

3次元PCNNを用いた3次元領域分割

渡辺 隆* 西 直也* 田中 勝*† 栗田 多喜夫† 三島 健稔*

概要 fMRI 画像やマルチスライス CT 画像など 2 次元スライス画像の組として表すことができるような 3 次元画像において、複数の各領域を抽出することを目的とした 2 次元スライス画像からの 3 次元領域自動抽出手法を提案する。本手法においては、神経生理学からの知見に基づいて提案された脳の視覚皮質のモデルの 1 つである Pulse-Coupled Neural Network (PCNN) を用いる。PCNN は学習を行う必要がなく未知の画像に対しても領域の分割やエッジの強調などの画像処理に有効な処理を行うことができるため、現在さまざまな応用が報告されている。本稿では、PCNN ニューロンを 3 次元格子状に配列したモデル (3 次元 PCNN) を用いることで 3 次元領域を自動抽出させる。また、提案手法を用いて人の頭部の fMRI スライス画像に対する各領域分割、抽出の結果を報告する。

キーワード Pulse-Coupled Neural Network, 領域分割, 2 次元スライス画像

1 はじめに

fMRI 画像やマルチスライス CT 画像、地層の断面図のような 2 次元スライス画像の組として構成することができるような 3 次元画像において、3 次元的な画像内の各領域を抽出することは、その領域の形状や位置、大きさの理解を容易にする。また、抽出された 3 次元的な領域を表す画像は、他の処理などのために有効的に使用することができる。例えば医療分野などでは、3 次元領域の可視化、定量化、手術計画という目的にも利用可能であろう。他にも特定領域の容量推定や比較などに対しても用いることできるものと期待される。しかし、3 次元的な画像の領域分割に関しては多くの研究がなされているものの、現状においてはさまざまな状況に適応可能な有効な手法が確立しておらず、手作業による領域分割さえ行なわれている。本稿では、2 次元スライス画像の組として 3 次元画像を扱うので、fMRI 画像においてもボクセルデータとしての 3 次元的な位置情報は利用しない。そこで、本研究は 2 次元スライス画像の組で構成される 3 次元画像に対し、3 次元的に各領域を分割する手法を提案する。2 次元スライス画像を一枚毎に領域分割していくと各 2 次元スライス画像間の上下の関係を常に考えなければならないが、3 次元的に領域を分割することにより、上下の繋がりをも考慮にいれた出力が得られ、一枚ずつ行うよりも短時間で領域分割を行うことができるものと期待できる。

本手法においては、3 次元領域分割の手法として脳の視覚皮質のモデルの 1 つである Pulse-Coupled Neural Network (PCNN) を用いる [John99]。一般的なニューラルネットワークは、McCulloch-Pitts 型ニューロンを基本素子として構成されており、ニューロン同士を結合するシナプスの重みを変化させることによって、ネットワークからの出力が変化する。一方、PCNN はパルスコーディング型ニューロンを基本素子として構成するニューラルネットワークであり、このニューロンの閾値は時間によって変化するため、ニューロンの出力も時間によって異なるものが得られる。この PCNN の時間に対するコーディングが一般的なニューラルネットワークとの大きな違いであり、これにより PCNN はより高い表現力を持っていると考えられる。

PCNN を画像処理に適用する場合には、画像 1 ピクセルに対して 1 個の PCNN ニューロンを割り当てる。その出力としては、入力画像に対して領域分割されたものやエッジ強調されたものが得られることが知られている。さらに、PCNN による画像処理では事前の学習を必要としないので、簡単にこれらの出力画像を得ることができる。このように PCNN は画像処理に対して非常に有効であり、例えば、血球や航空機の識別、物体の分離や物体への注視法など、数多くの研究がなされている [John94, Thomas98, 渡辺 02]。

本稿では、この PCNN を 3 次元へ拡張した 3 次元 PCNN を提案する。3 次元 PCNN は PCNN ニューロンを 3 次元格子状に配列させたモデルであり、通常の PCNN では 2 次元平面上のニューロン間でのみ相互作用が評価

* 埼玉大学工学部情報システム工学科 (〒 338-8570 埼玉県さいたま市下大久保 255)

† 産業技術総合研究所 (〒 305-8568 茨城県つくば市梅園 1-1-1 つくば中央第 2)

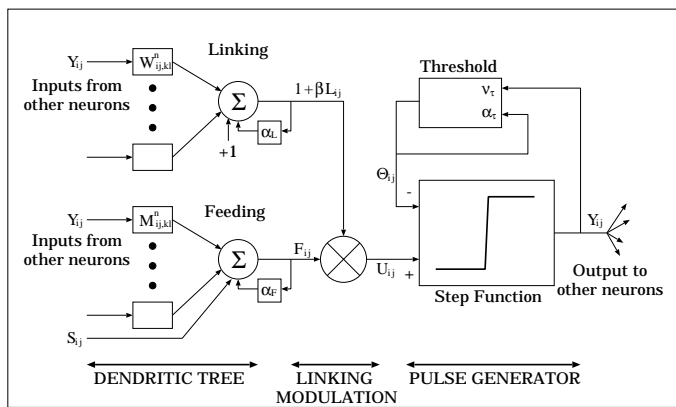


図 1: PCNN ニューロン模式図 (PCNN ニューロンは Dendritic Tree 部, Linking Modulation 部及び Pulse Generator 部の 3 つに分けられる.)

されるのに対して, 3 次元 PCNN ではそれらに加えて上下のニューロン間においても相互作用が評価されるように拡張されている. この拡張により, 3 次元領域画像に対して, 上下の繋がりを考慮に入れた 3 次元領域分割ができるものと期待される. さらに, 人の頭部の fMRI 画像を 2 次元スライス画像の組として扱った場合に対し, 3 次元 PCNN を用いた 3 次元領域分割の実験を行い, 各領域の分割及び抽出の結果についても報告する.

2 Pulse-Coupled Neural Network

Pulse-Coupled Neural Network(PCNN) は, 猫の視覚皮質での同期した視覚刺激に対するニューロン群の発火現象を説明するために Eckhorn が提案したモデル [Eckhorn90] をもとに, 計算機上でのシミュレーションが可能となるように拡張されたニューラルネットワークモデルである [Thomas98].

PCNN ニューロンの模式図を図 1 に示す. ニューロンの受容野は, Feeding 部と Linking 部と呼ばれる 2 つの部分から構成される. また, ニューロン間の相互作用は, シナプスの重み行列 M 及び W によって定義されている. 図 2 に, 1 次元の場合におけるシナプスの重みを示す. 一般的に, ニューロン間のそれぞれのニューロンは前時点における自分自身の状態を保持しており, この状態は時間とともに減衰項によって衰退していく. 受容野のうち Feeding 部のみが外部刺激 S を受ける. それぞれの受容野は次式によって計算される.

$$\begin{aligned} F_{ij}[n] &= e^{-\alpha_F} F_{ij}[n-1] + S_{ij} \\ &\quad + V_F \sum_{kl} M_{ij,kl} Y_{kl}[n-1], \quad (1) \\ L_{ij}[n] &= e^{-\alpha_L} L_{ij}[n-1] \end{aligned}$$




図 2: シナプスの重み行列 (横軸はニューロン間の距離, 縦軸は重みを表す. ここでは距離の逆数となるような重みを設定している.)

$$+ V_L \sum_{kl} W_{ij,kl} Y_{kl}[n-1]. \quad (2)$$

ここで, F_{ij} はニューロンを 2 次元に配列したときの (i, j) の位置に存在するニューロンの Feeding 部を表し, 同様に L_{ij} は同 PCNN ニューロンの Linking 部を表す. Y_{kl} は前時点 $[n-1]$ でのニューロンの出力を表す. Feeding 部, Linking 部ともに前時点の状態を保持することができるような記憶素子を持ち, それぞれの値は指数関数的に時間とともに減少する. また, α_F, α_L は時定数を表す. V_F 及び V_L はシナプスの重み行列を正規化するための定数である. これらは相互に作用させるニューロン群の大きさに合わせて設定する.

ニューロンの内部状態 U は, これら 2 つの受容野の状態の結合によって次式のように計算される.

$$U_{ij}[n] = F_{ij}[n](1 + \beta L_{ij}[n]). \quad (3)$$

ニューロンの出力 Y は, 内部状態と動的なしきい値 Θ の比較によって決定される. この決定は次式のように表現される.

$$Y_{ij}[n] = \begin{cases} 1 & \text{if } U_{ij}[n] > \Theta_{ij}[n-1] \\ 0 & \text{Otherwise} \end{cases}. \quad (4)$$

閾値は, ニューロンが発火 ($U > \Theta$) するとすぐにその値を急激に増加させる. その後, 次にニューロンが発火するまでの間, 指数関数的にその値を減少させる. この過程は次式のように表現される.

$$\Theta_{ij}[n] = e^{-\alpha_\Theta} \Theta_{ij}[n-1] + V_\Theta Y_{ij}[n]. \quad (5)$$

ここで, α_Θ は時定数である. V_Θ は U の平均値よりも大きな定数として設定する.

PCNN はこれらのニューロンの配列によって構成される. ニューロン間の相互作用 M, W は, 大抵の場合には




図 3: (2次元) PCNN の画像処理への適用 (n はネットワークの動作回数を表す (b) から (h) までを 1 周期として, 以下似たようなパターンを出力する.)




図 4: 時刻 n における発火ニューロン数 [Time Signal] (横軸はネットワークの動作回数 n を, 縦軸は Time Signal を表す. 図中の画像はその時刻における出力を示す. PCNN の動作の周期性を確認することができる.)

Gaussian 型の重みが利用される. 上記の配列 F, L, U, Y は初期状態として 0 を設定する. また, Θ も普通は同様に初期状態として 0 を設定するが, 目的に合わせていくつかの要素について適当な値をもたせることもある. 初期状態として Θ に 0 を設定した場合, それぞれのニューロンはどのような外部刺激に対しても最初のネットワークの動作で必ず発火し, 次の段階で閾値を増加させる. そして, 閾値は指数関数的に減少していき, ある時刻において再びニューロンの発火が発生する. 時刻 n にてニューロンが発火したとき, 前の発火時刻との発火時間間隔は

$$\tau_{ij} = \frac{1}{\alpha_{\Theta}} \ln \left(1 + \frac{V_{\Theta}}{F_{ij}[n](1 + \beta L_{ij}[n]) - \Theta_{ij}[n]} \right) \quad (6)$$

のようになる. PCNN は式 (1) から式 (5) までが繰り返




図 5: 3次元 PCNN のシナプス結合の重み (上下方向のニューロンの結合を加えることでオリジナルの PCNN を 3次元に拡張した.)

し計算されネットワークとして動作していく.

図 3 に PCNN の画像処理への適用例を示す. PCNN を画像処理に適用する場合には, 画像 1 ピクセルに対して 1 個の PCNN ニューロンを割り当てる. 入力画像には, 図 3(a) に示すような大きさや画素値が異なる正方形を対角線上に並べたものを用いた. 出力 Y は 0 もしくは 1 を取るので, 出力画像はパルス画像となる. なお, この例に使用した PCNN の各パラメータは $V_F = 0.5, V_L = 0.5, V_{\Theta} = 20.0, \alpha_F = 10.0, \alpha_L = 1.0, \alpha_{\Theta} = 5.0, \beta = 0.1$ である.

図 3 において, n は PCNN ネットワークの動作回数を表す. 図 3 では (e) - (h) において入力画像を構成する正方形が次々とそれぞれ単独に出力されている. しばらく経過した後 (k), (l) のように再び正方形が出力される.

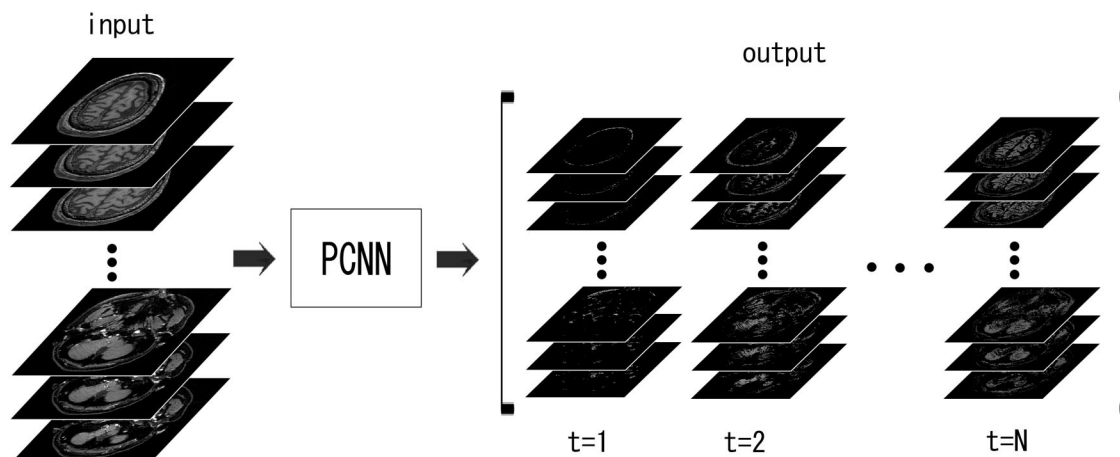


図 6: 3次元 PCNN を用いた 3次元領域抽出 (2次元スライス画像の組を入力とした 3次元 PCNN を動作させる. 動作時間毎に 2次元画像の組が一度に出力される.)




図 7: 実験に用いた 3次元 PCNN への入力画像の一部 (l はスライス位置を示す.)

また, 入力画像を構成する正方形のエッジが検出され, それが波のように外側へ伝播している. PCNN から出力される画像列は周期性を持っており, 似たようなパターンの画像が繰り返し出力される. 例えば図 3 では (b) から (h) までを 1 周期としてそれ以降似たようなパターンの画像列が出力される. この周期性は, Time Signal と呼ばれる時刻 n における発火ニューロン数

$$G[n] = \sum_{ij} Y_{ij}[n] \quad (7)$$

を見ることによって確認することができる. 図 4 に図 3 における Time Signal のグラフを示す. 図 4 で値が高くなっているときの出力を次々と見てみると, 図 3 (a) での左上の領域が抽出されている画像になっている. このようにある一定時間間隔で似たようなパターンの画像が

出力される.

PCNN のネットワークの終了時刻は利用者が決定する必要があるが, この Time Signal を利用することで例えば 2 周期分などどのように設定することができる.

このように, PCNN を用いると与えられた入力画像に対して画像処理に有効となる出力結果が得られ, また, それらの処理は学習を必要としないためすぐに適用でき, PCNN を用いた様々な応用が提案されている [John99, John94, Nishi02, 渡辺 02].

3 3次元 PCNN を用いた 3次元特徴抽出

本稿では, fMRI 画像などからの 3次元特徴抽出を目的として, PCNN を 3次元に対応できるように拡張した.




図 8: 3次元 PCNN より出力される画像の組 (左図のような画像の組が 1 回の 3次元 PCNN のネットワーク動作で出力される . これらは右図のような 2次元パルス画像 (ビットマップ画像) で構成される .)

この拡張した PCNN を 3次元 PCNN と呼ぶことにする . PCNN を fMRI 画像などに適用した例はいくつか報告されている [Abrahamson96, Paul99] が , すべてオリジナルの PCNN を利用したものであり , 上下の領域の関係は考慮されていない . そこで , 本稿では , fMRI 画像などの 2次元スライス画像より 2次元平面から得られる特徴だけでなく , 上下の特徴関係も考慮に入れることができるように 3次元 PCNN を提案する .

この 3次元 PCNN において , F 及び L は以下のように計算される .


$$F_{ijk}[n] = e^{-\alpha F} F_{ijk}[n-1] + S_{ij} + V_F \sum_{pqr} M_{ijk,pqr} Y_{pqr}[n-1], \quad (8)$$

$$L_{ijk}[n] = e^{-\alpha L} L_{ijk}[n-1] + V_L \sum_{pqr} W_{ijk,pqr} Y_{pqr}[n-1]. \quad (9)$$

ここで F_{ijk} は , ニューロンを 3次元に配列したときの (i, j, k) の位置に存在するニューロンの Feeding 部を表し , 同様に L_{ijk} は同 PCNN ニューロンの Linking 部を表す . オリジナルの PCNN との大きな違いは , ニューロン間の相互作用である . オリジナルの PCNN は 2次元方向のみの結合であるが , 3次元 PCNN は 3次元方向の結合を取り入れている . この様子を図 5 に示す .


その他の 3次元 PCNN 各部の計算については以下のようになる .

$$U_{ijk}[n] = F_{ijk}[n](1 + \beta L_{ijk}[n]), \quad (10)$$



(a) 動作回数:13 回

(b) 動作回数:14 回



(c) 動作回数:12 回

図 9: 出力画像の 3次元プロット (出力画像の組の全てについて 3次元構成したものである . 1 回の 3次元 PCNN のネットワーク動作でこのような出力を得ることができる .)

$$Y_{ijk}[n] = \begin{cases} 1 & \text{if } U_{ijk}[n] > \Theta_{ijk}[n-1] \\ 0 & \text{Otherwise} \end{cases}, \quad (11)$$

$$\Theta_{ijk}[n] = e^{-\alpha \Theta} \Theta_{ijk}[n-1] + V_{\Theta} Y_{ijk}[n]. \quad (12)$$

図 6 にこの 3次元 PCNN を用いた 3次元特徴抽出の手法を示す . この手法では , 3次元 PCNN への入力として 2次元スライス画像の組を用いる . スライス画像を組とした 3次元 PCNN を用いることにより , 上下の領域の関係を考慮に入れることができる . 3次元 PCNN のネットワーク動作によって , 2次元画像の組が出力される . この 2次元画像の組はネットワーク動作毎に一度に出力され , 1 回のネットワーク動作で得られる画像の枚数は入力として用いたスライス画像の枚数と同じである .

今回の実験では入力画像として , 人の頭部の fMRI スライス画像を用いた . その入力画像の一部を図 7 に示す . 図 7 において , l はスライス画像の位置を表す . ここでは , $l = 28, 37, 46, 55, 64, 73, 82, 91, 100, 111$ の位置のスライス画像を示した . これらの画像を含めた全てのスライス画像の組を 3次元 PCNN への入力とした .

3次元 PCNN を動作させると , 図 8 のような画像の組が出力される . これらの出力画像の組は 1 回の 3次元 PCNN のネットワーク動作で得られ , それぞれの画像は 2次元パルス画像 (ビットマップ画像) となる .

図 9 , 10 , 11 , 12 に図 7 を入力とした 3次元 PCNN による 3次元領域分割の実験結果を示す . 図 9 は , 図 8 の左図のように出力される 2次元画像の組を 3次元プロットしたものであり , また , 図 10 , 11 , 12 は図 8 の右図のように , 出力される 2次元画像の組からその一部を示したもの




図 10: 3次元 PCNN ネットワーク動作回数が 13 回のときの出力の一部 (l はスライス位置を示す . 図 9 (a) に対応する . 13 回の 3 次元 PCNN のネットワーク動作でこれらを含む全てのスライス位置での画像が出力される .)




図 11: 3次元 PCNN ネットワーク動作回数が 14 回のときの出力の一部 (図 9 (b) に対応する . 3 次元 PCNN の各パラメータは図 10 と同じものを用いた .)






図 12: 3次元 PCNN ネットワーク動作回数が 12 回のときの出力の一部 (図 9 (c) に対応する . 3 次元 PCNN の各パラメータは図 10 , 11 とは一部異なるものを用いた .)




(a) 2次元 PCNN による領域分割




(b) 3次元 PCNN による領域分割

図 13: 2次元 PCNN と 3次元 PCNN の領域分割の比較 (各図右側に拡大した画像を示す. 2次元 PCNN, 3次元 PCNN とも入力画像として図 7 (f) を用いた.)



(a) 2次元 PCNN による領域分割



(b) 3次元 PCNN による領域分割

図 14: 2次元 PCNN と 3次元 PCNN の領域分割の比較 (各図右側に拡大した画像を示す. 2次元 PCNN, 3次元 PCNN とも入力画像として図 7 (g) を用いた.)

である. 図 9 (a) と図 10 は, 3次元 PCNN の各パラメータとして $V_F = 0.01, V_L = 1.0, V_\Theta = 23632, \alpha_F = 20.0, \alpha_L = 1.0, \alpha_\Theta = 4.0, \beta = 0.3$ を用いて, 3次元 PCNN のネットワークを 13 回動作させた結果を示した. また, 図 9 (b) と図 11 は, 3次元 PCNN のパラメータは同様のものを用いて, 3次元 PCNN のネットワーク 14 回動作させた結果を示した. 図 9 (c) と図 12 は, 3次元 PCNN の各パラメータとして $V_F = 0.01, V_L = 1.0, V_\Theta = 1822, \alpha_F = 1.0, \alpha_L = 1.0, \alpha_\Theta = 4.0, \beta = 0.3$ を用いて, 3次元 PCNN のネットワークを 12 回動作させたときの結果を示した. 各実験でのシナプスの結合は, 注目しているニューロンを中心とした直径 7 の立方体の中にあるニューロンに限り作用し, シナプスの重みは距離の逆数で与えた. これら 3次元 PCNN の各パラメータの値は文献 [John99] などを参考にした.

図 10 では, 脳の内部, つまり, 白質部分が抽出されていることがわかる. また図 11 では, 脳の灰白質部分が抽出されている. 入力画像と比較してみると, 図 10 は入力画像のやや明るい部分と, また, 図 11 はそれよりも暗い部分と似た出力になっていることが分かる. 図 10, 11 は, 抽出する領域全体が発火しているが, 図 12 のように, 領域のエッジを抽出するような発火のパターンも観測できる.

図 10 や図 11 は白質部分や灰白質以外にも抽出されている部分が含まれているが, これらは隣接してはいないため, 簡単な画像処理により分割することができる. ま

た, 3次元 PCNN の 1 回の動作により図 9 のような 3次元領域を簡単に抽出することができる.

本手法の有効性を示すためいくつかの比較実験を行った. まず, 2次元 PCNN による領域分割との比較を行なった. 図 13, 14 にこの結果を示す. 図 13 (a) は図 7 (f) を入力として 2次元 PCNN を 11 回動作させたときの結果 (b) は同じものを入力としたときの 3次元 PCNN の結果 (図 11 (f) と同じ) である. また, 図 14 (a) は図 7 (e) を入力として 2次元 PCNN を 10 回動作させたときの結果 (b) は同じものを入力としたときの 3次元 PCNN の結果 (図 10 (e) と同じ) である. 各図において, 右図は左図の一部を拡大したものである. 図 13 では, 3次元 PCNN の方が領域が補完されている様子が分かる. また図 14 では, 領域の境界が鮮明になっている様子が分かる. これらは, 2次元 PCNN は平面のみ相互関係を組み込んでいるのに対して, 3次元 PCNN は上下方向の相互関係も考慮に入れているためである.

また, 閾値範囲を設定することにより領域抽出する方法との比較を行なった. 図 15 にこの結果を示す. 図 15 (a) は図 7 (f) より画素値が 90 から 255 までのものを切り出したものであり (b) は画素値が 120 から 255 までのものを切り出したものである (c) は同じものを入力としたときの 3次元 PCNN の結果 (図 10 (f) と同じ) であり (d) は同じものから手作業によるもので, 閾値処理を行い大まかな領域を取り出した後, ペイントソフトを用いて領域を抽出し作成したものである (a) では脳の中




図 15: 閾値範囲による領域分割と 3 次元 PCNN による領域分割の比較 (閾値による手法, 3 次元 PCNN による手法とも入力画像として図 7 (f) を用いた)




図 16: 手作業による領域分割と 3 次元 PCNN による領域分割の統計的比較 (左図は 3 次元 PCNN による領域分割の結果であり, 右図は手作業により領域分割をしたものである)

心部分を分ける領域は抽出されているが, 脳周辺部が大きく抽出されている. また (b) では脳周辺部は (a) よりも適切に抽出されているが, 脳の中心部を分ける領域が抽出されていない. 一方 (c) はどちらもより適切に評価されており (d) に最も近い結果となっていることが分かる.

さらに, これら 3 次元 PCNN による領域抽出の妥当性を示すため, 手作業により領域抽出したものととの比較を行なった. 図 16 にこの結果を示す. 図 16 において, 左図は 3 次元 PCNN による領域抽出の結果であり, 右図は手作業により領域抽出したものである. 図 16 (a) は, 図 7 (f) を入力としたものであり, (b)(c) は図 7 (e) を入力としたものである. ここで「総合適合率」とは, 左右両方の画像について一致したすべての画素数を画像全体の画素数で割ったものであり, 両画像の完全な一致度を示す. また「手作業画像との一致率」とは, 手作業画像が発火した点 (画素値が 0 でない点) すべてにおける, 3 次元 PCNN による画像の発火数の割合であり, 3 次元 PCNN の画像中に手作業画像がどのくらい含まれているかを示す. それぞれ 90% 程度の適合率, 一致率を示しており, 精度上においても十分であると言える.

以上のことから, 本手法を利用することで目的とする領域の分割が容易になると考えられる.

4 おわりに

本稿では, 脳の視覚皮質のモデルの 1 つとして提案されている Pulse-Coupled Neural Network (PCNN) を 3 次元に拡張した 3 次元 PCNN を用いた, 3 次元領域分割手法を提案した. PCNN は学習を行う必要がなく, 未知の画像に対しても領域の分割やエッジの強調などの画像処理に有効な処理を行うことができるため, この PCNN を利用した画像処理への応用が多数報告されている. その応用として fMRI 画像などに適用した研究が報告されているが, オリジナルの PCNN を用いた場合には上下の関係を考慮されていない. そこで, 2 次元スライス画像の組より 2 次元平面から得られる特徴だけでなく, 上下の特徴関係も考慮に入れられるように PCNN を 3 次元に拡張した. 3 次元 PCNN の特徴は, 相互作用をオリジナルのような 2 次元方向のみではなく, 3 次元方向にも拡張した点である. この 3 次元 PCNN を用いて, 人の頭部の fMRI 画像を入力とした 3 次元領域抽出の実験を行なった. この実験により, 3 次元領域を簡単に抽出することができた.

今後は, さらに精度の高い領域分割や抽出を行うため, パラメータの検討とパラメータ決定の自動化を図る予定である.

謝辞

本研究の一部は文部科学省の平成 14 年度科学技術振興調整費による「文脈主導型，認識・判断・行動機能実現のための動的記憶システムの研究」及び日本学術振興会特別研究員科学研究費補助金によるものである。また，本研究では産業技術総合研究所研究情報公開データベースにより公開されている「脳画像データベース」(<http://www.aist.go.jp/RIODB/brain/welcomej.html>) の fMRI 画像を用いた。

参考文献

- [John99] John L.Johnson, Mary Lou Padgett, Omid Omidvar: Special Issue on Pulse Coupled Neural Networks. IEEE Trans. Neural Networks, 10, 3, 1999.
- [Eckhorn90] R.Eckhorn, H.J.Reitboeck, M.Arndt et al: Feature Linking via Synchronization among Distributed Assemblies: Simulation of Results from Cat Visual Cortex. Neural Comp. 2:293-307, 1990.
- [John94] John L.Johnson: Pulse-coupled neural nets: translation, rotation, scale, distortion, and intensity signal invariance for images. Appl. Opt. 33:6239-6253, 1994.
- [Thomas98] Thomas Lindblad, Jason M.Kinser: Image Processing using Pulse-Coupled Neural Networks, Springer-Verlag, New York 1998.
- [Nishi02] Naoya Nishi, Masaru Tanaka, Takio Kurita: Three Dimensional Segmentation in PCNN, Proc. of The 2002 International Technical Conference On Circuits/Systems, Computers and Communications, 2:802-805, 2002.
- [Abrahamson96] S.L.Abrahamson: Pulse Coupled Neural Networks for the Segmentation of Magnetic Resonance Brain Images, MS Thesis, Air Force Institute of Technology, 1996.
- [Paul99] Paul E.Keller, David McKinnon: Pulse-Coupled Neural Network for Medical Image Analysis, Proc. of SPIE Application and Science of Computation Intelligence II conference, 3772, 47:444-451, 1999.
- [渡辺 02] 渡辺隆, 田中勝, 三島健稔: シグモイド型パルスジェネレータを取り入れた Pulse-Coupled Neural

Network による注視点探索法, 計測自動制御学会論文誌, 33, 8, 2002.

[Rybak92] L.A.Rybak, N.A.Shevtsova, V.M.Shandler: The Model of a Neural Network Visual Processor, Neurocomputing, 4:93-102, 1992.

筆者紹介



渡辺 隆 (わたなべ たかし)

2000 年埼玉大学大学院理工学研究科博士前期課程了。現在，同大学博士後期課程在学中。2000 年 4 月より日本学術振興会特別研究員。パターン認識および生体模倣型ビジョンの研究に従事。電子情報通信学会，計測自動制御学会各会員。



西 直也 (にし なおや)

2002 年埼玉大学工学部情報システム工学科卒。現在，同大学理工学研究科博士前期課程在学中。パターン認識および生体模倣型ビジョンの研究に従事。電子情報通信学会会員。



田中 勝 (たなか まさる)

1991 年九州大学大学院理工学研究科博士課程了。同年電子技術総合研究所情報科学部(現産業技術総合研究所)に入所。95～96 年カナダ国立科学研究協議会(NRC)招聘研究員。95～99 年大阪大学・連携大学院助教授(兼)。2000 年埼玉大学工学部情報システム工学科助教授，現在に至る。パターン認識および生体模倣型ビジョンの研究に従事。電子情報通信学会，日本神経回路学会，日本視覚学会，IEEE CS 各会員。理学博士。



栗田 多喜夫 (くりた たきお)

1981年名古屋工業大学工学部電子工学科卒。同年電子技術総合研究所に入所。90～91年カナダ国立科学研究協議会(NRC)招聘研究員。現在、産業技術総合研究所脳神経情報研究部門副研究部門長。統計的パターン認識および生体模倣型ビジョンの研究に従事。電子情報通信学会、日本神経回路学会、行動計量学会、日本顔学会、情報処理学会、IEEE CS 各会員。工学博士。



三島 健稔 (みしま たけとし)

1973年明治大学大学院工学研究科博士課程了。74年工業技術院電子技術総合研究所研究官。79年同主任研究員。92年城西国際大学設立に伴い経営情報学部教授。93年埼玉大学教養部教授。95年同工学部教授。現在に至る。数式処理、多値論理の形式的体系の解析、論理関数方程式、非線形問題等の研究に従事。現在、主としてセキュリティシステムインテグレーションに関心をもっている。日本数学会、日本数式処理学会、電子情報通信学会、情報処理学会、IEEE、ACM 各会員。工博。

Three dimensional segmentation using three dimensional Pulse-Coupled Neural Network

Takashi Watanabe*, Naoya Nishi*, Masaru Tanaka*[†]
Takio Kurita[†], Taketoshi Mishima*

* Department of Information and Computer Sciences, Saitama University

[†] The National Institute of Advanced Industrial Science and Technology

Abstract In this paper, we present a novel three dimensional segmentation method for a set of two dimensional sequential images such as fMRI images. The method is based on Pulse-Coupled Neural Network (PCNN), which is originally proposed for a possible explanation of the synchronous burst on cat's visual cortex by Eckhorn et. al. PCNN has a smoothing process in itself and it doesn't require a learning process. With these properties, PCNN gives good results for image processing such as edge detection, two dimensional segmentation, extracting invariant feature as a time signature, which is invariant under small distortion, rotation, scale transformation. PCNN consists of three parts, feeding part including the external stimulus, linking part, pulse generator. With extending PCNN to three dimensional one with spherical receptive fields for feeding and linking parts, for a given set of two dimensional sequential images corresponding to an external stimulus, the extended three dimensional PCNN can segment the set of two dimensional sequential images into each three dimensional region depending on the averaged intensity in the region automatically without any kinds of learning process. Some three dimensional segmentation results are also given in order to show the effectiveness of our three dimensional segmentation method.

keywords Pulse-Coupled Neural Network, segmentation, two dimensional sequential images