

感覚運動情報統合モデルを用いた ヒューマノイドの全身リーチング姿勢の生成

杉村 僚介[†] 香川 高弘[†] 田地 宏一[†] 宇野 洋二[†]

[†]名古屋大学大学院工学研究科 〒464-8603 名古屋市千種区不老町
E-mail: {r_sugimura, kagawa, taji, uno}@nuem.nagoya-u.ac.jp

あらまし 本研究ではニューラルネットワークを用いて、ヒューマノイドの全身リーチング動作姿勢を生成する。リーチングに必要な情報を各種センサと関節角度の情報統合によって獲得する。我々は全身リーチング動作を「腕のリーチング動作」と「リーチング時の体幹姿勢の決定」の2つの段階に分け、それぞれに対してネットワークを構築する。2つのネットワークは、はじめに個別に学習を行って入力情報を統合する。このとき入力情報の特徴量が一部のニューロンに抽出される。十分学習させた後、2つのネットワークを結合させ、緩和計算によって全身リーチング姿勢を生成する。リーチング姿勢には冗長性の問題があるが、このモデルでは学習時に抽出された特徴量を利用しタスクに応じて適切な姿勢を生成することができる。

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

Posture generation of a humanoid in whole body reaching movement using an integration model of sensory motor information

Ryosuke SUGIMURA[†], Takahiro KAGAWA[†], Kouichi TAJI[†], and Yoji UNO[†]

[†] Graduated School of Engineering, Nagoya University, Furo-cho, Chikusa-ku, Nagoya, 464-8603, Japan
E-mail: {r_sugimura, kagawa, taji, uno}@nuem.nagoya-u.ac.jp

Abstract We propose a method to integrate sensory and motor information of a humanoid in whole body reaching movements using a neural network. We divide a whole body reaching movement into an arm reaching task and a body posture task, and construct neural models for each task. Network operation consists of a learning phase and a posture generation phase. In the learning phase, each network model integrates sensory and motor information by feature extraction from input information. In the posture generation phase, two networks are combined, and the most suitable configuration of body joints corresponding to some criteria is obtained by a relaxation computation of the network.

Key words sensory motor information, neural network, feature extraction, whole body reaching, humanoid

1. はじめに

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すべてを設計していた。一方で、人間の生活空間は複雑であり、ユーザがすべてを設計することは困難である。そのような環境では、ユーザが設定し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。そのため、このような場合には、ロボットが自律的に環境を認識することが望ましい。

人間はどのようにして、感覚情報をもとに環境を認識しているのだろうか。環境認識において人間の学習機能が大きな役割

を果たしており、学習によって感覚情報から環境を表す特徴量を脳内に得ていると考えられる。たとえば、目の前の物体に対して腕を伸ばすリーチング運動を考える。リーチング運動を行うために必要となる感覚情報のひとつに視覚情報が挙げられる。リーチング運動では、目標となる物体の視覚情報からリーチング動作に必要な特徴量が抽出されるが、人間が正確に物体の座標を脳内で計算しているとは考えられず、「物体の視覚情報」と「リーチング動作に必要な腕の運動情報」を結びつける特徴量を学習によって脳内に獲得していると考えられる。ここで、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乗せる動作姿勢を生成した [1] [2]。このモデルは、視覚

情報と運動情報に対して、それぞれ砂時計型ニューラルネットワーク [3] [4] を用いており、第3層の一部のニューロンが同じ値となるように学習を行うことによって、入力情報の特徴量を抽出し、緩和計算を行うことにより視覚情報からタスクに応じた適切な姿勢情報を推定することができる。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、3次元空間における腕のリーチング姿勢の推定を行った [5]。

本研究ではニューラルネットワークの学習を利用して感覚情報であるセンサ情報と運動情報である関節角度を自律的に統合するモデルを提案し、そのモデルを用いて全身リーチング動作を行うことを目的とする。腕のみを動かすリーチング動作はカメラ画像からターゲットの位置情報を獲得し、それを関節角度に変換して行われる。しかし、全身リーチング動作では体幹を傾けるため、カメラの位置・角度の変化やロボットの転倒の危険性を考慮に入れなければならない。より多くの情報を利用して動作を設計する必要がある。はじめに、全身リーチング動作を行うネットワークモデルを提案し、ヒューマノイドに適用する。つぎにシミュレーション実験、実機実験を行い、モデルの有用性を検証する。

2. 感覚運動統合ネットワーク

我々は、全身リーチング動作を「腕のリーチング動作」と「体幹姿勢の決定」の2つの段階に分け、それぞれを個別に学習するネットワークを提案する。今回提案するモデルで使用する2つのネットワークは、それぞれ恒等写像を行う5層の砂時計型ニューラルネットワークで構成されている。第1層、第3層、第5層は線形ニューロン、第2層、第4層はシグモイド関数を用いた非線形ニューロンである。

腕のリーチングを行うネットワークでは手先の視覚情報 x と腕姿勢 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。体幹姿勢決定のネットワークでは、ターゲットの視覚情報および体幹姿勢 \hat{x} 、足圧センサ z の関係を学習することによって、ターゲット座標、足の圧力中心 (COP) に対応する特徴量が獲得される。学習を行った2つのネットワークを結合し、現在の視覚・体幹姿勢からリーチング時の体幹姿勢・腕姿勢を生成するタスクを行う。

リーチング動作において、関節角度の組み合わせは可動範囲内に複数存在する。通常のフィードフォワードネットワークでは、このような出力姿勢に冗長性がある多対多の関係を学習することは困難である。これに対して提案するネットワークでは、学習時にリーチング動作に必要な情報に対応する特徴量があるニューロンに獲得される。一方で、他のニューロンにはリーチングに必要な情報、すなわち姿勢の冗長性に対応する特徴量が獲得される。このニューロンを適切に修正することによって出力されるリーチング姿勢の変更が可能であり、冗長性の問題を扱うことができる。

2.1 腕リーチングネットワーク

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。上部の視覚情報を学習するネットワークには、ロボットに搭載さ

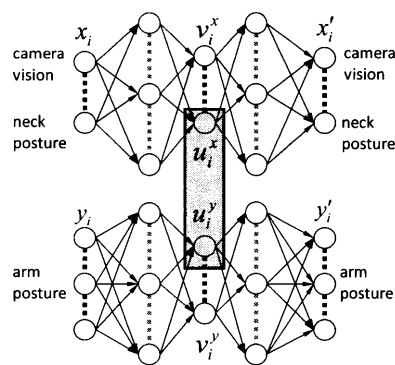


図1 Structure of arm reaching network




図2 Joint angles of arm reaching network

れているカメラからの画像情報を入力すると同時に、カメラの角度に関する情報として首関節の関節角度を入力する。下部の姿勢情報を学習するネットワークには、腕の姿勢情報として腕の関節角度を入力する。ネットワークの学習には誤差逆伝播法 (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 u^x , u^y が同じ値となるように拘束する。同じ値となるように学習を行う第3層のニューロンを“拘束ニューロン”と呼ぶとすると、この拘束ニューロンに2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、学習時に視覚のターゲットを自身の手先とすることで手先位置が視覚、腕姿勢の共通情報となる。視覚、姿勢の2つのネットワークは、それぞれ恒等写像の学習および、第3層のニューロンの拘束を同時に学習するため、学習に用いる誤差関数 E_x , E_y はそれぞれ次式のようになる。

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

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

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} は中間層の拘束に対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2乗誤差をそれぞれ表している。

十分に誤差が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 u^x , u^y が同じ値となり、このニューロンには手先位置に対応する情報が抽出される。一方で、共通情報とならない部分については、第3層の残りの拘束していない“非拘束ニューロン” v^x , v^y に抽出される。このネットワークにおいて非拘束ニューロン v^x , v^y は、それぞれ首姿勢の冗長性および、腕姿勢の冗長性に対応する情報が抽出される。

腕リーチングネットワークで使用する関節を図2に示す。入力する視覚情報は左右のカメラの画像座標であり、首姿勢は θ_a , θ_b である。よって、 $N_x = 6$ となる。また、腕姿勢は $\theta_1 \sim \theta_4$ を使用するため、 $N_y = 4$ となる。各情報は0~1で正規化され、ネットワークに入力される。ただし、手先に関しては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の棒の先を手先として扱う。拘束ニューロン u^x , u^y には、ターゲット位置の3次元の特徴量が抽出されるため、 $N_u = 3$ とする。非拘束ニューロン v^x , 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ため、それぞれ2次元、1次元とする。第2, 4層のニューロン数は20とした。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 体幹姿勢決定ネットワーク

図3に体幹姿勢の決定を行うネットワークモデルを示す。上部の視覚と体幹姿勢の関係を学習するネットワークには視覚情報、首姿勢、体幹姿勢を入力し、下部の足圧センサの学習を行うネットワークには足圧センサの情報のみを入力する。このネットワークでは、リーチングを行うために必要なターゲットのロボット本体からの相対位置の情報をニューロン p^x に抽出させる。一方で、ロボットの転倒防止に利用するCOPの情報は、足圧センサ z との関係进行学习させることによりニューロン q^x , q^y に抽出させる。 p^x にターゲットの位置を学習させるために、視覚と体幹姿勢の関係を学習するネットワークでは学習を行うときに \hat{x}_1 , \hat{x}_2 をそれぞれ入力する。この \hat{x}_1 , \hat{x}_2 は「同じ位置のターゲット」かつ「異なる姿勢」の情報であり、この2つの入力に対する共通情報は「ターゲットの位置」の情報のみとなる。よって、それぞれの入力に対する中間層のニューロンの値 p_1^x , p_2^x が同じ値となるように拘束を掛けると、このニューロンには「ターゲットの位置」に対応する情報が抽出される。また、上部のネットワークに体幹姿勢、下部のネットワークに足圧センサの情報が入力されているので、上下のネットワークの共通情報はロボットの足裏のCOPとなる。したがって、ネットワーク間の拘束ニューロン q にはCOPに対応する情報が抽出される。以上より、このネットワークの学習に使用される誤差関数は2つのネットワークに対してそれぞれ次式のようになる。

$$E_{\hat{x}} = \sum_{i=1}^{N_{\hat{x}}} (\hat{x}'_{1i} - \hat{x}_{1i})^2 + \gamma_p \sum_{i=1}^{N_p} (p_{1i}^x - p_{2i}^x)^2 + \gamma_{q1} \sum_{i=1}^{N_q} (q_i^x - q_i^z)^2 \quad (3)$$

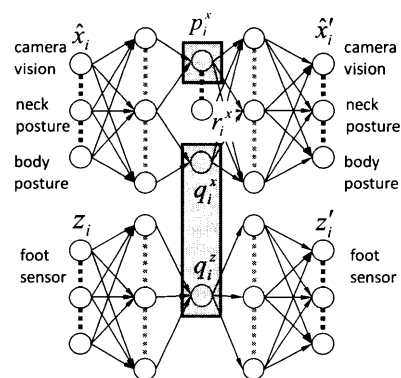


図3 Structure of body posture network




図4 Joint angles of body posture network

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

ここで、 γ_p , γ_{q1} , γ_{q2} は、それぞれの拘束に対する重みパラメータである。なお、 \hat{x} のネットワークの中間層の拘束されていない非拘束ニューロン r^x は、体幹姿勢、首姿勢の冗長性に対応する情報が抽出される。

体幹姿勢決定ネットワークで使用する関節を図4に示す。入力する視覚情報は左右のカメラの画像座標であり、首姿勢は θ_a , θ_b である。また、体幹姿勢は θ_c , θ_d を使用するため、合計で $N_{\hat{x}} = 8$ となる。足圧センサは左右それぞれ4つずつ搭載されているため $N_z = 8$ となる。各情報は0~1で正規化され、ネットワークに入力される。拘束ニューロン p^x には、ターゲット位置の3次元の特徴量が抽出されるため、 $N_p = 3$ 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が、今回の実験では体幹は前後方向のみ可動であるため $N_q = 1$ とする。残りの非拘束ニューロン r^x には、首、体幹姿勢の冗長性に対応する特徴量が抽出されるため3次元となる。第2, 4層のニューロン数は20とした。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 (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

学習を行った2つのネットワークを結合させ、全身リーチング姿勢を生成する。視覚情報から姿勢決定を行う情報の流れを

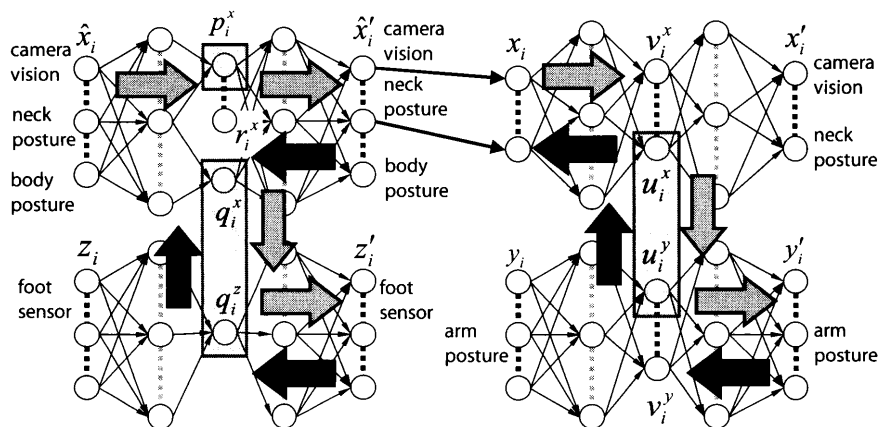


図5 Neural computation to generate whole body reaching posture

図5の灰色の矢印で示す。はじめに、ターゲットを視覚に捉えたときの視覚および、首・体幹姿勢の情報を \hat{x} として入力する。そして、各種の特徴量を抽出するように学習を行った p^x , q^x , r^x を経由し、 \hat{x}' の出力を行う。 \hat{x}' のうち、腕のリーチングと関係する視覚および首姿勢の情報を x として、右のネットワークに入力する。その後、カメラからの相対位置に対応する特徴量である u を経由して、腕の姿勢情報 y' が出力される。最終的に \hat{x}' の体幹姿勢および、 y' の腕姿勢の出力情報をもとにリーチングを行う姿勢が生成される。このネットワークモデルは、左側のネットワークにおいてリーチング時の体幹姿勢が生成されるとともに、そのときの視覚情報が推定される。その視覚情報を腕リーチングのネットワークに入力することで、腕のリーチング姿勢が生成され、全身リーチング姿勢を推定することができる。

左上の視覚と体幹姿勢の関係を学習したネットワークにおいて p^x はターゲット位置に対応し、この値を利用することでターゲットに対するリーチング姿勢およびそのときの視覚情報を生成できる。一方、 q^x , r^x はそれぞれ COP、姿勢の冗長性に対応し、この値を修正することによって生成される首・体幹姿勢を変更することができる。同様に、右下の腕姿勢を学習を行ったネットワークにおいて u^y を固定し、 v^y を修正することによって、生成される腕姿勢を変更することができる。正しく学習されたネットワークでは、ターゲット位置に関する特徴量が抽出された p^x , u^y を固定することによって、姿勢を変更してもターゲットに手先が届くことが保証される。 q^x , r^x , v^y の修正には z' , x' も使用するため、情報変換の流れは図5の灰色の矢印のようになる。

以下で示すように、コスト関数 C を設定し、 C が最小となるようにニューロンの値 q^x , r^x , v^y を修正することによって、姿勢が決定される。この緩和計算におけるニューロンの修正量 $\partial C / \partial q^x$, $\partial C / \partial r^x$, $\partial C / \partial v^y$ は学習に用いた誤差逆伝播法と同様の方法で計算でき、情報変換の流れは図5の黒色の矢印のようになる。コスト関数 C は次式のようにタスクに応じて設定される評価関数 C_p と関節角の可動範囲や転倒防止に関する制約条件に対するバリア関数 C_b の和で構成される。

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

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

入出力ニューロンの値 x, y, \hat{x}, z については $0 \sim 1$ 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、COP に関する拘束ニューロンの値 q^x については上下限を学習時の最大値 q^{max} および最小値 q^{min} としたバリア関数 B_2 を用いる。

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

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

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、 q^x には COP の特徴量が獲得されており、 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は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4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 q^x , r^x , v^y の初期値を求める。

$$C_0 = F_1(x) + F_1(y) + F_1(\hat{x}) + F_1(z) + F_2(q) \quad (9)$$

ここで、入出力ニューロンについての4次関数 F_1 および COP に関する拘束ニューロン q^x についての4次関数 F_2 をそれぞれ次式のようにする。

$$F_1(x) = \sum_{i=1}^{N_x} (x_i - 0.5)^4 \quad (10)$$

$$F_2(q^x) = \sum_{i=1}^{N_q} \left(q_i^x - \frac{q_i^{max} + q_i^{min}}{2} \right)^4 \quad (11)$$

4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

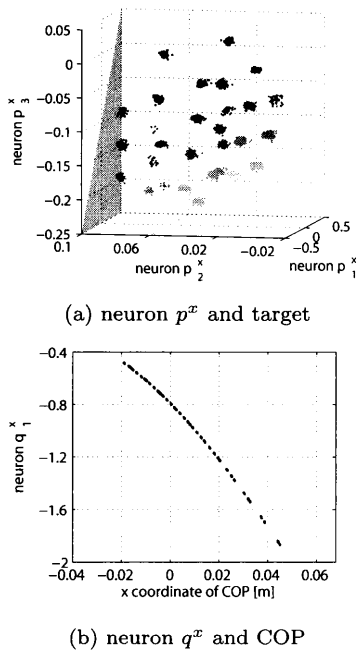


図 6 Relation between extract neuron and feature quantity

保証されないが、制約外においても中心向きの勾配をもっており、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)。この組合せは 63000 通りあるが、この中で 2 つのカメラ両方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、その時の視覚情報およ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 2 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。

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 6 に示す。図 6(a) は、教師信号で用いたターゲット 36 点に対して、その位置情報を抽出する拘束ニューロンの値 p^x を 3 次元でプロットしたものである。この図において、

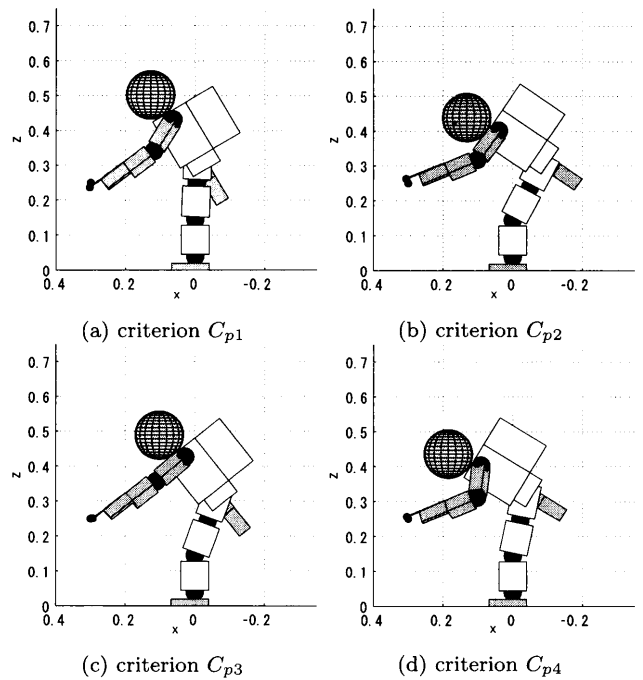


図 7 Whole body reaching postures of robot model

それぞれの点の集まりは同じターゲットに対する入力情報 \hat{x} を入力したときの拘束ニューロンの値 p^x を示しており、それぞれのターゲットに対して値が独立に分布していることから、絶対座標の情報が正しく抽出されていることがわかる。点の広がりには p^x の拘束に対する学習誤差を示している。また、図 6(b) 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おり、COP の情報が正しく抽出されていることがわかる。

ターゲット座標 (0.30, 0.10, 0.25) へのリーチング姿勢を生成する。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 4 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。

$$C_{p1} = \hat{x}'_7 + \hat{x}'_8 \quad (12)$$

$$C_{p2} = (1 - \hat{x}'_7)^2 + (1 - \hat{x}'_8)^2 \quad (13)$$

$$C_{p3} = y_4^2 \quad (14)$$

$$C_{p4} = (1 - y_4')^2 \quad (15)$$

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。

図 7 はそれぞれの評価関数を用いて、生成した姿勢を示している。この図では、姿勢は評価関数によって異なっているが、手先はターゲット座標と近い位置になっており、リーチングを正しく行っている様子が確認できる。これより、ネットワークの学習によって抽出された図 6(a) のようなターゲットに対する特徴量を利用して、適切に情報変換が行われていることがわかる。また、それぞれの姿勢に直目すると目標としたような姿


(a) criterion C_{p1} (b) criterion C_{p2}

図 8 Whole body reaching postures of HOAP-3

勢が適切に生成されており、ネットワークが狙い通りに機能していることがわかる。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、体幹姿勢決定ネットワークの学習誤差の影響が大きいと考えられる。

4. 実機実験

次に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)。この組合せは 6400 通りがあるが、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、その時の視覚情報およ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 2 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。

式 (12), (13) 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 8 に示す。図において、左側の小球がターゲットを示しており、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。2 つの図を比較すると体幹姿勢に関しては、図 8(a) では体幹を伸ばす姿勢、図 8(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 8(a) では手先とターゲットが一致しているが、図 8(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 8(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。今回の実験では学習精度の問題で手先誤差が生じたが、実機においても設定した条件に応じて異なるリーチング姿勢を生成することが可能であった。

5. 結論および今後の課題

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。提案するモデルでは、全身リーチング動作を「腕のリーチング動作」と「体幹姿勢の決定」の 2 つの段階に分け、それぞれに対してネットワークを構築する。リーチングを行う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動作に必要な情報と必要でない情報が中間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動作に必要な情報とは、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に多対多の冗長性の問題を扱うことができる。

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、1cm 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、今回のモデルは完全にフィードフォワードで姿勢を決定しており、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。よって、リーチングの精度の改善にはフィードバック要素が重要であると考えられるため、ネットワークにその要素を組み込むことで、手先誤差を減少させることができる。

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,” 電子情報通信学会技術研究報告, vol.102, no.730, pp.37-42, 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] G.W.Cottrell, P.Muno, and D.Zipser, “Image Compression by Back Propagation. An Example of Extensional Programmins,” ICS Report 8702, Institute for Cognitive Science, UCSD, 1987.
- [4] 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, 1990.
- [5] 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.