

研究論文

ニューラルネットワークを利用した動物毛の種類判別

丹羽昭夫*1、安田(吉野)庄子*1

Discrimination of Animal Hair by Image Recognition Using Neural Network

Akio NIWA*1 and Shoko YASUDA-YOSHINO*1

Food Research Center*1

食品への動物毛(以下毛)の混入原因の追究を目的とし、毛の種類判別が可能なニューラルネットワークを構築した。ネットワーク LeNet を用いて未知の毛の種類判別を行った結果、デジタルマイクロスコープによる実体顕微鏡画像では全正答率約 40%であったが、同透過顕微鏡画像では約 65%とより良好だった。データ数増加による学習時間増加を考慮してデータセット画像の色調及びサイズを決定し、ネットワークの探索により LeNet より効率が良く、約 70%とより全正答率が高いネットワークを見出した。ネットワークの改良により実用的に毛の種類判別できる可能性が認められた。

1. はじめに

食の安全性・信頼性の確保において、食品中への異物混入の問題解決は重要である。食品製造現場で特に問題となるものに、原料、環境、作業由来の動物毛(以下毛)の混入があるが、その種類判別は熟練者でも苦慮することがある。毛は太さ、表面、内部構造などの観察、また毛根があれば DNA 鑑別でも判別できる。しかし異物として扱われる毛は通常完全な形で存在しない。表面構造の損傷や内部構造の観察困難、部位による太さの違いや個体差など様々な問題があり、それらにより判別が困難となる。

人工知能(Artificial Intelligence, AI)は、生産現場での検査作業など人間の作業を肩代わりするシステムに活用されてきた。中でも近年はニューラルネットワークが注目されている。ニューラルネットワークとは「入力-出力」の単位を神経細胞であるニューロンに見立て、これを積み重ねネットワーク状に接続することで出力結果を得る仕組みである。これを活用することにより将棋などで人間に勝利する、画像情報から瞬時に指定条件の部分を特定するなど有効な知的能力を実現している¹⁾。そこでニューラルネットワークを活用すれば、毛の画像情報から種類判別ができることが期待される。実現すれば当センターでの迅速な種類判別、さらには中小企業の現場での問題解決に寄与できると考えられる。

本研究では異なる 7 種類の毛を対象に、毛の種類判別が可能なニューラルネットワークの構築を目指した。

2. 実験方法

2.1 毛の画像の収集

2.1.1 毛試料の採取

試料として、ブタ、ヒト、イヌ、ネコ、ウシ(ホルスタイン種、以下ホルスタイン)、ウシ(黒毛和種、以下和牛)、ヤギの 7 種の毛を用いた。ブタはブラシに使用されたもの、ヒトは複数のセンター職員、イヌはトイプードル、ネコはイエネコから採取した。ホルスタイン及び和牛は農業総合試験場、ヤギは県内商業施設でそれぞれ飼育されている複数頭から採取した。

2.1.2 デジタルマイクロスコープを用いた画像収集

画像はデジタルマイクロスコープ VHX-2000 ((株)Keyence 製)を用いてピクセルサイズ 1200×1600 で撮影した。倍率は 500 倍と 1000 倍とし、焦点が合った状態で位置を変えて撮影する方法と、いくつかの同じ位置で焦点を変えて撮影する方法を用いた。1 本の毛について倍率と焦点の組み合わせ 4 通りでそれぞれ 35 枚程度、計 140 枚程度撮影した。撮影画像(以下原画像)から画像分割ソフト E-cutter²⁾を用いて右側の 1200×400 ピクセル分を除去した後、90° 右回転した画像(以下回転画像)を作成し、原画像に加えて約 280 枚とした。これを 7 種類の毛各 4 本について、実体顕微鏡及び透過顕微鏡の 2 モードで行った。

4 本の毛の画像のうち 1 本の画像を評価用データセットに、残り 3 本のを学習用データセットに使用した。

2.1.3 生物顕微鏡を用いた画像収集

生物顕微鏡 ECLIPSE 80i((株)ニコン製)を用いてピクセルサイズ 1024×1280、倍率は 100 倍または 200 倍で 2.1.2 と同様に撮影し、右側の 1024×256 ピクセル分を

*1 食品工業技術センター 保蔵包装技術室

除去した回転画像を加え、4本の毛の画像のうち1本の画像を評価用に、残りを学習用とした。

2.2 データセットの作成

ニューラルネットワークのフレームワークとして Neural Network Console Version 1.50(ソニーネットワークコミュニケーションズ(株)製、以下 NNC)を使用して以下の作業を行った。画像データを毛の種類ごとにサブフォルダに分類したフォルダを選択し、56×56ピクセルに縮小したRGB画像でデータセットを作成した。縦横比1:1の回転画像はそのまま縮小、原画像は長い横軸の両端を除去し、縦横比を1:1とした中央部分を縮小した(画像例を図1に示す)。




図1 データセット画像の例

表1 データセットに用いた画像数

画像種類	1組目		2組目	
	学習用	評価用	学習用	評価用
実体顕微鏡画像	6009	1972	6003	1978
透過顕微鏡画像	5880	1960	5880	1960
生物顕微鏡画像	5830	2026	5937	1919

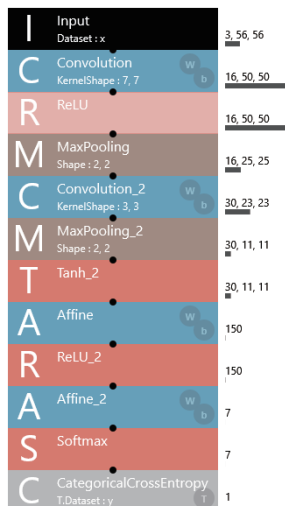


図2 LeNetのニューラルネットワーク構造

データセットは学習用、評価用それぞれ個別に作成した。評価用の毛を変えて2組のデータセットを作成し、それらを用いた学習及び判別結果の平均を求めた。データセットに用いた画像数は表1のとおりである。

2.3 ネットワークの設定

ニューラルネットワークには LeNet を使用し、RGB Color、56×56ピクセルに対応する次元数とサイズ、及び出力カテゴリ数の設定を NNC 上で行った(図2)。演算量を示す CostMultiplyAdd は Statistics に表示される数値を用いた。NNC での学習回数は100回とし、10回ごとに学習効果を示す Training Error、及び検証エラーを示す Validation Error により学習結果の評価を行った。同時に学習時間の計測を NNC 上で行った。

学習後に評価用データセットの画像の判別を行い、出力結果から全正答率を示す Accuracy、1つの項目に出力された判別結果の正答率を示す Precision、1つの種類の入力画像が正答に判別された率を示す Recall を求めた。

2.4 データセット画像の色調及びサイズの検討

デジタルマイクロスコープ画像を用いて 56×56ピクセル画像の gray scale への変更及び画像サイズの検討を行った。画像ピクセル数は原画像及び回転画像を 56×56の半分の 28×28、2倍の 112×112、4倍の 224×224としたものについて比較した。

2.5 ネットワークの改良

NNC はネットワークの自動探索が可能のため、透過顕微鏡画像のデータセットを用いて LeNet のネットワーク構造を出発点として NNC 上で自動探索を行い、Accuracy の上昇するネットワークを探した。

3. 実験結果及び考察

3.1 毛種類判別

3.1.1 デジタルマイクロスコープ画像による判別

実体顕微鏡画像と透過顕微鏡画像の学習結果及び Accuracy を表2に示す。実体顕微鏡画像では Training Error が十分低いにもかかわらず、Validation Error が非常に高く、Accuracy も低かった。これに対し透過顕微鏡画像では Validation Error、Accuracy 共に実体顕微鏡画像より良好だった。毛種類ごとの種類判別結果も図3に示した通り、ヤギの Recall を除いてすべて向上

表2 デジタルマイクロスコープ画像の学習結果及び Accuracy

顕微鏡	Training Error	Validation Error	Accuracy
実体顕微鏡	0.003	9.174	0.398
透過顕微鏡	0.001	2.470	0.650

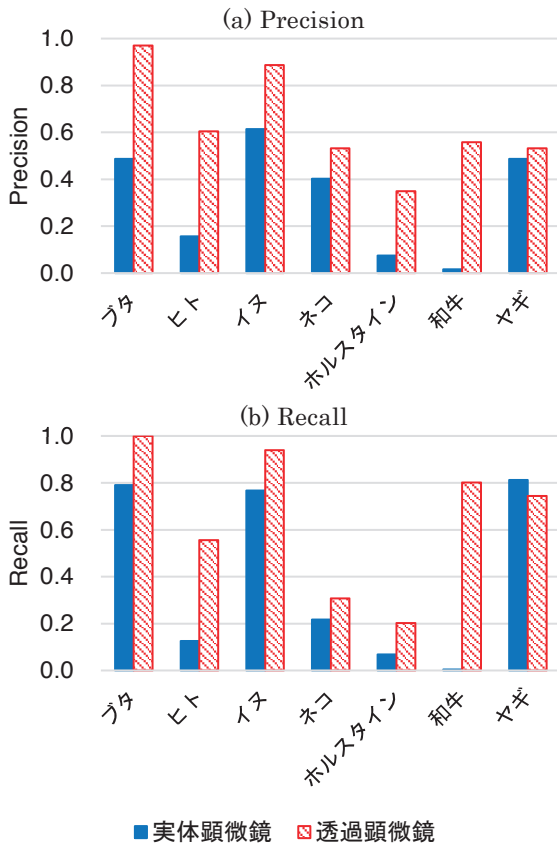


図3 デジタルマイクロスコープ画像の種類判別結果

していた。表面構造については実体顕微鏡画像の方が鮮明と考えられた(図 1)。これより、判別には表面構造などの細部よりも毛部分と背景で色の明度の差が大きいことが重要と考えられた。

3.1.2 生物顕微鏡画像による判別

生物顕微鏡は透過像を観察する点でデジタルマイクロスコープの透過顕微鏡と等価であると考えられた。しかし、生物顕微鏡による画像を用いて判別を行った結果、Validation Error が 5.436 と高く、Accuracy が 0.494 と透過顕微鏡画像と比べて低かった。これは画像撮影時の光学条件の違いが影響していると考えられ(図 1)、顕微鏡間のデータ統合のためには正答率が高くなる光学条件の検証が必要と考えられた。

3.2 データセット画像の色調及びサイズの検討

CostMultiplyAdd の低減のため、RGB Color の gray scale への変更を試みた結果を表 3 に示す。実体顕微鏡画像、透過顕微鏡画像いずれも gray scale では Accuracy が低くなった。

表3 RGB Color と gray scale の Accuracy 値比較

顕微鏡	RGB Color	gray scale
実体顕微鏡	0.398	0.379
透過顕微鏡	0.650	0.575

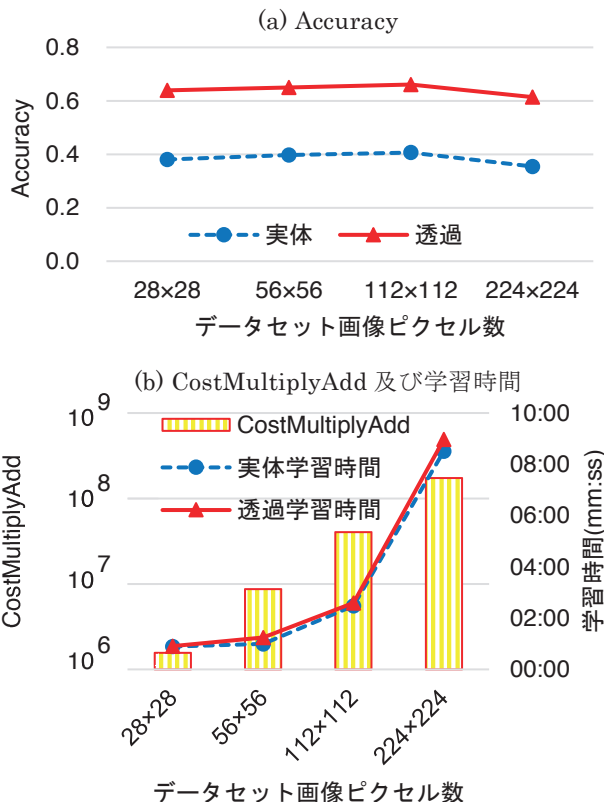


図4 画像ピクセル数の影響

画像ピクセル数を変えて検討した結果を図 4 に示す。Accuracy は実体及び透過顕微鏡画像のいずれも 28×28 は 56×56 より低く、112×112 で最高となり、224×224 ではむしろ低下した。ただし 56×56 と 112×112 の差は 0.01 程度とわずかだった。一方ピクセル数が増えるにつれ CostMultiplyAdd は指数的に増加し、学習時間も 28×28 と 56×56 では差が小さいが、112×112 では倍、224×224 では 56×56 の約 8 倍となった。

今後データ数が増えるほどこの差が大きくなると考えられたため、パラメータは当初の RGB Color、56×56 ピクセルとした。

3.3 ネットワークの改良

ネットワークの自動探索の結果、図 5 に示したネットワークが見つかった。これは表 4 に示す通り、CostMultiplyAdd 及び学習時間が LeNet より少なく、Accuracy も向上していた。

この改良ネットワークの種類判別結果を図 6 に示す。

表4 改良ネットワークの CostMultiplyAdd、学習時間及び Accuracy

ネットワーク	CostMultiplyAdd	学習時間 (mm:ss)	Accuracy
LeNet	8710830	1:15	0.650
改良ネットワーク	292708	0:38	0.716

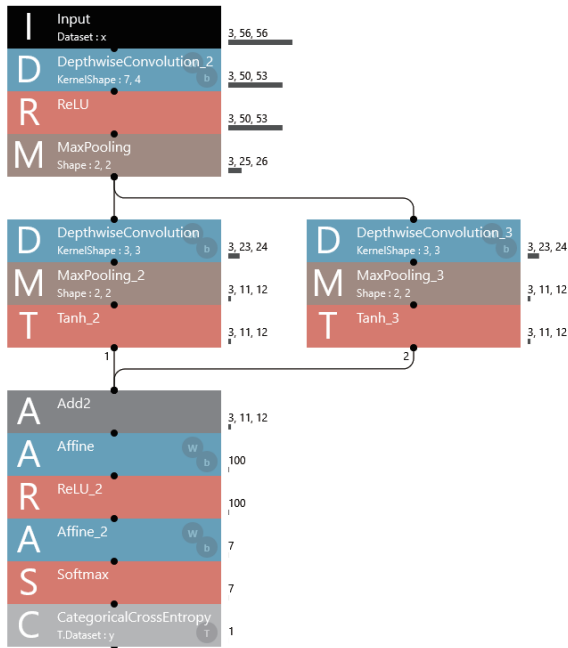


図5 改良ネットワークのニューラルネットワーク構造

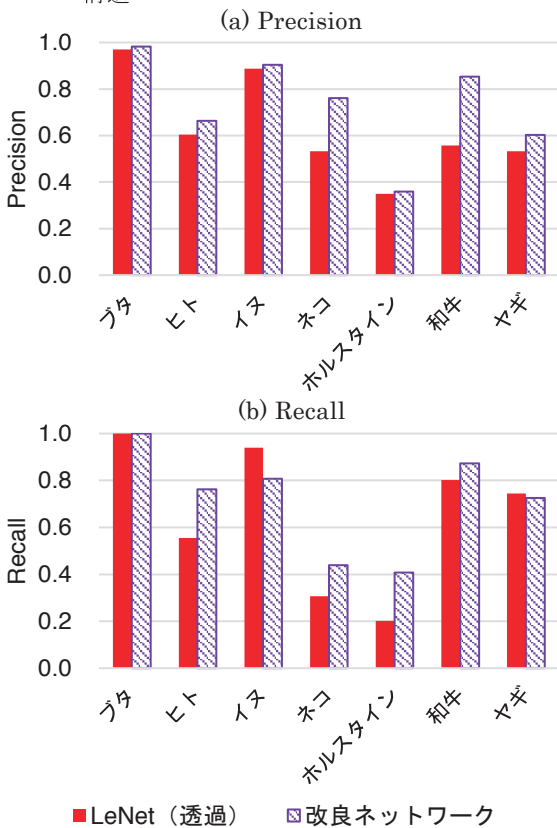


図6 改良ネットワークの種類判別結果

Precision はすべて向上、Recall も 5 種類の毛で向上した。特にネコと和牛の Precision、ヒト、ネコ、ホルスタインの Recall が上昇していた。これは表 5 に示す通

り、ネコに誤判別されるヒト画像数、和牛に誤判別されるヒト及びネコ画像数、ヤギに誤判別されるホルスタイン画像数が大幅に減少したためである。

表 5 LeNet と改良ネットワークの種類判別画像数

ネットワーク	判別結果			
	ヒト ネコ	ヒト 和牛	ネコ 和牛	ホルスタイン ヤギ
LeNet	143	104	229	342
改良ネットワーク	41	1	0	237

4. 結び

LeNetを用いて未知の毛の種類判別を行った結果、実体顕微鏡画像では全正答率約 40%だったが、透過顕微鏡画像では約 65%とより良好だった。学習時間を考慮して、データセット画像の色調及びサイズは RGB Color、56×56 ピクセルに決定した。ネットワーク探索で LeNet より効率が良く、約 70%とより全正答率が高いネットワークを見出した。

この種類判別ネットワークでは毛画像を適切に分類することで毛種類の追加、削除は容易であり、また毛以外の繊維などの画像を使用することも可能である。今回使用した画像データ数はまだまだ少なく、データ数増加やネットワークの改良により最低限求められる全正答率 80%に到達できるものと考えられた。画像データのさらなる蓄積及び正答率が高くなる光学条件の検証が今後の検討課題である。その手法としてデータセット画像は元画像から大幅に縮小されることから、画像数を増やす方法としてより低倍率で画像撮影し、画像を分割することで 1 撮影画像から複数の画像データを得る方法が考えられた。

謝辞

本研究の実施に当たって、牛 2 種の毛採取に協力いただいた農業総合試験場養牛研究室の大川智章室長（現畜産総合センター）に感謝します。また、毛試料の収集、NNC についてのアドバイスをくださった尾張繊維技術センターの市毛将司主任研究員に感謝します。

文献

- 柴田良一: はじめての「SonyNNC」, 8 (2019), 工学社
- のろぶさ: E-cutter, <https://www.vector.co.jp/soft/winnt/art/se508154.html>, (2021/8/11)