原著論文

動的ニューラルネットワークを用いた人間の明順応モデル

大西 厳*, 本居 宣久**, 木村 一郎***

*広島国際大学心理科学部, **松下電器産業株式会社, ***大阪電気通信大学

A HUMAN LIGHT ADAPTATION MODEL USING A DYNAMIC NEURAL NETWORK

Gen ONISHI*, Norihisa MOTOORI** and Ichiro KIMURA***

* Hiroshima International University, 555-36 Gakuendai, Kurose-cho, Higashihiroshima-shi, Hiroshima, 739-2695, Japan

** Matsushita Electric Industrial Co., Ltd., 1-15 Matsuo-cho, Kadoma City, Osaka 571-8504, Japan

*** Osaka Electro-Communication University 18-8, Hatsu-cho, Neyagawa-shi, Osaka, 572-9530, Japan

Abstract: With the development of recent science and technology, our daily life has been filled with high-performance and high-quality products. In this background, we are requiring new technologies with our *Kansei* or sense. Various researches are tried to reflect human sense in engineering. One of them, we notice the human light adaptation, and construct the model for subjective brightness with time varying. This paper presents a human light adaptation model using a dynamic neural network. The input of this model is the light intensity steps which are exposed to examinee's eyes. The output is human subjective brightness with time varying. As the result of analyzing the synaptic weights of the neurons after training, we confirmed that the model obtained some functions which agree well with the human optical nerve system.

Keywords: Dynamic Neural Network, Light Adaptation, Broca-Sulzer Effect

1. はじめに

近年、科学技術の発達によって、私たちの身のまわりには高機能・高品位の製品が溢れるようになってきた。特にインターネットなどをおこなう家庭用コンピュータの普及は、私たちの生活を格段と快適なものにしている。しかし、その一方でハードおよびソフトウェアの「感覚が一致しない。気がきかない。間違いを許容しない。」という点が指摘されるようになり、これらの問題を解決するために、コンピュータ側に人間の感覚や感性を理解させる技術が望まれるようになってきている [1] [2]。

人間の感じ方や感性をコンピュータ上でモデル化する試みが様々な研究分野で行われている [3-5]。たとえば、小松ら [6] はハンカチのデザインと被験者の印象を、数量化理論 I 類にファジィ推論を取り入れることによって、そのモデル化に成功した。これらの報告のほとんどが、対象の印象が時間的に変化しないものばかりであり、人間の感覚や感性のモデル化には、時間の影響を考慮する必要がある。また、塚田ら [7] は論理回路モジュールを組み合わせることによって人間の主観的な明るさ知覚（明順応）を再現している。しかし、このモデルでは人間の視覚神経系の入出力関係を数式によって表現しており、脳および視覚神経系の内部構造を生理学的に再現していないため、人間の感覚がどのような処理によって形成されるかを解明することができない。

明順応の一般的な例として、私達が自動車などを運転しているときに、暗いトンネルから明るい太陽光の下に出ると、瞬間的に眩しさを感じ周囲が見えなくなるが、その後数秒で周囲が認識できるようになる現象がある。この日常的に発生

する現象は、主に網膜上にある視細胞、杆体（rod）と錐体（cone）の働きによって引き起こされると言われており、生化学の分野においては盛んに研究 [8] されているものの、これらの視細胞がどのように主観的明るさに影響するのかは明確にされていない。

著者ら [9] は以前、音楽コード進行の時系列変化と感性の関係に注目し、人間の聴覚機構を入力部に取り入れた感性モデルを、動的ニューラルネットワークを用いてコンピュータ上に構築した。そして、そのモデルの内部表現の一部が、人間の情報処理手法と一致することを確認している。

本研究では、時間的な影響を受ける人間の主観的明るさ知覚（明順応）に注目し、その処理モデルを脳・神経系の内部構造を簡易的に模擬できる任意結合型の動的ニューラルネットワークを用いてコンピュータ上に構築する。さらに、学習によってネットワーク上に獲得した内部表現を解析することにより、この明順応モデルの特性を人間の脳や神経系、特に視覚神経処理の知見と照らし合わせて考察する。

2. 時系列データを学習するアルゴリズム

2.1 BP 法によるニューラルネットワーク

本研究では、階層型ニューラルネットワークの代表的なアルゴリズムであるバックプロパゲーション法（誤差逆伝播法：以下 BP 法と記す。）を基本アルゴリズムとして用いる。図 1 に一般的な BP 法によるニューラルネットワークの概要を示す。同図において、 y_j^m は、第 m 層 j 番目のユニットからの出力値を表し、 w_{ji}^{m-1} は第 $m-1$ 層 i 番目のユニットから第 m 層 j 番目のユニットへの結合荷重を表す。また、第 m 層 j 番目のユニットのしきい値を θ_j^m とする。ここで x_j^m を、第 m

層 j 番目のユニットへの入力値の総和とすると、その値は次式で与えられる。

$$x_j^m = \sum_i w_{ji}^{m-1} y_i^{m-1} \theta_j^m \quad (1a)$$

本研究で用いる BP アルゴリズムでは、しきい値を表すためのユニット（以下バイアス）を導入している。これは入力層と中間層の 1 番目のユニットに該当する。図 1 に示すように、バイアスは入力値を持たず、また常にそのユニット出力値が 1 となるように固定する。これにより、バイアスを前層のユニットの出力値と同様に扱うことが可能となり、(1a) 式は (1b) 式のように表すことができる。

$$x_j^m = \sum_i w_{ji}^{m-1} y_i^{m-1} \quad (1b)$$

ただし、 $i = 0$ のとき、

$$y_i^{m-1} = 1, \quad \theta_j^m = w_{ji}^{m-1}$$

y_j^m は第 m 層 j 番目のユニットの出力値で、その値は x_j^m に (2b) 式のシグモイド関数を施したものである。

$$y_j^m = f(x_j^m) \quad (2a)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2b)$$

次に、BP 法における結合加重の学習方法、更新方法について述べる。出力層を第 M 層とし、その各ユニットの実際の出力を y_i^M 、本来出力されるべき理想的な出力を d_i とする。このとき、2 乗誤差の総和 E を次式で定義する。

$$E = \frac{1}{2} \sum_i (y_i^M - d_i)^2 \quad (3)$$

この誤差関数 E が小さくなるように結合加重を修正していく。このような形の誤差関数を最小にする手段を一般に最小 2 乗平均誤差 (LMS) 法と呼ぶ。

図 1 Neural network

誤差関数 E とすべての結合加重との偏微分 $\partial E / \partial w_{ji}^m$ を考えると、誤差 E と結合荷重 w_{ji}^m についての勾配が求まる。これより、この値が正を取る時、 w_{ji}^m を増加すれば E も増加し、逆に負を取る時、 w_{ji}^m を増加させると E は減少する。よって、結合荷重を学習データ列および学習サイクルに対して次式を用いて逐次修正していくことにより、期待値と実際の出力値との誤差は減少していく。

$$w_{ji}^m[n_{t+1}] = w_{ji}^m[n_t] - \eta \frac{\partial E}{\partial w_{ji}^m[n_t]} + \alpha (w_{ji}^m[n_t] - w_{ji}^m[n_{t-1}]) \quad (4)$$

$$t = \{0, 1, 2, \dots, t, \dots, T-1, T\}$$

ただし T は 1 サイクル中のデータ数

n : 学習サイクルカウンタ

よって $(n)_T$ は $(n+1)_{t=0}$ となる。

本研究では、結合荷重を逐次修正法を用いて更新するため、1 サイクル中に存在するデータ列が時系列となり、ある学習サイクル n 回目における時刻 t を n_t として表している。結合荷重の更新が n_T まで達すると、次の学習サイクル $n+1$ 回目に移行する。(4) 式では、1 サイクル中の学習時刻における結合加重の変化に比例した項を追加することで、収束速度を速めている。また、 α および η は学習係数であり、これらは試行錯誤的に決定する。

2.2 自己フィードバック

本研究で用いる BP アルゴリズムは、時系列データを扱うために、中間層と出力層のすべてのユニットを時系列処理ユニットとする。時系列処理ユニットでは、1 サイクル中のある時刻 t において、それ以前の出力を指定した時間 D だけさかのぼって参照でき、現在の出力に過去の状態を反映することができる。(5) 式は、入力層を除いた任意の層において、ある時系列処理ユニット j に対する、学習サイクル n 回目、ある時刻 t における入力の総和 $\hat{x}_j[n_t]$ を表す。

$$\hat{x}_j[n_t] = \sum_i w_{ji} y_i[n_t] + w_{jd} \times \beta \times \sum_{a=1}^D \frac{y_j[n_{t-a}]}{P^{a-1}} \quad (5)$$

ここで w_{ji} は前層からの結合加重、 w_{jd} はユニット j 自体の過去出力であるフィードバック値に掛かる結合荷重、 β は時系列係数、 D は過去のフィードバック値を参照する時間、 P は自己フィードバック値の時間経過に伴う減衰率である。自己フィードバック値と前層からの入力値が大きくかけ離れていると効果的な学習が行えないため、自己フィードバック値は時系列係数 β と減衰率 P で調整する。

つまり、減衰率 P で時間の経過とともに過去の影響が弱まるようにし、時系列係数 β で自己フィードバック値自体の影響を調整できるようにしている。また、自己フィードバックに掛かる結合荷重 w_{jd} は、自己フィードバック値 $y_j[n_{t-a}]$ を仮想的に前層ユニットからの入力値とすることで、その更新についても (4) 式を用いて行うことができる。

2.3 全ユニット間の結合

本研究で用いるネットワーク中のユニットは、1つ前の層に存在するユニットからの出力以外は、1時刻前の出力値を入力するようにしている。これにより、同じ層のユニット間の結合や、隣接していない層のユニット間の結合が可能となり、様々な形のネットワークが構成できる。全ユニット間の結合を可能とするために、(5)式は(6)式ようになる。

$$\hat{x}_j[n] = \sum_i w_{ji} y_i[n] + w_{jd} \times \beta \times \sum_{a=1}^p \frac{y_j[n-a]}{p^{a-1}} + \sum_A w_{jA} y_A[n_{t-1}] \quad (6)$$

ただし、 $w_{jA} = 0$ ($A = i, j$ のとき)

ここで、 $\hat{x}_j[n]$ は、学習サイクル n 回目のときの、全ユニット間結合を考慮した、時刻 t におけるある層のユニット j の入力の総和、 A はバイアスを除いた全ユニットを表す、 w_{jA} はネットワーク内のユニット A からユニット j への結合荷重で、 $y_A[n_{t-1}]$ はユニット A の、学習サイクル n 回目のときの時刻 $t-1$ における出力である。ここで、 A が i または j の時、入力値が重複することを防ぐために、 $w_{jA} = 0$ とする。このユニット A からの入力を仮想的に前層からのものとする。ここで、結合荷重 w_{jA} についても(4)式を用いて更新することができる。

2.4 任意結合

本研究で用いるネットワークには、ユニット間の結合荷重を任意に設定し固定できる「任意結合型」を導入する。これにより、自己フィードバック結合、ユニット間の結合の有無が決定でき、様々なネットワークモデルの構成が可能となる。

3. 主観的明るさ知覚の時間的特性

3.1 Broca-Sulzer 効果

Broca と Sulzer は、ある強度の光が突然呈示されたとき、人間が実際に知覚する明るさが、時間的にどのように変化するかを測定した。その結果、ある強度以上の光が人間の眼に照射されると、瞬間的に本来知覚される明るさレベル以上に感じ、時間の経過とともに定常状態で知覚する強度に収束する、強調効果(オーバーシュート)が生じることを確認した。この現象を発見者の名前に由来して、Broca-Sulzer 効果[10]と呼ぶ。

また、人間の眼は、ある一定強度の光が照射されると、その光強度にあわせて感度を変化させる。これを明順応といい、映画館のような暗い室内から突然明るい外部に出た時に、Broca-Sulzer 効果によって、瞬間的に強い光強度が知覚されるが、徐々に本来知覚される光強度を感じるようになる現象に例えることができる。また、明順応と逆の現象を暗順応という。これは、明るい場所から暗い室内などに入る時、一瞬視界が消失するが、時間が経過すれば周囲の状況がよく見えるようになることから理解できる。明順応と暗順応と

では、完全に順応するまでの時間が異なる。この理由については、次節の視細胞の働きによって説明できる。本研究では、この人間の主観的明るさ知覚の時間的変化(Broca-Sulzer 効果)を扱う。

3.2 視細胞

光が眼に入った時、最終的に到達するのは網膜と呼ばれる眼球内部の一番奥に存在する箇所であり、そこで光のイメージを生理学的な応答に変換する[11]。(光電変換[12]とも言う。)しかし、網膜は光を感じる単一の物質からできた一様な表面ではなく、そこには莫大な数の光の受容器(視細胞)が存在し、その受容器に照射された光エネルギーに対して反応する。人間の網膜には2種類の受容器が存在し、それぞれ杆体(rod)と錐体(cone)と呼ばれる。

人間には、片目に約600万個の錐体と1億2000万個の杆体がある。この2つの要素は光の知覚に対して、異なる反応を示す。杆体1個は錐体1個に比べて光に対する感度が約500倍程度であるが、色情報を識別することができない。一方、錐体は色情報を識別するが、杆体と比較して光の強度に対する感度が悪い。このことから、薄暗い場所では杆体が働くことによって、物体の形状等は知覚できるが、錐体の働きが得られないため色情報は知覚できない。また、明るい場所では錐体の働きにより色情報や形状は知覚できるが、一度強い光に順応してしまうと、明るさが多少変化してもその変化を認識できない。

また、杆体と錐体では、明るさ知覚の時間的特性も異なっている。暗順応では、杆体の反応によって視覚認知できるようになるが、明るい状態では杆体が反応を示すのに必要な化学物質(視物質)がほぼ分解されてしまうため、杆体が反応を起こしてから完全に順応するまで約30~60分程度[11]の時間を要する。逆に明順応では、錐体の反応によって数秒程度の時間で、暗順応によって上がりすぎた光に対する感度を適正な値に戻すことができる。つまり、杆体は錐体と比較して時間的に緩やかな応答を示すといえる。

4. 明順応モデルの構築

時系列データを学習する動的ニューラルネットワークで、時間的特性を伴う主観的明るさの知覚である明順応をモデル化する。

4.1 入力データおよび教師データ

図2に、ある強度のステップ光の入力に対する明るさ知覚の時間的変化(Broca-Sulzer 効果)を示す。図2において、破線は入力されるステップ光の照度、実線は入力された各強度のステップ光に対する主観的明るさ知覚の時間的変化である。本研究では、このステップ光を入力データ、主観的明るさ知覚の時間的変化を教師データとし、ニューラルネットワークに学習させる。このときのサンプリング周波数は200 Hzとし、縦軸の照度0~750 luxを0.0~1.0の範囲に対応させ

るように規格化した。

4.2 学習および汎化結果

図3に、本研究で構成したネットワークを示す。中間層のユニット数を8個とし、入力層、出力層の数を、それぞれ1個とする。また、明順応現象は非常に複雑な細胞間の相互作用によって発生すると考えられることから、出力層ユニットの自己フィードバック結合以外は、全ユニット同士を結合させ、学習による内部表現の獲得を試みた。

本研究において、中間層のユニット数が8～11個のときの学習結果（学習データと教師データの誤差）および汎化結果（未知のデータと教師データの誤差）は、いずれもほぼ同様に良好であった。しかし、ユニット数が12個以上になると、ユニット数が8～11個のときと比べて、学習・汎化結果はほとんど変化しない傾向が現れた。また、ユニット数が8個より少なくなると、本ネットワークモデルが入力情報の

特徴を十分にとらえることができなくなった。中間層のユニット数は、必要以上に多くなると入力情報の特徴を抽出する機能が各ユニットに分散し、ひとつひとつのユニットの役割を解明することが困難になる。よって学習後の内部解析を容易にするためには、ユニット数をできるだけ少なくする必要がある。その結果、中間層のユニット数を8個に決定した。

このネットワークモデルにおいて、図2に示す170 lux, 64.5 lux, 32.4 luxの3パターンのステップ光をニューラルネットワークの学習に用い、126 luxのステップ光を、未知の入力に対する適応能力を調べる（汎化）データとして使用している。学習データは、実際のデータ部0.35秒×3パターンに、データのインターバル0.15秒×3の計1.5秒を1サイクルとしており、これを65000回繰り返して学習させる。（実際のネットワークでは、200 Hzのサンプリング周波数で入力データを取得し、その周期に対応する主観的知覚によって生じる照度を教師データとして学習させている。すなわち離散的に1.5秒の間を300個のポイントで測定し、それを近似的に連続時間として取り扱っている。）

また、結合荷重更新係数 $\eta = 0.3$, $\alpha = 0.1$, 時系列係数 $\beta = 0.2$, 減衰率 $P = 1.4$, 自己フィードバック参照時間 $D = 5$ とした。これらの係数は、シミュレーションを繰り返す中で、学習・汎化結果が良好になるものを試行錯誤的に決定した。たとえば、減衰率 P を1.1以下にすると、他のパラメータを変えても学習が収束しなくなることを確認している。このことは、自己フィードバックする過去の値が、時間の経過とともにある一定値より小さくなる必要があることを示しており、明順応を表現するユニット群の特性のひとつと考えられる。

図4に65000回学習させたあとの結果を、図5に学習後のネットワークを用いた汎化結果を示す。図の縦軸は明るさ（照度）で、横軸は時間である。図中の二点鎖線が入力データで、破線が教師データ、実線がネットワークの出力結果である。

図4より、本ネットワークモデルが、すべての入力パターンに対して、教師データとほぼ同様の値を出力していることが確認できる。ただし、すべての教師データは時間の経過に伴い、その主観的明るさの値が入力値に近づく傾向が見られる。一方、本ネットワークモデルでは、主観的明るさはピーク値を示した後、徐々に減少するものの、その後一定の値に収束している。この原因については、学習データが3パターンしか用意できなかったこと、またBroca-Sulzerの実験が、0.36秒までの測定値しか記録していなかったため、それ以降の収束状況を学習データとして与えられなかったことが挙げられる。しかし、それ以外に関しては、教師データの特徴を十分に獲得していることから、良好な学習結果といえる。

また、図5より、ネットワークの汎化後の出力が教師データと比較して早く応答している。これは、図4の時間0.5～0.85秒の応答（入力データが照度64.5 luxのステップ光）について、ネットワークが教師データよりも早く出力応答を示すように学習したため、このような結果になったと考えら

図2 Apparent brightness of flashes with various luminances, as a function of flash duration [10] [13]

図3 Network structure

れる。しかし、応答の際の立ち上がり、すなわちオーバーシュートについての特徴を捉えているといえる。

さらに、Broca-Sulzer の実験では与えられていない、入力値 75 lux と 150 lux が呈示されたときの、主観的明るさ

図4 The result after training

図5 The test result (adaptation)

図6 The test result (prediction)

図7 Synaptic weights after training

の変化をニューラルネットワークに予測させた。その結果を図6に示す。この図の出力は、あくまで予測値であり正解は確認できないが、図4の学習結果の特徴を捉えた予測をしていることがわかる。これらの結果から、このネットワークは人間の時間的変化を伴う主観的明るさ知覚の一つである明順応を表現する機能を内部に獲得しているといえる。

5. 明順応モデルの内部解析

人間に特有な明順応現象を学習させたネットワークの内部構造を解析する。これによって、人間の視神経から脳内部における主観的な明るさ知覚の処理構造の解明につながる。

5.1 視覚情報処理とネットワーク内部との比較

図7に本研究に用いたネットワークの学習後の各ユニットにおける結合荷重を示す。図7の結合荷重は、結合荷重の初期値を任意に変えて学習させた中で、学習・汎化結果がともに良好であったものを採用している。各ユニットに接している丸印が結合荷重で、白は正、黒は負を表し、その大きさが絶対値である。

ここで、ユニット d, e, h について、その結合荷重に注目すると、中間層のあるユニットからの入力以外は、全て負の値になっていることがわかる。すなわち、ユニット d, e, h は、ある1つのユニットからの入力のみを強調し、それ以外のユニットからの情報を抑制している。これは、生物の神経系によく見られる側抑制 [11] [14] という現象と類似している。

図8に側抑制の概要を示す。図中において白丸が正、黒丸が負の結合荷重を表す。図中のユニット A_2 について注目すると、ユニット A_1 からの入力は正の結合荷重が掛かっているが、 B_1 , C_1 からの入力は負の結合荷重が掛けられている。すなわち、ユニット B_1 , C_1 の出力信号によって A_2 の出力が抑制されているといえる。言い換えると、ユニット A_2 はユニット A_1 の出力を強調しているともいえる。この関係はユニット B_2 , C_2 についても同じことがわかる。

このような、あるニューロンの発火が他のニューロンの発火を抑制するように働く現象を側抑制という。側抑制は視神

図8 Lateral inhibition

経に限らず、聴覚、触覚、温度感覚など各種の感覚系に見られる基本的な機能で、視神経系においては、反射光のコントラストの情報を得る役割を果たす。

また、ユニット a, b, d, e, f, h の自己フィードバックの結合荷重を比較してみると、ユニット a, b, h はおよそ 8.5 ~ 13.0 の値を取るのに対して、ユニット d, e, f はおよそ -0.2 ~ 0.7 の値を取り、前者は後者に比べてかなり大きな値であることがわかる。特に、ユニット a, b, h の自己フィードバックの結合荷重は、その他のユニットからの結合荷重よりも大きく、ユニット d, e, f の自己フィードバックの結合荷重は、その他のユニットからの結合荷重よりも小さい。自己フィードバックの結合荷重が大きいと、そのユニットの過去の出力を保持するため、他のユニットからの入力に対して応答が遅くなると考えられる。逆に、結合荷重が小さければ、過去の影響をあまり受けずに、他のユニットからの入力に対して素早く応答すると考えられる。よって 3.2 節で述べているように、ユニット a, b, h については、視細胞における応答特性が鈍い杆体の機能を、ユニット d, e, f については、応答特性が鋭い錐体の機能を、部分的に獲得しているといえる。

これらの結果から、このネットワークは人間の視覚神経ネットワークの一部分を、単純化することによって再現しているといえる。

6. ま と め

本研究では、時系列処理ユニットを取り入れた動的ニューラルネットワークを用いて、人間の時間的変化を伴う主観的明るさ知覚である明順応モデルの実現性を検討した。その結果、このモデルが、ある強度のステップ光の入力に対する主観的な明るさ知覚の時間的変化 (Broca-Sulzer 効果) を学習していることを確かめた。さらに、学習後のネットワークの内部解析をすることによって、このネットワークモデルが Broca-Sulzer 効果を表現するうえで、以下に示す役割を果たしているユニットを確認した。

- (1) 生物の神経系に存在する基本的構造である側抑制をするユニットが形成される。
- (2) 人間の網膜内に存在する視細胞である杆体、錐体に類似する機能を有するユニットが存在する。

これらの結果から、本研究で構築した明順応モデルが、人間の視覚神経ネットワーク上にある一部の機能を、単純化することによって獲得していることを確認した。

現段階での明順応モデルは、ネットワーク構造も非常に単純であり、人間の光刺激に対する主観的な明るさを完全にモデル化しているとはいえないが、その中で動的ニューラルネットワークを用いることによって、人間の感覚処理機構を部分的に再現できる可能性があることを確かめた。このこと

は、人間の知覚処理モデルを構築する上での、重要なステップになると考える。

今後、本モデルの入力光のバリエーションを増やし、出力する主観的明るさをより詳細な情報を持つものに改善することにより、明順応についての新しい知見が得られるものと考ええる。特に錐体については、光の波長によって異なる感度を持つものが 3 種類存在する。(それぞれを、R-錐体、G-錐体、B-錐体という。) それらの特徴を学習するネットワークモデルを構築することによって、より深く明順応現象の生成過程を検討することが重要となる。また、本研究で扱った明順応は、人間の明るさ知覚に対する時間的特性のひとつに過ぎない。より人間の視覚神経ネットワークに近づけるためには、明るさに対する知覚だけではなく、色覚や輪郭抽出などの視覚における様々な処理機構についてモデル化し、それらをひとつずつ積み重ねていく必要がある。今後は、そのひとつひとつをモデル化していく予定である。

なお、本研究の一部は、文部科学省科学研究費・若手研究 (B) #19700209 の補助を受けた。記して謝意を表す。

参 考 文 献

- [1] 一松信, 村岡洋一, 感性と情報処理—情報科学の新しい可能性—, 共立出版株式会社, pp.3-26, (1993).
- [2] 井口征士, 田辺新一, 他 4 名, 感性情報処理, オーム社, pp.1-11, (1994).
- [3] 鈴木英明, 松崎吉衛, 藤川恵一, 感性学習機能を備えたフレンドリーな形状デザインシステムの試作, 電気学会論文集 D 編, 111 巻, 12 号, pp.1031-1037, (1991).
- [4] 長田典子, 亀井光仁, 他 2 名, 感性計測技術に基づく真珠品質評価システムの開発, 電気学会論文集 C 編, 112 巻, 2 号, pp.111-116, (1992).
- [5] 大西巖, 木村一郎, 他 2 名, ニューラルネットワークを用いた音色に対応する感性モデル, 日本機械学会論文集 C 編, 66 巻, 652 号, pp.3977-3983, (2000).
- [6] 小松由香, 亀井且有, 感性工学にもとづくハンカチデザインの評価, 電気学会論文集 C 編, 117 巻, 7 号, pp.934-939, (1997).
- [7] 塚田章, 川原田淳, 佐々木和男, ヒト視覚系の時間特性に関するモデル, 電子情報通信学会技術報告, MBE96-21, pp.141-147, (1996).
- [8] S.Kawamura, Photoreceptor light-adaptation mediated by S-modulin, a member of a possible regulator family of protein phosphorylation in signal transduction, Neuroscience Res.20, pp.293-298, (1994).
- [9] 大西巖, 木村一郎, 他 2 名, 音楽コード進行の時系列変化に対応する感性モデル, 日本機械学会論文集 C 編, 67 巻, 657 号, pp.1315-1321, (2001).
- [10] A.Broca, D.Sulzer, La Sensation Lumineuse en Fonction du Temps, Journal of Physiology, pp.632-640, (1902).

- [11] P.H.リンゼイ, D.A.ノーマン, 中溝幸夫他訳, 情報処理心理学入門Ⅰー感覚と知覚ー, サイエンス社, pp.63-68, pp.98-99, (1983).
- [12] 福島邦彦, 大串健吾, 斎藤秀昭, 視聴覚情報処理, 森北出版, pp.16-19, pp.12-13, (2001).
- [13] 福田忠彦, 生体情報システム論, 産業図書, p.79, (1995).
- [14] 石川友衛, 神経生理学・第3版, 医歯薬出版, pp.88-90, (1977).

大西 蔵 (正会員)

1996年大阪電気通信大学大学院・工学研究科博士課程(前期)修了, 同年徳山工業高等専門学校・機械電気工学科助手, 2004年長岡技術科学大学・技術開発センター講師,

2006年広島国際大学・心理科学部・感性デザイン学科講師となり現在に至る. 感性モデルの構築, 生体情報を用いた感性の定量評価, ニューラルネットワークの応用などの研究に従事. 博士(工学).

本居 宣久 (非会員)

2002年徳山工業高等専門学校専攻科・機械制御工学専攻卒業, 2004年京都工芸繊維大学大学院・工芸科学研究科・博士前期課程修了, 同年, 松下電器産業株式会社に入社, 現在に至る. 在学中は感性工学, ヒューマンインタフェースに関する研究に従事.

木村 一郎 (正会員)

1968年神戸大学工学部計測工学科卒業, 光洋精工(株)を経て, 1972年同大学大学院工学研究科修士課程修了, 同年神戸大学工学部助手, 1984年助教授, 1993年大阪電気通信大学教授となり現在に至る. 流れの画像計測, 計測の推定問題, ニューラルネット応用などの研究に従事.

1999年可視化情報学会学会賞(論文賞)受賞. (工学博士).