

画像解析によるしわ外観の評価

森 俊夫, 河合陽子
家政学部家政学科家政学専攻
(2002年9月12日受理)

Evaluation of Wrinkled Appearance Using Image Analysis

Department of Home Economics, Faculty of Home Economics,
Gifu Women's University, 80 Taromaru, Gifu City, Japan (〒501 - 2592)

MORI Toshio and KAWAI Yoko

(Received September 12, 2002)

1. 緒言

しわや折れ目は、消費者やアパレルメーカーにとって重要な関心事であり、取り除くことのできないしわのために外観を損なうことが多い。しわはどのような衣服でも着用すればつくものであり、程度によってはひどい苦情にもなる。したがって、しわ外観は衣服の着用性能であるイージーケア性や審美性と関係して重要な性能といえる。

しわ試験方法はJISにも多く採用されているが、一般に適用する判断基準がないのが現状であり、しわの評価は洗濯やドライクリーニング工業の研究者や布の外観保持性を研究する人びとにとっては、長い間重要な問題であった。これまでのしわを評価する方法では、熟練者が布の中についたしわと標準レプリカとを比較して目視により等級1から等級5までのランク付けを行なっている¹⁾。しかしながら、これらの評価は主観的であり、しばしば知覚が偏って感じられることがある。衣服素材が多様化するにつれて、衣服のしわなどの外観を適切に評価するための客観的で定量的な方法の確立が望まれる。

西松ら²⁾は紳士ズボン毛織物を試料とし、製品生産の最終工程で行なわれている専門家によるズボンしわの目視等級判定を、画像処理手法であるテクスチャ解析を用いて非破壊・非接触で客観的に行なう手法を提案している。そして専門家が目視で判定したズボンしわの等級結果と提案した解析手法を用いて予測した等級との対応関係を比較し、提案手法の妥当性を検討している。しかしながら、彼らの方法では、256階調で取り込まれたしわのグレイレベル画像が簡単化のために16階調に変換されるために、オリジナルなしわ情報が失われてしまうので問題がある。

しわ外観にはしわの大きさ、形態、密度、シャープニス、ランダムニス、不規則性、凹凸性、複雑性、コントラストなどの知覚的特徴が多数含まれている。これらは分離して単独で評価することが難しいと考えられる。本研究では紙にランダムなしわを付加させた試料を作成し、これらのしわレベルの異なる紙じわ外観について、画像解析により求めたテクスチャ特徴量などを入力値としてニューラルネットワークによるしわ外観の評価を試みた。

2. 方法

1) 試料

試料布として PPC 用紙を用い、手の加圧により、15種類のしわ外観やしわ強度の異なるランダムじわを作成した。

2) 画像の取り込み

作成したしわを解析するため、カラスキャンナ EpsonGT9500を用いてそれらの画像を取り込んだ。いずれの場合も画像領域512×512ピクセル、解像度72dpiの条件で撮像が行われた。カラー画像はRGBの光の3原色で構成されているので、色情報は各画像位置ごとに3色分解してRGBのそれぞれの画像の色濃度を256階調の濃度レベルにデジタル化して二次元配列として保存された。また、カラー画像は(1)式にしたがってグレイレベル画像に変換することができる。

$$L = 0.177R + 0.813G + 0.011B \quad (1)$$

ここで、LはRGB値が(R, G, B)である画素のグレイレベルである。このようにして変換されたグレイレベル画像も同様に0(黒)~255(白)の濃度レベルにデジタル化して保存された³⁾。

3) テクスチャ特徴量の抽出

画像の局所的性質を調べる統計的手段として画像内の一定の位置関係にある2点があるグレイレベルを有する確率をすべての組み合わせについて求める方法がある。この方法では画像内のグレイレベル*i*の点から一定変位 $\delta = (d, \theta)$ だけ離れた点のグレイレベルが*j*である確率 $P(i, j) \chi_{i, j = 0, 1, 2, \dots, n-1}$ を要素とする同時生起行列 $M(d, \theta)$ を求める。ここで d と θ は2つの画素間の距離と位置角度である。また、 $P(i, j)$ は正規化され、0から1の間の値をとり、その総和は1となる。ここでは $d = 1$ の場合のみについて、 $\theta = 0^\circ$ (水平方向), 45° (右対角線方向), 90° (垂直

方向)および 135° (左対角線方向)の同時生起行列を求め、各行列からテクスチャを特徴づけるパラメータのうち、よく利用される次の4つのパラメータを使用した⁴⁾。

(i) 角二次モーメント (ASM)

$$ASM = \sum \sum \{P(i, j)\}^2 \quad (2)$$

(ii) コントラスト (CON)

$$CON = \sum \sum (i - j)^2 P(i, j) \quad (3)$$

(iii) 相関 (COR)

$$COR = \{ \sum \sum i \cdot j P(i, j) \mu_x \mu_y \} / \sigma_x \sigma_y \quad (4)$$

$$\mu_x = \sum i \cdot P_x(i), \quad \mu_y = \sum j \cdot P_y(j),$$

$$\sigma_x^2 = \sum i^2 P_x(i) - \mu_x^2,$$

$$\sigma_y^2 = \sum j^2 P_y(j) - \mu_y^2,$$

$$P_x(i) = \sum P(i, j),$$

$$P_y(j) = \sum P(i, j),$$

(iv) エントロピー (ENT)

$$ENT = - \sum \sum P(i, j) \cdot \log \{P(i, j)\} \quad (5)$$

4) フラクタル解析

フラクタル図形の代表の一つであるコッホ曲線はいくら小さな部分でもそこを適当な大きさに拡大すれば元と同じ図形が得られる。このような性質はコッホ曲線だけに限られる訳ではなく、例えば海岸線にも似たような性質がみられる。しかしながら、海岸線の場合にはコッホ曲線のように部分と全体が完全に自己相似しているのではなく、どんどん拡大していくと同じような複雑さをもった形があらわれ、巨視的にみても微視的にみてもその複雑さにあまり変わりはない。フラクタル図形の自己相似性は通常の図形や自然の形態に対しては厳しすぎる条件であるので、厳密に形が自己相似していなくても構造の中に構造が見いだされるような広義の意味においてあるいは統計的に自己相似性が成り立つフラクタル次元を考える必要がある。ここで特に注目する必要があるのはコッホ曲線のような線形自己相似性とは異なる非線形の模様やテクスチャへのフラクタル解析の応用であ

る。自然界の多くのものは確率過程により生成されるし、非線形のフラクタルである。海岸線や山の形などは確率過程から生まれるランダムフラクタルとしてよく知られている⁴⁾。

フラクショナルブラウン運動を拡張して三次元空間におけるフラクタル曲面モデルから、自然界の中の様々な形やテクスチャをフラクタルを用いてうまく表現出来るが、このフラクタル次元は一般的なテクスチャの特徴量として利用することは難しい。その後いくつかの改良が試みられているが、本研究では画像のグレイレベル曲面の起伏を粗視化の度合いを変える方法を用いてフラクタル次元を計算する⁴⁾。

画像のグレイレベル曲面を1辺の画素間隔がr画素の立方体で被覆するときに必要な個数を $N(r)$ とするとグレイレベル曲面にフラクタル性があれば、 $N(r)$ とrの間に(6)式の関係が成立する。

$$N(r) = kr^D \quad (6)$$

両辺の対数をとると(7)式が得られる。

$$\log N(r) = D \log r + \log k \quad (7)$$

ここで、kは定数である。

本研究では中山ら⁵⁾によって改良された粗視化の度合いを変える方法に従い以下のようにしてフラクタル次元を計算する。画素間隔が r_{xi} 画素の領域を単位領域として考える。単位領域のグレイレベル曲面を被覆する1辺の画素間隔rの立方体の個数 $n(r)$ は(8)式で表される。

$$n(r) = \text{floor}\{[\max(L_i) - \min(L_i)]/r\} + 1 \quad (8)$$

(1 ≤ i ≤ 4 : iは整数)

ただし、floorは整数比(切り捨て)とする。次に、フラクタル次元を求めるブロック領域内のすべての単位領域で $n(r)$ を求め、その平均値が $\bar{n}(r)$ であるとき、

$$N(r) = \bar{n}(r) \cdot S / r^2 \quad (9)$$

をブロック領域のグレイレベル曲面を被覆する立方体の個数とする。各スケールrにおける $N(r)$ を求め、式(7)より $\log r$ と $\log N(r)$ とをプロットして回帰直線を最小二乗法により計算し、その傾きをフラクタル次元とする。

5) 一次統計量

濃度ヒストグラムから明度平均 AVE (10) 式を計算した。

$$AVE = \sum iR(i) \quad (10)$$

6) 官能評価

15種類の異なったしわレベルをもつ紙じわの「しわ外観」について評定尺度法による官能評価を行った。評価者は女子学生9名である。評価は評価者個々の視覚的認識に基づいて複雑なもの、単純なもの、どちらでもないものとまず3つのグループに分類させ、次に複雑なグループからさらに複雑なもの、単純なグループからさらに単純なものに分けさせた。非常に複雑なものを評価値5とし、5段階評価を行った。評価は北窓の自然光の入る部屋において25x25cmの大きさの試料を黒布の上に置いた状態で行い、真上から約50~60cm離れた位置から観察させた。

3. 結果と考察

ASM, CON, COR および ENT はそれぞれ画素対の相対位置関係(d,θ)の関数である。ここではd=1に対してθ=0°,45°,90°,135°の方向の値を求め、4方向の平均値をd=1に対するテクスチャ特徴量とした。表1と表2には紙じわ外観についてそれぞれ144dpiと80dpiにおけるテクスチャ特徴量をまとめた。また、表には明度平均(AVE)および官能検査から求めたしわのグレード(SV)を掲げた。表の各パラメータを縦軸に、官能検査から求めたしわ外観の平均評価値(しわ外

表1 テクスチャ特徴量 (144dpi)

試料	SV	ASM	CON	COR	ENT	AVE	D
1	4.2	5.61	5.98	0.966	4.27	238	2.14
2	2.8	11.1	2.02	0.974	3.92	241	2.06
3	2.9	11.1	1.86	0.977	3.92	242	2.06
4	5.0	2.95	17.9	0.952	4.63	225	2.15
5	1.7	55.2	0.9	0.901	2.74	251	2.01
6	3.9	7.47	3.88	0.971	4.13	241	2.11
7	1.8	46.1	0.92	0.925	2.91	251	2.01
8	1.0	88.9	0.88	0.735	2.27	252	2.01
9	4.9	3.31	13.6	0.959	4.58	228	2.14
10	1.8	26.9	1.13	0.946	3.21	249	2.02
11	4.0	7.66	4.51	0.97	4.15	242	2.12
12	1.2	55.3	0.98	0.839	2.59	251	2.01
13	2.9	13.7	1.68	0.973	3.78	244	2.05
14	1.0	68.6	0.88	0.809	2.48	251	2.01
15	5.0	2.36	19.8	0.95	4.68	222	2.16

表2 テクスチャ特徴量 (80dpi)

試料	SV	ASM	CON	COR	ENT	AVE	D
1	4.2	5.31	7.53	0.962	4.3	237	2.22
2	2.8	8.05	3.63	0.955	3.92	241	2.12
3	2.9	7.41	3.9	0.958	3.97	243	2.13
4	5.0	1.82	43.6	0.895	4.67	227	2.21
5	1.7	37.7	1.48	0.842	2.78	252	2.04
6	3.9	5.02	9.23	0.934	4.15	241	2.19
7	1.8	25.9	1.65	0.899	3.07	250	2.05
8	1.0	50.3	1.53	0.709	2.47	252	2.03
9	4.9	2.12	32.2	0.905	4.59	228	2.21
10	1.8	17.8	2.2	0.925	3.36	248	2.08
11	4.0	4.72	12.3	0.926	4.18	242	2.23
12	1.2	43.6	1.45	0.781	2.6	252	2.03
13	2.9	9.01	4.13	0.942	3.81	244	2.14
14	1.0	35.8	1.55	0.795	2.7	251	2.04
15	5.0	1.37	51.8	0.878	4.71	221	2.26

観レベル, SV) を横軸にして, 図1には144dpiの場合の結果を示した。80dpiの場合も144dpiの場合と同様の結果を示した。図からASMとAVEはSVの増加と共に曲線的に減少し, CONは反対に曲線的に増加することがわかる。CORはSVが増すと最初は増加するが, その後はほぼ一定値を示す。ENTとDはSVの増加と共に直線的に増加し, し

わ外観の複雑さを評価するのに良いパラメータとなることが分かる。

ニューラルネットの学習には教師データが必要である。一般に教師データが良ければ学習したニューラルネットの能力も良くなる。良い教師データとは可能な限り起こり得るあらゆる場合を教師データが含んでいることである。ASM, CON, COR, ENT, D および AVE はそれぞれテクスチャの一様性, 局所的变化, 線状性, 情報量, 複雑性および明るさと関係するパラメータと考えられているので, これらのパラメータはしわ外観の複雑さを評価するのに良い教師データ用のパラメータとなる⁶⁾。ニューラルネットワークの学習に用いる教師データはシステムの応答特性の情報をできる限り多くもつことが望まれる。そこで, 入力層の各ユニットにはAVE, ASM, CON, COR, ENT および D に関する教師データを, 出力層の各ユニットにはSVに関する教師データを入力して, カルマンフィルタをアルゴリズムとするニューラルネットワークによる学習を行った。教師データとして用いたのは任意に選んだ No. 3, 4, 8, 10, 11, 13, 14, 15の8種類の試料データである。学習回数とニューラルネットワークの学習過程での教師データと計算値の誤差の2乗和 (SSE) の関係を調べるために, 中間層ユニット数が学習精度に影響を及ぼすことから, 今回は中間層ユニット数2, 4, 6, 7のものを試した。一般にニューラルネットワークにおいて, 2乗誤差の値が, 最も小さくなる中間層ユニット数が用いられる。しかし, ニューラルネットワークを応用する観点からは, 教師データの学習精度に加えて未学習のデータに対する精度, すなわち, 汎化誤差が重要になる。ネットワークの自由度が低い間は自由度を増すにつれて教師用データ, 未学習用データともに誤差が減少するが, あるところから

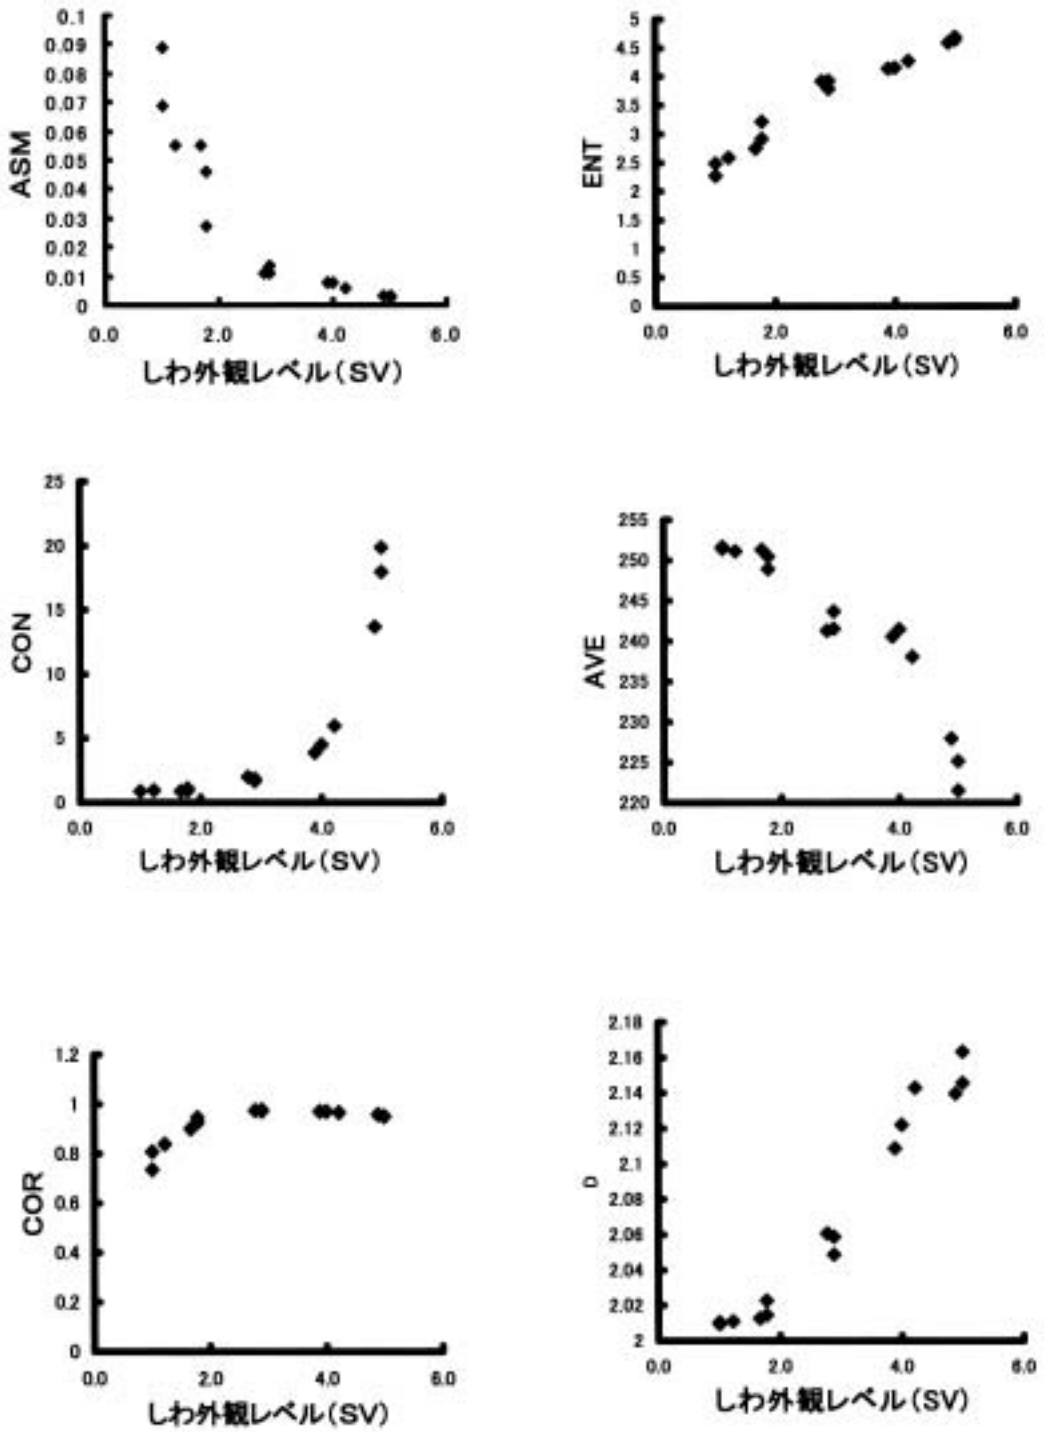


図1 テクスチャ特徴量としわ外観レベルの関係

は自由度を大きくしても汎化誤差が減少しなかったり、むしろ増加するようになる。本研究ではユニット数が7を超えると未学習の入力データに対して妥当な出力が生成しにくくなることから、中間層ユニット数を6とし、学習回数400回の場合の学習結果を同定用視覚評価モデルとして用いることにする。

学習後のニューラルネットの動作を検討するため、入力層にはニューラルネットワークの学習に用いたときと同じ試料8種類の教師データを同定用視覚評価モデルに与えて出力値を計算した。同定モデルにより計算された視覚評価値(CV)と官能評価値(SV)の相関係数は1.000と非常に高く、各ユニットの学習結果が非常に良好でほとんど正解に近い出力を与えることがわかった。

同定用視覚評価モデルの有効性を調べるために、教師データ以外の未学習のデータを入力した場合の視覚評価値(CV)を求めた。SV

とCVの関係を図2(144dpi)と図3(80dpi)にそれぞれ示した。図から、ニューラルネットによる視覚評価が非常に良好に行われたことが確認できる。

4. 結論

しわ外観の視覚的評価に適すると思われる画像情報量 AVE,ASM,CON,COR,ENT および D に関する教師データを入力層の各ユニットに、出力層の各ユニットには官能評価から求めた SV に関する教師データを入力して、ニューラルネットワークによる学習を行った。学習回数とニューラルネットワークの各学習過程での教師データと計算値の誤差の2乗和 (SSE) の関係を調べた結果、中間層ユニット数が7を超えると未学習の入力データに対して妥当な出力が生成しにくくなるので、中間層ユニット数を6とし、学習回数400回の場合の学習結果を同定用視覚評価モデルとして用いることにした。このモデルを用いて、未学習用試料について視覚評価を行なったところ、十分精度よく評価することができた。

文献

- 1) B.Xu and J.A. Reed.J.T ext. Inst. 87, 203 209 (1996)
- 2) 西松豊典, 鳥羽栄治, 太田健一: 織学誌, 56, 348 353 (200)
- 3) 森俊夫, 脇田登美司, 遠藤善道: 織学誌, 55, 424 431 (1999)
- 4) 森俊夫, 山田純子, 岩佐美代子: 家政誌, 49, 655 661 (1998)
- 5) 中山寛, 曾根光男, 高木幹雄: 情報学論, 30, 91 100 (1989)




図2 CVとSVの関係(144dpi)




図3 CVとSVの関係(80dpi)