

Title	機械学習によるOLED製造工程での不良検出に関する研究
Author(s)	富田, 暁
Citation	
Issue Date	2022-12
Type	Thesis or Dissertation
Text version	ETD
URL	<a href="http://hdl.handle.net/10119/18190">http://hdl.handle.net/10119/18190</a>
Rights	
Description	Supervisor:小谷 一孔, 先端科学技術研究科, 博士

博士論文

機械学習による OLED 製造工程での不良検出に関する研究

富田 暁

主指導教員 小谷 一孔

北陸先端科学技術大学院大学  
先端科学技術研究科 [情報科学]

令和四年十二月

## Abstract

In this paper, we discuss the automatic detection of mura defects, non-uniformity of brightness or color, which has been a long-standing challenge in the display industries. Our purpose is to develop a method using machine learning, which automatically detects and classifies mura in the front-end process. This will enable prompt feedback to the manufacturing process and contribute to improvement of the productivity.

The dataset we made for this work consists of 8 classes and 1000 images for each class, totaling 8000 images obtained from an actual OLED (Organic Light Emitting Diode) manufacturing line, including four different types of mura which frequently occur in the manufacturing process.

In the evaluations of multiclass classifications using general machine learning models such as SVM (Support Vector Machine), CNN (Convolutional Neural Network), and Residual Neural Network (ResNet), the accuracy was improved to 0.830 by adjustments of parameters such as layer structures and training modes. However, weak mura with low contrast and small defective areas are difficult to be detected by such models because of the confusion with normal displays with no defects, and thus new approaches were necessary.

Our approaches are based on the human visual perception. One of the measures taken to ensure test accuracy in the human visible test is that test-images appropriate for each type of defects are used to clarify the deference between the defective area and the normal area. To reproduce this measure with machine learning, we enhanced contrast of the images of the dataset before inputting them into the machine learning models. Another measure to ensure test accuracy in the human visible test is boundary-samples which are compared with a display being tested when a human tester is unsure of the decision. We evaluated 2-class classifications based on the subspace method to reproduce the boundary-samples with machine learning.

We propose “Progressive Hybrid model” which consists of a multiclass CNN, a 2-class ResNet, and a 2-class CNN. The two 2-class models which reproduce the boundary-samples in the human visible test are for accurate classification between Normal displays and weak mura with low contrast and small defective areas. To reproduce the appropriate test-images used in the human visible test, we enhanced contrast of the images of the dataset using the sigmoid function. The proposed model showed the improvement of the accuracy from 0.830 in the general application of CNN to 0.884. It was also confirmed that the proposed model is particularly effective to improve the classification accuracy of Normal displays by reducing the confusions with weak mura with low contrast and small defective areas. As Normal displays are usually the most numerous in the manufacturing, the improvement effect of the proposed method is further beneficial in the practical use.

Keywords: Display, Machine Learning, Mura, Detection, Subspace Method, Contrast Enhancement

# 目次

第1章 はじめに .....	1
1.1 背景.....	1
1.2 研究目的.....	5
第2章 先行研究 .....	8
第3章 機械学習による不良検出評価 .....	16
3.1 評価方法.....	16
3.1.1 システム概念図 .....	16
3.1.2 評価指標 .....	17
3.1.3 機械学習環境.....	18
3.1.4 データセット .....	18
3.2 目視検査特性 .....	21
3.2.1 目視検査.....	21
3.2.2 コントラスト強調.....	22
3.2.3 部分空間法 .....	24
3.3 多クラス分類の評価結果.....	28

3.3.1 SVM による多クラス分類の評価結果 .....	28
3.3.2 CNN による多クラス分類の評価結果 .....	33
3.3.3 Residual Network による多クラス分類の評価結果 .....	41
3.4 部分空間法による 2 クラス分類の評価結果 .....	47
3.4.1 SVM による 2 クラス分類の評価結果 .....	47
3.4.2 CNN による 2 クラス分類の評価結果 .....	52
3.4.3 Residual Network による 2 クラス分類の評価結果 .....	59
第 4 章 提案手法 .....	65
4.1 プログレッシブ・ハイブリッドモデル .....	65
4.2 提案手法の評価結果 .....	67
4.3 製造工程への導入 .....	72
第 5 章 結論 .....	75
第 6 章 今後の課題 .....	77
謝辞 .....	78
付録 小規模データセットによる概念検証 .....	79
1 位置付け .....	79
2 データセット .....	79
3 SVM での評価結果 .....	80

3.1 線形 SVM .....	80
3.2 コスト関数 .....	84
3.3 非線形 SVM .....	86
3.4 正規化 .....	88
3.5 主成分分析 .....	90
3.6 SVM 評価結果まとめ .....	91
4 CNN での評価結果 .....	92
5 概念検証結果の考察 .....	95

# 図目次

- ・ 図 1：ディスプレイの製造工程と基本構造の概要
- ・ 図 2：ディスプレイ製造工程で発生する表示不良と検査方法の概要
- ・ 図 3：画質予測のシステムフロー (“The system flow of image quality prediction”) [10]
- ・ 図 4：OLED ディスプレイでのムラ不良：スポットと線 (“Mura defects on OLED displays: spot and line”) [12]
- ・ 図 5：疑似的なムラの例 (“Some examples of pseudo Mura”) [8]
- ・ 図 6：One-class SVM のイメージ [23]
- ・ 図 7：DSI アルゴリズム概念図 [25]
- ・ 図 8：機械学習による識別手順 [26]
- ・ 図 9：システム概念図
- ・ 図 10：データセットの各項目の画像例
- ・ 図 11：(a)コントラスト強調に用いたシグモイド関数、(b)ムラ A のコントラスト強調実施前後の画像例
- ・ 図 12：多クラス分類(a)と部分空間法による 2 クラス分類(b)の概念図

- ・ 図 13：部分空間法によるデータセットの分割。(a)分割前の 8-class 分類、(b)各項目と良品との 2-class 分類、(c)各項目とそれ以外との 2-class 分類
- ・ 図 14：(a)良品ディスプレイの画像（左）とその階調ヒストグラム（右）、(b)ムラが発生したディスプレイの画像（左）とその階調ヒストグラム（右）。
- ・ 図 15：SVM による 8-class 分類の正解率
- ・ 図 16：SVM（コントラスト強調あり、非線形 RBF カーネル、 $C=10,000$ ）での項目別再現率、適合率
- ・ 図 17：畳み込み層と Max-Pooling 層を 2～6 組とした 8-class CNN の基本構造
- ・ 図 18：8-class CNN 正解率の畳み込み層と Max-Pooling 層の組数への依存性
- ・ 図 19：畳み込み層と Max-Pooling 層が 4 組の CNN の再現率と適合率
- ・ 図 20：コントラスト強調画像を用いた畳み込み層と Max-Pooling 層が 4 組の CNN の再現率と適合率
- ・ 図 21：Residual Network における残差接続の基本構造
- ・ 図 22：Residual Network による 8-class 分類正解率のコントラスト強調有無と学習方法への依存性
- ・ 図 23：Residual Network において全パラメータを学習(“trainable”)、コン

トラスト強調を実施した条件での再現率と適合率

- ・ 図 24：SVM によるムラ A の 2-class 分類正解率。左は良品とムラ A、右はムラ A とムラ A 以外。
- ・ 図 25：SVM によるムラ B の 2-class 分類正解率。左は良品とムラ B、右はムラ B とムラ B 以外。
- ・ 図 26：SVM によるムラ C の 2-class 分類正解率。左は良品とムラ C、右はムラ C とムラ C 以外。
- ・ 図 27：SVM によるムラ D の 2-class 分類正解率。左は良品とムラ D、右はムラ D とムラ D 以外。
- ・ 図 28：SVM による回路不良の 2-class 分類正解率。左は良品と回路不良、右は回路不良と回路不良以外。
- ・ 図 29：SVM による縦線欠陥の 2-class 分類正解率。左は良品と縦線欠陥、右は縦線欠陥と縦線欠陥以外。
- ・ 図 30：SVM による横線欠陥の 2-class 分類正解率。左は良品と横線欠陥、右は横線欠陥と横線欠陥以外。
- ・ 図 31：SVM による良品と良品以外の 2-class 分類正解率。
- ・ 図 32：CNN によるムラ A の 2-class 分類正解率。左は良品とムラ A、右はムラ A とムラ A 以外。

- ・ 図 33 : CNN によるムラ B の 2-class 分類正解率。左は良品とムラ B、右はムラ B とムラ B 以外。
- ・ 図 34 : CNN によるムラ C の 2-class 分類正解率。左は良品とムラ C、右はムラ C とムラ C 以外。
- ・ 図 35 : CNN によるムラ D の 2-class 分類正解率。左は良品とムラ D、右はムラ D とムラ D 以外。
- ・ 図 36 : CNN による回路不良の 2-class 分類正解率。左は良品と回路不良、右は回路不良と回路不良以外。
- ・ 図 37 : CNN による縦線欠陥の 2-class 分類正解率。左は良品と縦線欠陥、右は縦線欠陥と縦線欠陥以外。
- ・ 図 38 : CNN による横線欠陥の 2-class 分類正解率。左は良品と横線欠陥、右は横線欠陥と横線欠陥以外。
- ・ 図 39 : CNN による良品と良品以外の 2-class 分類正解率。
- ・ 図 40 : 2 クラス CNN の最終 Max-Pooling 層の可視化画像。
- ・ 図 41 : Residual Network によるムラ A の 2-class 分類正解率。
- ・ 図 42 : Residual Network によるムラ B の 2-class 分類正解率。
- ・ 図 43 : Residual Network によるムラ C の 2-class 分類正解率。
- ・ 図 44 : Residual Network によるムラ D の 2-class 分類正解率。

- ・ 図 45：Residual Network による回路不良の 2-class 分類正解率。
- ・ 図 46：Residual Network による縦線欠陥の 2-class 分類正解率。
- ・ 図 47：Residual Network による横線欠陥の 2-class 分類正解率。
- ・ 図 48：Residual Network による良品と良品以外の 2-class 分類正解率。
- ・ 図 49：提案手法のプログレッシブ・ハイブリッドモデルとその学習、評価方法。
- ・ 図 50：SVM、CNN、Residual Network 及び提案手法のプログレッシブ・ハイブリッドモデルの 8-class 分類正解率。
- ・ 図 51：SVM、CNN、Residual Network 及び提案手法のプログレッシブ・ハイブリッドモデルの項目別の再現率と適合率。
- ・ 図 52：SVM、CNN、Residual Network 及び提案手法のプログレッシブ・ハイブリッドモデルにおける良品の割合(歩留)と正解率の関係の試算結果。
- ・ 図 53：概念検証で用いたデータセットの画像例。
- ・ 図 54：概念検証における線形 SVM 結果の項目別再現率と適合率。
- ・ 図 55：概念検証におけるデータセット画像の階調分布。
- ・ 図 56：概念検証における線形 SVM、コスト関数  $C=1, 10, 100, 1000$  での正解率。
- ・ 図 57：概念検証における線形 SVM、コスト関数  $C=1, 10, 100, 1000$  での項

目別再現率と適合率。

- ・ 図 58：概念検証における非線形 SVM (RBF カーネル)、コスト関数  $C=1, 10, 100, 1000$  での正解率。
- ・ 図 59：概念検証における非線形 SVM (RBF カーネル)、コスト関数  $C=1, 10, 100, 1000$  での項目別再現率と適合率。
- ・ 図 60：概念検証における前処理として正規化を実施した SVM での正解率。
- ・ 図 61：概念検証における主成分分析を用いた SVM の正解率。
- ・ 図 62：概念検証における主成分分析( $n=2$ )の結果の可視化。
- ・ 図 63：概念検証における SVM 評価結果のまとめ。
- ・ 図 64：概念検証で用いた CNN の基本構造。
- ・ 図 65：概念検証における CNN 評価結果の再現率と適合率。

# 表目次

- ・ 表 1：SVM（コントラスト強調あり、非線形 RBF カーネル、 $C=10,000$ ）での混同行列
- ・ 表 2：畳み込み層と Max-Pooling 層が 4 組の CNN の混同行列
- ・ 表 3：コントラスト強調画像を用いた畳み込み層と Max-Pooling 層が 4 組の CNN の混同行列
- ・ 表 4：Residual Network において全パラメータを学習(“trainable”)、コントラスト強調を実施した条件での混同行列
- ・ 表 5：概念検証における線形 SVM の混同行列
- ・ 表 6：概念検証における CNN 評価結果の混同行列

# 第1章 はじめに

## 1.1 背景

液晶ディスプレイ(LCD: Liquid Crystal Display)は、厚くて重いブラウン管に置き換わる平面ディスプレイとして 1990 年前後に本格的な生産が開始され、その薄さ、軽さ、鮮明な画質、低消費電力によって、ノートパソコン、携帯電話、デジタルカメラ、カーナビゲーション、スマートフォン、壁掛けテレビなど人々の生活を変える様々な新製品の実現に貢献してきた。また 2000 年頃から、LCD よりも表示コントラストが高く、表示画面の曲面化(折り曲げ)も可能な有機 EL ディスプレイ(OLED: Organic Light Emitting Diode)が開発され、スマートフォンやウェアラブル端末、テレビなどに利用されている。

LCD や OLED の製造工程は図 1 に示すように、1~3m 四方のガラス基板 (Mother Glass 基板) 上に半導体と似たプロセス技術を用いて数個から数千個のディスプレイを形成する前工程と、Mother Glass 基板をディスプレイ単位に切断して電子部品や光学フィルム、カバーなどを取り付ける後工程に分けられる。ディスプレイの表示画面は多数の画素によって構成される。例えば一般的なスマートフォン用ディスプレイの場合、対角 5 インチ程度の表示画面にマトリクス状に配置されたサイズ 50~100  $\mu\text{m}$  四方、数百万個の画素 (Full HD 規格の場

合、縦 1920×横 1080×3(RGB)の約 600 万画素) で構成されている。LCD では、1 つの画素は電氣的には 1 つの薄膜トランジスタ(TFT: Thin Film Transistor)と 1 つの容量で形成され、走査信号によって選択された画素の容量に映像信号が書き込まれ、保持されることによって映像信号電圧が液晶層に印加され、液晶層の透過率が変化してバックライトからの透過光を制御することで映像信号電圧に応じた輝度が得られる。OLED では、1 つの画素は数個の TFT と容量で形成される。層構造としては電子輸送層、発光層、正孔輸送層が層状に重なり、映像信号電圧に応じた電圧が両端に印加されると発光層内で電子と正孔が結合し、そのエネルギーによって発光物質が励起され発光する。

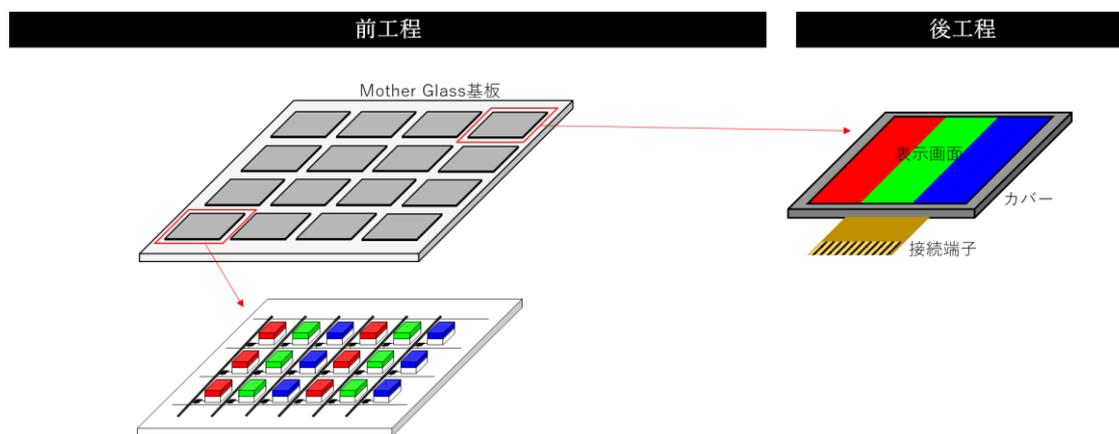


図 1：ディスプレイの製造工程と基本構造の概要

これら TFT や容量、それらへの配線の幅などは数 $\mu\text{m}$ 程度の大きさであり、先

端的な半導体ほど微細ではないが、基板サイズが 1~3m 四方と大きいため、基板内で均一に製造することには様々な困難が生じる。また製造工程では製造装置の状態、使用材料、クリーンルーム環境(異物)などの変動要因があり、Mother Glass 基板の投入からディスプレイの完成までは数週間以上を要するため変動の影響を受けやすい。こうした状況から、配線の断線やショートなどの加工不良、TFT の特性(閾値電圧等)ばらつき、異物(ゴミ)などの要因でディスプレイの表示画面には輝度や色度が異常になる表示不良が発生する。

表示不良には様々な種類があるが、輝度や色度の異常が発生する領域の違いで分類すると、画素単位で発生する点欠陥、画素に走査信号や映像信号を供給する配線単位で発生する線欠陥、走査信号配線や映像信号配線を駆動する回路が故障することで面状に発生する回路不良、発生領域が不明確なムラに大別される。これら表示不良のほぼ全ては図 2 に示すように前工程で発生する。従って表示不良の検査も前工程で実施し、不良を早期に発見して原因調査や対策にかなげることが生産性の観点からきわめて重要である。一般に工業製品のコストは、製造工程を経る毎に使用する材料や部品、製造装置、人的作業が積み重なることで増加していくため、不良の発生による損失は発見が遅れるほど拡大する。不良は自工程で発見し、次工程に流さないという自工程保証の重要性はディスプレイ製造にも当てはまる。このため LCD や OLED の開発当初から、ディス

プレイメーカーや検査装置メーカーが検査技術開発に取り組み、点欠陥、線欠陥、回路不良は、画像処理技術などを用いて概ね前工程での自動検査、即ち自工程保証が可能となっている[1][2][3][4][5][6]。

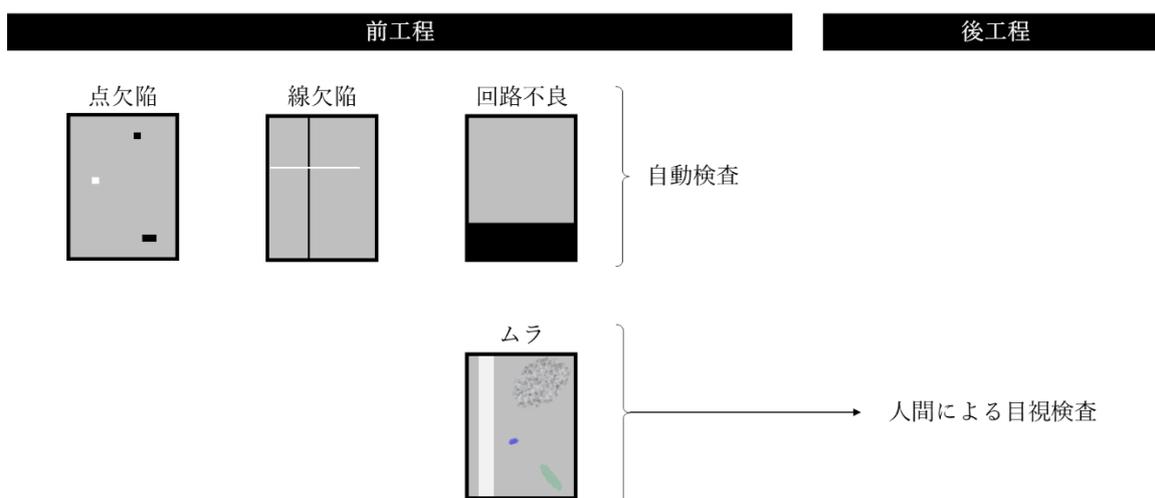


図 2：ディスプレイ製造工程で発生する表示不良と検査方法の概要

しかしムラは、他の不良に比べて自動的に検出することが非常に困難であるため、後工程で人間が目視検査している。即ち自工程保証ができない。その結果、人的要因に伴う検査精度の変動やコストの増加が生じるが、とりわけ深刻な問題は、ムラが発生してから検査するまでに長時間を要し、発生工程である前工程での原因調査や対策が遅れる点である。これはディスプレイ製造工程の生産性にとって深刻な問題であり、LCD や OLED の生産開始当初から現在までディスプレイメーカーや検査装置メーカーが努力を続けているものの、解決には至

っておらず、ディスプレイ産業における長年の課題となっている。

ムラの自動検出が困難な理由は、形状、大きさ、位置、向き、濃淡、色などが異なる様々な種類があり、人間が何をムラと認識するのかを定義することが困難なためと考えられる。

## 1.2 研究目的

本研究の目的は、OLED 製造工程で発生するムラを自動的に検出する手法を開発することである。これによりムラを早期に発見して製造工程にフィードバックし、原因調査や対策につなげることでディスプレイ製造工程の生産性改善に寄与する。最終的には高品質、低コストのディスプレイを顧客、社会に供給することに貢献できる。

この検出手法に要求されることは、まず高い検出・分類精度である。実際の製造工程で発生する不良の種類や程度は、各製造ラインにおける製造プロセス、製造装置、使用材料、それらの管理方法などによって異なる。従って求められる検出手法やその精度も製造ラインによって異なるが、他の検査装置の精度も考慮すると概ね 90%程度の正解率が目標になる。上述した通り本研究の目的は、前工程で不良を早期に検出して製造工程にフィードバックすることによる生産性改善であり、顧客に対して出荷品の品質を保証する検査は後工程で別途実施さ

れる。従って必ずしも 100%の不良検出精度が要求されるわけではない。

項目別の分類精度については、一般に工業製品の製造工程の検査で重視される良品と不良品（良品以外）の分類精度は本研究でも重要である。不良を良品と誤分類すると不良の発生に気づかないのでフィードバックできず、良品を不良と誤分類すると製造工程に誤ったフィードバックをしてしまう。同時に、不良項目間の分類も重要である。不良は多種多様であり、発生工程つまりフィードバックすべき製造工程は不良毎に異なる。従って、良品と不良品の分類だけではなく、不良項目間の分類精度も重要である。本研究では、第3章で詳述する通り、発生頻度が高い複数のムラ項目およびムラ以外の不良項目や良品も含むデータセットを使用し、分類精度を評価する。

また本検出手法には、製造工程における不良の発生状況の変化に対応するための拡張性も求められる。実際の製造工程では、プロセスや装置状態、クリーンルーム環境などの変動による不良の増加、新しい種類の不良の発生、またプロセス対策や装置メンテナンスによる不良の減少、一旦解決した不良の再発などの変化は日常的に発生している。製造工程における不良検出には、こうした変化に臨機応変に対応することで早期フィードバックすることが求められる。

なお一般に人間による検査工程を自動化する場合、人間の作業を完全に置き換えるのではなく、人間の負担を軽減することも目的となるが、本研究の場合、

前工程では人による目視検査は実施していないので、人間の負担軽減は目的ではない。

こうした要求を満たし得る手法として、近年急速に進歩している機械学習が考えられる。多くの機械学習アルゴリズムのなかでも、機械が特徴量を自動的に学習する深層学習は、定義が困難なムラの検出にも有効との期待から本研究の着想に至った。

## 第2章 先行研究

ディスプレイ分野で世界最大の学会である SID(Society for Information Display)が毎年開催する国際シンポジウムでは、2020 年から “Machine Learning for Displays”というセッションが設けられ、筆者が参加した 2022 年は同セッションが 4 つの“Special Topics”の一つになるなど、ディスプレイ分野でも機械学習の活用が進んでいる。活用方法としては、本研究のように検査や評価に用いる場合[7]-[17]と、ディスプレイの表示品質改善や製品設計に用いる場合に大別される[18]-[22]。これら先行研究のうち本研究が対象とするムラと関連が深いものは下記が挙げられる。

- ムラ予測システム…図 3 に示すように、ディスプレイ製造工程で得られる光学検査画像から、トランジスタ、抵抗や容量などの電気特性を機械学習によって抽出し、表示輝度をシミュレーションすることでムラの発生を予測するシステムに関する研究[10]。本論文では冒頭に、著者が所属する、OLED 分野ではリーディングカンパニーとされる Samsung Display 社において、ムラは創立以来最も重要な不良であり、その唯一の検出方法はディスプレイ完成後の人間の認識との言及がある。この問題意識は本研究と重なるが、本論文はムラの発生を予測するもので、実際に発生したムラを

検出する内容ではない。

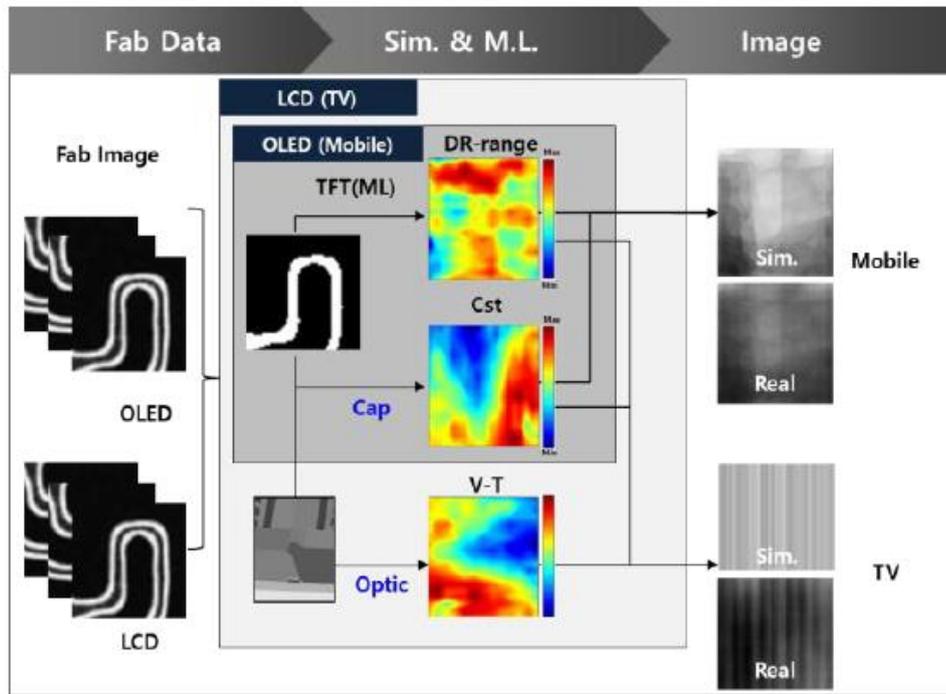


図 3：画質予測のシステムフロー (“The system flow of image quality prediction”) [10]

- SVM によるムラの 2 クラス分類…図 4 に示す White-Spot(89 枚) と Horizontal-Line(113 枚) の 2 種類のムラを対象に、画像処理で領域と特徴を抽出し、SVM binary classifier で分類、両ムラとも再現率 1.0、適合率 0.9 以上を達成したとの報告[12]。この研究は、実際に発生したムラの画像を用いて機械学習で分類している点で本研究と重なる。しかしムラは 2 種類のみで実際の製造工程で発生する不良の種類としては少ない。特に、量産において最も多数で、弱いムラとの識別が困難な良品を対象としてい

ない。サンプル数も 100 枚程度と少なく、モデルも SVM binary classifier のみであり、実運用の前段階の基礎検討という位置づけと考えられる。

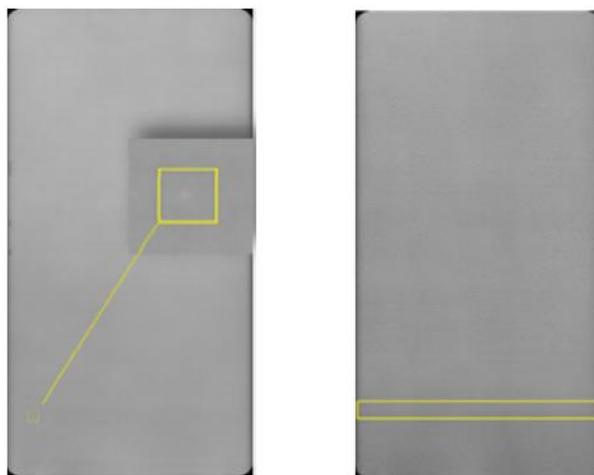


図 4：OLED ディスプレイでのムラ不良：スポットと線 (“Mura defects on OLED displays: spot and line”) [12]

- ムラ定量評価…Neural Network を用いたムラ定量評価システムに関する研究[8]。43 枚の LCD に図 5 に示すような線状、円状など 4 種類のムラを濃淡を変化させて疑似的（人工的）に表示し、人間が 12 段階で目視評価する。この結果と、システムのムラ評価指数（Mean Squared Error, Similarity, Effective Error）をピアソン相関係数で評価、0.82 を達成した。この研究は、機械学習と人間の目視評価との関係に着目している点で本研究と重なるが、実際の製造工程で発生したムラを検出、分類する内容ではない。



図 5：疑似的なムラの例 (“Some examples of pseudo Mura”) [8]

以上のようにディスプレイのムラの自動検出に関する先行研究は数が少なく、内容的には小規模なデータを用いた解析的な研究である。このためディスプレイ分野以外で、画像を用いる検査に機械学習を応用する先行研究を調査した。

- 画像検査への AI 応用…画像を用いた検査への AI（機械学習）応用についてのサーベイ的論文であり、製品の表面状態の画像からディープラーニングを用いて不良検出する検査を例に、製造現場の外観検査に AI を導入する際の課題や対策について議論している [23]。代表的なモデルとしてディープラーニングと One-class SVM を組み合わせたモデルを紹介している。良品画像のみから学習する半教師学習であり、図 6 に示すように、学習し

た良品画像から特徴空間での識別境界を定め、不良品を外れ値として識別する手法である。これは良品と不良品の分類精度を向上させる技術であり、本研究においても参考になるが、本研究では発生工程に早期フィードバックすることが目的であり、不良によって発生工程が異なるため、不良項目間の分類精度も求められる点が異なっている。一方で本先行研究は、様々な外乱要素がある製造現場への AI 導入は人を必要としないものづくりの実現ではなく、これまで以上に人の知識や経験が必要になると主張している。もともと人間が実施している目視検査を機械学習で実施する場合、人間の作業や判断のプロセスを機械で再現することが精度向上につながることを示唆しており、本研究でも参考になる。

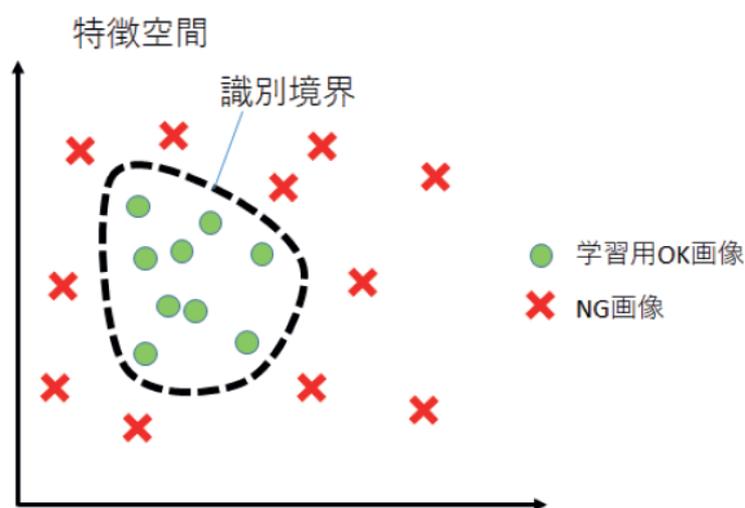


図 6 : One-class SVM のイメージ[23]

- 半導体での機械学習を用いた外観検査…LCD や OLED の製造工程では半導体のプロセスや検査を応用した技術や装置が用いられることが多い。半導体ウェーハ表面に発生した欠陥を光学的に検出、分類する手法としてDSI(Die-to-Statistical Image)比較法が知られている[24][25]。これは良品学習アルゴリズムであり、図7に示すように、良品の学習用画像を統計処理することで良品バラツキを含んだモデルを作成し、これと比較することで欠陥を検出する。疑似欠陥（良品を不良品と誤分類）の発生頻度が低いことが利点であり、本研究でも参考になるが、本研究では発生工程に早期フィードバックすることが目的であり、不良項目間の分類精度も求められる点が異なっている。

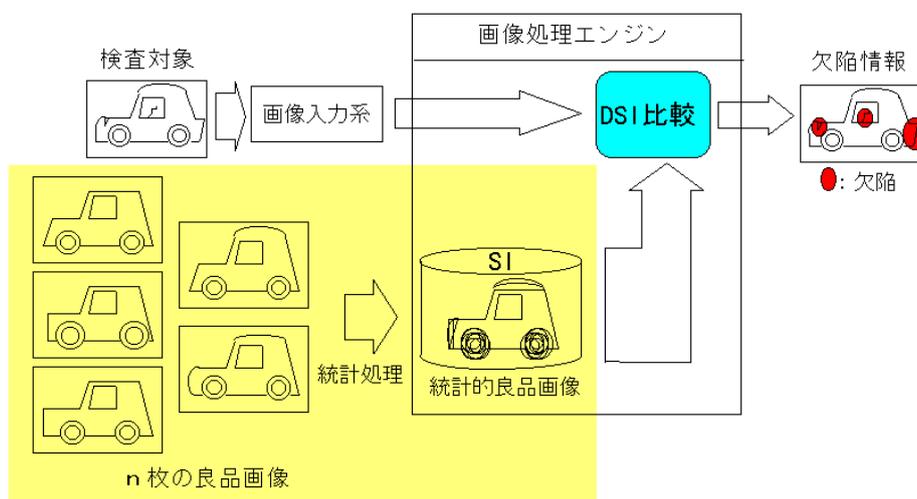


図7：DSI アルゴリズム概念図 [25]

- プリント基板での機械学習を用いた外観検査…基板上に微細な配線を形成する点でディスプレイと共通するプリント基板の製造工程においても、人による目視検査から自動検査への移行が課題になっており、本先行研究では表面実装プリント基板におけるはんだ不良の検出を評価している [26]。図 8 に示すように、前処理にて検査対象画像を読み込み、はんだ箇所を切り出す。はんだ箇所の画像を CNN で識別し、正常品らしさを 0.0~1.0 の数値として出力する。8 種類の学習モデルで 0.9 前後の不良検出率が得られている。本先行研究にも画像の前処理や識別機の構成など参考になる知見があるが、良品か不良品かを識別する検査であり、本研究が目指す不良を分類して発生工程にフィードバックする内容ではない。

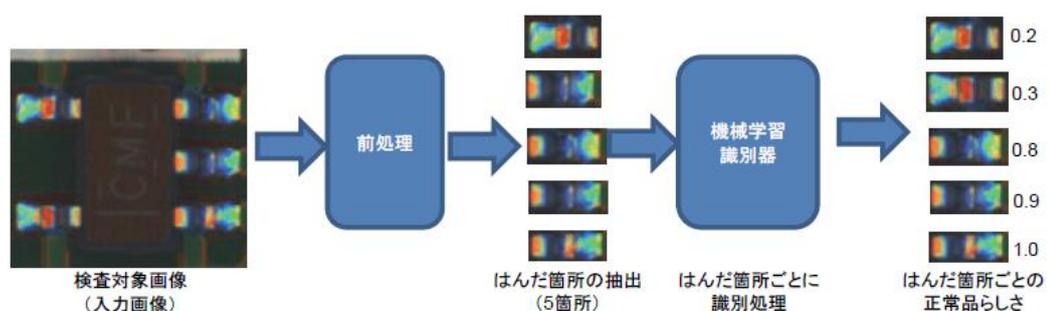


図 8：機械学習による識別手順 [26]

以上のようにディスプレイ分野以外における画像を用いた外観検査への機械学習応用について先行研究を調査したが、良品と不良品の分類精度

向上を目的とする研究が多い。これは、機械学習を応用する検査工程が品質を保証する出荷検査であり、顧客や市場に不良品を流出させないことが最優先に求められるためと考えられる。

## 第3章 機械学習による不良検出評価

### 3.1 評価方法

#### 3.1.1 システム概念図

図9に本研究のシステム概念図を示す。第1章で述べた通り、OLEDの製造工程は、1~3m四方のMother Glass基板上に半導体と似たプロセス技術を用いて数個から数千個のディスプレイを形成する前工程と、Mother Glass基板をディスプレイ単位に切断して電子部品や光学フィルムなどを取り付ける後工程に分けられる。前工程には点灯検査装置があり、Mother Glass基板上のディスプレイそれぞれを点灯し、表示状態を撮像し、画像データを生成、出力する。この画像データに、人間の目視検査結果を正解ラベルとして対応付け、両者を結びつける機械学習モデルを構築する。これにより人の感覚を持った計算機が不良を自動的に検出、分類する手法を実現する。なお同図は学習時の状態であり、運用時には画像データが機械学習モデルに入力され、推定結果が出力される。

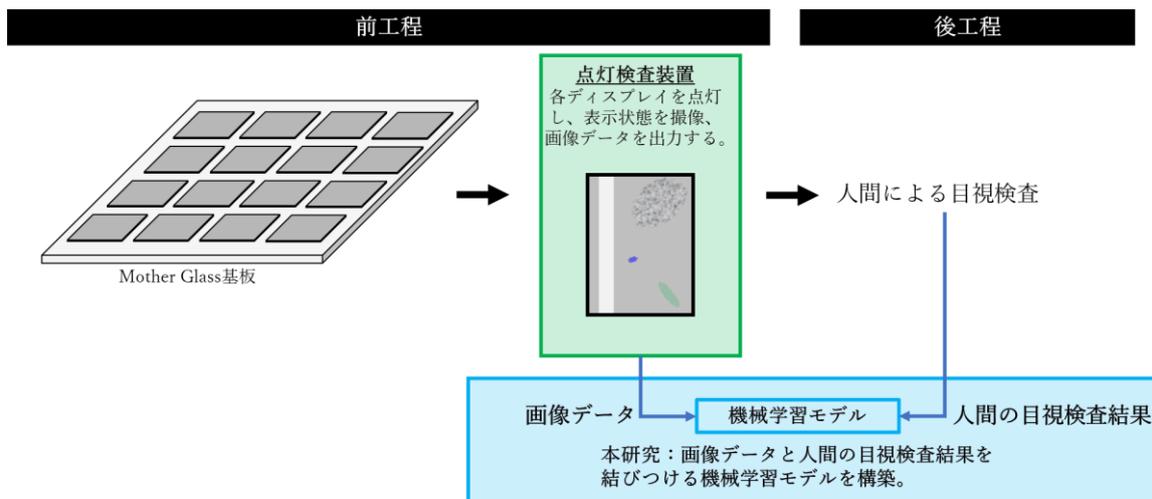


図 9：システム概念図

### 3.1.2 評価指標

本研究ではディスプレイの点灯状態を撮像した画像データを機械学習モデルに入力し、人間の目視検査結果との対応関係を学習させる。機械学習モデルの性能は、その推定結果と目視検査結果の一致の度合いを主に下記 3 つの指標を用いて評価する。

- ・ 正解率(Accuracy)・・・全ての評価（テスト）データのうち、機械学習モデルの推定が目視検査結果と一致した割合。
- ・ 再現率(Recall)・・・項目毎の評価（テスト）データのうち、機械学習モデルの推定が目視検査結果と一致した割合。
- ・ 適合率(Precision)・・・項目毎の機械学習モデルの推定結果のうち、目視検査結

果と一致した割合。

機械学習モデルの学習と評価においては、汎化性能を正しく評価するため、5分割交差検証を実施し、上記指標には5分割の平均値を用いる。

### 3.1.3 機械学習環境

- ・ プログラミング言語：Python
- ・ 実行環境：Jupyter Notebook
- ・ ライブラリ：機械学習関係 scikit-learn、数値計算 NumPy、データ解析 Pandas、グラフ描画 matplotlib、等
- ・ 深層学習フレームワーク：Tensorflow, Keras
- ・ ハードウェア：高速 GPU(RTX2080i)搭載 PC

### 3.1.4 データセット

実際の OLED 製造工程で発生頻度が高い不良に着目し、8項目、各項目 1000枚、計 8000枚の画像データからなるデータセットを作成した。これは前述した先行研究の 10 倍以上の規模である。製造工程の点灯検査装置において、各ディスプレイを点灯させ、点灯画像を光学カメラで撮像する。各画像には人間の目視検査結果を正解ラベルとして対応付ける。実際の製造工程ではプロセス条件、製

造装置の状態、クリーンルームの環境などの要因で様々な不良が発生するが、本データセットでは発生率が高く、特徴の異なる4項目のムラ（ムラA～D）を選んだ。良品との誤分類を評価するため、欠陥のない良品も項目の一つとしている。またムラ以外の不良である回路不良、縦線欠陥、横線欠陥は、ムラとは発生する原因や工程が異なり、正確なフィードバックのためにはムラと分類することが求められるためデータセットに含めた。8つの項目は下記となる。各項目の画像例を図10に示す。ムラの領域は赤い線で示している。なお同図に示した例は、説明のため明確な（程度が酷い）不良を選んだが、実際には認識が困難なほど薄い不良や小さい不良が多い。

- 良品…欠陥のないディスプレイ。
- ムラA…楕円状のムラであり、大きさ、形状、向き、数、位置、濃淡などの特徴は発生したディスプレイ毎に異なる。
- ムラB…縦帯状の輝度が異なる領域がディスプレイのほぼ全面に発生するムラ。形状や大きさは似た場合が多いが、隣接する縦帯の境界での輝度差（コントラスト）は小さい。
- ムラC…面積の小さいスポット状のムラで、画素単位の点欠陥の集合とも見なせる。形状、大きさ、濃淡、位置、数、向きなど多種多様である。
- ムラD…最も特徴のないムラの一つで、特定の形状や大きさ、位置はなく、

濃淡も異なる。

- 回路不良…明確な境界を持った領域で輝度差が生じる不良で、主に走査線や信号線を駆動する周辺回路の故障によって発生する。
- 縦線欠陥…特定の映像信号配線に沿った画素で輝度差が生じる不良。配線間のショートやオープン（断線）が主原因である。
- 横線欠陥…特定の走査信号配線に沿った画素で輝度差が生じる不良。縦線欠陥同様に配線間のショートやオープン（断線）が主原因である。

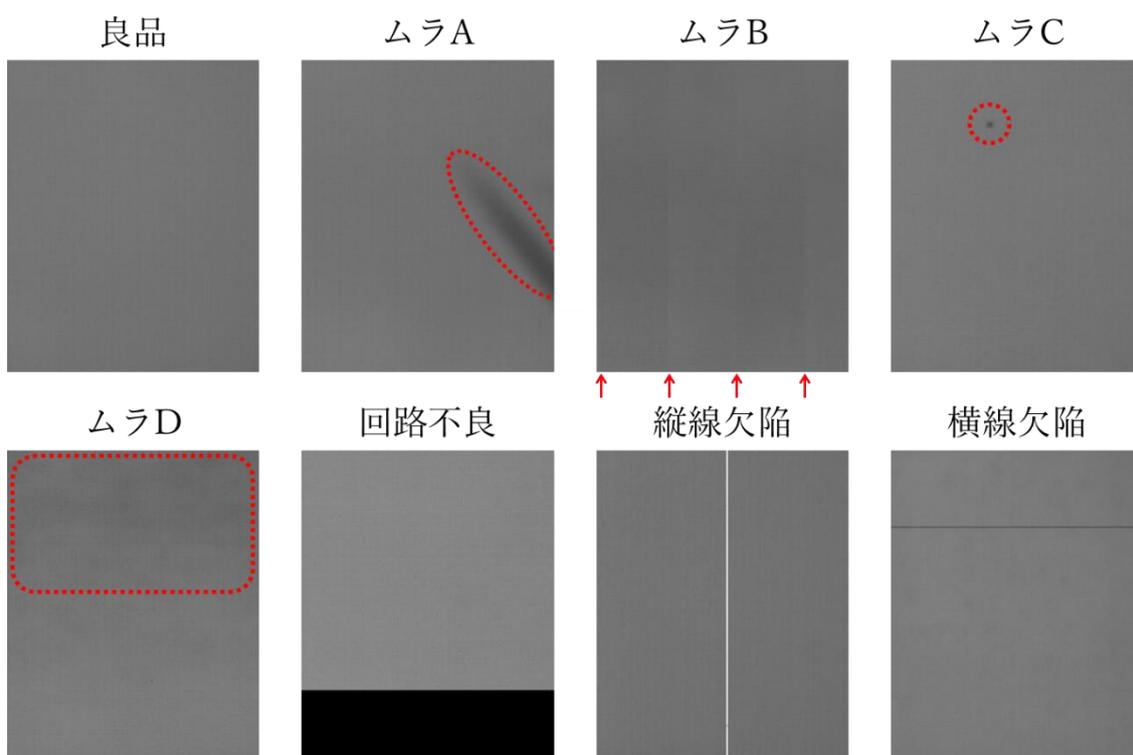


図 10：データセットの各項目の画像例

## 3.2 目視検査特性

### 3.2.1 目視検査

人間による目視検査では、検査精度を担保するために検査条件や検査環境などに様々な工夫がなされているが、人間の視知覚特性から特に重要な点として、不良毎の点灯画面と限度見本が挙げられる。

人間によるディスプレイの表示品質の検査では、不良の検出精度を向上させるため様々な点灯画面が用いられている。例えば正常部よりも輝度が高い不良は、画面全体の輝度が低い点灯画面を用いることで見つけやすくしている[6]。ヴェーバーによる人間の感覚刺激の識別に関する法則では式(1)に示すように、感覚刺激を  $I$ 、その刺激の強度の変化を初めて識別できる変化量（弁別閾値）を  $\Delta I$  とすると、その比である  $k = \Delta I / I$  は広範囲で一定（ $k$  はコンスタント）になることが知られている。

$$k = \frac{\Delta I}{I} \quad (1)$$

これをディスプレイの目視検査にあてはめると、不良検出精度を向上させるには正常部と異常部の差に相当する  $\Delta I$  を大きくしたいが、 $\Delta I / I$  が一定なので、 $\Delta I$  が大きくなる  $I$  を選ぶ。この  $I$  が点灯画面に相当する。例えば正常部より輝度が高い不良を検出するには、正常部と異常部の輝度差に相当する  $\Delta I$  が大きく

なるよう輝度が低い点灯画面  $I$  を用いる。これを機械学習で再現する場合、ヴェーバーの法則は機械には当てはまらないため、 $\Delta I$  自体、つまり正常部と異常部の輝度差自体を拡大する画像のコントラスト強調処理が考えられる。詳細は 3.2.2 項で述べる。

また目視検査において人間が判断に迷う場合、判断基準となる限度見本を用いる方法が知られている [27]。限度見本は良品と不良項目毎の不良品の限度を示す見本であり、不良に近い良品である良品限度と、良品に近い不良である不良限度がある。判断に迷った検査対象品を限度見本と比較することで、検査精度のばらつきを抑える効果がある。これを機械学習で再現するためには、部分空間法を用いてデータ空間を分割することで不良項目毎に 2 クラス分類を実施することが考えられる。詳細は 3.2.3 項で述べる。

### 3.2.2 コントラスト強調

人の目視検査において不良を検出しやすい点灯画面を用いることを機械学習で再現するため、画像のコントラスト強調を評価する。正常部との輝度差（コントラスト）が小さい不良の検出に有効性が期待される。画像処理分野においてコントラストを強調する手法は多くあるが、本研究ではスムーズな強調が可能であるシグモイド関数によるコントラスト強調を評価する。シグモイド関数は  $S$

字型の形状を持ち、式(2)で示される。ここで、 $x$ は強調前の画像の階調(0~255)、 $a$ はゲイン、 $b$ は変曲点、 $y$ は強調後の画像の階調である。

$$y = \frac{255}{1 + \exp[a \times (b - x)]} \quad (2)$$

パラメータ  $a$  と  $b$  は調整の結果、 $a$  は 0.05、 $b$  は階調の中心である 128 に設定した。この設定によるシグモイド関数を図 11(a)に、この関数によるコントラスト強調をムラ A に適用する前後の画像を同図(b)に示す。

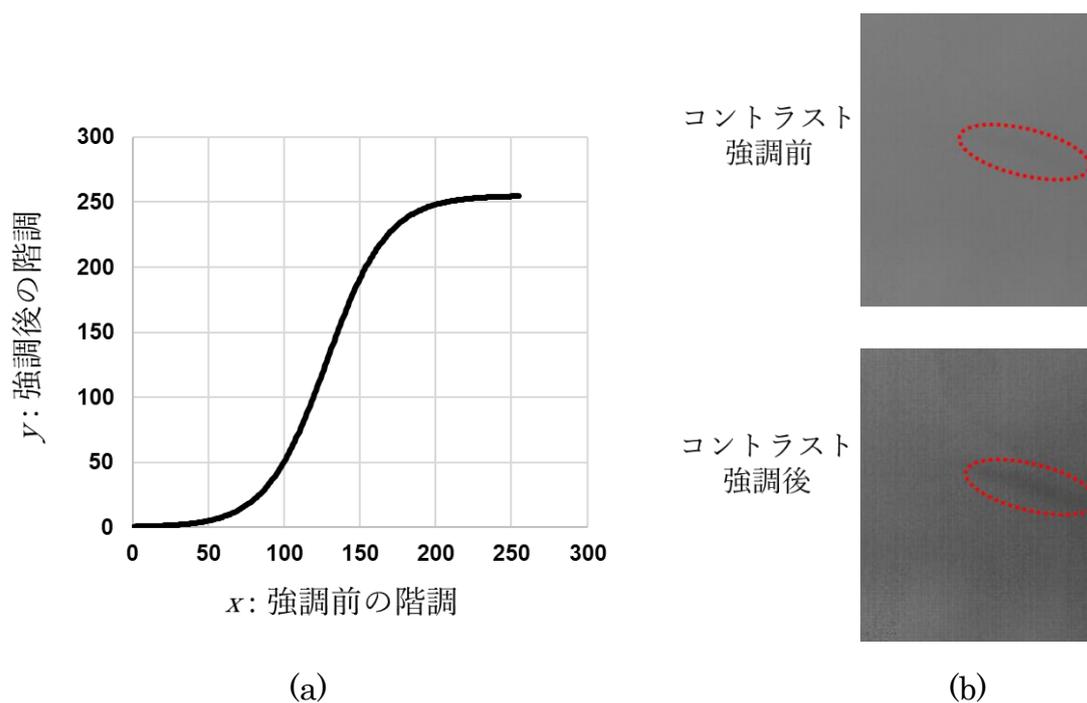


図 11 : (a)コントラスト強調に用いたシグモイド関数、(b)ムラ A のコントラスト強調前後の画像例

コントラスト強調前、ムラ部分（赤い線内）は非常に薄いですが、強調後には認識しやすくなる。ただし背景の正常部の輝度バラツキも増加しており、これが分類精度に与える影響も評価する必要がある。

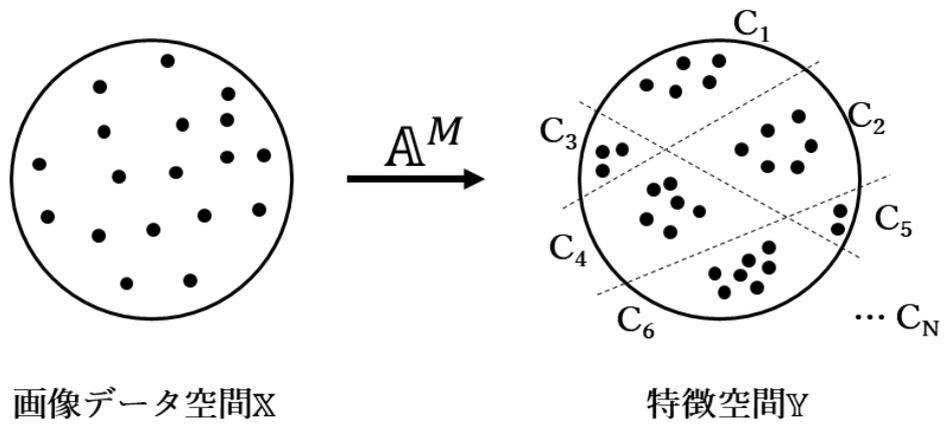
### 3.2.3 部分空間法

目視検査において人が判断に迷う場合に判断基準として使用される限度見本を機械学習で再現するために、不良項目毎に分類する部分空間法を評価する。部分空間法はパターン認識においてデータ空間を部分空間に分割することで分類精度を改善する手法である。図 12(a)は、本研究に多クラス分類を適用した場合の概念図である。画像データ空間 $\mathbb{X}$ 、特徴空間 $\mathbb{Y}$ 、画像データを特徴空間に射影する射影関数  $\mathbf{A}^M$ で構成され、これらの間には式(3)の関係がある。

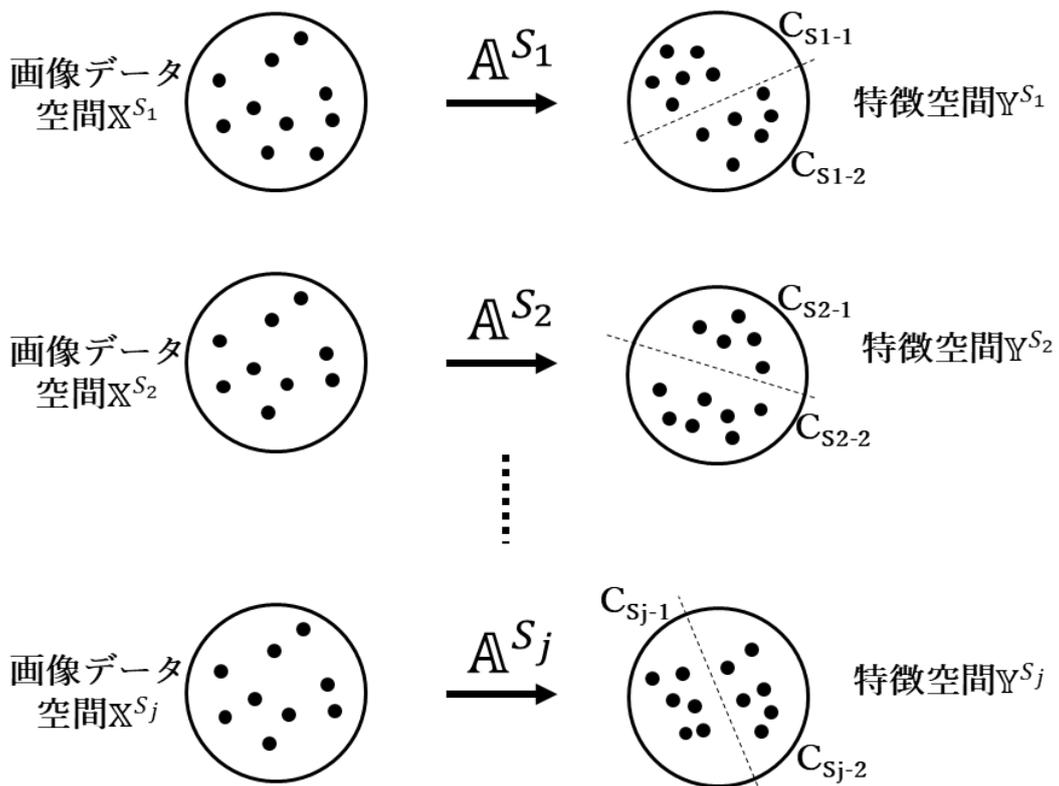
$$\mathbb{Y} = \mathbf{A}^M \mathbb{X} \quad (3)$$

本研究では射影関数  $\mathbf{A}^M$ は多クラス分類を行う機械学習モデルに相当する。画像データは機械学習モデルによって特徴空間に射影され、境界線によって多クラス分類される。

同図(b)は本研究に部分空間法を用いた場合の概念図であり、同図(a)を  $j$  個の部分空間  $S_1, S_2, \dots, S_j$  に分割した場合に相当する。



(a) 多クラス分類



(b) 部分空間法による 2 クラス分類

図 12：多クラス分類(a)と部分空間法による 2 クラス分類(b)の概念図

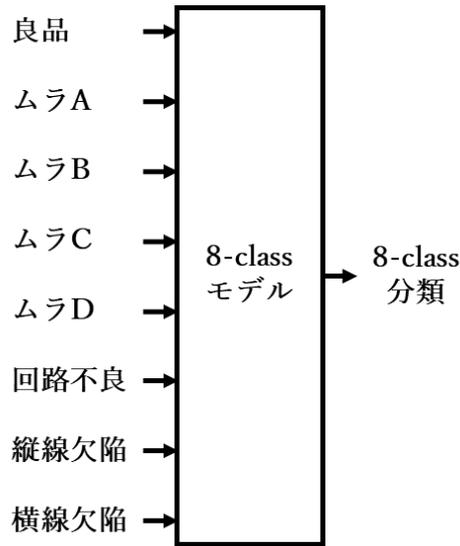
各部分空間において、画像データ空間 $X^{S_j}$ は射影関数 $A^{S_j}$ によって特徴空間 $Y^{S_j}$ に射影され、これらの間には式(4)の関係がある。

$$Y^{S_j} = A^{S_j} X^{S_j} \quad (4)$$

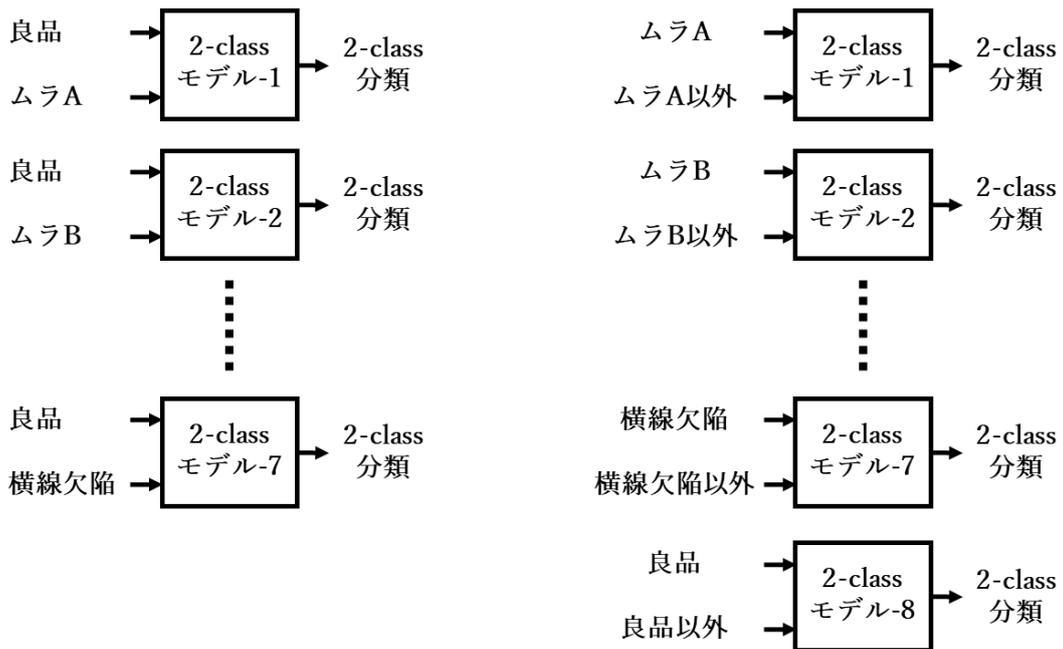
本研究では射影関数 $A^{S_j}$ は各部分空間において2クラス分類を行う機械学習モデルに相当する。

部分空間法を本研究のデータセットに適用する場合、各項目と良品との2-class分類と、各項目とそれ以外との2-class分類の二種類の方法が考えられる。

図13において、分割前の多クラス分類では同図(a)に示すように8項目のデータを1つの8-classモデルに入力し、8-classの分類結果を得る。部分空間法による分割のうち、各項目と良品との2-class分類では同図(b)のように、良品と他の7項目のうちの1項目の画像を7つの2-classモデルそれぞれに入力し、2-class分類結果を得る。また各項目とそれ以外との2-class分類では同図(c)のように、各項目とそれ以外の7項目を1つのクラスとして8つの2-classモデルそれぞれに入力し、2-class分類結果を得る。



(a) 分割前の 8-class 分類



(b) 各項目と良品との 2-class 分類      (c) 各項目とそれ以外との 2-class 分類

図 13：部分空間法によるデータセットの分割。(a)分割前の 8-class 分類、(b)

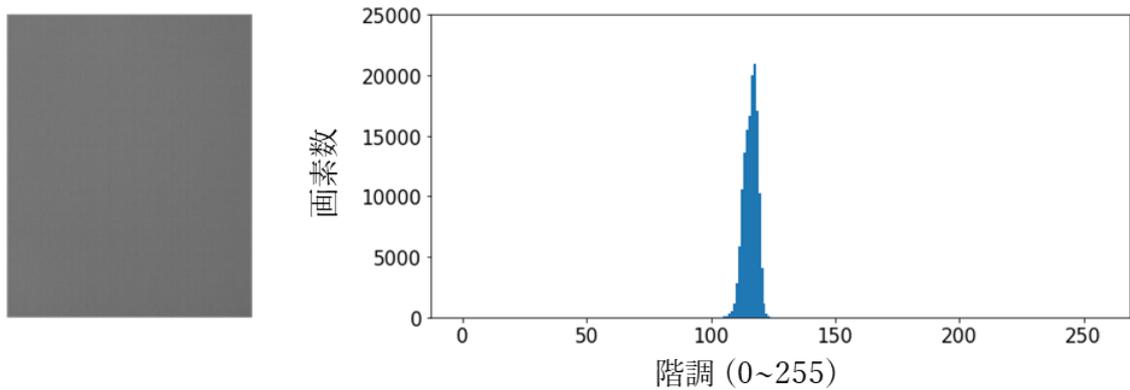
各項目と良品との 2-class 分類、(c)各項目とそれ以外との 2-class 分類。

### 3.3 多クラス分類の評価結果

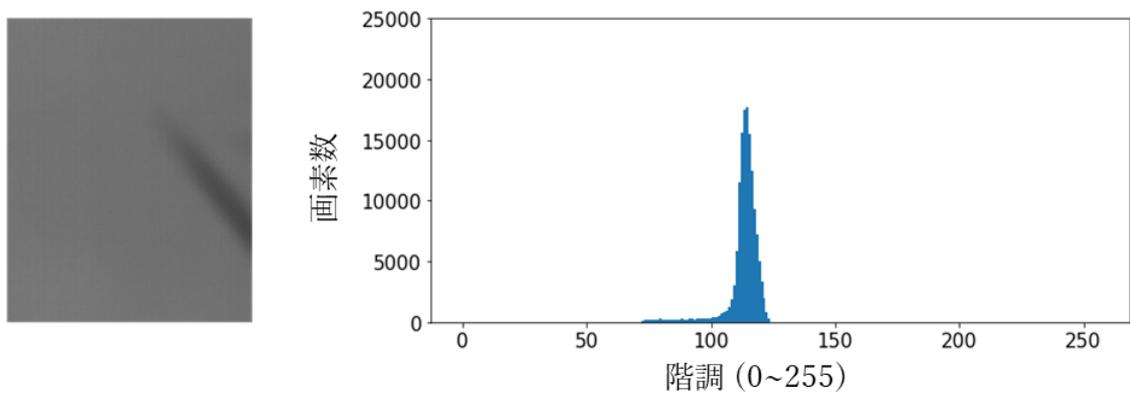
#### 3.3.1 SVM による多クラス分類の評価結果

サポートベクトルマシン(SVM: Support Vector Machine)は、1960年代に Vapnik らによって提案された機械学習アルゴリズムである。一般に機械学習アルゴリズムはクラス分類問題においてクラス間を識別する超平面を求めるが、SVMは複数考えられる超平面のなかからマージンが最大となる超平面を選び出すことが特徴である[28]。名称のサポートベクトルとは各クラスのデータのなかで超平面までの距離が最も短いデータであり、この距離(マージン)を最大にするような超平面を求めることで分類性能を向上させている。1990年代には、入力データを高次の特徴空間に写像することで非線形分類にも対応可能となるカーネル法(カーネルトリック)という手法が提案され、現在においても有力な機械学習アルゴリズムである。

本研究では SVM の特徴量として、画像データの基本的な特徴を示す階調毎の画素数(階調ヒストグラム)を用いる。図 14(a)は良品、同図(b)はムラが発生したディスプレイの画像とその階調ヒストグラムである。各ディスプレイの画像データは、輝度が最も低い黒を示す 0 から輝度が最も高い白を示す 255 までの 256(8bit)階調を持った約 5 万個の画素で構成される。階調ヒストグラムの横軸は 0 から 255 までの階調、縦軸は階調毎の画素数である。



(a)



(b)

図 14 : (a)良品ディスプレイの画像 (左)とその階調ヒストグラム (右)、  
(b)ムラが発生したディスプレイの画像 (左) とその階調ヒストグラム (右)。

同図(a)の良品では全画素が階調 120 前後の中央付近に分布しているが、同図(b)のムラが発生したディスプレイのヒストグラムでは、良品パネルに近い正常部に加え、その左側（低階調側）に裾野のような形でムラ領域の画素が分布している。こうした違いを特徴量としてムラの検出、分類が可能かを評価する。

図 15 は、データセット画像のコントラスト強調の有無、非線形性 (RBF カーネル)、正則化コスト関数  $C$  をパラメータとした 7 条件での SVM による 8-class 分類の正解率を示している。同図の縦軸は 5 分割交差検証の正解率の平均値である。コントラスト強調はデータセットの全 8000 枚の画像を前述のシグモイド関数を用いて前処理した。なお SVM については付録の概念検証において小規模データによる事前評価を実施しており、その結果から条件を選んでいる。同図のように、正解率は 0.469~0.681、7 条件のうち 6 条件で 0.603~0.681 と狭い範囲に集中している。条件別では、コントラスト強調により正解率は 0.610 から 0.634 に改善、一定の効果は認められた。また線形分類ではコスト関数  $C$  による相違は小さく、非線形分類ではコスト関数  $C$  への依存性が認められた。こうした傾向は、小規模のデータで実施した概念検証でも同様であった。

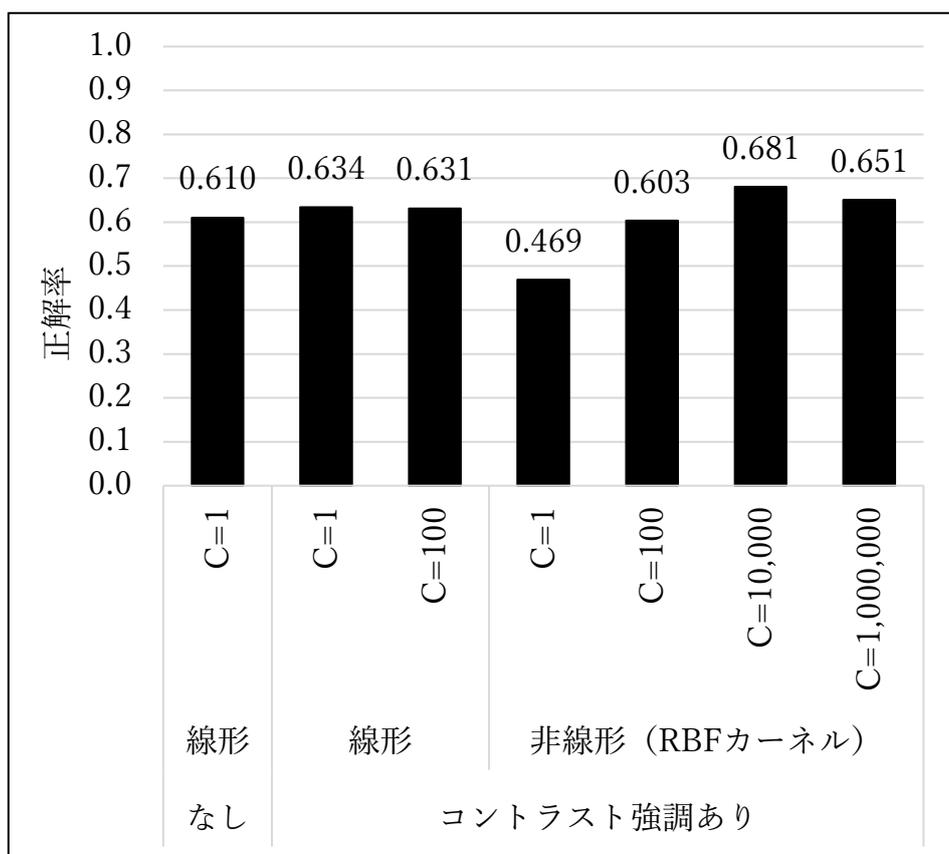


図 15 : SVM による 8-class 分類の正解率

このうち正解率が 0.681 と最も高かった条件（コントラスト強調あり、非線形 RBF カーネル、C=10,000）の混同行列を表 1 に、混同行列から計算した項目別の再現率と適合率を図 16 に示す。ムラ D では再現率、適合率ともに 0.9 以上と良好であるが、ムラ A~C では 0.4~0.7 と低く、良品も 0.5 前後と低い。混同行列でもムラ A~C と良品の 4 項目の中での混同（誤分類）が多くなっている。またムラ以外の不良では、回路不良は 0.95 程度と良好、縦線欠陥も 0.8~0.9 と比較的良好だが、横線欠陥は 0.6 前後と低い。

項目 (目視検査結果)	推定結果								合計
	良品	ムラA	ムラB	ムラC	ムラD	回路不良	縦線欠陥	横線欠陥	
良品	117	24	10	40	1	0	2	7	200
ムラA	50	99	7	31	2	0	1	10	200
ムラB	19	10	135	20	4	3	1	8	200
ムラC	56	25	18	86	0	0	2	12	200
ムラD	2	4	5	0	184	0	0	4	200
回路不良	0	0	1	1	0	193	3	1	200
縦線欠陥	7	3	5	5	1	1	162	15	200
横線欠陥	26	18	10	22	4	0	8	111	200

表 1 : SVM (コントラスト強調あり、非線形 RBF カーネル、C=10,000) での

混同行列

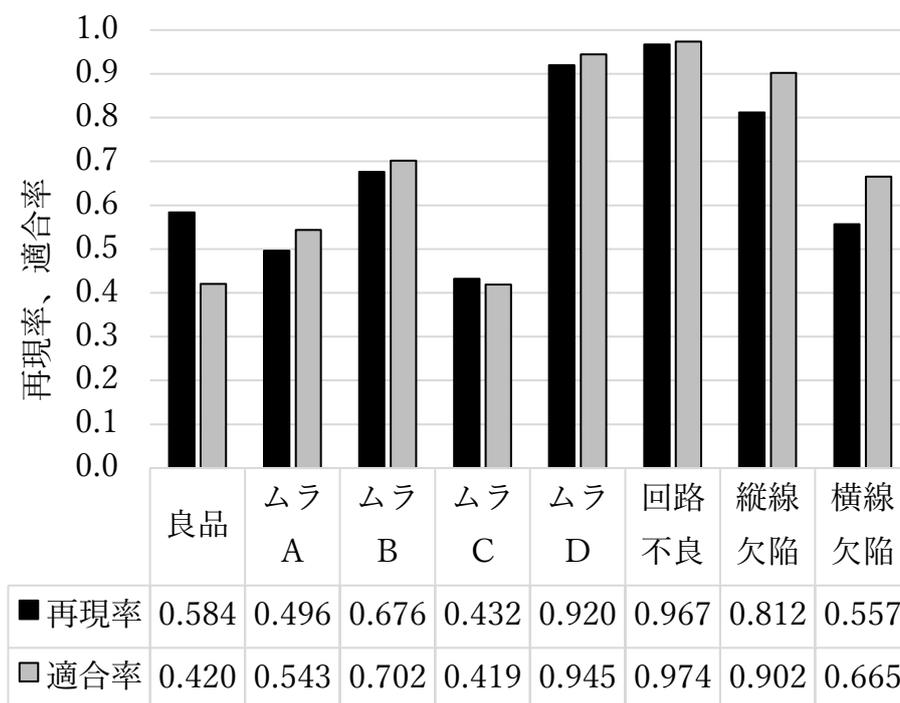


図 16 : SVM (コントラスト強調あり、非線形 RBF カーネル、C=10,000) で

の項目別再現率、適合率

### 3.3.2 CNN による多クラス分類の評価結果

本研究が対象とする画像データは、縦横 2 次元および色情報(RGB)の 3 次元の構造を持つ。上述した SVM では画像データを階調毎の画素数という 1 次元のデータに変換するため、画素の位置情報が失われることになるが、画像データをもとの構造のまま入力することが可能なアルゴリズムとして畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) がある [29][30][31][32]。

図 17 に本研究で用いる CNN の基本構造を示す。畳み込み層、Max-Pooling 層、全結合層、ソフトマックス関数が主な構成要素である。

畳み込み層は、入力画像に対して小さなサイズ (3x3 や 5x5 画素程度) のフィルタをスライドさせながら畳み込み演算を実施することで、入力画像の中の局所的な特徴を抽出する。入力される画像データ (あるいは前層からのデータ) のサイズを  $W$  (幅)  $\times$   $H$  (高さ)  $\times$   $C$  (チャンネル) とする。本研究で用いる画像データの場合、 $W=218$ 、 $H=266$ 、 $C=3$ (RGB)である。各画素のインデックスを  $(i, j, c)$  ( $i=0, 1, \dots, W-1, j=0, 1, \dots, H-1, c=0, 1, \dots, C-1$ )とし、画素値を  $z_{ijc}$  で表す。またフィルタのサイズを  $W_f$  (幅)  $\times$   $H_f$  (高さ)  $\times$   $C$  (入力のチャンネルと同数)、フィルタの画素インデックスを  $(p, q, c)$  とし、各フィルタの画素値を  $h_{pqc_k}$  ( $k=0, 1, \dots, C-1$ )で表す。畳み込み層では各フィルタについて並行に計算が

実行され、それぞれサイズ  $W \times H \times 1$  の出力が得られ、この結果を画素ごとに全チャンネルに渡って加算する。また各チャンネルではバイアス  $b_k$  が加算される。以上によって得られる  $l$  層の畳み込み演算結果  $u_{ijk}^l$  は下式で表すことができる。

$$u_{ijk}^l = \sum_{c=0}^{C_f-1} \sum_{p=0}^{W_f-1} \sum_{q=0}^{H_f-1} z_{i+p, j+q}^{l-1} h_{pqc}^l + b_k^l \quad (5)$$

これに対して活性化関数  $f(u)$  が適用され、

$$z_{ijk}^l = f(u_{ijk}^l) \quad (6)$$

となり、次の層に伝搬される。本研究では活性化関数として ReLu(Rectified Linear unit)関数を用いる。下記式で表されるように恒等関数  $f(u) = u$  のうち  $u < 0$  の部分を  $u = 0$  で置き換えた関数である。

$$f(u) = \max(u, 0) \quad (7)$$

プーリング層は、入力データに対して小さなサイズ (2x2 程度) のフィルタをスライドさせて最大値や平均値を抽出することで、その局所領域内の値を要約する平滑化の機能がある。また入力データの空間解像度を下げるダウンサンプリングの機能もあり、画像内の特徴の移動不変性 (位置変化に対する不変性) が得られる。本研究では最大値を抽出する Max-Pooling 層を用いる。入力される

画像データ（あるいは前層からのデータ）のサイズを  $W$ （幅） $\times H$ （高さ） $\times C$ （チャンネル）とし、フィルタのサイズを  $W_f$ （幅） $\times H_f$ （高さ） $\times C_f$ （チャンネル）とする。入力データにおいて画素 $(i, j)$ を中心とするフィルタ領域に含まれる画素の集合 $P_{ij}$ から最大値を抽出し、下式のように  $l$ 層の出力 $u_{ijk}^l$ を得る。

$$u_{ijk}^l = \max_{(p, q) \in P_{ij}} z_{pqk}^{l-1} \quad (8)$$

畳み込み層と Max-Pooling 層から出力された 2 次元データは、平坦化層 (Flattening layer) で 1 次元データになり、全結合層を経て、ソフトマックス関数に入力される。ソフトマックス関数は、多クラス分類において最終層の活性化関数として一般的に用いられ、入力された画像データが各クラスに属する確率を出力する。最終層は分類するクラス数と同数のユニット ( $n$ ) を持ち、各ユニットの入力を  $u_i$  ( $i=1, 2, \dots, n$ ) とすると、 $k$  番目のユニット（クラス）の出力は下式で表すことができる。

$$y_k = \frac{\exp(u_k)}{\sum_{i=1}^n \exp(u_i)} \quad (9)$$

一般に CNN では畳み込み層と Max-Pooling 層は概ね交互に積層され、入力画像の 2 次元的特徴を移動不変に抽出することができるが、本研究においては、同じ項目に属するムラを表示画面内に発生する位置や向き、数に関わらず同じ

項目として検出、分類することに有効と期待できる。ムラ検出に有効な CNN の基本構造を評価するため、畳み込み層と Max-Pooling 層を 2~6 組に変化させた 5 つの CNN を評価した。

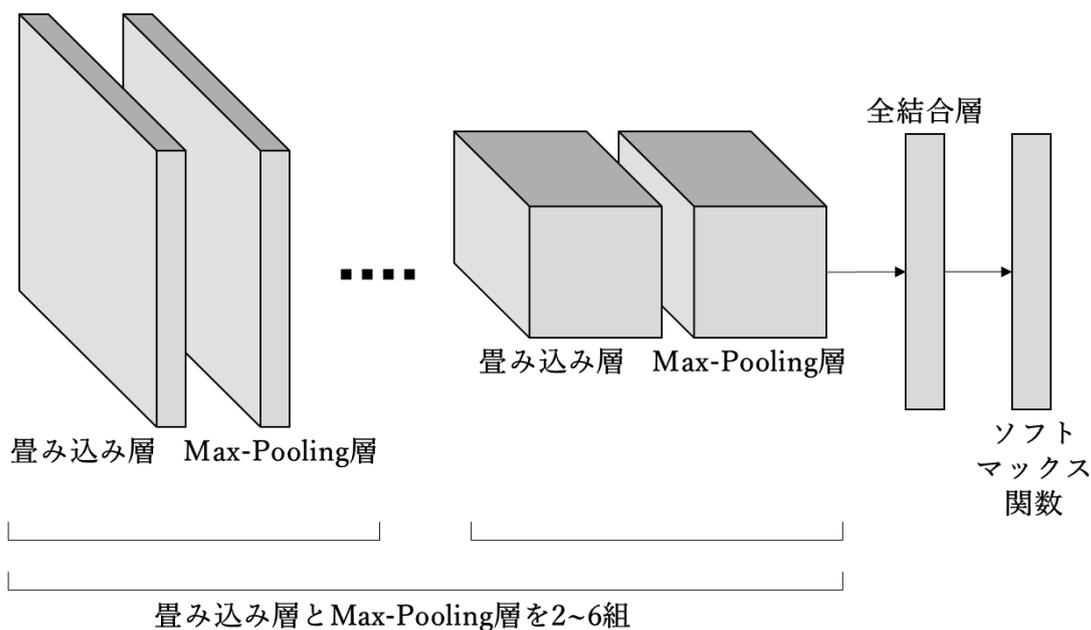


図 17：畳み込み層と Max-Pooling 層を 2~6 組とした 8-class CNN の基本構造

図 18 に CNN 正解率の畳み込み層と Max-Pooling 層の組数への依存性を示す。同図の縦軸は 5 分割交差検証の正解率の平均値である。同図に示すように、畳み込み層と Max-Pooling 層が 2 組の最も浅い CNN の正解率は最も低い 0.756 だった。層数が増えると正解率は向上し、3 組では 0.799、4 組および 5 組では 0.830 だったが、6 組では逆に 0.818 に低下した。

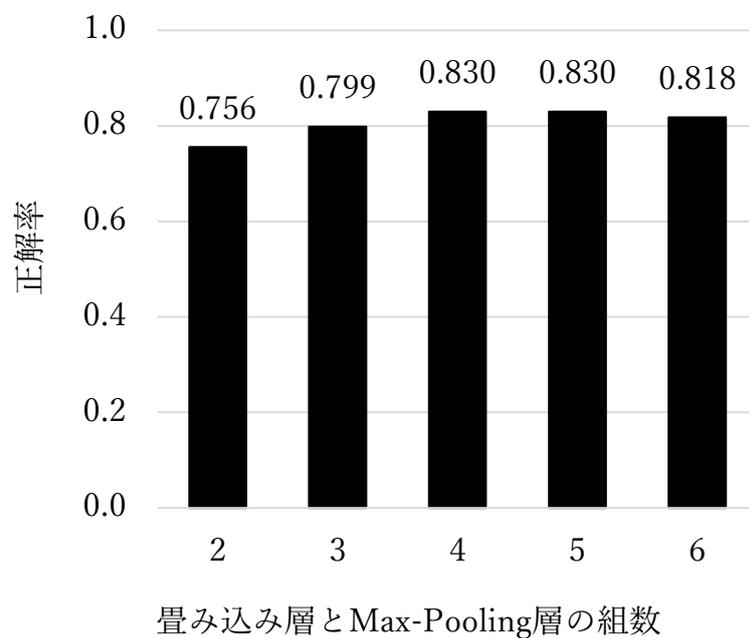


図 18：8-class CNN 正解率の畳み込み層と Max-Pooling 層の組数への依存性

このうち正解率が 0.830 と最も高かった畳み込み層と Max-Pooling 層が 4 組の CNN の混同行列を表 2 に、混同行列から計算した項目別の再現率と適合率を図 19 に示す。

項目 (目視検査結果)	推定結果								合計
	良品	ムラA	ムラB	ムラC	ムラD	回路不良	縦線欠陥	横線欠陥	
良品	140	35	1	17	0	0	0	7	200
ムラA	58	117	1	17	0	0	0	7	200
ムラB	2	2	187	4	0	3	1	1	200
ムラC	21	11	1	161	0	0	0	6	200
ムラD	1	0	3	1	194	0	0	0	200
回路不良	4	2	1	1	0	188	1	2	200
縦線欠陥	4	1	0	3	0	1	187	2	200
横線欠陥	17	13	1	12	0	1	1	154	200

表 2：畳み込み層と Max-Pooling 層が 4 組の CNN の混同行列

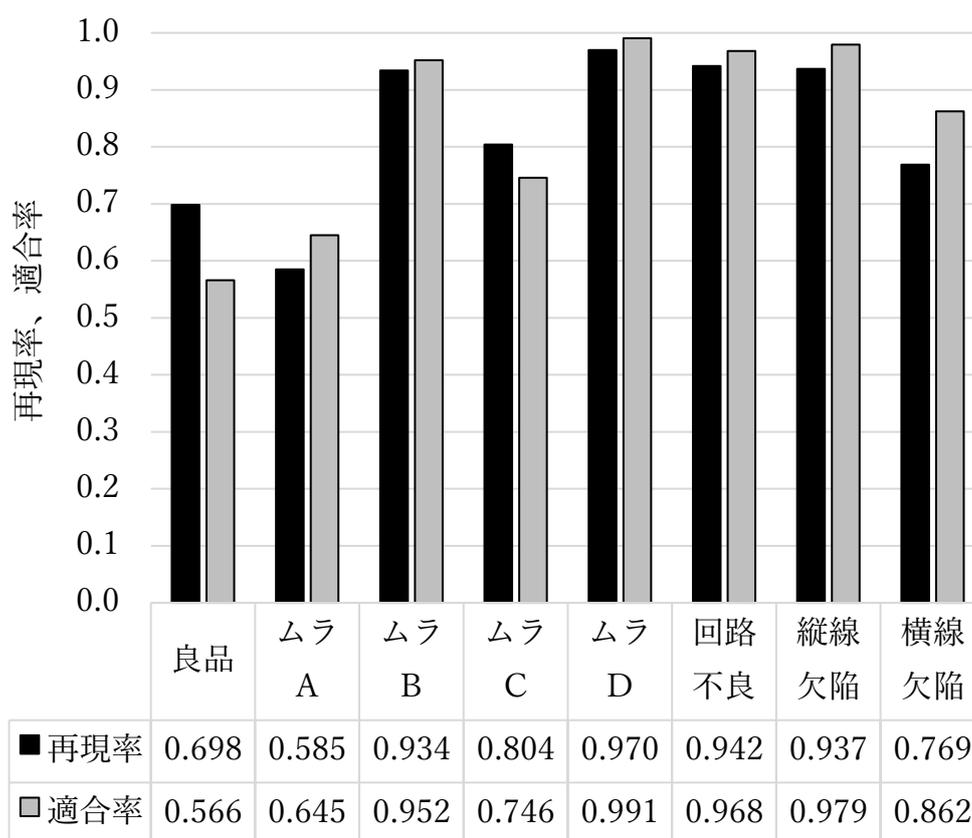


図 19：畳み込み層と Max-Pooling 層が 4 組の CNN の再現率と適合率

同図が示すように、ムラ B、ムラ D、回路不良、縦線欠陥の 4 項目は再現率と適合率が 0.95 程度と良好である。一方、良品とムラ A は再現率と適合率が 0.6 程度と低く、ムラ C も 0.8 前後と不十分である。表 2 の混同行列においても、ムラ A は 200 枚のテスト画像のうち 58 枚を良品と混同しており、誤分類のうち最多となっている。良品をムラ A と混同した逆のケースも 35 枚と多く発生した。ムラ C と良品の間でも混同が 21 枚、17 枚と多い。

この畳み込み層と Max-Pooling 層が 4 組の CNN を用い、コントラスト強調を実施した場合の混同行列を表 3 に、再現率と適合率を図 20 に示す。全 8000 枚の画像を、前述のシグモイド関数を用いてコントラスト強調し、畳み込み層と Max-Pooling 層が 4 組の CNN で処理した。8 項目全体の正解率はコントラスト強調前の 0.830 からコントラスト強調後で 0.846 に改善、SVM 同様、一定の効果を確認した。項目別では、良品の適合率は 0.566 から 0.610 に改善したが、再現率は 0.698 から 0.699 と同等。ムラ A では再現率は 0.585 から 0.609、適合率は 0.645 から 0.658、ムラ C では再現率は 0.804 から 0.852、適合率は 0.746 から 0.822 と一定の改善効果を確認できた。しかしムラ B やムラ D の 0.95 程度には及ばなかった。

項目 (目視検査結果)	推定結果								
	良品	ムラA	ムラB	ムラC	ムラD	回路不良	縦線欠陥	横線欠陥	合計
良品	140	36	2	14	1	0	1	6	200
ムラA	53	122	3	11	2	0	0	9	200
ムラB	1	1	191	2	1	3	1	1	200
ムラC	12	10	2	170	0	0	0	5	200
ムラD	0	0	2	1	195	0	1	0	200
回路不良	5	2	1	1	0	187	2	3	200
縦線欠陥	3	2	1	2	0	1	188	2	200
横線欠陥	15	13	2	7	1	1	1	161	200

表 3：コントラスト強調画像を用いた畳み込み層と Max-Pooling 層が 4 組の

CNN の混同行列

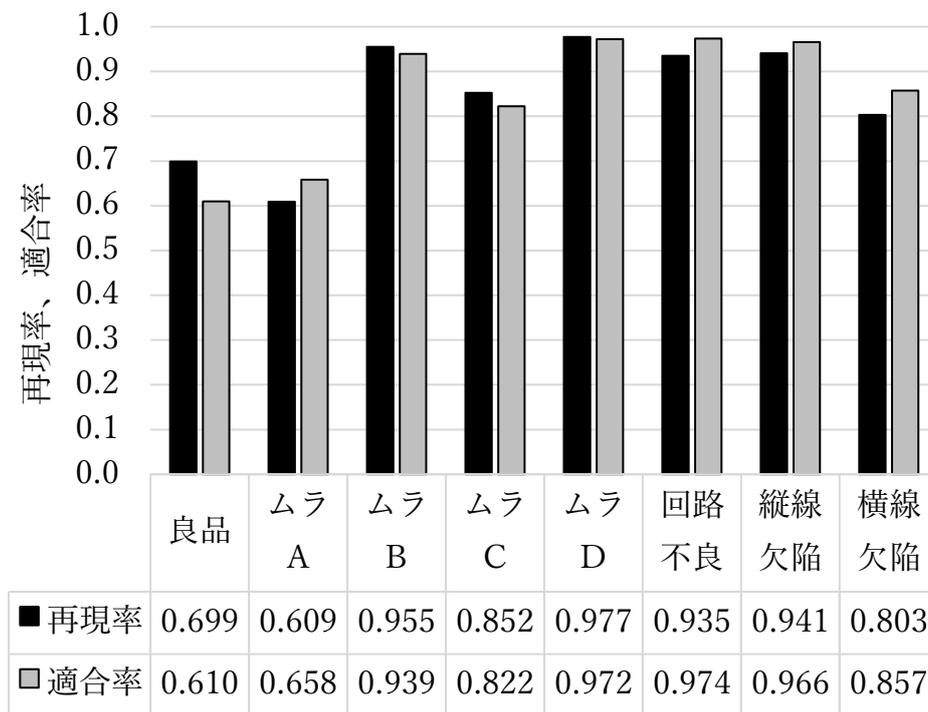


図 20：コントラスト強調画像を用いた畳み込み層と Max-Pooling 層が 4 組の

CNN の再現率と適合率

以上のようにコントラスト強調は、大幅ではないが一定の改善効果が認められ、懸念された輝度バラツキ増加に伴う悪影響は特に認められなかった。また前述 SVM で最も正解率が高かった条件の再現率と適合率（図 16）と比較すると、計 16 の指標のうち 14 の指標で CNN（図 20）の方が良好である。残り 2 つの指標では、回路不良の再現率は SVM で 0.967 に対し CNN で 0.935 とどちらも良好、適合率は両者 0.974 だったので、項目別でも SVM より CNN が良好と判断できる。

### 3.3.3 Residual Network による多クラス分類の評価結果

一般に深層学習では、層を深くすると精度が向上する傾向があるが、層を深くしすぎると勾配消失等のため学習が不十分となり精度が改善しない課題がある。Residual Network は有効な対策の一つであり、図 21 に示すようにモデル中に残差接続（ショートカット構造、バイパス構造等とも呼ばれる）を設けたネットワークで、ある層の出力に過去の層の出力を加算することで処理の過程で情報が失われることを防ぐ[33]。

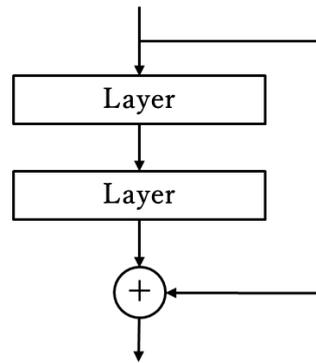


図 21：Residual Network における残差接続の基本構造

前項の CNN の正解率は、畳み込み層と Max-Pooling 層を 2 組から 5 組まで増やしていくと改善していったが、6 組では逆に低下した。また正解率が最も高かった畳み込み層と Max-Pooling 層が 4 組の CNN では、正常部との輝度差（コントラスト）が小さいムラ A や、発生面積が小さいムラ C で再現率、適合率が不十分であった。これらが Residual Network によって改善するかを評価するため、本研究では Keras の ResNet50 を用い、ResNet50 の後段に前項の CNN で使用した全結合層以下を接続した。CNN の構成を示した図 17 において、畳み込み層と Max-Pooling 層の部分を ResNet50 に置き換えたモデルである。学習方法については、ResNet50 のパラメータに Keras が提供する ImageNet 画像による学習済みのパラメータをそのまま用いて全結合層のパラメータのみを本研究のデータセットで学習する方法（以降、“not trainable”と呼ぶ）と、ResNet50 のパラメータを含めて全パラメータを本研究のデータセットで学習する方法

(以降、“trainable”と呼ぶ)の2通りを評価した。

この2通りの学習方法とコントラスト強調の有無を条件とした Residual Network 正解率を図 22 に示す。評価には 5 分割交差検証を用い、同図の縦軸は 5 分割の正解率の平均値である。コントラスト強調による正解率の改善については、学習方法が”not trainable”の場合で 0.410 から 0.561 に、学習方法が”trainable”の場合で 0.598 から 0.788 と、前述の SVM や CNN 以上にコントラスト強調による正解率改善効果が認められた。学習方法については、コントラスト強調有無いずれの場合も、ResNet50 のパラメータを含めて全パラメータを学習する方法(“trainable”)で正解率が高い。この原因はデータセットの特徴にあると考えられる。本データセットの画像は図 2 に示すように、類似した画像から小さな違いを見つけることが特徴である。一方、Keras が提供する ResNet50 のパラメータは、枚数もカテゴリもはるかに多い ImageNet (1400 万枚、2 万カテゴリ以上)を用いて学習している。このため ResNet50 のパラメータは本データセットに有効ではなく、ResNet50 を含めた全パラメータを本データセットで学習した条件 (“trainable”) で正解率が高かったと考えられる。しかし正解率は最高でも 0.788 で、SVM よりは良好だが、CNN には及ばなかった。

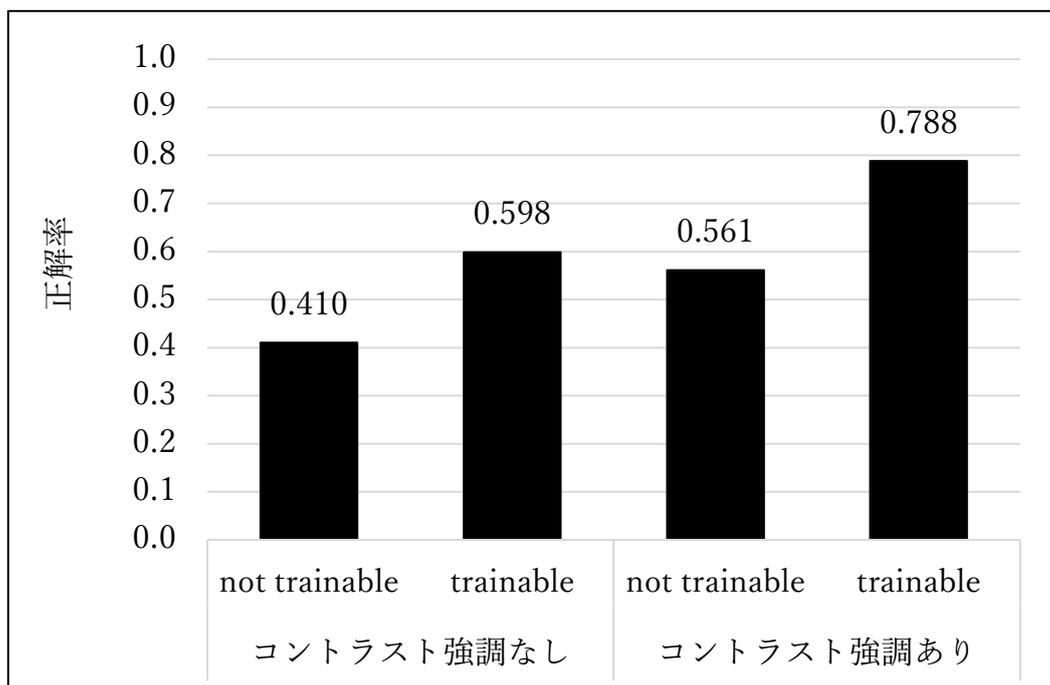


図 22 : Residual Network による 8-class 分類正解率のコントラスト強調有無  
と学習方法への依存性

このうち正解率が 0.788 と最も高かった、コントラスト強調を用いて ResNet50 のパラメータを含めて全パラメータを学習する条件(“trainable”)での混同行列を表 4 に、混同行列から計算した項目別の再現率と適合率を図 23 に示す。Residual Network で改善を期待した正常部との輝度差 (コントラスト) が小さいムラ A と発生面積が小さいムラ C のうち、まずムラ A に着目すると、表 4 においてムラ A を良品と混同したのは 40 枚、その逆の混同は 23 枚だが、CNN (コントラスト強調あり) では表 3 においてそれぞれ 53 枚と 36 枚だったので、Residual Network において 2/3 程度に低減が認められる。ムラ C につい

ては、表 4 においてムラ C を良品と混同したのは 13 枚、その逆の混同は 5 枚であるが、CNN（コントラスト強調あり）では表 5 においてそれぞれ 12 枚と 14 枚だった。Residual Network においてムラ C を良品と混同したのは 1 枚増加だが、良品をムラと混同したのは 1/3 程度に減少している。再現率と適合率についても Residual Network（図 23）と CNN（図 20）を比較すると、ムラ A の再現率は CNN の 0.609 から Residual Network で 0.602 と同等だが、適合率は 0.658 から 0.751 に改善、ムラ C の再現率は 0.852 から 0.785 に減少だが、適合率は 0.822 から 0.912 と改善した。このように Residual Network では薄いムラが多いムラ A、発生面積が小さいムラ C で一定の改善効果が認められる。しかし、ムラ B とムラ D については、Residual Network で良品をムラ B と混同したのは 23 枚（表 4）で、CNN の 2 枚（表 3）から大幅増加するなど悪化した。これが 8-class 全体の正解率が CNN に及ばなかった原因である。

以上のように本研究のデータセットにおいては Residual Network によって改善する項目と悪化する項目があることが分かった。

項目 (目視検査結果)	推定結果								
	良品	ムラA	ムラB	ムラC	ムラD	回路不良	縦線欠陥	横線欠陥	合計
良品	106	23	23	5	21	1	0	21	200
ムラA	40	120	11	4	12	0	0	11	200
ムラB	32	4	139	1	16	3	1	3	200
ムラC	13	6	8	157	8	2	0	6	200
ムラD	3	0	0	0	196	0	0	0	200
回路不良	0	0	0	0	2	196	1	1	200
縦線欠陥	1	1	1	1	2	4	189	2	200
横線欠陥	17	6	8	4	4	2	1	158	200

表 4 : Residual Network において全パラメータを学習(“trainable”)、コントラ

スト強調を実施した条件での混同行列

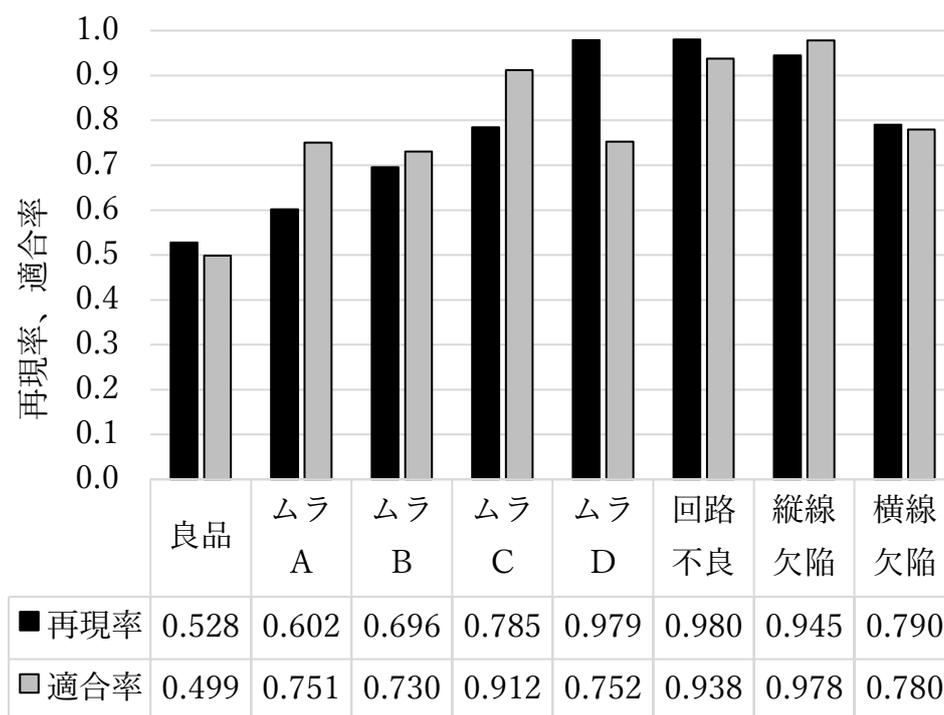


図 23 : Residual Network において全パラメータを学習(“trainable”)、コント

ラスト強調を実施した条件での再現率と適合率

### 3.4 部分空間法による 2 クラス分類の評価結果

目視検査において人間が判断に迷う場合に使用される限度見本を機械学習で再現するために、部分空間法にもとづく不良項目ごとの 2 クラス分類を評価する。ここで 2 クラス分類には、良品と他の 7 項目のうちの 1 項目による 2 クラスと、各項目とそれ以外の項目による 2 クラスの二種類がある。機械学習モデルとしては前節の多クラス分類と同様、SVM、CNN、Residual Network のそれぞれで精度を評価する。

#### 3.4.1 SVM による 2 クラス分類の評価結果

前節の 8-class 分類で評価した 7 条件からコントラスト強調なしを除いた 6 条件の SVM で 2-class 分類を実施した結果の正解率を図 24~31 に示す。各図において縦軸の正解率はこれまでと同様に 5 回の交差検証の平均値である。

ムラ A では、良品との 2-class 分類、ムラ A 以外との 2-class 分類のいずれにおいても正解率は 0.65~0.75 程度で条件への依存性は小さく、8-class 分類の再現率 0.496、適合率 0.543 からは大きく改善した。ムラ B では 2 通りの 2-class 分類のいずれも rbf カーネルを用いてコスト関数  $C=100$  の条件で正解率が最も高くなり、それぞれ 0.870 と 0.821 と、8-class 分類の再現率 0.676、適合率 0.702 から大きく改善した。ムラ C では良品との 2-class 分類で線形 SVM を用いた条件の正解率が 0.8 前後と、これも 8-class 分類の再現率 0.432、適合率 0.419 か

ら大きく改善した。ムラ D は 2 通りの 2-class 分類とも rbf カーネルを用いると正解率は 0.95 前後と良好だが、8-class 分類でも再現率 0.920、適合率 0.945 と良好であった。また図 31 の良品と良品以外の 2-class 分類では、正解率は 0.7~0.8 程度で条件への依存性は小さく、8-class 分類の再現率 0.584、適合率 0.420 からは大きく改善した。回路不良、縦線欠陥、横線欠陥についても、8-class 分類と同等以上で、予想通り部分空間法による 2-class 分類では 8-class 分類より良好な結果となった。

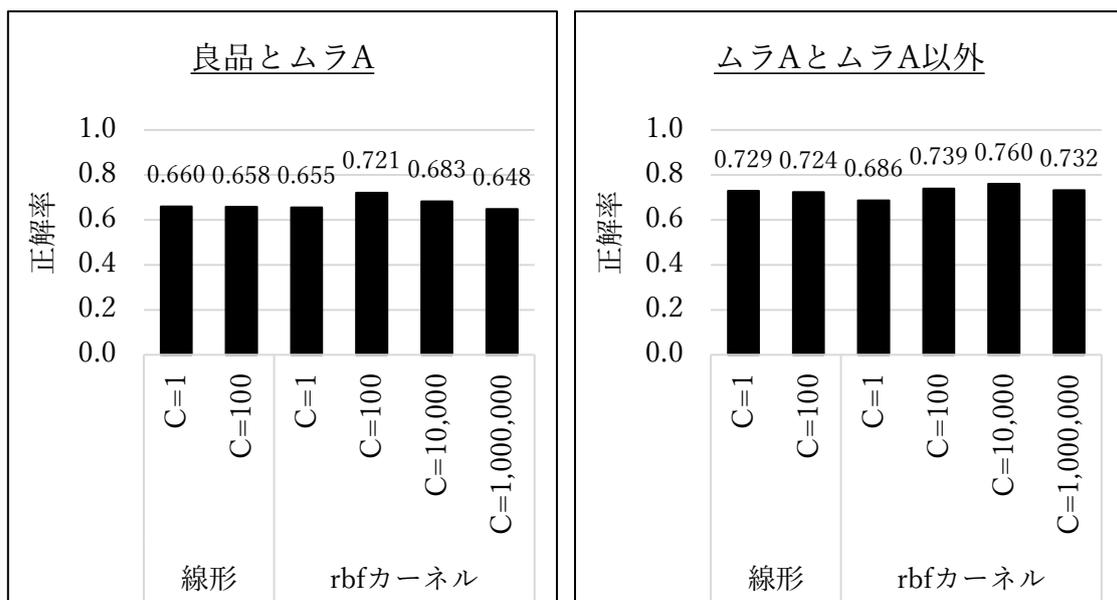


図 24：SVM によるムラ A の 2-class 分類正解率。左は良品とムラ A、右はム

ラ A とムラ A 以外。

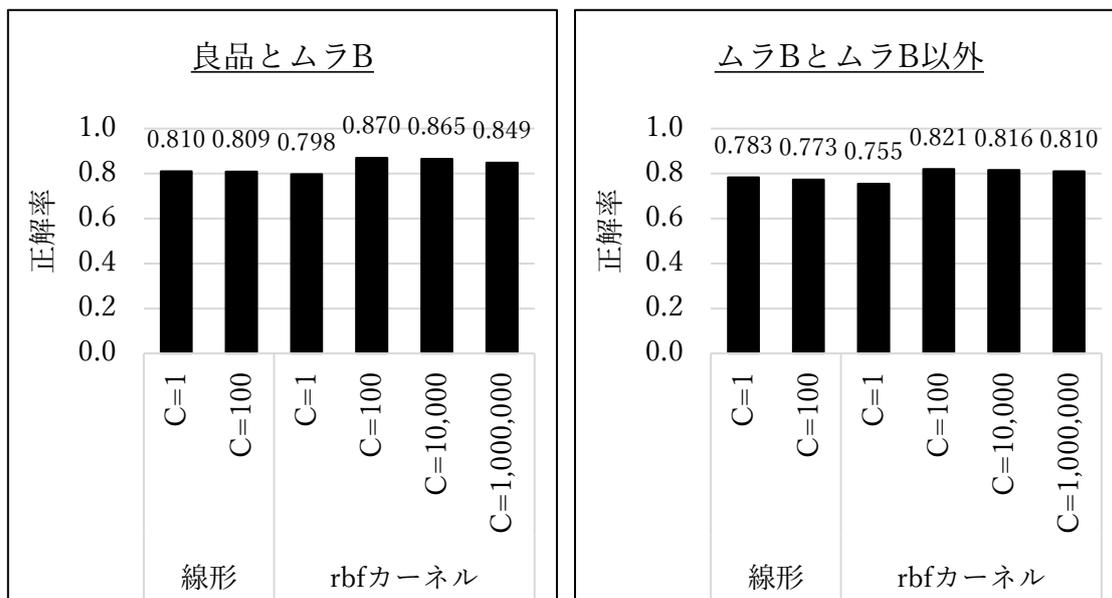


図 25 : SVM によるムラ B の 2-class 分類正解率。左は良品とムラ B、右はムラ B とムラ B 以外。

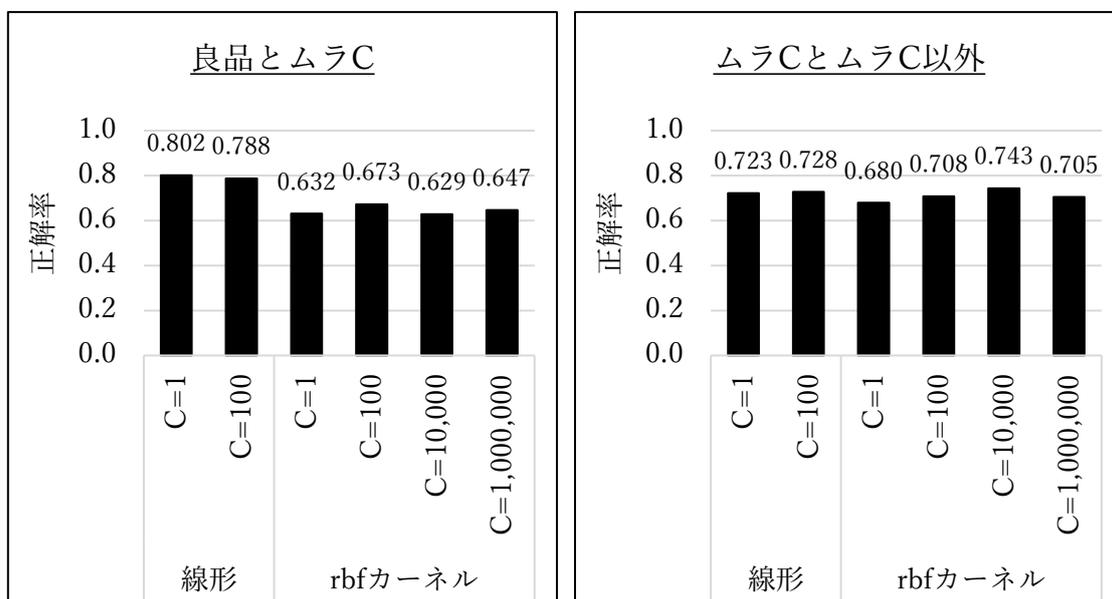


図 26 : SVM によるムラ C の 2-class 分類正解率。左は良品とムラ C、右はムラ C とムラ C 以外。

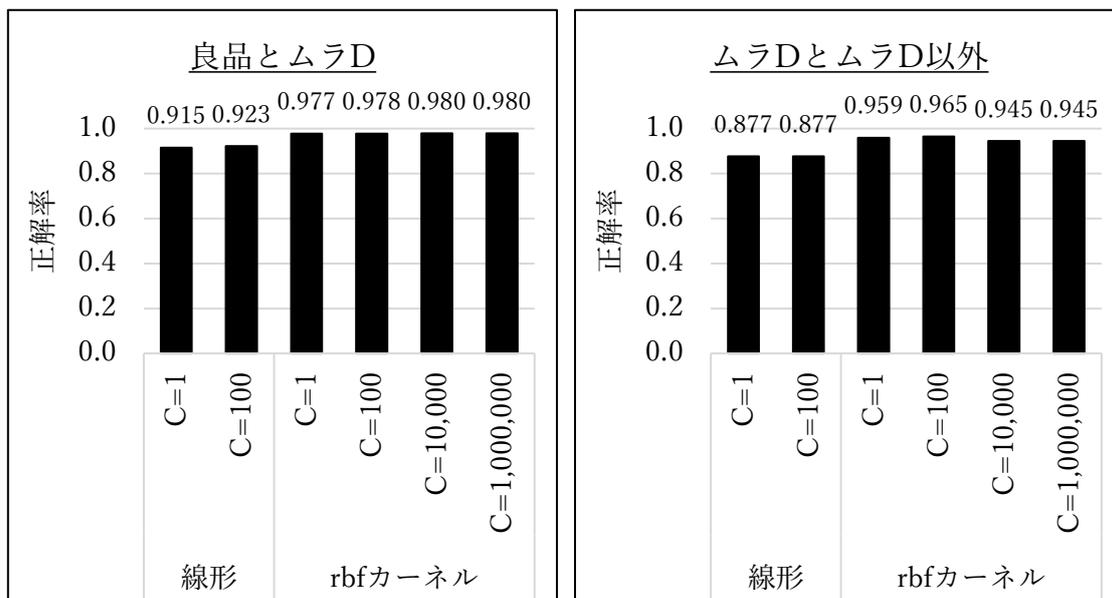


図 27 : SVM によるムラ D の 2-class 分類正解率。左は良品とムラ D、右はムラ D とムラ D 以外。

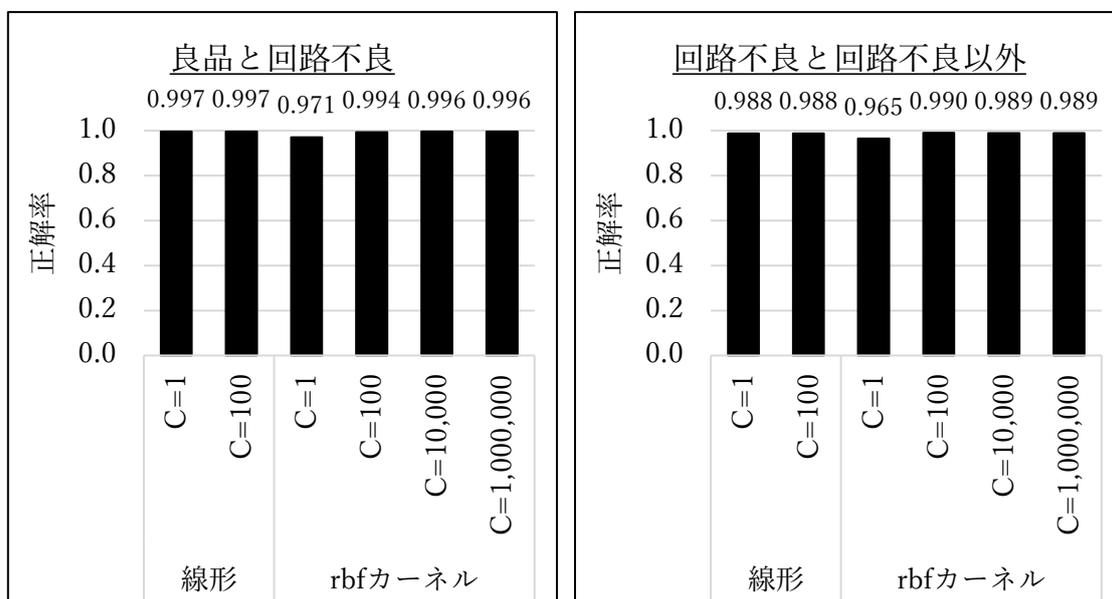


図 28 : SVM による回路不良の 2-class 分類正解率。左は良品と回路不良、右は回路不良と回路不良以外。

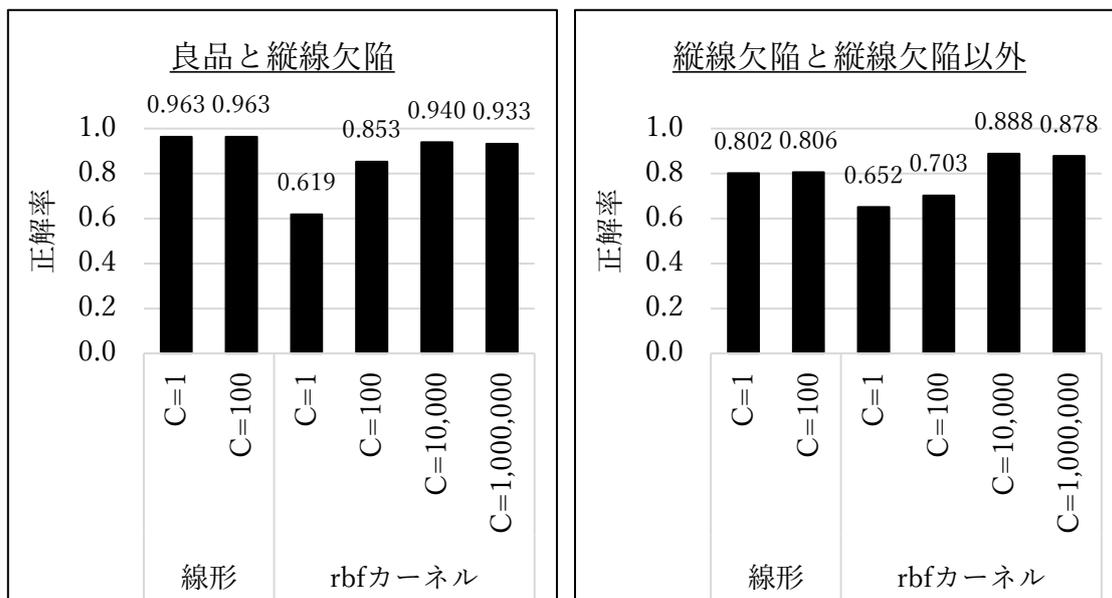


図 29 : SVM による縦線欠陥の 2-class 分類正解率。左は良品と縦線欠陥、右は縦線欠陥と縦線欠陥以外。

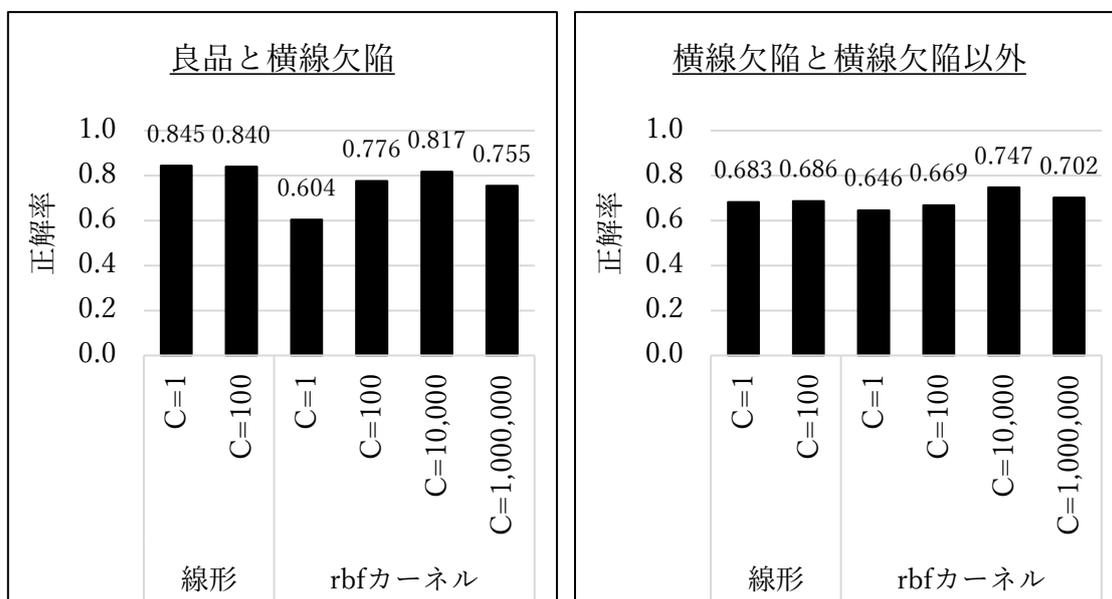


図 30 : SVM による横線欠陥の 2-class 分類正解率。左は良品と横線欠陥、右は横線欠陥と横線欠陥以外。

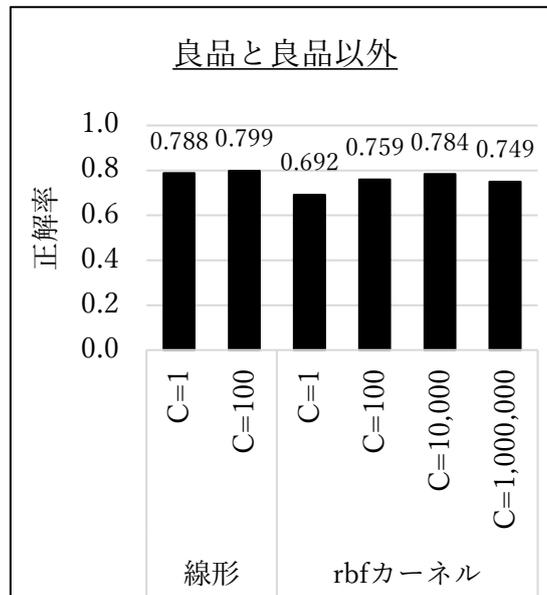


図 31 : SVM による良品と良品以外の 2-class 分類正解率。

### 3.4.2 CNN による 2 クラス分類の評価結果

前節の 8-class 分類と同様に、畳み込み層と Max-Pooling 層を 2~6 組とした 5 つの CNN を用いて 2-class 分類を実施した結果を図 32~39 に示す。コントラスト強調画像を用いており、縦軸の正解率は 5 分割交差検証の平均値である。

図 33、35、36、37 に示すように、ムラ B、ムラ D、回路不良、縦線欠陥の 4 項目の正解率は、良品との 2-class 分類、その他との 2-class 分類のいずれにおいても 0.93 以上と良好で、畳み込み層と Max-Pooling 層の組数への依存性をほとんど示さなかった。これら 4 項目は、前節の 8-class 分類の評価において畳み込み層と Max-Pooling 層が 4 組の CNN で再現率と適合率が 0.95 程度と良好だ

った4項目と一致している。

一方、図32、34、38に示すように、他の3項目のムラA、ムラC、横線欠陥の正解率は、良品との2-class分類、その他との2-class分類のいずれにおいても畳み込み層とMax-Pooling層の組数への依存性を示し、比較的浅いCNNで良好な傾向がある。ムラAでは、良品との2-class分類、その他との2-class分類のいずれにおいても最も高い正解率は畳み込み層とMax-Pooling層が3組のCNNで得られ、それぞれ0.827と0.819であり、8-class分類の再現率0.609、適合率0.658から大きく改善した。ムラCでも、良品との2-class分類、その他との2-class分類のいずれにおいても最も高い正解率は畳み込み層とMax-Pooling層が3組のCNNで得られ、それぞれ0.857と0.856であり、8-class分類の再現率0.852、適合率0.822から改善した。また横線欠陥では、良品との2-class分類、その他との2-class分類のいずれにおいても最も高い正解率は畳み込み層とMax-Pooling層が2組のCNNで得られ、それぞれ0.904と0.874であり、8-class分類の再現率0.803、適合率0.857から改善した。これら3項目は、前節の8-class分類の評価において畳み込み層とMax-Pooling層が4組のCNNで再現率と適合率が低かった3項目と一致している。また図39の良品と良品以外の2-class分類でも、浅いCNNで良好な傾向があり、最も高い正解率は畳み込み層とMax-Pooling層が2組のCNNで得られた0.849である。これ

は 8-class 分類の再現率 0.699、適合率 0.610 から大きく改善した。全体に CNN でも部分空間法による 2-class 分類では 8-class 分類よりも良好な結果が得られた。また SVM の 2-class 分類と比較すると、全ての項目で CNN が同等以上の正解率を示した。

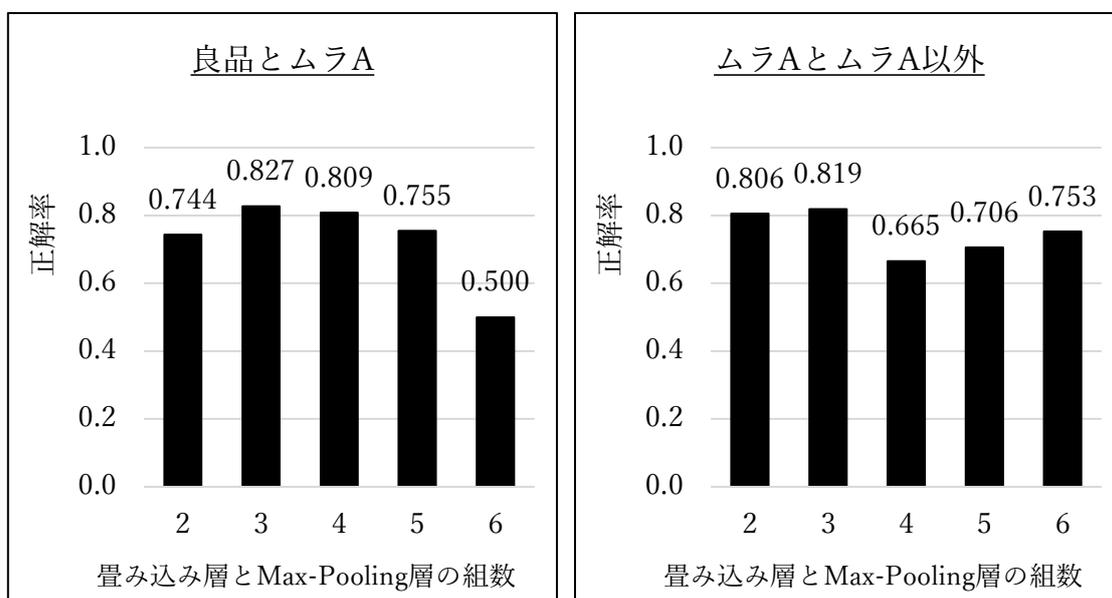


図 32 : CNN によるムラ A の 2-class 分類正解率。左は良品とムラ A、右はム

ラ A とムラ A 以外。

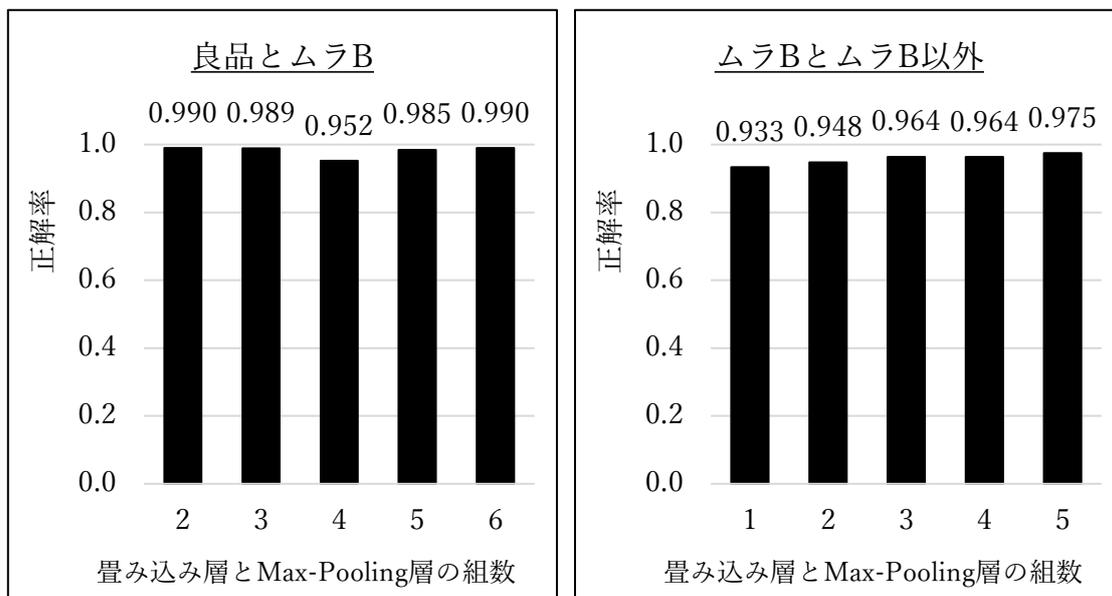


図 33 : CNN によるムラ B の 2-class 分類正解率。左は良品とムラ B、右はムラ B とムラ B 以外。

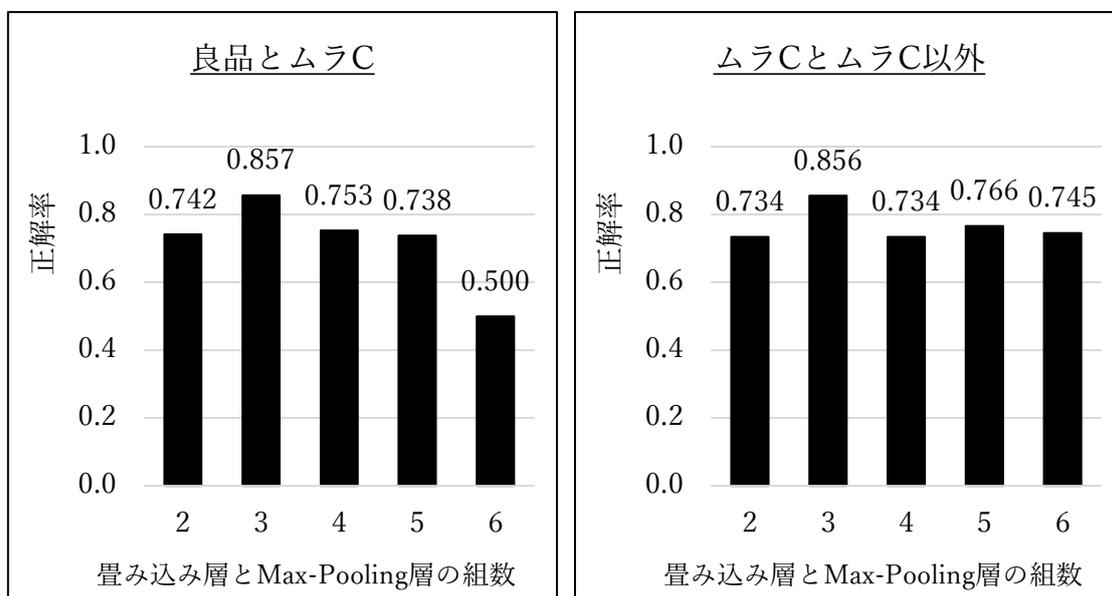


図 34 : CNN によるムラ C の 2-class 分類正解率。左は良品とムラ C、右はムラ C とムラ C 以外。

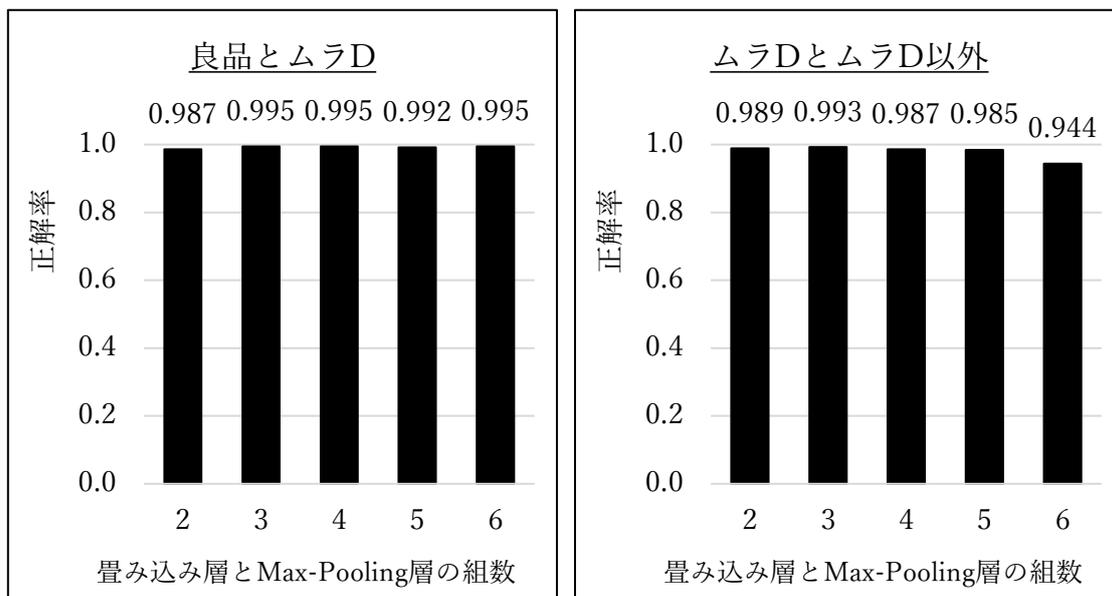


図 35 : CNN によるムラ D の 2-class 分類正解率。左は良品とムラ D、右はムラ D とムラ D 以外。

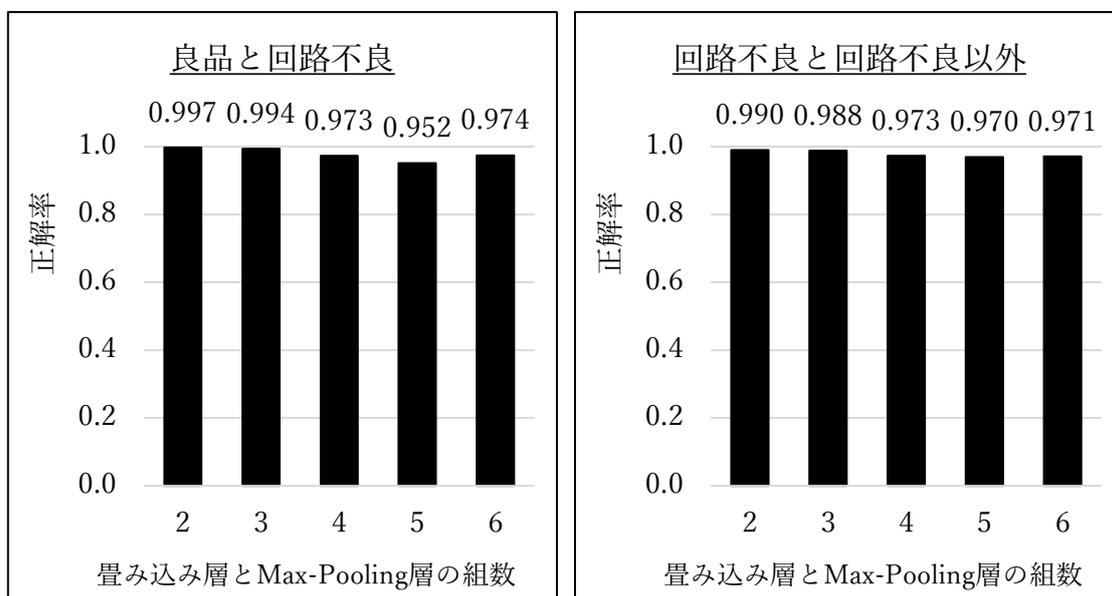


図 36 : CNN による回路不良の 2-class 分類正解率。左は良品と回路不良、右は回路不良と回路不良以外。

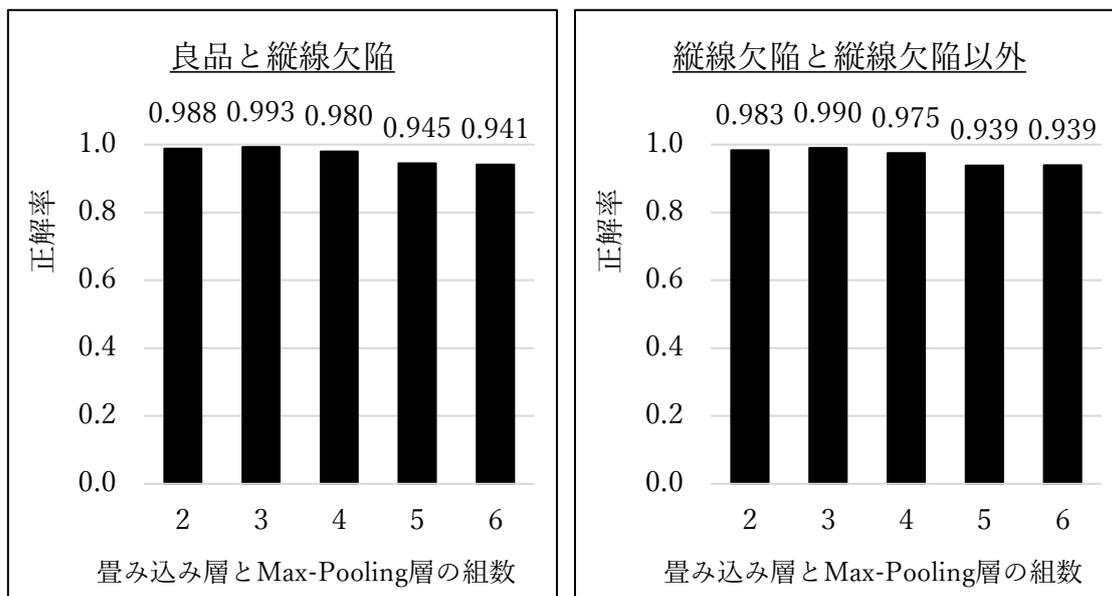


図 37 : CNN による縦線欠陥の 2-class 分類正解率。左は良品と縦線欠陥、右は縦線欠陥と縦線欠陥以外。

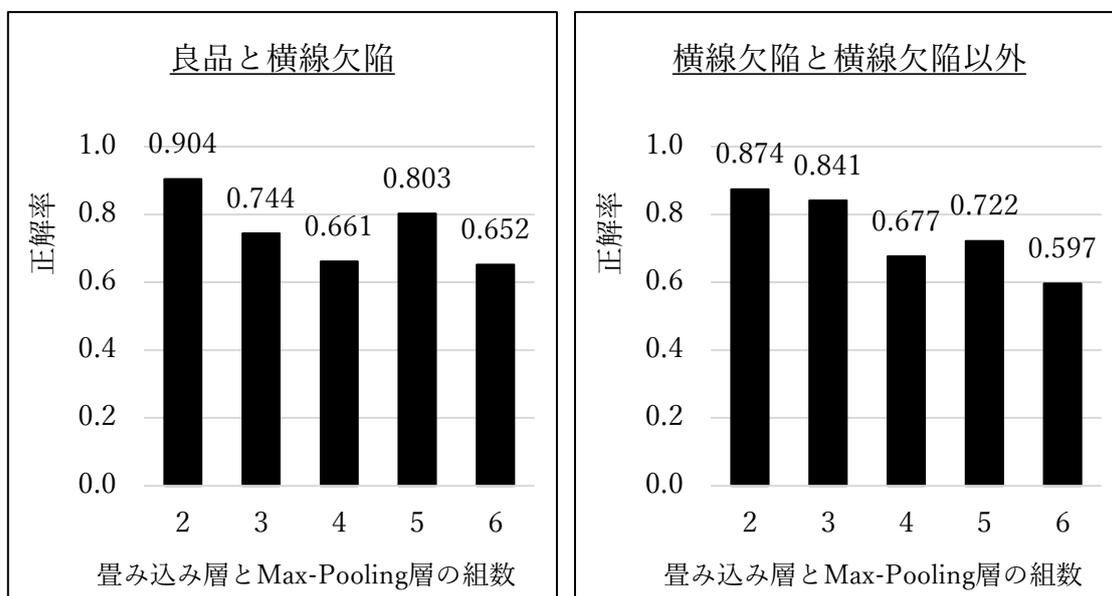


図 38 : CNN による横線欠陥の 2-class 分類正解率。左は良品と横線欠陥、右は横線欠陥と横線欠陥以外。

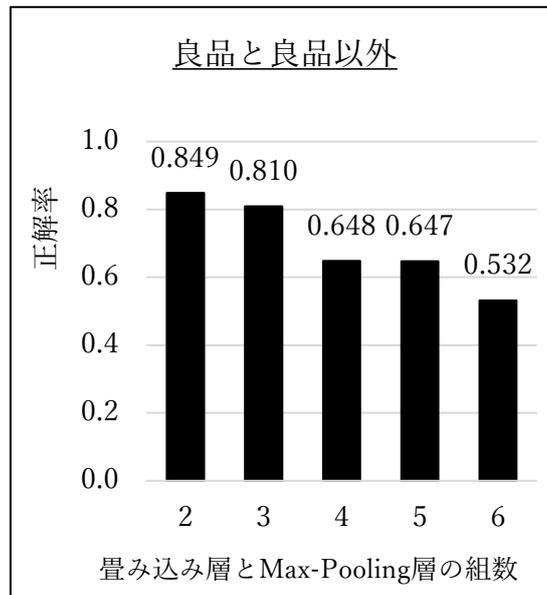


図 39 : CNN による良品と良品以外の 2-class 分類正解率。

図 40 は、ムラ A~D の 2 クラス分類の中で正解率が最も高かった CNN における最終 Max-Pooling 層の出力を可視化した画像である。ムラ A は良品との 2 クラス分類で畳み込み層と Max-Pooling 層が 3 組、ムラ B は同 2 組、ムラ C は同 3 組、ムラ D は同 3 組の CNN を用いた。ムラ A の場合、正解率が最も高かった畳み込み層と Max-Pooling 層が 3 組の CNN に、図 2 のデータセット画像例のムラ A 画像を入力した。3 組目の Max-Pooling 層は本 CNN では最後の 2 次元画像を処理する層であり、128 個のフィルタで構成されている。128 個のフィルタには入力したムラ A のムラ発生領域が出力（活性化）されており、その一例を図 40 に示している。他のムラも同様である。図 2 の元画像と比べると、

各ムラの特徴が CNN によって強調、抽出されていることが分かる。

またムラ A~D で正解率が畳み込み層と Max-Pooling 層の組数に依存したムラ A とムラ C について、正解率が最も低かった畳み込み層と Max-Pooling 層が 6 組の CNN を用い、同様に図 2 の画像を入力したところ、6 組目の Max-Pooling 層では全てのフィルタで全面黒の画像となり、入力画像の特徴は全く認められなかった。これが、正解率が低かった原因と考えられる。

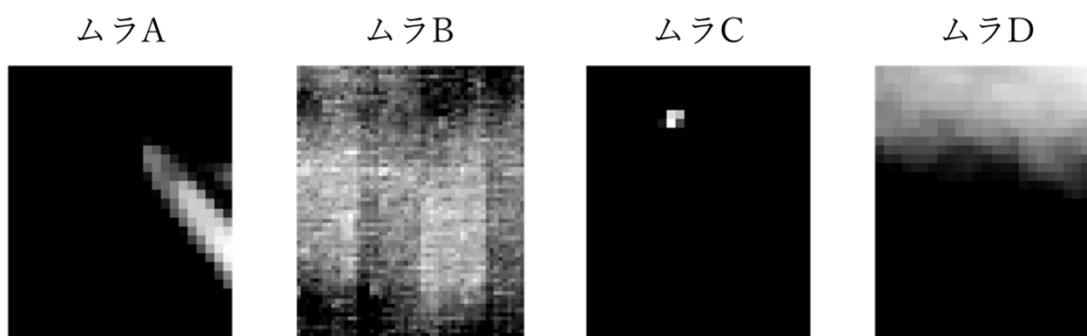


図 40 : 2 クラス CNN の最終 Max-Pooling 層出力の可視化画像。

### 3.4.3 Residual Network による 2 クラス分類の評価結果

Residual Network の 2-class 分類では、前節の 8-class 分類と同様に ResNet50 に CNN の全結合層以下を接続したモデルを使用した。コントラスト強調処理を実施し、全結合層のパラメータのみを学習する方法(“not trainable”)と、ResNet50 のパラメータを含めて全パラメータを学習する方法(“trainable”)の 2

通りの学習方法で 2-class 分類を実施した結果を図 41~48 に示す。縦軸の正解率は 5 分割交差検証の平均値である。

図 43 のムラ C を除く 7 項目については、Residual Network の全 4 条件で前術の CNN と同等以下の正解率となった。注目すべきは図 43 において、良品とムラ C の 2-class 分類で学習方法を“trainable”とした条件で正解率が 0.965 と、CNN の 2 クラス分類での最高正解率 0.857 を大きく上回った点である。発生面積が小さいムラ C に対して、残差接続を持つ Residual Network が有効だったと考えられる。

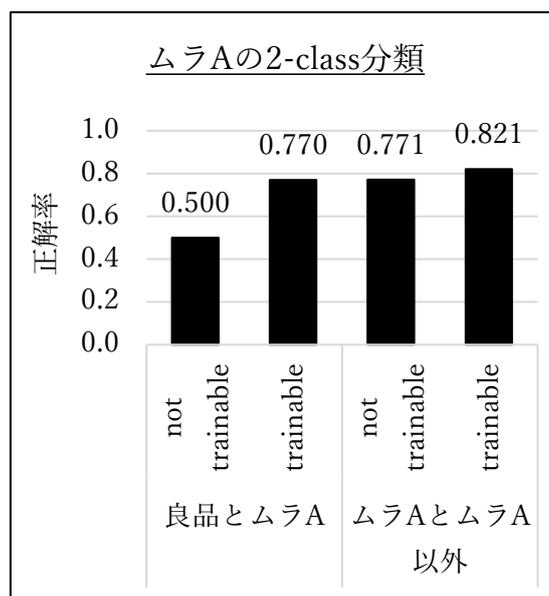


図 41 : Residual Network によるムラ A の 2-class 分類正解率。

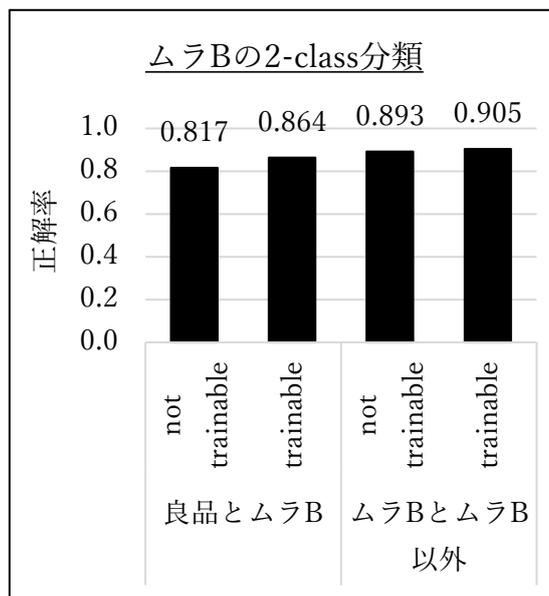


図 42 : Residual Network によるムラ B の 2-class 分類正解率。

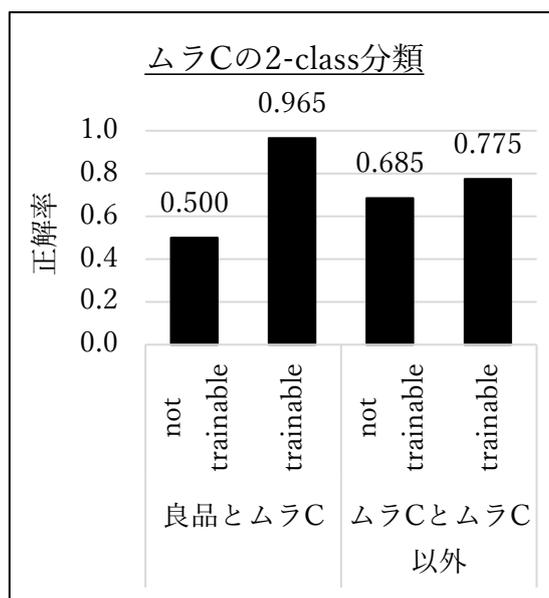


図 43 : Residual Network によるムラ C の 2-class 分類正解率。

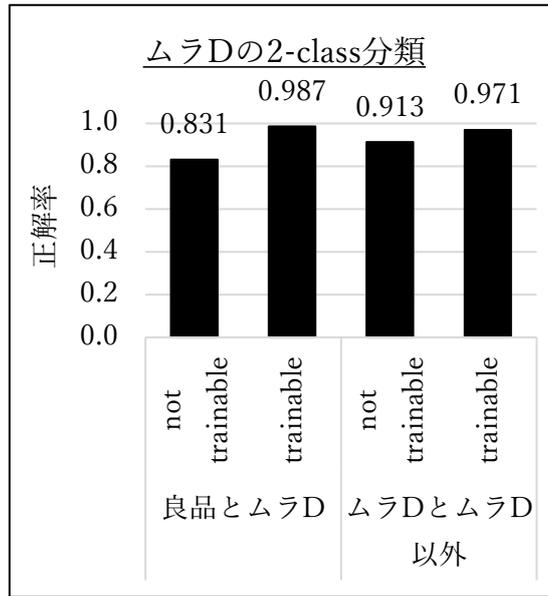


図 44 : Residual Network によるムラ D の 2-class 分類正解率。

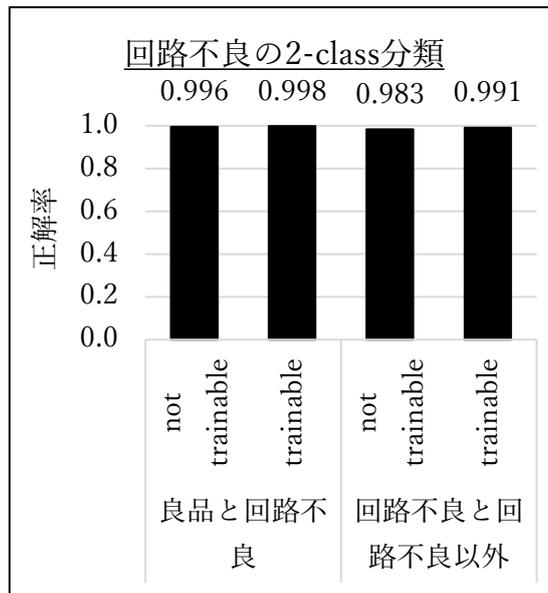


図 45 : Residual Network による回路不良の 2-class 分類正解率。

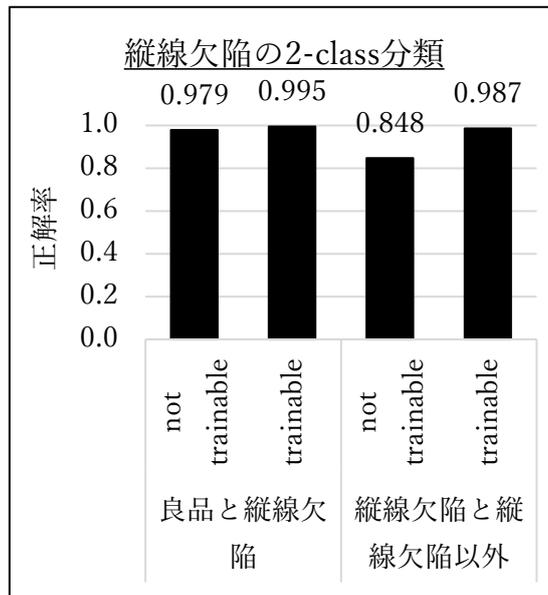


図 46 : Residual Network による縦線欠陥の 2-class 分類正解率。

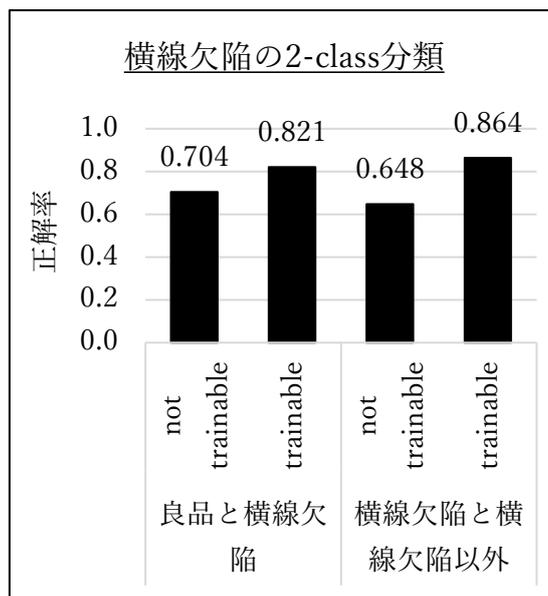


図 47 : Residual Network による横線欠陥の 2-class 分類正解率。

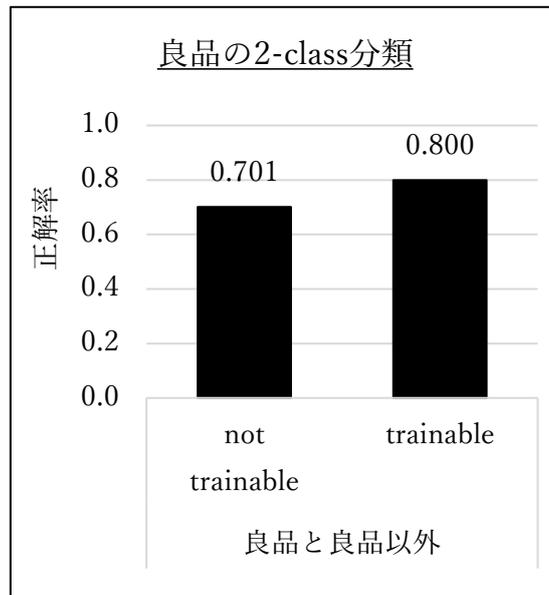


図 48 : Residual Network による良品と良品以外の 2-class 分類正解率。

## 第4章 提案手法

### 4.1 プログレッシブ・ハイブリッドモデル

前章までに述べた通り、8-class 分類においては特定のモデルで全ての項目を高精度に分類することは困難であること、部分空間法による 2-class 分類においては不良項目によって最適なモデルが異なることから、各不良項目に適した複数のモデルを組み合わせる手法を提案する。図 49 は本手法とその学習、評価方法を示している。本手法は、全 8 項目を分類する 8-class CNN、良品とムラ-C を分類する 2-class Residual Network(ResNet)、良品とムラ-A を分類する 2-class CNN の 3 つのモデルで構成される。最初に 8-class CNN で分類し、分類精度が不十分なムラ A、ムラ C、良品は 2-class モデルを用いて再分類、再々分類する。前章までの評価結果から、全 8 項目を分類する 8-class CNN は畳み込み層と Max-Pooling 層が 4 組、良品とムラ A を分類する 2-class CNN は畳み込み層と Max-Pooling 層が 3 組の構成とし、良品とムラ C の分類には 2-class ResNet を用いる。複数のモデルが漸進的に処理を進めるため、本手法をプログレッシブ・ハイブリッドモデルと呼ぶ。その学習と評価は下記手順で実施した。

- 全 8 項目の学習データを用いて 8-class CNN を訓練する（図中、緑色の点線で示す）。

- 良品とムラ A の学習データを用いて 2-class CNN を訓練する（図中、青色の点線で示す）。
- 良品とムラ C の学習データを用いて 2-class ResNet を訓練する（図中、オレンジ色の点線で示す）。
- 全 8 項目のテストデータを 8-class CNN に入力し、1 回目の分類結果(1<sup>st</sup> Classification Results)を得る。
- 1 回目の分類結果でムラ B、ムラ D、回路不良、縦線欠陥、横線欠陥に分類されたテストデータは、これを最終結果とする。
- 1 回目の分類結果で良品またはムラ C に分類されたテストデータを 2-class ResNet に入力し、2 回目の分類結果(2<sup>nd</sup> Classification Results)を得る。
- 2 回目の分類結果でムラ C に分類されたテストデータは、これを最終結果とする。
- 1 回目の分類結果でムラ A に分類されたテストデータと、2 回目の分類結果で良品と分類されたテストデータを 2-class CNN に入力し、3 回目の分類結果(3<sup>rd</sup> Classification Results)を得、これを良品とムラ A の最終結果とする。
- 全 8 項目のうち、ムラ B、ムラ D、回路不良、縦線欠陥、横線欠陥の 5 項

目は 1 回目の分類結果、ムラ C は 2 回目の分類結果、良品とムラ A は 3 回目の分類結果を組み合わせることで、全 8 項目の最終分類結果(Final Classification Results)を得る。

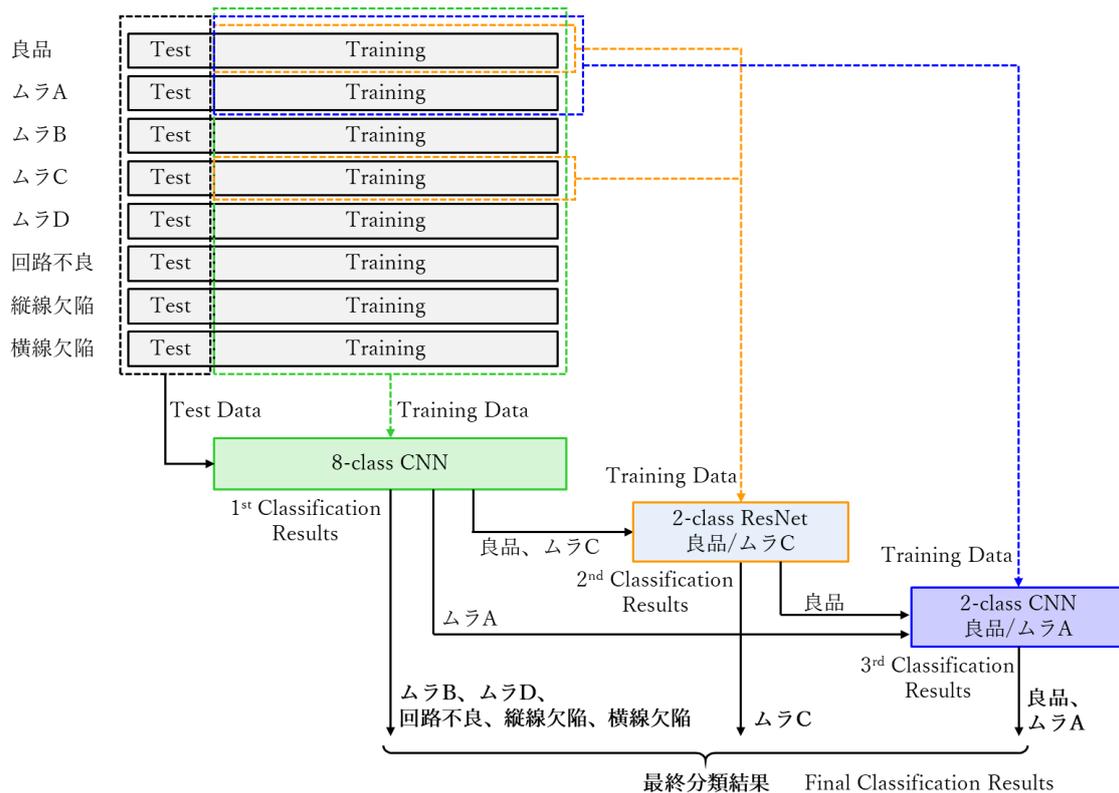


図 49：提案手法のプログレッシブ・ハイブリッドモデルとその学習、評価方

法。

## 4.2 提案手法の評価結果

図 50 にプログレッシブ・ハイブリッドモデルによる 8-class の正解率と、前章の 8-class の SVM、CNN、Residual Network の評価結果から最も高い

正解率を示す。プログレッシブ・ハイブリッドモデルの正解率は 0.884 となり、前章で最良だった CNN の 0.846 から+0.037 の改善が得られた。

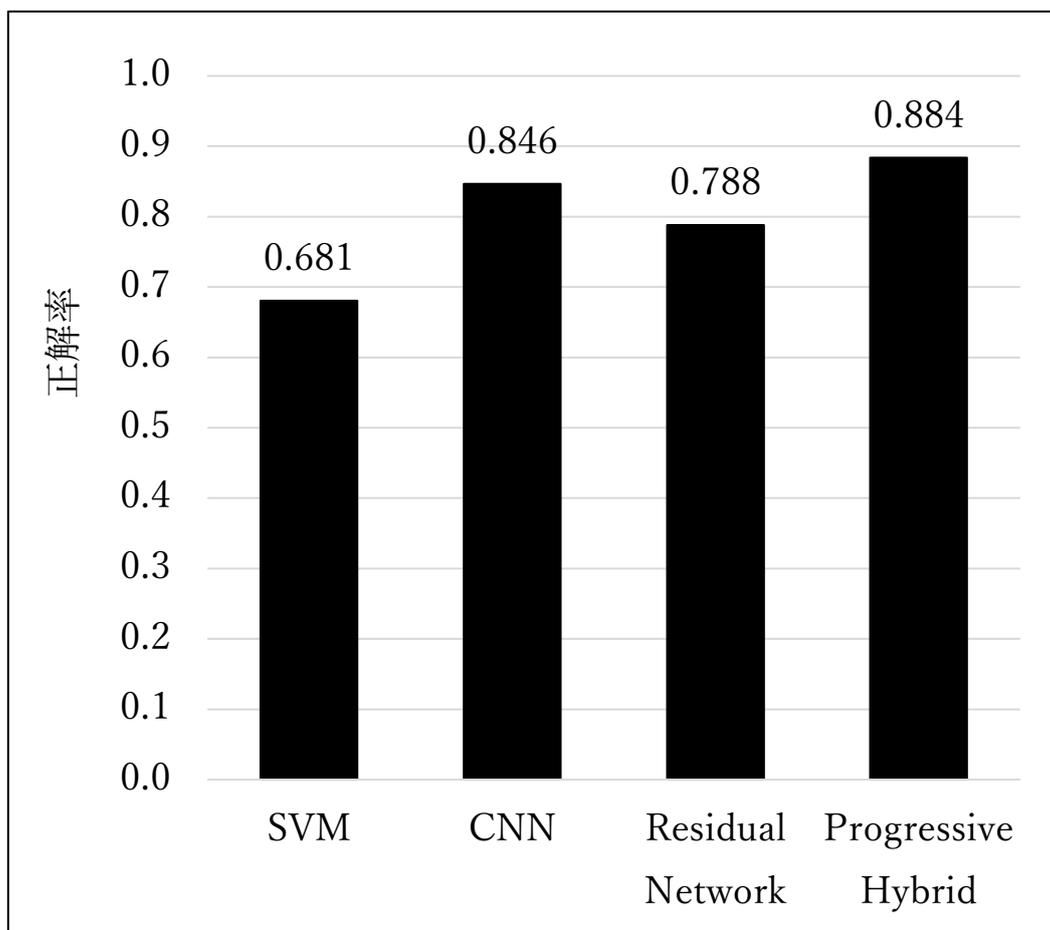


図 50 : SVM、CNN、Residual Network 及び提案手法のプログレッシブ・ハイブリッドモデルの 8-class 分類正解率。

図 51 に項目別の再現率と適合率を示す。同図から、本提案手法は特に良品の誤分類低減に有効なことが分かる。本手法では 1 回目の 8-class CNN で良品に分類された画像は、ムラ C に分類された画像とともに 2-class ResNet で 2 回目

の分類を行う。2回目も良品に分類された画像はさらに、1回目でムラAに分類された画像とともに2-class CNNで3回目の分類を行う。このように、本当に良品であるかを、誤分類しやすい不良を対象に繰り返し確認することで良品の精度改善が得られた。

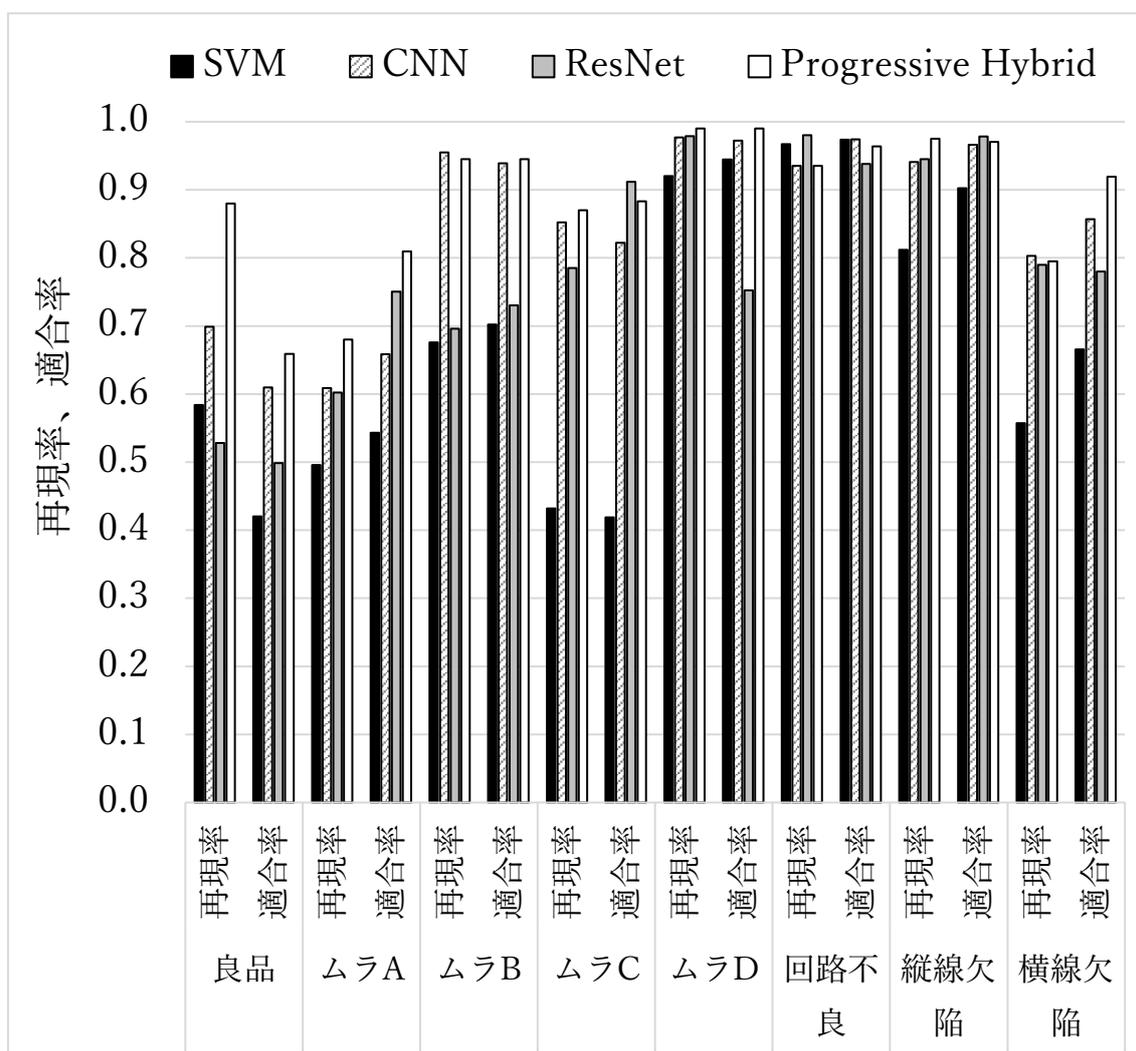


図 51 : SVM、CNN、Residual Network 及び提案手法のプログレッシブ・ハイブリッドモデルの項目別の再現実率と適合率。

また 8-class CNN で精度が低かったムラ A とムラ C の再現率、適合率も、本提案手法では改善が認められる。ムラ A は良品と一对一の 2-class CNN、ムラ C は良品と一对一の 2-class ResNet による分類を追加した効果と考えられる。

全不良項目を見ると、全ての指標で本提案手法が最良ではないが、実際の製造工程での運用では良品の占める割合が多い点を考慮すると、本提案手法は全体の分類精度を大きく改善可能と考えられる。この改善効果を試算した結果を図 52 に示す。本研究のデータセットでは 8 項目の各サンプル数は同じため、良品の割合、即ち歩留は 12.5%に相当する。各モデルの混同行列において良品の分類結果を正解、不正解ともに等倍することで良品の割合（歩留）を増加させ、8 項目全体の正解率を試算した。図 52 の横軸は良品の割合、縦軸は正解率である。同図において最も左側の良品の割合 0.125 のプロットは図 50 と同じ結果を示している。SVM、CNN、ResNet では、良品の分類精度が全体の正解率よりも低い。そのため、歩留が高くなるほど正解率は低下していく。一方、本提案手法では良品の再現率と全体の正解率がほぼ同じため、歩留が高くなっても正解率は変化していない。既存手法で最も精度が高い CNN の正解率との差は、歩留 12.5%では 0.037 だが、歩留 80%では 0.099、歩留 90%で 0.164 に拡大する。

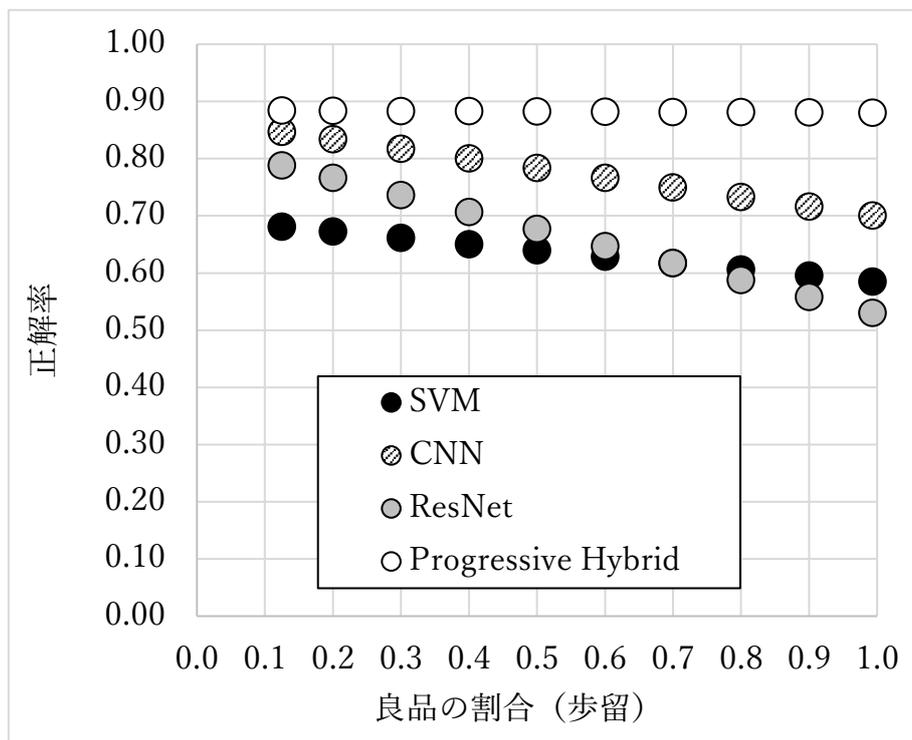


図 52 : SVM、CNN、Residual Network 及び提案手法のプログレッシブ・ハイブリッドモデルにおける良品の割合 (歩留) と正解率の関係の試算結果。

以上のように本提案手法で精度が改善できた理由は、3.2 節で述べたように、人の目視検査特性を機械学習で再現したことと考えられる。目視検査における不良毎の点灯画面はコントラスト強調、限度見本は部分空間法による 2 クラス分類で再現した。このうち後者が特に有効だったと考えられる。人が判断に迷う不良、従って誤分類が起きやすい不良は、良品との違いが小さい不良であり、今回のデータセットでは薄い不良が多いムラ A と面積が小さい不良が多いムラ C

である。人の目視検査では不良に近い良品である良品限度あるいは良品に近い不良である不良限度を判断基準とすることで検査精度を確保しているが、これを本提案手法では、ムラ A とムラ C をそれぞれ良品と一対一で分類する 2-class モデルによって再分類、再々分類することで再現している。これによって正解、即ち人間の目視検査結果との一致が増加したと考えられる。

本研究のデータセットでは、1 枚のディスプレイの画像データに対して 1 つの目視検査結果を対応付けているが、実際の運用では 1 枚のディスプレイに複数の不良が発生する場合もある。この場合、モデル出力における項目毎の発生確率が複数の項目で拮抗するので、どれも発生したとみなす運用が想定される。ただし複数の不良が発生したディスプレイは複数の製造工程で異状が発生しており、発生頻度が低いことに加え、分類精度に影響を与えるような程度の軽い不良ではなく明確な不良になると考えられる。人の目視検査でも問題となるのは良品と程度の軽い不良の分類であり、そのために良品限度（不良に近い良品）と項目毎の不良限度（良品に近い不良品）を用いている。それを本提案手法では再現した。

### 4.3 製造工程への導入

本研究で開発した機械学習モデルを用いた自動ムラ検出システムを OLED

製造ラインに試験的に導入した。

- 製造される各OLEDディスプレイを点灯し、光学カメラで点灯状態を撮像し、画像データを得る。
- コントラスト強調等の前処理を実施する。
- 本研究で開発した機械学習モデルを用いて、ムラを検出、分類する。
- ムラの検出、分類結果を解析用ソフトウェアで可視化するための後処理を実施する。

解析用ソフトウェア上で、ムラの項目毎の発生状況、増減の傾向、Mother Glass 基板での分布状況などを解析することができる。詳細は評価中である。

本研究で提案したプログレッシブ・ハイブリッドモデルは、分類精度を高めるだけでなく、製造工程において頻繁に発生する不良の変化に臨機応変に対応可能、即ち拡張性という利点もある。ディスプレイの製造工程では、プロセスや装置状態、クリーンルーム環境などの変動による不良の増加、新しい種類の不良の発生、プロセス対策や製造装置メンテナンスによる不良の減少、一旦解決した不良の再発などの変化は日常的に発生している。このため製造工程における不良の検出や分類では、こうした変化に臨機応変に対応することで、早期フィードバックに寄与することが重要である。例えば新たな不良(ムラ E)が発生した場合、

ムラ E が良品に類似し、最初の多クラスで良品に分類されるのであれば、本提案手法では良品とムラ E の 2-class モデルによる処理を付加することが容易に可能である。その 2-class モデルは、対象となるムラ E と発生頻度の高い良品の学習データで作成され、多クラスモデル作成のデータ収集や学習ほどの時間を必要とせずに導入可能である。ただしムラ E の特性によっては最初の多クラス分類モデルの修正が必要になる場合もある。またプロセスの改善によって不良（例えばムラ A）が解決した場合にはムラ A の処理を停止（スキップ）し、再発した場合には処理を再開することも本提案手法では容易に可能である。

このようにプログレッシブ・ハイブリッドモデルは、分類精度を改善するだけでなく、拡張性にも優れ、製造工程の変動に追随することで目的である製造工程への早期フィードバックに寄与することに有効である。

## 第5章 結論

本研究では、液晶や有機ELディスプレイ分野で生産開始当初からの課題であるムラの自動検出に機械学習を用いて取り組んだ。実際の OLED 製造工程で発生頻度が高い不良に着目し、8項目、各項目1000枚、計8000枚のディスプレイ点灯画像を収集し、人間の目視検査結果を正解ラベルとして対応付けたデータセットを準備した。

人の目視検査特性に着目し、目視検査において不良を検出しやすい点灯画面を用いることを機械学習で再現するため、シグモイド関数を用いた画像コントラスト強調を評価した。さらに目視検査において人間が判断に迷う場合に判断基準として使用される限度見本を機械学習で再現するために、部分空間法にもとづく不良項目毎の2クラス分類を評価した。

機械学習モデルとして SVM、CNN、Residual Network を使い、モデルの構造やパラメータ、学習方法を条件に 8-class 分類を評価し、CNN によって最高正解率 0.830 を得た。コントラスト強調および部分空間法による 2-class 分類を評価し、8-class 分類で精度が不十分だったコントラストが低いムラ（ムラ A）、発生面積が小さいムラ（ムラ C）、良品の再現率と適合率を改善可能なモデル、パラメータの知見を得た。

これらの評価結果から、部分空間法をもとに複数のモデルを組み合わせるプログレッシブ・ハイブリッドモデルを提案。全 8 項目を分類する 8-class CNN、良品とムラ-C を分類する 2-class Residual Network、良品とムラ-A を分類する 2-class CNN の 3 つのモデルで構成される。最初に 8-class CNN で分類し、分類精度が不十分なムラ A、ムラ C、良品は 2-class モデルを用いて再分類、再々分類する。評価の結果、8-class 全体の正解率では 0.830 から 0.884 への改善が得られた。項目別でも、コントラストが低いムラ（ムラ A）と発生面積が小さいムラ（ムラ C）の再現率と適合率が CNN 以上であることに加え、実際の製造工程で多数を占める良品の誤分類の低下に有効なことを確認した。

また本プログレッシブ・ハイブリッドモデルは、精度改善だけではなく、拡張性にも優れ、製造工程の変動による不良の増減にも臨機応変に対応可能であり、目的である製造工程への早期フィードバックにも有効である。また本研究で開発した機械学習モデルを用いた自動ムラ検出システムを OLED 製造ラインに試験的に導入し、ムラの発生状況の解析に有効であることを確認した。

## 第6章 今後の課題

本研究で得られた機械学習モデルを製造工程で本格的に運用し、実際に発生する不良に対する早期フィードバックがどの程度可能かを評価していく。また最終的な目標である生産性改善への貢献も評価していく。

分類精度のさらなる改善のため、Data Augmentation (データ拡張) の効果を評価する。本データセットの 8 項目、各 1000 枚、合計 8000 枚という規模は、ディスプレイ分野の先行研究に比べれば大きいですが、ImageNet のような一般的に深層学習に用いられるデータセットに比べれば小規模である。現在のデータセットの画像を上下反転、左右反転、180 度回転等の処理をすることで数倍の規模に拡張できる。特に学習パラメータが多い Residual Network での効果に注目して評価する。

また精度不足に対する運用上の工夫として人間との協調も検討する。機械学習モデルの出力 (各項目の発生確率) が一定以下の場合や、複数の項目が拮抗する場合、人間がディスプレイの点灯画像を目視することで機械学習モデルを補う運用が考えられる。

## 謝辞

本研究を進めるにあたり、主指導教授として日頃から暖かくご指導いただきました本学小谷一孔教授に心から感謝いたします。入学に際して貴重なご助言をいただき、その後も副指導教授としてご指導いただいた本学東条敏教授に心から感謝いたします。副テーマ指導教授としてご指導いただいた本学長谷川忍教授には特にプログラミングについてのご指導に深く感謝しております。また審査を通じて貴重なご助言をいただいた東北大学阿部亨准教授、本学岡田将吾准教授に深く感謝いたします。そして多くの貴重なご助言をいただいた本学 Prarinya Siritanawan 助教に心から感謝いたします。

本研究は、筆者が所属する(株)ジャパンディスプレイの学位取得支援制度のもとで実施しました。会社においてご支援いただいた多くの関係者の方々に深く感謝いたします。とりわけ日頃からご指導いただき、本研究にもご配慮いただいた所属部署の上長である武田篤氏、平田教行氏、河村真一氏に心から感謝いたします。

# 付録 小規模データセットによる概念検証

## 1 位置付け

本研究においては事前に概念検証を実施した。目的は、ムラの自動検出を小規模のデータ、モデルで先行実施することにより、機械学習を用いてムラを自動検出、分類すること自体が可能かを確認すること（概念検証）と、本研究における検出精度改善の出発点（ベースライン）を得ることである。

## 2 データセット

本章の概念検証においては、実際の製造工程での発生頻度は特に考慮せず、機械学習を用いたムラ検出の基礎評価のため、極端に程度が酷い明瞭なムラ、中程度のやや不明瞭なムラ、検出が難しいと予想される不明瞭なムラの 3 段階のムラを対象とした。また良品、回路不良、線欠陥の 3 項目はムラではないがムラとの混同を評価するために加えた。データセットの分類項目としては、良品、回路不良、線欠陥、明瞭なムラ、やや不明瞭なムラ、不明瞭なムラの 6 項目となり、それぞれ 100 枚ずつ、計 600 枚の画像を収集した。図 53 に各項目の画像例を示す。

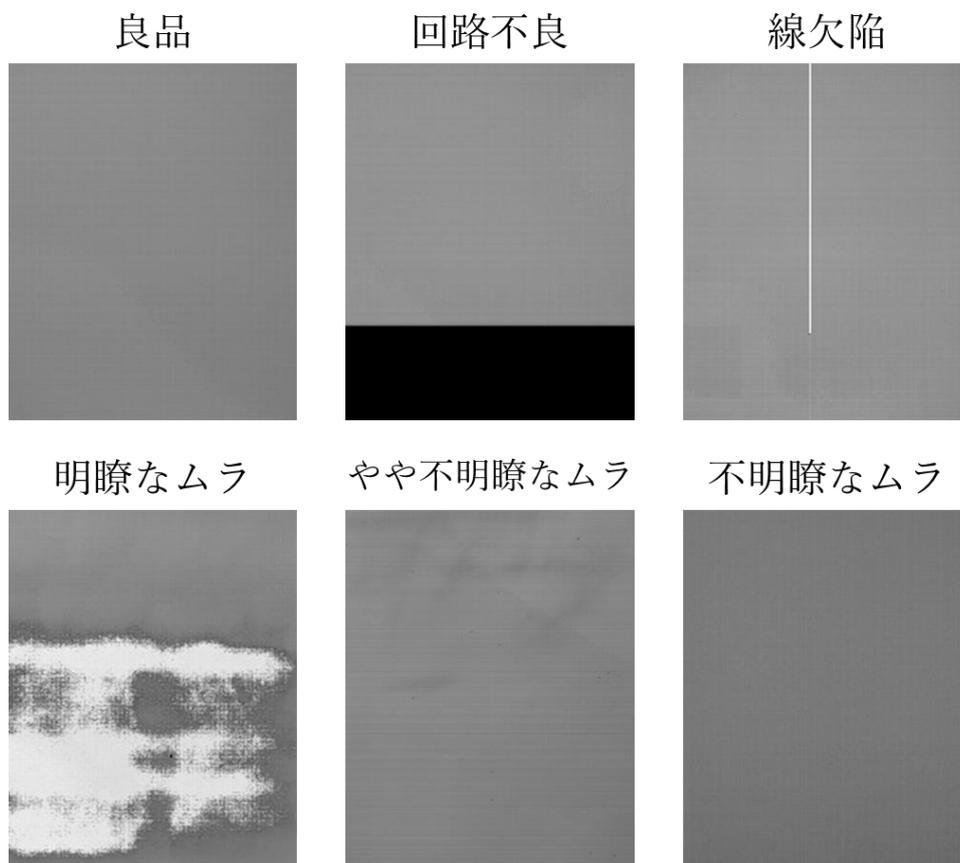


図 53：概念検証で用いたデータセットの画像例。

### 3 SVM での評価結果

#### 3.1 線形 SVM

表 5 に線形 SVM の結果である混同行列を示す。特徴量には階調毎の画素数（階調ヒストグラム）を用いている。混同行列の各行（横方向）は、人間の目視検査による項目に対応している。前述の通りデータセットは 6 つの項目毎に 100 枚の画像があり、このうち 80 枚を学習に用い、残り 20 枚でテストを実施している。混同行列の各列（縦方向）は 20 枚のテスト画像を SVM が項目別に予測

した枚数である。項目毎のテスト画像のうち目視検査結果と一致した枚数（表中の対角線上の数字）を合計し、全テスト画像枚数（120枚）に対する割合を正解率と定義すると 0.650 となった。また 5 分割交差検証も実施したところ、分割毎の正解率は 0.617~0.657、平均 0.657 となった。

項目 (目視検査結果)	推定結果						合計
	良品	回路不良	線欠陥	明瞭な ムラ	やや不明 瞭なムラ	不明瞭な ムラ	
良品	10	0	6	0	3	1	20
回路不良	1	16	2	1	0	0	20
線欠陥	7	0	10	0	2	1	20
明瞭なムラ	0	0	3	16	1	0	20
やや不明瞭なムラ	7	0	1	1	9	2	20
不明瞭なムラ	2	0	0	0	1	17	20

表 5：概念検証における線形 SVM の混同行列

図 54 に表 5 の混同行列から計算した項目毎の再現率と適合率を示す。再現率は項目毎のテスト画像枚数に対する正解数の割合であり、適合率は項目毎の予測数に対する正解数の割合である。

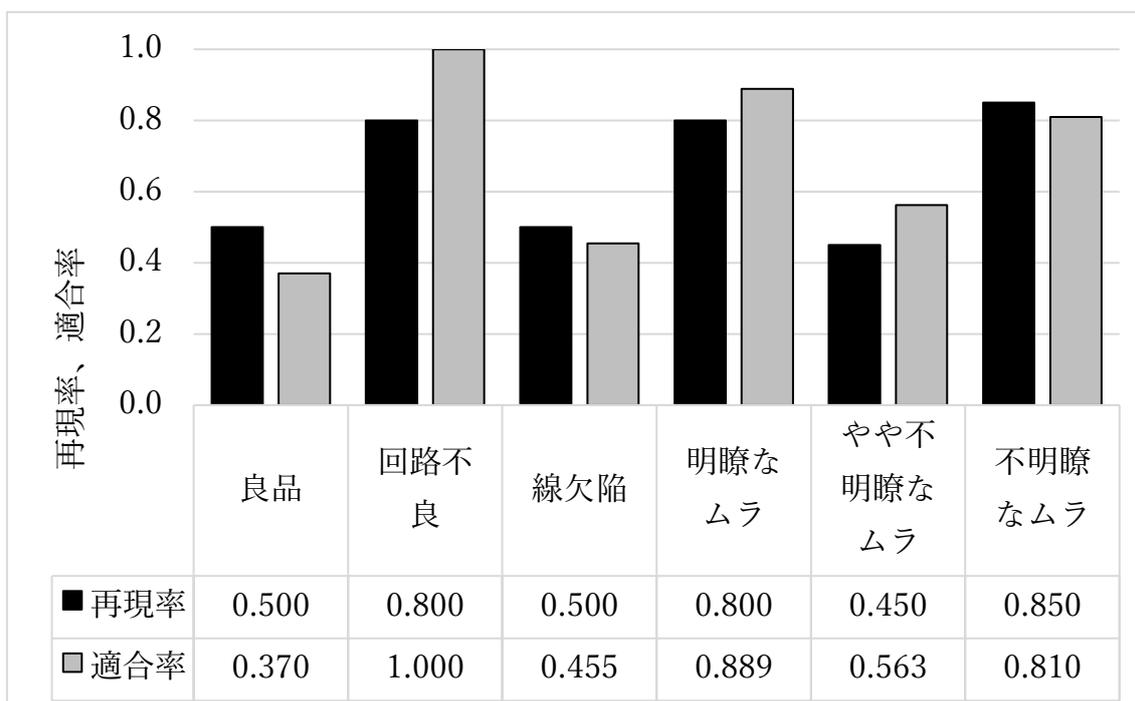


図 54：概念検証における線形 SVM 結果の項目別再現率と適合率。

項目別では、回路不良、明瞭なムラ、不明瞭なムラの 3 項目は再現率と適合率が 0.8 以上と比較的良好だが、良品、線欠陥、やや不明瞭なムラの 3 項目は再現率と適合率が 0.5 前後と低く、これら 3 項目のなかで互いに混同していることが表 5 の混同行列でも認められる。

この結果の要因を、図 54 に示すデータセット 600 枚の画像の階調分布を用いて解析した。同図の横軸は 600 枚の画像であり、1~100 は良品、101~200 は回路不良、201~300 は線欠陥、301~400 は明瞭なムラ、401~500 はやや不明瞭なムラ、501~600 は不明瞭なムラである。縦軸は各画像の輝度別の画素数であり、0~255 の 256 段階の輝度を、低輝度（階調 0~99）、中輝度（階調 100~155）、高

輝度（階調 156~255）の 3 段階で示している。全 6 項目のうち特徴的な輝度分布を示しているのは回路不良（横軸 101~200）、明瞭なムラ（横軸 301~400）、不明瞭なムラ（横軸 501~600）の 3 項目である。回路不良では低輝度、中輝度、高輝度の画素が不規則に混在している。この不良は走査線を駆動する回路が途中停止するため停止位置以下の画素は走査されず、輝度が最低(0)または最高(255)付近となるが、停止位置は不規則なため、低、中、高輝度の画素が不規則に混在する分布となる。明瞭なムラ（横軸 301~400）の輝度分布は、同グラフの上下半分に分かれるように上半分に中輝度、下半分に高輝度が分布している。この不良は、発生領域では輝度が高くなり、その面積は酷いものでも画面の半分程度という特徴があり、この特徴が階調分布に示されている。また不明瞭なムラ（横軸 501~600）は、一部の画素の輝度が低下する不良であるが、正常な中輝度の画素数がやや減少し、ムラが発生した低輝度の画素数がやや増加していることが階調分布に認められる。

以上のように再現率と適合率が 0.8 以上と比較的良好だった回路不良、明瞭なムラ、不明瞭なムラの 3 項目は、それぞれの不良の特徴が階調分布に反映されたために他項目との分類が可能だったことが分かる。逆に再現率と適合率が 0.5 前後だった良品、線欠陥、やや不明瞭なムラの 3 項目は、階調分布が似たために分類が不十分で混同したことが分かる。

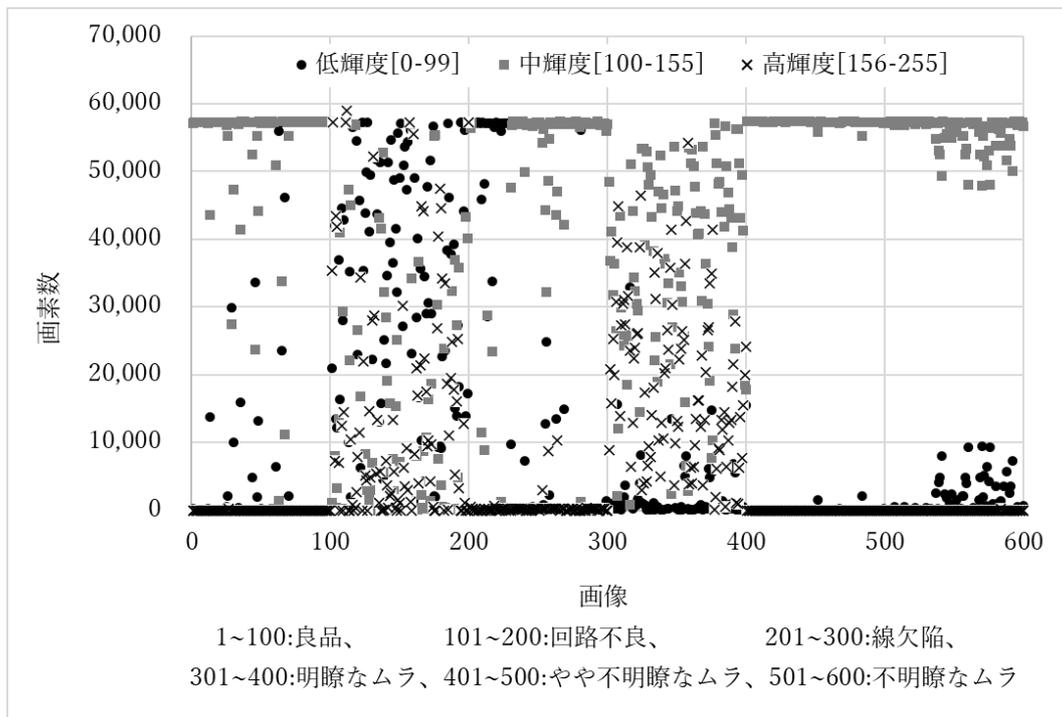


図 55：概念検証におけるデータセット画像の階調分布。

### 3.2 コスト関数

SVM には正則化パラメータとしてコスト関数“C”がある。学習時の誤分類を許容する指標であり、C が小さいほど誤分類を許容し、大きいほど許容しない。

一般に機械学習においては、学習時にモデルを複雑にすることで学習時性能を高めることができるが、複雑にしすぎると汎化性能が低下する過学習（過剰適合）が発生する。C を 1、10、100、1000 として SVM を実施した結果の正解率（5 分割交差検証の平均値）を図 55 に、項目別の再現率と適合率を図 56 に示す。

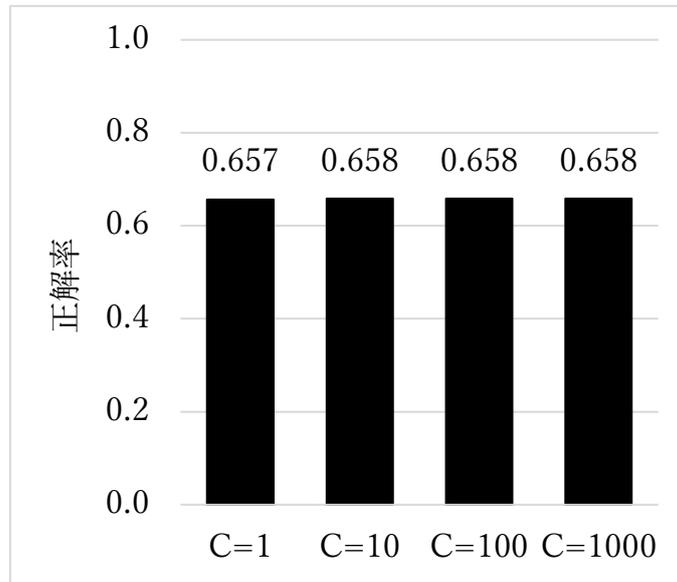


図 56：概念検証における線形 SVM、コスト関数 C=1, 10, 100, 1000 での正解

率。

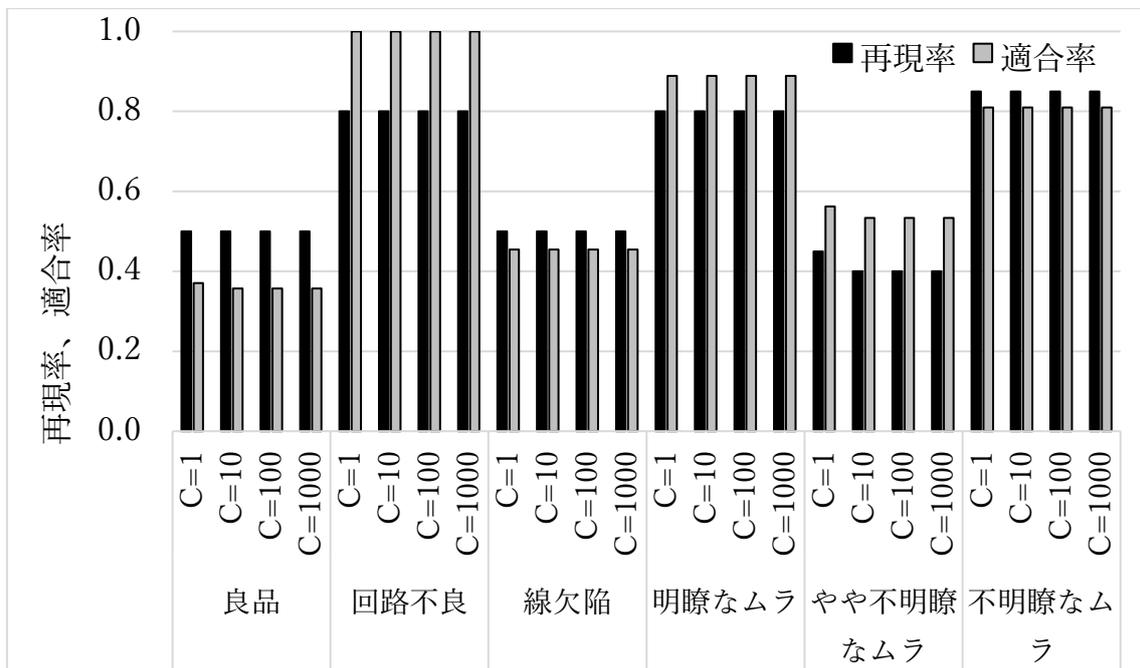


図 57：概念検証における線形 SVM、コスト関数 C=1, 10, 100, 1000 での項目

別再現率と適合率。

このうち  $C=1$  はデフォルト設定なので前項と同じである。図 55 に示すように正解率は  $C=1, 10, 100, 1000$  のいずれにおいても 0.65 程度で同等であり、図 56 における項目別の再現率と適合率も同等だった。 $C$  を大きくしても、即ちモデルを複雑にしても精度が変化しないという結果は、線形分類の限界を示していると考えられるため、次項では非線形分類を検討する。

### 3.3 非線形 SVM

前項までは SVM を線形分類器として使用した結果であるが、SVM は入力データを高次の特徴空間に写像 (マッピング) することで非線形分類にも対応させることができ、この際の計算量の増加を抑えるカーネル法 (カーネルトリック) という手法が用いられる。高次元空間へのマッピング方法には、多項式カーネルと放射基底関数 (RBF: Radius Basis Function) カーネルがある。RBF カーネルはガウシアンカーネルとも呼ばれ、必ず分離平面が存在する無限次元に拡張することができる。ここでは RBF カーネルを用い、さらに前項と同様にコスト関数  $C$  を 1,10,100,1000 とした 4 条件で SVM を実施した。結果の正解率 (5 分割交差検証の平均値) を図 57 に、項目別の再現率と適合率を図 58 に示す。

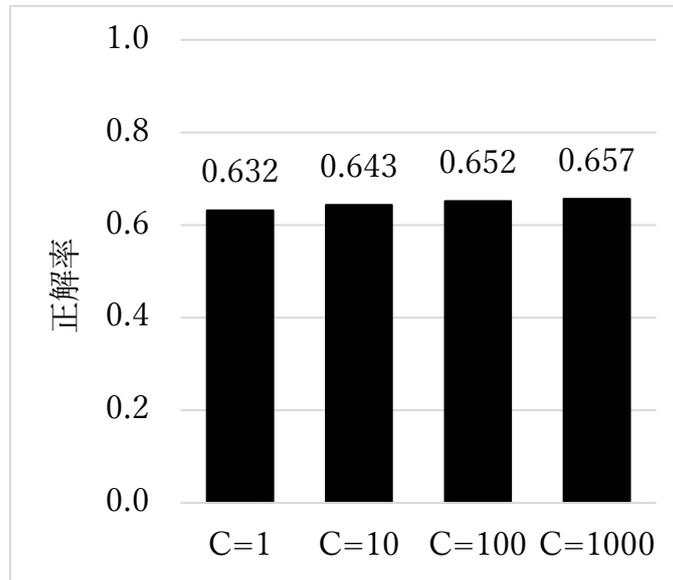


図 58：概念検証における非線形 SVM（RBF カーネル）、コスト関数 C=1, 10,

100, 1000 での正解率。

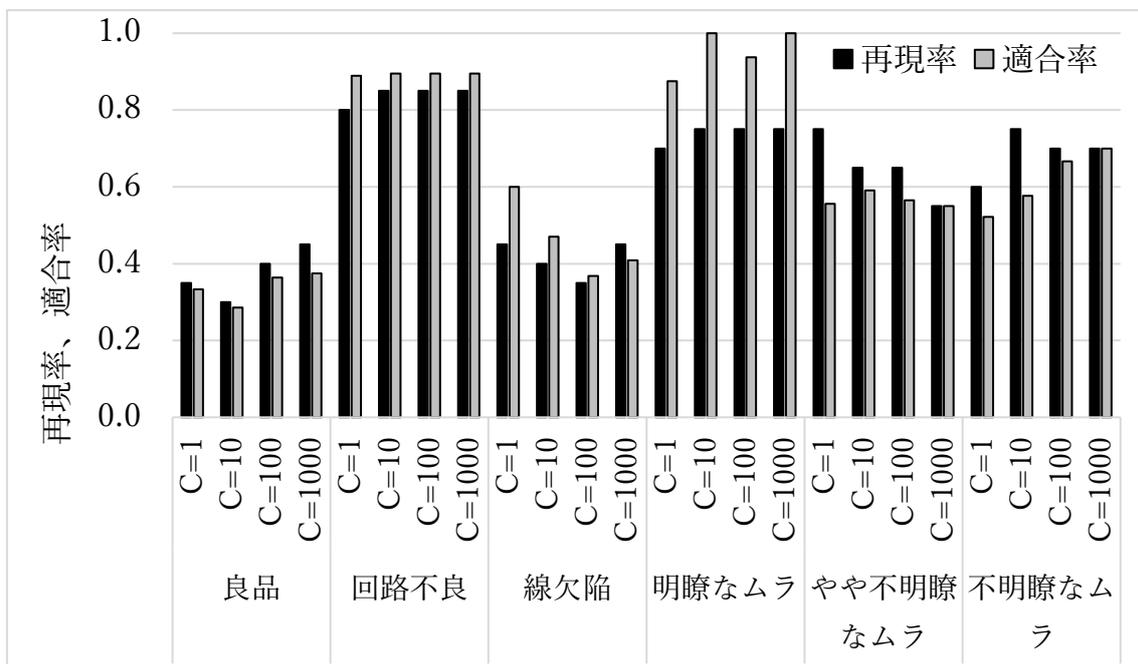


図 59：概念検証における非線形 SVM（RBF カーネル）、コスト関数 C=1, 10,

100, 1000 での項目別再現率と適合率。

C=1 の場合、正解率は 0.632 で、線形 SVM の 0.657 から若干だが低下となった。C を 10,100,1000 と大きくすると正解率は少しずつ改善するが、C=1000 でも 0.657 と線形 SVM と同等。項目別の再現率と適合率は、回路不良と明瞭なムラは 0.7~1.0 で比較的良好、線欠陥は 0.5 前後と線形 SVM と同傾向だが、良品は 0.4 前後、不明瞭なムラ 0.7 前後で線形 SVM より低下、やや不明瞭なムラは 0.6 前後と線形 SVM より改善した。全体に線形 SVM に比べると再現率と適合率に C 依存性が生じたが、大きな違いは認められなかった。

### 3.4 正規化

機械学習において使用する特徴量の単位や値の範囲が異なる場合、学習の前処理として各特徴量が概ね同じ範囲になるよう正規化（スケーリングとも呼ぶ）することが一般的である。ここでは scikit-learn に用意されている下記 4 種類の方法を用いる。

- ・ `MinMaxScaler` … 各特徴量を最小値が 0、最大値が 1 となるよう変換する。
- ・ `StandardScaler` … 各特徴量を平均が 0、分散が 1 となるよう変換する。
- ・ `RobustScaler` … 各特徴量を中央値と四分位数を用いて変換することで、外れ値に対してロバストにする。
- ・ `Normalizer` … 各特徴量をユークリッド長 1 のベクトルに変換（半径 1 の

超球面に投射) する。

上記 4 種類の前処理を実施して SVM (非線形、RBF カーネル使用) を実行した結果の正解率 (5 分割交差検証の平均値) を図 59 に示す。正解率は MinMaxScaler を用いた場合で 0.605、StandardScaler で 0.570、RobustScaler で 0.385%、Normalizer で 0.612 となり、どれも正規化を実施しない場合に比べて低下する結果になった。本研究の特徴量は画像ファイルの階調毎の画素数であるため、単位の違いはなく、正規化によって項目毎のむしろ特徴量の違いが小さくなったためと考えられる。

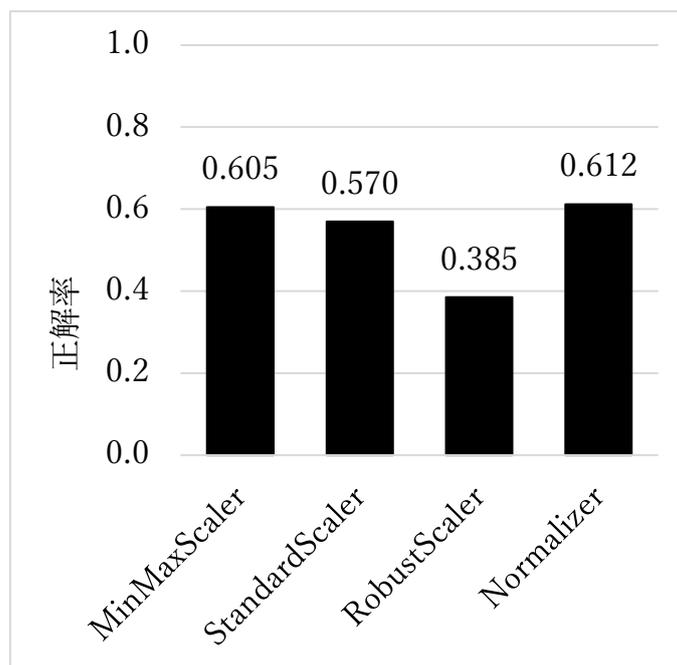


図 60：概念検証における前処理として正規化を実施した SVM での正解率。

### 3.5 主成分分析

主成分分析(PCA: Principal Component Analysis)はデータの次元を削減する手法である。データの要約ととらえることができ、相関のある多数の変数から相関のない少数の変数(主成分)を合成する。本研究においては、256 階調の輝度毎の画素数から、各ムラ固有の階調を要約することで精度が改善するかに着目し、PCA の主成分数  $n=2, 10, 100, 200$  の 4 段階で SVM を実施した。その結果の正解率を図 60 に示す。主成分数  $n=100, 200$  の正解率は 0.665 と前項までの結果を同等だった。これは本データセットの成分数はもともと 256 で、 $n=100, 200$  では差が生じなかったためと考えられる。より要約した場合の正解率は、 $n=10$  で 0.612 に、 $n=2$  では 0.482 に低下した。

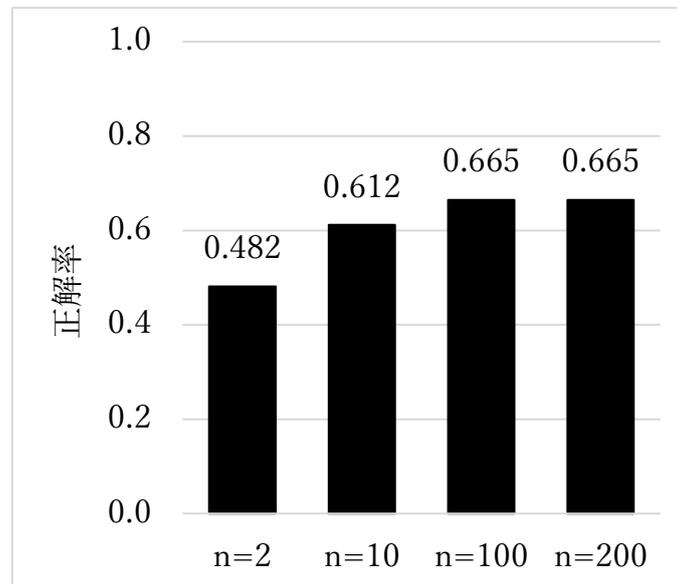


図 61：概念検証における主成分分析を用いた SVM の正解率。

図 61 は本データセットに  $n=2$  の PCA を適用した結果を可視化したグラフである。横軸の第 1 主成分に沿って回路不良と明瞭なムラの一部が分布しているが、他の項目は一か所に固まった状態になっている。縦軸の第 2 主成分に対しては、不明瞭なムラはグラフ上部に集中する傾向があるが、他の項目は混在する分布になっている。このように要約によって項目毎の特徴が混在したために正解率が低下したと考えられる。

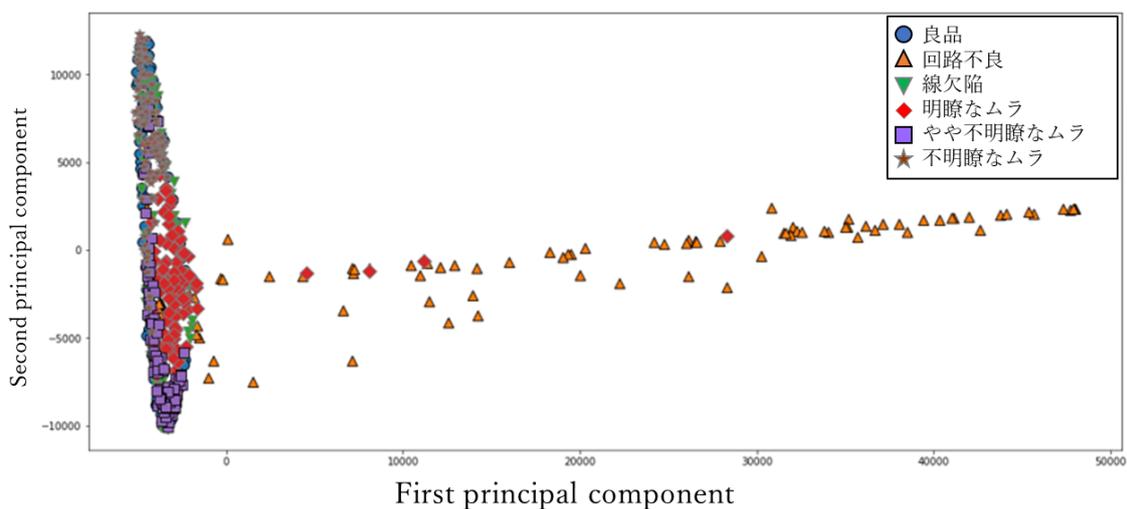


図 62：概念検証における主成分分析( $n=2$ )の結果の可視化。

### 3.6 SVM 評価結果まとめ

前述の通り、6 項目、100 枚ずつのデータセットに対して、線形、非線形、コスト関数  $C$ 、正規化、主成分分析と合計 16 条件で SVM による評価を実施した。16 条件の正解率を図 62 に示す。各条件の正解率は 5 分割交差検証の平均値で

ある。同図に示すように 16 条件のうち 13 条件は正解率が 0.60~0.67 の範囲に集中し、ほぼ同等という結果だった

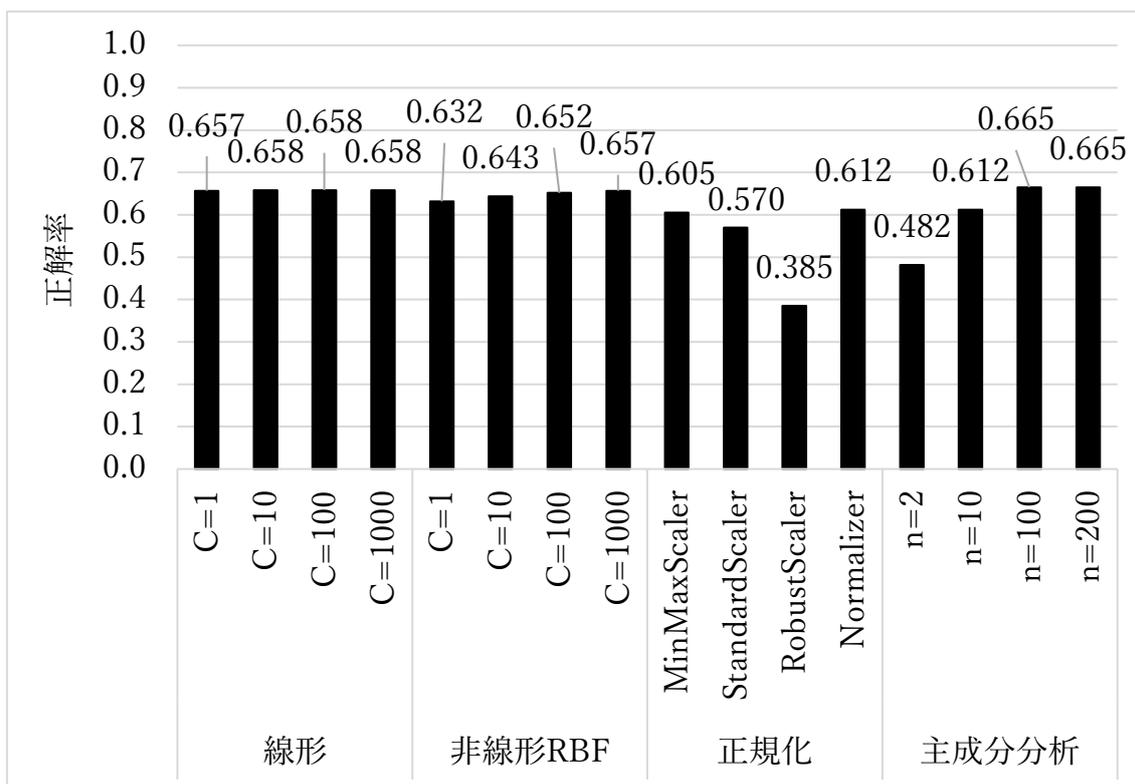


図 63：概念検証における SVM 評価結果のまとめ。

## 4 CNN での評価結果

前節の SVM では画像データを階調毎の画素数という 1 次元のデータに変換するため、画像データの位置情報が失われることになるが、画像データをもとの構造のまま入力することが可能なアルゴリズムとして畳み込みニューラルネットワーク(CNN: Convolutional Neural Network)がある。本章の概念検証では、

CNN がディスプレイのムラ検出に有効かを基礎評価するため、1998 年に初の CNN として発表された LeNet をベースとし、図 63 に示すように畳み込み層と Max プールング層を 2 組使用するシンプルなモデルを用いる [30]。

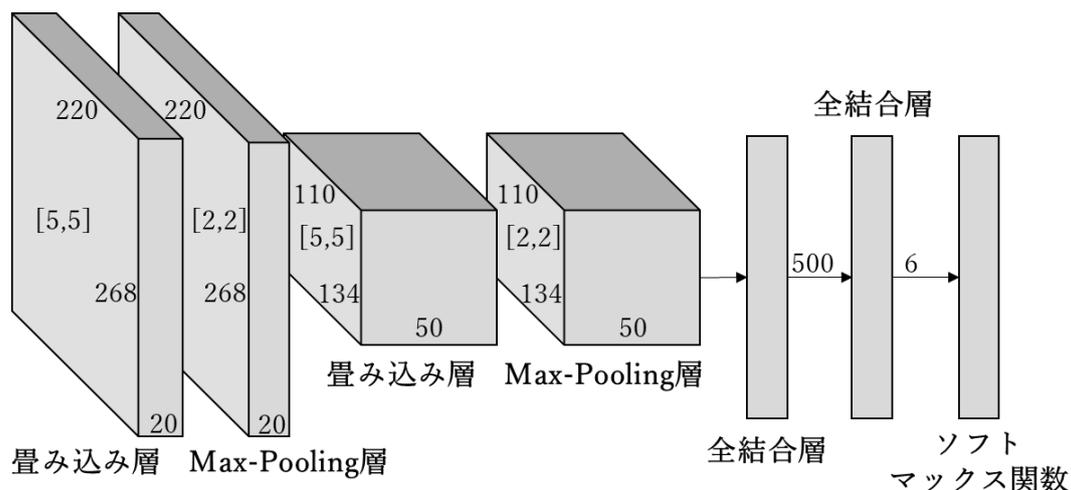


図 64：概念検証で用いた CNN の基本構造。

表 6 は上記 CNN の実施結果の混同行列であり、5 回の交差検証の平均値である。6 項目合計の正解率は 0.658 であり、前節 SVM と同等であった。ただし交差検証 5 回の正解率は、SVM では 61.7~67.5%だったが、CNN では 51.7~78.3%でばらつきが大きかった。図 64 は混同行列から求めた項目別の再現率と適合率である。比較のため、前節の SVM で正解率 0.658 と最も高く CNN と同等だった条件（線形、C=1000）での結果を併記している。項目別には、CNN と SVM 共通で、回路不良と不明瞭なムラの 2 項目は 0.8 以上と比較的良好、良品、

線欠陥、やや不明瞭なムラの3項目は0.3~0.6と低調。明瞭なムラではCNNとSVMに相違があり、CNNで0.65前後だがSVMでは0.8前後とSVM優位だった。

項目 (目視検査結果)	推定結果						合計
	良品	回路不良	線欠陥	明瞭なムラ	やや不明瞭なムラ	不明瞭なムラ	
良品	12	0	4	1	2	1	20
回路不良	0	17	0	2	0	0	20
線欠陥	7	0	7	1	4	1	20
明瞭なムラ	1	1	0	13	4	0	20
やや不明瞭なムラ	3	0	0	3	12	1	20
不明瞭なムラ	1	0	1	0	0	18	20

表6：概念検証におけるCNN評価結果の混同行列

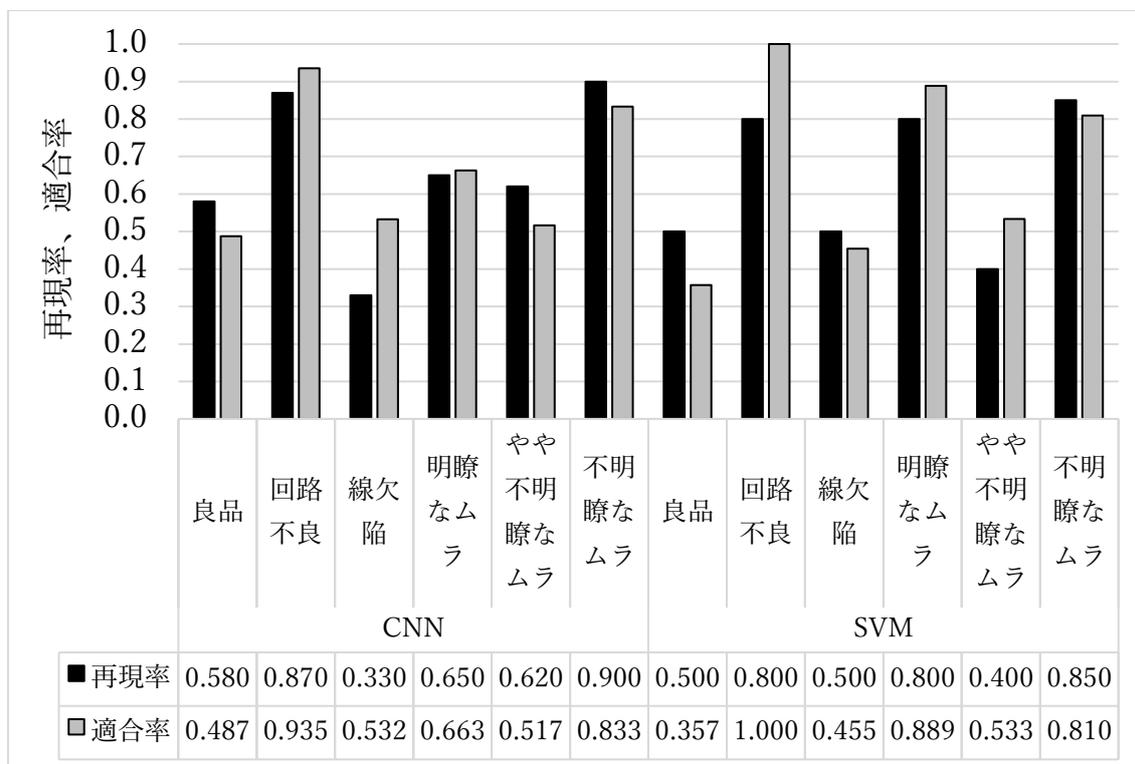


図65：概念検証におけるCNN評価結果の再現率と適合率。

## 5 概念検証結果の考察

以上述べたように、3 項目のムラを含む 6 項目、各 100 枚の小規模なデータセットを対象に、SVM と CNN を用いて検出、分類し、その精度を評価した。その結果、概念検証として機械学習を用いてムラを検出、分類すること自体は可能であることを示すことができた。検出精度についてはベースラインとして正解率 0.65 という指標が得られた。アルゴリズム別では、SVM は 16 条件で正解率が 0.65 程度で留まり、うち 13 条件 0.60~0.67 の範囲に集中したことから改善は困難と考えられるのに対し、CNN は正解率 0.65 で同等だが、層数の少ないモデルを用いたこと、データセットの規模が小さいこと、交差検証間の正解率のバラツキが大きいことから、データセット規模拡大や層構造等のモデル改善によって精度改善の可能性があると考えられる。本研究では、データセットの規模を拡大したうえで、CNN を中心に評価を実施する。

## 本研究に関連する発表

### ■ 発表論文（査読有）

- ・ Tomita S., Siritanawan P., and Kotani K., "In-Line Mura Detection Using Machine Learning and Subspace Method in Display Manufacturing", Journal of the Society for Information Display.

### ■ 学会発表（国際会議）

- ・ Tomita S., Siritanawan P., and Kotani K., "In-Line Mura Detection using Convolutional Neural Network in Display Manufacturing", Society for Information Display Symposium Digest of Technical Papers 2022, 963-966.

### ■ 特許出願

- ・ 出願番号：特願 2021-191229 部分空間法によるムラ検出
- ・ 出願番号：特願 2021-191230 ムラ検出におけるコントラスト強調手法

### ■ 電子情報技術産業協会（JEITA）人間工学検討グループでの講演

- ・ 「畳み込みニューラルネットワークを用いたディスプレイ製造工程でのムラ検出」 2022年11月25日

### ■ その他の本研究に関する発表論文（査読有）

- ・ Tomita. S, Okada T., and Takahashi H., "An in-cell capacitive touch sensor integrated in an LTPS WSVGA TFT-LCD", Journal of the Society for Information Display Volume 20, Issue 8, First published: 21 August 2012.
- ・ Tomita. S, Jurichich S., and Saraswat K. C., "Transistor sizing for AMLCD integrated TFT drive circuits", Journal of the Society for

Information Display Volume 5, Issue 4, First published: 18 June 2012.

- Tomita S., Tomita O., and Kasahara K., “A compensative driving method for common-electrode voltage distortions in TFT-LCDs”, Journal of the Society for Information Display Volume 1, Issue 2, First published: June 1993

## 参考文献

- [1] Kido T, Kishi N, and Takahashi H, "Optical Charge-Sensing Method for Testing and Characterizing Thin-Film Transistor arrays", IEEE JOURNAL OF SELECTED TOPICS IN QUANTUM ELECTRONICS, VOL. 1, No. 4, DECEMBER 1995
- [2] Troutman R R, Jenkins L C, Polastre R J, Wisnieff R L, "Characterization of TFT/LCD Arrays", Conference Record of the 1991 International Display Research Conference, p.231-234.
- [3] Henley F J, "Flat-Panel In-process Test, Repair, and Inspection: An Overview", SID Symposium Digest of Technical Papers 1992, 623-627.
- [4] Schmitt R, Brunner M, and Winkler D, "Electron-beam testing of flat panel display substrates" Microelectronic Engineering Volume 24, Issues 1-4, March 1994, Pages 35-42
- [5] Chung K Y, "Profit Maximization of TFT-LCD Manufacturing by Optimizing TFT-Array Test Parameters", SID Symposium Digest of Technical Papers 2003, 366-369.
- [6] 齊藤 文彦、「液晶ディスプレイ画質検査装置における画素欠陥検出手法」、精密工学会誌 Vol. 63, No. 4, 1997, 520-524.
- [7] Xiong W, Lee J, Qu S, and Jang W, "Data Augmentation for Applying Deep Learning to Display Manufacturing Defect Detection", SID Symposium Digest of Technical Papers 2020, 1210-1213.
- [8] Tsutsukawa K, Kobayashi M, and Bamba Y, "Neural Network Based Quantitative Evaluation of Display Non-Uniformity Corresponds Well with Human Visual Evaluation", SID Symposium Digest of Technical Papers 2020, 1214-1217.
- [9] Guo K, et al., "Array Defect Detection and Repair Based on Deep Learning", SID Symposium Digest of Technical Papers 2022, 1222-1225.
- [10] Lee Y W, et al., "Image Quality Predication System in Display

- Fabrication Process”, SID Symposium Digest of Technical Papers 2020, 1226-1229.
- [11] Guo K, et al., "A Visualization Method of Training Data Completeness in Array Defect Recognition Based on Deep Learning", SID Symposium Digest of Technical Papers 2021, 196-199.
- [12] Lee J, "Region-Based Machine Learning for OLED Mura Defects Detection”, SID Symposium Digest of Technical Papers 2021, 200-203.
- [13] Tang H, Liu J, Xu G, "A Proposal for Image-Compression Algorithm for Display Test Images", SID Symposium Digest of Technical Papers 2022 May, 967-970.
- [14] Cheng Q, et al., "Deep Learning Based Visual Defect Detection in Noisy and Imbalanced Data", SID Symposium Digest of Technical Papers 2022 May, 971-974.
- [15] Mou S, et al., "Synthetic Defect Generation for Display Front-of-Screen Quality Inspection: A Survey", SID Symposium Digest of Technical Papers 2022 May, 975-978.
- [16] Park K, Lee J, Lee K, "AI Analysis of HOP Circuit Failure and Improvement", SID Symposium Digest of Technical Papers 2022 May, 1445-1447.
- [17] Jung S, "The Solution for Imbalanced Image Data of Mass Production", SID Symposium Digest of Technical Papers 2022 May, 1462-1466.
- [18] Xu P, Tang H, Xu G, "Display Graylevel Gamma Tuning Algorithm and System Implementation", SID Symposium Digest of Technical Papers 2020 May, 1218-1221.
- [19] Zou G, Wang Z, Yang W, Yang B R, and Qin Z, "Deep Learning-Enabled Image Content Adaptive Driving Algorithm for Field Sequential Color LCDs with Mini-LED Backlight", SID Symposium Digest of Technical Papers 2022 May, 857-860.
- [20] Koh J, et al., "A Light and Fast Branched Neural Network using Perceptual Optimization for High-Quality Visual Restoration of UDC images", SID Symposium Digest of Technical Papers 2022 May, 861-864.
- [21] Nam H, Kang H, and Cho H, "Foveated Super Resolution Network for Virtual Reality Head-Mounted Displays", SID Symposium Digest of Technical Papers 2022 May, 869-872.

- [22] Jeong K J, Lim M, Kang M, Lee Y, and Kim Y, "AI Based Simulation and Design Space Exploration for Pixel Layout", SID Symposium Digest of Technical Papers 2022 May, 873-876.
- [23] 成田 浩久、館山 武史、永野 佳孝、藤本 英雄、「画像検査への AI の応用についての現状と将来に関する考察」、表面技術 Vol.71, No.7, 2020, 459-463
- [24] 東レエンジニアリング先端半導体 MI テクノロジー (株)、「光学式半導体ウェーハ外観検査装置 INSPECTRA シリーズ」、[https://www.toray-eng.co.jp/tasmit/products/measuring/mea\\_010.html](https://www.toray-eng.co.jp/tasmit/products/measuring/mea_010.html) (閲覧日 2022/06/23)
- [25] 北川 克一、「“INSPECTRA”技術資料 検査アルゴリズム： D S I 比較法」、<http://kitagawa.image.coocan.jp/in-tech.html> (閲覧日 2022/06/23)
- [26] Shiori K, Hamano S, "Application of Machine Learning to Printed Circuit Board External Inspection", Anritsu Technical Review No.28 September 2020, 45-51
- [27] 高島 信治、「限度見本による外観検査のバラツキの管理」、金属表面技術 Vol. 12, No. 12, 1961, 16-19
- [28] 竹内 一郎、烏山 昌幸、「サポートベクトルマシン」講談社 (2015 年)
- [29] 岡谷 貴之、「深層学習」講談社 (2022 年)
- [30] Lecun Y, Bottou L, Bengio Y, and Haffner P, "Gradient-Based Learning Applied to Document Recognition", Proceedings of the IEEE (November 1998).
- [31] Krizhevsky A., Sutskever I., and Hinton G. E., "ImageNet classification with deep convolutional neural networks" In NIPS, pp. 1106–1114, 2012.
- [32] Chollet F, "Deep Learning with Python", chapter 5, Manning

Publications, 2017.

- [33] He K, Zhang X, Ren S, and Sun J, “Deep Residual Learning for Image Recognition”, arXiv:1512.03385v1 [cs.CV] (Dec 2015)