

ニューラルネットワークによる照明光の変化を考慮したカテゴリカル色知覚モデル

A Categorical Perception Model in Consideration for Illuminant Changes Using Neural Network

矢田 紀子[†], 正会員 長尾 智晴[†], 正会員 内川 恵二^{††}

Noriko Yata[†], Tomoharu Nagao[†] and Keiji Uchikawa^{††}

Abstract We developed a model that can operate similarly to human categorical color perception. The color of an object is not exclusively determined by the reflection spectrum from the surface of the object but is greatly affected by the ambient environmental conditions and depends upon color constancy. The mechanism of color constancy, however, is not explained in detail so acquiring the cognition of the categorical color name of objects under different illuminations is difficult. To that end, the relationship between the chromaticity and the categorical color perception of colored chips under different illuminations is the product of a categorical color-naming experiment was learned by using a neural network. The results showed that the obtained neural network has similar characteristics to those of human vision system.

キーワード：カテゴリカル色知覚、色恒常性、ニューラルネットワーク

1. まえがき

我々人間は、色の微妙な違いを見分けることができる一方で、その色を赤・青などのように大雑把に幾つかにまとめて表現することがある。例えば、洋服を買うときには、微妙な色の違いに注目して好みの色のものを選ぶだろう。しかし、それを友人などに伝えようすると、ピンクのシャツを買ったというように、その色を大雑把に表現する。この色の大雑把な分類を、カテゴリカル色知覚といいう¹⁾。Berlin and Kay は 100 種類以上の言語を調べて、白・赤・緑・黄・青・茶・オレンジ・紫・ピンク・灰・黒の 11 色が、言語や人に因らず等しく用いられる基本カテゴリ色であることを示した²⁾。これら 11 色の色名が基本カテゴリ色であることは、Uchikawa と Boynton による心理物理実験⁴⁾や松沢によるチンパンジーの行動実験⁵⁾でも示されている。

また、人間は環境光のスペクトルが変化しても物体の色

を安定して知覚することができる。これは一般的には恒常性 (constancy) として知られており、色知覚上では色恒常性と呼ばれている¹⁾。

さて、我々が色を大雑把に表現するときに感じる赤色や青色といった感覚は、頭の中でどのように生じているのであろうか。視覚系は、目の内側にある網膜で光のエネルギーが電気信号に変換されることから始まる。その信号が動きと色や形の情報に分類され、動きの処理を行う部位や色や形の処理を行う部位へと伝達され、最終的に高次の知覚へと発展していく。しかし、これらが全体でどのような処理を行っており、色恒常性やカテゴリカル色知覚のような高度な処理を行っているかは未だに不明である。一方、コンピュータビジョンにおいて色の認識を行いたい場合には、一般にカメラのセンサ値や階調値に閾値を設定して特定の色を判断するが、人間と同じように色を色名に分類して認識することは非常に困難である。

また、NN (Neural Network) を用いて、視覚系の処理している課題を学習させ、その中間層に生体の神経細胞と同様な応答をする中間ユニットを獲得している先行研究が多くある。Zipser and Anderson は、網膜上に投影された刺激の網膜上の位置とその刺激を見たときの眼球の向きから、提示されている物体の位置を計算する課題を NN に BP 法を用いて学習させた⁶⁾。その結果、ネットワークモデルはマカクザルの V7a 野における、同様の処理をしていると考えられている細胞と似た応答をする中間ユニットを獲得

2005 年 1 月、日本視覚学会冬季大会で発表

2005 年 5 月 2 日受付、2005 年 10 月 5 日再受付、2005 年 10 月 13 日採録
†横浜国立大学 大学院 環境情報学府

(〒 240-8501 神奈川県横浜市保土ヶ谷区常盤台 79-7, TEL 045-339-4136)
††東京工業大学 大学院 総合理工学研究科

(〒 227-0801 神奈川県横浜市緑区長津田町 4259, TEL 045-924-5453)

†Graduate School of Environment and Information Sciences, Yokohama National University

(79-7, Tokiwadai, Hodogaya-ku, Yokohama 240-8501, JAPAN)

††Interdisciplinary Graduate School of Science and Engineering,
Tokyo Institute of Technology

(4259, Nogatsuta-cho, Midori-ku, Yokohama 227-0801, JAPAN)

表 1 実験に用いた照明光の色度と相関色温度
Color temperature and CIE(1931)xy-chromaticity of illuminants.

照明光	相関色温度	xy 色度 (x, y)
o	3000K	(0.439, 0.410)
w	6500K	(0.313, 0.332)
b	25000K	(0.255, 0.252)

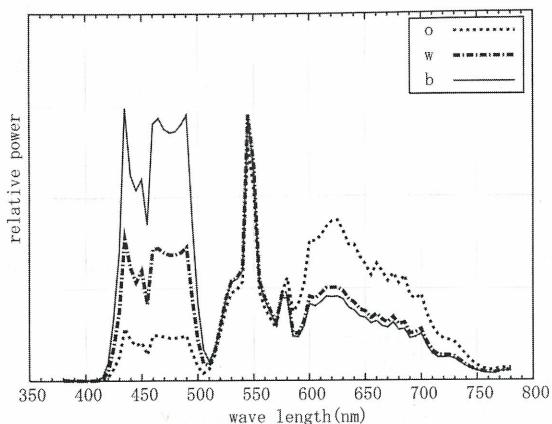


図 1 実験に用いた照明光の分光分布
Spectral distributions of illuminant.

した。また Usui らは、ある単色光に対する L, M, S 錐体の応答から、V4 野に確認されている色に対する選択性をもつ細胞への写像を、Zipser and Anderson と同様に BP 法を用いて NN に学習させた¹¹。その結果、ネットワークの中間層には、マカクザルの外側膝状体内に見られる反対色応答を示す細胞と似た応答を示すユニットが現れた。筆者らの研究グループでは、NN を用いたカテゴリカル色知覚のモデルを提案している¹²。しかし、このモデルは白色の照明光下に限定したモデルであり、色恒常性は考慮されていなかった。そこで本論文では、3 種類の照明光の下で行ったカラーネーミング実験の結果を NN を用いて学習するとともに、ネットワークの構造を改良することによって、色恒常性を考慮したカテゴリカル色知覚の新しいモデルを提案する。

2. カテゴリカルカラーネーミング実験

人間のカテゴリカル知覚特性を調べるために行ったカテゴリカルカラーネーミング実験について述べる。カテゴリカルカラーネーミングとは、被験者が呈示された色票の見えを、もっとも良く表す色名を 11 色の基本カテゴリ色の中から 1 個答える方法である。この実験では、呈示刺激として OSA 色票 424 枚を用いた。刺激は暗室内で天井から LCD プロジェクタによって照明され、灰色 (equivalent of N5) のボード上に 1 枚ずつ提示される。照明光が変化したときのカテゴリカル知覚の変化を調べるために、照明光には o, w, b の 3 種類を用いた。この 3 種類の照明光の相関色温度および CIE (1931) xy 色度を表 1 に示す。また、これらの分光分布を図 1 に示す。

被験者は、それぞれの照明光に順応した状態で提示され

る色票を見て、その色票の見えをもっとも良く表す色名を 11 個の基本色の中から 1 個答える。被験者は 4 名で、それぞれ色票 424 枚に対してのネーミングを 1 セッションとして、同一照明光で 2 回のセッションを行い、3 照明光 × 2 回 = 6 セッションを行った。ここで、内川らによる研究⁸⁾から、色空間を基本カテゴリ 11 色で領域分割する場合、いつ誰が見ても安定して分割される領域分割の安定性があることがわかっているので、4 人 × 2 セッションに対する実験でも、一般的なモデルを獲得するためのサンプルとして充分であると考えられる。

この実験結果を CIE (1931) xy 色度図にプロットして図 5 に示す。この図では、入力値のサンプル色の色度をグラフの座標で表し、実験結果の色名をプロット点の色によって表した。ただし、色名が白の場合は水色でプロットした。また、それぞれの照明光の色度を十字でプロットした。ここでサンプル色とは、それぞれの照明光の下に提示されたときの OSA 色票の色のことであり、実験結果とは、4 人 × 2 セッション = 8 回の結果をまとめた結果で、1 枚の色票に対して 8 回中最も多く答えられた色とする。今回の実験では実験結果が“黒”となったサンプルがなかった。これは OSA 色票では、低輝度の色票が少ないことが原因であると考えられる。

図 5 から、色票の色度点は照明光によって大きく変化しており、色度点から判断すると限られた色名しか得られないはずであるにもかかわらず、被験者の応答には複数の色名が用いられていることがわかる。これは色名が色票の色度だけによって決まっているのではなく、照明光成分を差し引いて色票の分光特性の違いによって決まっていることを示している。つまり、色恒常性が成立しているといえる。

さらに、この実験結果から各照明光・色票に対しての回答について、4 人 × 2 セッション = 8 回中での色名の一一致率を調べたところ、一致率 100% が 48.3%，一致率 50% 以上 100% 未満が 50.1% であり一致率 50% 以下は 1.7% と少なかった。このことから、今回の実験でも過去の研究と同様に領域分割の安定性が保たれていたといえる。

3. ニューラルネットワークを用いたモデルの提案

3.1 ニューラルネットワークの構造

本実験では、多数回の試行実験による実験結果を基に、最終的に入力層 1 層、中間層 2 層、出力層 1 層からなる 4 層のフィードフォワード型ニューラルネットワークを採用し、中間層と出力層の入出力関数にはシグモイド関数を用いた。入力ユニットは、3 種類の錐体 (L, M, S) に相当するユニットをサンプル色、照明光色それぞれに対して 1 セットずつ、合計 6 ユニットを用いた。ここで、照明光の変化に頑健なモデルを獲得するために、NN を 4 層にして 2 層ある中間層の 1 層目では照明光の補正は行わず、2 層目で照明光の補正を行うような NN の構造を新たに採用した。すなわち、入力層と中間層第 1 層は、共にサンプル色に対

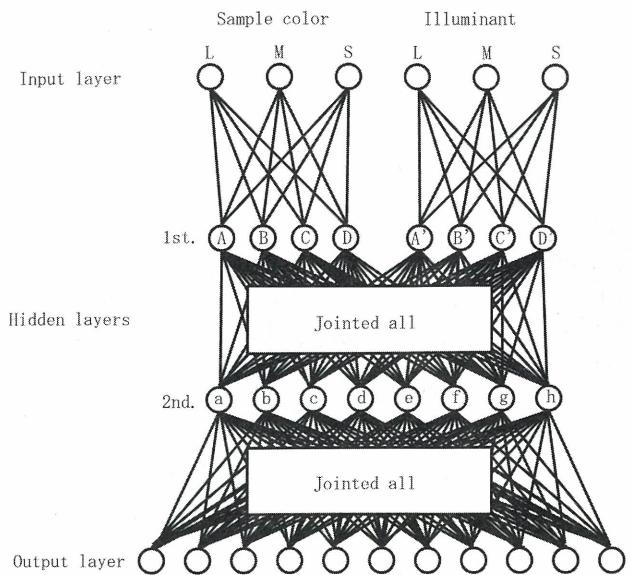


図 2 学習用いたニューラルネットワークの構造
Structure of neural network.

する部分と照明光色に対する部分に分かれており、それぞれの部分内では、全結合であるが部分間では互いに結合のない構造である。この構造を図 2 に示す。

このような構造をもつことによって、この NNにおいて中間層第 1 層では、サンプル色成分に起因する信号群と照明光色成分に起因する信号群が別々に伝達され、中間層第 2 層でサンプル色に対する照明光の補正が行われる。またこのとき中間層 1 層までの処理では、照明光成分に起因する信号に対してもサンプル色成分に起因する信号に対しても全く同じ処理を行う。つまり、ネットワークの学習の際に、この二つの処理を行う部分の構造上対応関係にあるユニット間の結合荷重同士が、互いに全く同じになるようにした。この学習方法については §3.3 で述べる。

このような構造を採用することで、照明光色に対する部分の学習にもサンプル色に対する学習結果が活かされるという利点があり、学習に用いる照明光の色数が少くとも、学習過程において様々な信号に対する学習が行われることになる。このため、NN を用いたカテゴリカル色知覚のモデル¹²⁾では不可能であった一般的な照明光下での色恒常性を備えたモデルが獲得できると考える。

中間層のユニット数は、試行実験を基にして最も適当なユニット数を決定した。中間層第 1 層は $4 \times 2 = 8$ ユニット、中間層第 2 層は 8 ユニットからなる。また出力層は、11 ユニットからなり、各ユニットが 11 色の基本カテゴリ色にそれぞれ対応している。

3.2 教師データセット

NN の学習用いた教師データセットは §2 の心理物理実験を元にして作成した。入力データは、サンプル色の CIE (1931) xy 色度 (x, y) と輝度 Lum から求めた L, M, S 錐体応答値と、そのときの照明光色の色度から輝度 Lum を一定値として求めた L, M, S 錐体応答値の計 6 個の値

とした。サンプル色、照明光色それぞれの L, M, S 錐体応答値は次のようにして求めた。まず、式 (1) ~ (3) に示す変換式⁹⁾を用いて XYZ 三刺激値 (X, Y, Z) へと変換した。

$$X = \frac{x}{y} \times Lum \quad (1)$$

$$Y = Lum \quad (2)$$

$$Z = \frac{1-x-y}{y} \times Lum \quad (3)$$

次に、得られた (X, Y, Z) を、式 4 に示す Smith-Pokorny の錐体分光感度関数¹⁰⁾を用いて L, M, S 錐体応答値へ変換した。ここで得られた (L, M, S) を [0, 1] の間に正規化したものを入力データに用いた。

$$\begin{pmatrix} L \\ M \\ S \end{pmatrix} = \begin{pmatrix} 0.15514 & 0.54312 & -0.03286 \\ -0.15514 & 0.45684 & 0.03286 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \end{pmatrix} \quad (4)$$

教師データには、実験で 4 名 \times 2 セッション中に得られた結果の、ある色票の見えに対してある基本色名が何度用いられたかを表す色名使用比率を、[0, 1] に正規化した値を用いた。このような教師データを学習させることで、NN は人間が行っている色の認識課程を L, M, S 錐体応答から基本カテゴリ色名への写像という計算課題として学習することが期待される。教師データセットには、3 照明光 \times 424 枚=1272 セットを用意した。

3.3 学習方法

NN の学習は、誤差逆伝播法の修正モーメント法を基に、入力層-第一中間層間はサンプル色に対する部分と照明光色に対する部分で、それぞれ全く同じネットワークが形成されるように改良した手法を用いて学習した。この方法では、例えば、図 2 の入力層サンプル色部分の L 錐体に対応するユニットと、中間層第 1 層のユニット A 間の結合荷重を修正する際に、入力層照明光色部分の L 錐体に対応するユニットと中間層第 1 層のユニット A' 間の結合荷重にも同じ修正が加わる。また逆に、照明光色部分のある結合荷重を修正する際には、サンプル色部分の構造上対応する結合の結合荷重にも同じ修正が加わる。つまり、入力層-中間層第 1 層間の結合荷重は、1 回の学習で 2 回の修正が加えられる。これは、互いに構造上対応する結合同士で共通の結合荷重をもち、サンプル色成分に対する処理と照明光成分に対する処理で共用することに等しい。

4. 結果と検証

4.1 学習結果

獲得した NN の構造と結合荷重を図 3 に示す。ここでは、プラスの結合を実線で、マイナスの結合を破線で表した。また、結合荷重の大きさを線の太さで表した。図 3 から、入

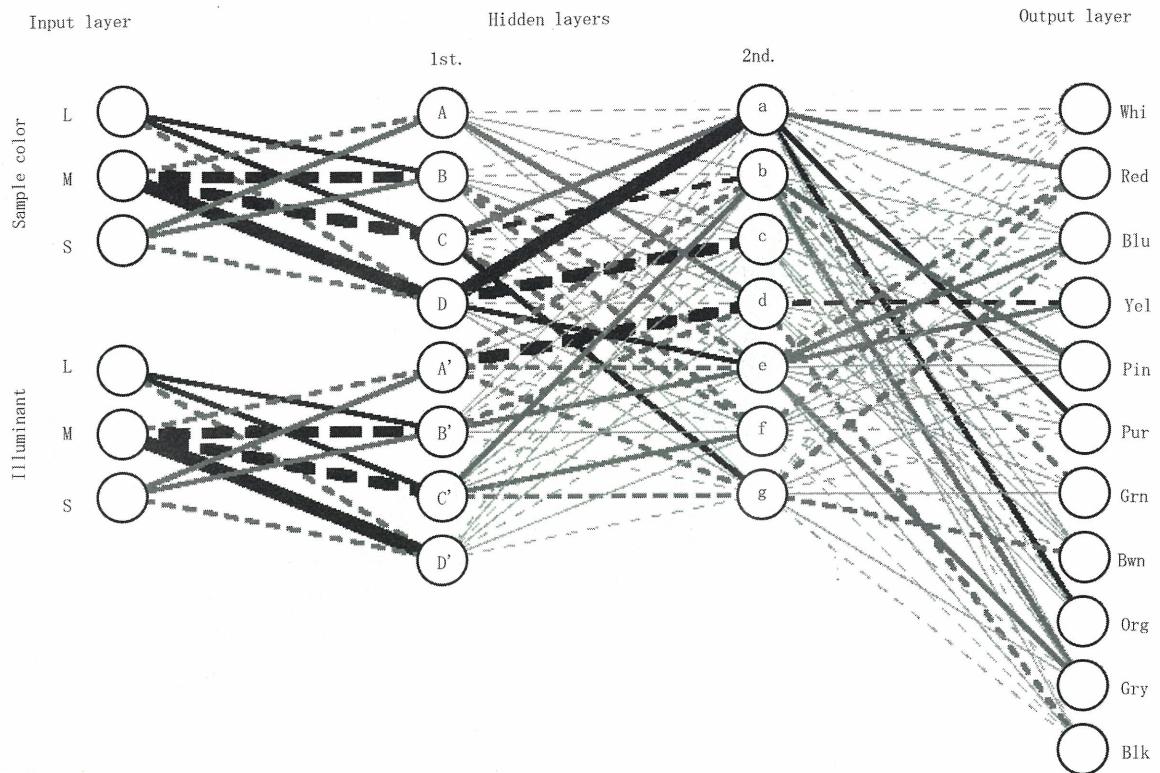


図 3 獲得したニューラルネットワーク
Obtained neural network.

表 2 教師データと NN の出力結果の誤差と正解率
Matching rates with training data.

照明光	平均 2 乗誤差	正解率 1 (%)	正解率 2 (%)
o	0.015	80.4	90.6
w	0.008	85.6	94.3
b	0.022	73.4	84.9

力層と中間層 1 層目がサンプル色に対応する部分と照明光色に対応する部分で全く同じ結合をしていることがわかる。また、学習後の NN の出力と教師データとの誤差と正解率を表 2 に示す。ここで平均 2 乗誤差とは、NN の出力値と教師データの誤差の平均を 2 乗して和を求めたものであり、正解率 1 とは、NN の出力の一番大きかった色名が心理物理実験の回答 8 回のうち、最も多く答えられた色名と一致した確率、正解率 2 とは、NN の出力の一番大きかった色名が、心理物理実験の回答 8 回のうち、最も多く答えられた色名か 2 番目に多く答えられた色名と一致した確率である。

また、学習に用いた心理物理実験結果と NN の出力結果を比較するために、OSA 空間にプロットして図 6 に示す。OSA 空間にでは、照明光に関係なく同じ色票は同じ座標にプロットされる。ただし、L 値は区別せず、 jg 面上に各カテゴリーの最も外側の線だけを示す。今回の心理物理実験では、実験結果が“黒”となったサンプルがなかったので、NN の出力結果にも“黒”は見られなかった。図 5 と図 6 の (1) ~ (3) を比較すると、照明光によって色票の色度が大きく変化しているのにもかかわらず同一の色票に対して同じ色名を出力していることから、NN が色恒常性を獲得できたといえる。

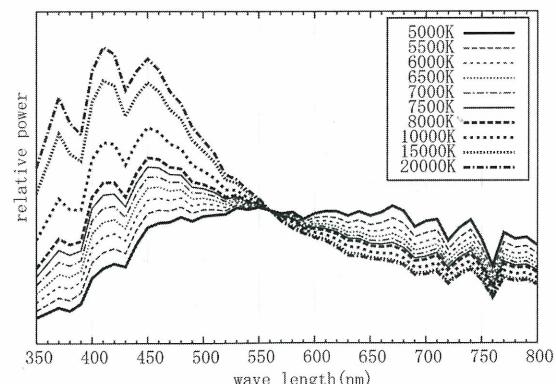


図 4 Daylight の分光分布
Spectral distributions of DayLight.

て同じ色名が答えられていることがわかる。また、図 5 と図 6 の (4) ~ (6) を比較すると、獲得した NN も照明光によって、色票の色度が大きく変化しているのにもかかわらず、同一の色票に対して同じ色名を出力していることから、NN が色恒常性を獲得できたといえる。

4.2 未知の照明光を用いた入力に対する検証

獲得した NN の性能の評価として、学習に用いた以外の照明光を入力した場合でも、同様に色恒常性を示すかどうか調べるために、未知データに対する出力の検証を行った。未知の照明光として色温度が 5000K~20000K の 10 種類の Daylight データ (Color Science.p.8~p.10¹¹) を入力値に用いたときの出力値を調べた。このとき用いた Daylight

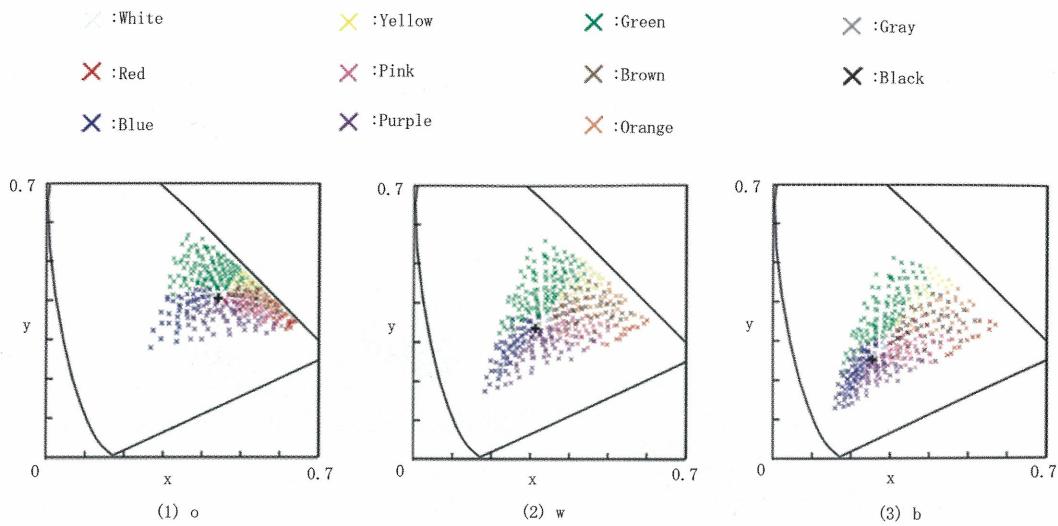


図 5 心理物理実験の結果
Chromaticity of chips and color names.

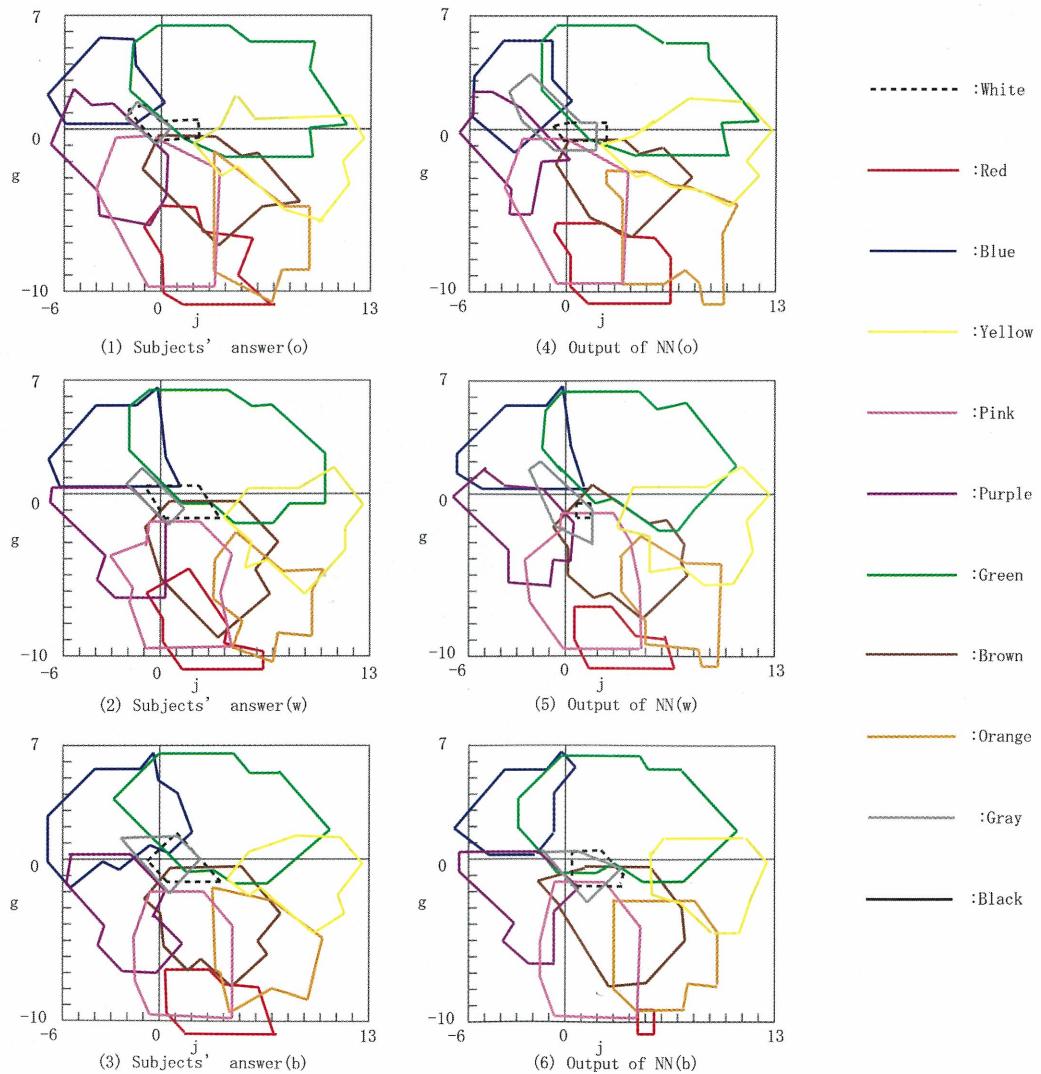


図 6 OSA 空間上の色名の分布
Distribution of categorical color name on OSA space.

表 3 未知の照明光への適用結果
Matching rates with unknown data.

照明光	平均 2 乗誤差	正解率 1 (%)	正解率 2 (%)
DL5000K	0.020	74.8	84.9
DL5500K	0.015	80.4	89.4
DL6000K	0.009	86.3	94.8
DL6500K	0.013	81.8	92.5
DL7000K	0.009	85.1	94.3
DL7500K	0.010	81.8	92.7
DL8000K	0.016	76.7	90.3
DL10000K	0.022	70.1	84.0
DL15000K	0.022	68.6	82.6
DL20000K	0.024	70.5	83.0
Average	0.016	78.1	89.1

表 4 3 層の NN の出力結果の誤差と正解率
Matching rates of three-layered NN with training data.

照明光	平均 2 乗誤差	正解率 1 (%)	正解率 2 (%)
o	0.010	89.2	95.1
w	0.010	86.8	96.2
b	0.012	84.0	95.5
average	0.010	86.6	95.6

表 5 3 層の NN の未知の照明光への適用結果
Matching rates of three-layered NN with unknown data.

照明光	平均 2 乗誤差	正解率 1 (%)	正解率 2 (%)
DL5000K	0.075	37.5	51.9
DL5500K	0.060	47.9	63.7
DL6000K	0.039	63.7	79.5
DL6500K	0.015	81.8	93.4
DL7000K	0.011	88.0	96.5
DL7500K	0.024	76.7	89.9
DL8000K	0.034	72.9	85.8
DL10000K	0.038	69.3	83.0
DL15000K	0.022	78.8	91.7
DL20000K	0.014	82.8	94.6
Average	0.033	69.9	83.0

データの分光分布を図 4 に示す。

未知の照明光に対する出力結果の正解率を求めるために、§2 の心理物理実験の結果を各色票の色名の正解として用い、5000K～6000K の出力結果は 3000K か 6500K の実験結果のいずれかと一致したものを正解とした。同様に、7000K～20000K の出力結果は 6500K か 25000K の場合、6500K の出力結果は 6500K の場合と一致したものを正解とした。また、§4.1 と同様に正解率 1 と正解率 2 を求めた。この結果を表 3 に示す。

ここで、提案手法との比較のために、一般的なフィードフォワード型ニューラルネットワークを提案手法で用いたのと同じ教師データセットを用いて、誤差逆伝播法の修正モーメント法で学習して獲得した NN¹³⁾ の出力結果を示す。この NN は、3 層のフィードフォワード型ニューラルネットワークで、入力層 6 ユニット、中間層、出力層 11 ユニットからなる。また、中間層と出力層のユニットの入出力閾数にはシグモイド関数を用いた。この NN に §3.2 と同様の教師データを学習させた。学習後の NN の出力と教師データとの誤差と正解率を表 4 に示す。

また、提案手法に対してと同様に、色温度が 5000K～20000K の 10 種類の Daylight データを未知の照明光とし

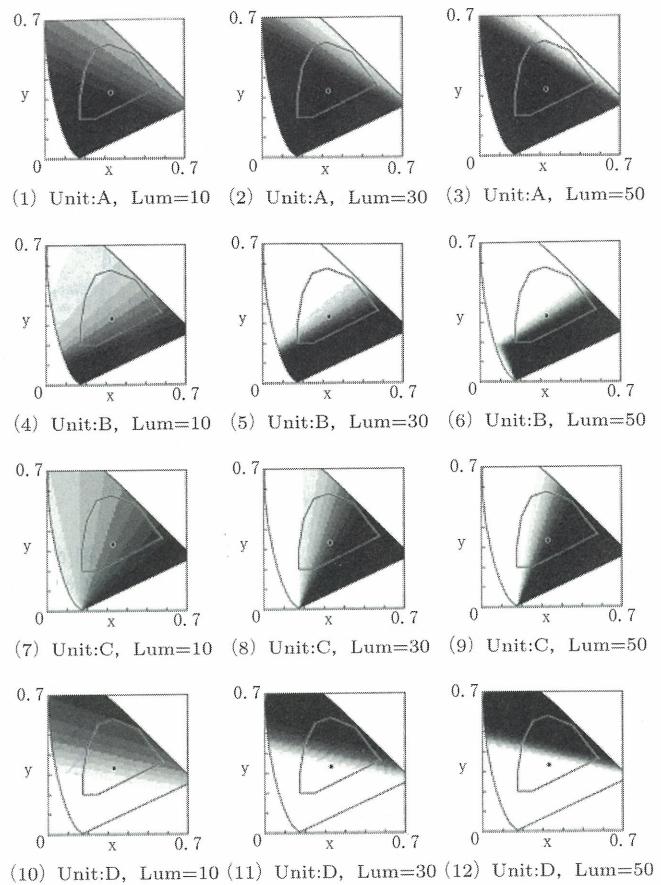


図 7 中間層 1 層目の出力応答 (6500K)

Output of the hidden unit in 1st. hidden layer.

て入力したときの、NN の出力の正解率を表 5 に示す。表 5 では、教師データとして用いた照明光に色度の近い照明光では、高い正解率を保っているが、教師データと教師データの間の色度をもつ照明光を用いたときには、表 3 の結果と比較して正解率が低くなっている。このことから、今回の提案手法で、新しく採用した構造の NN を用いたことで、照明光の変化に対して、より頑健なモデルが獲得できたといえる。

4.3 中間ユニットの入出力応答

実験で得られた NN に対して、照明光 (3000K, 6500K, 25000K:3 種) と輝度 ($Lum = 5, 10, 30, 50, 75 [cd/m^2]$:5 種) 每において、サンプル色の色度 (x, y) をそれぞれ 0.01 每に変化させた値を入力とした場合の中間層の出力値から、照明光および輝度の変化に対する中間ユニットの応答を調べた。図 7 に中間層 1 層目の中間ユニットの出力結果を示す。これらの図の座標は、入力値のサンプル色の色度座標に対応しており、プロット点の色がそのときの中間ユニットの出力の強度を示している。出力の強い点が黒、弱い点が白になるよう、10 段階でプロットした。その結果、中間層 1 層目の中間ユニットの出力値の強度分布は、色空間を分割するようなはっきりとした境界線を示しており、xy 色度図上で直線になっている。

この結果を、神経生理学データと比較してみる。マカク

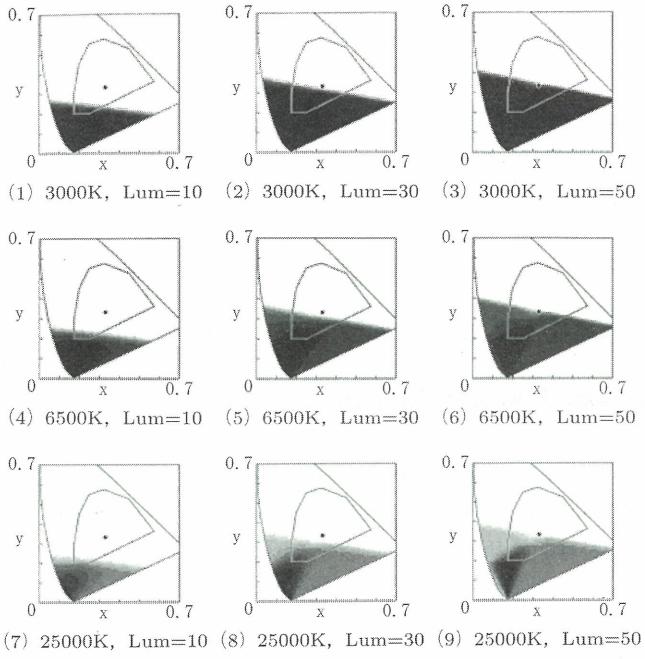


図 8 中間層 2 層目の中間ユニットの入出力応答 (ユニット:c)

Output of the hidden unit in 2nd. hidden layer.

ザルに様々な色を見せたときの大脳皮質での各細胞の応答を調べた小松らの研究¹⁴⁾によると、細胞の発火強度の等高線が xy 色度図上で直線になるもの・曲線になるもの・閉曲線になるものがあったとされている。今回獲得された NN の中間層でも色空間を直線・曲線で 2 分割するユニットが見られ、これは小松らの研究結果との共通点である。

また、中間層 2 層目のユニットの入出力応答を調べたところ、照明光の入力値によって発火する範囲の境界線が変化するものが存在した。この例として、図 3 のユニット c の応答結果を図 8 に示す。図 8 から中間ユニットが、NN に入力される照明光色の値の変化に伴って、サンプル色の値に対応した補正を行うための応答を獲得できたことがわかる。このことから、今回の提案モデルで一般的な照明光に対する色恒常性が実現できたのは、中間層 1 層目において、照明光成分についてもサンプル色成分と同様に、広い範囲の色に適用可能な処理を獲得し、その後の 2 層目以降でサンプル色成分から照明光成分を差し引く処理を獲得できたからであると考えられる。つまり、NN を 4 層にして、2 層ある中間層 1 層目では照明光の補正是行わず、2 層目以降で照明光の補正を行うような NN の構造を採用したことが活かされたといえる。

5. む す び

本論文では、中間層の 1 層目では照明光の補正是行わず、2 層目で照明光の補正を行うような 4 層構造の階層型 NN を新たに提案した。この NN に 3 種類の照明光の下で行ったカテゴリカルカラーネーミング実験の結果を学習させることで、さまざまな照明光の下で人間と同様なカテゴリカル

色知覚を行うことができるモデルを獲得することができた。

今後の課題としては、構築した NN の精度の向上や、筆者らの研究グループで開発済みの任意構造の NN を自動構築することができる進化型 NN によって、順応などの時間的に応答が変化するモデルを構築することなどがある。また、これらのモデルをコンピュータビジョンに適用することで、人と同様な色知覚を行うことができる人工システムを構築する予定である。

[文 献]

- 内川恵二：“色彩科学選書4 色覚のメカニズム 色を見る仕組み”，朝倉書店（1998）
- Berlin, B. and Kay, P.：“Basic Color Terms:Their Universality and Evolution”, University of California Press, Berkley(1969)
- Crawford, T. D.：“Defining 'basic color terms' ”, Amthropol. Linguist., 24, pp.338-343(1969)
- Uchikawa, K. and Boynton, R. M.：“Categorical color perception of Japanese observers:comparison with that of Americans”, Vision Res., 27, 10, pp.1825-1833(1987)
- 松沢哲郎：“認知科学選書 23 チンパンジーから見た世界”，東京大学出版会（1991）
- Zipser, D and Anderson, R. A.：“A back proragation programmed network that simulates response properties of posterior parietal neurons”, Nature, 331, 25, pp.679-684(1988)
- Usui, S., Nakauchi, S., Miyake, S.：“Acquisition of color opponent representation by a three-layered neural network model”, Biol. Cybern., 72, pp.35-41(1994)
- 内川恵二, 栗木一郎, 篠田博之：“開口色と表面色モードにおける色空間のカテゴリカル色名領域”, 照學誌 77, pp. 346-354(1993)
- 池田光男：“色彩工学の基礎”, 朝倉書店 (1980)
- Smith, V. C. and Pokorny, J.：“Spectral sensitivity of the foveal cone photopigments between 400 and 500nm”, Vision Res., 15, pp.161-171(1975)
- Wiszecki, G. and Stiles, S. R.：“Color Science: Concepts and Methods”, Quantitative Data and Formulaw(2nd edition). John Wiley and Sons, NewYork(1982)
- 鈴木哲明, 長尾智晴, 栗木一郎, 内川恵二：“ニューラルネットワークによる色のカテゴリカル知覚の学習”, 映情学技報, 23, 29, pp. 19-24(1999)
- N. Yata, T. Nagao, and K. Uchikawa:“A Categorical Perception Model in consideration for Color Constancy”, IWAIT'04, January 12-13, Singapore (2004)
- Hanazawa, A., Komatsu, H. and Murakami, I. ;“Neural selectivity for hue and saturation of colour in the primary visual cortex of the monkey”, European J. Neurosci., 12, pp.1753-1763(2000)



矢田 紀子 1981 年生。2005 年、横浜国立大学大学院環境情報学府博士前期課程修了。現在、同博士後期課程在学中。カテゴリカル色知覚、人間情報処理などに関する研究に従事。



長尾 智晴 1959 年生。1985 年、東京工業大学大学院博士後期課程中退。同年、同大学工学部附属像情報工学研究院施設助手。1995 年、同大学工学部附属像情報工学研究院施設助教授。2001 年、横浜国立大学大学院環境情報研究院教授、現在に至る。工学博士。正会員。



内川 恵二 1950 年生。1980 年、東京工業大学大学院博士課程修了。カナダ、ヨーク大学博士研究員を経て、東京工業大学工学部像情報工学研究施設教授、現在に至る。視覚情報処理、色覚認識に関する研究に従事。工学博士。正会員。