

# ディープラーニングによる瓦の欠陥検出手法に関する基礎研究

阿野裕司\*

## Fundamental Study on Detection Method of Tile Defects using Deep Learning Yuji Ano

画像処理で瓦の欠陥であるひび割れの検出を行う場合、欠陥と欠陥でない模様等のノイズを判別する必要がある。一般的には色や明るさ、エッジ(輪郭)といった特徴量を用いて判別を行うが、ひび割れと模様はどちらも黒色系かつ線状の特徴を示すため、特徴量の抽出は困難となる。そこで、本研究では瓦の欠陥検出において特徴量を自動で抽出するディープラーニングの有用性を検証した。その結果、瓦の欠陥検出におけるディープラーニングの有用性が確認された。

### 1. 緒言

人件費削減や製造時間短縮のため、多くの製造現場において画像処理を用いた検査工程の自動化が行われている<sup>1)</sup>。また、カメラの低コスト化、汎用 PC の高性能化等により、市販の自動検査システムを用いなくても、汎用機器を用いて自動検査システムを構築することが可能となってきている<sup>2)</sup>。

一般に、画像処理による欠陥検出を行う場合、検査対象に欠陥でない模様等のノイズが混在していることがあるため、欠陥とそれらノイズを判別する必要がある。その場合、色や明るさ、エッジ(輪郭)といった特徴量を用いて判別を行うが、欠陥とノイズの特徴量に明らかな違いが無い場合、どのような特徴量が適しているか抽出するのは困難なことが多い。そのため、現在でも様々な検査工程において目視検査が行われているのが現状である<sup>3)</sup>。

一方で近年、機械学習の一手法で特徴量を自動で抽出するディープラーニングが様々な分野で従来手法を超える性能を示し注目を集めている<sup>4)</sup>。画像処理の分野でも 2012 年の一般物体認識コンペティション(ILSVRC2012)において、ディープラーニングを用いた手法のエラー率(誤認識率)が 2011 年の従来手法の結果と比較して 10%も改善されたことから、以降のコンペティションではディープラーニングを用いた手法が中心となっている<sup>4)</sup>。

本研究では、欠陥とノイズを持ち、それらを判別する特徴量の抽出が困難である瓦の欠陥検出において、ディープラーニングの有用性を検証した。具体的には、瓦を撮影した画像から欠陥の有無でクラス分けを行ったデータセットを作成し、そのデータセットを用いてディープラーニングで学習を行った。その学習結果を用いて瓦の欠陥検出を試みたところ、欠陥検出におけるディープラーニングの有用性を確認したので、その結果を報告する。

### 2. 実験方法

#### 2・1 検査対象

検査対象となる瓦は県内企業が製造しているプレスセメント瓦である。瓦の全景を図 1 に示す。瓦はモルタルをプレス成型後、乾燥、塗装することで製造されており、大きさは 423×324mm である。瓦の欠陥であるひび割れに対しては、現在プレス成型後に目視による欠陥検査が行われているが、5~10%程度の見逃しが発生しているため、塗装前等にも目視による欠陥検査が実施されている。

ひび割れはプレス成型後、型から抜き出す作業中に受け板に瓦が衝突することで発生する。その大きさは数 mm 程度から瓦全体に及ぶものまで様々であるが、本研究では目視で確認した際に明らかなひび割れとして認識できるもの(幅 0.4mm 程度、長さ 10mm 程度以上)を検出対象とする。また、瓦には欠陥以外に模様や汚れ等のノイズも存在する。欠陥とノイズを拡大した画像を図 2 に示す。図 2(a)は欠陥であるひび割れの一例である。図 2(b)はノイズとなる模様の一例、図 2(c)は同じくノイズとなる汚れの一例である。図 2(a)と図 2(b)に示す通り、ひび割れと模様はどちらも黒色系かつ線状の特徴を示すため、特徴量の抽出を行うことが困難である。なお、図 2(d)にはひび割れと模様が混在している一例を示す。




図 1 瓦の全景

\* 企業支援部電子応用グループ




図2 欠陥とノイズ

## 2・2 撮影環境

撮影環境を図3、瓦を撮影した画像の一例を図4に示す。瓦には曲面が存在し、その曲面部にひび割れが発生することもあるため、カメラ1台で瓦全体の撮影を行うことは困難であった。そこで、図3に示すとおり、カメラ2台

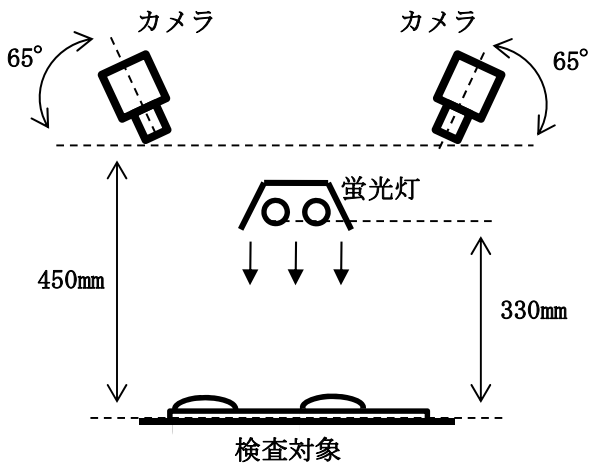


図3 撮影環境




図4 撮影画像

を用いた撮影環境とした。

撮影には XIMEA 製の解像度 400 万画素 (2,048 × 2,048 pixels), CCD サイズ 11.2 × 11.2 mm のカメラを用い、興和光学製の焦点距離 16 mm のレンズと組み合わせた。ここで、カメラと撮影対象の距離を WD (Working Distance), カメラの CCD サイズを L, レンズの焦点距離を F とすると、次式により視野角  $V$  が求められる。

$$V = \frac{WD \times L}{F} \dots \dots \dots (1)$$

カメラを瓦に対して斜めに設置しているため、WD は瓦の場所によって 420 ~ 570 mm と差があるが、最も遠い 570 mm とした場合でも視野角 399 mm となり、1 pixel 当たりの撮影範囲は 0.195 × 0.195 mm となる。幅 0.4 mm 程度以上のひび割れを検出するために必要な画像を取得可能である環境とした。

照明はアイゼット製の蛍光灯、画像の取り込みや処理には GPU を搭載した汎用デスクトップ PC を用いた。なお、本研究は欠陥の検出が可能かどうかの検証が目的であるので、カメラ 1 台で検討を行った。

## 2・3 ディープラーニング開発環境

ディープラーニングの開発環境としては画像処理の分野で良く用いられている Caffe を採用した<sup>4)</sup>。また、インターフェースとして NVIDIA が公開している DIGITS を用いた。OS は、ディープラーニングを利用する際に使われることが多い Linux を採用し、GPU の開発環境には CUDA、ディープラーニング用ライブラリには cuDNN を用いた。なお、Caffe と DIGITS, CUDA, cuDNN はすべてオープンソースとして無料で公開されている。

ディープラーニングで用いるデータセットは、図4に示した瓦を撮影した画像から瓦部を一定サイズ毎に切り出し、欠陥の有無でクラス分けを行い作成した。具体的には 18 枚の瓦を図3の撮影環境で撮影し、瓦部を 256 × 256 pixels ずつ切り出した後、欠陥のある画像と無い画像をそれぞれ 1,504 枚ずつ、合計 3,008 枚用意してデータセットとした。なお、3,008 枚のうち、学習用に 2,254 枚、検証用に 250 枚、テスト用に 504 枚を用いた。検証用画像で学習途中の欠陥検出率を検証し、テスト用画像で学習後の欠陥検出率を確認する。

構築したソフトウェアの階層構造を図5に示す。ディープラーニングでの学習に用いるネットワークは AlexNet と GoogLeNet の 2 種類を、学習方法は SGD, NAG, AdaGrad, AdaDelta の 4 種類を組合せた。AlexNet は 8 層、GoogLeNet は 22 層のネットワークであるため、学習に必要な時間は GoogLeNet の方が長くなるが、一般物体認識においては GoogLeNet の方が高性能である。学習方法は SGD が基本手法で、データの収束速度等を改善した NAG や AdaGrad, AdaDelta は SGD を発展させた学習方法である。

ディープラーニングによる学習、検証を 50 回繰り返した後、テスト用画像を用いて欠陥検出を行い、学習ネットワークと学習方法の組合せによる検出率の違いを比較した。また、データセットの画像サイズが欠陥検出に及ぼす

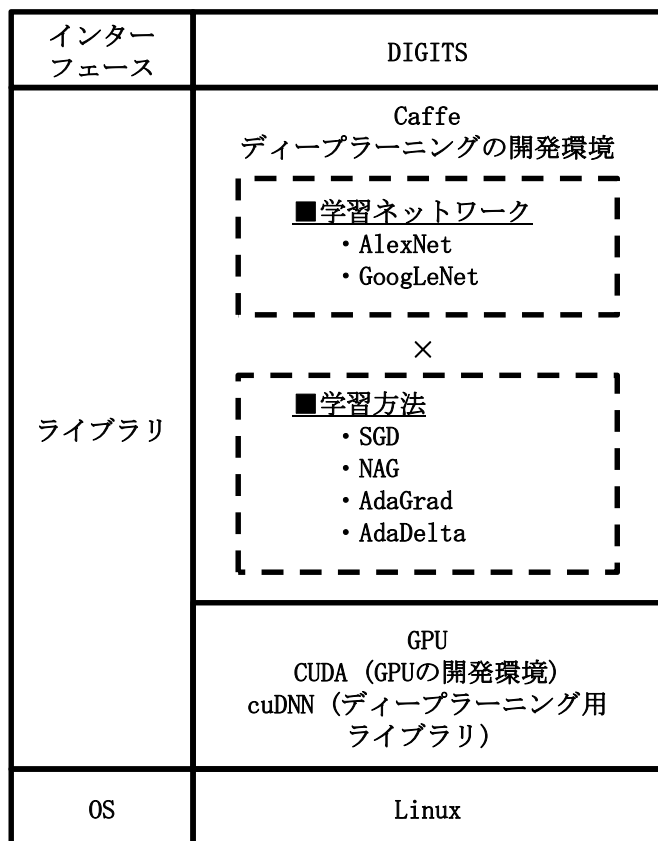


図5 ソフトウェアの階層構造

影響を検証するため、瓦部を切り出すサイズを128×128pixelsとした場合も比較した。

### 3. 実験結果

データセットの画像サイズが256×256pixelsの場合のテスト画像に対する欠陥検出率を表1に示す。また、データセットの画像サイズが128×128pixelsの場合のテスト画像に対する欠陥検出率を表2に示す。検出率が最も高いのは、データセットの画像サイズが256×256pixelsで学習用ネットワークにGoogLeNet、学習方法にNAGを用いた場合で93.65%となった。2・1で述べたとおり、現状の目視検査においても5~10%程度の欠陥の見逃しが発生していることから、ディープラーニングを用いた欠陥検出は目視検査に近い結果を得られる有用な手法であると考えられる。

今回検出率が最大となったのはデータセットの画像サイズが大きい256×256pixelsを用いた手法であったが、一般的には、データセットの画像サイズが小さくなれば、欠陥のある画像の場合、画像全体に占める欠陥の面積が増えるため、欠陥の有無がより明確になることで、検出率が高くなると考えられる。本実験においても、データセットの画像サイズが小さい128×128pixelsの場合で93.05%とほぼ同等の検出率が得られていることから、データセットの画像サイズをさらに小さくすることで、より高い検出率を得られる可能性がある。

また、学習ネットワークについては一般物体認識と同じくGoogLeNetの方が高性能であることを確認したが、学習方法については基本手法であるSGDに対してNAGや

表1 ディープラーニングを用いた瓦の欠陥検出率  
(データセット256×256pixels)

単位は %

		学習ネットワーク	
		AlexNet	GoogLeNet
学習方法	SGD	88.10	90.48
	NAG	77.18	93.65
	AdaGrad	65.48	90.67
	AdaDelta	65.48	70.63

表2 ディープラーニングを用いた瓦の欠陥検出率  
(データセット128×128pixels)

単位は %

		学習ネットワーク	
		AlexNet	GoogLeNet
学習方法	SGD	88.97	92.75
	NAG	89.88	93.05
	AdaGrad	71.90	88.82
	AdaDelta	72.51	80.97

AdaGrad, AdaDeltaの方が一概に検出率が高くなるわけではないことが分かった。その理由としては、認識する対象によって適した学習方法があるためと考えられる。なお、データセットの画像枚数の増減によっても検出率は変化する可能性があるため、今後検証を行う予定である。

### 4. 結論

本研究では、欠陥とノイズを持ち、それらを判別する特微量の抽出が困難である瓦の欠陥検出において、ディープラーニングの有用性を検証した。

瓦を撮影した画像から欠陥の有無でクラス分けを行ったデータセットを作成し、そのデータセットを用いてディープラーニングで学習を行った。その学習結果を用いて瓦の欠陥検出を試みたところ、93.65%の検出率となった。また、データセットの画像サイズをさらに小さくすることで、より高い検出率を得られる可能性があることが分かった。さらに学習ネットワークについては、一般物体認識と同じくAlexNetよりGoogLeNetの方が高性能であることを確認したが、学習方法については基本手法であるSGDに対してNAGやAdaGrad, AdaDeltaの方が一概に検出率が高くなるわけではないことが分かった。

今後は、データセットの画像枚数や画像サイズ、学習ネットワークの再学習が欠陥検出率に及ぼす影響の検証を行う予定である。また、瓦以外の製品に対する欠陥検出においても、ディープラーニングの有用性を検証したい。

本研究の遂行に当たり、数多くの有益なご指導、ご助言を賜りました国立大学法人山口大学大学院理工学研究科水上准教授に深く感謝致します。

瓦のサンプル提供でご協力頂いた株式会社コトガワ 佐々岡良介代表取締役社長、大谷康雄技術開発・製造課長に深く感謝致します。

#### 参考文献

- 1) 青木公也：目視検査の自動化技術 画像処理の産業応用について，検査技術，**10**(12)，p. 1-8 (2005).
- 2) 藤原義也，是永晋治，安部重毅，後藤孝文，大賀 誠，打田澄雄，矢式良行，北村好道：情報通信技術を活用したランダムピックアップシステムの開発(第1報)安価なシステム構築を目指すランダムピックアップ基盤技術の開発，広島県立総合技術研究所西部工業技術センター研究報告，Vol. **57**，p. 1-4 (2014).
- 3) 中谷信幸：知的搬送技術による各種自動外観検査装置の研究，博士論文(高知工科大学)，p. 3-6 (2013).
- 4) 山下隆義：イラストで学ぶ ディープラーニング，(株)講談社，(2016).