された。全脳容積の影響を考慮するために、GM の体積に対して全脳容積の比例補正による正規化を実施した。正規化された GM 画像から算出される体積を平均値 100, 標準偏差が 15 になるようにして個人間比較を可能にした。

また長門の 60 名のデータに対して、本論文の後半で脳波の推定に利用するために、ラベル付けを行った。GM 量は年齢と負の相関関係にあるため、GM 量と年齢の散布図に回帰直線を引いたとき、1)回帰直線の信頼区間の上限より上側, 2)回帰直線の信頼区間内, 3)回帰直線の信頼区間の下限より下側の 3 分類を行った。

3.2 1 秒率算出

呼吸機能に関しては、取得した努力性肺初量から 1 秒率を算出した。1 秒率は努力性肺活量のうち最初の 1 秒間に吐き出した空気量の割合のことである。1 秒率は正常値が 70%であり、70%を下回った場合 COPD の可能性が疑われる[9]。

3.3 共分散構造解析

緒言で述べたように住宅内温熱環境は呼吸機能及び脳機能に影響があり、呼吸機能低下は脳機能低下に影響していると考えられるため、住宅内温熱環境、呼吸機能及び脳機能の関係について Fig.8 のような仮説モデルの概念図を考えた。住宅内温熱環境が呼吸機能及び脳機能に影響を与え、呼吸機能低下が脳機能低下に影響を与えるという仮説の関係を明らかにすることを目的として共分散構造解析を実行した。呼吸機能として呼吸器の閉塞性を示す 1 秒率、脳機能として脳の灰白質の量を表す GM-BHQ を使用した。上記の 3 項目以外に、呼吸機能と脳機能に影響を与える個人属性として、年齢及び性別を考慮に入れて分析を行った。モデルの評価には適合度指標として一般的に使用される GFI(Goodness of Fit Index), RMSEA(Root Mean Square Error of Approximation)及びカイ二乗適合度検定 (χ^2 , p 値)を採用した。比較のため全てのパス係数は標準化推定値で示している。

3.4 脳波の前処理と分類

取得した脳波データに対して、脳波以外の成分を除去する目的でバンドパスフィルタをかけた。通過帯域は 1-45Hz とした。また脳波に混入している心電由来のノイズを除去する目的で、アンサンブル経験的モード分解 (EEMD: Ensemble Empirical Mode Decomposition) を使用した。EEMD は入力信号を固有モード関数 (IMF: Intrinsic Mode Function) に分解する EMD の拡張版である [10]。EMD では全範囲で極値の数とゼロの交差点の数が同じ数または 1 個違いとなるように、また各 IMF の平均値がゼロとなるようにしたものである。EEMD ではさらに元信号にホワイトノイズを加えたうえで EMD を複数回実行することで分解の精度を高めた。今回は最大 IMF 数を 7 個とし、EMD の反復回数を 20 回とした。モード間の相関係数の値が高いものが心電由来のノイズであると考えられるため、相互相関をそれぞれで求め相互相関の高かったモードの組み合わせを除去して、脳波を再構成した。最後に再構成した脳波を 5 秒ごとに分割した。




Fig.8 仮説モデルの概念図

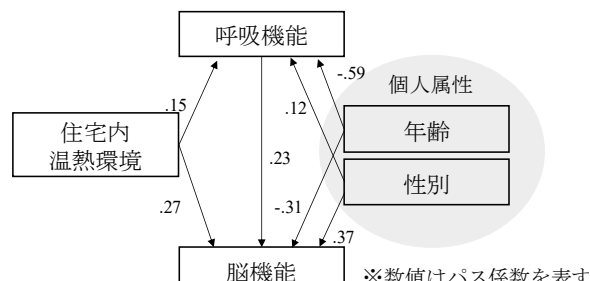


Fig.9 共分散構造解析の結果




Fig.10 特徴量の重要度

3.5 分類と評価

脳波の特徴量を抽出することを目的として、時間領域から標準偏差, 平均絶対偏差, 中央絶対偏差, L1 ノルム, L2 ノルム及び Max ノルムを算出した。また自己回帰モデルを用いて、パラメータの抽出を行った。

$$x_s = \sum_{j=1}^M a_j x_{s-j} + \varepsilon_s$$

最尤推定法によって、パラメータ a を推定する。推定するときに近似を用いるのが、最尤推定法における近似法の一つである Yule-Walker 法である。Yule-Walker 法では以下の Yule-Walker 方程式を解くことで、係数ベクトル $a_1 \sim a_M$ を推定することができる。推定した係数ベクトルの長さ, 最大値, 最小値, 平均, 分散及び歪度を特徴量として抽出した。

また抽出した特徴量に対してランダムフォレストを利用して分類した。ランダムフォレストは複数の決定木を融合させたアンサンブル学習である。決定木とは特徴量をもとに分類する平易な機械学習である。個々の決定木に投入する標本はブートストラップサンプリングを行った。ブートストラップサンプリングは母集団から重複を許してランダムに標本抽出を行う手法である。作成した標本データの数だけ決定木を作成し、バギングと呼ばれる方法ですべての決定木の結果の多数決を取った。分類の際に精度評価として 10 分割公差検証を行った。データを 10 分割し、学習用データとテスト用データに分けた。ランダムフォレストは投入した特徴量の重要度の評価す

ることができる. 特徴量の重要度推定の方法として, Out-of-Bag(OOB)推定が使われる. OOB 推定では, まずブートストラップサンプリングで含まれないサンプルである OOB サンプルを抽出する. OOB サンプルのうちランダムに選んだ特徴量を置換する. 特徴量の置換前後の平均誤分類率の比較を行う. このとき算出された平均誤分類率の増加分が大きいほど重要な特徴であると言える.

4 結果及び考察

共分散構造解析の結果を Fig.9 に示す. 因子間の関係はパス形数によって表されている. パス係数が有意であった住宅内温熱環境は寝室の床上 1.1m 室温であった. $\chi^2=2.026$, $p=.567$ より帰無仮説「構成されたモデルは正しい」が棄却されなかったため, 帰無仮説は正しいことが示唆された. また GFI=0.984 が 0.9 以上であり, RMSEA=0.000 が 0 に近いこと, 提案したモデルは適合していると言える. このことから GM-BHQ, 1 秒率及び寝室 1.1m 室温の関係には仮説モデルの関係があると考えられる. またこのモデルでは年齢及び性別の影響も考慮されている.

また分類に使用された脳波データは学習用データ 1010 件, テスト用データ 113 件に分けられた. ランダムフォレストの分類結果は 67.1%であった. 特徴量の重要度は Fig.10 に示される.

5 結論

本研究では, 住宅内温熱環境, 呼吸機能及び脳機能のそれぞれの因果関係を解明することを目的とした. このために共分散構造解析を用いて, 住宅内温熱環境, 呼吸機能及び脳機能の関係について仮説モデルを設定し検証した. また年齢などの他の因子の影響についても考慮した. その結果, 住宅内温熱環境が脳機能の低下に直接影響していると共に, 呼吸機能の低下を介して脳機能の低下に影響していることが示唆された. 今後はモデルの適合度を高めるとともに, 現段階で未考慮の他因子の影響についても考慮する必要がある. また脳波から脳全体の灰白質量の推定の可能性についても検討した. 分類の結果, 脳波から推定することができる可能性を確認した. 今後特徴量のさらなる検討と, その他分類器の使用の検討を進めていく.

参考文献

- 1) 厚生労働省, “認知症施策推進総合戦略(新オレンジプラン)”, 2015.
- 2) 栗山長門, 渡邊能行, “血管性認知症に関する疫学研究: 京都発の調査研究からの情報発信”, 京府医大誌, Vol.127, No.7, pp.435-449, 2018.
- 3) 松本実紗, “冬季の室温温度差が脳健康指標に及ぼす影響”, 平成 29 年度大会学術講演論文集, Vol.6, pp.221-224.
- 4) Esser Roland W., et al., “Structural Brain Changes in Patients with COPD”, CHEST, Vol.149, No.2, pp.426-434, 2016.
- 5) E.Canu, et, al., ”Microstructural Diffusion Changes are independent of macrostructural volume loss in moderate to severe Alzheimer’s Disease”, J.Alzheimer’s Dis, Vol.19, No.3, pp.963-976, 2010.
- 6) 一般社団法人日本サステナブル建築協会, “CASBEE コミュニティの健康チェックリスト” 2011.

- 7) 小海宏之, 前田明子, 山本愛, 加藤佑佳, 岡村香織, 園田薫, 安藤悦子, 岸川雄介, “日本語版 MMSE の検出力と特異性について”, Vol.18, pp91-96, 2008.
- 8) 山田実, “高齢者における二重課題条件下の歩行能力には注意機能が関連している”, 理学療法科学, Vol.23, No.3, pp.435-439, 2008.
- 9) 日本呼吸器学会 COPD ガイドライン第 2 版作成委員会, “COPD (慢性閉塞性肺疾患) 診断と治療のためのガイドライン第 2 版”, メディカルレビュー社, 2004.
- 10) Ahnaf Rashik Hassan, Mohammed Imamul Hassan Bhuiyan, “Automated Identification of Sleep States from EEG Signals by Means of Ensemble Empirical Mode Decomposition and Random under Sampling Boosting”, Computer Methods and Programs in Biomedicine, Vol.140, pp.201-210.

心弾道図を用いた外乱に頑健な心拍推定手法

○中井川隼也 満倉靖恵 (慶應義塾大学)

Heart Rate Estimation Method Robust to Disturbance by Measuring BCG

* Toshiya Nakaigawa and Yasue Mitsukura (Keio University)

Abstract — In this paper, we construct a system that can estimate heart rate easily and non-contact by measuring ballistocardiogram (BCG) acquired from chair leg sensors. Heart disease is a problem worldwide as the top cause of death. Heart disease patients have heartbeat abnormalities, so it is effective to detect the symptoms early by monitoring heartbeats. In recent years, BCG has been attracting attention because it can acquire heartbeats contactless by using sensors attached to a chair. However, it is difficult to estimate the heart rate depending on the posture because the sensor is attached to the backrest in existing method. In this study, we propose a heart rate estimation algorithm using Shannon entropy and a system to acquire BCG by chair leg sensors. As a result, it is confirmed that the heart rate can be obtained by the proposed system, and heart rate estimation is performed with high accuracy compared to the method without Shannon entropy.

Key Words: ballistocardiogram (BCG), cardiac signal analysis, biomedical measurements.

1 はじめに

本論文では、電極等を取り付けることなく、非接触で簡便に心拍情報を取得可能なシステムを構築することを目的とする。

近年、心疾患は世界で死亡要因第1位であり、日本においても悪性新生物に次いで2番目に多い死亡要因となっている¹⁾。また、心疾患により心肺停止した後蘇生した場合でも、その1か月後の生存率は13.3%と低い²⁾。このため、心疾患の兆候を発見し未然に防ぐことが重要である。心疾患による死亡率の内訳を確認すると、自宅での死亡率が67%となっており、睡眠中や食事中における死亡率が特に高くなっている³⁾。そのため、自宅における日常的なモニタリングが重要だと考えられる。

心臓は体内において血液を体中に送り出すポンプの役割を果たしており、その運動を心拍と呼ぶ。心拍は運動や食事等の物理的な要因とストレス等による精神的な要因により常時変化する自律神経の影響を受ける。自律神経は交感神経と副交感神経の相反する二つの神経により制御され、これらの均衡度合いにより変動する。一般的に加齢に伴い心拍数は減少するが、これは2つの神経のバランスが交感神経優位に傾くためと考えられており、心疾患と関連しているとされている。実際65歳以上の高齢者における心疾患による死亡率は全体の83%を占めており、自律神経を反映する心拍をモニタリングすることは心疾患の予防において有効である⁴⁾。

心拍を測定する手法としては、心電図や光電式容積脈波記録法、心弾道図などがあげられる。一つ目の心電図 (ECG : Electrocardiogram) は心臓が拍動する際に発生する電気信号を取得する手法である⁵⁾。この手法では、安定して心拍を測定することが可能なため、病院でも用いられている最も一般的な手法となっている。その一方で、電極を張り付ける必要があるため、装着によるストレスや日常的な計測に向かない等の問題点があげられる。二つ目の光電式容積脈波記録

法 (PPG : Photoplethysmography) は血管に対し赤外光を照射した際に反射した光を見ることで、血管内の血流量を測定する手法である⁶⁾。この手法では指や腕等体の様々な部位で測定ができるため、腕時計型のもの等装着型の小型ウェアラブルデバイスを体に取り付けることで心拍を測定することが可能である。これにより、通勤や通学等を含む日中に心拍を測定するうえで有効である。そのため、近年ウェアラブルデバイスが注目を集めている。その一方で、バッテリーを電力源としているため、使用時間に限りがあるほか、血流量を測定しているため、心拍の周期以外の情報を得ることが困難である。しかし、心拍は心疾患等によりその波形に異常が生じた場合、変化した波形の部位から心筋のどの位置に異常が生じたかを判断することができるため、周期以外の情報も重要となっている。三つ目の心弾道図 (BCG : Ballistocardiogram) はベッドや椅子に取り付けたセンサを用いて心臓が拍動した際に押し出した血液の反作用から心拍を測定する手法である⁷⁾。この手法では、計測機器を体に取り付ける必要がないため、ほかの手法と比較し簡便に心拍情報を取得することが可能である。また、血液の拍出量や呼吸等ほかの手法と比較しより多くの特徴量をモニタリングすることが可能である。その一方で、体に直接機器を取り付けておらず、体動によるアーチファクトや姿勢により得られる波形が変わるため、解析が困難である。

上記で述べたように、睡眠中や食事中等自宅での日常的なモニタリングが心疾患の早期発見において有効である。BCGは椅子に取り付けたセンサにより非接触で簡便に心拍測定を行えるため、上記三つの手法の中で最も有効であると考えられる。既存手法では椅子の背板にシート型のセンサを取り付け、背中からBCG信号を取得するシステムが提案されている⁸⁾。しかし、この手法ではシートに背中が密着している必要があるため、姿勢によっては心拍を測定することが困難である。そこで、本研究では、上記課題を解決可能なBCG測定システムを提案する。2章では、作成した計測システムについて述べ、3章では実験について述べる。

また、4章では解析手法、5章では評価方法について述べる。6章では結果および考察について述べ、7章では本論文をまとめる。

2 計測システム

本研究ではロードセルを作成し、BCG信号の計測を行った。ロードセルは荷重負荷位置に加えられた力を、ひずみ→抵抗値→電圧と変換して計測するセンサである⁹⁾。本研究では、心臓の拍動により生じた反作用による力を、ロードセルを用いて電圧として測定し、BCG信号を取得した。センサの内部にはひずみゲージ4つを用いたホイートストンブリッジ回路が組み込まれている。この回路では、荷重負荷位置に加わった力に応じてひずみゲージ内の抵抗線が伸縮し、出力電圧が変化する。このセンサを椅子の脚部4本の下に敷くことで、その上に着席している被験者の心拍計測を試みる。センサおよび計測システムの全体図を図1に示す。

3 実験

本研究で作成したセンサおよび解析手法の評価を目的としてBCG計測実験を行った。被験者は男性9名、女性4名の計13名の健康者を対象とした。また、今回の評価ではそもそも今回作成した計測システムにてBCG信号が計測できるか確認するために、安静状態にて計測を行った。計測時間は10分とし、1被験者あたり1~2回の計測を行った。実験の際は椅子取り付け型センサによるBCG計測と並行して、Alice PDx (フィリップス・レスピロニクス合同会社製)を用いてECGの計測も同時に行った。計測したECGはBCGに対する正解データとし、それぞれから推定した心拍間隔の誤差を用いて作成したセンサおよび解析手法の評価を行った。ECGおよびBCGのサンプリング周波数はそれぞれ200Hzとした。また、椅子取り付け型センサの出力はPCD-400A (共和電業製)により取得した。

4 解析

BCGやECGの波形には、心臓の拍動に応じた周期信号が現れる。この周期信号にはピークが存在し、BCG, ECGそれぞれJ波, R波と呼ばれている。本研究ではこれらのピーク位置を抽出し、その間隔を算出することで、心拍間隔の推定を行った。以下ではピーク位置の抽出方法について述べる。

作成したシステムにより取得した信号には、心拍由来の波形の他に呼吸由来の波形や、ロガー由来の高周波ノイズ等が混入する。そのため、これらの成分が合成された信号から心拍由来成分を抽出する必要がある。そこで、バンドパスフィルタを用いてこれらのアーチファクトの除去を行う。バンドパスフィルタは経験的にフィルタ帯域を1-5Hz、10次のバンドパスフィルタとする。図2に示すバンドパスフィルタ後の波形を確認すると、約1秒周期の信号が確認された。また、同時刻のECG信号を確認すると、同じ周期で信号が変




Fig. 1: Measuring system




Fig. 2: Wave after bandpass filter.

動していることが確認できることから、作成した計測システムにより心拍を推定が可能であると考えられる。そこで、本論文では取得したBCG信号から心拍間隔の推定を行う。心拍推定において最も一般的であるECG信号では、心臓付近から電気信号を取得するため、その波形にはR波と呼ばれる鋭いピーク波形がみられる。このため、R波の位置の特定およびその間隔を求めることで心拍間隔の推定を行うことができる。これに対し、今回取得したBCG信号は臀部から伝わる心拍の反作用を取得しており、波形変化が小さいため心電図と同様の手法では解析が困難である。しかし、BCG信号においてもピーク波形が存在する。そのため、取得信号の差分を算出し、その変化量を見ることで、ピーク波形の強調を行う。差分算出後の信号は正負の極性を持つ。そこで、極性の除去およびピーク波形の強調を目的とし、以下の式により情報エントロピーの算出を行う¹⁰⁾。

$$BCG_{entropy} = -|BCG_{dif}[n]| \times \log|BCG_{dif}[n]| \quad (1)$$

情報エントロピーを確認すると、図3に示すように上下に激しく変動していることが確認された。そこで、波形のピーク抽出および3次のスプライン補完により平滑化を行う。その後、安静時の心拍は0.6-1秒のため、最低間隔を0.6秒に設定し、ピーク抽出を行う¹¹⁾。ここで得られた座標はBCG信号における変化量が大きい点であり、実際のピーク位置とは異なる。そのため、ピーク前後のどちらを検出するかによりその後の心拍間隔を算出する際に大きな誤差が生まれてしまう。バンドパスフィルタ後の波形に対し、得られた座標にもっとも近いピークを探索することで、ピーク位置の修正を行う。そして修正後の座標の間隔を算出することで心拍間隔の算出をする。






Fig. 3: Shanonn entropy.



(a) Before peak correction



(b) After peak correction

Fig. 4: Peak correction.

5 評価方法

Alice PDxにより取得した ECG 信号およびバンドパスフィルタとピーク抽出により解析した BCG 信号との比較を行う。ECG 信号については、BCG と同様のバンドパスフィルタを通過させた後、最低間隔を 0.6 秒に設定したピーク抽出を行い、その間隔を算出することで心拍間隔の算出を行った。ECG, BCG とともに得られた心拍間隔に対しスプライン補完およびリサンプリングを行い、1 秒間隔に修正し、差分を算出した。この差分が 0 に近いほど高精度で推定できていると考えられる。本論文ではこの指標を用いて提案システムの評価を行う。

6 結果および考察

椅子の 4 つの脚部から取得した BCG 信号に対しピーク抽出を行った結果を図 5 に示す。図を確認すると、CH2 と CH3 においてはピークを有する周期的な波形が得られていることが確認された一方で、CH1 と CH4 では周期的信号は得られているが、CH2 および CH3 と比較し波形に乱れが生じていることが確認できる。また、CH2, CH3 と CH1, CH4 でピークが生じるタイミングが異なっていることが確認された。それぞれのセ

ンサの位置を確認すると、CH1 と CH4 が前脚、CH2 と CH4 は後ろ脚に置かれたセンサである。また、実験の時被験者は背筋を伸ばして座っており、重心位置が後方に寄っていたことが予測される。以上のことから、座っている人の重心位置に近いほどセンサにより取得される信号は明瞭になると考えられる。また、重心位置から遠いセンサほど信号が伝達されるタイミングが遅くなることが予想される。CH により波形タイミングが異なるのはこれに起因すると考えられる。

図 5 より、CH2 により取得した信号が最も高精度で心拍間隔推定を行えていたため、CH2 の BCG と ECG の差を算出し、手法の評価を行った。結果を図 6 に示す。図を確認すると、ピーク抽出のみの手法と比較し、データのばらつきが小さく、高い精度で心拍間隔を推定できていることが確認された。このことから今回用いた手法の有効性が確認された。また、ECG との誤差が大きい個所は数か所に固まっていることが読み取れる。誤差が大きい個所のバンドパスフィルタ通過後の波形を拡大し、確認すると、波形が乱れ、周期波形が表れていないことが確認された。これは体動により信号が乱れたことに起因すると考えられる。そのため、体動等によるアーチファクトと信号を分離する必要性があると考えられる。




Fig. 5: Peak estimation.




Fig. 6: Peak estimation.

(a) With Shanonn entropy (b) Without shanonn entropy

7 おわりに

本論文では、電極等を取り付けることなく、非接触で簡便に心拍情報を取得可能なシステムを構築することを目的とし、椅子取り付け型センサおよび BCG 信号の解析手法の提案を行った。実験の結果、作成した

計測システムにより心拍が取得可能であることが確認された。また、センサにより波形の乱れ度合いやタイミングが異なることが確認された。解析の結果、ピーク抽出のみを行った手法と比較し、提案した手法では高精度に心拍間隔を推定できていることが確認された。今後は、4つのセンサにより取得した信号を選択または統合し、心拍推定を行うアルゴリズムの構築を目指す。また、自由行動下において追加実験を行い、体動等による外乱に頑健な心拍間隔推定手法の確立を目指す。

参考文献

- 1) World Health Organization, “Global Health Estimates 2016 Deaths by Cause, Age, Sex, by Country and by Region, 2000-2016”, 2018.
- 2) 総務省消防庁, 「平成 29 年版 消防白書」, 2017.
- 3) 日本循環器学会, 「虚血性心疾患の一次予防ガイドライン (2012 年改訂版)」, 2015.
- 4) 厚生労働省, 「患者調査(平成 29 年)」, 2018.
- 5) 井上 博, 「心電図を読み解く」, 文光堂, 1997.
- 6) 藤原幸一, 「ヘルスマonitoringのために心拍変動解析」, システム/制御/情報, Vol. 61, No. 9, pp. 381-386, 2017.
- 7) E. Pinheiro, et al., “Theory and Developments in an Unobtrusive Cardiovascular System Representation: Ballistocardiography”, The Open Biomedical Engineering Journal, Vol.4, pp. 201-216, 2010.
- 8) O. Postolache, “New Device for Assessment of Autonomous Nervous System Functioning in Psychophysiology”, MEMEA 2007: Second - IEEE International Workshop on Medical Measurement and Applications, pp. 99-+, 2007.
- 9) 小川鑛一, 「人と物の動きの計測技術 - ひずみゲージとその応用 - 」, 東京電機大学出版局, 2002.
- 10) Won Kyu Lee, et al, “Physiological Signal Monitoring Bed for Infants Based on Load-Cell Sensors”, Sensors (Basel), Vol.16(3), 409, 2016.
- 11) 田中喜美夫, 「右脳で覚える 12 誘導心電図」, 医学芸術社, 2002.

γ 帯域の脳神経活動を増大させる聴覚刺激の確立手法の提案

○宮沢遼平 石川智愛 満倉靖恵 安井正人 (慶應義塾大学)

Establishment Method of Auditory Stimuli to Increase Neural Activity in γ Band

* R. Miyazawa and T. Ishikawa and Y. Mitsukura and M. Yasui (Keio University)

Abstract— The cause of Alzheimer's disease is the death of neurons due to the deposition of amyloid β protein in the brain. In previous studies, it was confirmed that the power of γ band (20-50Hz) decreased in the neural activity of Alzheimer model mice. In addition, when γ band (40 Hz) auditory stimulation is performed on Alzheimer model mice, the power spectrum of the neural activity γ band increases and amyloid β decreases. However, the investigation is conducted with only one sound fixed, and details of the sound are not considered. Therefore, it is necessary to investigate what kind of sound increases the neural activity in the γ band. So, in this study, we aim to discover auditory stimuli that increase neural activity in the γ -band, and measure neural activity when performing various γ -band auditory stimuli with varying pitch and length. As a result, it was confirmed that the power spectral density was high when the sound length was short.

Key Words: Neural activity, Auditory stimuli

1 はじめに

本研究では、 γ 帯域の脳神経活動を増大させる聴覚刺激を発見することを目的とする。

アルツハイマー病は認知症の中で最も患者数が多いが、未だ根本的な原因は解明されていない^{1,2)}。このため、近年アルツハイマー病の発生機序に関する研究が盛んに行われている。現在、アルツハイマー病患者における脳内の異常な物質的变化として、アミロイド β 蛋白質の脳内沈着による神経細胞の死滅により脳機能が低下することが注目されている^{3,4,5)}。先行研究では、アルツハイマーモデルマウスの脳神経活動において γ 帯域 (20-50Hz)のパワーが減少することが確認された^{6,7,8)}。この結果を踏まえ、アルツハイマーモデルマウスに対して γ 帯域の聴覚刺激を行った際、脳神経活動の γ 帯域のパワースペクトルが増大し、アミロイド β が減少することが報告されている⁹⁾。しかし、減少の仕組みは未解明であり、また音の詳細である音の高さおよび音の長さについては考慮されていない。したがって、如何なる音が γ 帯域の脳神経活動を増大させるかを調査する必要がある。そこで、本研究では γ 帯域の脳神経活動を増大させる聴覚刺激を発見することを目的とし、音の高さおよび音の長さを変化させた様々な γ 帯域の聴覚刺激を行う際の脳神経活動を計測した。

2 実験

2.1 音の製作

本研究では、まず聴覚刺激を行うための音の製作を行った。全ての音は、先行研究と同様に音の on/off が1秒間に40回切り替わる刺激周波数40Hzの音である⁹⁾。40Hzは γ 帯域であるため、すべて γ 帯域の刺激音となる。また、すべての音の波形はsin波形である。

本研究では、音の高さと音の長さを変化させた216種類の音を製作した。音の高さ(周波数)は、マウスの可聴領域が1kHzから100kHzであることから10k, 20k, ..., 90kHzの9種類で変化させた¹⁰⁾。また、音の長さは音の on と off の長さの合計値が25ms(=1/40s)であることから1m, 2m, ..., 24msの24種類で変化させた。

したがって、音の高さを9種類、音の長さを24種類変化させた 9×24 つまり216種類の音を製作した。これらの音の製作はAudacityというフリーのオーディオ編集ソフトを用いて行った。例として音の長さが2msの時の音の on/off の様子を Fig. 1 に示す。

2.2 電極取り付け手術

次に、脳神経活動計測のための電極を取り付ける手術を行った。本研究では、遺伝子組み換えを行っておらず、野生の集団に普遍的にみられる野生型 (Wild Type) のマウス (C57BL/6J) 8匹に対して手術を行った。また、電極取り付け手術はマウスの週齢が10~12週齢である時に行った。脳神経活動の計測部位は大脳皮質の聴覚野とし、マウスの頭蓋骨におけるブレグマ(骨と骨のつなぎ目である縫合線の交差点の一つ)から右に4mm、後ろに2.5mmの部分の頭蓋骨を歯科用ドリルで削った後、セメントを用いて電極を取り付けた(Fig. 2)。電極はメスのヘッダーピン(2.54mm間隔, 1 \times 40ピン)を用いた。この電極取り付け手術は、三種混合麻酔薬(ドミツール:0.75mg/kg, ミダゾラム「サンド」:4mg/kg, ベトルファール:5mg/kg)を用いて麻酔下で行った。

2.3 脳活動計測

次に、製作した音をマウスに刺激した際の聴覚野の脳神経活動(局所フィールド電位)を計測した。本計測は自由行動下とし、マウスの週齢が11~16週齢である時に行った。計測は Fig. 3 に示す暗所において行った。実際の計測の様子を Fig. 4 に示す。

実験は、計216種類の音をそれぞれ1回ずつ刺激する実験を1セットとし、4セット行った。1セットにおける216種類の刺激の刺激順序はランダムとした。音の刺激時間を1種類の音で1分間、前の刺激の影響をなくすために刺激と刺激の間隔を4分間とした。そのため、5分間ごとにマウスに対して音を刺激する




Fig. 1: Details of stimulus sound
(Example: sound length 2ms).




Fig. 2: Neural activity measurement site.



Fig. 3: Experiment environment.




Fig. 4: State of measurement.




Fig. 5: How to separate stimuli.




Fig. 6: Stimuli sequence in 120 minutes.

ことになるが、マウスへの負担を考慮し1回の測定では120分間で24種類の音を刺激した。したがって、120分間の計測を9回行うことにより1セット216種類の音を刺激できる(Fig. 5)。Fig. 6に120分間における刺激の順序を示す。

計測におけるサンプリング周波数は128Hzとした。また、差動増幅器はA-M SYSTEMS社のMODEL 1700 DIFERENTIAL AC AMPLIFIER, ADコンバータはNATIONAL INSTRUMENTS社のcDAQ-9171およびNI-9215を使用して計測を行った。

3 解析

得られた脳神経活動のデータの内、各音刺激において、音刺激なしと音刺激ありの各区間において1分間ずつを抽出した。Fig. 7に図を示す。この際、直前に行った刺激の影響を最小限とするため、刺激なしの4分間のうちの最後の1分間を抽出した。本研究では手入力により音刺激をマウスに与えていることから多少のズレが生じていると考えられるため、抽出した1分間のうち前後2.5秒を除いた55秒間を解析対象とした。

次に、それぞれの解析対象区間の脳神経活動データに対し、まず40Hz前後である20-60Hzを抽出するバンドパスフィルタと交流周波数成分50Hzを除去するノッチフィルタを使用した。ともにMATLABを用いて位相の歪みがないFIR (Finite Impulse Response)フィルタを設計した。その後、ノイズ混入などにより振幅値が通常の約5倍である0.1mVより大きい区間は解析対象外とし、高速フーリエ変換を行った。この際、時間幅は10秒、オーバーラップ50%でシフトさせ、窓関数にはハニング窓を用いた。そして、先行研究と同様に40Hzのパワースペクトル密度を(1)式により算出した⁹⁾。

$$PSD(\omega) = \frac{|F(\omega)|^2}{f_s N} \quad (1)$$

(1)式において、 ω は周波数、 $PSD(\omega)$ はパワースペクトル密度、 $F(\omega)$ は高速フーリエ変換で算出した値、 f_s は脳神経活動計測時のサンプリング周波数、 N は信号のサンプリング数である。本研究で行った解析のフローチャートをFig. 8に示す。

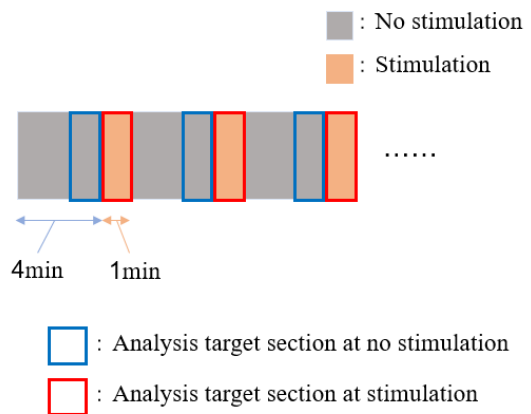


Fig. 7: Analysis target section.




Fig. 8: Flowchart of analysis.

4 結果および考察

はじめに、脳神経活動からパワースペクトル密度を算出した結果の一例を Fig. 9 に示す。この例は音の高さ 30kHz、音の長さ 2ms のときのものである。この結果より、40Hz におけるピークが確認されたことから、 γ 帯域の聴覚刺激により γ 帯域の脳神経活動が増大していると考えられる。

次に、音の高さおよび音の長さを変化させ刺激した際の脳神経活動における 40Hz のパワースペクトル密度を Fig. 10 に示す。また、各音刺激の直前での無刺激時の脳神経活動における 40Hz のパワースペクトル密度を Fig. 11 に示す。Fig. 10 および Fig. 11 より、全体として聴覚刺激時に γ 帯域のパワースペクトル密度が増大していることが確認された。

音の長さに関しては、Fig. 12 のように全体を音の長さが短い区間・中間の区間・長い区間で3分割にすると、短い・長い・中間の順でパワースペクトル密度が高いことが確認された。この結果より、Fig.13 のように音の長さが短い時ほど神経細胞の活動が重ならず、パワースペクトル密度が大きくなると考えられる。ただし、音のない区間に反応するオフ反応により音の長




Fig. 9: Power spectral density (example).




Fig. 10: Power spectral density (Stimulation).

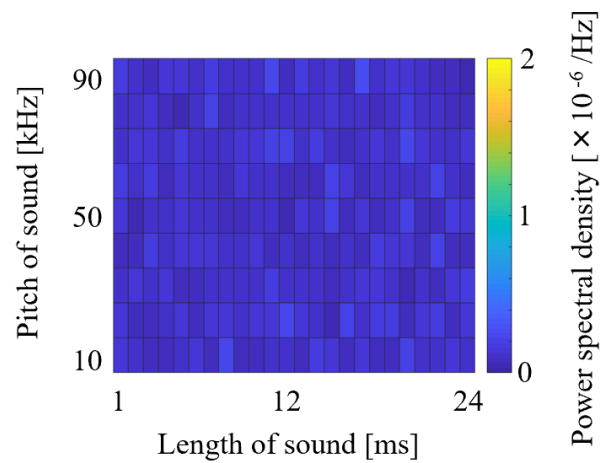


Fig. 11: Power spectral density (No stimulation).




Fig. 12: Three divisions (Stimulation).

さが長い区間は中間の区間よりパワースペクトル密度が大きくなっていると考えられる¹⁾。加えて、先行研究の結果を踏まえると、音の長さが短い聴覚刺激が音の長さが短くない聴覚刺激よりも $A\beta$ を減少させ得ると考えられる⁹⁾。

また、音の高さに関しては、音の長さが中間の区間・




Fig. 13: Schematic diagram of nerve cell activity.

長い区間では音の高さによらずパワースペクトル密度がほぼ一定であることが確認された。しかし、音の長さが短い区間では音の高さが低い時と高い時にパワースペクトル密度が高いことが確認された。これは、可聴領域の中間から遠ざかることにより聴覚野が敏感に反応している可能性が考えられる。

5 おわりに

本研究では γ 帯域の脳神経活動を増大させる聴覚刺激を発見することを目的とし、音の長さが短い聴覚刺激が γ 帯域の脳神経活動をより増大させることを発見した。今後は本研究をさらに検証するため、それぞれの音について複数回脳神経活動を計測することによりデータ数を増加させて統計的に検証を行う。

参考文献

- 1) C. Reitz, et al. : Epidemiology of Alzheimer Disease, *Nature Reviews Neurology*, **7**, 137/152 (2011)
- 2) A. Shepherd, et al. : Transgenic Mouse Models as Tools for Understanding How Increased Cognitive and Physical Stimulation Can Improve Cognition in Alzheimer's Disease, *Brain Plasticity*, **4**-1, 127/150 (2018)
- 3) R. A. Sperling, et al. : Amyloid Deposition Is Associated with Impaired Default Network Function in Older Persons without Dementia, *Neuron*, **63**, 178/188 (2009)
- 4) S. D. Mesquita, et al. : Functional Aspects of Meningeal Lymphatics in Ageing and Alzheimer's Disease, *Nature*, **560**, 185/191 (2018)
- 5) A. W. Bero, et al. : Neuronal activity regulates the regional vulnerability to amyloid- β deposition, *Nature Neuroscience*, **14**, 750/756 (2011)
- 6) H. F. Iaccarino, et al. : Gamma Frequency Entrainment Attenuates Amyloid Load and Modifies Microglia, *Nature*, **540**, 230/235 (2016)
- 7) C. J. Stam, et al. : Generalized Synchronization of MEG Recordings in Alzheimer's Disease: Evidence for Involvement of the Gamma Band, *Journal of Clinical Neurophysiology*, **19**, 562/574 (2002)
- 8) A. K. Gillespie, et al. : Apolipoprotein E4 Causes Age-dependent Disruption of Slow Gamma Oscillations During Hippocampal Sharp-wave Ripples, *Neuron*, **90**, 740/751 (2016)
- 9) A. J. Martorell, et al. : Multi-sensory Gamma Stimulation Ameliorates Alzheimer's-Associated Pathology and Improves Cognition, *Cell*, **177**-2, 256/271 (2019)
- 10) R. P. Reynolds, et al. : Noise in a Laboratory Animal Facility from the Human and Mouse Perspectives", *Journal of the American Association for Laboratory Animal Science*, **49**-5, 592/597 (2010)
- 11) H. Jufang, et al. : OFF Responses in the Auditory Thalamus of the Guinea Pig., *Journal of Neurophysiology*, **88**-5, 2377/2386 (2002)

長時間連続計測による ステロイドホルモン投与マウスの行動意欲推定

○葛西凜々子 満倉靖恵 (慶應義塾大学)

Motivation Estimation of Steroid Hormone-Treated Mouse

by Automated Long-Term Continuous Measurement

* R. Kasai and Y. Mitsukura (Keio University)

Abstract— Steroid hormones are widely used as anti-inflammatory agents, but their side effects are large. It is important to identify appropriate doses and duration since mental disorders as one of side effects of steroid is a problem. We estimated motivation of steroid hormone-treated mouse with the long-term behavior measurement to grasp depression caused by administration of steroid hormone. As a result of our analyzation, rearing motivation of decreased continually after 450-hour administration at 24 ages of the week's mouse and after 540-hour administration at 36 ages of the week's mouse. The ingested amount reached 7.2mg and 8.0mg. Therefore, we suggested that continuous decrease of motivation means depression of mouse.

Key Words: Image processing, Translational research

1 はじめに

本研究は、ステロイドホルモン投与量変化に伴うマウスの逐次的な行動意欲変化の推定を目的とする。ヒトにおいて、ステロイドホルモンは抗炎症薬として臨床的に広く用いられるが、投与に伴う重い副作用の発症が問題である¹⁾。副作用の一つとしてうつ症状が続くステロイド誘発性精神障害があり、1 か月程度の投与患者の約3割に発症が確認された²⁾。これを未然に防ぐ為には、適切な投与量と投与期間を明らかにする必要がある。投与量とその影響に関する既存研究では、トランスレーショナルリサーチとしてマウスにコルチコステロン(マウスにおけるステロイドホルモン)を投与した結果、3 週経過時の行動量の減少から行動意欲低下によるうつ様状態である可能性が示された³⁾。しかし、計測時間が1 週間に1 度、30 分間のみと断続的であり、マウスにおけるうつ様状態の指標とされる行動意欲の逐次的な変化の検証がないため、うつ様状態への真の変化点が不明である。

以上より本研究では、1 か月間の連続計測に基づく時系列行動解析によりマウスの行動意欲変化の推定を目指す。一般に行動意欲は行動解析から算出した行動量と正の相関があるとされるが、行動量の増減は投与のみでなく計測環境等にも依存する。これら他因子を除き投与量変化に伴う行動意欲変化推定の為、観測ノイズを含む観測値から状態ノイズを含む内部の状態変化を推定可能な状態空間モデルを用いる。従って、長時間計測時において発生する計測環境の変化等による行動意欲変化を観測ノイズとし、ステロイドホルモン投与量変化に伴うマウスの行動意欲変化を推定する。これにより、ステロイドホルモン投与量変化に伴ううつ様状態への変化点も明らかになると考える。

2 実験

2.1 実験手順

本研究では1 か月間、コルチコステロン投与マウス2 匹に対しコルチコステロンを飲水投与した(Table.1 参照)。ここで投与量は水 1ml 中 35 μ g であり、既往研

究と同量とした³⁾。他 2 匹にはコルチコステロンを投与せずコントロールマウスとした。なお、コルチコステロンは水に対し難溶性を示すため、溶解を促す作用を持つデキストリンを加えており、条件統一のためコントロールマウスの投与溶液にも加えている(Fig.1 参照)。投与溶液中のデキストリン量は水 1ml につき 450 μ g とした。

マウスはガムテープで遮光したプラスチックケージ内で1 匹ずつ飼育し、深度センサ(Kinect®)を用いて1 か月間投与下で深度計測を行った(Fig.2 参照)。マウスは計測環境に慣れるまで探索行動が多くなるという特徴を持つため、その影響を排除するために7 日間の順応期間を設定した(Fig.1 参照)。

Table. 1: Experimental condition.

マウス数	コントロール	♂2 匹 (24 週齢, 36 週齢)
	コルチコステロン投与	♂2 匹 (24 週齢, 36 週齢)
計測場所	各ケージ内 (18cm×26cm×60cm)	
計測時間	24 時間×35 日間	
計測機器	Xbox One Kinect® (深度センサ)	




Fig. 1: Experimental flow.




Fig. 2: Cage and cage size.

2.2 計測機器及び計測原理

本研究で用いた深度センサ(Kinect®)は ToF(Time of Flight: ToF)方式を用いて、赤外線パルスを照射し、対象物で反射した光が受光素子に入射するまでの時間遅れを求めることで深度を計測している。この計測原理により立ち上がり行動等、上下方向の行動の捕捉が可能となる。ここで、マウスの行動のみに着目するため深度センサはケージの床から 15cm 上までを深度計測範囲に設定しており、約 0.02mm の深度差を捕捉可能である。マウスの体長が 7cm 以下であることを考慮すると十分な精度であると考えられる。

3 解析

一般に断続的な計測においてマウスのうつ様状態時は歩行、走行、リアリング(立ち上がり行動)が減少、不動が増加するとされている為、これらを解析対象の行動とした。まず取得した深度データを輝度値の画像に変換する。ケージの床を 0, 15cm の高さを 255 として輝度値と対応付けた。これにより、マウスの高さ方向の情報をグレースケールとして表示した動画を作成した。その後、輝度値が大きい塊状ピクセルの検出によりマウスの輪郭を求め、輪郭内の輝度値の重心をマウスの重心とした。重心の位置変化をマウスの移動とみなし、位置変化がない場合を不動、速度が 11cm/s 未満を歩行、11cm/s 以上を走行とした。11cm/s はマウスの走行時の平均的な速度である⁴⁾。次に、リアリング行動の算出のためにマウスの脊柱の輝度を求めた。ここでマウスの脊柱は、輪郭に近似した楕円の長軸とした(Fig.3 参照)。マウスの脊柱の輝度はマウスの姿勢により変化する(Fig.4 参照)。例としてリアリング時にはマウスの頭側の脊柱が高くなる為、輝度値は大きくなる。従って、脊柱部分の輝度値が経験的に定めた閾値の条件を満たすものをリアリングとして算出した。また、正確性向上のため、動画の各フレームの画像をハッシュ化し正解のリアリング画像とのハミング距離が 10 以上である場合をリアリングから除外した。




Fig. 3: Mouse spine detection.




Fig. 4: Correspondence of spine height and brightness.

最後に各行動時間を1時間毎に累積し、1時間の行動量とした。そしてその値を正規化し状態空間モデルを用いて行動意欲推定のモデル化を行った。状態空間モデルとは、直接観測が困難な内部の潜在変数を直接観測が可能な観測変数から推定するモデルである。このモデルは、状態ノイズ v_t を含み一つ前の状態 x_{t-1} から一意に決まる状態 x_t の時系列モデル(Eq. (1))と、観測ノイズ w_t を含み状態 x_t から一意に決まる観測値 y_t の生成モデル(Eq. (2))で表される⁵⁾。

$$x_t = f_t(x_{t-1}) + v_t \quad (1)$$

$$y_t = h_t(x_t) + w_t \quad (2)$$

本研究で状態空間モデルを用いる理由は、長時間計測時の環境変化のノイズを除外し、行動意欲のみの変化を明らかにするためである。長時間計測と短時間計測における主な環境の相違点はケージ環境である。短時間計測時は飼育ケージと別のケージに一時的にマウスを移して計測するが、長時間計測時は飼育ケージ内で計測する。以下で長時間特有のケージ環境変化の一例を挙げる。一時的なケージと異なり、飼育ケージには床敷と呼ばれる紙や木素材のチップを敷く必要がある。これは糞尿の飛散防止等、飼育管理の面及び巣を作る習性があるマウスの居住性確保の面から不可欠である⁶⁾。また、衛生面から1週間毎に床敷を変えることが一般的である。しかし、変えた直後と1週間後では、上述の巣作りの習性から床敷の配置が大きく変わっている。このような長時間特有のケージ内の環境変化が行動量に影響を及ぼしている可能性が考えられる。

従って本研究では、観測変数を歩行、走行、リアリング、不動の各行動量とし、潜在変数を行動意欲、状態ノイズをステロイドホルモン投与による行動意欲変化、観測ノイズを計測環境の変化による行動意欲変化とした。検討モデルは最も基本的な状態空間モデルであるローカルレベルモデル、ローカルレベルモデルにトレンド、季節性及びそれらの両方を考慮したモデルの計4つである。季節性とはモデルが持つ周期性のことである。各モデルの妥当性は、赤池情報量規準(AIC)を用いて検証した。AICとは、モデルの複雑さに対するデータの適合度の指標であり、一般的にAICが最小のモデルを使用することが望ましいとされている⁷⁾。

4 実験結果と考察

4.1 各モデルの妥当性

Table. 2-5 に行動量毎に各モデルを適合させた場合の AIC を示す。Table. 2,3 は 24 週齢のコントロールマウスとコルチコステロン投与マウス, Table. 4,5 は 36 週齢のコントロールマウスとコルチコステロン投与マウスにおける結果である。

Table. 2: AIC of each model.
(24 ages of the week, control mouse)

	歩行	走行	リアリング	不動
ローカルレベルモデル	-1267	-2386	-340.6	-459.1
トレンド有	-1254	-2370	-327.4	-446.8
季節性有	-1219	-2311	-313.7	-423.4
トレンド有 季節性有	-1211	-2300	-305.5	-416.0

Table. 3: AIC of each model.
(24 ages of the week, corticosterone-treated mouse)

	歩行	走行	リアリング	不動
ローカルレベルモデル	-598.8	-1387	-1508	-764.7
トレンド有	-589.3	-1371	-1491	-748.4
季節性有	-579.9	-1336	-1465	-742.8
トレンド有 季節性有	-574.6	-1324	-1453	-731.5

Table. 4: AIC of each model.
(36 ages of the week, control mouse)

	歩行	走行	リアリング	不動
ローカルレベルモデル	-342.6	-871.2	-729.3	-325.3
トレンド有	-330.5	-856.6	-713.3	-313.8
季節性有	-290.1	-811.9	-669.7	-271.3
トレンド有 季節性有	-282.9	-802.4	-658.6	-264.8

Table. 5: AIC of each model.
(36 ages of the week, corticosterone-treated mouse)

	歩行	走行	リアリング	不動
ローカルレベルモデル	-362.6	-742.9	-1060	-356.5
トレンド有	-346.4	-729.2	-1043	-343.8
季節性有	-304.3	-690.3	-996.0	-300.2
トレンド有 季節性有	-292.7	-681.5	-984.3	-292.4

Table. 2-5 に示した値より、行動や週齢、コルチコステロン投与・非投与によらずローカルレベルモデルが

最小の AIC となるため、モデルとして最も適合度が高いと考えられる。また、今回の計測時においてはトレンドや季節性がないことが確認された。

4.2 行動意欲変化


4.1 節で全ての行動量のモデル化においてローカルレベルモデルが適切であることが確認されたため、4.2 節ではローカルレベルモデルによる行動意欲推定結果のみを示す。Fig.5(a)-(d)が 24 週齢マウスの結果、Fig.6(a)-(d)が 36 週齢マウスの結果である。x 軸に投与開始後の 1 時間毎の経過時間、y 軸に各行動時間(黒線)とそれに基づき推定した行動意欲の変化(赤線)を示す。

まず、24 週齢のコントロールマウスにおいては、歩行時とリアリング時の行動意欲はほぼ変化せず一定であった。また走行及び不動時の行動意欲は、およそ 24 時間を 1 周期として周期的に変化した。一方、24 週齢のコルチコステロン投与マウスにおいて、歩行時の行動意欲は一定であった。走行時の行動意欲は、投与開始後 100-145 時間(累積投与量 1.5-2.0mg)、250-300 時間(累積投与量 3.7-4.3mg)、410 時間(累積投与量 6.3mg)において一時的な低下が確認された。リアリング時の行動意欲は、投与開始後 190 時間(累積投与量 2.5mg)、280-350 時間(累積投与量 4.2-4.9mg)に一時的な低下が、450 時間(累積投与量 7.2mg)以降計測終了まで低下状態の持続が確認された。不動時においては周期的な変化及び投与開始後 280-590 時間(累積投与量 4.2-9.9mg)の増加、590 時間(累積投与量 9.9mg)の減少が確認された。なお、不動時間と行動意欲は負の相関関係であるため、不動時間から推定した値が大きい場合に行動意欲は低くなる。

次に、36 週齢のコントロールマウスにおいては、歩行時の行動意欲はほぼ変化せず一定であった。また、走行、リアリング及び不動時の行動意欲はおよそ 24 時間を 1 周期として周期的に変化した。一方、36 週齢のコルチコステロン投与マウスにおいて、歩行及び不動時の行動意欲は一定であり、走行時においては投与開始後約 300 時間(累積投与量 4.4mg)における一時的な低下及び投与時間経過に伴う減少トレンドが確認された。リアリング時の行動意欲は投与開始後約 220 時間(累積投与量 3.3mg)、約 400 時間(累積投与量 5.9mg)で一時的に低下し、540 時間(累積投与量 8.0mg)以降計測終了まで低下状態が持続した。


24 週齢、36 週齢のコントロールマウスにおいて行動意欲がほぼ一定であった理由として、コルチコステロンを投与しないコントロールマウスにおいては行動意欲に変化が起きないことが考えられる。更に、コルチコステロンの溶解剤として水に入れているデキストリンも行動意欲の変化に影響を及ぼさない可能性が高い。また、コントロールマウスの行動意欲は周期的変化が発生したケースもあるが、これはマウスの活動特性によると考えられる。マウスは夜行性であり、日中は活動量が減少し頻りに睡眠を取る。そのため、昼と夜を合わせた 1 日の活動周期が行動意欲の周期性として表れている可能性がある。以上から、コントロールマウスにおける行動意欲には大きな変化は起きていないと考えられる。一方、コルチコステロン投与マウスにおいては、24 週齢及び 36 週齢マウスのリアリング時の行動意欲において、ある時点から計測終了まで継続した低下状態が確認された。通常、投与による体内

の cortisol 量の増加は制御機構により抑えられるが、長期に渡り続くことで制御機構が損なわれることがある¹⁾。ここで、ステロイドホルモンは行動意欲を減退させる作用を持つ¹⁾。従ってリアリング時の行動意欲は一時的に低下した後、制御機構の損傷による cortisol 量増加に伴い計測終了まで低下が続いた可能性がある (Fig.5 (c), right 及び Fig.6(c), right 参照)。行動意欲の低下の持続はうつ様状態の一つであるため²⁾、24 週齢マウスにおいては 450 時間 (累積投与量 7.2mg) 以降、36 週齢マウスにおいては 540 時間 (累積投与量 8.0mg) 以降にうつ様状態へ変化したことが示唆される。また、リアリング時の行動意欲のみにおいて二回の一時的低下の後に継続的な低下状態が続く 24,36 週齢に共通な変化傾向が確認された。しかし、共通な変化傾向が未確認である走行及び不動時の行動意欲の変化は個体差である可能性もあるため、更なる実験による検証が必要であると考えられる。




(a) Walking.

(left: control mouse, right: corticosterone mouse)




(b) Running.

(left: control mouse, right: corticosterone mouse)



(c) Rearing.

(left: control mouse, right: corticosterone mouse)




(d) Non-moving.

(left: control mouse, right: corticosterone mouse)


Fig. 5: Motivation estimation of each behavior.

(24 ages of the week)




(a) Walking.

(left: control mouse, right: corticosterone mouse)




(b) Running.

(left: control mouse, right: corticosterone mouse)



(c) Rearing.

(left: control mouse, right: corticosterone mouse)



(d) Non-moving.

(left: control mouse, right: corticosterone mouse)

Fig. 6: Motivation estimation of each behavior.

(36 ages of the week)

5 おわりに

本研究は、マウスの行動変化からステロイドホルモン投与量変化に伴う逐次的な行動意欲変化を推定することを目的とした。行動意欲に変化が確認されなかったコントロールマウスに対し、24 週齢の cortisol 投与マウスのリアリング時の行動意欲は投与開始後 190 時間 (累積投与量 2.5mg)、280-350 時間 (累積投与量 4.2-4.9mg) に一時的に低下し、450 時間 (累積投与量 7.2mg) 以降に低下状態が持続した。36 週齢の cortisol 投与マウスのリアリング時の行動意欲は投与開始後約 220 時間 (累積投与量 3.3mg)、約 400 時間 (累積投与量 5.9mg) で一時的に低下し、540 時間 (累積投与量 8.0mg) 以降に低下状態が持続した。行動意欲低下の持続はうつ様状態の一つであるため²⁾、24 週齢マウス

ウスにおいては450時間以降, 36週齢マウスにおいては540時間以降にうつ様状態へ変化したことを示唆している。以上より, ステロイドホルモン投与によるマウスの行動意欲の連続的な時系列変化を捉えた可能性がある。

参考文献

- 1) E. J. Nestler: Molecular Neuropharmacology, McGraw-Hill Education, 306/307 (2015)
- 2) 厚生労働省: ステロイド薬剤誘起性うつ病, 重篤副作用疾患別対応マニュアル, 14/18, (2008)
- 3) R. A. Brachman: Ketamine as a Prophylactic Against Stress Induced Depressive like Behavior, Biological Psychiatry, 79-9号, 776/786 (2016)
- 4) D.P. Wolfer: Cage Enrichment and Mouse Behaviour, Nature, 432号, 821/822 (2004)
- 5) 岡本厚: 岩波データサイエンス 時系列解析—状態空間モデル・因果解析・ビジネス応用, 株式会社岩波書店, 6/8, (2017)
- 6) 小出剛: マウス実験の基礎知識, 株式会社オーム社, 12/13, (2013)
- 7) E.J. Wagenmakers: AIC model selection using Akaike weights, Psychonomic Bulletin & Review, 11-1号, 192/196 (2004)

著作権 © 2019

公益社団法人計測自動制御学会(SICE)
〒101-0052 東京都千代田区神田小川町 1-11-9 金子ビル 4 階

カタログ番号 19 PG 0012

著作権は、計測自動制御学会がもっている
ので、個人の使用のための複製以外の
目的で掲載の記事の一部または全文を
複製する場合には、著作権者に許可を求
め規定の複製料を支払うこと。

発行日：2019年12月19日

発行者：公益社団法人計測自動制御学会 システム・情報部門
コンピューターショナル・インテリジェンス部会，知能工学部会