

令和 2 年度
修士学位論文

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

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

1235070 早川 晋矢

指導教員 栗原 徹

2021 年 2 月 5 日

高知工科大学大学院 工学研究科 基盤工学専攻
情報学コース

要 旨

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

早川 晋矢

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、一部難易度の高い特徴に対して導体パターンが潰れていた。

そこで本研究では、PWB 撮影画像の RGB 特徴だけでなく、PWB 撮影画像から大津の 2 値化にて大まかな導体パターンを抽出し、RGB と導体パターンを入力とすることを行った。

実験の結果、配線パターンを組み合わせた場合、RGB のみの場合比べ、短絡断線が大きく減少することを確認出来たので、その内容を報告する。

キーワード 深層学習, U-Net, PWB, 2 値化, 画像の傷除去

Abstract

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

Shinya HAYAKAWA

When analyzing a multilayer board, the board is removed from the top, and an image of the printed wiring board (PWB) is taken and binarized. However, since scratches and dirt adhere to the film during film removal, Otsu's binarization, which is generally used for binarization, is used. It is difficult to restore the original pattern by itself, and the current situation is that it is done manually.

To improve work efficiency The authors proposed an automatic generation method of binary images by CNN with U-Net structure [1]. The U-Net model was effective for datasets with increased features, The wiring pattern was crushed for some of the difficult features.

Therefore, in this research, not only the RGB information of PWB captured images, but also A rough wiring pattern is extracted from the PWB image by binarizing Otsu. We used RGB and wiring patterns as inputs.

As a result of the experiment, when the wiring patterns are combined, Since it was confirmed that the short-circuit disconnection was greatly reduced compared to the case of only RGB, I will report the contents.

key words Deep learning, U-Net, PWB, Binarization, Scratch removal of image

目次

第 1 章	はじめに	1
1.1	背景と目的	1
1.2	2 値化の障害となる PWB 撮影画像の特徴	2
1.3	論文構成	3
第 2 章	関連技術	4
2.1	大津の 2 値化	4
2.2	畳み込みニューラルネットワーク (CNN)	4
2.3	U-Net	6
2.4	pix2pix	6
第 3 章	2 値分類・欠損復元に関する研究	7
3.1	劣化文書からの 2 値分類	7
3.2	画像の欠損補完	8
3.3	劣化前の画像生成	9
第 4 章	提案手法	12
4.1	使用ネットワークモデル	12
4.2	導体パターンの生成	14
4.2.1	特徴量増加データセットの問題点	14
4.2.2	導体パターンの生成手法	16
4.3	学習方法	18
第 5 章	実験結果	19
5.1	評価方法	19

目次

5.1.1	導体パターンの2値画像に対する評価項目	19
5.1.2	モデルのサンプリング条件と評価方法	19
5.2	検証結果	20
5.2.1	各手法の比較	20
5.2.2	2値分類正解率の推移	21
5.2.3	出力結果例	22
第6章	結論	24
	謝辞	25
	参考文献	26

目次

1.1	PWB 撮影画像特徴	2
1.2	導体パターン撮影画像	2
2.1	畳み込み処理	5
3.1	Calvo-Zaragoza らによるネットワーク (出典 [7])	8
3.2	文書の 2 値分類結果 (出典 [7])	8
3.3	Sasaki らによるネットワーク ([11] を元に作成)	9
3.4	線画の復元結果 (出典 [11])	9
3.5	劣化文書の定式化 (出典 [12])	10
3.6	DeepOtsu のネットワーク構造 (出典 [12])	10
3.7	DeepOtsu のネットワーク構造 (出典 [12])	11
4.1	U-Net モデルの構造	13
4.2	撮影画像 A におけるヒストグラム	15
4.3	撮影画像 B におけるヒストグラム	15
4.4	撮影画像 A に対する入力 RGB のみ U-Net モデルの出力例	16
4.5	撮影画像 B に対する入力 RGB のみ U-Net モデルの出力例	16
4.6	撮影画像の縁にある導体パターンに影響しない領域	17
4.7	図 4.5 の撮影画像に対する大津の 2 値化	17
5.1	テスト画像における 2 値分類正解率推移	21
5.2	評価画像における 2 値分類正解率推移	22
5.3	評価画像における 2 値分類正解率推移	23

表目次

4.1 U-Net モデルの詳細	13
5.1 深層学習による評価結果	20
5.2 大津の 2 値化による結果	21

第 1 章

はじめに

1.1 背景と目的

電子機器に使用される基板には絶縁体の表面に銅などの導電体を張り付け導電パターンを形成する、プリント配線板 (PWB) が使用される。一見すると 1 枚の板にしか見えない PWB だが、外から目視できない導電パターンを持つ中間層が多数存在し、薄いものでは層間厚さ 10 μ m 以下も存在する。

この PWB を、自社技術に対する特許侵害の検査や喪失した回路図の復元を目的に解析されることがあるが、それには中間層にも存在する、全ての導電パターンを解析する必要がある。実際に行われている導電パターン解析業務の 1 つとして、X 線で構造を解析したのち、部品を取り除き、薄い層間を 1 層毎に除膜を行うことで中間の導体パターンを撮影する解析が行われる。これを 2 値化によって導体パターンを画像として出力することで解析を進めて行くが、この際導体パターン撮影画像には図 1.1 の様に、上部を除膜した際の傷や汚れが多数付着しており、一般的に 2 値化で使用する大津の 2 値化だけでは元のきれいな PWB の導電パターンを復元する事が難しいため、現状は人の手による 2 値画像の修正を行っている。

本研究は PWB を解析する際に必要となる導体パターンを示す 2 値画像を、深層学習にて自動的に生成させることで、基盤解析の効率化を行うことを目的として行われた。

1.2 2 値化の障害となる PWB 撮影画像の特徴

1.2 2 値化の障害となる PWB 撮影画像の特徴

図 1.1 の様に PWB 撮影画像には上部を削った際に傷や汚れが多数付着しており、仮に大津の 2 値化をした際に、接続関係を狂わせ断線を生み出す要因となっている。また擦れたような歪みによって、配線の太さなどのパターンを構成するのに必要なきれいな境界を構成することができないといった問題が存在する。こういった傷や汚れ、歪みを取り除き、元のパターンを復元し、解答画像のような 2 値画像を自動生成することを目的とする他、図 1.2 の様に、色や形状に複数の特徴を持つ為、これら幅広い特徴に対応できることも目的とする。

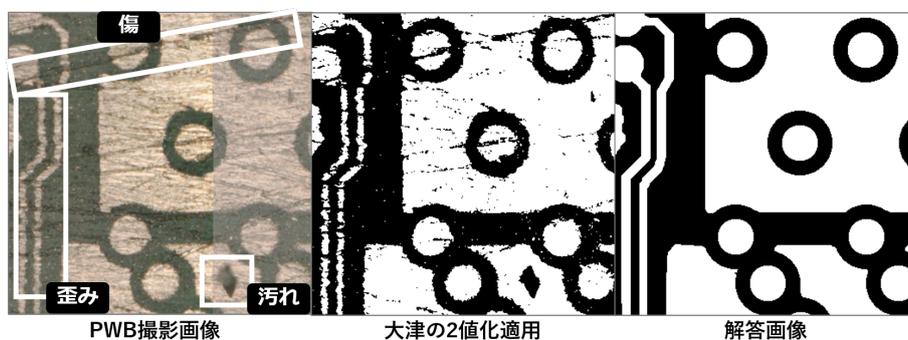


図 1.1 PWB 撮影画像特徴

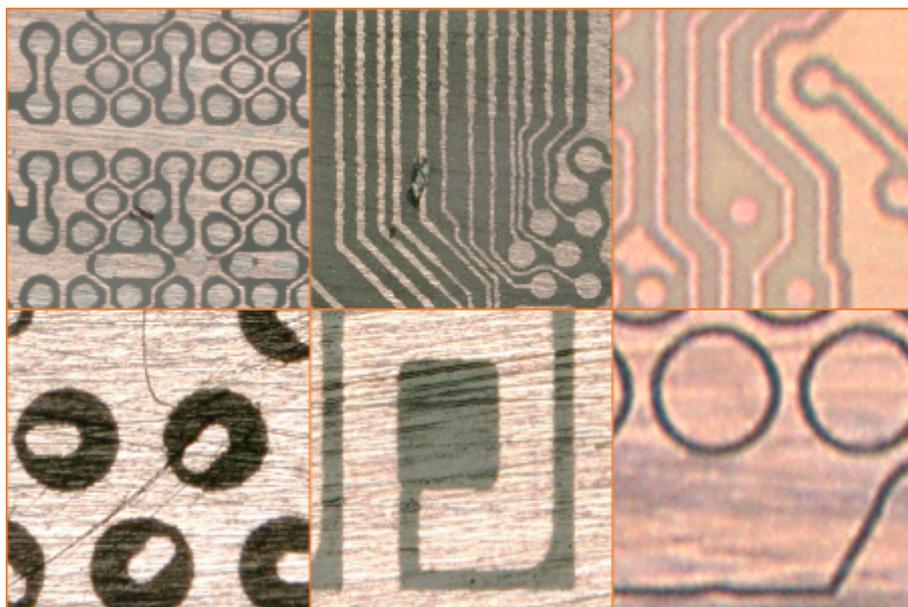


図 1.2 導体パターン撮影画像

1.3 論文構成

本論文の構成として、第 2 章にて本研究の比較対象とした大津の 2 値化の他、関連技術について述べる。第 3 章では汚れや欠損などのある画像から 2 値画像や改善された画像を生成する研究について述べる。第 4 章では 2 値画像の自動生成を行うため構築したネットワークと学習方法、また性能向上の余地を検証する為の比較ネットワークについて述べる。第 5 章では実際にネットワークを学習させ、得られた出力の結果とそれについての考察を述べる。第 6 章では本研究について簡潔にまとめる。

第 2 章

関連技術

2.1 大津の 2 値化

大津の 2 値化とはグレースケール画像に対して閾値を求め、2 値化する処理の 1 つである。黒に分類する画素と白に分類する画素をそれぞれクラスとして分けて考えた時に、画素値のクラス内分散が小さいこと、またクラス間分散が大きいことを示す、分散度が大きくなるように閾値を定める。

クラス内分散を σ_w^2 、クラス間分散を σ_b^2 としたときに、分散度は σ_b^2/σ_w^2 で示される。また全分散 σ_t^2 とクラス内分散 σ_w^2 、クラス間分散 σ_b^2 の関係 $\sigma_t^2 = \sigma_b^2 + \sigma_w^2$ より、 $\sigma_b^2/\sigma_w^2 = \sigma_b^2/\sigma_t^2 - \sigma_b^2$ となる為、クラス間分散 σ_b^2 が最大になるように閾値を定めれば良い。黒画素クラスの画素数、平均、分散を $\omega_1, m_1, \sigma_1^2$ 、白画素クラスの画素数、平均、分散を $\omega_2, m_2, \sigma_2^2$ とすると、クラス間分散 σ_b^2 は以下の式で求めることができる。

$$\sigma_b^2 = \frac{\omega_1(m_1 - m_t)^2 + \omega_2(m_2 - m_t)^2}{\omega_1 + \omega_2} = \frac{\omega_1\omega_2(m_1 - m_2)^2}{(\omega_1 - \omega_2)^2}$$

この大津の 2 値化はどのような画像でも閾値を一意に決めることができる為、よく使用される。

2.2 畳み込みニューラルネットワーク (CNN)

畳み込みニューラルネットワーク (CNN) とは Lecun ら [2] が考案した、畳み込み層と Pooling 層を組み合わせたネットワークであり、画像に対する処理に高い効果を持つ。

CNN が提唱されるまでのニューラルネットワークは、一般的に隣接する層の間のすべて

2.2 畳み込みニューラルネットワーク (CNN)

のニューロン (入力値と中間層, 中間層と出力値の間も含む) 同士が結合される全結合からなるニューラルネットワークが用いられた. しかし全結合はすべてのデータを次の層につなげている為, 付近のピクセルは似た値を持つなどの, 画像が持つ縦と横方向における空間的情報を生かしておらず, 明らかに無駄なデータの参照を行っている.

これを CNN は全結合の代わりに, ニューロン間の重みをフィルター状に配置し層の間で畳み込みを行う畳み込み層によって, 画像が持つ 3 次元の形状を保ったまま次の層にデータを渡すことを可能とした. 図 2.1(入力: x , 出力: y , 重み: w) は畳み込み処理を示しており, このフィルターの重みを更新することで学習する. これによって前層のすべてのニューロンと結合していた全結合と比べ, 必要な重みパラメータがはるかに少なくなったことで, 多数のフィルターを重ねることができるようになり, 複雑な特徴を捉えることにつながった. 以降このフィルターをカーネルと呼ぶ.

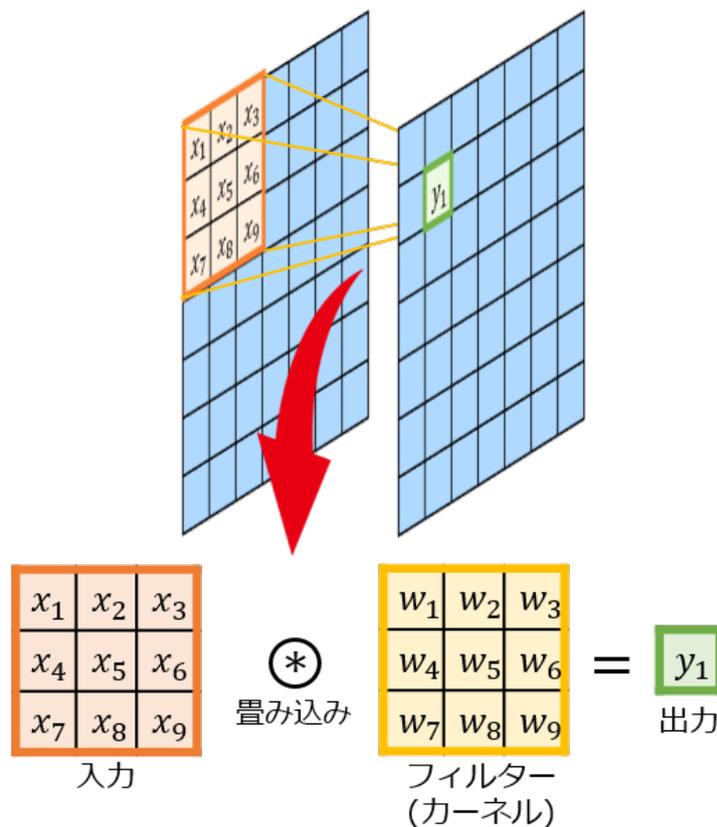


図 2.1 畳み込み処理

2.3 U-Net

また CNN ネットワークの内、全結合を使用していない様なネットワークをしばしば FCN(Fully Convolutional Networks) と呼ぶことがあり [3], これは入力変数の数が固定される全結合層が存在しない為、1つのネットワークで複数の画像サイズに対応できる様になる。

2.3 U-Net

U-Net とは O. Ronneberger ら [4] 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。

2.4 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 [5]。以降 P. Isola らの手法を pix2pix と呼ぶ。

pix2pix では Generative Adversarial Nets[6](以降 GAN) の一種である、Conditional GAN と呼ばれる手法が用いられている。GAN で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 が用いられ、Discriminator は Generator が生成した画像を暴き、Generator は Discriminator を騙すといった敵対的に同時に学習させる。

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。

第 3 章

2 値分類・欠損復元に関する研究

3.1 劣化文書からの 2 値分類

画像を 2 値分類する問題は文字の書かれた文書データを中心として盛んにおこなわれており、コンペティション (DIBCO) が開催される程である。その中でも PWB 撮影画像のように汚れが存在する画像に対して効果を示していたものとして、Calvo-Zaragoza ら [7] の研究が挙げられる。Calvo-Zaragoza らの貢献は、輪郭抽出のタスクに有効であったエンコーダデコーダモデルを、文書の 2 値分類タスクにおいても有効であることを示したことであり、エンコーダデコーダモデルによるネットワークの出力は劣化した文書から汚れを取り除くことができていた。Calvo-Zaragoza らは図 3.1 の様な 3 段の圧縮からなるネットワークを基準として、これを畳み込み層とエンコード、デコードのみで構成する CAE[8] (Convolutional Auto-Encoder), エンコーダが max pooling で圧縮する際に、取得した値の位置をデコーダに渡す SWWAE[9](Stacked What-Where Auto-Encoder), エンコードで得られた特徴マップをデコーダ時に足し合わせることで ResNet のように残差学習を行う RED-Net[10] (Very deep Residual Encoder-Decoder Network) の手法で検証している。彼らの出力結果 (図 3.2 の SAE が Calvo-Zaragoza らの手法, 赤が黒欠損, 青が黒余分) を見ると、劣化した文書から汚れが除去され文字が綺麗に抽出できている様子が見てとれる。

3.2 画像の欠損補完

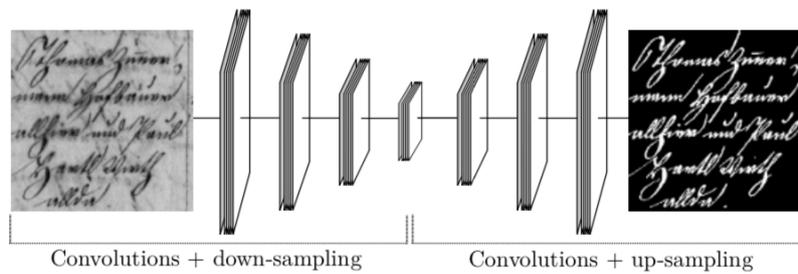


図 3.1 Calvo-Zaragoza らによるネットワーク (出典 [7])

	D16	PL-I	ES
Source			
SAE			
State of the art			
Su et al.			

図 3.2 文書の 2 値分類結果 (出典 [7])

3.2 画像の欠損補完

画像中の情報が欠損した箇所の復元を行ったものとして、Sasaki ら [11] による線画の欠陥補完が挙げられる。Sasaki らの貢献は前手法が欠けた位置を指定しないと補完できなかったものを、ネットワークが自動で欠けた位置を検出でき、さらに性能が前手法より高いという点である。Sasaki らは図 3.3 の様なエンコーダデコーダモデルからなる、4 段の圧縮が存

3.3 劣化前の画像生成

在するネットワークを構築した。ネットワークの設計理念として、前半のエンコーダ部は入力画像の特徴を捉え、後半のデコーダ部で線を統合して出力を滑らかにする為に、後半は前半と比べチャンネル数が少ない。図 3.4 は出力結果を示したものであり、途切れた線画を離れた位置の情報からうまく復元している様子が見れとれる。

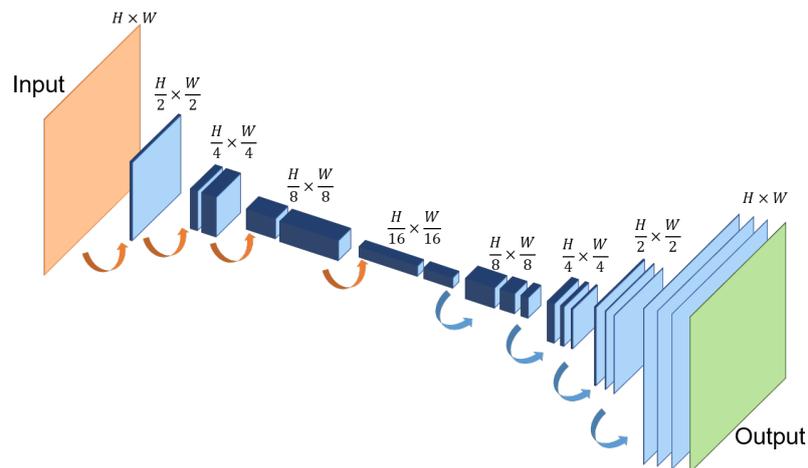


図 3.3 Sasaki らによるネットワーク ([11] を元に作成)

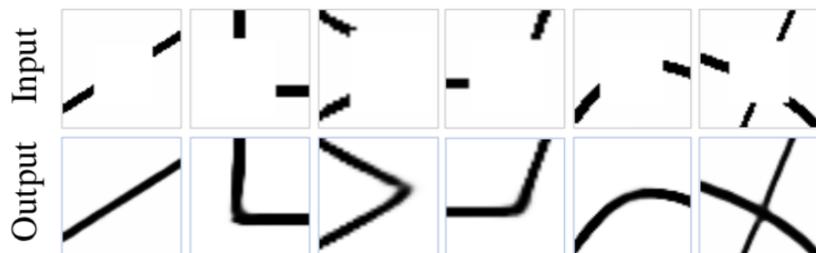


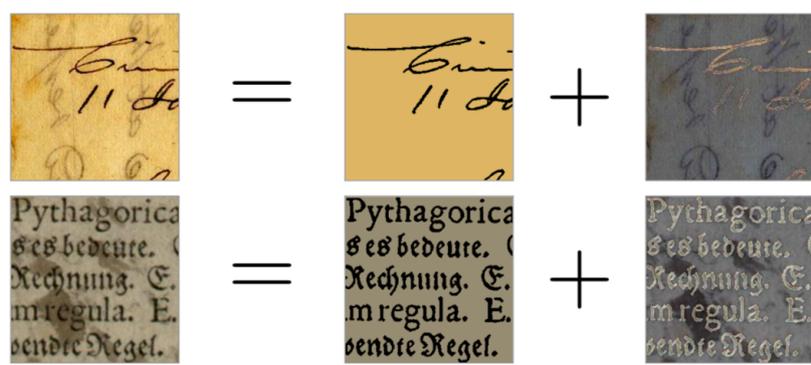
図 3.4 線画の復元結果 (出典 [11])

3.3 劣化前の画像生成

また He ら [12] は直接 2 値画像を生成するのではなく、文書の劣化を取り除き、大津の 2 値化などの閾値を用いた手法によって 2 値化可能な、きれいな文書データを出力させる DeepOtsu を提唱した。考え方としては、図 3.5 のように劣化した入力画像 X を劣化前の画像 X_u と劣化 e が足し合わせたものとする。そして図 3.6 のようにネットワークの出力に入力画像 X を足し合わせることで、ネットワークは X_u を最終的に生成する為に、劣化 e

3.3 劣化前の画像生成

を除去することを学習するようになる。これによって劣化を除去することに特化したネットワークを構築できる。この劣化を学習するネットワークには U-Net[4] が使われている。また出力画像として改善された入力画像が得られる為、再帰的な学習が可能となり、一度の学習ではネットワークが捉えることができない汚れを同じネットワーク、もしくは異なるネットワークに再度学習させることで、性能の向上を図ることが可能となる。図 3.7 は出力結果を示したもの (左:入力画像, 中央:出力画像, 右:2 値化) であり、汚れや背景が取り除かれ、また薄くなっている文字もはっきりとしている。



$$\mathbf{X} = \mathbf{X}_u + \mathbf{e}$$

図 3.5 劣化文書の定式化 (出典 [12])

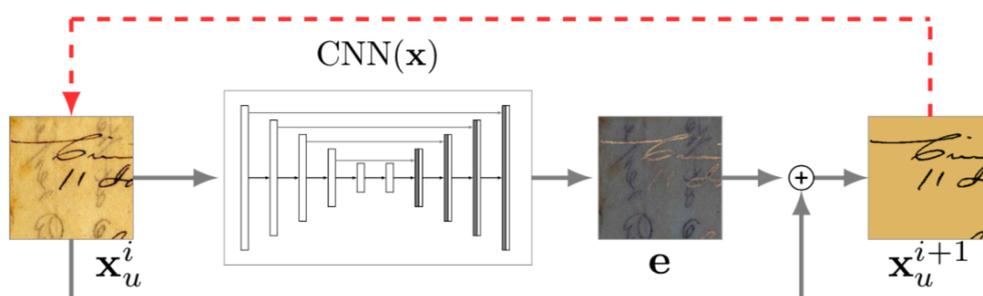


図 3.6 DeepOtsu のネットワーク構造 (出典 [12])

3.3 劣化前の画像生成



図 3.7 DeepOtsu のネットワーク構造 (出典 [12])

第 4 章

提案手法

4.1 使用ネットワークモデル

今回の検証実験にて用いた U-Net モデルは pix2pix[5] 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 4.1 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 4×4 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 4×4 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 BatchNormalization と、拡張部一部の層に 50% の DropOut を適用し、全ての層に bias を配置し学習させる。

本モデルの形状は [1] と同じであるが、[1] では RGB 特徴のみで推論を行っており、本稿においては RGB 特徴に加え、後述する 2 値画像である導体パターンを入力に加えて推論を行う。

4.1 使用ネットワークモデル

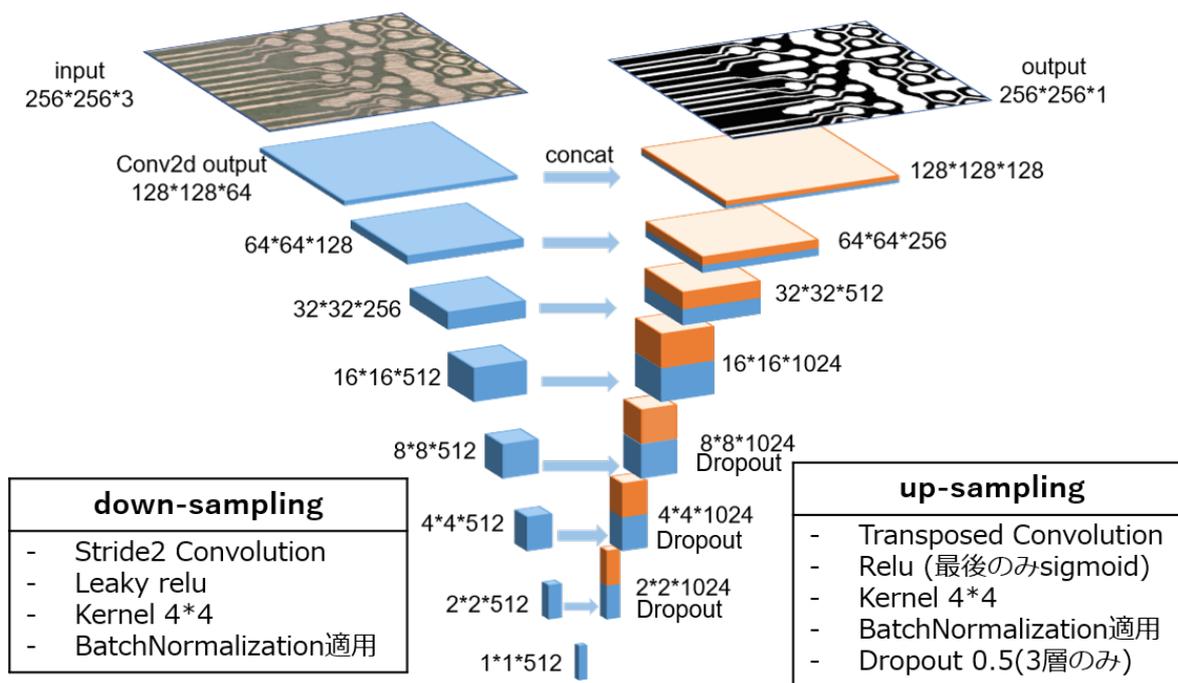


図 4.1 U-Net モデルの構造

表 4.1 U-Net モデルの詳細

layer type	kernel	strides	output size
input	-	-	$256 \times 256 \times ch$
convolution	4×4	2×2	$128 \times 128 \times 64$
convolution	4×4	2×2	$64 \times 64 \times 128$
convolution	4×4	2×2	$32 \times 32 \times 256$
convolution	4×4	2×2	$16 \times 16 \times 512$
convolution	4×4	2×2	$8 \times 8 \times 512$
convolution	4×4	2×2	$4 \times 4 \times 512$
convolution	4×4	2×2	$2 \times 2 \times 512$
convolution	4×4	2×2	$1 \times 1 \times 512$
transposed convolution	4×4	$1/2 \times 1/2$	$2 \times 2 \times 512$
concat	-	-	$2 \times 2 \times 1024$
transposed convolution	4×4	$1/2 \times 1/2$	$4 \times 4 \times 512$
concat	-	-	$4 \times 4 \times 1024$
transposed convolution	4×4	$1/2 \times 1/2$	$8 \times 8 \times 512$
concat	-	-	$8 \times 8 \times 1024$
transposed convolution	4×4	$1/2 \times 1/2$	$16 \times 16 \times 512$
concat	-	-	$16 \times 16 \times 1024$
transposed convolution	4×4	$1/2 \times 1/2$	$32 \times 32 \times 256$
concat	-	-	$32 \times 32 \times 512$
transposed convolution	4×4	$1/2 \times 1/2$	$64 \times 64 \times 128$
concat	-	-	$64 \times 64 \times 256$
transposed convolution	4×4	$1/2 \times 1/2$	$128 \times 128 \times 64$
concat	-	-	$128 \times 128 \times 128$
transposed convolution	4×4	$1/2 \times 1/2$	$256 \times 256 \times 3$

4.2 導体パターンの生成

4.2.1 特徴量増加データセットの問題点

以前筆者らが提案した [1] においては RGB 特徴を元に U-Net モデルで推論を行っていたが、RGB 特徴だけでは特徴量増加したデータセットに対応出来ていなかった。

図 4.2, 4.3 に 2 枚の PWB 撮影画像のヒストグラムを示す。実線が 2 値画像にて黒に割り振りたい画素、一点鎖線が 2 値画像にて白に割り振りたい画素を示す。また RGB 特徴のみで U-Net モデルで推論を行った結果を図 4.4, 4.5 に示す。

今回扱った PWB 撮影画像の内、大多数は撮影画像 A(図 4.2) の様に RGB 特徴がヒストグラム上で白と黒の画素で分かれているが、中には撮影画像 B(図 4.3) のようにヒストグラム上で白と黒の画素を分離するのが難しい PWB 撮影画像がある。実際にこれら PWB 撮影画像を RGB 特徴のみで推論させた場合、撮影画像 A においては図 4.4 のように綺麗だが、撮影画像 B においては図 4.4 の様に黒画素が大きく消えるなどの誤りを生み出す。

図 4.4 の様な誤りは RGB 特徴のみでは解決出来ないとし、RGB 特徴に大津の 2 値化によって作成した導体パターンの 2 値画像を入力に加えることを考案した。

4.2 導体パターンの生成

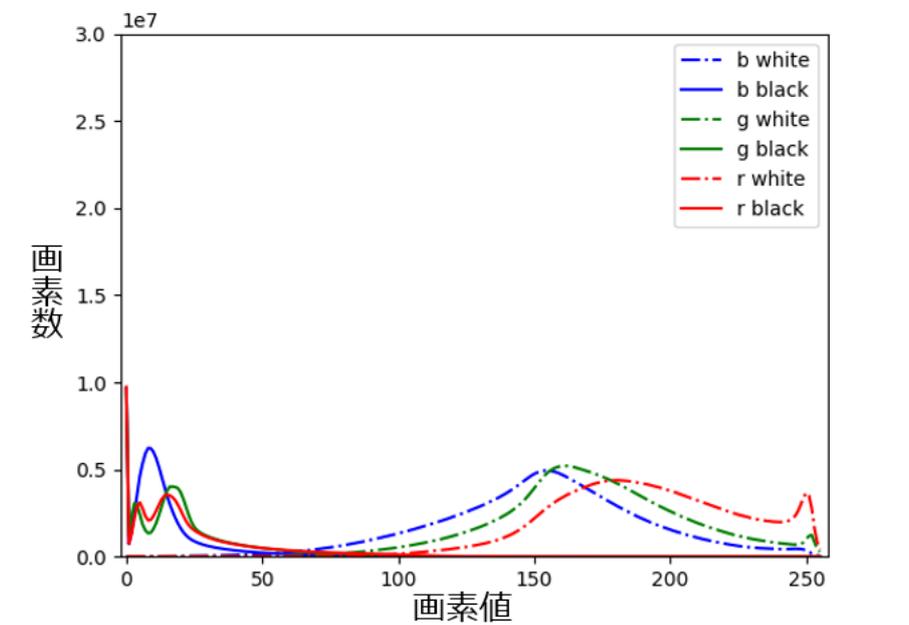


図 4.2 撮影画像 A におけるヒストグラム

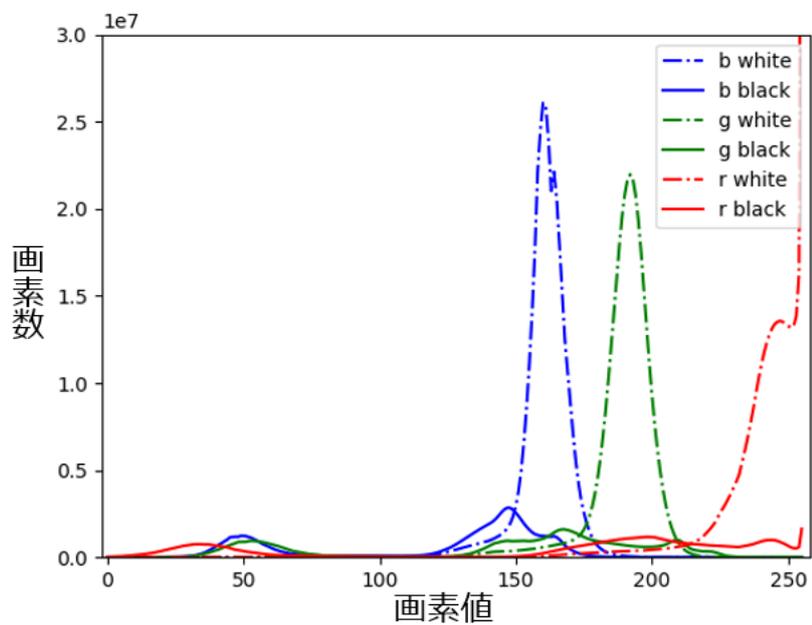


図 4.3 撮影画像 B におけるヒストグラム

4.2 導体パターンの生成

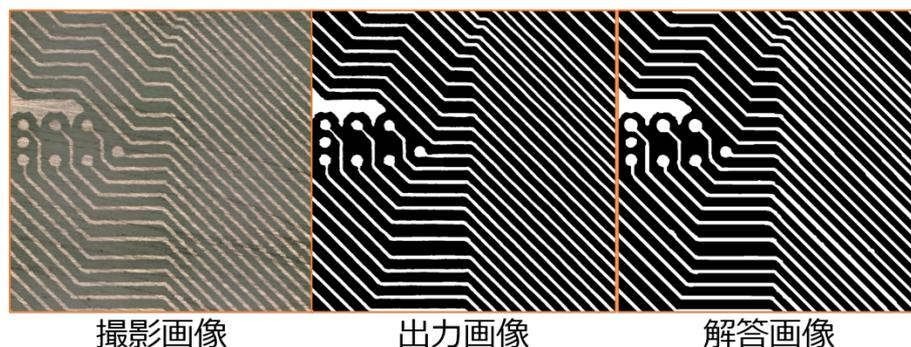


図 4.4 撮影画像 A に対する入力 RGB のみ U-Net モデルの出力例

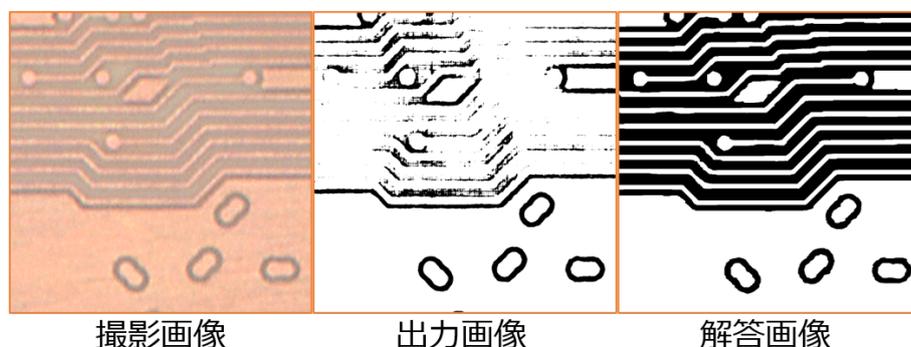


図 4.5 撮影画像 B に対する入力 RGB のみ U-Net モデルの出力例

4.2.2 導体パターンの生成手法

導体パターンを大津の 2 値化にて作成する際に、撮影画像の縁除去による画素分布の調整と RGB 色空間から HSL 色空間への変換を行う。

撮影画像には図 4.6 の様に導体パターンに影響しない縁が存在し、 24756×19608 pixel の撮影画像の中の約 1 割を占めており、この縁に存在する画素が大津の 2 値化に悪影響を与える為、導体パターンが綺麗に取得出来なくなる。その為縁を除去し、導体パターンの領域のみの画素分布を取得する。

その後 RGB 色空間を HSL 色空間に変換したのちに大津の 2 値化にて輝度値 L の閾値を求める。RGB 色空間にて式 $0.299 * R + 0.587 * G + 0.114 * B$ で輝度値を求めた際に 2 値分類正解率が 94.783% となるのに比べ、輝度値 L を使用することで 2 値分類正解率が

4.2 導体パターンの生成

95.558% となり, 約 0.8% 改善する.

これらのことを行い, 図 4.5 に対して大津の 2 値化によって生成した導体パターンの 2 値画像を図 4.7 に示す.

大津の 2 値化によって強い汚れを除去することが出来ないが, 図 4.3 の様に汚れが強くない領域において大まかな導体パターンを入力として渡すことが可能となった.

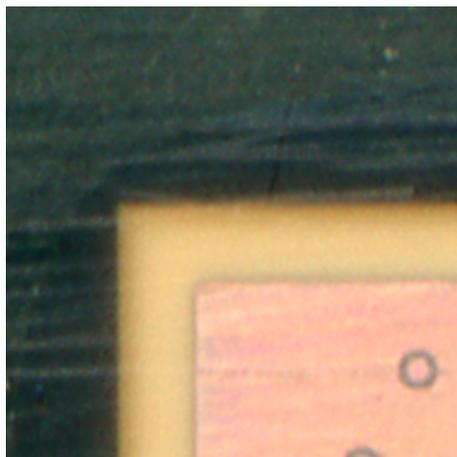


図 4.6 撮影画像の縁にある導体パターンに影響しない領域

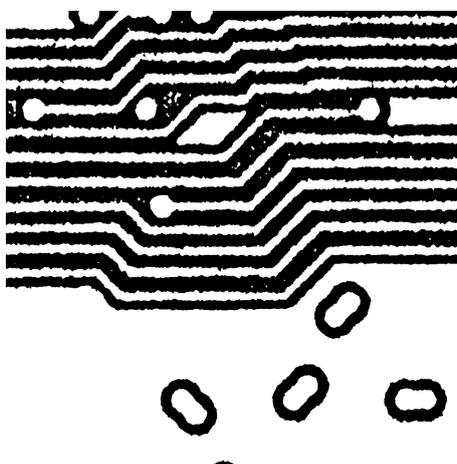


図 4.7 図 4.5 の撮影画像に対する大津の 2 値化

4.3 学習方法

実験を行うにあたって、 24576×19608 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 256×256 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 87552 枚、テスト用 21888 枚、評価用 21888 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。また学習中に Data Augmentation として、画像を $0^\circ, 90^\circ, 180^\circ, 270^\circ$ の回転を等確率で行っている。そして学習は過学習が確認できる 20 epoch まで学習を行った、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。

第 5 章

実験結果

5.1 評価方法

この説では評価の方法について記載する。

5.1.1 導体パターンの 2 値画像に対する評価項目

基板解析は回路図作成と CAD データ作成を目的として行われる。回路図作成においては、銅箔や絶縁体などの領域による接続関係が重要であるために、2 値画像に断線や短絡が発生しないことが要求される。一方 CAD データ作成では、配線やホールの導体パターンの正しさも重要となり、上記に加えて 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。

5.1.2 モデルのサンプリング条件と評価方法

データセット中の学習用画像の内 4 分の 1 に該当する 21888 枚の学習が終了する度にモデルを保存し、1 回の学習にて $20epoch \times 4 = 80$ のモデルを取得する。その後、テスト用画像にて 2 値分類正解率をモデルを評価し、一番高い 2 値分類正解率を持つモデルを評価用モデルとする。そして評価用モデルにて評価用画像の 2 値分類正解率、短絡断線数、画像生成の処理時間を求める。2 値分類正解率、短絡断線数は評価用画像 3 枚 \times 6 データセット $= 18$ 枚の結果を平均したものであり、画像生成の処理時間は 18 枚の画像を生成した際の処

5.2 検証結果

理時間を平均したものである。

5.2 検証結果

5.2.1 各手法の比較

6つのデータセットによる評価の平均を表 5.1, 5.2 に示す。手法の U-Net(RGB+Otsu) は U-Net モデルに RGB 特徴に追加で大津の 2 値化で得られた導線パターンを入力して学習させたものであり、U-Net(RGB) は RGB 特徴のみで学習させたものである。Otsu(RGB) は小節 4.2.2 と同様に、縁を除去した画像の RGB から輝度信号を求め、閾値を求めた後、元のサイズの画像に対して大津の 2 値化を行ったものであり、Otsu(L) は RGB から輝度信号を求めるのではなく、HSL 色空間に変換したのちに輝度値 L を元に同様のことを行ったものである。Otsu(L)+closing(size= n) は Otsu(L) で得た画像に対して白画素の膨張を n 回繰り返したのち、白画素の収縮を n 回繰り返す、クローズング処理を行ったものである。また Otsu のみで出力した画像については、短絡断線の面で粗い画像となり評価が長時間掛かるため、2 値分類正解率のみを提示している。

表 5.1 の結果より、U-Net モデルの入力に大津の 2 値化によって得られた導線パターンを入力とすることで、2 値分類正解率、短絡断線数共に改善させる事が出来処理時間も RGB 情報のみの場合と同等である。

また大津の 2 値化や膨張・収縮による結果においても優位であり、U-Net(RGB+Otsu) の手法は優れていると言える。

表 5.1 深層学習による評価結果

手法	2 値分類正解率	短絡断線数	処理時間
U-Net(RGB+Otsu)	98.111%	215.7	1 分 44.04 秒
U-Net(RGB)	97.662%	374.8	1 分 39.30 秒

5.2 検証結果

表 5.2 大津の 2 値化による結果

手法	2 値分類正解率
Otsu(RGB)	94.784%
Otsu(L)	95.556%
Otsu(L)+closing(size=1)	96.519%
Otsu(L)+closing(size=2)	97.091%
Otsu(L)+closing(size=3)	97.348%
Otsu(L)+closing(size=4)	97.447%
Otsu(L)+closing(size=5)	97.397%

5.2.2 2 値分類正解率の推移

図 5.1, 5.2 に 2 値分類正解率の推移を示す.

U-Net(RGB+Otsu) の結果は U-Net(RGB) 比較し, 2 値分類正解率の推移でも安定して優位である為, 偶然得られた結果であるとは考えにくい.

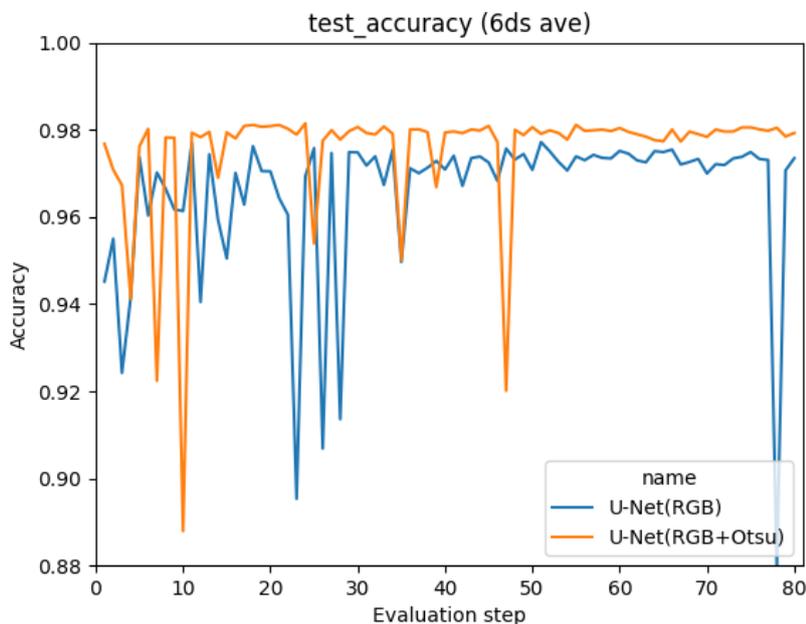


図 5.1 テスト画像における 2 値分類正解率推移

5.2 検証結果

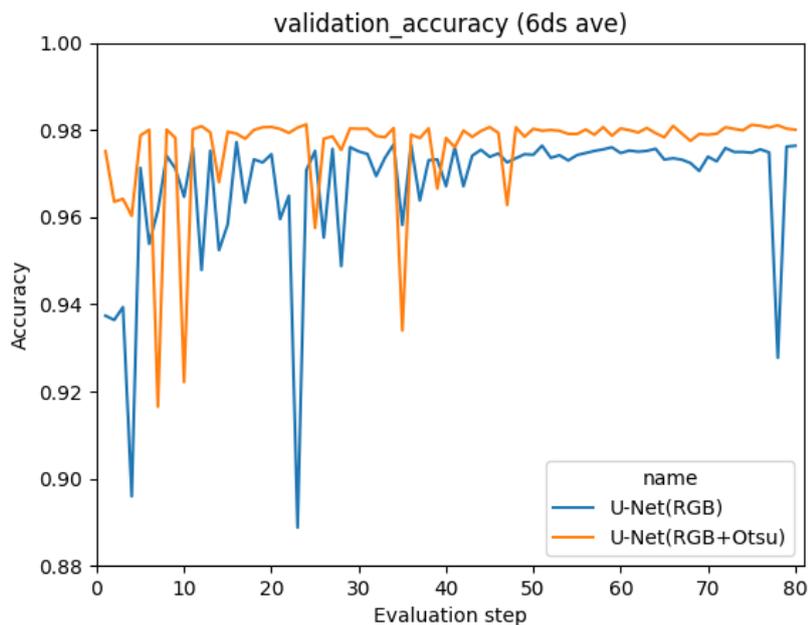


図 5.2 評価画像における 2 値分類正解率推移

5.2.3 出力結果例

小節 4.2.1 にて取り上げていた、問題点のある画像の出力結果を図 5.3 に示す。RGB 特徴のみでは対応出来なかった導線パターンに対して、モデル構造を変えず、入力を追加するだけで対応出来ている事がわかる。

5.2 検証結果

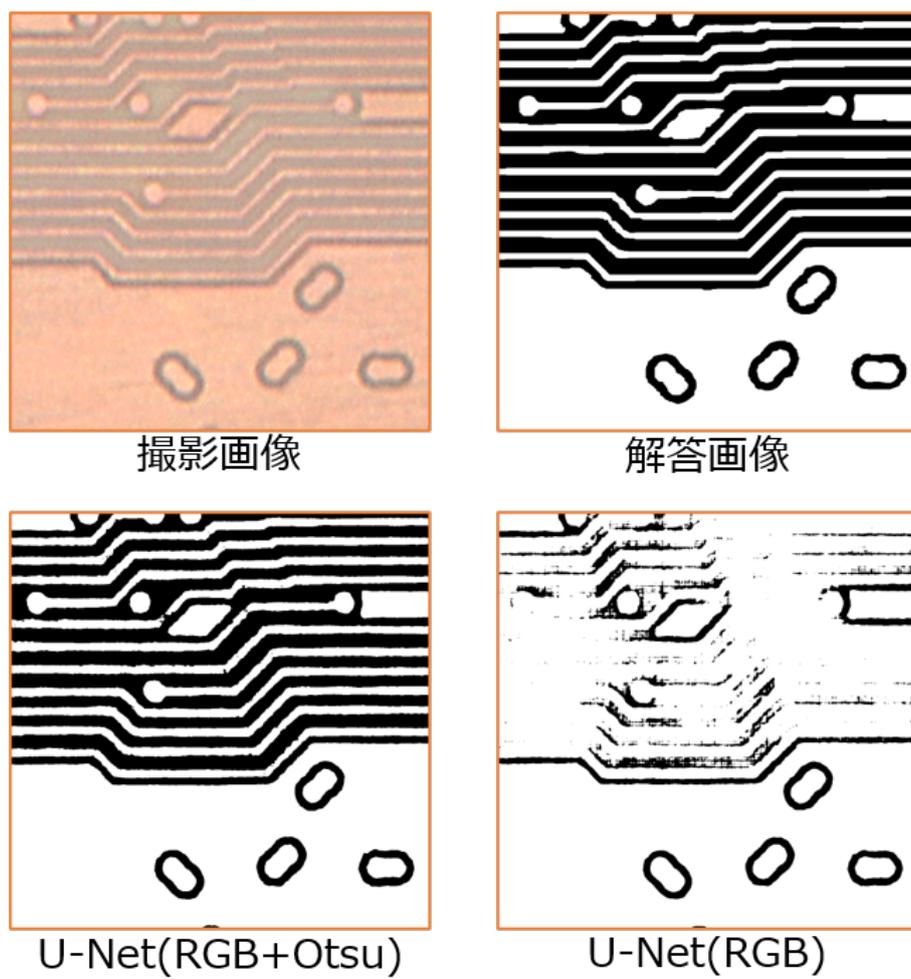


図 5.3 評価画像における 2 値分類正解率推移

第 6 章

結論

筆者らはより実用的な PWB 撮影画像の 2 値化手法とする為、多数の特徴を持つデータセットに対して良い結果を持つ U-Net モデルを提案してきた。しかし、難易度の高い特徴に対しては性能が高くない問題点を抱えていた。

この問題点を解決する為に、U-Net モデルに RGB 情報のみでなく、大津の 2 値化によって得られた大まかな導体パターンを 2 値画像として入力に追加することで、今まで対応出来なかった難易度の高い特徴にも対応する事が可能となった。その為より一層幅広い特徴に対する PWB 撮影画像に対応出来る様になり、また処理時間についても前手法と変動がなく、実用性が高まったと言える。

大津の 2 値化によって得られた画像を入力とした場合に性能が上がることを確認出来た事は、更に別の入力を試すことでも性能が向上する可能性があることを示しており、今後さらなる改善を望むことが出来ると考えられる。

謝辞

最後に本研究を進めるにあたり，常に向上を目指す志の元，手厚いご指導をして頂きました栗原 徹 准教授には心から感謝を申し上げます。お忙しい中副査を務めて頂いた松崎 公紀 教授，吉田 真一教授にも深く感謝いたします。また本研究の発端となったお話をいただき，データや評価プログラムの提供までしていただいた株式会社エルテック シニアスペシャリスト 葛本 貴俊様に厚く御礼を申し上げ，感謝する次第です。

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, パシフィコ横浜, 06/10-12, 2020.
- [2] Y. Lecun, L. Bottou, Y. Bengio, P. Haffner, ”Gradient-based learning applied to document recognition”, Proceedings of the IEEE, **86-11**, p.2278-2324, 1998.
- [3] J. Long, E. Shelhamer, T. Darrell, ”Fully convolutional networks for semantic segmentation”, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), p.3431-3440, 2015
- [4] 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)
- [5] 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).
- [6] 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)
- [7] J. Calvo-Zaragoza, A. Gallego, “A selectional auto-encoder approach for document image binarization”, Pattern Recognition, **86**, p.37-47, 2019.
- [8] J. Masci, U. Meier, D. Ciresan, J. Schmidhuber, ”Stacked Convolutional Auto-Encoders for Hierarchical Feature Extraction” Artificial Neural Networks and Machine Learning – ICANN 2011, p.52-59, 2011
- [9] J. Zhao, M. Mathieu, R. Goroshin, Y. LeCun ”Stacked What-Where Auto-encoders” International Conference on Learning Representations(ICLR), Retrieved from <https://arxiv.org/abs/1506.02351v8>, 2016.

参考文献

- [10] X. Mao, C. Shen, Y. Yang, "Image Restoration Using Very Deep Convolutional Encoder-Decoder Networks with Symmetric Skip Connections", Neural Information Processing Systems(NIPS), Retrieved from <https://papers.nips.cc/paper/6172-image-restoration-using-very-deep-convolutional-encoder-decoder-networks-with-symmetric-skip-connections>, 2016
- [11] K. Sasaki, S. Iizuka, E. Simo-Serra, H. Ishikawa, "Joint Gap Detection and Inpainting of Line Drawings", Computer Vision and Pattern Recognition(CVPR), p.5725-5733, 2017.
- [12] S. He, L. Schomaker, "DeepOtsu: Document Enhancement and Binarization using Iterative Deep Learning" Pattern Recognition, <https://doi.org/10.1016/j.patcog.2019.01.025>, 2019.