

Scale-Free Cellular Neural Networks の提案

松本 勝慶^{†1} 上原 稔^{†1} 森 秀樹^{†1}

Cellular Neural Networks(CNN)に複雑ネットワークの small-world ネットワーク構造を導入した Small-World Cellular Neural Networks(SWCNN)が提案されている。SWCNNは、small-world のネットワーク構造を導入することで、一部のアプリケーションにおいて処理が CNN と比較し、向上した。scale-free ネットワークは、各ノードが持つリンク数の存在確率がべき則になるネットワークである。scale-free ネットワークの特徴として、ネットワークの距離が短い、多くリンクを持つハブが存在することが挙げられる。また、scale-free ネットワークは、ランダムな故障に対し非常に強い特徴をもつ。本研究では、Cellular Neural Networks に scale-free ネットワークのネットワーク構造を導入した Scale-Free Cellular Neural Networks を提案する。CNN に scale-free ネットワークのネットワーク構造を導入することで画像処理アプリケーションに適用し、その特徴を明らかにする。

Proposal of Scale-Free Cellular Neural Networks

MATSUMOTO KATSUYOSHI,^{†1} MINORU UEHARA^{†1}
and HIDEKI MORI^{†1}

Small-World Cellular Neural Networks(SWCNN) have small-world network in Cellular Neural Networks(CNN). The Small-World Cellular Neural Networks have better performances than CNN in some image processing applications. Scale-free network has feature that is power law each node's links. In this paper, we propose and evaluate Scale-Free Cellular Neural Networks. Scale-Free Cellular Neural Networks has scale-free network.

^{†1} 東洋大学工学研究科情報システム専攻

Dept. of Open Information Systems, Graduate School of Engineering, Toyo University

1. はじめに

Cellular Neural Networks(CNN)に複雑ネットワークの small-world ネットワーク構造を導入した Small-World Cellular Neural Networks(SWCNN)が提案されている¹⁾⁻³⁾。SWCNNは、small-world のネットワーク構造を導入することで、一部のアプリケーションにおいて処理が CNN と比較し、向上した。

scale-free ネットワークは、各ノードが持つリンク数の存在確率がべき則になるネットワークである^{2),5),6)}。scale-free ネットワークの特徴として、ネットワークの距離が短い、多くリンクを持つハブが存在することが挙げられる。また、scale-free ネットワークは、ランダムな故障に対し非常に強い特徴をもつ⁷⁾。

本研究では、Cellular Neural Networks に scale-free ネットワークのネットワーク構造を導入した Scale-Free Cellular Neural Networks を提案する。CNN に scale-free ネットワークのネットワーク構造を導入することで画像処理アプリケーションに適用し、その特徴を明らかにする。

本論文の構成は、第2章に scale-free ネットワークについて述べ、第3章に Cellular Neural Networks について述べる。第4章で提案する Scale-free Cellular Neural Networks について述べる。第5章で、実験、評価を行う。

2. 複雑ネットワーク

複雑ネットワークの代表的な例として small-world ネットワークと scale-free ネットワークについて述べる³⁾⁻⁷⁾。

2.1 small-world ネットワーク

small-world ネットワークの特徴として、 C が大きく、 L が小さいネットワークであることが挙げられる。 L は、全ノードの平均距離 L_n の平均を示す。 L_n は、ノード n の全ノード間最短パスの平均距離を示す。 C_n は、ノード n におけるクラスタリング係数を示す。small-world ネットワークは少しのランダム性を持つネットワークであるため、ノードがもつ次数分布は均一とポワソン分布の中間に位置する。scale-free ネットワークは、次数分布がべき的である特性をもつことがあげられる。また、scale-free ネットワークは L が小さく C も小さいという特徴をもつ。

2.2 scale-free ネットワーク

ここでは、複雑ネットワークの代表的な例の一つである scale-free ネットワーク⁴⁾⁻⁶⁾ に

ついて述べる。

scale-free ネットワークでは、各ノードが持つリンク数(次数)によりネットワークを判別する^{?)、5)、6)}。scale-free ネットワークは、ノードが次数 k を持つ確率がべき的であるネットワーク構造である。scale-free ネットワークは、小さい次数を持つノードの存在確率は非常に高い。しかし、非常に大きな次数を持つノードの存在確率も 0 ではない。図 1 に scale-free ネットワークの次数分布を示す。非常に大きな次数を持つようなノードはハブノードと呼ばれる。ハブノードは多数のノードと接続しているため、ネットワークの中心と呼ばれることもある。一方でランダムなネットワークにおいて、ノードの次数 k の存在確率は指数関数的に減衰する。そのため、ランダムなネットワークではハブノードが出現する確率が非常に低い。




図 1 scale-free の次数分布
Fig. 1 Degree of k

scale-free ネットワークにおけるネットワークの生成モデルとして BA モデルを利用する^{?)、5)、6)}。BA モデルでは、成長と優先的選択により scale-free ネットワークを生成する。初期ノード数 m_0 の完全結合ネットワークとする。つぎにノードを 1 つずつ追加する。追加するノードはリンク数 m ($m_0 \geq m$) とする。追加されたノードは優先的選択で接続する。優先的選択では、ノードが n 個あるとき既存のノード v_i が次数 k_i 持つとすると、新しいノードとの接続する確率はつぎに示す式 (1) となる。

$$\Pi(k_i) = \frac{k_i}{\sum_{j=1}^n k_j}, (1 \leq i \leq n) \quad (1)$$




図 2 scale-free ネットワーク

図 2 は、BA モデルを用いて生成したネットワークである。BA モデルで生成したネットワークでは、ノードが持つリンク数が不定であり、ハブノードが存在することがわかる。

3. Small-World Cellular Neural Networks

ここでは、cellular neural networks(CNN), small-world cellular neural networks(SWCNN) について述べる。

3.1 Cellular Neural Networks

Cellular Neural Networks¹⁾ は、ニューロン同士の結合が局所的に接続されたニューラルネットワークである(図 3.1)。CNN は、画像処理、パターン認識などの様々なアプリケーションを持つ。以下に CNN の状態、出力方程式を示す。文献¹⁾によると状態 $x_{i,j}$ と示し、出力を $y_{i,j}$ と示す。状態方程式を以下の式 (2) に示し、出力方程式を式 (3) に示す。

$$\begin{aligned} x(t+1) = & -x_{i,j}(t) + I \\ & + \sum_{c(k,l) \in N_r(i,j)} A(i,j;k,l)y_{k,l}(t) \\ & + \sum_{c(k,l) \in N_r(i,j)} B(i,j;k,l)u_{k,l}(t) \end{aligned} \quad (2)$$




図 3 CNN
Fig. 3 CNN

$$y(t) = \frac{1}{2}(|x_{i,j}(t) + 1| - |x_{i,j}(t) - 1|) \quad (3)$$

出力 $y_{i,j}$ は上記の出力方程式により -1 1 の範囲で出力する。テンプレートは近傍素子との結合係数を示す。A は出力テンプレートで、B は入力テンプレートである。出力テンプレートは、フィードバックテンプレートであり、出力 $y_{i,j}$ に依存する。入力テンプレートはフィードフォワードテンプレートであり、入力 $u_{i,j}$ に依存する。 $N_r(ij)$ は素子 i,j の近傍を示す。近傍距離は r の値によって決まる。 $r = 1$ の場合、 3×3 となり近傍は以下 (図 3.1) になる。 I は閾値である。

3.2 Small-World Cellular Neural Networks

Small-World Cellular Neural Networks は、徳島大の鶴田らが提案した Cellular Neural Networks である^{1),2)}。SWCNN の特徴として、画像処理アプリケーションのエッジ検出において、エッジの検出が良くなっている。また、Hole Filling においては、収束がよくなっている。

鶴田らが提案した SWCNN では、ランダムに繋ぎ small - world ネットワークを実現する。素子同士の結合は 1 対 1 に対応する。SWCNN の状態方程式を式 4 に示す。

CNN の接続に新たにエッジを追加して、Small-World ネットワークを形成させている。この新たに追加されるエッジは、1 対 1 にのみ接続する。ここで、SW 用エッジを追加させる確率 p_c を導入する。 $p_c = 1$ のとき、追加されるエッジの数は $M \times N$ 行列では、 $(M \times N)/2$ 本が追加される。 $p_c = 0$ のときは、CNN と同じネットワークである。SWCNN の状態方程式 4 に示す。




図 4 SWCNN
Fig. 4 SWCNN

$$\begin{aligned} x(t+1) = & -x_{i,j}(t) + I + w_c M(i,j;p,q) y_{p,q}(t) \\ & + \sum_{c(k,l) \in N_r(i,j)} A(i,j;k,l) y_{k,l}(t) \\ & + \sum_{c(k,l) \in N_r(i,j)} B(i,j;k,l) u_{k,l}(t) \end{aligned} \quad (4)$$

ここで、 w_c は、新たに追加された Small-World ネットワークのショートカットエッジの結合係数である。 $M(ij;pq)$ は $c(ij)$ と $c(pq)$ が接続しているかどうかの結合判定子となっている。 $c(ij)$ と $c(pq)$ が接続しているならば、 $M = 1$ となり、接続していないならば $M = 0$ となる。SWCNN の特徴として、画像処理のタスクにおいて、ノイズ除去やエッジ検出などの特定のタスク性能 (収束性, 画質) の向上する。

4. Scale-Free Cellular Neural Networks

CNN にスケールフリーネットワークを導入した、scale-free cellular neural networks を提案する。scale-free cellular neural networks のネットワークイメージは、図 5 に示す。

Scale-Free ネットワークを構築するための方法として、BA モデルを用いて CNN をスケールフリーネットワーク構造にさせた。はじめにランダムに優先的に繋がれる素子を一定数選択する。次に、ランダムにまだ接続されていない素子を選択する。未接続の素子と接続する素子を優先的に接続される素子の中から選択する。

SFCNN の状態方程式を以下の式 5 に示す。




図5 Scale-free Cellular Neural Networks
Fig.5 Scale-free Cellular Neural Networks

$$\begin{aligned}
 x(t+1) = & -x_{i,j}(t) + I + \sum_{c(p,q) \in R(i,j)} w_c y_{p,q}(t) \\
 & + \sum_{c(k,l) \in N_r(i,j)} A(i,j;k,l) y_{k,l}(t) \\
 & + \sum_{c(k,l) \in N_r(i,j)} B(i,j;k,l) u_{k,l}(t)
 \end{aligned} \quad (5)$$

ここで、 $R(i,j)$ は $c(i,j)$ がもつショートカットリンクの集合である。 w_c は、ショートカットリンクの重みである。

5. 評価

評価として、以下の画像処理アプリケーションを用いて評価を行う。

- ノイズ除去
- 二値化
- エッジ検出
- Hole Filling

アプリケーション毎に評価を行う。

5.1 ノイズ除去

ノイズ除去は、画像中のノイズを除去することができる。式(6)にテンプレートを示す^{1),2)}。

$$A = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix}, B = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 0 \end{bmatrix}, I = 0, w_c = 1.0 \quad (6)$$

図6～図9にノイズ除去の処理結果を示す。




図6 原画像
Fig.6 Original Image




図7 CNN
Fig.7 CNN




図8 SWCNN(p=1)
Fig.8 SWCNN(p=1)




図9 SFCNN
Fig.9 SFCNN

ノイズ除去では、図7はCNNの処理結果である。CNNでノイズ除去を処理させるとノイズがうまく消されている。図8はSWCNNの処理結果である。SWCNNで、ノイズ除去を行うとノイズがわずかに残ってしまう。しかしながら、大部分のノイズは消去可能である。図9はSFCNNの処理結果である。SFCNNのノイズ除去は、SWCNNと同様に大部分のノイズを消去することが可能であるが、わずかにノイズが残ってしまう。

5.2 二値化

二値化は、グレースケール画像を二値画像に変換するテンプレートである。式(7)に二値

化のテンプレートを示す^{1),2)}。

$$A = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}, B = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 0 \end{bmatrix}, I = 0, w_c = 1.0 \quad (7)$$

図 10～図 13 に二値化の処理結果を示す。



図 10 原画像
Fig. 10 Original Image



図 11 CNN
Fig. 11 CNN



図 12 SWCNN($p = 1$)
Fig. 12 SWCNN($p = 1$)



図 13 SFCNN
Fig. 13 SFCNN

ここでは、二値化の処理結果を述べる。図 11 は CNN の処理結果である。図 12 は、SWCNN の処理結果である。図 13 は、SFCNN の処理結果である。二値化では、CNN の

処理結果が最もよく見える結果となった。SWCNN では、グレースケール画像のグレー画像部分がモザイク状に二値化されている。SFCNN は SWCNN と同様にグレー画像部分がモザイク状に二値化されているが、その範囲が SWCNN と比較して広い部分でモザイク状となった。

5.3 エッジ検出

エッジ検出は、グレースケール画像中のエッジを抽出するテンプレートである。式 (8) にエッジ検出のテンプレートを示す^{1),2)}。

$$A = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}, B = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}, I = -1, w_c = 1.0 \quad (8)$$

図 14～図 17 に原画像と CNN, SWCNN, 提案した SFCNN の処理結果を示す。

図 15 は、CNN での処理結果でエッジ検出はされている。図 16 は SWCNN での処理結果である。CNN では、検出できなかったエッジが検出することができるになっている。図 17 は、SFCNN の処理結果となっている。SFCNN は、エッジの検出は CNN と同程度であるが、ノイズが非常に多くないっている。

5.4 ホールフィリング

ホールフィリングは、二値画像の穴を埋める画像処理アプリケーションである。式 (9) にテンプレートを示す^{1),2)}。

$$A = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 3 & 1 \\ 0 & 1 & 0 \end{bmatrix}, B = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 0 \end{bmatrix}, I = -1, w_c = 1.0 \quad (9)$$

図 18～図 17 にホールフィリングの処理結果を示す。ホールフィリングでは、CNN(図 19) と SWCNN(図 20) は囲まれた部分が穴埋めされているが、SFCNN(図 21) では、穴埋めされていない。また、処理結果にノイズが混ざっている。

次に収束時間について図 18 に示す。収束時間では、SFCNN は CNN, SWCNN と比較して収束時間が非常に短い。

6. まとめ

本研究では、CNN に scale-free ネットワークのネットワーク構造を導入した Scale-Free



図 14 原画像
Fig.14 Original Image



図 15 CNN
Fig.15 CNN



図 16 SWCNN($p=1$)
Fig.16 SWCNN($p=1$)



図 17 SFCNN
Fig.17 SFCNN




図 18 原画像
Fig.18 Original Image




図 19 CNN
Fig.19 CNN



図 20 SWCNN($p=1$)
Fig.20 SWCNN($p=1$)




図 21 SFCNN
Fig.21 SFCNN

Cellular Neural Networks を提案した。SFCNN はノイズ除去はノイズをうまく除去することができた。SFCNN の二値化はグレー部分のモザイクが SWCNN と比較し、増えている。SFCNN のエッジ検出はノイズが混ざりエッジがうまく検出できない。ホールフィリングでは、SFCNN は早く収束するが、穴埋めができない。

提案した SFCNN は、画像処理アプリケーションでは一部のアプリケーションを除いて結果が得られなかった。今後の課題として、連想記憶などの別のアプリケーションで評価する必要がある。

参考文献

- 1) L. O. Chua, and L. Yang: "Cellular neural networks: theory and applications," IEEE Trans. Circuit & Syst., vol.35, pp.1257-1290, 1988.
- 2) K. Tsuruta, Z. Yang, and Y. Nishio: "Small-World Cellular Neural Networks for Image Processing Applications," European Conference on Circuit Theory and Design, 1, pp.225- 228
- 3) D. J. Watts, and S. Strogatz : "Collective dynamcis of 'small-wolrd' networks," Nature, 393, pp.440-442, 1998.
- 4) A. L. Barabasi, and R. Albert: "Emergence of Scaling in Radom Networks," Sci-




図 22 収束時間
Fig. 22 Convergence Time

- ence, 286, pp.509-512, 1999
- 5) 増田直紀, 今野紀雄: “複雑ネットワークの科学,” 産業図書, 2005
 - 6) M. E. J. Newman: “The Structure and Function of Complex Networks,” SIAM Review, Vol. 45, No. 2, pp.167-256, 2005
 - 7) R. Albert, H. Jeong, and A.-L. Barabasi: “Error and attack tolerance of complex networks,” Nature, 406, pp.378-382, 2000