

強化学習を用いた FFR 活性化率指向テスト生成法

日大生産工 (学部) ○土田 晨人 日大生産工 細川 利典
京産大 吉村 正義

1 はじめに

近年, 超大規模集積回路 (Very Large Scale Integrated circuits : VLSI) の大規模化, 複雑化が進んでいる. これに伴い, VLSI テストにおいて検出困難な欠陥が増加している. そのため, 様々な欠陥を検出できるテストパターンの生成が必要になっている.

VLSI 中に存在する様々な欠陥を検出するためには, その欠陥箇所から外部出力や疑似外部出力である観測点までの経路が活性化されるテストパターンが必要になる. できるだけ多くの経路を活性化することで, 様々な欠陥を検出できる可能性が高まる.

様々な欠陥をモデル化した複数の故障モデルに対してテストパターンを生成することは, テストパターン増大の観点から現実的でない.

本論文では, 強化学習を用いたファンアウトフリー領域 (Fanout Free Region : FFR) 活性化率指向テスト生成法について提案する. 本手法では, 強化学習を用いて活性化経路の多いテスト集合を生成し, 様々な欠陥を検出することを目的とする.

本論文の構成は以下の通りである. 第 2 章で経路活性化について説明する. 第 3 章で強化学習を用いた FFR 活性化率指向テスト生成法を提案する. 第 4 章で実験結果を示す. 第 5 章でまとめと今後の課題について述べる.

2 経路活性化

本論文では, 組合せ回路を FFR 分割する. 2.1 節で FFR 分割について説明し, 2.2 節で FFR の入力信号線の活性化を定義する. 2.3 節で FFR_i - j 活性化率について定義する. 本論文では, 疑似外部出力を特に区別せずに単に外部出力と表記する.

2.1 FFR 分割

FFR 分割¹⁾とは, 組合せ回路を分岐のない領域ごとに分割することである. 図 1 に回路を FFR 分割した例を示す. 図 1 の回路の場合, FFR は三つに分割される.

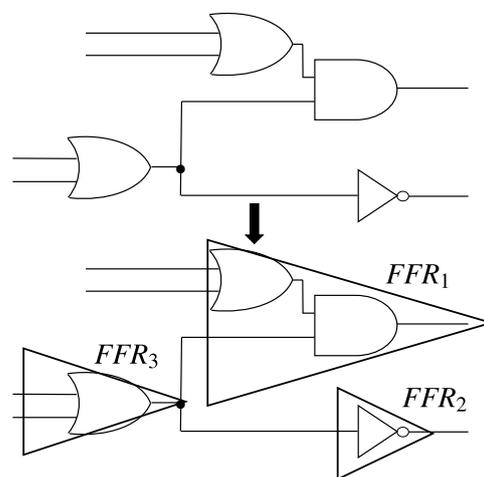


図 1 FFR 分割

2.2 FFR の入力信号線活性化

本節では, FFR の入力信号線の活性化について定義する.

定義 1 ある FFR_i の出力信号線から出力方向に到達可能な FFR を FFR_i から到達可能な FFR と定義する.

定義 2 FFR_i の入力信号線 j から FFR_i の出力信号線までの経路に対する経路外の入力の値がすべて経路上のゲートの非制御値であるか, または, 経路外の入力が存在しないとき, なおかつ以下の条件のいずれかを満たすとき, FFR_i の入力信号線 j が活性化されていると定義する.

条件 1 FFR_i の出力信号線が外部出力である.

条件 2 FFR_i の出力から任意の外部出力までの少なくとも 1 本の経路において, その経路上に存在するすべての FFR の入力信号線が活性化されている.

図 2 に活性化する FFR の入力信号線の例を示す. 図 2 において, 信号線 h, i は外部出力である. 図 2 の場合, まず FFR_1 の入力信号線 f から FFR_1 の出力信号線までの経路に対する経路外の入力の値がすべて経路上のゲートの非制御値であり, FFR_1 の出力信号線 h は外部出力であるため, FFR_1 の入力

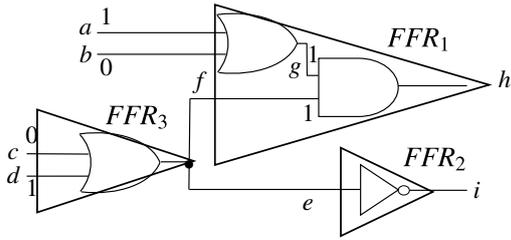


図2 活性化 FFR 入力信号線の例

信号線 f は活性化されている (条件 1). FFR_3 の入力信号線 d は, 経路外の入力の値が非制御値かつ, $FFR_3 \rightarrow FFR_1 \rightarrow$ 外部出力 h の経路と $FFR_3 \rightarrow FFR_2 \rightarrow$ 外部出力 i の経路とも経路上の FFR の入力信号線が活性化されているので, FFR_3 の入力信号線 d は活性化されている (条件 2).

2.3 FFR_i - j 活性化率

本節では, FFR の入力信号線ごとに FFR_i - j 活性化率を定義する. FFR_i - j 活性化率は以下の式 (1) のように表される.

$$FFR_i\text{-}j \text{ 活性化率} = \frac{FFR_i \text{ の入力信号線 } j \text{ を活性化した TP 数}}{\text{印加した TP 数}} \times 100 \quad (1)$$

式 (1) において, TP 数はテストパターン数を表す. FFR_i - j 活性化率は, 印加したテストパターン数のうち, FFR_i の入力信号線 j を活性化したテストパターン数の割合を表している.

3 強化学習を用いた FFR 活性化率指向テスト生成法

本章では, 強化学習を用いた FFR 活性化率指向テスト生成法を提案する. 3.1 節で FFR の重み付けについて説明する. 3.2 節で提案手法で用いる強化学習の構成について説明する. 3.3 節で提案手法のアルゴリズムについて説明する.

3.1 FFR の重み付け

提案手法では, まず, 後述する強化学習の報酬設定のために, 各 FFR の入力信号線ごとに重み付けを行う. テスト生成対象回路に, ランダムに生成したテストパターンを印加し, FFR_i - j 活性化率を計算する. FFR_i - j 活性化率の値によって重み付けを行う. 表 1 に重み付けの基準を示す. 表 1 の活性化率において, $x \sim y$ は x より大きく y 以下であることを表す. 例えば FFR_i の入力信号線 j の活性化率が 0.4 である場合は, FFR_i の入力信号線 j の重みは 60 となる.

表 1 重み付けの基準

活性化率	重み
0.0	100
0.0 ~ 0.1	90
0.1 ~ 0.2	80
0.2 ~ 0.3	70
0.3 ~ 0.4	60
0.4 ~ 0.5	50
0.5 ~ 0.6	40
0.6 ~ 0.7	30
0.7 ~ 0.8	20
0.8 ~ 0.9	10
0.9 ~ 1.0	1

表 2 強化学習の構成

エージェント	テスト生成プログラム
状態	外部入力の論理値割当て状態
行動	外部入力の論理値を変化させる
報酬	FFR_i - j 活性化率が 0 の FFR 入力信号線を活性化 → 大きな正の報酬 活性化された FFR 入力信号線の重みの合計が閾値以上 → 小さな正の報酬

3.2 強化学習の構成

表 2 に提案手法で用いられる強化学習の構成を示す.

エージェントはテスト生成プログラムである. 本プログラムは, ランダムなテストパターンでの活性化率が 0% であった FFR の入力信号線の活性化率を 0% より大きい値にすることを第一の目的とする. また, FFR_i - j 活性化率の平均値の向上を第二の目的とする.

エージェントの行動は, 初期テストパターンとしてあらかじめ割当てられた外部入力の論理値を変化させる. 初期テストパターンは 3.1 節のランダムテストパターンを用いる. この初期テストパターンが割当てられた状態を初期状態とする. 図 3 に初期状態の例を示す. 図 3 では, 初期テストパターンとして $(a, b, c, d, e) = (0, 0, 1, 0, 1)$ が割当てられている. この状態では FFR_1 の入力信号線 g , FFR_2 の入力信号線 c , FFR_3 の入力信号線 j , FFR_3 の入力信号線 e が活性化されている.

図 4 に図 3 の状態から信号線 c の論理値を 0 にするという行動をとった場合の例を示す. 行動の結果, テストパターンが $(a, b, c, d, e) = (0, 0, 0, 0, 1)$ に変化する. この状態では FFR_1 の入力信号線 g , FFR_2 の入

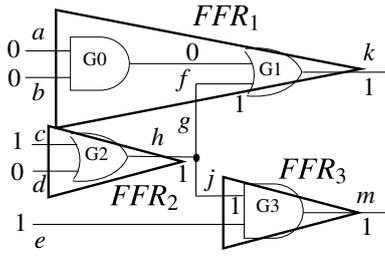


図3 初期状態の例

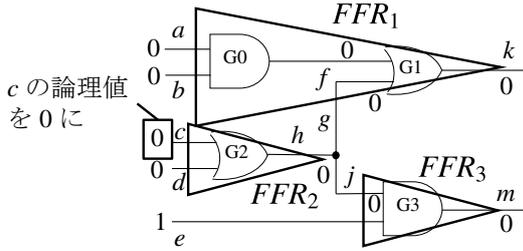


図4 行動の例

力信号線 c , FFR_2 の入力信号線 d , FFR_3 の入力信号線 j が活性化されている。この状態での各 FFR の活性化の状況を観測し、報酬を算出する。報酬算出の条件は以下の 3 種類存在する。

ケース 1 3.1 節でのランダムパターンで活性化率が 0% である FFR の入力信号線が活性化された場合。

ケース 2 活性化された FFR の重みの合計が閾値以上である場合。

ケース 3 ケース 1 とケース 2 の両方の条件を満たす場合。

ケース 1 の条件を満たす場合、大きな正の報酬を与える。ケース 2 の条件を満たす場合、小さな正の報酬を与える。ケース 3 の条件を満たす場合、ケース 1 とケース 2 の報酬の合計を報酬とする。

本手法では、終了状態が定まらないため、あらかじめ行動回数の上限を設定し、上限に達したときの状態を終了状態とする。

3.3 提案手法のアルゴリズム

提案手法では、強化学習の手法としてモンテカルロ法²⁾を、方策として ϵ -greedy 法²⁾を用いる。図 5 に提案手法のアルゴリズムを示す。

T_{rand} はランダムテストパターン集合、 a は強化学習における行動回数の上限、 e は強化学習におけるエピソード数の上限である。提案手法では、あらかじめランダムテストパターン集合 T_{rand} を生成する。

T_{rand} : Random Test Set

a : Number of Actions

e : Number of Episodes

```

1: procedure RL TEST GENERATION( $T_{rand}, a, e$ )
2:   Set FFR Weight( $T_{rand}$ )
3:   for Each Test of  $T_{rand}$  do
4:      $t_{ini} \leftarrow$  Select Initial Test( $T_{rand}$ )
5:     for  $i = 1, 2, \dots, e$  do
6:       Reset Initial State( $t_{ini}$ )
7:       for  $j = 1, 2, \dots, a$  do
8:          $t_{ini} \leftarrow$  Change Logic Value( $t_{ini}$ )
9:          $f \leftarrow$  FFR Activation Observation( $t_{ini}$ )
10:         $r \leftarrow$  Calculate Rewards( $f$ )
11:      end for
12:       $R \leftarrow$  Calculate Total Rewards( $r$ )
13:       $q \leftarrow$  Update Q value( $R$ )
14:    end for
15:     $T \leftarrow$  Test Generation( $q$ )
16:  end for
17:  return  $T$ 
18: end procedure

```

図5 提案手法アルゴリズム

T_{rand} を用いて FFR の重み付けを行う (行 2)。 T_{rand} 内のすべてのテストパターンに対して学習を行う (行 3)。 T_{rand} から強化学習における初期テストパターン t_{ini} を一つ選択する (行 4)。 強化学習のエピソードを e 回繰り返す (行 5)。 まず、 t_{ini} を外部入力に割当て、状態を初期状態にリセットし (行 6)、 a 回だけ行動をとる (行 7)。 t_{ini} の論理値を変化させ (行 8)、 FFR の入力信号線活性化の状況 f を観測する (行 9)。 その結果をもとに報酬 r を計算する (行 10)。 報酬 r をもとに総報酬 R を計算し (行 12)、 Q 値 q を更新する (行 13)。 学習済みの Q 値をもとに、 Q 値が最大になるような行動をとってテスト集合 T を生成する (行 15)。 最後に T をリターンし (行 17)、 処理を終了する。

4 実験結果

本実験では、ランダムに生成されたテスト集合と、提案手法によって生成されたテスト集合で FFR 入力信号線活性化の状況の比較を行った。提案手法の強化学習における行動回数の上限は、対象回路の外部入力信号線数 $\times 30$ 、試行回数の上限は 30 にそれぞれ設定した。対象回路として ISCAS'89 ベンチマーク回路を用いた。

表 3 に実験結果を示す。「ランダムパターン」はランダムに生成されたテスト集合での結果を、「提案手

表 3 実験結果

回路	FFR 入力信号線の総数	ランダムパターン		提案手法	
		平均 FFR_{i-j} 活性化率 (%)	未活性化 FFR 入力信号線数	平均 FFR_{i-j} 活性化率 (%)	未活性化 FFR 入力信号線数
s208	112	18.52	14	24.29	3
s444	263	21.96	2	34.11	1
s713	320	31.73	44	33.31	28
s820	531	4.45	73	6.29	39
s953	535	23.82	85	25.23	34
s1196	666	13.66	69	15.11	29
s1238	729	12.62	99	13.93	59
s1423	766	26.19	9	38.47	8
s1494	847	6.59	11	8.19	21
s5378	2490	32.25	183	32.88	100
s9234	3637	26.28	902	26.62	651

法」は提案手法アルゴリズムによって生成されたテスト集合での結果を表している。「平均 FFR_{i-j} 活性化率」は FFR_{i-j} 活性化率の平均を、「未活性化 FFR 入力信号線数」は FFR_{i-j} 活性化率が 0% であった FFR 入力信号線の数を表す。

未活性化 FFR 入力信号線数に関しては、提案手法がランダムパターンに比べて、多くの回路で 40% 以上の削減率を達成した。しかしながら、s1423, s1494 はその改善が見られなかった。これらの回路では、ランダムパターンで FFR_{i-j} 活性化率が 0% であった信号線の 88% 以上が提案手法では FFR_{i-j} 活性化率が 0% より大きくなった。しかしながら、ランダムパターンで FFR_{i-j} 活性化率が 0% より大きい信号線が提案手法では FFR_{i-j} 活性化率が 0% になったものが存在したため、結果的に未活性化 FFR 入力信号数が削減できなかった。一方、平均 FFR_{i-j} 活性化率は、提案手法はランダムパターンと比較して小規模な回路では向上が見られたが大規模な回路ではあまり変化がみられなかった。本手法では、 FFR_{i-j} 活性化率が 0% である信号線の数減らすことを第一の目的としているため、強化学習の平均 FFR_{i-j} 活性化率に関する報酬は低く設定されている。そのため、大規模な回路では Q 値にその報酬が反映されづらくなり、平均 FFR_{i-j} 活性化率がさほど変化しなかったと考えられる。

5 おわりに

本論文では、強化学習を用いた FFR 活性化率指向テスト集合生成法を提案した。実験結果より、多くの回路で未活性化 FFR 入力信号線数の 40% 以上の削減に成功した。一方、平均 FFR_{i-j} 活性化率は大規

模な回路では 1% 程度の向上にとどまった。

今後の課題として、ランダムパターンで FFR_{i-j} 活性化率が 0 より大きい信号線の FFR_{i-j} 活性化率が 0% にしないように考慮することや、 FFR_{i-j} 活性化率が 0% である信号線数を削減した上で、 FFR_{i-j} 活性化率の平均を向上させていくことが挙げられる。そのために、強化学習の手法や学習回数、報酬設定の方法の見直しが必要であると考えられる。強化学習の手法に関しては、モンテカルロ木探索 (Monte-Carlo Tree Search : MCTS) の利用を検討する。MCTS は囲碁のような手の探索空間が広いゲームで有効であり、初めてプロ棋士に勝利したプログラム AlphaGo³⁾ で利用された。本研究における外部入力への論理値割当ては、 n ビットの外部入力力で 2^n 通りのパターンがあり探索空間が広いいため、MCTS の利用が有効であると考えられる。

参考文献

- 1) K. Taniguchi, H. Fujii, S. Kajihara, and X. Wen, "Hybrid fault simulation with compiled and event-driven methods," *International Conference on Design and Test of Integrated Systems in Nanoscale Technology, 2006. DTIS 2006.*, pp. 240–243, 2006.
- 2) R. S. Sutton and A. G. Barto, "Reinforcement learning: An introduction," *MIT press*, 2018.
- 3) D. Silver, A. Huang, *et al.*, "Mastering the game of go with deep neural networks and tree search," *nature*, vol. 529, no. 7587, pp. 484–489, 2016.