

〔論文〕

畳み込みニューラルネットワークによる久留米絣の模様ずれ分類

島添 稔^{*1}・新井 康平^{*2}・小田 まり子^{*2,3}・呉 濟元^{*2}

Pattern Shift Classification of Kurume Kasuri Using Convolutional Neural Network

Jin SHIMAZOE^{*1}, Kohei ARAI^{*2}, Mariko ODA^{*2,3} and Jewon OH^{*2}

Abstract

Kurume Kasuri is a traditional cotton fabric from the Chikugo region. The weaving process, which begins with the dyeing of cotton threads, produces a subtle shift in the fabric, resulting in a unique blurred pattern, which is an attractive feature of the Kurume Kasuri. If the pattern is too far off, it must be sold at a low price, and this is a concern as the evaluation criteria for pattern shift differ among dealers and weavers. Furthermore, it is extremely difficult to adjust for pattern shifts and to pass on the tacit knowledge of skilled weavers to younger weavers. In this study, we investigate the evaluation criteria of weavers using a questionnaire and construct a convolutional neural network (CNN)-based pattern shift classification model to verify whether the evaluation criteria of pattern shift can be unified. Furthermore, we examine the effect of the number of training samples on model training and the classification accuracy. As a result, it is possible to classify whether the pattern shift is good or bad using the CNN-based model, and it is difficult to unify the evaluation criteria, necessitating the construction of an appropriate model for each weaver. We also found that overfitting is suppressed as the number of training samples increases and that the effect on classification accuracy is negligible.

Key Words :Kurume Kasuri, Quality estimation, CNN, Image recognition, Data augmentation, AI

1. 緒 言

久留米絣は筑後地方に伝わる伝統的な綿織物であり、図案－括り－染色－織りという流れで、30 以上もの工程を経て完成に至る。糸をあらかじめ染色し、模様の入った糸で柄を合わせながら織る「先染め織り」により、微妙なずれが生じ、独特なかすれ模様となるのが大きな特徴であり、それが久留米絣の魅力である⁽¹⁾。

このずれ具合について、適度な模様ずれであれば良いが、あまりに大きくずれてしまうと売れなくなり、低価格で販売せざるを得なくなるという問題がある。また、その模様ずれの評価基準が販売店や織元ごとでも異なるという問題もある。他にも、久留米絣は機械で織るが、適度な模様ずれになるように調整するのは経験の浅い職人にとって非常に困難である。更に、熟練の職人は長年の経験と勘で操作をしているため、その暗黙知を伝えることも難しく、若手への技術の継承も完全ではない。

久留米絣に関する既往研究として、内山⁽²⁾は、ネットでのアンケート調査による久留米絣の需要構造分析を行っている。このような研究が行われている一方で、久留米絣の品質評価に関する研究は行われていない。また、模様の品質評価に関する既往研究として、森⁽³⁾は、カルマンフィルタを学習アルゴリズムとして用いたニューラルネットワークにより、レース模様の視覚評価モデルの構築を行っているが、畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) を用いた模様の品質評価は行われていない。

以上を踏まえて、我々は、これまでに、久留米絣の模様ずれを 1/f ゆらぎと捉え、模様ずれの良否 (品質) を評価する方法を提案している⁽⁴⁾。本研究では、CNN を用いて模様ずれ分類モデルを構築し、暗黙知を形式知として示すことで、模様ずれの評価基準の明確化や若手の育成に繋がるシステムの構築を目的とする。具体的には、久留米絣画像を用いて、主観評価により模様ずれを許容するものと、許容しないものとに分類し、これを望ましい出力として CNN で学習し、模様ずれ評価モデルを作成する。そこでまず、久留米絣の個々の模様に対する良否評価 (許容範囲か否か) を判断するために、スキャンした絣画像から模様を一つずつ切り出す画像処理を施し、抽出した各々の模様に対する、職人 (織元) の主観評価基準を把握するためのアンケートを実施する。CNN の学習には、入力画像データ及び正解データが必要であるが、入力画像データは抽出した個別の久留米絣模様 (パターン) とする。また、織元のアンケート回答結果から得られた評価基準を学習用教師データ (正解

^{*1} 電子情報システム工学専攻, ^{*2} AI 応用研究所

^{*3} 情報ネットワーク工学科

令和 4 年 12 月 12 日受理

データ)とする。これらの個別の久留米絣パターンと主観評価による正解データを用いて、CNNによる深層学習を行い、久留米絣画像の模様ずれを分類する画像認識モデルを構築する。そして、評価基準が販売店や織元ごとでも異なる久留米絣の品質を評価する一手法として本CNNモデルを用いた久留米絣模様の品質評価手法を提案する。第2章では、模様ずれ分類の事前準備として、アンケート及びCNNの学習に利用する久留米絣パターンの抽出と、模様に対する織元の主観評価基準を把握するためのアンケートについて述べる。第3章では、CNNを用いた模様ずれ評価モデルの作成に加えて、トレーニングサンプル数の違いがモデルの学習過程や模様ずれの分類精度に及ぼす影響について検証する。第4章では、結論と今後の課題について述べる。

2. 事前準備

2・1 画像処理による久留米絣パターン抽出

代表的な模様である矩形模様の久留米絣(下川織物)をスキャンして得られた画像(Fig.1(a))から、pythonで画像処理のライブラリであるOpenCVを用いて、模様部分をそれぞれ同じサイズで抽出した。この久留米絣は、模様ずれに対する許容範囲に関するアンケート調査の際は、この評価の公正性を担保するため、どこの織元の製品かについては明示しないことにした。手順は次の通りである。

- (1) 元画像をグレースケール化した後、大津の二値化⁶⁾による二値化処理を行う(Fig.1(b))
- (2) 輪郭を検出するために、色の反転処理を行う(OpenCVを用いて輪郭を検出する場合、背景が黒、検出対象が白でなければならないため)(Fig.1(c))
- (3) 輪郭の検出を行う(Fig.1(d))
- (4) 輪郭情報を基に外接矩形を求め、中心座標を求める(Fig.1(e))
- (5) 中心座標から上下左右に一定間隔で抽出範囲を指定する(Fig.1(f))

以上のような手順で、全ての模様を80×80で抽出した。

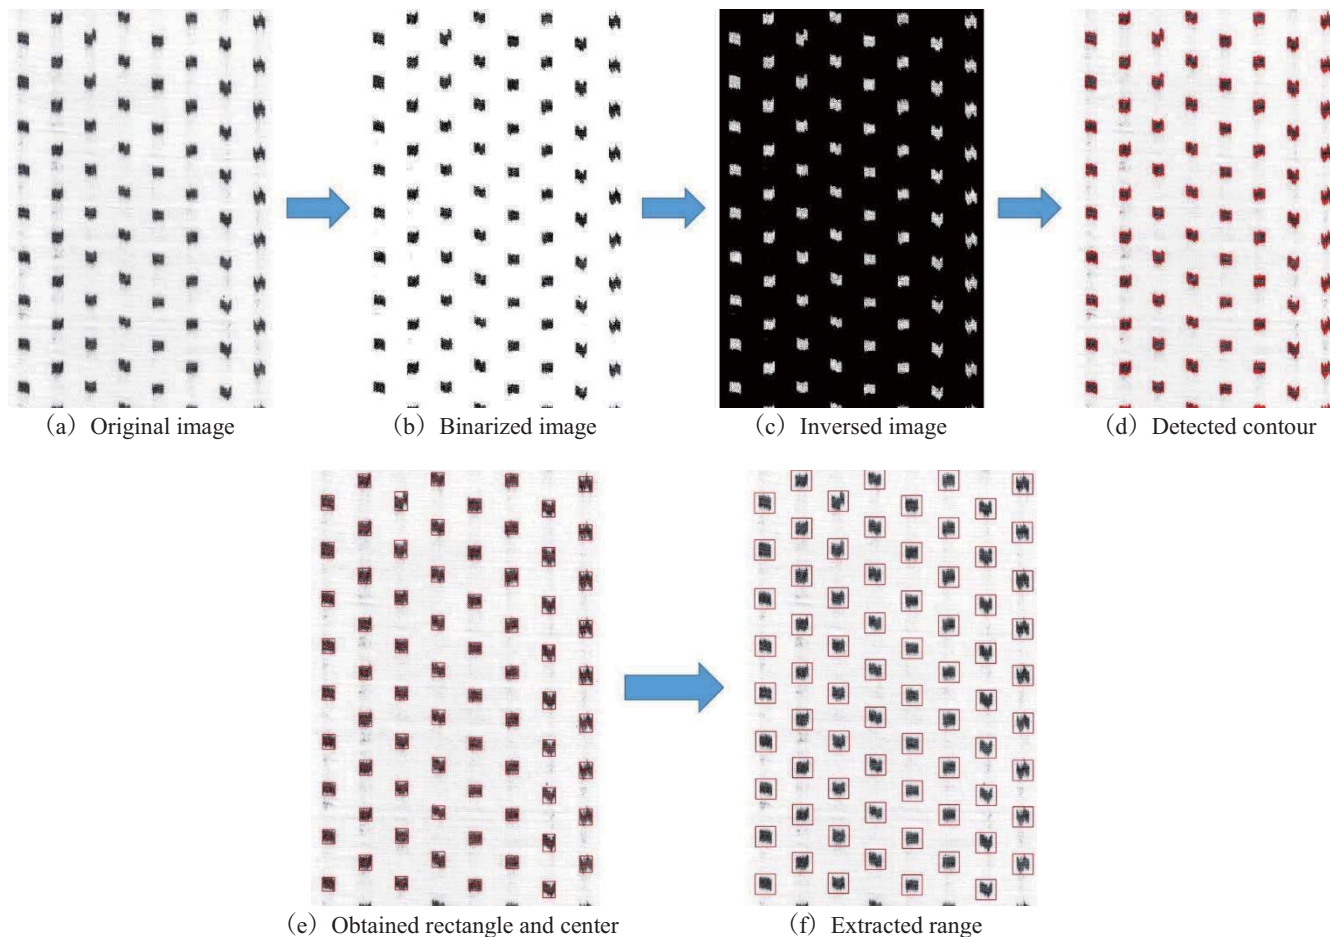



Fig.1 Procedure for extracting Kurume Kasuri pattern

2.2 アンケート実施

職人（織元）の模様ずれの評価基準を把握するためのアンケートを8社の織元計35名に対して実施し、2.1で抽出した模様70枚を良い・許容範囲内・許容範囲外の3段階で評価していただいた。アンケートの様式をFig.2に示す。

このアンケートの結果を基にして、「良い」を2点、「許容範囲内」を1点、「許容範囲外」を0点として、各模様の平均点や会社ごとの平均点を求めた。なお、CNNによる学習の際には、「良い」と「許容範囲内」を許容範囲内（good）と改め、それ以外を許容範囲外（bad）として正解データとした。織元全体（All）の平均点と、比較的回答者の多かった2社（久保かすり織物：Kubo, 下川織物：Shimogawa）の平均点をTable.1に示す。久保かすり織物は模様ずれの評価が全体よりもかなり厳しく、下川織物は全体よりも多少厳しめだが、久保かすり織物よりは緩めであることが分かる。

1. 下の柄のズレの程度を3段階で評価してください。*



良い

許容範囲内

許容範囲外

【許容範囲外】を選んだ方は、柄のどの部分（上部、中部、下部）のいずれのズレが許容範囲外とお考えですか？（複数回答も可）*

上部

中部

下部

（自由回答）よろしければ【許容範囲外】を選んだ理由について、簡単に教えてください。

回答を入力

Fig.2 Questionnaire to weavers (Orimoto)

Table.1 Questionnaire results

	The Number of evaluators	Average
All	35	0.733
Kubo	13	0.388
Shimogawa	7	0.799

3. 模様ずれの分類

模様ずれが許容範囲か否かを分類するために、python で深層学習のライブラリである Keras を利用して、主に画像認識の分野で用いられる CNN のモデルを構築した。CNN は、主に畳み込み層とプーリング層で構成されており、基本的にそれらを何度か繰り返した後、全結合層を通り、結果を出力するような構造となっている。畳み込み層では、入力された画像に対してフィルタ（カーネル）を適用し、畳み込み演算を行う。プーリング層は、一般的には畳み込み層の直後に利用され、畳み込まれた画像のダウンサンプリングを行う。CNN を用いた既存の画像認識モデルとして、1998 年に Yann LeCun が考案した初の畳み込みニューラルネットワークである LeNet や、Dropout や ReLU を採用し、データ拡張を行ったことにより、2012 年の ILSVRC でそれまでの記録を大幅に更新し優勝した Alex Krizhevsky らの AlexNet がある⁽⁶⁾⁽⁷⁾。

本研究において構築したモデルの構造を、Fig.3 に示す。過学習を抑えるために Dropout を採用し、畳み込み層における活性化関数には ReLU、出力層の活性化関数には Softmax を用いた。また、損失関数は交差エントロピー誤差（Categorical cross entropy）、最適化アルゴリズムは Adam を用い、学習率はデフォルトの 0.001 とした。




Fig.3 Structure of the built model

3・1 モデルの学習

モデルの学習データについて、2・1 で抽出した模様画像 70 枚を、2・2 のアンケートにより得られた 3 つの平均点（織元全体：All、久保かすり織物：Kubo、下川織物：Shimogawa）を基準とし、織元全体の評価による各模様の平均点を基にして、基準を上回る模様を good、下回る模様を bad として仕分けた。その後、トレーニングサンプル数の違いによる分類精度への影響を調べるために、3 つの基準それぞれで、以下の 4 つのデータセットを用意した。

- (1) 元画像の good, bad それぞれで、平均点の高い方から半分の画像
 - (2) 元画像のみ
 - (3) (2) に加え、元画像全てにごま塩ノイズ⁽⁸⁾を付加した画像 (Fig.4 (a))
 - (4) (2) に加え、元画像全てにアフィン変換 (15°のスキュー)⁽⁹⁾を加えた画像 (Fig.4 (b))
- (3) 及び (4) は、Data augmentation (学習データの画像に対して平行移動、拡大・縮小、回転、ノイズの付加などの処理を加えることで、データ数を人為的に増やすテクニック) は、学習性能を向上するために、学習データの数を増やす方法として施したものである。それぞれのデータの内訳を Table.2 に示す。Tra_good は good と bad に仕分けたデータの内の good の訓練データ、Tra_bad は bad の訓練データ、Test_good は good のテストデータ、Test_bad は bad のテストデータを表す。

また、全てのデータセット (3 つの基準×4 つのデータセット) での学習において、入力画像の形式は 80×80×3 (RGB)、エポック数を 40、バッチサイズを 16 とし、データの偏りによりモデルの性能を正しく評価できないことを防ぐために、層化 K 分割交差検証 (5 分割) を行った。通常の K 分割交差検証はデータを K 個に分割して、そのうちの一つを検証データ、残りの K-1 個を訓練データとして K 回の学習・検証を行うが、分割されたデータのクラスごとの数 (割合) が等しくならない場合がある。これに対して層化 K 分割交差検証は、クラスごとのデータの割合がほぼ等しくなるように分割することが可能である。層化 5 分割交差検証により得られた 5 つのモデルの学習過程の平均を Fig.5 に示す。ave_tra_loss は訓練誤

差, ave_val_loss は汎化誤差, ave_tra_acc は訓練データでの正解率, ave_val_acc は検証データでの正解率を表す. ave_tra_loss (訓練誤差) と ave_val_loss (汎化誤差) の様子から, トレーニングサンプル数が増加するほど, 概ね過学習が起こりづらくなっていることが分かる.






Fig.4 Data augmentation

Table.2 Details of the number of data (Tra_good: Training good, Tra_bad: Training bad)


	All				Kubo				Shimogawa			
	half	normal	noise	skew	half	normal	noise	skew	half	normal	noise	skew
Tra_good	14	29	58	87	21	44	88	132	13	28	56	84
Tra_bad	15	31	62	93	7	16	32	48	15	32	64	96
Test_good	3	5	10	15	3	5	10	15	3	5	10	15
Test_bad	3	5	10	15	3	5	10	15	3	5	10	15
Total	35	70	140	210	34	70	140	210	34	70	140	210




(a) Half



(b) Normal



(c) Normal + Noise



(d) Normal + Noise + Skew

Fig.5 Learning processes (ave_tra_loss: average training loss function, ave_val_loss: average validation loss function, ave_tra_acc: average training accuracy, ave_val_acc: average validation accuracy)

3.2 テストデータによるモデルの精度確認

層化5分割交差検証による学習で作成された5つのモデルにテストデータを入力し、それぞれのモデルの精度（正解率）を確認した。結果を Table.3 に示す。元画像の半分のデータセットで作成したモデルの平均正解率は、全体基準は 96.7%、久保かすり織物基準は 73.3%、下川織物基準は 80%であった。元画像のみのデータセットで作成したモデルの平均正解率は、全体基準は 78%、久保かすり織物基準は 88%、下川織物基準は 76%であった。元画像にごま塩ノイズを付加した画像のデータセットで作成したモデルの平均正解率は、全体基準は 78%、久保かすり織物基準は 88%、下川織物基準は 77%であった。元画像にスキューを加えた画像のデータセットで作成したモデルの平均正解率は、全体基準は 81.3%、久保かすり織物基準は 90%、下川織物基準は 76%であった。

トレーニングサンプル数と正解率の関係を表すグラフを Fig.6 に示す。基準ごと（織元全体：0.733、久保かすり織物：0.388、下川織物：0.799）の結果でみると、基準が高くなるにつれて、正解率が低くなっていることが分かる。この結果とアンケートの結果から、織元ごとに模様ずれの評価基準が異なるため、一つの基準で全ての織元の要件を満たすことは困難であり、織元ごとに適した模様ずれ分類モデルを構築する必要があると考える。また、データセットごとの結果でみると、3つの基準全てにおいて、元画像の半分のデータセット以外での正解率の変化はそれほど大きくないことが分かる。この結果から、トレーニングサンプル数による分類精度への影響はほとんどないと考えられる。なお、元画像の半分のデータセットでの学習結果において、全体、下川織物は他のデータセットよりも正解率が上がっており、久保かすり織物は下がっているのは、久保かすり織物のトレーニングサンプル数が good に対して bad が少なすぎることに伴い、学習がうまくいっていないためであると考えられる。

Table.3 Average accuracy to test data

	All	Kubo	Shimogawa
Half	96.67%	73.3%	80.0%
Normal	78%	88%	76%
Noise	78%	88%	77%
Skew	81.3%	90%	76%




Fig.6 Effect of number of training samples on learning performance

4. 結 語

本研究では、アンケート結果により得られた久留米絨の模様ずれの評価基準を基に、構築した CNN のモデルに用意した 4 つのデータセットそれぞれを学習させ、模様ずれ分類モデルを作成することで、全ての織元で共通利用が可能なモデルを構築できるか検証し、加えて、トレーニングサンプル数の違いが学習過程や分類精度へどのような影響を及ぼすか検証した。その結果、以下の結論が得られた。

1. CNN を用いることで、久留米絨の模様ずれの良否を分類することが可能である。
2. 一つのモデルで全ての織元に対応することは困難であるため、織元ごとに適したモデルを構築する必要がある。
3. トレーニングサンプル数が増加するほど過学習が抑えられることが分かった。また、これによる分類精度への影響はほとんどないことも分かった。

今後について、作成したモデルの精度は十分であるとはいえないため、モデルの構造の改良や、グリッドサーチによるハイパーパラメータの決定⁽¹⁰⁾等も試みたいと考えている。また、今回行った Data augmentation は、ごま塩ノイズとスキューのみであったため、回転や拡大・縮小、Mixup⁽¹¹⁾、GAN⁽¹²⁾による画像生成等、他の手法も検証する必要があると考える。他にも、今回検証に用いた模様は矩形模様のみであるため、水玉模様等の他の模様での検証も必要であると考えられる。

文 献

- (1) 中村健一, “久留米絨の歴史”, 繊維学会誌, Vol. 61, No. 6, pp. 152-156, 2005.
- (2) 内山敏典, “伝統工芸品久留米絨の需要構造分析”, エコノミクス 第 24 巻第 3・4 号, 2020.
- (3) 森俊夫, “ニューラルネットワークによるレース模様の視覚評価”, 日本家政学会誌, Vol. 51, No. 2, pp. 147-156, 2000.
- (4) Jin Shimazoe, Kohei Arai, Mariko Oda, Jewon Oh, “Method for 1/f Fluctuation Component Extraction from Images and Its Application to Improve Kurume Kasuri Quality Estimation”, International Journal of Advanced Computer Science and Applications, 13, 11, 465-471, 2022.
- (5) 大津の二値化, <https://ja.wikipedia.org/wiki/%E5%A4%A7%E6%B4%A5%E3%81%AE%E4%BA%8C%E5%80%A4%E5%8C%96%E6%B3%95> (参照: 2022.12)
- (6) LeCun, Yann, et al. “Gradient-based learning applied to document recognition.” Proceedings of the IEEE 86.11 (1998): 2278-2324.
- (7) Krizhevsky Alex, Ilya Sutskever, and Geoffrey E. Hinton, “Imagenet classification with deep convolutional neural networks”, NIPS, 2012.
- (8) ごま塩ノイズ: Image Analyzer, <https://www.altech-ads.com/products/Image-Analyzer/> (参照: 2022.12)
- (9) アフィン変換: OpenCV, <https://note.nkmk.me/python-opencv-warp-affine-perspective/> (参照: 2022.12)
- (10) ハイパーパラメータとモデルチューニング, <https://di-acc2.com/analytics/ai/8377/> (参照: 2022.12)
- (11) Zhang, Hongyi, et al. “mixup: Beyond empirical risk minimization.” arXiv preprint arXiv:1710.09412, 2017.
- (12) Ian J. Goodfellow, et al. “Generative Adversarial Nets”, NIPS, 2014.