

## 敵対的生成ネットワークに基づく木材欠陥検出アルゴリズムに関する研究

G2121016 カウンキョク

### 1. はじめに

木材は、家具や建築など多くの産業の基礎原料として重要な役割を担っている。木材の欠陥はその商品価値に重大な影響を及ぼす。木材は成長する過程で、節や虫害、割れなどのさまざまな欠陥が生じることが多く、家具製造に必要な木材の品質等級を満たすために優先的に加工する場合、さらに識別して切断処理する必要がある、企業による原木の活用を著しく低下させる。

今日、木材の欠陥の目視品質検査は、木工業界の訓練を受けた作業員によって行われている<sup>[1]</sup>。ある研究では、木材の欠陥検査における人的ミスは、22%の廃材を生み出し、木材製品の総収量を63.5%から47.4%に減少させた<sup>[2]</sup>。一方、木材の欠陥を人の目で認識するには労働集約型で人間の主観に依存している。Buehlmann と Thomas は、以下を発見している。Buehlmann と Thomas は、検出精度を2.5%向上させることができれば、木材生産量を5.3%増加させることができることを発見した<sup>[3]</sup>。

そのため、木材の欠陥の自動的かつ迅速な検出は、あらゆる企業にとって急務となっている。初期の木材の自動欠陥検出は、センサーに大きく依存していましたが、センサーの使用には安定した環境が必要だけでなく、アプリケーションの場所以が制限されることがある。例えば、超音波センサーは外部からの影響を受けて不安定になることがあり、応力波センサーは木材の表面にしっかりと密着させる必要がある。機械学習の台頭により、木材の欠陥検出には人手で抽出した特徴量を用いた機械学習法が多く用いられているが、人手で抽出した特徴量の良し悪しに大きく依存し、再利用性に乏しいという問題がある。

ディープラーニング技術は、画像の特徴を自動的に抽出することができ、特に画像処理に優れているため、木材の欠陥検出に新たなソリューションを提供する。畳み込みニューラルネットワークは、木材欠陥画像サンプルの識別において、優れた耐障害性と自己学習の利点を持ち、手動による主観やエラーが発生しやすいという制約がないだけでなく、検出を達成するために手動による特徴選択を必要としない。畳み込みニューラルネットワークは、その優れた性能から、欠陥検出の分野で広く利用されている。

しかし、木材欠陥検出における畳み込みニューラルネットワークには、木材欠陥データの集中、欠陥の種類アンバランス、データ量の少なさなどの問題が残っており、検出アルゴリズムは検出効率が低く、精度も低いという問題がある。本論文では、欠陥検出のためのエンコーダコンポジットを持つGANを提案する。メインのネットワークはDCGANで、これに必要に応じてエンコーダを追加し、さらに学習用の損失関数を設計している。本手法では、学習に正のサンプルしか必要としないため、欠陥セットの収集とラベル付けが困難という問題がある程度解決される。

## 2. 関連研究

### 2.1 木材欠陥検出

従来、木材の加工ラインでは、熟練工が目視で木材の欠点を発見し、品質等級付けと合わせて行っていたため、人的資源の消耗が大きいだけでなく、識別の面でも非効率的なものでした。

センサー技術の発達により、木材の欠陥をセンサーで自動的に検出することが企業にとって好ましい選択肢となり、現在木材の欠陥検出には、超音波技術とX線検出が主に使われている。

Wang Lらは、ウェーブレット変換と人工ニューラルネットワークを用いた木材の超音波非破壊検査について研究した<sup>[4]</sup>。

Mou Hongboらは、木材の欠陥のX線画像を用いて、灰色共分散行列を用いて画像特徴を決定し、ファジー逆伝播ニューラルネットワークを用いて木材の欠陥を識別し、90%の精度を達成した<sup>[5]</sup>。

木材の欠陥の非破壊検出はセンサーで実現されているが、使用する場所や機器に制約がある場合が多い。機械学習の台頭により、木材の欠陥認識にマシンビジョンを用いた機械学習が主流となっている。

Zhang らは、X線を用いて得られた木材欠陥画像をグレイ変換し、木材欠陥の特徴の数学的モデルを確立し、その特徴をBPニューラルネットワークに与えて、欠陥認識を90%の精度で行った<sup>[6]</sup>。

### 2.2 GAN

GAN (Generative Adversarial Networks) は、2014年にIan Goodfellowら<sup>[7]</sup>によって提案された生成モデルである。しかし、GANは学習中に学習が不安定になったり、パターンが崩れたりすることがある。

前述の通り、GANは学習が不安定であるため、この問題を軽減するためにRadfordらはDCGANモデルを提案した<sup>[8]</sup>。DCGANは、オリジナルのGANと比較して、いくつかの改良がな

されている。

Thomas ら<sup>[9]</sup>は、GANを介して異常検知タスクを達成するモデルであるAnoGANアルゴリズムを提案した。

### 2.3 本研究の立場

マシンビジョンを用いた機械学習は、木材の欠陥認識で良好な結果を得ているが、人手で設計した特徴量に依存しており、機械学習アルゴリズムそのものよりも特徴量の選択が木材認識に影響を与える。

本論文では、現在の木材欠陥検出技術の研究において、データ量が少なすぎる、欠陥の種類が不均一、検出精度が不十分といった問題に対して、GANを用いた検出方法を提案する。

## 3. 本研究の概要

ディープラーニングを用いた木材の欠陥検出技術により、木材の品質管理に有効な技術的保証を提供します。実用化にはまだ問題がある。例えば、木材の欠陥データセットでは、欠陥の種類とデータ量の少なさがアンバランスになっています。これは検出モデルの性能劣化につながる可能性があり、そのために、エンコーダー付きDCGANを用いた教師なし木材欠陥検出法を提案する。

GANは、ノイズを使って実際のデータに近いデータを生成する強力な生成モデルである。多くの検査モデルでは、GANを用いてサンプルデータを拡張し、良好な検出結果を得ている。しかし、GANは学習が難しく、パターン崩れが起こりやすいため、GANを用いたデータ補強手法にはまだ課題が残っている。また、GANのデータ増強に関してもパラドックスがある。GANも良質で明確に使えるデータを生成するためには、大量のデータを学習させる必要があるが、問題の本質はデータ増強のためのデータ量が不足していることである。GANの学習を少数のデータセッ

トで行うと、生成されるデータの質が低くなり、その後の学習で使用するデータの均質性・多様性が十分に得られなくなるためである。したがって、データサンプル不足によるモデル検出精度の低下という問題を解決するために、GANを用いたデータ拡張のアプローチには、まだまだ反省と改善の余地があると考えられる。

そこで本研究では、データ不足の問題を解決するために、教師なしアプローチを採用した。教師なし木材欠陥検出アルゴリズムは、ポジティブサンプルで学習され、エンコーダ付き DCGAN の強力な画像再構成機能を使用して、欠陥を局所的に検出します。GAN の強力な画像生成能力と生成されたデータの信頼性は多くの研究により実証されていますが。しかし、GAN には、学習が難しく、学習過程が不安定という欠点もある。GAN におけるこれらの問題を解決するために、また本研究で必要となるように、DCGAN にはエンコーダが埋め込まれている（具体的な学習モデルの枠組みは、図1に示すとおりである）。

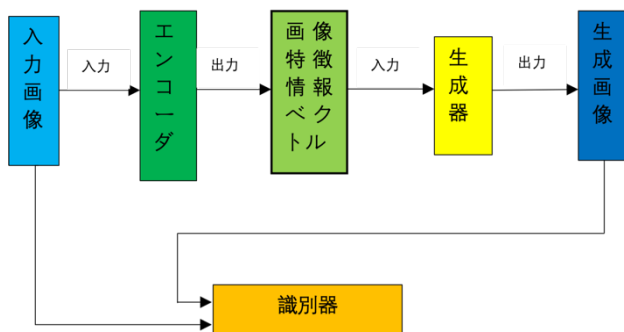


図 1

エンコーダは画像を潜在空間に完全にマッピングすることができるからである。つまり、ランダムなノイズの代わりに、DCGAN への入力はエンコーダの出力となるわけです。これは、入力がランダムなノイズではなく、画像の特徴に関する情報を持つベクトルであるため、DCGAN の学習がしやすく、サンプルデータの分布に速くフィットするためである。学習されたモデルは、入

力された正のサンプルを非常によく再構成することができるが、検出段階では、モデルの入力が欠陥サンプルである場合、あまりうまく再構成することができない。

#### 4. 研究計画

今後の研究スケジュールは以下の通りである。

	8月	9月	10月	11月	12月	1月	2月
損失関数	■						
実装・調整	■	■	■	■			
評価			■				
論文執筆				■	■	■	
学外発表					■		■

表 1

#### 5. 進捗状況

現在 Python の基礎を学習し終わり、画像の前処理、および環境構築を進んでいる。

#### 6. おわりに

本研究では、教師なし木材欠陥検出モデルを形成するために、実木材データセットに基づく DCGAN にエンコーダコンポーネントを導入する。新しいモデルを適応させるために、オリジナルの DCGAN 敵対的損失目的関数を改良し、生成器が生成するデータがより現実的で明確になるようにするとともに、モデルの学習速度と安定性を速める予定である。このため、木材欠陥データセットにおける欠陥の種類の変りやデータサイズの小ささといった問題をある程度解決することができる。

#### 7. 参考文献

- [1] Hashim U R, Hashim S Z, Muda A K. Automated Vision Inspection of Timber Surface Defect: A Review[J]. Jurnal Teknologi, 2015, 77(20): 315-323.
- [2] Buehlmann U, Edward Thomas R. Impact of Human Error on Lumber Yield in Rough Mills[J]. Robotics and Computer-Integrated Manufacturing, 2002, 18(3-4): 197-

203.

[3] Thomas R E. Relationship between Lumber Yield and Board Marker Accuracy in Rip-First Rough Mills[J]. *Holzals Rohund Werkstoff*, 2007, 65(1): 43–48.

[4] Wang L, Qi W. Recognizing the Patterns of Wood Inner Defects Based on Wavelet Neural Networks[C]. 2007 IEEE International Conference on Automation and Logistics, Boston, MA, USA, 2007: 1719–1724.

[5] 牟洪波,王世伟,戚大伟,等.基于灰度共生矩阵和模糊 BP 神经网络的木材 缺陷识别[J]. *森林工程*, 2017, 33(04): 40-43+54.

[6] Mu H, Zhang M, Qi D, et al. Detection and Recognition of Wood Defects Based on Gray Transformation and BP Neural Network[J]. *International Journal of Agriculture Innovations & Research*, 2014, 2(6): 5-18.

[7] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[J]. *Advances in neural information processing systems*, 2014, 27.

[8] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks[J]. *arXiv preprint arXiv:1511.06434*, 2015.

[9] Schlegl T, Seeböck P, Waldstein S M, et al. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery[C]. *International conference on information processing in medical imaging*, FL, USA, 2017: 146-157.