

C_022

画像処理用 Small World CNN のフォルトトレラント実装

Implementation of Fault-Tolerant techniques in Small World Cellular Neural Networks for Image Processing

松本 勝慶† 森秀樹† 上原稔†

Katsuyoshi Matsumoto Hideki Mori Minoru Uehara

1. はじめに

CNN で画像処理を行う場合、Small World のネットワークモデルを組み込むことにより、エッジ検出、ノイズ除去など特定のタスクにおいて性能の向上が期待される[1]。しかしながら、この CNN は故障に対して考慮されていない。

CNN は近隣のセルと演算を行うので、故障が起きた場合エラーが伝搬される。そこでセルが故障した場合、セルごとに多数決をとる SWCNN を提案する。

2. 関連研究

2. 1 Small World Networks

スモールワールドネットワークとは、社会心理学の分野で生まれた概念である[4]。

このグラフの形態として、クラスタリング係数 C が大きく、すべてのノードの最短パス長平均 L が小さいグラフのことをいう。

このグラフの持つ特徴として、流行や伝染病が伝わりやすいなどが挙げられる。

2. 2 Cellular Neural Networks (CNN)

CNN とは、素子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。CNN は単純なセルの組合せから生成する複雑な時空間ダイナミクスを利用する非線形回路網である。CNN は画像処理、非線形システムの様々な現象のモデリング、パターン認識など様々なアプリケーションを持つ[1][2]。

2. 3 SWCNN

CNN にスモールワールドを組み込むことにより、画像処理のアプリケーションにおいて、タスクの向上することがある。

SWCNN におけるスモールワールドのネットワークの形態を以下の図に示す。




図1 SWCNNのネットワークイメージ

このネットワークモデルでは、基本の CNN にランダムに結合するエッジを追加する。このエッジを追加するためのランダム結合確率 p_c を導入する。この追加されるエッジは、1対1のみに結合する。 $p_c = 1$ の場合、すべてのセルが1対1に結合する。 $p_c = 0$ のときはオリジナル

の CNN である。以下の式(1),(2)に SWCNN の状態方程式、出力方程式をそれぞれ示す。

状態方程式の A はフィードバックテンプレート、 B はフィードフォワードテンプレートを示し、 u_{ij} は入力を表す。出力 y_{ij} は-1~1の範囲で出力する。

$$\dot{x} = -x_{ij} + \sum_{c(k,l) \in N_r(i,j)} A(i,j) y_{kl}(t) + \sum_{c(k,l) \in N_f(i,j)} B(i,j) u_{kl} + w_c M(i,j;p,q) y_{pq} \quad \dots(1)$$

$$y_{ij}(t) = \frac{1}{2} (|x_{ij} + 1| - |x_{ij} - 1|) \quad \dots(2)$$

w_c はランダム結合の結合荷重、 M は接続先を示す。 $M(i,j;p,q)$ ならば、 $c(i,j)$ と $c(p,q)$ が結合していることになる。

3. 三重化モジュール方式(TMR)

古くからエラーマスクの方法として、よく知られているものが三重化モジュール方式(TMR)である[4][5]。一つのアイテムを三重化しその出力結果の多数決をとることで決定する方法である。(図2)




図2 三重化モジュール方式(TMR)

4. フォルトトレラント SWCNN

本研究では、SWCNN の耐故障性を高めるために TMR を選択した。この方法の概念図を図3に示す。

この手法では、CNN のセルを3つ並べて、多数決を行う。




図3 フォルトトレラント SWCNN

多数決の結果が一致すれば一致した値を返し、すべて異なった場合、親となるセルの結果を返すこととする。

† 東洋大学大学院工学研究科情報システム専攻 Graduate School of Engineering, Toyo University Dept. of Open Information Systems

5. 実験方法と結果

5.1 実験方法

上記で設計した画像処理用フォルトトレラント SWCNN を用いて評価を行う。以下の条件でシミュレートを行った。

- ・ 故障率 0,10,30,50%でシミュレート
 - ・ ランダム結合確率 p_c は故障率 0%のときシミュレートし、最良の結果を得られた値に固定
- 故障は1故障でシミュレーションを実行した。

画像処理のタスクは、以下の3つについて行った。

- (1)スモールオブジェクト除去
- (2)グレースケールの二値画像化
- (3)グレースケールのエッジ検出

5.2 実行結果

以下にシミュレーション結果を示す。

(1)ノイズ除去

このタスクは、二値画像におけるノイズを除去することができる。

ランダム結合確率 $p_c = 1$ として実験を行った。

以下の図にシミュレーション結果を示す。




図4 スモールオブジェクト除去

(a)は初期画像で、(b)は故障率 0%のシミュレーション結果、(c)は故障率 10%で比較回路なしの場合、(d)は故障率 10%で比較回路ありの場合のシミュレーション結果。

このタスクでは、エラーの伝搬が早く 10%までの故障にしか対応できなかった。

(2)グレースケールの二値画像化

グレースケールを二値画像化することがこのタスクでは、可能である。

ランダム結合確率 $p_c = 0.3$ とした。




図5 グレースケールの二値画像化

上の図では、(a)初期画像、(b)故障率 0%、(c)故障率 30%で比較回路なし、(d)故障率 30%で比較回路ありを示す。

このタスクでは、フィードフォワードテンプレートが自分にしか結合していないので、エラーの伝搬が遅く 30%程度の故障までは耐えることが出来た。

(3)グレースケールのエッジ検出

グレースケール画像におけるエッジ検出こすることが可能となるタスクである。

$p_c = 1$ としてシミュレーションを行った。シミュレーション結果を下の図に示す。




図6 グレースケールのエッジ検出

(a)入力画像、(b)故障率 0%のとき、(c)故障率 30%のとき、(d)故障率 30%で比較回路を実装した場合のシミュレーション結果を表す。

エッジ検出のタスクでは、上記のグレースケールの二値画像化と同じく、30%程度の故障までは回避することが出来た。

6. まとめ

今回作成した方法でシミュレートした結果は、10%未満~30%程度の故障まで三重化行わない場合と比較すると画質の改善を行うことが出来た。しかし、この手法では多重化を行うため無駄が多い。

今後の課題として、故障したセルのsmall world化されたエッジを切っていく、エラーの伝搬を抑える方法を実装していきたい。

参考文献：

- [1]鶴田、楊、西尾、牛田、「スモール・ワールド・セルラ・ニューラル・ネットワークとその画像処理への応用」、信学技法、NLP2003-40(2003-07), pp67-70, (2003)
- [2]L.O.Chua, L.Yang, 「Cellular Neural Networks : theory and Applications」, IEEE Trans. Circuits & Syst., vol35pp.1257-1290, (1988)
- [3]ダンカン・ワッツ, 「スモールワールド」, 東京電機大出版局(2006)
- [4]向殿、秋田、奥村、尾崎、菊野、古賀、南谷、藤原、蓬原, 「フォルトトレラントコンピューティング」, 丸善(1989)
- [5]当麻、岩田, 「高次機能を利用した相互結合型フォルトトレラントニューラルネットワーク」, 電子情報処理学会論文誌, D-I Vol. J81-D-I No.2, pp. 114-125(1998)