

情報統合の神経回路モデルを用いたヒューマノイドの 全身リーチング姿勢の決定

杉村 僚介[†] 香川 高弘[†] 田地 宏一[†] 宇野 洋二^{†a)}

Posture Determination of a Humanoid in Whole Body Reaching Movements Using
a Neural Network Model for Information Integration

Ryosuke SUGIMURA[†], Takahiro KAGAWA[†], Kouichi TAJI[†], and Yoji UNO^{†a)}

あらまし 多自由度をもつヒューマノイドには、システムの冗長性により、関節角などの「姿勢情報」とカメラ画像などからの「視覚情報」との間に多対多の関係がある。特に、全身を使ってターゲットに手を伸ばすリーチングでは、体幹を傾けることによるカメラ画像の変化やロボットの転倒の危険性を考慮して、姿勢を設計する必要がある。本論文では、全身リーチングの姿勢を腕のリーチング姿勢と体幹姿勢の二つの部分に分け、それぞれに対して砂時計型の多層ニューラルネットワークを構成する。まず、二つのネットワークを個別に学習させて、視覚情報と姿勢情報とを統合する。このとき、リーチングに関する特徴量が中間層の一部のニューロンに抽出される。十分な学習の後に二つのネットワークを結合し、ニューラルネットの緩和計算により全身リーチング姿勢を決定する。提案のニューラルネットモデルは、学習時に抽出された特徴量を利用することによって、リーチング姿勢の変更が可能であり、冗長性に起因する多対多の問題を扱うことができる。最後に、計算機シミュレーション及び実験を行って、提案手法の有効性を確認した。

キーワード 感覚運動統合, ニューラルネットワーク, 情報抽出, 全身リーチング, ヒューマノイド

1. ま え が き

近年、ヒューマノイドロボットに対して、人間と同様に感覚情報をもとに全身の動作を制御することが行われるようになった。多くの研究ではユーザがロボットのタスク座標の全てを設計していた。一方で、人間の生活空間は複雑であり、ユーザが全てを設計することは困難である。そのような環境では、ユーザにより設定されたタスク座標がロボットに対して適切な表現となるとは限らない。

運動タスクを実行するための適切な表現は、感覚情報、特に視覚情報をもとにどのようにして得ることができるのであろうか。ここで、目の前の物体へと腕を伸ばすリーチングにおいて、手先がターゲットに届くときの身体姿勢を決定する問題を取り上げる。これまで多くのロボットアーム制御では、ターゲットに関す

るカメラ座標から、作業空間における三次元位置を幾何学的に計算してリーチングを実行する。しかしながら人間のリーチングでは、脳が三次元空間におけるターゲットの正確な座標値を知ることはない。たとえ学習によって、ターゲットの網膜座標から三次元空間座標への変換を獲得しようとしても、教師信号としてのターゲットの三次元位置情報は得られない。脳が学習で利用できる情報は、手先をターゲットへと移動する試行で網膜に投影されたターゲットの座標と手先の座標、及び体幹、腕、脚の姿勢情報である。それゆえ、ニューラルネットワークの学習によって、「ターゲットの視覚情報」と「身体の姿勢情報」を結び付け、リーチングに必要な不可欠な特徴量を抽出するメカニズムを考える。

若城、福村らはニューラルネットワークにより視覚情報と運動情報を統合するモデルを提案し、4脚ロボットが障害物に足を載せる動作姿勢を生成した [1], [2]。伊藤らは、このネットワークを応用し、転がってくるボールを狙った方向に蹴るというタスクに対して視覚の時系列データから運動情報の推定を行った [3]。ま

[†] 名古屋大学大学院工学研究科, 名古屋市
Graduate School of Engineering, Nagoya University, Furo-cho, Chikusa-ku, Nagoya-shi, 464-8603 Japan
a) E-mail: uno@nuem.nagoya-u.ac.jp

た、我々はこれまでに若城らの手法を用いてステレオカメラによる視覚情報と腕の関節角度の情報の統合を行い、三次元空間における腕のリーチング姿勢の推定を行った [4].

本論文では、ヒューマノイドロボットのリーチングにおいて、手先がターゲットに届く身体姿勢を決定することを目的とし、視覚情報と関節角情報を統合するニューラルネットワークモデルを提案する。このニューラルネットワークの計算は、ロボットのリーチングにおける終端の姿勢を決定するもので、全身の静的なバランスも考慮しなければならない。すなわち、全身リーチングでは体幹を傾けるため、カメラの位置・角度の変化による視覚の変化や足底の圧力中心 (COP) の移動によるロボットの転倒の危険性 [5] があるので、より多くの情報を利用して姿勢を設計する必要がある。

以下 2. では感覚運動統合を行うネットワークについて説明し、3. ではロボットモデルを用いたシミュレーション実験の結果を示す。また、4. ではヒューマノイドロボットを用いた実機実験の結果を示し、最後に 5. で提案法の有効性と問題点について議論する。

2. 情報統合のネットワーク

多自由度をもつロボットの全身リーチングでは、ターゲットに対する視覚情報はロボットの姿勢によって変化する。また、あるターゲットに対してリーチングを行う関節角度の組合せは可動範囲内に複数存在する。すなわちシステムの冗長性により、視覚情報と姿勢情報の間には多対多の関係が存在する。通常のフィードフォワードネットワークでは、このような多対多の関係を学習することは困難である。例えば、フィードフォワードネットワークに手先の視覚情報 \mathbf{x} を入力し、腕の関節角情報 \mathbf{y} を出力するように学習する場合を考える。この場合、ある視覚情報 \mathbf{x}^1 に関して、複数の学習データ $(\mathbf{x}^1, \mathbf{y}^1)$, $(\mathbf{x}^1, \mathbf{y}^2)$, \dots , $(\mathbf{x}^1, \mathbf{y}^n)$ があり得るので、ネットワークの学習後には、おおむね教師信号 $\mathbf{y}^1, \mathbf{y}^2, \dots, \mathbf{y}^n$ の平均に近い値 \mathbf{y}^* が出力されるようになるだろう。しかしながら、 \mathbf{x} と \mathbf{y} は非線形な関係であるので、対 $(\mathbf{x}^1, \mathbf{y}^*)$ がロボットシステムの正しい関係に含まれるとは限らない。それゆえ、学習をどれだけ繰り返してもかなり大きな出力誤差が残ることとなる。多対多の関係を多層のネットワークに埋め込むための一つのアイデアは、視覚情報も姿勢情報も共に入力層に送って二つの情報を統合することである。しかしながら、異なる二つの情報を単純にネット

ワーク内で混ぜるだけでは、有用な表現を得ることはできない。手先がターゲットに届く姿勢を求めるための必要不可欠な内部表現が獲得されるように、ネットワーク内の情報処理を行うことが求められる。そのための一つの方法は情報圧縮であり、砂時計型ニューラルネットワークを利用することである。

砂時計型ニューラルネットワークは恒等写像を学習する多層のネットワークであり、ある中間層のニューロンの数を入出力層のニューロンの数よりも少なくすることによって情報の圧縮をすることができる。Cottrellらは3層の砂時計型ネットワークを画像圧縮などに利用したが、第2層に抽出されるのは線形な内部表現である [6]。入江、川人は5層のネットワークへ拡張することにより、第3層に非線形な内部表現が獲得されることを示した [7]。更に、5層の砂時計型ネットワークはセンサ情報の統合 [8] や非線形主成分分析 [9] などの研究へも応用された。本研究では、視覚情報と姿勢情報の圧縮・統合のために、入力層から中間層、中間層から出力層に非線形な変換を必要とするので、5層の砂時計型ニューラルネットワークを用いる。そして、全身リーチング姿勢を「リーチングの腕姿勢」と「リーチング時の体幹姿勢」の二つのパートに分け、それぞれを砂時計型ニューラルネットワークで学習するモデルを提案する。2.1 で述べるように、腕のリーチングのネットワークでは、手先の視覚情報 \mathbf{x} と腕姿勢 \mathbf{y} の関係を学習することによって、手先座標に対応する特徴量が内部表現として獲得される。また、2.2 で述べるように、体幹姿勢のネットワークでは、ターゲットの視覚情報及び体幹姿勢 $\hat{\mathbf{x}}$ 、足圧センサ \mathbf{z} の関係を学習することによって、ターゲット座標、圧力中心 (COP) に対応する特徴量が獲得される。その後、学習を行った二つのネットワークを結合し、緩和計算によってリーチング時の体幹姿勢・腕姿勢を決定する (2.3)。

2.1 リーチングの腕姿勢ネットワーク

図1に腕のリーチングを行うネットワークモデルを示す。5層から成る砂時計型ネットワークが上下に二つあり、それぞれ第1層、第3層、第5層には線形ニューロン群、第2層、第4層にはシグモイド関数を用いた非線形ニューロン群を設定した。上部のネットワークには、視覚情報として、ロボットに搭載されているカメラからの画像情報と首関節の角度を入力する。画像情報には画素ベクトルが対応するが、ここでは簡単のため、画像処理後のターゲットの座標値を用いる

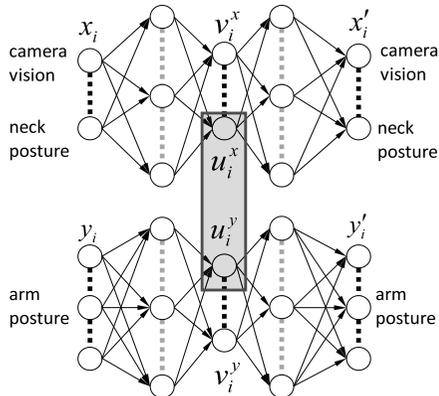


図1 リーチングの腕姿勢ネットワークの構造
Fig. 1 Structure of an arm posture network.

ことにする。また、首関節が動くとカメラ画像は変化するが、それによってロボットの手先が変動することはないので、本研究では首関節角度を視覚情報とみなす。一方、下部のネットワークには、腕の姿勢情報として腕の各関節角度を入力する。各情報は0~1で正規化され、ネットワークに入力される。ネットワークの学習には誤差逆伝搬法 (BP) を用いるが、学習を行うときに第3層の一部のニューロンの値 \mathbf{u}^x , \mathbf{u}^y が同じ値となるような拘束条件を課す。同じ値となるようにする第3層のニューロンを「拘束ニューロン」と呼ぶとすると、ここに二つのネットワークの共通した情報が特徴量として現れることが期待できる。このネットワークでは、手先の位置は視覚情報から求まるし、腕の関節角度からも求まる。よって、手先位置が上下のネットワークの共通情報となり、手先位置に関する特徴量が拘束ニューロンに抽出されることが考えられる。

以上、図1のネットワークにおいて、入力層から出力層への恒等写像、及び第3層のニューロンの拘束条件が共に満たされるように学習するため、パターン \mathbf{x} , \mathbf{y} に関する誤差関数 E_x , E_y を次式のように定める。

$$E_x = \sum_{i=1}^{N_x} (x'_i - x_i)^2 + \gamma_{u1} \sum_{i=1}^{N_u} (u_i^x - u_i^y)^2 \quad (1)$$

$$E_y = \sum_{i=1}^{N_y} (y'_i - y_i)^2 + \gamma_{u2} \sum_{i=1}^{N_u} (u_i^y - u_i^x)^2 \quad (2)$$

ここで、 x_i , y_i は各ネットワークの入力ニューロンの値、 x'_i , y'_i は出力ニューロンの値、 u_i^x , u_i^y は第3層の拘束ニューロンの値であり、 N_x , N_y , N_u は各ニューロンの数である。また、 γ_{u1} , γ_{u2} は第3層の拘束に対

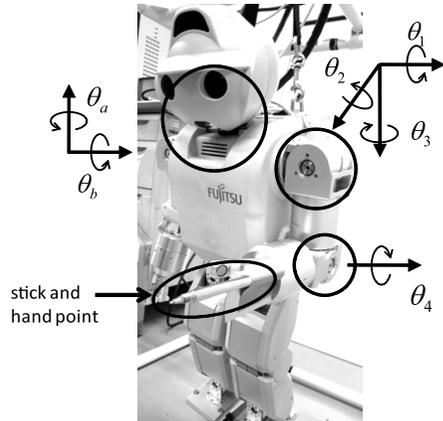


図2 腕姿勢ネットワークに入力する関節角情報
Fig. 2 Joint angles for an arm posture network.

する重みパラメータである。したがって、第1項は砂時計型ネットワークでの恒等写像の学習、第2項は拘束による情報統合の学習についての二乗誤差をそれぞれ表している。

誤差が十分に減少するまで学習を行ったネットワークでは、拘束ニューロンの値 \mathbf{u}^x , \mathbf{u}^y がほぼ同じ値となり、手先位置に対応する表現が抽出されると期待される。一方で、第3層の残りの拘束していないニューロン \mathbf{v}^x , \mathbf{v}^y は「非拘束ニューロン」と呼ばれ、それぞれ首姿勢の冗長性、及び腕姿勢の冗長性に対応する表現を担うことになる。

リーチングの腕姿勢ネットワークに入力する関節角を図2に示す。ここで、腕の長さや実機のカメラの視野の関係から、左手に持たせた10cmの棒の先にマーカー (小球) をつけて手先とした。画像情報として高次元の画素ベクトルを用いると、非常に多数のニューロンを用意する必要がありネットワークの学習の負担が大きくなる。そのため、カメラ画像上のマーカーの二次元的な位置を画像処理によりあらかじめ求めておき、手先の位置座標とした。したがって、視覚情報は左右のカメラ画像上の手先の位置座標 (2×2 次元) と首関節角 θ_a , θ_b (二次元) で、計 $N_x = 6$ 次元である。一方、腕の姿勢情報は肩関節角 $\theta_1 \sim \theta_3$ と肘関節角 θ_4 で、計 $N_y = 4$ 次元である。拘束ニューロン \mathbf{u}^x , \mathbf{u}^y には、三次元作業空間におけるターゲット位置の特徴量の抽出を期待し、 $N_u = 3$ とする。非拘束ニューロン \mathbf{v}^x , \mathbf{v}^y には、首姿勢、腕姿勢の冗長性に対応する特徴量が抽出されることを期待し、それぞれ二次元、一次元とする。第2, 4層のニューロン数は20とした。

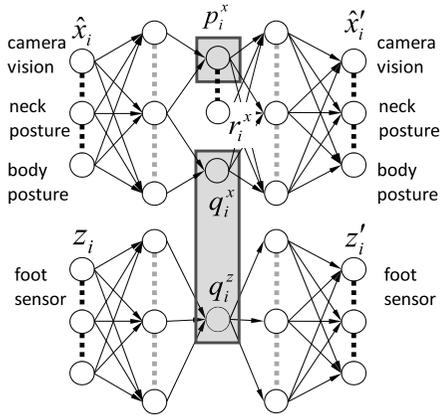


図3 体幹姿勢ネットワークの構造
Fig.3 Structure of a body posture network.

よって、各ネットワークのニューロン数をまとめると、それぞれ (6-20-5[3]-20-6), (4-20-4[3]-20-4) となる。ここで [] 内は拘束するニューロン数である。

2.2 体幹姿勢ネットワーク

図3に体幹姿勢のネットワークモデルを示す。これは上下に並べた二つの5層砂時計型ネットワークから成る。上部のネットワークには視覚情報(カメラ画像上のターゲット座標, 首姿勢)と体幹姿勢を入力し, かつ同じ値が出力されるように恒等写像の学習を行う。また, 下部のネットワークには足圧センサの情報を入力し, かつ同じ値が出力されるように恒等写像の学習を行う。図3の $\hat{\mathbf{x}}$ は, 図1の視覚情報 \mathbf{x} に体幹姿勢の情報を追加したものとなる。このネットワークでは, リーチングを行うロボットの接地点を基準としてターゲットの位置情報を第3層のニューロン \mathbf{p}^x に担わせる。ロボットシステムの冗長性により, 手先が同じ位置にあっても(視覚情報が同じでも)異なる姿勢をとり得る。今, m 個のパターン $\hat{\mathbf{x}}^1, \hat{\mathbf{x}}^2, \dots, \hat{\mathbf{x}}^m$ が姿勢は異なるものの, ある同じターゲット位置に手先があるものとする。これらのパターンを入力したとき, 「ターゲットの位置」は共通な情報であるはずであるから, 各パターンに対する第3層のニューロンの値 $\mathbf{p}^{x,1}, \mathbf{p}^{x,2}, \dots, \mathbf{p}^{x,m}$ が同じ値となるように拘束をかけることにする。また, 上部のネットワークに姿勢の情報 $\hat{\mathbf{x}}$, 下部のネットワークに足圧センサの情報 \mathbf{z} が入力されているので, 上下のネットワークに共通な情報はロボットの足裏のCOPとなる。よって, 二つのネットワークの第3層のニューロン $\mathbf{q}^x, \mathbf{q}^z$ が同じ値をとるように拘束することによって, COP に関す

る情報を担わせる。

以上より, 手先位置が同じで姿勢が異なる m 個のパターン $\hat{\mathbf{x}}^1, \hat{\mathbf{x}}^2, \dots, \hat{\mathbf{x}}^m$ に対応して, 次のような誤差関数 $E_{\hat{\mathbf{x}}}, E_z$ を定める。

$$E_{\hat{\mathbf{x}}} = \sum_{\alpha=1}^m \left\{ \sum_{i=1}^{N_{\hat{\mathbf{x}}}} (\hat{x}'_i{}^{\alpha} - \hat{x}_i{}^{\alpha})^2 + \gamma_{q1} \sum_{i=1}^{N_q} (q_i^{x,\alpha} - q_i^{z,\alpha})^2 + \gamma_p \sum_{\beta \neq \alpha} \sum_{i=1}^{N_p} (p_i^{x,\alpha} - p_i^{x,\beta})^2 \right\} \quad (3)$$

$$E_z = \sum_{\alpha=1}^m \left\{ \sum_{i=1}^{N_z} (z'_i{}^{\alpha} - z_i{}^{\alpha})^2 + \gamma_{q2} \sum_{i=1}^{N_q} (q_i^{z,\alpha} - q_i^{x,\alpha})^2 \right\} \quad (4)$$

ここで, ある姿勢パターン $\hat{\mathbf{x}}^{\alpha}$ に対応する足圧センサの情報 \mathbf{z}^{α} とし, これらをネットワークへ入力したときの各ニューロンの値は, 添字 α を付けて表してある。式(3)第3項の $p_i^{x,\alpha}, p_i^{x,\beta}$ はそれぞれパターン $\hat{\mathbf{x}}^{\alpha}$, あるいは $\hat{\mathbf{x}}^{\beta}$ をネットワークへ入力したときの \mathbf{p}^x の i 番目のニューロン値を表す。ただし, $\hat{\mathbf{x}}^{\alpha}$ と $\hat{\mathbf{x}}^{\beta}$ は, 手先位置が同じで姿勢が異なり, 第3項ではこれらの異なる組合せ全てに対して, ニューロン \mathbf{p}^x での誤差をとる。なお, $\gamma_p, \gamma_{q1}, \gamma_{q2}$ は, それぞれの拘束に対する重みパラメータである。

最終的にネットワークの学習では, 手先位置が同じで姿勢が異なる全てのパターンの組について式(3), 式(4)と同様の誤差関数を設定し, それらが最小となるように結合荷重を調整する。学習が十分収束すれば, 拘束ニューロン \mathbf{p}^x と $\mathbf{q}^x = \mathbf{q}^z$ にそれぞれ位置の情報とCOPの情報が抽出されることが期待できる。また, ネットワークの第3層で拘束されていない残りの「非拘束ニューロン」 \mathbf{r}^x は, 体幹姿勢, 首姿勢の冗長性に対応する表現を担うことになる。

体幹姿勢ネットワークに入力する関節角を図4に示す。入力する視覚情報は腕姿勢ネットワークと同様で, 左右のカメラ画像上の手先の位置座標 (2×2 次元) と, 首関節角 θ_a, θ_b (二次元) の計六次元である。これに体幹姿勢として, 腰関節 θ_c と膝関節 θ_d が加わり, 合計次元は $N_{\hat{\mathbf{x}}} = 8$ となる。また, 足圧センサは左右それぞれ四つずつ搭載されているため $N_z = 8$ である。各情報は $0 \sim 1$ で正規化され, ネットワークに入力される。拘束ニューロン p^x には, ターゲット位置の三次元の特徴量が抽出されることを期待して, $N_p = 3$ とする。もう一方の拘束ニューロン q^x, q^z には, COP

の特徴量が抽出されることを期待し、かつ体幹が前後方向のみ可動であると仮定して $N_q = 1$ とする. 残りの非拘束ニューロン \mathbf{r}^x には, 首, 体幹姿勢の冗長

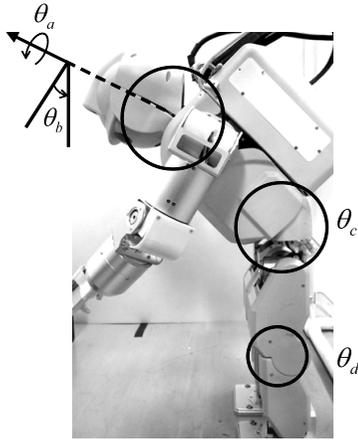


図 4 体幹姿勢ネットワークに入力する関節角情報
Fig. 4 Joint angles for a body posture network.

性に対応する特徴量が抽出されることを予想し, 三次元とする. 各ネットワークのニューロン数をまとめると, それぞれ (8-20-7[3,1]-20-8), (8-20-1[1]-20-8) となる. ここで [] 内は拘束するニューロン数である.

2.3 全身リーチング姿勢の決定

カメラの画像上のターゲット位置の座標値と首の関節角情報が与えられたときに, 全身リーチングの終端姿勢を決定する問題を扱う. システムの冗長性により手先がターゲットに届く姿勢は無数にあり得るが, タスクに応じて適当な評価関数を定めることにより最適姿勢を求めることにする. 更に, 関節角の可動範囲や転倒防止の条件も満たさなければならないので, 結局, 全身リーチング姿勢を決定することは拘束条件付き最適化問題となる. ここでは, 2.1 のリーチング腕姿勢のネットワークと 2.2 の体幹姿勢のネットワークをそれぞれ十分学習させた後, その結合荷重を固定する. そして図 5 に示すように, この二つのネットワー

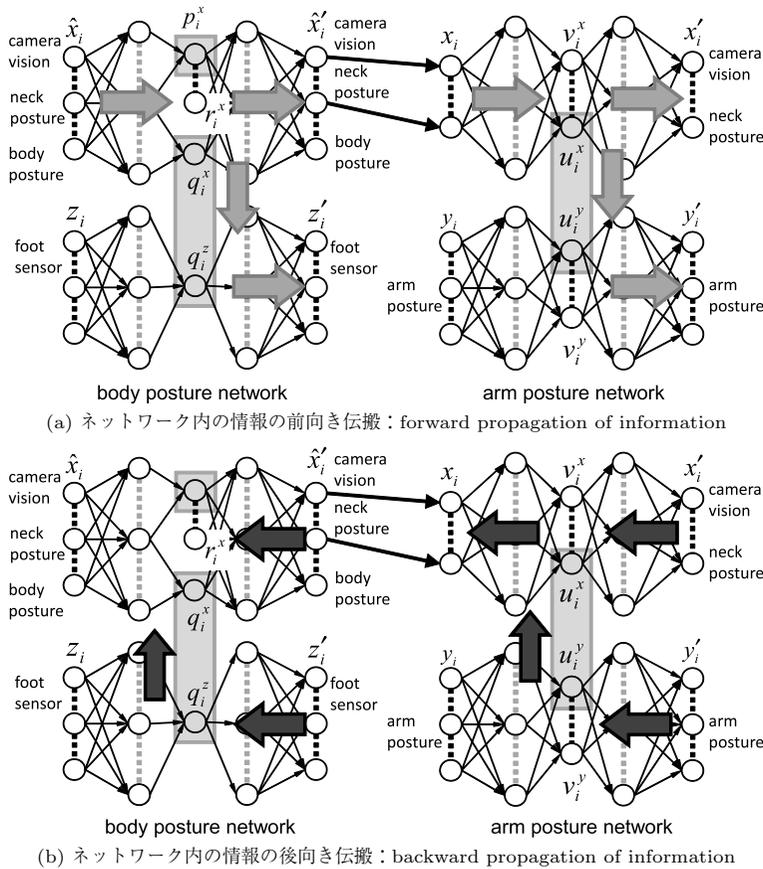


図 5 全身リーチング姿勢を決定するネットワーク内の情報の流れ

Fig. 5 Neural computation to generate whole body reaching posture.

クを結合させて、ニューラルネットの緩和計算によりこの最適化問題を解く。緩和計算において、ニューラルネットが最小にすべきコスト関数（いわゆるエネルギー関数）を C とすると、 C は最適性を表す評価関数 C_p と拘束条件を表す関数 C_b の和である。

$$C = C_p + C_b \quad (5)$$

C_p はリーチングタスクに応じて定めることになるが、その具体的な関数形については、後の 3. で紹介する。拘束条件である関節角度の上下限、及び転倒防止のための COP に関する条件は不等式で表されるので、バリア関数を導入して C_b を定める。すなわち、ネットワークの入出力ニューロンの値 $\mathbf{x}, \mathbf{y}, \hat{\mathbf{x}}, \mathbf{z}$ と COP に関する拘束ニューロンの値 \mathbf{q}^x の関数として、次のように C_b を定義する。

$$C_b = B_1(\mathbf{x}) + B_1(\mathbf{y}) + B_1(\hat{\mathbf{x}}) + B_1(\mathbf{z}) + B_2(\mathbf{q}^x) \quad (6)$$

ただし、 $\mathbf{x}, \mathbf{y}, \hat{\mathbf{x}}, \mathbf{z}$ については 0~1 で正規化されているため、上下限を 0, 1 としたバリア関数 B_1 を用い、 \mathbf{q}^x については上下限を学習時の最大値 \mathbf{q}^{\max} 及び最小値 \mathbf{q}^{\min} としたバリア関数 B_2 を用いる。

$$B_1(\mathbf{x}) = \sum_{i=1}^{N_x} \left\{ \left(\frac{1}{x_i} \right)^2 + \left(\frac{1}{1-x_i} \right)^2 \right\} \quad (7)$$

$$B_2(\mathbf{q}^x) = \sum_{i=1}^{N_q} \left\{ \left(\frac{1}{q_i^x - q_i^{\min}} \right)^2 + \left(\frac{1}{q_i^{\max} - q_i^x} \right)^2 \right\} \quad (8)$$

以下で述べるように緩和計算では、ネットワーク内で情報を前向きに伝搬させる計算と後向きに伝搬させる計算とを繰り返して、コスト関数 C を最小にすることにより、最適な全身リーチング姿勢を求める。

はじめに、ターゲットをカメラで捉えたときのネットワーク内の情報の前向きの流れを図 5(a) の灰色の矢印で示す。ターゲットに関する視覚情報及び、体幹姿勢の情報を $\hat{\mathbf{x}}$ として左側の体幹姿勢ネットワークへ入力する。そして中間層のニューロン $\mathbf{p}^x, \mathbf{q}^x, \mathbf{q}^z, \mathbf{r}^x$ を経由し、 $\hat{\mathbf{x}}', \mathbf{z}'$ の出力を行う。ここで留意すべきことは 2.2 で述べたように、 \mathbf{p}^x がロボット接地点からのターゲットの相対的な位置情報をコードし、拘束ニューロン $\mathbf{q}^x = \mathbf{q}^z$ がロボット足裏の COP 情報をコードしていることである。体幹姿勢ネットワークの出力 $\hat{\mathbf{x}}'$ のうち、リーチング腕姿勢と関係する視覚を \mathbf{x} とし、右側のリーチング腕姿勢ネットワークへ入力

する。そして中間層のニューロン $\mathbf{u}^x, \mathbf{u}^y, \mathbf{v}^x, \mathbf{v}^y$ を経由して、 \mathbf{x}', \mathbf{y}' が出力される。ここで留意すべきことは 2.1 で述べたように、拘束ニューロン $\mathbf{u}^x = \mathbf{u}^y$ がターゲットのカメラからの相対的な位置情報をコードしていることである。

上記のようにして、ネットワークが 1 回の前向き計算で求めたリーチングの腕姿勢や体幹姿勢は通常、最適な姿勢とはならないので、ニューロンの値を変更して、拘束条件を満たし評価関数が最小となる姿勢を求めなければならない。そこで、式 (5)~(8) で定めたコスト関数 C がより小さな値になるようにニューロン値を修正していく（ネットワーク内のこの情報処理は図 5(b) の黒色の矢印に対応する）。ニューロン値を修正して姿勢を変更したときにも、手先がターゲットに届いていなければならないが、これはターゲットの位置に関する特徴量をコードするニューロン \mathbf{p}^x と \mathbf{u}^y ($= \mathbf{u}^x$) の値を固定することによって保証される。したがって、COP に関する情報を表現する \mathbf{q}^x ($= \mathbf{q}^z$) の値と、システムの冗長性を担う \mathbf{r}^x と \mathbf{v}^y の値を修正することによってコスト関数 C を減少させることにする。ニューロン値の修正量 $\Delta \mathbf{q}^x, \Delta \mathbf{r}^x, \Delta \mathbf{v}^y$ は次式のように最急降下法を用いて求められる。

$$\Delta \mathbf{q}^x = -\epsilon_q \frac{\partial C}{\partial \mathbf{q}^x} \quad (9)$$

$$\Delta \mathbf{r}^x = -\epsilon_r \frac{\partial C}{\partial \mathbf{r}^x} \quad (10)$$

$$\Delta \mathbf{v}^y = -\epsilon_v \frac{\partial C}{\partial \mathbf{v}^y} \quad (11)$$

上式の右辺は微分のチェインルールで計算できる。すなわち、この修正量は学習における誤差逆伝搬法と同様にして求められ、 $\epsilon_q, \epsilon_r, \epsilon_v$ はそのときの学習率に相当する。2.1, 2.2 のネットワークの学習では、結合荷重を修正することにより出力情報を調整し多対多の情報変換を獲得するが、ここでは学習後のネットワークにおいて、結合荷重を固定したまま一部のニューロンの値を修正することによって出力情報を調整する。よって、このニューロンの修正を行う情報の流れは出力層から入力層への後向きの伝搬であり、図 5(b) の黒色の矢印のようになる。

以上、ニューラルネットの緩和計算では、図 5(a), (b) の $\mathbf{p}^x, \mathbf{q}^x, \mathbf{r}^x$ から始まる灰色の矢印と黒色の矢印の情報変換を繰り返し行う。そして、式 (9), (10), (11) の修正 $\Delta \mathbf{q}^x, \Delta \mathbf{r}^x, \Delta \mathbf{v}^y$ がほとんどなくなり、ネットワークの緩和計算が終了したとき、出力層の \mathbf{y}'

にリーチングの腕姿勢, $\hat{\mathbf{x}}'$ の一部のニューロンに体幹姿勢が表現されて, 全身リーチング姿勢が決定される.

さて, 入出力ニューロンのバリア関数は関節の可動範囲や視野範囲に対応するとともに, 学習範囲外のデータに対してリーチング不可能な姿勢が生成されることを防ぐ. また, \mathbf{q}^x には COP の特徴量が獲得されており, \mathbf{q}^x に対する上下限を設定することによってロボットが転倒するような姿勢の生成を防ぐ. バリア関数を含めたコスト関数を用いるためには, 目的変数をあらかじめ制約内に指定する必要がある. ここで, リーチングを行うために体幹姿勢の変更が必要となるターゲットの場合を考える. 入力情報を前向きに計算すると, 腕リーチングのネットワークにはリーチング不可能なターゲットに対する情報が入力されるため, 関節可動範囲を超えるような姿勢が出力される可能性が高い. このため, 次式のような四次関数 F_1 , F_2 を用いたコスト関数 C_0 を用いて事前計算を行い, C の緩和計算で用いる \mathbf{q}^x , \mathbf{r}^x , \mathbf{v}^y の初期値を求める.

$$C_0 = F_1(\mathbf{x}) + F_1(\mathbf{y}) + F_1(\hat{\mathbf{x}}) + F_1(\mathbf{z}) + F_2(\mathbf{q}) \quad (12)$$

ここで, 入出力ニューロンについての四次関数 F_1 及び COP に関する拘束ニューロン \mathbf{q}^x についての四次関数 F_2 をそれぞれ次式のようにする.

$$F_1(\mathbf{x}) = \sum_{i=1}^{N_x} (x_i - 0.5)^4 \quad (13)$$

$$F_2(\mathbf{q}^x) = \sum_{i=1}^{N_q} \left(q_i^x - \frac{q_i^{max} + q_i^{min}}{2} \right)^4 \quad (14)$$

四次関数はバリア関数と違い制御変数が制約を満たすことは保証されないが, 制約外においても中心向きのこう配をもっており, これをコスト関数として事前計算を行うことにより, 対象となるニューロンが制約を満たすような出力を生成できる. また, C_0 の事前計算後においても対象となるニューロンが制約を満たさない場合は, そのターゲットに対する自立可能なリーチング姿勢がそもそも存在しないと考えることができる.

3. シミュレーション実験

提案するネットワークモデルの有用性を検証するためにシミュレーション実験を行った. 腕リーチングネットワークの学習に用いる教師信号は以下のように関節角度を動かして手先に対する視覚情報を取得し

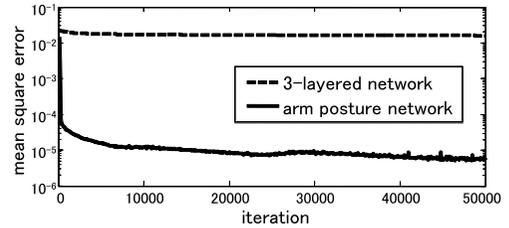


図 6 提案の腕姿勢ネットワークの学習曲線 (実線) と通常の 3 層のネットワークの学習曲線 (点線)

Fig. 6 Learning curves for the proposed arm posture network (solid line) and the usual 3-layer network (dashed line).

た. 首関節 θ_a , $-30^\circ \sim 50^\circ$ (9 通り), θ_b , $-34^\circ \sim 15^\circ$ (8 通り), 腕関節 θ_1 , $-30^\circ \sim 90^\circ$ (7 通り), θ_2 , $0^\circ \sim 80^\circ$ (5 通り), θ_3 , $-10^\circ \sim 70^\circ$ (5 通り), 肘関節 θ_4 , $-80^\circ \sim 0^\circ$ (5 通り). この組み合わせは 63000 通りあるが, この中で左右両方のカメラに対して視覚情報を取得することができたものが 1651 通り存在し, これを教師信号とした. また, 体幹姿勢ネットワークでは, 36 個のターゲットに対して以下のように関節角度を動かして, その時の視覚情報及び足圧センサ情報を取得した. 首関節 θ_a , $-30^\circ \sim 50^\circ$ (11 通り), θ_b , $-33^\circ \sim 15^\circ$ (9 通り), 腰関節 θ_c , $0^\circ \sim 90^\circ$ (16 通り), 膝関節 θ_d , $0^\circ \sim 30^\circ$ (7 通り). 学習に用いるのは, このうち「両眼カメラにターゲットが写っている」, 「COP が足裏に存在 (転倒していない)」の二つの条件を満たしているデータであり, 合計 3663 点存在した. どちらのネットワークも BP による学習を 50000 回行い, 誤差が十分に減少したことを確認した.

なお, 2. で述べたように, 通常のフィードフォワードネットワークでは, 一つの入力情報に対して出力に複数の教師信号が存在するような関係をそのまま学習することは困難である. 図 6 には, 3 層のニューラルネットに上記と同じトレーニングデータを用いて腕の姿勢情報が出力されるように学習した場合の学習曲線 (点線) を示すが, 学習を繰り返しても大きな出力誤差が残っている. これに対して, 本研究で提案の腕姿勢ネットワークの学習では, 誤差がスムーズに減少している (実線).

十分に誤差が減少するまで学習を行った後の拘束ニューロンの出力値を図 7 に示す. 図 7(a) には教師信号として用いた 36 点のターゲットが示されており, 図 7(b) にはそれらの位置情報が抽出された拘束ニューロンの値 \mathbf{p}^x (三次元) がプロットされている.

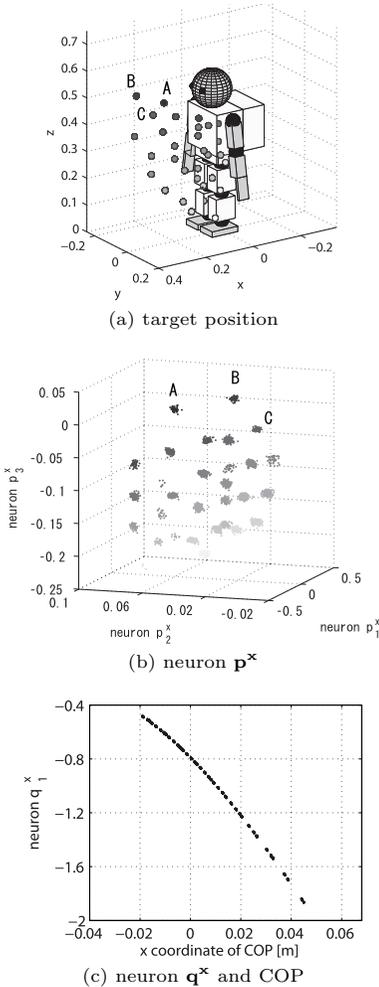


図 7 拘束ニューロンと特徴量の関係
Fig. 7 Relation between extract neuron and feature quantity.

例えば、(a) のターゲット A に対して、(b) には拘束ニューロンの値 p^x が示されている。これは手先が A に届く異なる複数の姿勢が対応して、わずかにばらつきのある点の固まりを形成している。(a) のターゲット B, C についても、それぞれ (b) の B, C の点の固まりが対応する。更に、他のターゲットに対しても同様であり、それぞれのターゲットに対して拘束ニューロンの値 p^x は独立に分布している。ここで、それぞれの固まりの点の広がりには p^x の拘束に対する学習誤差に対応する。また、図 7(c) は、COP に対応するニューロンの値 q^x と関節角度からキネマティクスによって得られる COP の x 座標の関係をプロットした

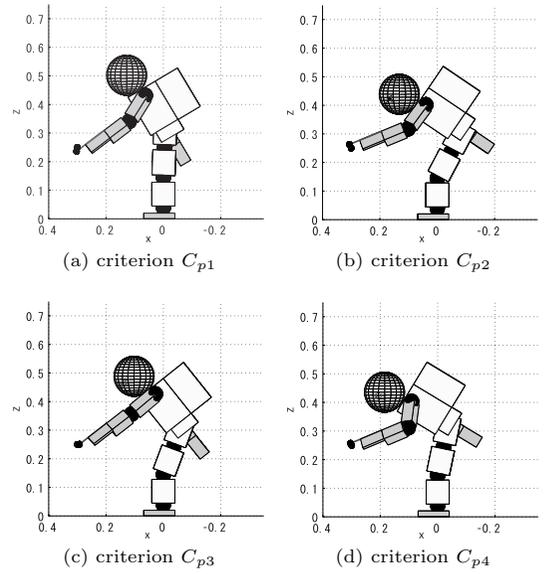


図 8 ロボットモデルの全身リーチング姿勢
Fig. 8 Whole body reaching postures of robot model.

ものである。図のように、COP の x 座標の値に対し、 q^x が単調減少になっている（学習時の結合荷重の初期値によっては単調増加となる場合もある）。このように p^x , q^x とともに抽出される情報であるターゲットや COP に対して一対一に対応する表現が得られた。

上記の学習及び特徴量の抽出後、緩和計算を用いてリーチング姿勢を決定した。今回のシミュレーション実験では、 C_{p1} ：体幹を伸ばす。 C_{p2} ：体幹を曲げる。 C_{p3} ：腕を伸ばす。 C_{p4} ：腕をたたむ。という四つの評価関数を用いて、出力される姿勢を比較する。それぞれの評価関数は次のようになる。

$$C_{p1} = \hat{x}'_7{}^2 + \hat{x}'_8{}^2 \quad (15)$$

$$C_{p2} = (1 - \hat{x}'_7)^2 + (1 - \hat{x}'_8)^2 \quad (16)$$

$$C_{p3} = y_4'^2 \quad (17)$$

$$C_{p4} = (1 - y_4')^2 \quad (18)$$

ここで、 x_7 , x_8 は、それぞれ腰関節角度 θ_c 、膝関節角度 θ_d と対応するニューロンの値であり、 y_4 は肘関節角度 θ_4 と対応するニューロンの値である。

足先からの座標値が (0.30, 0.10, 0.25) であるターゲットに対して、ネットワークが計算したリーチング姿勢を図 8 に示す。採用した評価関数によって異なるリーチング姿勢が生成されるが、いずれも手先がターゲット座標とほぼ同じ位置にあり、かつ転倒しない全

身姿勢をとった。これより、ネットワークは図 7(b) のようなターゲットに対する特徴量を抽出し、評価関数に応じて適切な姿勢を計算していることが分かる。各姿勢における手先誤差は $C_{p1} \sim C_{p4}$ でそれぞれ 0.016, 0.015, 0.011, 0.008 [m] であった。この手先誤差はネットワークの学習誤差が原因であるが、特に姿勢と関係する評価関数を用いた場合に誤差が大きくなっていることから、体幹姿勢ネットワークの学習誤差の影響が大きいと考えられる。なお、リーチング姿勢をとり得る手先位置の範囲で 0.01 [m] 単位の格子点にターゲットを置いて、ネットワークの計算によりターゲットごとのリーチング姿勢を求めたところ、その全てで手先とターゲットの誤差は 0.03 [m] 未満であった。

4. 実機実験

実機に対してネットワークを適用し、全身リーチングの実験を行った。制御対象は富士通オートメーション製のヒューマノイドロボット HOAP-3 である。腕リーチングネットワークの学習に用いる教師信号は以下のように関節角度を動かし手先に対する視覚情報を取得した。首関節 θ_a , $-20^\circ \sim 40^\circ$ (5 通り), θ_b , $-40^\circ \sim 0^\circ$ (5 通り), 腕関節 θ_1 , $-15^\circ \sim 75^\circ$ (4 通り), θ_2 , $0^\circ \sim 75^\circ$ (4 通り), θ_3 , $-15^\circ \sim 75^\circ$ (4 通り), 肘関節 θ_4 , $-90^\circ \sim 0^\circ$ (4 通り)。この組み合わせは 6400 通りあるが、カメラの視野角が狭いため、この中で両方のカメラに対して視覚情報を取得することができたものが 359 通り存在し、これを教師信号とした。また、体幹姿勢ネットワークでは、20 個のターゲットに対して以下のように関節角度を動かし、その時の視覚情報及び足圧センサ情報を取得した。首姿勢 θ_a , $-40^\circ \sim 20^\circ$ (5 通り), θ_b , $-40^\circ \sim 0^\circ$ (5 通り), 腰関節 θ_c , $10^\circ \sim 85^\circ$ (17 通り), 膝関節 θ_d , $0^\circ \sim 24^\circ$ (7 通り)。学習に用いるのは、このうち「両眼カメラにターゲットが写っている」、「COP が足裏に存在 (転倒していない)」の二つの条件を満たしているデータであり、合計 2060 点存在した。どちらのネットワークも BP による学習を 50000 回行い、誤差が十分に減少したことを確認した。

次に、緩和計算を 200 回繰り返して (約 0.115 秒の所要時間で)、ロボットの全身リーチング姿勢を決めた。式 (15), (16) の評価関数 C_{p1} : 体幹を伸ばす C_{p2} : 体幹を曲げるを用いて生成された姿勢を図 9 に示す。図において、左側の小球がターゲットを示して

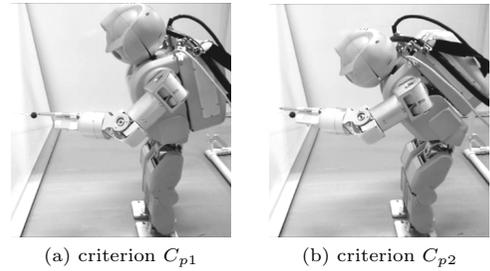


図 9 HOAP-3 の全身リーチング姿勢
Fig. 9 Whole body reaching postures of HOAP-3.

おり、腕の棒の先端を手先とみなして小球へのリーチングを行っている。二つの図を比較すると体幹姿勢に関しては、図 9(a) では体幹を伸ばす姿勢、図 9(b) では体幹を曲げる姿勢が正しく生成できている様子が確認できる。しかし、ターゲットへのリーチングに関しては、図 9(a) では手先とターゲットが一致しているが、図 9(b) では手先がターゲットを追い越してしまっている。シミュレーションでは手先誤差は微小であったため、ネットワークのアルゴリズム自体は妥当であると考えられ、実機における手先のずれの原因は教師信号の計測誤差に起因していると考えられる。特に図 9(b) のような体とターゲットが近い場合のデータは計測誤差が大きく、また、視野の関係で教師信号のデータ数自体も少なくなってしまうため、学習誤差が比較的大きくなってしまいう傾向がある。以上、今回の実機実験では計測環境と学習精度の問題で手先誤差が生じたが、設定した条件に応じてリーチング姿勢を生成することができた。

5. むすび

本研究では、ニューラルネットワークを用いて感覚運動情報を統合し、全身リーチング姿勢を生成する方法を提案した。リーチングの姿勢には冗長性が存在するため、多対多の情報変換が必要となる。このモデルはネットワークの学習によりセンサ情報と姿勢情報を統合するが、このときリーチングに必要な情報と必要でない情報が中間層のニューロンにおいて分離される。姿勢情報においてリーチングに必要な情報とは、姿勢の冗長性に関する情報であり、この情報が抽出されたニューロンを修正することによって設定した条件に応じて異なるリーチング姿勢を生成できる。通常のフィードフォワードネットワークでは冗長性のある多対多の関係を学習することは困難であるが、提

案するネットワークではこのような多対多の冗長性の問題を扱うことができる。このネットワークは視覚情報から姿勢情報を決定するだけでなく、姿勢情報から視覚情報を決定するという逆の変換も可能である。なお、本研究で扱ったのはリーチングの終端における姿勢の決定であり、リーチング軌道の制御を行うものではない。軌道制御を行うには、静的なバランスだけでなく、動力学を考慮しなければならず、より困難な問題を解かねばならない。

今後の課題としては、リーチングの精度の改善が挙げられる。今回の実験では、教師信号が十分であると考えられる点においても、1 cm 程度の手先誤差が生じた。これは、ネットワークの学習誤差が原因であると考えられ、学習精度を向上させることによって改善させると考えられる。また、今回の実機実験ではフィードフォワード制御だけで姿勢を生成しており、人間では一度見たターゲットに対して目を閉じてリーチングを行っていることに相当する。リーチングの精度の改善には視覚フィードバックが重要であるため、リーチング中の視覚情報をネットワークにフィードバックさせることによって手先誤差を減少させることができると考えられる。

謝辞 本研究の一部は科学研究費補助金基盤研究 (B) No.21300092, (C) No.23560526 により行われた。

文 献

- [1] 若城圭太郎, 福村直博, 宇野洋二, “感覚運動統合による 4 脚ロボットの障害物認識・行動選択モデル,” 信学技報, NC2002-178, 2003.
- [2] N. Fukumura, K. Wakaki, and Y. Uno, “A Modular structure of auto-encoder for the integration of different kinds of information,” Lect Notes Comput. Sci, vol.3610, pp.313–321, 2005.
- [3] 伊藤 寛, 福村直博, 宇野洋二, “感覚運動統合によりタスクに必要な情報を分離抽出する神経回路モデル,” 信学技報, NC2004-106, 2004.
- [4] 杉村僚介, 香川高弘, 田地宏一, 宇野洋二, “ニューラルネットワークを用いたステレオカメラ画像・関節角度間の情報統合,” 第 28 回日本ロボット学会学術講演会予稿集, RSJ2010AC2I2-4, 2010.
- [5] 梶田秀司 (編), ヒューマノイドロボット, オーム社, 2005.
- [6] G.W. Cottrell, P. Muno, and D. Zipser, “Image compression by back propagation: An example of extensional programming,” in Models of cognition: A review of cognitive science, ed. N.E. Sharkey, pp.208–249, Ablex Pub., Norwood, N.J., 1989.
- [7] 入江文平, 川人光男, “多層パーセプトロンによる内部表現の獲得,” 信学論 (D-II), vol.J73-D-II, no.8, pp.1173–1178, Aug. 1990.

- [8] 柳沼義典, 木本 隆, 山川 宏, “砂時計型ニューラルネットワークを用いたセンサ情報融合による内部表現の自動獲得,” ファジィシステムシンポジウム講演論文集, vol.11, pp.711–714, 1995.
- [9] E.C. Malthouse, “Limitations of nonlinear PCA as performed with generic neural networks,” IEEE Trans. Neural Netw., vol.9, no.1, pp.165–173, 1998.
(平成 24 年 9 月 26 日受付)



杉村 僚介

平 22 名大・工卒, 平 24 同大学院工学研究科博士前期課程了。同年 4 月 (株) 東芝入社, 現在に至る。大学ではニューラルネットワークによる感覚運動統合の研究に従事。日本ロボット学会会員。



香川 高弘 (正員)

平 18 豊橋技科大・工・博士後期課程単位取得退学。同年慶大・理工・生命情報学科助手。同大月が瀬リハビリテーションセンターに転出。平 19 名大・工・機械助教。博士 (工学), 現在に至る。身体運動の解析とリハビリテーション工学の研究に従事。

計測自動制御学会, 電気学会各会員。



田地 宏一

平 5 京都大学大学院・工・博士・中退。同年奈良先端大・情報助手, 平 10 阪大・基礎工・講師, 平 15 同助教授, 平 16 名大・工・助教授, 平 19 准教授となり現在に至る。最適化アルゴリズムの理論及びシステム論などへの応用に関する研究に従事。京都大学博士 (工学)。日本オペレーションズ・リサーチ学会, 計測自動制御学会, SIAM 等各会員。



宇野 洋二 (正員)

昭 63 大阪大学大学院基礎工学研究科博士課程了。工博。同年東大・工・計数助手。平 3 同講師。平 4 ATR 人間情報通信研究所主任研究員。平 8 豊橋技科大情報工学系教授。平 18 名大・工・機械教授, 現在に至る。生体の運動機能の研究に従事。日本神経回路学会, 計測自動制御学会各会員。