

ニューラルネットワークを用いた被疑故障信号線の故障種類推定法

日大生産工(院) ○太田 菜月 日大生産工 細川 利典 明治大学 山崎 浩二
日大生産工 山内 ゆかり 日大生産工 新井 雅之

1. はじめに

半導体微細化技術の進歩に伴い、超大規模集積回路 (Very Large Scale Integrated circuits : VLSI) において、異常動作の物理的な原因を特定する物理的故障解析 (Physical Fault Analysis : PFA) [1]は、歩留まりの向上のために重要である。PFA では、電子顕微鏡などを用いて故障 VLSI 内部の観測を行うため、多大なコストを要する。そのため、故障 VLSI に存在する可能性のある故障 (被疑故障) の数を事前にできる限り絞り込んでおく故障診断[2]が、故障解析コスト低減のために重要となる。故障診断では、故障 VLSI の異常な外部出力応答を裏付けることのできる故障箇所および故障種類を推定する。

組合せ回路やフルスキャン設計された順序回路における単一縮退故障モデルの故障診断は様々な手法が提案されており、被疑故障数も大きく削減できることが報告されている[2]。順序回路の診断でも、故障モデルを縮退故障などに限定すれば、故障シミュレーションを実行することで被疑故障を絞り込むことが可能である[3]。しかしながら、特定の故障モデルに限定した故障診断では、故障 VLSI の異常な外部出力応答を裏付ける故障箇所が存在しない場合や、誤った箇所を被疑故障として診断する可能性がある。それゆえ、特定の故障モデルに限定しない診断法が重要となる。

すべての論理故障を表現できるユニバーサル論理故障モデル[4]を用いた論理故障 VLSI に対する故障診断手法が提案されている。この手法では、レイアウト情報を基に、支配型ブリッジ故障やオープン故障が存在する不良 VLSI モデルを作成し、ユニバーサル論理故障シミュレーション[4]を用いた故障診断法を適用し、その結果、診断解がないものや誤診断が存在しないことが確認されている[5]。しかしながら、この手法では被疑故障信号線の多さや故障種類の推定が不可能なことが課題として残る。

根本的な故障種類の特定は、二次テストで分解能の高い追加テストを用いた場合にのみ可能であることが多く、PFA によって補われる[1]。PFA は、システマティック欠陥のようなレイアウトに依存する欠陥やその位置を特定するアプローチを基に故障種類の特定を行う。それにも関わらず、故障によって引き起こされる誤った振舞いの正確な論理モデルの不足は、この分析を複雑化する。故障の活性化や検出は物理学的なものや設計のトポロジー因子に依存し、それらは予測不可能なものも存在する。

人口ニューラルネットワーク (Artificial Neural Network : ANN) は、人間の脳内神経回路網を模した数理モデルであり、ANN を多層にして用いることで、データに含まれる特徴を段階的に深く学習することができる。それゆえ、テストの結果と故障メカ

ニズムを関連づける予測可能なルールを基にしたパラメトリックな故障種類推定では判定しきれない故障種類の推定は、ANN のアプローチに最適である[5]。

本論文では、文献[4]の手法を用いて絞り込まれた被疑故障信号線に対し、ANN を用いた故障種類推定手法を提案し、評価する。提案手法では、各被疑故障に対して主要な論理故障モデルである縮退故障、支配型ブリッジ故障、オープン故障を表すそれぞれの特徴量を求め、ANN を用いて、それらから故障種類の推定を行う。

第 2 章ではユニバーサル論理故障診断法について述べる。第 3 章ではニューラルネットワークについて述べる。第 4 章ではニューラルネットワークを用いた故障種類推定法について述べる。第 5 章では実験結果について述べる。最後に第 6 章では、結論と今後の課題について述べる。

2. ユニバーサル論理故障診断法

2.1 ユニバーサル論理故障モデル

本論文では、論理関数を変化させる論理故障を特に分類せず、ゲートの故障をまとめて取り扱う。なお、スキャンテストのキャプチャモードに複数サイクル間の順序動作を組み込んだマルチサイクルキャプチャテスト[6]の故障診断では、被検査回路を時間展開して考えるため、単一故障であっても複数の時刻で誤りが生じ得る。本論文では、マルチサイクルキャプチャテストの時間展開数 k の各時刻における故障励起の有無に基づいて故障をモデル化する。この故障モデルをユニバーサル論理故障モデルと呼ぶ。

図 1 及び表 1 に、3 サイクルキャプチャテストの場合のユニバーサル論理故障モデルの例を示す。表 1 は、ある信号線 n に対し、各時刻で誤りが生じるときを F 、生じないときを P で示している。例えば表 1 の誤り 4 は、1 時刻目に信号線 n の値が期待値と異なる値をとり、2 時刻目、3 時刻目では期待値と等しい値をとることを表している。

表 1 より、 k サイクルキャプチャテストの場合、ある信号線 n に対して、誤りが現れる時刻の組合せは、 $2^k - 1$ 通りであることがわかる。本論文の診断手法では、この $2^k - 1$ 通りの組合せすべてに関して振舞いをシミュレーションする。

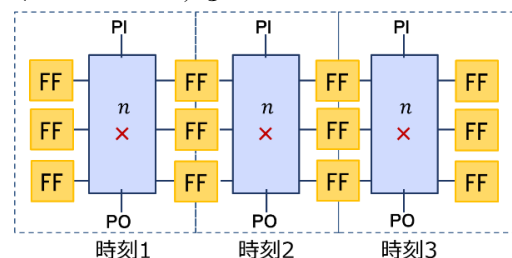


図 1. ユニバーサル論理故障モデル概念図($k = 3$)

An Estimation Method of a Defect Types
for Suspected Fault Lines in Logical Faulty VLSI Using Neural Networks

Natsuki OTA, Toshinori HOSOKAWA, Kouzi YAMAZAKI, Yukari YAMAUCHI and Masayuki ARAI

表 1. ユニバーサル論理故障モデルの動作($k = 3$)

時刻	1	2	3
誤り1	P	P	F
誤り2	P	F	P
誤り3	P	F	F
誤り4	F	P	P
誤り5	F	P	F
誤り6	F	F	P
誤り7	F	F	F

2.2 ユニバーサル論理故障モデルを対象とした故障シミュレーション法

ユニバーサル論理故障モデルを対象とした故障シミュレーション法では、フェイルパターンのみを用いて故障診断を行う。パスパターンを診断に用いない理由は、単一ユニバーサル論理故障モデルでは故障の励起条件が不明であるため、パステストでの故障の励起の有無を判断できないためである。

本論文では、任意の論理故障を対象とした故障診断を行う。単一ユニバーサル論理故障に故障シミュレーション法を適用するには、図 4 と表 1 で示したような、考えるすべての誤りの組合せについて故障シミュレーションを実行し、外部出力のシミュレーション値と観測値を比較する。すべてのフェイルテストに関して両者が完全に一致したものを被疑故障とする。

表 2 に、3 サイクルキャプチャテストにおける、ある信号線 n , m に関する故障診断の例を示す。表 2 の $ft1$, $ft2$ はフェイルテストを示しており、 n , m の列は $ft1$, $ft2$ の故障シミュレーション値を、観測値の列は $ft1$, $ft2$ を印加したときの観測値を示す。 $ft1$ を印加した際、信号線 n , m は共に観測値を説明できる誤り動作が存在するので、続いて $ft2$ の故障シミュレーションを実行する。 $ft2$ を印加した際、信号線 n においては誤り動作 FPP が観測値を説明できるが、信号線 m は観測値を説明できない誤り動作が存在しない。それゆえ、信号線 n において、 $ft1$ で誤り動作 FPP として振る舞い、 $ft2$ で誤り動作 FPP として振る舞う論理故障と、 $ft1$ で誤り動作 FPP として振る舞い、 $ft2$ で誤り動作 FPP として振る舞う論理故障が被疑故障と判定される。したがって、信号線 n は被疑故障信号線と判定される。

ユニバーサル論理故障モデルを対象とした故障シミュレーション法は、論理故障 VLSI に対して誤診断をすることはなく、診断時間が長くなる。したがって、本手法では文献[7]と同様に、前処理として誤り経路追跡法[8]によって被疑故障集合を絞込んでから故障シミュレーション法を実施することで、高速かつ高精度な故障診断を行う。

表 2. ユニバーサル論理故障診断例($k = 3$)

動作	時刻			n		m		観測値	
	1	2	3	ft1	ft2	ft1	ft2	ft1	ft2
動作1	P	P	F	01	01	11	10	00	11
動作2	P	F	P	11	10	01	10		
動作3	P	F	F	10	01	10	01		
動作4	F	P	P	00	11	01	00		
動作5	F	P	F	11	01	00	01		
動作6	F	F	P	00	00	00	00		
動作7	F	F	F	11	11	11	10		

3. ニューラルネットワーク

人工ニューラルネットワーク(Artificial Neural Network: ANN)は、神経細胞を模した人工ニューロン(ノード, ユニット)がシナプスを模した結合荷重によりネットワークを形成し、学習によってシナプスの結合強度を変化させる生物の神経回路網から着想を得た機械学習の数理モデルを指す。ANN は、人間の専門家やその他の計算技術では複雑すぎて検出することのできないデータの傾向や構造を検出することができる。提案手法で用いる教師あり学習では、入力信号に対して教師信号(正解)が与えられ、出力誤差を減少させる。また、分類とは、特定のパターンの特徴を基に特定のカテゴリ、つまり特定の故障モデルに分けることを指す。

本節では、文献[9]に基づいて分類のための教師あり学習という観点から、ANN の構造や学習方法について説明する。

3.1. 構造と順伝播

ANN は、人工ニューロン(ノード, ユニット)と呼ばれる多数の処理要素によって形成される。それぞれのノードは、有向エッジによって他のノードに接続され、エッジには重みが付けられる。

また、ANN のネットワーク構造は層で構成されており、各層は $l-1$ 層と $l+1$ 層に接続される。層間においてすべてのノードが完全に接続している構造を全結合型と呼び、これは l 層のすべてのノードが、 $l-1$ 層のすべてのノードを先行ノードとして持ち、 $l+1$ 層のすべてのノードを後続ノードとして持つことを意味する。本論文では、全結合型のネットワークを用いる。

図 2 に本論文で用いるニューラルネットワークの構造を示す。層には入力層、隠れ層、出力層の 3 種類がある。入力層は 1 つの特徴量につき 1 つのノードがあり、特徴量として与えられた値がそのまま伝搬される。隠れ層は非線形のデータに分類する際に必要であり、層の数、及びノードの数に決まりはない。また、Tanh 関数を活性化関数として用いて伝搬する値が計算される。したがって、本論文で用いる隠れ層の活性化関数は式(1.1)および、式(1.2)のように計算される。

$$f(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (1.1)$$

$$x = A_{l-1} * W_l^T \quad (1.2)$$

式(1.2)において、 A_{l-1} は前の層の出力を表し、 W_l は重み行列を表す。このとき、行列のサイズは前の層のノード数と等しい。

出力層は分類する故障モデルの数だけノードがあり、活性化関数として式(2)に示すソフトマックス関数を用いる。

$$y_k = e^{x_k} / \sum_{i=1}^N e^{x_i} \quad (2)$$

式(2)において、 y_k は出力層の k 番目のノードの出力を、 N は出力層のノード数を、 e^{x_i} は前の層の i 番目のノードの出力を表す。このとき出力 y_k は $0 \leq y_k \leq 1$ を満たすため、出力値を確率ベクトルとして変換して考えることができる。出力層の各ノードの出力の中で、最も大きな値を出力したノード(対応する故障モデル)が解として採用される。このように、入力ベクトルを指定して出力を計算する手順を順伝播と呼ぶ。

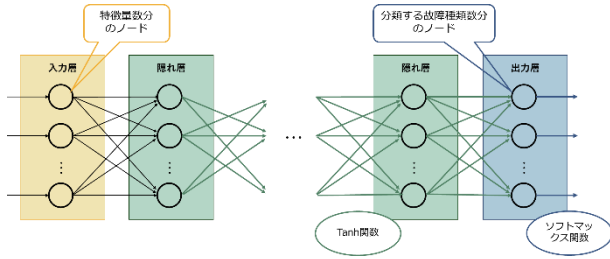


図 2. ニューラルネットワークの構造

3.2. 学習

ANN はノードに付けられた重みを調整することができるため、学習を行う。ANN の学習に使用される訓練データは、(特徴量, ラベル) のペアから構成される大規模な集合で構成され、学習アルゴリズムが最小化しようとする目的関数が定義される。ラベルについては第 4.2 節で述べる。本論文では、学習アルゴリズムとして誤差逆伝搬法 (Back Propagation) [10]を用いる。

誤差逆伝播法は、ANN において出力層ノードの出力と望ましい出力である教師信号との誤差を、複数の層の結合荷重の修正により減少させる学習方法である。誤差逆伝播法は、勾配降下最適化アルゴリズムによって、損失関数の勾配を計算することで、ノード間の結合荷重を調整する。誤差は出力層ノードの出力と教師信号との二乗誤差で計算され、隠れ層を介して入力層に伝播される。

4. ニューラルネットワークを用いた故障種類推定

本提案手法では、事前に行われている故障 VLSI のテストや故障診断から得られた情報を基に故障種類の分類を行う。図 3 に本提案手法の基本構成、入力および出力を示す。製造テストからはフェイルテスト系列を、故障診断からは被疑故障箇所およびそれらの検出情報や隣接信号線の情報を得て、それらを用いて特徴量を求める。1 つの欠陥に対する被疑故障信号線が複数得られた場合、すべての被疑故障信号線に対しての特徴量をそれぞれ求める。

また、本提案手法のアルゴリズムは大きく分けて、step1 の特徴量の抽出と step2 の ANN を用いた故障種類分類の 2 つに分かれる。故障種類分類は学習済み ANN を含み、ANN の入力として step1 から特徴量を得て、ANN の出力として故障種類を出力する。




図 3. 故障種類分類アルゴリズム

4.1 特徴量

ANN のネットワーク構造や学習と同様に、特徴量選択、及び特徴量抽出は本論文で提案する故障種類推定法の正答率を向上するために非常に重要である。現時点での分類対象の故障モデルは 0 縮退故障、1 縮退故障、支配型ブリッジ故障、オープン故障の論理故障の 4 種類である。

特徴量抽出では、表 1 に示したようなユニバーサル論理故障モデルの動作の P・F 情報 (故障検出情報) を用いて、フェイルテスト系列 $T_f \subset T$ を用いた論理シミュレーションより、以下の値を取得することができる。ただし、 T はテスト系列集合を表す。

1) 0 縮退故障を表す特徴量

式(3)に 0 縮退故障を表す特徴量を求める式を示す。

$$feature_{sa0} = x / (cycle * sequence) \quad (3)$$

x は、P・F 情報の P のときに被疑故障信号線の論理値が 0、もしくは F のときに被疑故障信号線の論理値が 1 である回数、 $cycle$ はサイクル数、 $sequence$ はフェイルテスト系列数を表す。

2) 1 縮退故障を表す特徴量

式(4)に 1 縮退故障を表す特徴量を求める式を示す。

$$feature_{sa1} = x / (cycle * sequence) \quad (4)$$

x は、P・F 情報の P のときに被疑故障信号線の論理値が 1、もしくは F のときに被疑故障信号線の論理値が 0 である回数、 $cycle$ はサイクル数、 $sequence$ はフェイルテスト系列数を表す。

3) 支配型ブリッジ故障を表す特徴量

式(5)に支配型ブリッジ故障を表す特徴量を求める式を示す。

$$feature_{bridge} = x / adjacent \quad (5)$$

x は被疑故障を励起する可能性のある隣接信号線数、 $adjacent$ は、被疑故障信号線の全隣接信号線数を表す。被疑故障を励起する可能性のある隣接信号線とは、全フェイルテスト系列において以下の条件 1、条件 2 をともに満たす時刻が少なくとも 1 つ存在する隣接信号線を指す。

【条件】

1. P・F 情報の P のときに、被疑故障信号線の論理値と等しい論理値を持つ
2. P・F 情報の F のときに、被疑故障信号線の論理値と異なる論理値を持つ

4) オープン故障を表す特徴量

式(6)にオープン故障を表す特徴量を求める式を示す。

$$feature_{open} = x / (cycle * sequence) \quad (6)$$

$cycle$ はサイクル数、 $sequence$ はフェイルテスト系列数を表す。 x は以下の条件 1、条件 2、または条件 3 のいずれかを満たす回数を表す。

【条件】

被疑故障信号線の全隣接信号線において、

1. P・F 情報の P のときに、 $Victim = V_a(|V_{0A}|, |V_{1A}|)$ が成り立つ。
2. P・F 情報の F のときに、 $Victim! = V_a(|V_{0A}|, |V_{1A}|)$
3. P・F 情報の F のときに、 $|V_{0A}| = |V_{1A}|$ が成り立つ

ただし、 $Victim$ は被疑故障信号線の論理値 ($\in \{0,1\}$)、 $|V_{0A}|$ は隣接信号線集合 A のうち論理値が 0 である信号線数、 $|V_{1A}|$ は隣接信号線集合 A

のうち論理値が0である信号線数,

$V_a(|V0_A|, |V1_A|)$ は $|V0_A| > |V1_A|$ のとき0を返し,
 $|V0_A| < |V1_A|$ のとき1を返し, それ以外のときは不定値を返す関数である.

4.2 出力符号化

本論文では, 論理故障の故障種類を0縮退故障, 1縮退故障, 支配型ブリッジ故障, オープン故障の4つに分類する. 出力は, 分類する故障モデル数の長さのベクトル $[y_0, y_1, y_2, y_3]$ ($y_0, y_1, y_2, y_3 \in \{0,1\}$)として符号化される. y_0 は0縮退故障のラベル値, y_1 は1縮退故障のラベル値, y_2 は支配型ブリッジ故障のラベル値, y_3 はオープン故障のラベル値を表す. 訓練データの場合, ラベルの値は既知の値であり, 教師信号として, 分類したい故障モデルを表すノードのラベルを1に, その他のノードのラベルを0に設定する. 分類したい故障モデルが支配型ブリッジ故障の場合, 教師信号は $[0,0,1,0]$ に設定され, オープン故障の場合 $[0,0,0,1]$ に設定される.

5. 実験結果

本故障種類推定法の有用性を示すためにRTLベンチマーク回路のMULを用いた実験結果を示す. 本実験は, ユニバーサル論理故障診断法[4]を用いて絞り込まれた被疑故障信号線に対し, ANNを用いた故障種類推定手法を適用する. また, 主要な論理故障モデルである0縮退故障, 1縮退故障, 支配型ブリッジ故障, またはオープン故障を分類対象とする. ANNの入力データである特徴量は, 全データの70%を訓練データ, 残りの30%をテストデータとする. このとき, データの振分けはランダムに行う.

表3に, 隠れ層の層数を2層, ノード数を9つに固定して実験を行った際の実験結果を示す. 「Recall」は再現率, 「Accuracy」は正解率を表す. 再現率とは, 答えがAであるもののうち, 正しくAと推測されたものの割合を指す. 正解率とは, 全予測に対する正答率を表す.

表3. 故障種類推定結果

	y'_0	y'_1	y'_2	y'_3	Recall
$y = 0 : sa0$	260	6	17	17	0.8666
$y = 1 : sa1$	0	200	66	34	0.6666
$y = 2 : bridge$	44	6	173	77	0.5766
$y = 3 : open$	49	2	167	82	0.2733

Accuracy : 52.96%

表3より, 故障種類の答えが0縮退故障であるときに1縮退故障と推定されたものや, 答えが1縮退故障のときに0縮退故障と推定されたものの割合が低いことが分かる. したがって, 0縮退故障と1縮退故障の特徴の相違点は正しく学習されたと考えられる. しかしながら, 答えが支配型ブリッジ故障, およびオープン故障であるときの推定結果はばらつきがあり, 再現率も低い. これより, 支配型ブリッジ故障やオープン故障の特徴は抽出できなかったことが分かる. これは, ANNの入力データである特徴量の種類が少なすぎたことや, 支配型ブリッジ故障やオープン故障を表すは特徴量で, それらの故障モデルの特徴を表せていなかったことが原因と考えられる.

6. おわりに

本論文では, ユニバーサル論理故障診断法[4]を用いて絞り込まれた被疑故障信号線に対し, ANNを用いた故障種類推定手法を提案した. RTLベンチマーク回路のMULを用いた実験では, 正解率52.96%という結果となった. 提案手法では, 0縮退故障と1縮退故障の特徴の相違点は正しく学習されたものの, 支配型ブリッジ故障やオープン故障の特徴は抽出できなかったため, 今後の課題として, ANNの入力データである特徴量に隣接信号線のみの特徴やゲートを考慮した特徴を加え, 被疑故障信号線とその周りの信号線の関係をより細かく表現できる特徴量を求めることが挙げられる.

参考文献

- [1] S.-Y. Liu, Y.-C. Hou, C.-C. Chang, and J.-C. Lin, "Sige profile inspection by using dual beam fib system in physical failure analysis", in 20th IEEE Int'l Symposium on the Physical and Failure Analysis of Integrated Circuits, 2013 (IPFA'13), July 2013, pp. 490–492.
- [2] H.Y.Chang, E.Manning and G.Metze, Fault Diagnosis of Digital Systems, Computing and Information Sciences, 1970.
- [3] Ismed Hartanto, Srikanth Venkataraman, W. Kent Fuchs, Elizabeth M. Rudnick, Janak H. Patel, Sreejit Chakravarty, "Diagnostic simulation of stuck-at faults in sequential circuits using compact lists," ACM Transactions on Design Automation of Electronic Systems (TODAES), pp.471-489, Volume 6, Issue 4, October 2001.
- [4] H. Takano, T. Hosokawa, H. Yamazaki and K. Yamazaki, "A Fault Diagnosis Method for a Single Universal Logical Fault Model Using Multi Cycle Capture Test Sets," Proc 16th IEEE Workshop on RTL and High Level Testing (WRTL'15), pp74-79, Nov 2015.
- [5] C. M. Bishop, Pattern Recognition and Machine Learning (Information Science and Statistics). Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006.
- [6] J.Abraham, U.Goel and A.Kumar, "Multi-cycle sensitizable transition delay faults," VLSI Test Symposium, pp.306-313, 2006.
- [7] 山崎浩二 山田輝彦, 誤り経路追跡と故障シミュレーションを用いた順序回路における単一故障の診断法, 電子情報通信学技報 FTS97-68, 1997-12
- [8] 山田輝彦 中村芳行, 組合せ回路における単一縮退故障の一診断法, 電子情報通信学会論文誌, 1991.
- [9] L.R.Gómez and H.-J.Wunderlich, "A Neural-Network-Based Fault Classifier", IEEE 25th Asian Test Symposium, 2016.
- [10] P.J.Werbos, "Beyond regression: New tools for prediction and analysis in the behavioral sciences", Ph.D. dissertation, Harvard University, department of Applied Mathematics, 1974.