モノクロ画像のカラー化に関する基礎的研究

A Method for Transferring Color to Grayscale Images

学生会員 小林 洋平[†], 正会員 白山 晋^{††}Yohei Kobayashi[†] and Susumu Shirayama^{††}

Abstract Adding color to a grayscale image is important in various fields. However, much trial and error is needed to obtain the appropriate colorized result since no standard method exists for this procedure. We propose a method to colorize grayscale images using a neural network. The relation between brightness and color in a reference color image was studied using the neural network. The grayscale image was then colorized through the network. For images consisting complicated scene components, multiple neural networks among the *swatches* proposed by Reinhard et al. were utilized. We show the superiority of our approach over the conventional methods by demonstrating several examples.

キーワード: Grayscale image, Colorization, Neural network

1. ま え が き

現在では、カラー画像が一般的でありモノクロ画像が使われることは少ない。しかしながら、カラーフィルムが本格的に普及したのは、1970年代以降からで、多くのモノクロ画像（写真、映像）が蓄積されている。また、撮影機器やデータ転送量の制限から、医療分野でのレントゲン写真やMRIやCTなど、また衛星画像や定点観測画像、赤外線写真など、モノクロ画像が用いられる分野は現在でも少なくない。これらのモノクロ画像においては、識別能力の向上のためにカラー化というニーズが存在し、映像産業を中心にモノクロ画像のカラー化が試みられている¹⁾。

モノクロ画像のカラー化は、一成分の画素に多次元成分の値を与えることになるので、本質的に正しい解は存在しない。このため、人為的な処理が必要とされる。例えば、図1(a)に示す画像をカラー化するには、Photoshop²⁾などのアプリケーションソフトウェアによって用意されたカラーパレット等を利用して、花びらにふさわしい色を選択して色付け（図1(b)）、次に葉にふさわしい色を選択して色付け（図1(d)）という工程によって全体をカラー化する。このような処理法、処理手順には作業者の経験や勘に依存す

図1 手作業によるカラー化の例.
Example of colorization by hand.

る部分が多く、さらには企業のノウハウのような形で扱われる部分も少なくない。具体的な手法が公表されることはほとんどなく、方法論が定まっていないのが現状である。

近年、Welshらは、カラー画像である参照画像と、モノクロ画像である目標画像の二つの画像を用いて、参照画像から目標画像に色を移行するという手法を提案した³⁾。この手法はユーザの手作業を減らし、簡便なカラー化を行うという意味において画期的なものである。しかしながら、彼らの手法にも物体のエッジ部分などでノイズのように色が混在する、あるいは表現できる色数が少ないなどの問題がある。

本研究の目的は、モノクロ画像のカラー化において、手

2003 年映像情報メディア学会年次大会で発表

2004 年 4 月 30 日 受付, 2005 年 1 月 7 日 最終受付, 2005 年 2 月 10 日 採録

[†] 東京大学大学院工学系研究科

(〒153-8904 目黒区駒場 4-6-1, TEL 03-5452-5185)

^{††} 東京大学人工物工学研究センター

(〒277-8568 柏市柏の葉 5-1-5, TEL 04-7136-4263)

[†] School of Engineering, University of Tokyo

(4-6-1 Komaba, Meguro-ku, Tokyo 153-8904, Japan)

^{††} RACE, University of Tokyo

(5-1-5 Kashiwanoha, Kashiwa-shi, Chiba 277-8568, Japan)

作業が少なく、高品質のカラー画像を得る方法を提案し、カラー化システムを構築することである。ニューラルネットを用いて、参照カラー画像の輝度と色情報との関係を学習し、学習した結果をもとに目標画像のカラー化を行うという戦略にもとづいてカラー化システムを構築する。

2. 提案手法

2.1 ニューラルネットによる学習

モノクロ画像中の被写体を正確に認識できれば、各々に対して適切なカラー化が可能になることが多い。図1で示した手作業によるカラー化は、そのような方法によって行われている。最新のパターン認識技術を用いたとしても、画像中の物体等を正確に識別することは難しいが、この原理が利用できれば、カラー化における手作業の部分を減ずることができるはずである。Welshらの手法³⁾は、参照カラー画像中の画素の輝度と近傍画素の輝度の統計量に対して、色情報との関数関係を定め、モノクロ画像の画素の輝度値と統計量を入力として、色情報を与えるものである。論文に明示されているわけではないが、彼らの方法を分析すると、その指導原理は局所的なパターンを認識し、参照カラー画像とモノクロ画像の類似する部分に対して、色を移行するものになっていると考えられる。すなわち、上述したパターン認識の原理を応用したものに分類できる。

彼らの方法の問題点は、複数の類似するパターンがある場合においては、いずれか一つのものを用いることになるために、モノクロ画像側で輝度分布の複雑な領域があると色飛びが起こり、ノイズのように色が混在してしまうことである。また、色付け可能な最大色数が、参照カラー画像から抽出された色の数となるために、自然な階調を表現できないという問題もある。本研究では、ニューラルネットワークの導入によってこれらの問題の解決を試みる。

はじめに、参照カラー画像とモノクロ画像を用意する(図2)。モノクロ画像は輝度値によって構成されるものとする。参照カラー画像が原色信号RGB形式の場合は、式(1)によってYUV形式に変換する。本稿では、Y,U,V,R,G,Bを輝度信号(Y)、色差信号(U,V)、原色信号(R,G,B)の表記とし、それぞれの値を0から1の実数をとる変数 y,u,v,r,g,b で示す。

$$\begin{aligned} y &= 0.299r + 0.587g + 0.114b \\ u &= -0.168r - 0.332g + 0.500b + 0.5 \\ v &= 0.500r - 0.419g - 0.081b + 0.5 \end{aligned} \quad (1)$$

次に参照カラー画像からいくつかの画素を抽出する。等しい画素数毎に抽出した例を図3に示す。図中の◎で示した中心から画像成分を抽出する。画素の抽出後、図4に示すように抽出された画素とその近傍に着目し、輝度値と色差信号値の関係をニューラルネットワークによって学習する。ニューラルネットワークの構造としては、階層型ネッ

図2 参照カラー画像(左)と目標画像(右)の例
Example of a reference color image (left figure) and a grayscale image to be colorized (right figure).

図3 均等抽出の例
Extraction of image components from equally distributed sampling points.

図4 抽出画素と近傍画素 ($L=2, M=2$)
A pixel extracted by sampling and its 24 neighbor pixels ($L=2, M=2$).

トワークを用い、入力層には画素の輝度、およびその近傍の画素の輝度の平均、標準偏差の三つの入力データを用いることにする。抽出した画素 p の輝度を y_p 、近傍の平均を $\bar{y}_p$ 、近傍の標準偏差を σ_p とすると、

$$\begin{aligned} y_p &= y_{0,0} \\ \bar{y}_p &= \sum_{l=-L, m=-M}^{L, M} y_{l,m} \\ \sigma_p &= \sqrt{\frac{\sum_{l=-L, m=-M}^{L, M} (y_{l,m} - \bar{y}_p)^2}{N}} \end{aligned} \quad (2)$$

となる。中間層のニューロン数は入力層と同じ数にする。出力層は u と v を出力するものとする。学習は誤差逆伝播学習法を用いる⁵⁾。この学習法では、ニューロン数を入力デー

図 5 ニューラルネットワークの例
A part of the neural network.

タの数+1個とし、その一つに1を与える。図5にニューラルネットワークの一部を示す。また、誤差逆学習伝播法の概要を以下に示す。

Step1. 学習用に参照カラー画像から入力データ、教師データを用意する。

Step2. 入力層、中間層、出力層の順番に各ニューロンの出力を計算する。

Step3. 教師信号と実際の出力の2乗誤差を計算する。

Step4. 自乗誤差が減少するように、出力層から入力層に向かって各層間の重みを修正する。

Step5. すべての入力データに対する2乗誤差が設定値以下になれば学習を終了する。そうでなければStep2に戻る。

具体的な手順は次の通りである。はじめに教師信号として参照カラー画像から P 個の画素を抽出する。 P 個の画素の輝度、近傍の平均、近傍の標準偏差を入力データとする。入力層の画素 p に対する入力信号は、

$$i_{p,1}^1 = 1.0, i_{p,2}^1 = y_p, i_{p,3}^1 = \bar{y}_p, i_{p,4}^1 = \sigma_p \quad (3)$$

となる。また、出力層の出力値は u, v なので、画素 p を提示したときの出力層 m のニューロン i の教師信号 $t_{p,i}^m$ は、

$$t_{p,1}^m = u_p, t_{p,2}^m = v_p \quad (4)$$

となる。

次に、ニューロンの出力を計算する。画素 p を提示したときの第 k 層 ($k = 2, \dots, m$) の各ニューロンの出力関係は次式のようにになる。

$$o_{p,j}^k = f_j^k(i_{p,j}^k) \quad (5)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

$$i_{p,j}^k = \sum_{i=1}^{n_{k-1}+1} w_{i,k}^{k-1,k} o_{p,i}^{k-1} \quad (7)$$

ここで、 $o_{p,j}^k$ は画素 p を提示したときの第 k 層の j 番目のニューロンの出力値、 $i_{p,j}^k$ は、画素 p を提示したときの第 k 層の j 番目のニューロンの入力値、 f_j^k は、第 k 層の j 番目のニューロンの入出力関数である。また、 n_k は、第 k 層のニューロン数である。各ニューロンについて、出力を計算をして、出力層の出力 $o_{p,1}^m$ 、及び $o_{p,2}^m$ を求める。

画素 p を提示したときの教師信号 $t_{p,1}^m, t_{p,2}^m$ と実際の出力 $o_{p,1}^m, o_{p,2}^m$ の2乗誤差 E_p は次式のようにになる。

$$E_p = \frac{1}{2}((t_{p,1}^m - o_{p,1}^m)^2 + (t_{p,2}^m - o_{p,2}^m)^2),$$

$$E = \sum_p E_p \quad (8)$$

ここで、 E は誤差関数である。最急降下法を用いて、この誤差関数 E の値が小さくなるように変化させる。

重みの初期値を与え、学習率を μ とすると重みの修正量 $\Delta_p w_{i,j}^{k-1,k}$ は、次のように求められる。

$$\Delta_p w_{i,j}^{k-1,k} = -\eta \frac{\partial E}{\partial w_{i,j}^{k-1,k}} = -\eta \frac{\partial E}{\partial i_j^k} o_i^{k-1} \quad (9)$$

ここで、 $\delta_j^k = -\frac{\partial E}{\partial i_j^k}$ とすると、

$$\delta_j^m = (t_j^m - o_j^m) o_j^m (1 - o_j^m) \quad (10)$$

$$\delta_j^k = o_j^k (1 - o_j^k) \sum_{l=1}^{n_{k+1}} (\delta_l^{k+1} w_{j,l}^{k,k+1}),$$

$$(k = 2, 3, \dots, m-1) \quad (11)$$

である。この修正を繰り返し、2乗誤差 E が十分に小さくなった場合に学習を終了する。なお、以下の例では、重みの初期値は -0.1 から 0.1 までのランダムな値に設定し、学習率 μ を 0.1 としている。

2.2 カラー化

カラー化は、目標画像のすべての画素において、輝度値、平均、標準偏差を入力データとして、学習済みネットワークを通し、出力 $(u(c), v(c))$ を推定する（ある画素を c とした）。ニューラルネットからの出力を、必要に応じて、 $U_8 = 255u(c)$ 、 $V_8 = 255v(c)$ のように256階調に変換する。これにより、目標画像に対するYUV画像成分を得ることができる。また、適宜、YUV成分をRGB成分に変換するなどして目的のカラー画像を得ることになる。

2.3 リマップ

学習において、参照カラー画像と目標画像の輝度分布が極端に異なる場合は、学習が成功したとしても適切な色付けがなされないことが多い。この場合は、2画像の輝度の平均と標準偏差が等しくなるように輝度の調整を行う⁶⁾。参照カラー画像の輝度の平均を μ_S 、標準偏差を ρ_S 、目標画像の平均を μ_T 、標準偏差を ρ_T として、参照カラー画像の画素 p の輝度値 y_p を式(12)によって調整する（調整後の値を y'_p とする）。

$$y'_p = \frac{\sigma_T}{\sigma_S} (y_p - \mu_S) + \mu_T \quad (12)$$

これにより、目標画像の輝度値を変えることなく、参照カラー画像と目標画像の輝度値の平均、標準偏差を一致させることができる。このように参照カラー画像の輝度のヒストグラムを目標画像に近づけることが可能になり、生成されるカラー化画像の品質を向上させることができる。

図 6 swatch の例
Example of swatch.

2.4 Swatch の利用

学習が難しい画像の場合は, Reinhard らの提案した *swatch*⁴⁾ を複数個用いる. *swatch* とはユーザが参照カラー画像, 目標画像のそれぞれから任意に選択した領域のことである. 図 6 に示すように, ユーザが参照カラー画像と目標画像の類似した部分に対応付ける. 提案手法では, はじめに, それぞれの *swatch* 間のみで学習を行いカラー化する. 次に, 目標画像のカラー化されていない部分とカラー化された *swatch* 内を比較して, 用いるネットワークを選択して全体をカラー化する. このため, *swatch* と同数の学習済みネットワークが存在することになり, カラー化されていない画素を色付けるためのネットワークの選択が問題になる. どのネットワークを用いるかを決定するために, はじめに, 参照カラー画像の *swatch* 内における 5×5 分の画素の輝度値を取得し, カラー化する画素 c の 5×5 近傍の輝度値の 2 乗誤差が最も小さくなる *swatch* を見つける. 画素 c は, この *swatch* のネットワークによって色付けられる. ただし, 二つの *swatch*, $s1$ と $s2$ に対して, 2 乗誤差が近接している場合, 近い色になると予想される隣り合う画素が異なるネットワークを通してカラー化されてしまい, 結果的にチェッカーボード的なノイズが生じる可能性がある. そこで, 2 乗誤差の小さな二つのネットワークを組合せて, カラー化を行うことにした. 2 乗誤差の小さな二つの *swatch* を $s1, s2$ として, 画素 c の入力データを $s1$ のネットワークを通したときの出力を u_1, v_1 , $s2$ を通したときの出力を u_2, v_2 とすると, 最終的な出力 $u(c), v(c)$ は,

$$u(c) = \left(1 - \frac{N^{s1}(c)}{N^{s1}(c) + N^{s2}(c)}\right)u_1 + \left(1 - \frac{N^{s2}(c)}{N^{s1}(c) + N^{s2}(c)}\right)u_2 \quad (13)$$

$$v(c) = \left(1 - \frac{N^{s1}(c)}{N^{s1}(c) + N^{s2}(c)}\right)v_1$$

$$+ \left(1 - \frac{N^{s2}(c)}{N^{s1}(c) + N^{s2}(c)}\right)v_2 \quad (14)$$

となる.

2.5 カラー化システムの構成

以上の手法を用いてモノクロ画像のカラー化システムを構築した. システムのスナップショットを図 7 に示す. また, 全体のながれを図 8, および図 9 によって説明する. はじめに, カラー化される単一または複数のモノクロ画像とカラー画像群を用意する. 次に, 非カラー化領域決定部 A において, モノクロ画像群に対してカラー化の対象としない領域を決める.

参照カラー画像群選択部 B において, 用意したカラー画像群から参照カラー画像群を選択し, カラー化領域の対応付け部 C においてカラー化されるモノクロ画像の領域と参照カラー画像の領域を対応させる.

次に図 9 を参照して, 図 8 の対応領域の学習済みネットワーク生成部 D を説明する. 対応領域の学習済みネットワーク生成部 D は, 主として入力信号成分決定部 a , 出力信号成分決定部 b , 入力信号生成部 c , 教師信号生成部 d ,

図 7 カラー化システムのスナップショット
A snapshot of the system of colorization.

図 8 カラー化システムのブロック図 (全体図)
A block diagram for the colorization system.

図 9 カラー化システムのブロック図
A part of the block diagram for the colorization system.

ニューラルネットワークによる学習部 *e*、学習終了判断部 *f* から構成され、各々の対応領域に対してニューラルネットワークを利用した学習を行う。

入力信号成分決定部 *a* においては、はじめに対応画像成分を決める。例えば、これを輝度とすれば、参照カラー画像の成分を YUV 形式に変換し、輝度を対応画像成分とする。次に参照カラー画像のある画素における対応画像成分と、その画素の近傍の画素の対応画像成分を用いて、平均、標準偏差等の統計量を算出し、対応画像成分、および統計量を用いて入力信号成分を決定する。出力信号成分決定部 *b* では、出力信号となる色情報の成分を決定する。

次に入力信号生成部 *c* において、参照カラー画像上のモノクロ画像に対応付けられた画像領域の中から適当な方法で複数の画素を抽出する。抽出された参照カラー画像の複数の画素における入力信号成分を用いて入力信号を生成する。

参照カラー画像から抽出した画素の色情報の成分を出力信号とし、教師信号生成部 *d* において前記入力信号と合わせて教師信号を生成する。この後、ニューラルネットワークによる学習部 *e* において、ニューラルネットワークによって学習を行う。なお、所定の回数以下の場合であっても、学習の途中で誤差が数居値以下になった場合は、学習終了判断部 *f* に進む。

学習の終了は、学習終了判断部 *f* において判断される。はじめに誤差が数居値以下になっているか、学習ステップが所定の回数分進められたかによって判断される。誤差が数居値以下の場合は、学習に成功したものと学習済みフラグを 1 とし、**E** に進む。所定回数の学習ステップが終了し、誤差が大きい場合は、入力信号成分決定部 *a* に戻るかどうかが問い合わされる。入力信号成分決定部 *a* に戻らない場合は、学習済みフラグを 1 (学習に成功)、または 0 (学習に失敗) に設定することで **E** に進む。

対応領域に対する学習終了判断部 **E** では、学習済みフラグの値によって、学習に失敗した対応領域を判断し、失敗した領域がある場合は、カラー化領域の対応付け部 **C** に戻る。すべての対応領域で学習に成功している場合は、カラー化が行われる。

カラー化は、はじめに対応領域のカラー化部 **F** において、モノクロ画像の各々の対応領域の画素に対して、各々の学習済みネットワークを利用して、出力として色情報を得ることによって行われる。

モノクロ画像において、対応領域以外にカラー化対象領域が存在する場合は、非対応領域のカラー化部 **G** において学習済みネットワーク群を利用してカラー化する。2. 4 節で述べた方法以外に、単純に、カラー化されたモノクロ画像の対応領域上の画素群に対して、画素の輝度、および近傍画素の輝度の平均、標準偏差を求め、それらの平均値を各々の対応領域の代表値とし、対応領域以外の画素に対するものと比べることによって、最も類似度の大きい対応領域を求め、その領域の学習済みネットワークを用いてカラー化する。このようにして、モノクロ画像におけるカラー化対象領域がカラー化される。終了処理部 **H** において、カラー化に成功したと判断すれば、カラー化処理を終了し、そうでない場合は、参照カラー画像群選択部 **B** まで戻る。

3. 検証実験と結果

図 10 に示すような形状が複雑なものに対して、カラー化を試みた (*swatch* は用いていない)。左図が参照カラー画像を、右図にカラー化する目標画像を示している。Welsh らの方法と提案手法によってカラー化された結果を図 11 に示す。ここで近傍には抽出された画素の周りの 5×5 画素 ($L = 2, M = 2$) を用いるものとする。図 11 左図で示す Welsh らの手法による結果では、苺の瘦果の部分やクリームの部分に細かな斑模様が生じていることがわかる。一方、提案手法による結果では、そのような斑模様は確認できず、自然にカラー化されていることがわかる。

次に、Welsh らの手法と本手法のカラー化の詳細な機構を調べるために形状は複雑であるが、ある程度領域が分離できる図 12 に示すような形状に対して、カラー化を試みた

図 10 形状が入り組んだ対象に対するカラー化 I 参照カラー画像 (左)、目標画像 (右)

A colorization for a grayscale image contains complicated geometries I. Reference color image (left figure), Grayscale image to be colorized (right figure)

図 11 形状が入り組んだ対象に対するカラー化 I Welsh らの方法 (左), 提案手法 (右)

A colorization for a grayscale image contains complicated geometries I. Welsh et al.(left figure), Present method(right figure)

(同様に *swatch* は用いていない). 結果を図 13 に示す. 図 13 の右図は, 左図の四角で示した部分を拡大したものである. Welsh らの手法による結果では, 花びらと背景が混じり合ったり, つぼみの影や茎の部分が花びらの色によって色付けられている. 提案手法では, そのような色の混在がなく, 自然にカラー化されていることがわかる. 図 14(a) は, 図 12(a) を用いて図 12(b) を色付けした際 (結果は図 13(b)) に, 形成された学習済みネットワークに対して, 入力信号の平均と標準偏差を固定して, y 値を 0 から 1 まで 256 段階に変化させたときの出力 v のグラフである. 同様に, 平均と標準偏差を固定し, y 値を 256 段階に変化させ, Welsh らの手法で目標画像を色付けする場合の y 値と v の対応関係を図 14(b) に示す. いくつかの場合についてグラフを調べ, 典型的なものを図 14 に示した. 図からわかるように, Welsh らの方法では, 多くの不連続性があり, 色飛びが起こっていることがわかる. この不連続性は, 参照

(a) Reference color image

(b) Grayscale image to be colorized

図 12 形状が入り組んだ対象に対するカラー化 II (a) 参照カラー画像, (b) 目標画像

A colorization for a grayscale image contains complicated geometries II. (a) Reference color image, (b) Grayscale image to be colorized

(a) Welsh et al.

(b) Present method

図 13 形状が入り組んだ対象に対するカラー化 II (a) Welsh らの方法, (b) 提案手法

A colorization for a grayscale image contains complicated geometries II. (a) Welsh et al., (b) Present method

カラー画像から抽出した色を用いて, 参照カラー画像と同様の輝度のパターンの場合に, 同一色で色付けるという方法自体の問題から生じるものである. 一方, 提案手法では, 輝度や標準偏差等が近い画素群では, v も近くなり (u も同様の結果となる), 色飛びは生じない. また, 物体のエッジ付近のような輝度値の変化が激しい部分であっても, 画素群の重み付けによって色付けされ, 背景色との混在がないことがわかる. しかしながら, Welsh らの方法と比べ, 物体内の境界近傍で色が強調され, かつ境界が拡散的になる. これは, 輝度, 平均, 標準偏差による学習の限界を示しており, 改善することが今後の課題である.

次に *swatch* の例を示す. 図 15 は図 2 の目標画像を *swatch* を用いずにカラー化したものである. Welsh らの手法においては, 先述した二つの例と同様の斑模様のノイズが生じていることがわかる (図 15 左図). また, 前面の平原部分に空の青色が, 山岳部分では空の青色と (参照画像の) 草原の緑色が, 森林部分においては草原の緑色が混在していることがわかる. Welsh らの手法では, 草原や森林に含ま

図 14 輝度値 y と出力 v の関係 (a) 提案手法, (b) Welsh らの方法
Relation between brightness y and chrominance difference v . (a) Present method, (b) Welsh et al.

図 15 目標画像 (図 2) のカラー化の例 Welsh らの方法 (左), 提案手法 (右)
The grayscale image in fig.2 is colored. Welsh et al.(left figure), Present method(right figure)

れる複雑な形状部分に対して, 図 11 や図 13 と同様の理由で自然な色付けができないためである. このため, *swatch* を用いたとしても改善できない. 一方, 提案手法では先述した理由によって, そのような部分であっても自然な色付けが可能になる. ただし, 斑模様のノイズは生じないが, 平原に対しては参照画像の山岳の色が, 山岳には平原に相当する色が混在していることがわかる. そこで, 森林, 山岳, 空に対する *swatch* を用いてカラー化を試みる (目標画像の輝度分布は参照画像の草原に相当する部分がないことを示しており草原は利用しないことにした). 結果として, 図 16 に示すように, 自然な階調のカラー化が実現できることがわかった.

最後に, ニューラルネットワークの構造を決定するために, これまで示した対象以外のものを加えて同様の実験を行った. その結果, 中間層は 2 層以上にしても, また, ニューロン数を 5 個以上にしても, 得られるカラー画像やグラフの変化がほとんどないことがわかった. よって, ニューラルネットワークの構造は, 中間層 1 層, ニューロン数 4 個で十分であると判断した.

4. む す び

モノクロ画像をカラー化するために複数のニューラルネットワークを用いた手法を提案した. 提案した手法は従来の手法の欠点を補い, 手作業を軽減するとともに, ノイズの減少や表現色の増加によって, 自然な階調のカラー化を可

図 16 目標画像 (図 2) のカラー化の例 (*swatch* あり)
The grayscale image in fig.2 is colorized by present method with *swatch*.

能にするものであることをいくつかの事例によって示した. また, 数値実験の結果, ニューラルネットワークの構造は, 入力データには, ピクセルの輝度とその近傍 5×5 あるいは 7×7 の範囲の輝度の平均, 標準偏差を用い, 中間層は 1 層でニューロン数は 4 個あればよいことがわかった.

提案手法は様々な画像に適用できるが, さらに画質を高め, より自然な色付けを実現するためには, 適切な *swatch* の指定が必須になると考えられる. このため, 手作業の増加を抑える必要性が生じる. 矩形以外の *swatch* と, その領域を自動的に決定する手法の検討を今後の課題とし, 方策としてパターン認識の応用を考えている.

〔文 献〕

- 1) Colorization:
"http://www.museum.tv/archives/etv/C/htmlC/colorization/colorization.htm"
- 2) www Factory CG Workshop photoshop LE:
"http://www.simz.com/cg.html"
- 3) T. Welsh, M. Ashikhmin and K. Mueller: "Transferring color to grayscale images", In Proceedings of ACM SIGGRAPH2002, pp.277-279, 2002
- 4) E. Reinhard, M. Ashikhmin, M. Gooch and P. Shirley: "Color Transfer between Images", IEEE Computer Graphics and Application, 21, 5, pp.34-41, 2001
- 5) 吉成康成: "ニューラルネットワーク", 旭屋書店, pp.27-49, (2002)
- 6) A. Hertzmann, C. Jacobs, N. Oliver, B. Curless and D. Salesin: "Image Analogies", In Proceedings of ACM SIGGRAPH2002, pp.341-346, 2002

こばやし ようへい
小林 洋平 1980 年生. 2003 年, 東京大学工学部システム創成学科知能社会システムコース卒業. 同年, 同大学大学院工学系研究科精密工学専攻博士前期課程進学. 正会員.

しらやま すずむ
白山 晋 1959 年生. 1982 年, 京都大学工学部航空工学科卒業. 1987 年, 東京大学工学系航空工学専攻博士後期課程修了. (株) 計算流体力学研究所などを経て, 1999 年, 東京大学工学系研究科環境海洋工学専攻助教授. 2002 年, 同大学人工物工学研究センター助教授. 工学博士. 主として 可視化情報に関する研究に従事. 正会員.