

## U-Net による特徴量増加した傷つきプリント配線板画像の2値化に関する研究

1235070 早川 晋矢 【画像情報工学研究室】

## Study on binarization of scratched printed wiring board images with more features using U-Net.

1235070 HAYAKAWA Shinya 【Image Processing and Informatics Lab.】

## 1 はじめに

多層基板解析の際、基板を上部から除膜し、プリント配線板 (PWB) の画像を撮影して2値化を行う。しかし除膜の際、図1の様に傷や汚れが付着する為、一般的に2値化で使用する大津の2値化だけでは元のパターンを復元することが難しく、人の手で行うのが現状である。

業務効率化の為、筆者らは U-Net 構造 (以降 U-Net モデル) の CNN による2値画像の自動生成手法を提案した [1]。U-Net モデルは特徴量増加したデータセットに対して効果的であったが、モデルの一部が処理時間に対して、2値画像生成に及ぼす影響が低いと考えられた。

そこで本稿においてはモデルの一部を削減し、それによって生じる処理時間と2値画像生成性能の変動について検証したので、その内容を報告する。




図1 導体パターン撮影画像

## 2 関連研究

## 2.1 U-Net

U-Net とは O. Ronneberger ら [2] の医療画像セグメンテーションに用いられた、U型に構成された CNN を示す。ネットワークは収縮部と拡張部にて構成されており、収縮部から同じ特徴マップサイズを持つ拡張部に特徴マップの受け渡しを行う接続が存在する点が特徴的である。これによってネットワークは特徴マップを拡張する際に、エッジの位置などの情報を元に拡張を行う事が可能となる。

## 2.2 pix2pix

U-Net を用いられた研究として、ラベルマップから合成写真の生成や白黒画像の色付けといった、画像の自動生成を行った P. Isola らの研究がある [3]。以降 P. Isola らの手法を pix2pix と呼ぶ。

pix2pix は Generative Adversarial Nets [4] (以降 GAN) の一種である。GAN は画像などのデータ生成を行う Generator と、データの真偽を判定する Discriminator を敵対的に学習を行い、性能を向上させる手法である。

pix2pix ではこの Generator において U-Net の構造を用いた CNN を使用しており、pix2pix の結果から U-Net は画像生成にて適していると言える。

## 3 ネットワークモデル

## 3.1 U-Net モデルの詳細

本稿の検証実験にて用いた U-Net モデルは pix2pix [3] で用いられている Generator を参考に構成した。構築した U-Net モデルの詳細を図2に示す。U-Net モデルは特徴マップの収縮を行う down sampling 8層による収縮部と、拡張を行う up sampling 8層による拡張部の計16層にて構成される。down sampling は stride 2, kernel  $4 \times 4$  の convolution にて収縮が行われ、活性化関数に leaky relu を用いている。up sampling は stride 2, kernel  $4 \times 4$  の transposed convolution にて拡張が行われ、活性化関数に relu を用いている。また up sampling を行う前に、収縮部から特徴マップを受け取り結合を行う。最終層の活性化関数に sigmoid 関数を用い、この値を導電体である白画素の確率としている。その他最初の convolution 層以外に Batch Normalization と、拡張部一部の層に 50% の Dropout を適用している。

## 3.2 比較ネットワーク

U-Net モデルの down sampling 層が続き、up sampling 層に切り替わる境目付近の畳み込み層は出力される特徴量が少なく、処理時間に対して2値画像生成に及ぼす影響が低いと考えられた。

そこで down sampling 層と up sampling 層を同数削




図2 U-Netの構造




図3 比較ネットワーク

減したネットワークを図3の様に構築し、比較を行った。以後 down sampling 層と up sampling 層を共に  $n$  層削減したものを drop  $n$  モデルと呼ぶ。

## 4 検証実験

### 4.1 学習手法

実験を行うにあたって、 $24576 \times 19608$ pixel の PWB 撮影画像を 18 枚使用した。18 枚の画像を学習用 12 枚、テスト用 3 枚、評価用 3 枚に分類し、それぞれの画像をタイル状に並ぶように  $256 \times 256$  にて切り出しを行う。切り出しの際ゼロ画素による整形を行う事で切り出し余りが出ないようにする。これによって学習用 8752 枚、テスト用 2188 枚、評価用 2188 枚とし、学習用、テスト用、評価用を変えてデータセットを 6 つ作成する。そして過学習が確認できる 20 epoch まで学習を行い、テスト画像にて最も 2 値分類の正解率が高かったモデルを採用し、評価用の画像を使い性能を比較した。

また損失関数には 2 値分類で一般的な cross entropy を、最適化アルゴリズムには Adam を用いている。

### 4.2 評価項目

導体パターン解析業務は回路図作成と CAD データ作成を目的として行われる。回路図作成では接続関係が重要であり、2 値画像に断線や短絡が存在しないことが要求される。一方 CAD データ作成では、配線やホールのパターンの正しさも重要となり、2 値分類の正解率も要求される。また業務効率化を進めるために、2 値画像の生成速度も求められ、2 値分類正解率、短絡断線数、画

像生成の処理時間を評価項目とする。

## 4.3 検証結果

検証結果を表 1 と図 4, 5 に示す。層数は down sampling 層と up sampling 層を合わせた総数を示す。2 値分類正解率と短絡断線数は 6 つのデータセットの平均である。処理時間は  $24576 \times 19608$ pixel の PWB 撮影画像 1 枚の入力に対してモデルが処理を終えるまでの時間を計測しており、画像をメモリに読み込む処理や HDD に書き込む処理など、モデルによって左右されない処理は計測から外している。また処理時間は 54 試行の平均である。

結果から drop4, drop5 から大きく劣化する傾向があり、drop3 までは 2 値画像を大きく劣化させずに処理速度を向上することが可能であると言える。

表1 パラメータ数・計算コスト比較

モデル名	層数	2 値分類正解率	短絡断線数	処理時間
U-Net	16	97.447%	475.6	6 分 31.4 秒
drop 1	14	97.429%(-0.018%)	671.4(+195.8)	5 分 4.7 秒(-83.7 秒)
drop 2	12	97.243%(-0.203%)	616.2(+140.6)	4 分 39.0 秒(-112.4 秒)
drop 3	10	97.478%(+0.031%)	569.5(+93.9)	4 分 19.7 秒(-131.7 秒)
drop 4	8	96.751%(-0.696%)	665.6(+190)	3 分 43.0 秒(-168.4 秒)
drop 5	6	96.707%(-0.740%)	1046.1(+570.5)	2 分 57.9 秒(-213.5 秒)
drop 6	4	96.586%(-0.861%)	1903.2(+1427.6)	2 分 11.8 秒(-259.6 秒)




図4 正解率と処理時間




図5 短絡断線と処理時間

## 5 結論

本稿は [1] にて提案した U-Net モデルの内、重要度の低い箇所を削減し、処理速度について検証した。結果として多少の劣化と引き換えに処理速度を向上できることが確認できた。多少の劣化を許容できる環境下で、多数の画像を処理する状況などで有用である。

## 参考文献

- [1] 早川晋矢, 栗原徹, “深層学習による傷付きプリント配線板画像の 2 値化”, SSII, IS1-22, パシフィック横浜, 06/10-12, 2020.
- [2] Olaf Ronneberger, Philipp Fischer, and Thomas Brox “U-Net: Convolutional Networks for Biomedical Image Segmentation” Olaf Ronneberger, Philipp Fischer, Thomas Brox, in MICCAI 2015, pp 234-241, (2015)
- [3] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, Alexei A. Efros “Image-to-Image Translation with Conditional Adversarial Nets”, in CVPR 2017, pp.1125-1134 (2017).
- [4] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, “Generative adversarial nets”, in NIPS 2014, <https://papers.nips.cc/paper/5423-generative-adversarial-nets.pdf>, (2014)