

CNN を使用した LSI レイアウトの不良位置推定法に関する考察 A Note on Failure Prediction Scheme for LSI Layout Images Using CNN

藤田樹[†] 永村美一[†] 新井雅之[‡] 福本聡^{††}
Itsuki FUJITA Yoshikazu NAGAMURA Masayuki ARAI Satoshi FUKUMOTO

1. はじめに

近年デザインルールの微細化に伴い、LSI の集積率は高くなり、LSI 製造に対する信頼性向上は重要性を増している。製造不良を含む LSI チップは、製造後に適用される量産テストによって検出・破棄されるが、コスト、効率、および信頼性向上のため、設計・製造の初期段階において、CAD(Computer Aided Design) データに基づいて不良位置を予測する技術の開発が進められている。特に近年、機械学習を用いた検出・予測手法が注目されている。例として、機械学習を用いたホットスポットの検出が挙げられる。ホットスポットとは、LSI 製造工程のうち回路パターンをチップ上に転写するリソグラフィ工程において、十分な間隔がないことなどから配線の短絡や断線が生じ LSI の動作不良が起こる可能性の高いレイアウトを指す。従来はこれらの解析はシミュレーションに基づいて行われていたが、製品全体の回路を検証する計算負荷は膨大となる。そこで、汎用性が高く比較的計算時間の少ない機械学習の運用が試行されている。文献 1) および 2) では、CNN(Convolutional Neural Network) を用いたホットスポット検出法について提案されている。

本研究では、CAD データから得られる回路レイアウト画像を多数のセグメントに分割し、CNN によって不良位置を含むセグメントを学習・予測する手法について論ずる。配置された複数の論理セルの相互作用により発生するような製造不良の検出を対象としており、ホットスポット検出の場合に対して桁違いに大きいセグメント画像サイズを想定する。不良が発生した LSI を物理的に解析して不良の原因となった回路部分を特定することは高コストなため、事前に準備できる不良位置の情報は希少であるものとする。教師データとして用いる不良位置を擬似的に設定して評価モデルを構築し、希少な不良位置データから効果的に不良位置の予測を可能とする手法と、データが増えたときの学習の変化について検討する。

2. 準備：LSI の構造と製造・不良解析フロー

研究の内容に先立って、LSI についての概要を紹介する。まずはじめに高純度のシリコンインゴットから直径数十 cm ほどの円盤(ウェハ)を切り出し、そのウェハ上に回路パターンを転写していく。このウェハからさいの目状に切り分けられたチップ一つ一つをダイという。

シリコン基盤上に作られたトランジスタなどの素子

は配線層により相互に接続される。近年の大規模かつ複雑な LSI においては、配線層は図 1 に示すとおり多重に積層される。これらの配線層はシリコン基盤に近い方から M1 層、M2 層、M3 層、... という。




図 1: LSI の製造の流れと断面図

通常、LSI は大量生産をされることから、同じ回路レイアウトを持つダイはいくつも作られることになる。製造不良を含むチップはテストパターンの印加による量産テストによって検出されるが、歩留まりや信頼性向上のため、故障解析や物理解析と呼ばれる技術を用いて不良の位置や発生原因を特定することがある。同一の回路レイアウトに基づく LSI を長期にわたり製造した場合、このような希少な不良位置の情報が順次蓄積されていくこととなる。新たに得られた不良データを教師データに加え、再度学習をおこなうことで不良の可能性のあるセグメントを推定する精度が高まることが期待される。

3. 実験概要：CNN に基づく不良位置予測フローと対象データ

本研究では、全体の LSI レイアウト中に、共通するレイアウトの特徴を持つ不良発生の可能性のあるセグメントが散りばめられている状況をモデル化する。モデル化の際は比較的特徴の似ていた M2 層と M3 層の画像を使用した。M2 層のセグメントの集合に M3 層を混ぜ、M2 層を不良を含まないレイアウトと、M3 層を不良を含むある特徴を持ったレイアウトと想定して実験をおこなった。

今回の機械学習で使用したデータの作成方法は以下の通りである。LSI のレイアウトパターンとして、ICCAD-2014³⁾ から配線層(M2, M3 層) データを得た。このレイアウトデータを画像に変換し、そのレイアウトを 23 枚 × 57 枚の合計 1311 枚(これをセグメントとする)に分割し CNN に入力することでレイアウトを解析していく。LSI 製造において同じレイアウトを持つダイが量産されるので、レイアウト単位で考えると不良箇所のデータを複数集めることができ、まとめてそのレイアウトが持つ既知の不良とすることができる。この事前情報を使用することで、全セグメントの中か

[†] 東京都立大学 大学院 システムデザイン研究科, Graduate School of System Design, Tokyo Metropolitan University

[‡] 日本大学 生産工学部, College of Industrial Technology, Nihon University

^{††} 東京都立大学 システムデザイン学部, Faculty of System Design, Tokyo Metropolitan University

ら次に調べるべき場所を順位付けることで調査の対象を絞ることができたり、他のレイアウトパターンを設計する際に不良の危険性を減らすように注意することができる。

そして、引き続き LSI を製造していくと、他のダイでも不良が発生する可能性は十分考えられる。その発生した不良をさらに教師データに加えることで、不良推定の精度を上げられるのかどうかをモデルを使用して検証した。実験では M3 層の画像をランダムに選択して順次不良ありの教師データに追加した。

4. 実験結果

本節ではモデルの実行した際の結果をまとめる。データは 1311 枚ある M2 層のうち 100 枚を、不良がある可能性のあるレイアウトとして M3 層のセグメントに置き換える。その 100 枚のうち 10 枚を既知の不良として教師データとし、残りは不良の可能性を持つが一般のセグメントと混ぜて学習を行う。実際に不良が発生するのは不良の可能性のあるセグメントからのみである。最初の学習に使用する教師データの組み合わせを以下のようにする。

$$(x_0, y_0) = (25, 10). \quad (1)$$

x_0 は不良の可能性のあるセグメントを含む一般の集団から無作為に選ばれた (M2 層 or M3 層) セグメントの枚数、 y_0 は不良発見済みとしたセグメント (M3 層) の枚数である。

さらに、学習を終えるごとに先の 100 枚の M3 層の中から学習で不良発見済とされていないセグメントをランダムに二枚選び y_0 に加えていく。このときの x_0 への操作は以下の式 (2)-(4) を考えた。

$$(x_i, y_i) = (x_{i-1}, y_{i-1} + 2), \quad (2)$$

$$(x_i, y_i) = (x_{i-1} + 2, y_{i-1} + 2), \quad (3)$$

$$(x_i, y_i) = (x_{i-1} + 4, y_{i-1} + 2). \quad (4)$$

ここでの添字 $i (\geq 1)$ は i 回目の学習であることを表す。式 (2) は不良発見済のデータのみを教師データに加え、式 (3) はどちらのクラスにも同じ枚数のデータを加える方法を意味している。式 (4) では一番最初の学習のときの教師データの割合を保つように両クラスに教師データを加えていく。今回は 2.5 倍のデータ量だったので、切り捨てて 2 倍のデータ数を加えた。以上の方法をそれぞれ独立に試行して、データ数の増やし方で差が出るかを検証した。

また、学習には教師データに対して、LSI のレイアウト画像にも効果があると思われる拡大縮小などのデータ拡張⁴⁾を用いてデータ数を増やした。さらに、M2 層と M3 層では長い線の向きが 90° 異なっていたので、全ての M3 層に回転を加えて識別をより困難にしてある。

図 2 に学習の結果を示す。横軸は y_0 へ加えた、新しく発見した不良セグメントの枚数である。縦軸には最初に不良の可能性のあるものとして設定した 100 枚の M3 層から、教師データで使用した y_i 枚のデータを除いた残りのセグメント全てに対して、CNN モデルが出力した予測値の平均を取っている。




図 2: 教師データに加えた不良発見済のセグメント枚数の増加による、不良の可能性のあるセグメントの予測値の平均の変化。

この結果から教師データで使用する不良データ数が増えるにしたがって、事前に不良の可能性があると想定した M3 層データが不良と判定される確率が増加していることがわかる。これは分類結果を用いてダイを解析する際に不良箇所を発見しやすくなることを示している。またデータ数の増やし方については途中まではあまり違いは見られないが、データが増えると両クラスにデータを加えていく方法 (2)(3) は逆にノイズになっていると考えられる。

5. おわりに

本研究では CNN を用いた LSI の不良推定として、レイアウトのうち配線層である M2 層と M3 層を用いてモデルを通して検証を行った。

今後の課題として、実際の不良データを使用して不良箇所を重みをつけたり、使用したデータとは異なるデザインルールを持った LSI レイアウトでの検証や汎化性を高めるような学習を行わせることが考えられる。

参考文献

- 1) Haoyu Yang, Yajun Lin, Bei Yu, and Evangeline F.Y. Young. "Lithography hotspot detection: From shallow to deep learning". *International System on Chip Conference*, Vol. 2017-Sept, pp. 233-238, 2017.
- 2) Kareem Madkour, Sarah Mohamed, Dina Tantawy, and Mohab Anis. "Hotspot detection using machine learning". In *2016 17th International Symposium on Quality Electronic Design (ISQED)*, pp. 405-409. IEEE, 2016.
- 3) R. O. Topaloglu. "iccad-2014 cad contest in design for manufacturability flow for advanced semiconductor nodes and benchmark suite". In *2014 IEEE/ACM International Conference on Computer-Aided Design (ICCAD)*, pp. 367-368, Nov 2014.
- 4) 村川魁, 藤田樹, 永村美一, 福本聡. "CNN を用いた LSI レイアウト画像の分類手法の検討". 信学技法, DC2019-105, pp. 69-74, 2020.