

一時故障における SWCNN の耐故障化

松本 勝慶, 上原 稔, 森 秀樹

東洋大学大学院 工学研究科 情報システム専攻

セルラ・ニューラルネットワーク (Cellular Neural Networks:CNN) を用いて画像処理を行う場合に Small-World ネットワークのネットワークモデルを組み込むことにより, ノイズ除去やエッジ抽出など特定のタスクはよりよい画像処理が期待される. スモールワールドネットワークとは, 旅先やパーティなどで出会った人と思いがけずに共通の知人を発見したりすることである. このネットワークの特徴として, 流行や伝染病が伝わりやすいなどがある. SWCNN では, 故障によるエラーが CNN と伝搬される速度が速くなっている. 以前, ニューロンの固定故障に対し各ニューロンの処理を多重化することで, 故障回避方法を提案し, 評価を行った. 本研究では, 一時故障向けにタイムスタンプを用いた方法の提案を行う.

Fault Tolerant SWCNN for Intermittent Fault

Katsuyoshi Matsumoto, Minoru Uehara, and Hideki Mori

Toyo University Graduate School, Department of Open Information Systems

Cellular Neural Networks(CNN) is a neural network model linked to only neighborhood. CNN is suited for image processing such as noise reduction and edge detection. Small World Cellular Neural Networks(SWCNN) is a CNN extended by adding a small world link, which is global short-cut. SWCNN has better performance than CNN. One of weak points of SWCNN is fault tolerance. We proposed multiple SWCNN layers in order to improve fault tolerance of SWCNN. However, it is not sufficient because only stop failure is considered. In this paper, we propose Time Stamp Voting method in order to improve tolerance for intermitted faults.

1. はじめに

現在, 携帯電話などにもカメラが搭載されるようになり, モバイルマルチメディア機器が身近になってきている. このような機器を用いることで, ブログなど個人からの情報発信が容易になった. また, 従来災害時等, 被災地に従来のメディアが行けないような場合, 被災地における重要な情報発信源となりつつある. このようなモバイル機器はセンサにもなりうる.

近年, インターネットを利用した, 防犯, 家電制御向けなどのリモート監視システムの関心が高まっている. このようなセンサ・ネットワークを用いた例として, アクティブカメラ群を用いた協調監視システムが提案されている[8]. カメラを用いたセンサ・ネットワークの場合, カメラから送られてくる画像をサーバが処理するためサーバの負荷が大きい. そこでセンサ側である程度の画像処理を行い, サーバの負荷を抑えることが重要となる. また, このような監視システムにおいてセンサノードの故障は, 死角が増えると監視システムが機能しなくなる可能性があり, センサノードの耐故障性の向上の必要である. また, 屋外で利用されることを考慮すると高い耐故障性が必要である.

Cellular Neural Networks (CNN)[1][2]はニューロンを格子状に配置し, 近傍系のニューロンのみと結合するニューラルネットワークである. また, リンク重みはテンプレートにより一様に設定される. CNN は, テンプレートを変化させることにより, 画像処理, パターン認識など, 様々に応用可能である. CNN で画像処理を行う場合, 処理性能が課題となる. 処理性能はニューラルネットワークの収束性に依存する. 鶴田ら[2]は, CNN の欠点を補う方法として small-world ネットワークを組み込むことだ Small-World Cellular Neural Networks (SWCNN) を提案している. Small-world ネットワークは, 規則的なネットワークと不規則なネットワークの中間に存在するネットワークである. このネットワークモデルを組み込むことによって, CNN の性能が向上する. 文献[2]では, 通常 CNN のネットワークに1本のリンクを追加した Added SWCNN を提案した.

第2章では SWCNN について述べる. 第3章では本研究で耐故障化 SWCNN について述べる. 第4章では, 実験方法と評価について述べる. 最後に本論文のまとめとする.

2. Small-World Cellular Neural Networks

2.1 Cellular Neural Networks

CNN[1][2]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[1][2]を示す。文献[1]によると状態 x_{ij} とし、出力

$$\dot{x}_{ij}(t) = -x_{ij}(t) + I + \sum_{c(kl) \in N_r(i,j)} B(ij;kl)u_{kl}(t) + \sum_{c(kl) \in N_r(i,j)} A(ij;kl)y_{kl}(t) \quad (1)$$

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

を y_{ij} と示す。状態方程式を以下の式(1)に示し、出力方程式を式(2)に示す。

出力 y_{ij} は上記の出力方程式により -1 から 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_{ij} 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_{ij} に依存する。 $N_r(ij)$ は素子 ij 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1)になる。 I は閾値である。

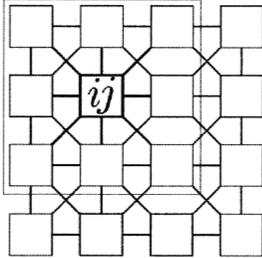


図1 CNN

2.2 Small-World Networks

Small-World ネットワーク[3][4]は、世界中の人々とは6次の隔たりですべてつながっていること示す。1998年、Wattsらがネットワークモデルとして定式化した。定式化されたモデルにおける2つの特徴量を以下に示す。

- L : すべてのノード間の平均パス長
- C : クラスタリング係数

ここで、 L はすべてのノード間の最短パス長の平均である。 C は、 $C(p)$ を定義する。ノード k が k_r 個の隣接ノードを持つ時、 k_r 個の隣接ノードから2つのノードを選び出すペアの数が $k_r(k_r-1)/2$ 個となる。すべてのノードで $C(p)$ をとり、平均したものが C となる。

これら2つの特徴量、 L が小さく、 C がおおきいグラフが small-world ネットワークである。簡単に説明すると、ネットワーク上にあるノードがクラスタ状に集まっているにも関わらず、ノード間の距離が短いグラフである。このグラフの特徴として、伝染病や流行が伝わりやすいなどを持つ。

2.3 Small-World Cellular Neural Networks

SWCNNは、鶴田ら[2]により提案されたCNNである。CNNのネットワーク構造を Small-World 化するために、CNNに1本のリンクを追加することにより、Small-World ネットワークを実現している(図2)。

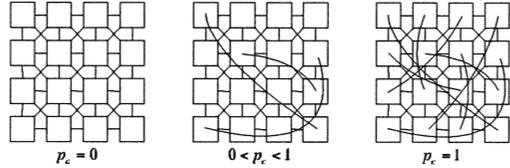


図2 SWCNN

SWCNNは、CNNに比べて特定のタスクの性能を向上させることが可能である[1][2]。このネットワークモデル(図2)では、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(3)に示す。

$$\dot{x}_{ij}(t) = -x_{ij}(t) + I + w_c M(ij; pq) y_{pq}(t) + \sum_{c(kl) \in N_r(i,j)} A(ij;kl) y_{kl}(t) + \sum_{c(kl) \in N_r(i,j)} B(ij;kl) u_{kl}(t) \quad (3)$$

w_c は、新たに追加されたSW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。

以下にノイズ除去[1][2]のテンプレート(式4)を示す。

$$A = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix}, B = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}, I = 0, w_c = 1.0 \quad (4)$$

図3は、ノイズ除去の原画像と $p_c=0$ 時と $p_c=1$ 時の出力画像である。

つぎにエッジ検出のテンプレート(式5)を示す。

図4は、エッジ検出の $p_c=0$ 時と $p_c=1$ 時の出力画像である。

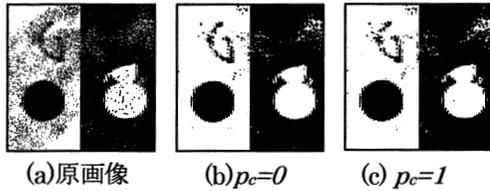


図3 ノイズ除去

$$A = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix}, B = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}, I = 0, w_c = 1.0 \quad (5)$$

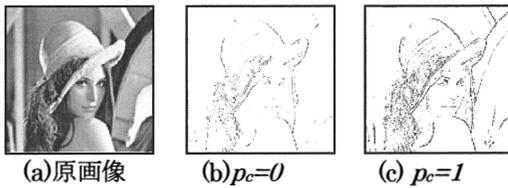


図4 エッジ検出

エッジ検出では、ニューロンを small-world ネットワーク化 ($p_c = 1$) することにより、オリジナルの CNN ($p_c = 0$) と比較し、エッジの検出が効率よくできる。CNN(図4(a))では、検出できなかったエッジが SWCNN(図4(b))ではエッジの検出が可能となっている。

3. 耐故障化 SWCNN

3.1 多重化 SWCNN

我々は、耐故障性 SWCNN として Duplex [6], TMR[6] を用いたフォルトトレランス方法を提案した。3.2 で Duplex について説明する。また、3.3 で TMR 方式について述べる。本研究では、一時故障向けに信頼評価カウンタを用いた耐故障化 SWCNN を提案する。

3.2 Duplex

Duplex 方式[5], [6] は、同一モジュールを並列にし、同一データに対し演算を同時に実行する。その実行結果を比較することにより故障を検出する。しかし、この方式では、故障の検出のみ可能であり、故障の復旧が困難となっている。

Duplex 方式[5], [6] では、SWCNN を2つ並列にし、同一箇所のニューロンの出力を比較し、比較結果により、故障の判定を行う。故障の判定が行われたニューロンが故障しているならば、そのニューロン箇所は両方の SWCNN より隔離される。隔離された箇所のニューロンは、入力値を利用する。図6に Duplex 方式を示す。

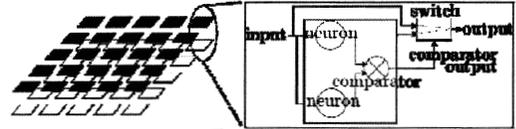


図5 Duplex

3.3 TMR

TMR 方式[5], [7] は、Duplex 方式と同様に同一のモジュールを3つ並列にする。3つ並列のモジュールの出力を多数決により出力を決定する方式である。この方式では、故障が1つのモジュールまで許容され、他の2つのモジュールが出力が一致しているならば、正常に出力される。

TMR 方式[5], [7] では、Duplex 方式と同様に同じネットワークを持った SWCNN を3つ並列にし、同一箇所のニューロンの出力を多数決することにより、SWCNN の耐故障性の向上をはかる。多数決の結果により出力を決定する。3つのニューロンの出力が同じならば、そのまま一致した値を出力する。2つのニューロンが2つ一致したならば、一致したニューロンの出力が出力となる。すべてが異なった場合は、ランダムに選び出力を決定する。

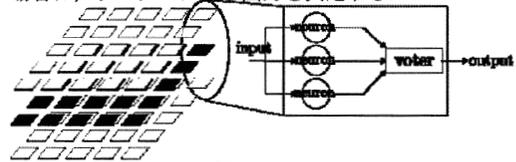


図6 TMR

3.4 信頼評価カウンタ SWCNN

(Reliability Counter)

この方式では、TMR にニューロンごとに信頼度の評価を行う。信頼度の付け方は、多数決判定により少数派になった時、その少数派ニューロンの信頼度を下げる。この信頼度は、最終的な出力時に信頼度を元に出力を決定する (図7)。

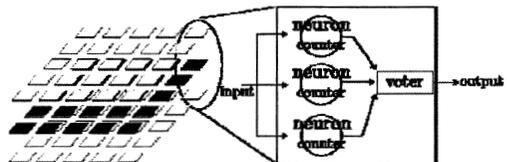


図7 信頼評価カウンタ SWCNN

4. 実験評価

4.1 実験方法

ここでは、本研究における実験方法と評価方法について述べる。まず、実験方法について説明する。

- 故障：一時故障
 - 復旧率：0, 0.5, 1
- 故障率：0~0.09
- CNNのタスク：ノイズ除去, エッジ検出

一時故障は、故障が発生するが一定の確率で故障した箇所を復旧する故障とする。また、故障した箇所の故障値は、一定の値1とした。復旧する確率、復旧率を定義する。復旧率0の時は、故障ニューロンが復旧せず、そのまま故障したままの状態とする。復旧率1の時は、100%の確率で故障した箇所が復旧し、もとの状態に戻ることとする。復旧率0.5の時は、50%の確率で故障箇所が復旧することとする。

評価方法は、処理画像に故障がなかった時の処理画像とどの程度離れているのかを示す画素の不一致率で評価する。参照画像と処理画像を画素ごとに比較し、異なる画素の数の比率を不一致率とする。不一致率は以下の式(6)に示す。

$$\text{不一致率} = \frac{\text{不一致画素数}}{\text{すべての画素数}} \quad (6)$$

4.2 シミュレーション結果

図8~10にノイズ除去のシミュレーション結果を示し、図11~13にエッジ検出のシミュレーション結果を示す。まず、図9に故障率0.01、復旧率1時ノイズ除去のシミュレーション結果を示す。復旧率1では、TMR、信頼評価カウンタで故障を抑制することができ、SWCNNと比較しノイズが少なくなっている。

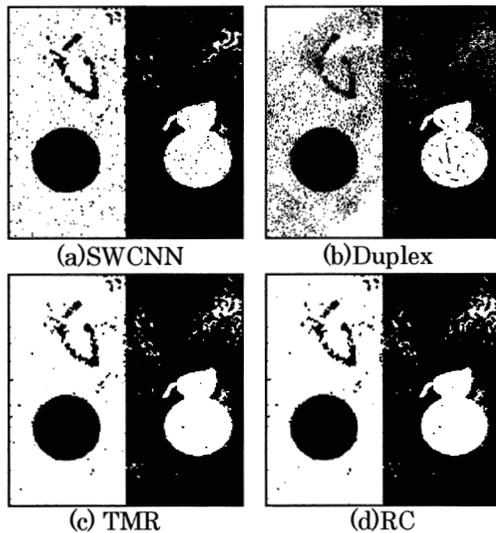


図8 ノイズ除去 (故障率0.01, 復旧率1)

図9に故障率0.01、復旧率0.5時のノイズ除去のシミュレーション結果を示す。

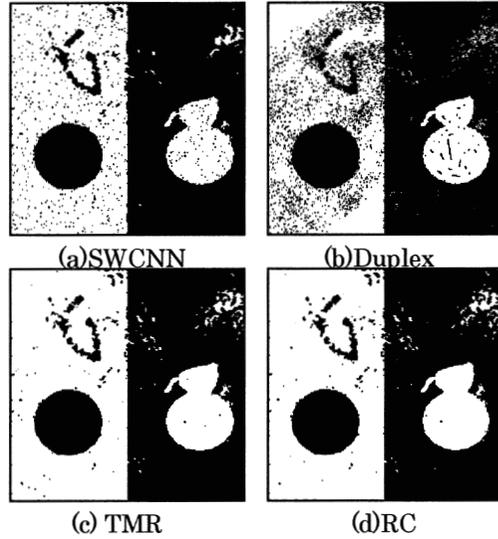


図9 ノイズ除去 (故障率0.01, 復旧率0.5)

復旧率0.5では、TMR、信頼評価カウンタで故障を抑えることができ、SWCNNと比較しノイズが少なくなっている。また、TMR、TMR with Reliability Counterでは、見た目の差がほとんどみられなかった。Duplex方式は、復旧率1と同様により結果が得られた。

図10に復旧率0時のノイズ除去のシミュレーション結果を示す。

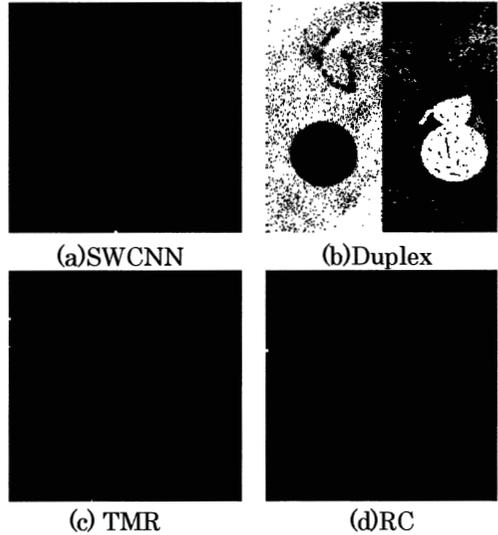


図10 ノイズ除去 (故障率0.01, 復旧率0)

復旧率0では、TMR、信頼評価カウンタで耐故障性の効果が得られなかった。また、Duplex方式は、復旧率0の時では非常に大きな耐故障性が得られた。ノイズ除去では、復旧率が0の時Duplex方式以外は同じ結果が得られた。

次に、エッジ検出のシミュレーション結果を示す。

図 12 で復旧率 1 のシミュレーション結果を示す。

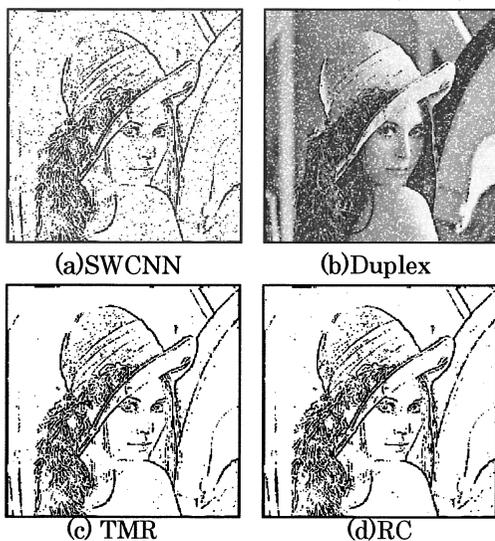


図 11 エッジ検出 (故障率 0.01, 復旧率 1)

復旧率 1 の時, TMR, 信頼評価カウンタは CNN と比較し, 故障を抑えることができ, ノイズが減っている。Duplex 方式では, 故障箇所との隔離のみを行い, 出力が入力となるため, 原画像が出力されている。

次に復旧 0.5 時のシミュレーション結果を図 12 に示す。

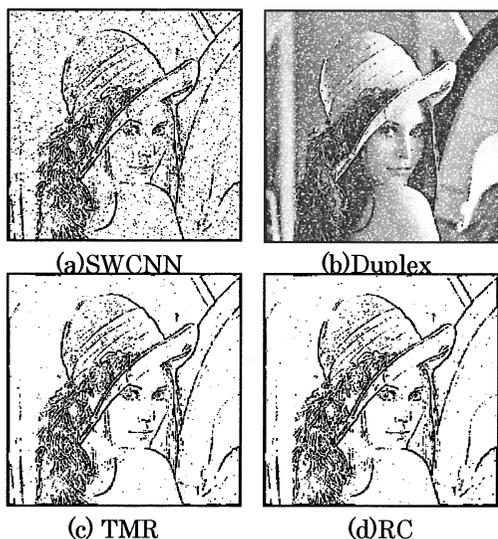


図 12 エッジ検出 (故障率 0.01, 復旧率 0.5)

復旧率 0.5 では, 復旧率 1 時と同様に TMR, 信頼評価カウンタで故障を抑えることができた。しかし, TMR と信頼評価カウンタでは, わずかであるが信頼評価カウンタ方式にノイズがわずかであるが残っている。Duplex 方式は, このタスクにおいて故障の発

見は可能であるが, 故障からの回復ができていない。

図 13 に復旧率 0 時のシミュレーション結果を示す。

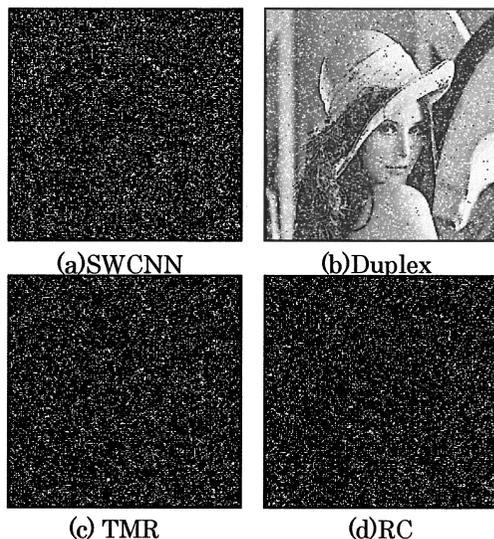


図 13 エッジ検出 (故障率 0.01, 復旧率 0)

復旧率が 0 の時, このタスクでは, すべての方式で耐故障性の向上がない。Duplex 方式では, 故障箇所が検出されていることがわかる。

復旧率が低い場合, これまで提案した 3 つの方法では, 故障の回避が困難である。そこで, タイムスタンプ方式(図 14) を提案する。この方式では, TMR を用いてどのプレーンのニューロンが故障したかの故障箇所の特定を行う。故障と判定されたニューロンは故障を記録する。多数決により, 故障したニューロンと一致した場合, 一致したニューロンを故障と判定し記録する。そのとき, 出力はもう一つのニューロンの出力値を出力とする。出力が 3 つすべて同じで, 故障と判定されているニューロンがあった場合でも, 出力は正常と判断される。

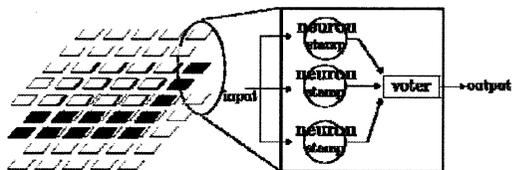
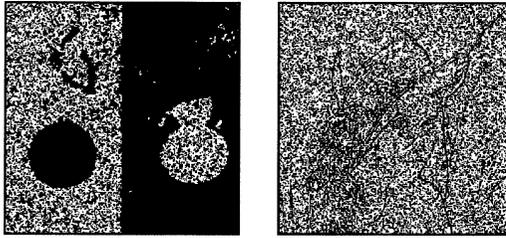


図 14 タイムスタンプ方式

故障率 0.01, 復旧率 0 時のタイムスタンプ方式のシミュレーション結果を図 15 に示す。タイムスタンプ方式を用いることで, 復旧率 0 時でもある程度の故障を抑えることが可能となる。また, 図 16, 17 にタイムスタンプ方式の不一致率を示す。



(a)ノイズ除去 (b)エッジ検出
図 16 タイムスタンプ (故障率 0.01, 復旧率 0)

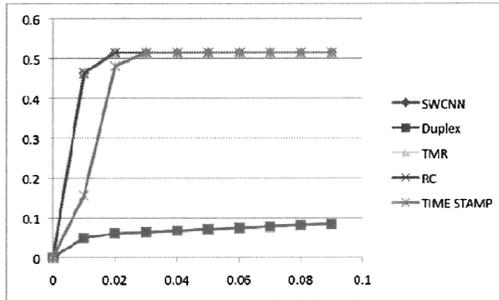


図 17 不一致率 ノイズ除去 (復旧率 0)

ノイズ除去では、Duplex 方式がもっとも故障の回避が行われている。次にタイムスタンプ方式を用いることで、故障率が低い時、不一致率を大幅に減らすことができた。しかし、故障率が高くなると方式 TMR、信頼評価カウンタ方式と変わらなくなっている。復旧率 0 時において、TMR、信頼評価カウンタ方式では、SWCNN と比較しても効果がないということがわかった。

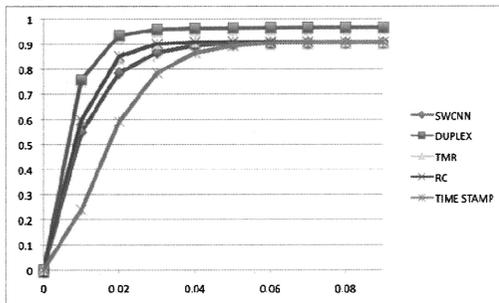


図 17 不一致率 エッジ検出 (復旧率 0)

エッジ検出では、ノイズ除去とは逆に Duplex 方式が最も故障に弱い結果となった。これは、Duplex 方式が、故障箇所を隔離し、出力に入力値を利用したためである。タイムスタンプ方式を用いることで、故障率が低い場合、不一致率を低下させることが可能である。しかし、故障率が高くなると、他の方式と変わらない結果となった。

5. まとめ

本研究では、一時故障における耐故障化 SWCNN の評価を行った。また、一時故障のモデルとして、復旧率を導入してシミュレーションを行った。しかし、多重化や信頼カウンタを用いた方法では、復旧率が低い場合、耐故障性の向上は見込めない。そこで、タイムスタンプ方式を提案し、評価を行った。タイムスタンプ方式を用いることで復旧率の低い場合でも耐故障性の向上が得られた。

参考文献

- [1] L. O. Chua, and et. al., "Cellular Neural Networks: Theory", IEEE Transactions Circuit and Systems Vol. 35, 10, pp.1257-1272
- [2] K. Tsuruta, and et. al., "Small-World Cellular Neural Networks for Image Processing Applications", European Conference on Circuit Theory and Design, Vol. 1, pp.225-228
- [3] D. J. Watts, and et. al., "Collective dynamics of 'small-world' networks", Nature, 393, pp.440-442
- [4] M. E. J. Newman, "The Structure and Function of Complex Networks", SIAM Review, Vol. 45, No. 2, pp.167-256
- [5] D. K. Pradhan, "Fault-Tolerant Computing System Design", Prentice Hall PTR.
- [6] Katsuyoshi Matsumoto, Minoru Uehara, and Hideki Mori, "Fault Tolerant Small-World Cellular Neural Networks", In Proceedings of 4th International Symposium on Frontiers in Networking with Applications (FINA2008), pp.168-172
- [7] Katsuyoshi Matsumoto, Hideki Mori, and Minoru Uehara, "Fault Tolerance in Small-World Cellular Neural Networks for Image Processing", In Proc. of 21th International Conference on Advanced Information Networking and Applications Workshops/Symposia 2007, Vol. 1, pp.835-839
- [8] Collins, R.T., et al., "Algorithm for Cooperative Multisensor Surveillance", Proc. IEEE, Vol.89, No.10, pp.1456-1477