

# 日本機械学会論文集

Transactions of the Japan Society of  
Mechanical Engineers

別 刷

70 卷 695 号 C 編

(平成16年7月)

社団法人 日本機械学会

## 非接触インピーダンスのオンライン学習と接触作業への応用\*

寺内 睦博<sup>\*1</sup>, 石井 靖久<sup>\*2</sup>  
ト 楠<sup>\*2</sup>, 辻 敏夫<sup>\*3</sup>On-Line Learning of Non-Contact Impedance and its Appliation  
to Contact TasksMutsuhiro TERAUCHI<sup>\*4</sup>, Yasuhisa ISHII,  
Nan BU and Toshio TSUJI<sup>\*4</sup> Department of Kansei Information, Hiroshima International University,  
555-36 Gakuendai, Kurose-cho, Kamo-gun, Hiroshima, 724-0695 Japan

Impedance control is one of the most effective control methods for interaction between a manipulator and task environments. The force resulted by the interaction, however, does not occur until the end-effector of the manipulator touches its environment. A non-contact impedance control method has been proposed in order to achieve the impedance control before the contact. The method can regulate not only the end-point impedance but also the virtual impedance such that the end-effector is surrounded by a virtual object which can touch the environment before a real contact. This paper proposes a learning method using neural networks to regulate the virtual impedance parameters for given tasks. The validity of the method is verified through computer simulations and experiments with a conventional robot manipulator.

**Key Words:** Impedance Control, Virtual Impedance, Impedance Learning, On-Line Learning

## 1. はじめに

マンピュレータが環境に対して柔軟な接触作業を行うための制御法の一つに、インピーダンス制御<sup>(1)(2)</sup>がある。インピーダンス制御は、機械的なインピーダンス、すなわち剛性、粘性、慣性を望ましい値に制御しようとするもので、外力に対するマンピュレータの応答特性を調節することが可能である。しかしながら従来のインピーダンス制御では手先と対象物が接触してはじめて手先の運動が変化するため、環境や対象物に接触する前に手先を減速したり、対象物との距離をできるだけ一定に保つといった接触を伴わない作業を行うことは不可能であった。

この問題に対して、中坊ら<sup>(3)</sup>や、辻ら<sup>(4)(5)</sup>は視覚情報などを用いて環境とマンピュレータとの間に仮想的なインピーダンスを設定する方法を提案している。中坊らは、特定の画像特徴量について仮想的なインピーダンスを設定し、その画像から計算されたインピーダンスによるトルクをロボットの各関節に加えるというビジュアルインピーダンス制御を実現した。一方、辻らは、マンピュレータの手先に仮想的な球を設定し、その内部に侵入してきた対象物と手先との間に非接触イン

ピーダンスを設定することで、対象物との接触前に手先に仮想的な外力を加えるという非接触型インピーダンス制御を提案した。しかしながら、これらの方法では作業対象物や環境が非線形特性を含んでいるため、適切なインピーダンスパラメータを設定することは容易ではない。

一方、作業に応じたインピーダンスパラメータを設定する方法として、非線形特性に対して優れた近似能力を有するニューラルネットワーク(以下NNと略記)を利用して、パラメータを学習的に調節する手法が提案されてきた。例えば、Gomi and Kawatoはインピーダンス制御系の非線形の補償器として、NNを用いた学習型非線形フィードバック制御法を提案した<sup>(6)</sup>。しかしながら、これらの多くはマンピュレータや環境のモデルに含まれる不確かさや外乱に対して望ましいインピーダンスを学習的に実現しようとするもので、目標インピーダンス自体はあらかじめ与えられていると仮定している。これらの研究に対して、Asadaは力フィードバック制御器にNNを用いることで、非線形的な粘性のみのコンプライアンスを学習的に求める方法を提案した<sup>(7)</sup>。Cohen and Flashは、手先の速度と力の評価に基づいてNNによる学習的な粘弾性パラメータ調節を提案している<sup>(8)</sup>。Yang and Asadaは作業速度を段階的に変化させながら目標インピーダンスを学習するというProgressive learning法を提案している<sup>(9)</sup>。

これらの従来研究に対して、辻ら<sup>(10)(11)</sup>は剛性、粘性、

\* 原稿受付 2003年7月18日。

<sup>\*1</sup> 正員, 広島国際大学人間環境学部(☎724-0695 広島県賀茂郡黒瀬町学園台555-36)。<sup>\*2</sup> 広島大学大学院工学研究科(☎739-8527 東広島市鏡山1-4-1)。<sup>\*3</sup> 正員, 広島大学大学院工学研究科。

E-mail: tsuji@bsys.hiroshima-u.ac.jp

慣性すべてのインピーダンスパラメータの調節をNNを利用した繰り返し学習で実現する方法を提案し、同時に目標軌道を修正することで自由運動から拘束運動への滑らかな移行が可能であることを示した。文献(10)(11)では作業を繰り返し行うオフライン学習法を、また文献(12)では環境の特性を同定することでインピーダンス制御中に学習可能なオンライン学習法を提案した。さらに、文献(13)では非接触インピーダンス制御にオフライン学習法を適用し、接近してくる対象物を受け止めるというキャッチング作業を実現した。しかしながら、文献(13)の手法では非接触インピーダンスをオフラインで調節するため、作業対象や環境の特性が動的に変化するような繰り返し作業に対しては適応できなかった。

そこで本論文では、辻らの方法<sup>(12)</sup>を非接触型インピーダンス制御に応用し、NNを用いて学習的に非接触インピーダンスをオンラインで調節する方法を提案する。本手法では設定した評価関数に基づいてオンラインで非接触インピーダンスを学習することができ、また異なる評価関数を用いて非接触インピーダンスを学習することにより複数の作業を実現することができる。以下、2章で非接触型インピーダンス制御の定式化を行い、3章で本論文で提案するNNの学習法について詳しく述べる。4章では実機を用いてキャッチング作業、打ち返し作業を行い、本手法の有効性を示す。

## 2. 非接触型インピーダンス制御

**2.1 インピーダンス制御** 一般に環境に接触しているマニピュレータの運動方程式は、作業空間の自由度を  $l$ 、関節自由度を  $m$  とすると、

$$M(\theta)\ddot{\theta} + h(\theta, \dot{\theta}) = \tau + J^T(\theta)F_{int} \quad (1)$$

と記述できる。ただし、 $\theta \in \mathbb{R}^m$  は関節角度ベクトル、 $M(\theta) \in \mathbb{R}^{m \times m}$  は慣性行列 (以下  $M$  と略記)、 $h(\theta, \dot{\theta}) \in \mathbb{R}^m$  は、コリオリ力、関節摩擦、遠心力、重力等を表す項、 $\tau \in \mathbb{R}^m$  は関節駆動トルク、 $F_{int} \in \mathbb{R}^l$  は外力、 $J \in \mathbb{R}^{l \times m}$  はヤコビ行列を表す。

いま、マニピュレータ先端の目標慣性、粘性、剛性を  $M_e, B_e, K_e \in \mathbb{R}^{l \times l}$  とするとその挙動は次式に従う。

$$M_e d\ddot{X} + B_e d\dot{X} + K_e dX = F_{int} \quad (2)$$

ここで、 $dX = X_e - X_d$  は目標手先位置  $X_d \in \mathbb{R}^l$  と現在位置  $X_e \in \mathbb{R}^l$  との偏差を表す。このとき、マニピュレータのインピーダンス制御則<sup>(2)</sup>は、

$$\tau = \tau_{effector} + \tau_{comp} \quad (3)$$

$$\tau_{effector} = J^T \{ M_x(\theta) [M_e^{-1} (-K_e dX - B_e d\dot{X}) + \ddot{X}_d - \dot{J}\dot{\theta}] - [I - M_x(\theta)M_e^{-1}] F_{int} \} \quad (4)$$




Fig. 1 Scheme of a non-contact impedance control

$$\tau_{comp} = (M^{-1} J^T M_x(\theta) J)^T \hat{h}(\theta, \dot{\theta}) \quad (5)$$

$$M_x(\theta) = (J \hat{M}^{-1}(\theta) J^T)^{-1} \quad (6)$$

で与えられる。ただし、 $\hat{M}(\theta)$  は慣性行列  $M$  の推定値、 $\hat{h}(\theta, \dot{\theta})$  は  $h(\theta, \dot{\theta})$  の推定値を表す。 $\tau_{effector}$  はマニピュレータの手先インピーダンスを調節するための関節トルク、 $\tau_{comp}$  は運動方程式に含まれる  $h(\theta, \dot{\theta})$  を補償するための関節トルクであり、 $M_x(\theta) \in \mathbb{R}^{l \times l}$  はアームが特異姿勢にない限り正則である。以上より、マニピュレータの手先インピーダンスを自由に調節することが可能となる。

**2.2 非接触型インピーダンス制御** 図1に非接触型インピーダンス制御の概念図を示す。ある対象物がロボットに近づいてくる際、ロボットの手先位置を中心とする半径  $r$  の仮想的な球を設定する。手先の位置を  $X_e \in \mathbb{R}^l$ 、対象物の位置を  $X_o \in \mathbb{R}^l$  とすると、仮想球の表面から対象物への法線ベクトル  $dX_o \in \mathbb{R}^l$  は、

$$dX_o = X_r - r n \quad (7)$$

と記述できる。ただし、手先から対象物へのベクトルを  $X_r = X_o - X_e$  とし、ベクトル  $n \in \mathbb{R}^l$  は、

$$n = \begin{cases} \frac{X_r}{|X_r|} & (X_r \neq 0) \\ 0 & (X_r = 0) \end{cases} \quad (8)$$

と定義する。

対象物が仮想球の内部に侵入 ( $|X_r| < r$ ) したとき、対象物と手先との間に非接触インピーダンスを設定する。この非接触インピーダンスと  $dX_o$  を用いて、対象物から手先に加わる仮想外力  $F_o \in \mathbb{R}^l$  を、

$$F_o = \begin{cases} M_o d\ddot{X}_o + B_o d\dot{X}_o + K_o dX_o & (|X_r| \leq r) \\ 0 & (|X_r| > r) \end{cases} \quad (9)$$

と定義する。ただし、 $M_o, B_o, K_o \in \mathbb{R}^{l \times l}$  はそれぞれ非接触インピーダンスの慣性行列、粘性行列、剛性行列である。なお、式(8)、(9)から明らかのように、対象物が仮想球の外部に存在する場合や、対象物と手先の位




Fig. 2 The block diagram of the non-contact impedance control

置が一致する場合には  $F_o = 0$  となる。式 (2), (9) より、非接触インピーダンス制御におけるマニピュレータの手先の運動方程式は、

$$M_e d\ddot{X} + B_e d\dot{X} + K_e dX = F_{int} + F_o. \quad (10)$$

となる。これにより対象物と接触する前にマニピュレータの手先に仮想外力  $F_o$  が作用し、運動が生じる。

図 2 に非接触型インピーダンス制御 (式 (9)(10)) のブロック線図を示す。図から対象物の位置  $X_o(s)$  と目標手先位置  $X_d(s)$  に対する手先位置  $X_e(s)$  の応答は、

$$\begin{aligned} X_e(s) = & \frac{M_o s^2 + B_o s + K_o}{M s^2 + B s + K} X_o(s) \\ & + \frac{M_e s^2 + B_e s + K_e}{M s^2 + B s + K} X_d(s) \\ & - \frac{(M_o s^2 + B_o s + K_o) r n + F_{int}(s)}{M s^2 + B s + K} \end{aligned} \quad (11)$$

となる。ただし  $M = M_o + M_e$ ,  $B = B_o + B_e$ ,  $K = K_o + K_e$  である。したがってこの系の安定条件は  $M_o \geq -M_e$ ,  $B_o \geq -B_e$ ,  $K_o \geq -K_e$  となる (ただし、等号は 3 つ同時には成立しないものとする)。

手先と対象物との間に非接触インピーダンスを設定することにより、対象物に対する手先の相対的な運動を調節できるという利点を有している。そこで、次節では作業に適した非接触インピーダンスパラメータ ( $M_o, B_o, K_o$ ) を NN を用いて学習的に調節することを考える。

### 3. NN による非接触型インピーダンスの学習

**3-1 NN の構成** 本手法では、図 2 の制御系の非接触インピーダンス部分を、Non-contact Stiffness Network (以下 NCSN と略記)、Non-contact Viscosity Network (以下 NCVN と略記)、Non-contact Inertia Network (以下 NCIN と略記) という 3 つの NN で表現する。これらの NN へは、手先と対象物との相対位置  $X_r$ 、相対速度  $\dot{X}_r$ 、相対加速度  $\ddot{X}_r$  および相互作用力  $F_{int}$  を入力とし、非接触インピーダンスパラメータ  $K_o, B_o, M_o$  をそれぞれ出力する多層型 NN である。ここで、 $K_o, B_o, M_o$  は対角行列とする。図 2 に




Fig. 3 Non-contact impedance composed of three components




Fig. 4 Non-contact stiffness realized by a neural network

ける非接触インピーダンスの詳しい構成を図 3 に、また、 $K_o$  を学習する NCSN を図 4 に示す。なお、NCVN, NCIN の構造も同様である。いずれの NN も入力層には線形の入力関数を用いる。中間層、出力層にはシグモイド関数を用いる。したがって、各層のユニットの入出力を  $x_i, y_i (i, j = 1, 2, \dots$  ただし  $j < i$ ) とすると、

$$x_i = \begin{cases} I_i & (\text{入力層}) \\ \sum w_{ij} y_j & (\text{中間層, 出力層}) \end{cases} \quad (12)$$

$$y_i = \begin{cases} x_i & (\text{入力層}) \\ \frac{1}{1 + e^{-x_i}} & (\text{中間層}) \\ \frac{U}{2} \left( \frac{1 - e^{-x_i + \theta}}{1 + e^{-x_i + \theta}} \right) & (\text{出力層}) \end{cases} \quad (13)$$

となる。ここで、 $I_i$  は NN への入力、 $w_{ij}$  はユニット  $j$  からユニット  $i$  への重み係数、 $U, \theta$  は正の定数で、それぞれネットワーク出力の最大値、しきい値を表す。

**3-2 オンライン学習** NN の学習は予め定義された評価関数  $E(t)$  を各時刻において最小にするように NN の重み係数をオンラインで更新する。各 NN の重み  $w_{ij}$  は評価関数  $E(t)$  の最急降下方向へ修正することにより、NN の出力である非接触インピーダンスは評価関数  $E(t)$  を最小化することにより望ましい値に近づいていくことになる。

各 NN の重み  $w_{ij}$  の修正量  $\Delta w_{ij}$  は

$$\Delta w_{ij} = -\eta \frac{\partial E(t)}{\partial w_{ij}} \quad (14)$$

$$\frac{\partial E(t)}{\partial w_{ij}} = \frac{\partial E(t)}{\partial F_{act}(t)} \frac{\partial F_{act}(t)}{\partial O(t)} \frac{\partial O(t)}{\partial w_{ij}} \quad (15)$$

と書くことができる。ただし、 $\eta$  は NN の学習率、 $F_{act}(t) \in \mathbb{R}^1$  は制御入力であり、 $O(t) \in \mathbb{R}^{3 \times 3}$  は各 NN の出力を示す。ここで、 $\frac{\partial F_{act}(t)}{\partial O(t)}$  は図 2 および式 (9) を用いて計算でき、 $\frac{\partial O(t)}{\partial w_{ij}}$  は誤差逆伝播法により計算することができる。しかしながら、 $\frac{\partial E(t)}{\partial F_{act}(t)}$  はマニピュ




Fig. 5 An experiment system

レータのダイナミクスが存在するため、直接計算することはできない。そこで提案法では、式(15)に含まれる  $\frac{\partial E(t)}{\partial F_{act}(t)}$  を離散系において近似し、 $F_{act}(t)$  の微小変化に対する  $E(t)$  の変化量を用いて、各 NN の重みの修正量  $\Delta w_{ij}$  をオンラインで計算する。

一方、 $E(t)$  が手先の位置  $X_e(t)$  と速度  $\dot{X}_e(t)$  を用いて表現できる場合を考えると、

$$\frac{\partial E(t)}{\partial F_{act}(t)} = \frac{\partial E(t)}{\partial X_e(t)} \frac{\partial X_e(t)}{\partial F_{act}(t)} + \frac{\partial E(t)}{\partial \dot{X}_e(t)} \frac{\partial \dot{X}_e(t)}{\partial F_{act}(t)} \quad (16)$$

のように展開することができる(図2参照)。 $F_{act}(t)$  を微小量  $\Delta F_{act}(t)$  だけ変化させたとき、

$$\Delta X_e(t) \approx \Delta F_{act}(t) \Delta t_s^2 \quad (17)$$

$$\Delta \dot{X}_e(t) \approx \Delta F_{act}^{(k)}(t) \Delta t_s \quad (18)$$

と近似することができるので、

$$\frac{\partial X_e(t)}{\partial F_{act}(t)} = \frac{\Delta X_e(t)}{\Delta F_{act}(t)} = \Delta t_s^2 I \quad (19)$$

$$\frac{\partial \dot{X}_e(t)}{\partial F_{act}(t)} = \frac{\Delta \dot{X}_e(t)}{\Delta F_{act}(t)} = \Delta t_s I \quad (20)$$

となる<sup>(12)</sup>。ただし、 $\Delta t_s$  は十分に小さなサンプリングタイム、 $I \in \mathbb{R}^{l \times l}$  は単位行列を表す。以上より、この学習則を用いることで非接触インピーダンスの学習をオンラインで実行することが可能となった。

#### 4. 非接触型インピーダンス制御実験

本章では、NN のオンライン学習に用いる評価関数を与えられた作業内容に応じて設定することにより、異なる作業が実現できることを実験により示す。ロボットに与える作業として、接近してくる対象物の運動をスムーズに抑制する作業(以下、キャッチング作業と呼ぶ)と、接近してくる対象物を打ち返す作業(以下、打ち返し作業と呼ぶ)を取り上げる。

**4.1 実験システムの構成** 図5に実験環境の概念図を示す。対象物は木製の直方体とし、この対象物を天井からアルミ製の支持棒でつるすことにより振り子運動を実現した。本実験システムは、図6に示す多関節マニピュレータ(MoveMaster RM-501: (株)三菱電機)を制御する計算機、計算機からマニピュレータへの指令電圧を増幅するパワーアンプからなり、非接触インピーダンスのオンライン学習が必要となる高サンプリングでの実機制御が可能である。ここで、マニピュレータと対象物との相互作用力はマニピュレータ先端に取り付けたロードセル((株)共和電業)で計測し、対象物の位置は3次元位置センサ(ISOTRACK II: POLHEMUS 社)を用いて計測した。対象物は  $y-z$  平面(鉛直面)上で振り子運動を行うことから、作業を行う前にマニピュレータの作業空間が対象物の運動面と一致するように初期制御を行い、作業中に対象物とマニピュレータとの接触面の変動を抑えた。また、ロードセルで計測した接触力は外力  $F_{int}$  の  $y$  成分としてマニピュレータに与えて、非接触インピーダンスの学習を行った。

マニピュレータのリンク長は  $l = (l_1, l_2, l_3)^T = (0.30, 0.25, 0.27)^T$  [m] であり、初期関節角度は  $\theta = (\theta_1, \theta_2, \theta_3)^T = (\frac{\pi}{2}, \frac{\pi}{9}, \frac{7\pi}{18})^T$  [rad] とした。振り子の長さは  $L = 1.7$  [m]、対象物の初期位置はマニピュレータの手先位置から距離  $D = 0.25$  [m] とし、対象物の質量は重りをつけて  $M_b = 0.2$  [kg] とした。また、マニピュレータの目標手先インピーダンスを  $K_e = \text{diag.}[400, 400, 400]$  [Ns/m]、 $B_e = \text{diag.}[200, 200, 200]$  [N/m]、 $M_e = \text{diag.}[10, 10, 10]$  [kg] と設定し、手先を中心とする仮想球の半径は  $r = 0.2$  [m] とした。なおサンプリングタイムは衝突の際に生じる衝撃力を計測可能な時間を考慮し、 $\Delta t_s = 1$  [ms] とした。

**4.2 キャッチング作業** キャッチング作業ではマニピュレータや環境に過大な力が加わらないように、接触力をできるだけオーバーシュートすることなく目標とする接触力に近づける必要がある。そのためには接触後に力を制御するだけでなく、接触前に予めマニピュレータと環境の間の相対速度を小さくしておけばよい。そこでキャッチング作業に対する NN の学習に用いる評価関数を

$$E_c = E_{cv}(t) + \mu E_{cf}(t) \quad (21)$$

$$E_{cv}(t) = \frac{1}{2} \alpha (|X_r|) |\dot{X}_r(t_c) - \dot{X}_r(t)|^2 \quad (22)$$

$$E_{cf}(t) = \frac{1}{2} \int_0^t |F_{cd}(u) - F_{int}(u)|^2 du \quad (23)$$

と定義する<sup>(13)</sup>。ただし、 $X_r \in \mathbb{R}^l$  は手先から対象物への相対位置ベクトル、 $t_c$  は環境が仮想球に進入した瞬




Fig. 6 A three-joint manipulator




Fig. 7 A gain function used for the catching-a-ball task


間の時刻,  $F_{cd} \in \mathbb{R}^l$  はキャッチング作業時の目標の相互作用力,  $\mu$  は学習における式 (23) の影響を調節するための正定数である. ここで, 式 (22) の関数  $\alpha(|X_r|)$  は対象物が仮想球に侵入した直後からの速度の変化による影響を滑らかにする働きがあり, 本論文では

$$\alpha(|X_r|) = \begin{cases} \sin\left(\frac{(|X_r| - R_b)\pi}{2(r - R_b)}\right) & (|X_r| \geq R_b) \\ 0 & (|X_r| < R_b) \end{cases} \quad (24)$$


とした.  $r$  は仮想球の半径,  $R_b$  は対象物の半径である.  $\alpha(|X_r|)$  の変化を図 7 に示す.

学習に用いた NN は 4 層構造で, ユニット数は入力層 4, 中間層  $20 \times 2$  層, 出力層 1 である. 重み係数  $w_{ij}$  の初期値は  $|w_{ij}| < 0.05$  の一様乱数で与え, NCSN の学習率を  $\eta_p = 0.01$ , NCVN の学習率を  $\eta_v = 0.015$ , NCIN の学習率を  $\eta_a = 0.00001$  とした. また, NN の出力値である非接触インピーダンスパラメータを  $-1000 \sim 1000$  の範囲に制限するため,  $U = 2000$  とした. なお, 式 (21) の  $\mu$  は 0.001 とし, 目標相互作用力は  $F_{cd} = \text{diag}[0.0, -2.0, 0.0]$  [N] と設定した. ここで, 対象物と手先が接触した後は仮想外力を  $F_o = \mathbf{0}$  とし, 非接触インピーダンスパラメータの学習を停止した.


図 8(a) に, オンライン学習を行った場合と学習を行わなかった場合の手先と対象物の  $y$  軸方向の挙動を示す. なお, 対象物が仮想球に侵入した時間を  $t_c$  とした. 学習前と学習後で接触前の対象物の挙動が違うのは, 対象物を手動でリリースしているためである. また, 図 8(b) は学習なし, (c) は学習ありの場合の  $y$  軸方



(a) Trajectories of Object and End-point with and without learning



(b) Interaction force without learning



(c) Interaction force with learning

Fig. 8 Experimental results of the catching-a-ball task

向の相互作用力の時間変化である. 図 8 より, 学習を行い相対速度を 0 に近づけることで, 対象物との接触前に手先を引く動作が実現されており, 接触時に生じる相互作用力が減少していることがわかる.

図 9 に  $y$  軸方向の非接触インピーダンス  $K_{oy}, B_{oy}, M_{oy}$  の時間変化を示す. 対象物が仮想球に侵入した直後は手先を対象物と反対方向に引いて相互作用力を抑える必要があるため  $K_{oy}, B_{oy}, M_{oy}$  がともに増加している. 本論文のシステムでは対象物の加速度の変化が大きいため  $M_{oy}$  の学習率を小さくした. そのため  $M_{oy}$  の変化は  $K_{oy}, B_{oy}$  に比べて小さい. また,  $B_{oy}$  のほうが  $K_{oy}$  に比べて大きな値となっていることから, 主に粘性を用いて手先を引く動作を行っていることがわかる. これは式 (22) の  $E_{cv}(t)$  が相対速度に基づいて定義しているためと考えられる.

**4.3 打ち返し作業** 次に打ち返し作業の評価関数を定義する. 対象物を打ち返し作業を実現するためには, マニピュレータの手先を対象物の運動方向とは逆方向に制御すればよい. そこで本論文では, 対象物の速度に応じて手先速度を制御することで打ち返し作業を実現する. 打ち返し作業における評価関数を

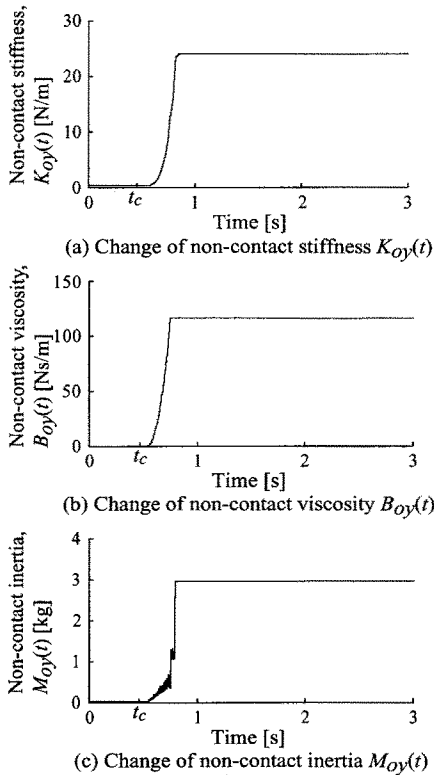


Fig. 9 Changes of the non-contact impedance parameters during the catching-a-ball task

$$E_h = E_{hv}(t) + \mu E_{hf}(t) \quad (25)$$

$$E_{hv}(t) = \frac{1}{2} |\beta(|\mathbf{X}_r|) \dot{\mathbf{X}}_o(t) - \dot{\mathbf{X}}_e(t)|^2 \quad (26)$$

$$E_{hf}(t) = \frac{1}{2} \int_0^t |\mathbf{F}_{hd}(u) - \mathbf{F}_{int}(u)|^2 du \quad (27)$$

と定義する。ただし、 $\mathbf{F}_{hd} \in \mathcal{R}^3$  は打ち返し作業時の目標の相互作用力、 $\mu$  は式 (27) の影響を調節するための正定数である。 $E_{hv}(t)$  で対象物とマニピュレータの速度誤差を、 $E_{hf}(t)$  で力制御誤差をそれぞれ評価する。ここで、式 (26) の関数  $\beta(|\mathbf{X}_r|)$  は対象物が仮想球に侵入した直後からの速度の変化による影響を滑らかにする働きがあり、本論文では

$$\beta(|\mathbf{X}_r|) = \begin{cases} \sin\left(\frac{(|\mathbf{X}_r| - R_b)\pi}{2(r - R_b)}\right) - 1 & (|\mathbf{X}_r| \geq R_b) \\ 0 & (|\mathbf{X}_r| < R_b) \end{cases} \quad (28)$$

とした。 $\beta(|\mathbf{X}_r|)$  の変化を図 10 に示す。仮想球に侵入した瞬間のマニピュレータと対象物の相対距離は  $|\mathbf{X}_r| = r$  となるため  $\beta(r) = 0$  となり、対象物が仮想球に侵入した瞬間の式 (26) の速度誤差は 0 になる。その後、相対距離が小さくなるほど  $\beta(|\mathbf{X}_r|)$  は  $-1$  に近づくため、 $E_{hv}(t)$  を小さくするためには手先速度  $\dot{\mathbf{X}}_e$  を




Fig. 10 A gain function used for the hitting-a-ball task

対象物速度  $\dot{\mathbf{X}}_o$  の反対方向に近づけねばならない。これにより、接触前に手先が対象物に接近していく。また、手先と対象物が接触した直後は  $\beta(|\mathbf{X}_r|) = -1$  となるため、 $E_{hv}(t)$  を小さくするためには手先速度を対象物速度の反対方向に制御せねばならない。これにより、接触後に手先が対象物から離れていく。このように、対象物の速度に応じてマニピュレータの手先速度を調節することで連続的な打ち返し作業を試みた。


実験システムの条件はキャッチング作業と同様な設定とし、NN は 4.2.2 節で述べたものと同様のものを用いた。非接触インピーダンスパラメータの学習率はそれぞれ  $\eta_p = 0.015$ ,  $\eta_v = 0.02$ ,  $\eta_a = 0.00001$ ,  $\mu = 0.001$  とし、目標相互作用力は  $\mathbf{F}_{hd} = \text{diag}[0.0, -80.0, 0.0]$  [N] と設定した。

図 11(a) に手先と対象物の位置の  $y$  軸方向の挙動を、(b) に相互作用力の時間変化を、図 12 に  $y$  軸方向の非接触インピーダンスパラメータの時間変化を示し、対象物が仮想球に侵入した時間を  $t_h$  とした。図 12 より、対象物が仮想球に侵入した直後は手先が対象物に接近して打ち返す必要があるため、 $K_{oy}$ ,  $B_{oy}$ ,  $M_{oy}$  はともに減少する。接触後、手先と対象物の相対距離が  $r$  付近になると  $\beta(|\mathbf{X}_r|) \approx 0$  となり、手先速度を 0 にするため  $K_{oy}$ ,  $B_{oy}$  が増加する。また、対象物が接近し始めると  $\beta(|\mathbf{X}_r|)$  が変化し、 $K_{oy}$ ,  $B_{oy}$  を減少させることにより手先速度を対象物速度の反対方向に近づけている。このように、対象物の運動に応じて  $K_{oy}$ ,  $B_{oy}$  の変化が周期的になるため、仮想外力の変化も周期的となる。これにより、図 11 のように手先の位置変化も周期的となり、対象物が打ち返され続ける。


## 5. まとめと今後の課題

本論文では NN を利用して非接触インピーダンスパラメータをオンラインで調節する方法を提案した。そしてこの方法を実機に応用し、作業を行うための非接触インピーダンスパラメータをオンラインで学習的に獲得できることを示した。また、与えられた作業内容に適した評価関数を設定することにより、複数の作業が実現できることを示した。

本論文では非接触インピーダンスのみを調節するこ



(a) Trajectories of Object and End-point with learning



(b) Interaction force with learning

Fig. 11 Experimental results of the hitting-a-ball task

とで議論を進めてきたため、手先インピーダンスの調整法については特に考察してない。しかしながら、自由空間での作業においては非接触インピーダンスパラメータを調節し、接触後は手先インピーダンス制御のみに移行し、手先インピーダンスパラメータを調節し作業を行うという方法も考えられる。今後は手先インピーダンスの変化による作業の変化を考察し、手先インピーダンスパラメータを非接触インピーダンスと並列に学習させることにより学習の効率化についての検討を行う予定である。

なお、本論文をまとめるにあたり、御指導と御助言を賜りました広島大学の田中良幸助手に深く感謝いたします。また、本研究の一部は文部科学省科学研究費補助金(15360226)によるもので、ここに改めて謝意を表します。

## 文 献

- (1) N. Hogan: "Impedance Control: An Approach to Manipulation, Parts I, II, III," ASME Journal of Dynamic Systems, Measurement, and Control, Vol. 107, No. 1, pp. 1-24, 1985.
- (2) N.Hogan: "Stable Execution of contact tasks using impedance control," Proc. IEEE International Conference on Robotics and Automation, pp. 1047-1054, 1987.
- (3) 中坊: "ビジュアルインピーダンスを用いたロボットの制御", ロボティクス・メカトロニクス講演会講演論文集, pp. 999-1002, 1996.
- (4) 辻, 畑木, 赤松, 金子: "マニピュレータの非接触型インピーダンス制御", 日本ロボット学会誌, Vol. 15, No. 4, pp. 136-143, 1997.
- (5) T. Tsuji and M. Kaneko: "Non-contact Impedance Control for Redundant Manipulator," IEEE Transaction on Systems, Man, and Cybernetics - PartA, Vol. 29, No. 2, pp. 184-193, 1999.




(a) Change of non-contact stiffness  $K_{Oy}(t)$ (b) Change of non-contact viscosity  $B_{Oy}(t)$ (c) Change of non-contact inertia  $M_{Oy}(t)$ 

Fig. 12 Changes of the non-contact impedance parameters during the hitting-a-ball task

- (6) G. Gomi and M. Kawato: "Neural Network Control for a Closed Loop System Using Feedback-Error-Learning," Neural Networks, Vol. 6, No. 7, pp. 933-946, 1993.
- (7) H. Asada: "Teaching and Learning of Compliance Using Neural Nets: Representation and Generation of Nonlinear Compliance," Proc. of IEEE Int. Conf. on Robotics and Automation, pp. 1237-1244, 1990.
- (8) M. Cohen and T. Flash: "Learning Impedance Parameters for Robot Control Using an Associative Search Networks," IEEE Trans. on Robotics and Automation, Vol. 7, No.3, pp. 382-390, 1991.
- (9) B. -H. Yang, H. Asada: "Progressive Learning and Its Application to Robot Impedance Learning," IEEE Transaction on Neural Networks, Vol. 7, No. 4, pp. 941-952, 1996.
- (10) 辻, 西田, 伊藤: "ニューラルネットワークによるインピーダンスパラメータの繰り返し学習", 計測自動制御学会論文集, Vol. 28, No. 12, pp. 1461-1468, 1992.
- (11) T. Tsuji, K. Ito and P. Morasso: "Neural Network Learning of Robot Arm Impedance in Operational Space," IEEE Transaction on Systems, Man, and Cybernetics-PartB, Vol. 26, No. 2, pp. 290-298, 1996.
- (12) 辻, 赤松, 原田, 金子: "ニューラルネットワークによるロボットインピーダンスのオンライン学習", 日本ロボット学会誌, Vol. 17, No. 2, pp. 234-241, 1999.
- (13) 野口, 辻, 原田, 金子: "ニューラルネットワークによる非接触型インピーダンス制御のパラメータ学習", 日本ロボット学会誌, Vol. 18, No. 4, pp. 561-568, 2000.