

ニューラルネットによる非接触型インピーダンス制御のパラメータ学習

野口裕史* 辻敏夫* 原田研介* 金子真*

Learning of Virtual Impedance Parameters in Non-contact Impedance Control using Neural Networks

Yuji Noguchi*, Toshio Tsuji*, Kensuke Harada* and Makoto Kaneko*

Although an impedance control is one of the most effective control method for a manipulator in contact with its environment, the end-effector of the manipulator does not move until an external force is exerted. In order to control the manipulator motion before contact with the environment, a non-contact impedance control has been proposed, which can regulate not only the end-point impedance but also virtual impedance between the manipulator and the environment using visual information. The characteristics of the non-contact impedance control, however, is determined by the virtual impedance which must be designed according to given tasks. The present paper proposes a method to regulate the virtual impedance parameters using neural networks by reducing an energy function during iterative execution of the given task. The proposed method is implemented using a direct-drive robot in a planar task space to show effectiveness of the method.

Key Words: Impedance Control, Non-contact Impedance, Neural Networks, Robot Manipulator, Impact Control

1. はじめに

マニ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 [1] [2] 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、外力に対するマニ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、視覚情報を利用してインピーダンス制御を実現しようとする研究がいくつか行われている [3] ~ [6]。例えば Castano and Hutchinson [3] は視覚センサ情報と内界センサ情報のハイブリッド制御系を構成し、仮想的に設定した作業平面にマニピュレータの手先を拘束する方法を提案した。また辻ら [4] [5]、中坊ら [6] はカメラからの視覚情報を用いて環境とマニ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。辻らの方法は、マニピュレータの手先に仮想的な球を設定し、その球の内部に侵入してきた対象物と手先との間に仮想的なインピーダンスを設定することで手先と対

象物が接触する前に手先に仮想的な外力を加えるというもので、非接触型インピーダンス制御と呼ばれる。しかしながら作業対象や環境の特性、またそれらの時間変化などを考慮して仮想インピーダンスパラメータを適切な値に設定する一般的な方法を導出することは極めて困難である。

一方、インピーダンス制御では作業に応じたインピーダンスパラメータを設定するために今までに様々な研究がなされてきた。本論文では特にニューラルネットワーク (以下 NN と略記) を利用した方法に注目する。

これまでにも、NN をマニピュレータの力制御やハイブリッド制御 [7] ~ [14] に応じた研究は数多く行われている。また NN を利用したインピーダンス制御に関しても多くの研究報告がなされているが、それらの多くはマニ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学習的に望ましいインピーダンスを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ると仮定している [15] ~ [19]。これに対して例えば Asada [20] は力フィードバック制御器に NN を用いることで、非線形な粘性コンプライアンスを学習的に求める方法を提案した。Cohen and Flash [21] 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検討している。辻ら [22] ~ [24] は慣性、粘性、剛性のすべてのインピーダンスパラメータの調節を NN を利用して実現する方法を示しており、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。また Yang and Asada [25] は作業速度を段階的に変化させながら目

原稿受付 1999年4月5日

* 広島大学工学部

* Hiroshima University

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。

本論文では辻らの方法 [22] [23] を非接触型インピーダンス制御に応用し, NN を用いて学習的に仮想インピーダンスパラメータを調節する方法を提案する. 本手法では作業に応じて設定した評価関数に基づいてオフラインで仮想インピーダンスを学習することができ, これにより接触前の相対速度や接触後の相互作用力を作業に適した値に調節することができる. 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学習法について詳しく述べる. 4章では接触作業への応用を考え, コンピュータシミュレーションおよび実験により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

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,

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

と書くことができる. ここで, $\theta \in \mathbb{R}^m$ は関節角度ベクトル, $M(\theta) \in \mathbb{R}^{m \times m}$ は慣性行列, $h(\theta, \dot{\theta}) \in \mathbb{R}^m$ 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, 手先の目標インピーダンスを

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

により記述する. ただし, $M_e, B_e, K_e \in \mathbb{R}^{l \times l}$ はそれぞれ, 手先の目標慣性行列, 目標粘性行列, 目標剛性行列で, $dX = X_e - X_d$ は目標手先位置を現在位置との偏差を表す. このとき, ヤコビ行列の逆行列を用いないインピーダンス制御則 [2] は次のようになる.

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

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

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

ただし, $M_x(\theta) = (JM^{-1}(\theta)J^T)^{-1} \in \mathbb{R}^{l \times l}$ はアームが特異姿勢にない限り正則で, $\hat{M}(\theta)$ は慣性行列の推定値, $\hat{h}(\theta, \dot{\theta})$ は $h(\theta, \dot{\theta})$ の推定値を表す. 式(4)の $\tau_{effector}$ はマニピュレータの手先のインピーダンスを調節するための関節トルク, 式(5)の τ_{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る.

以上より, マニピュレータの手先の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

Fig. 1 に非接触型インピーダンス制御 [4] の概念図を示す. いま, ある対象物がロボットに近づいてくる場合を考え, ロボットの手先を中心とする半径 r の仮想的な球を設定する. ここで, 手先の位置を $X_e = [x_e^1, x_e^2, \dots, x_e^l]^T \in \mathbb{R}^l$, 対象物の位

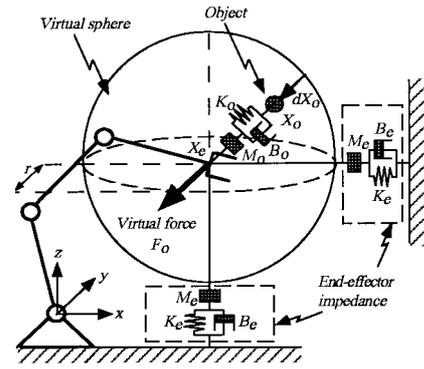


Fig. 1 Schematic representation of a non-contact impedance control

置を $X_o = [x_o^1, x_o^2, \dots, x_o^l]^T \in \mathbb{R}^l$ 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,

$$dX_o = X_r - rn \quad (6)$$

で与えられる. 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,

$$n = \begin{cases} \frac{X_r}{|X_r|} & (X_r \neq 0) \\ 0 & (X_r = 0) \end{cases} \quad (7)$$

と定義する.

対象物が仮想球の内部に侵入 ($|X_r| < r$) すると, 対象物と手先との間に仮想的なインピーダンス $M_o, B_o, K_o \in \mathbb{R}^{l \times l}$ を設定する. M_o, B_o, K_o は, それぞれ仮想慣性行列, 仮想粘性行列, 仮想剛性行列を表す. この仮想インピーダンスとベクトル 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,

$$F_o = \begin{cases} M_o d\ddot{X}_o + B_o d\dot{X}_o + K_o dX_o & (|X_r| \leq r) \\ 0 & (|X_r| > r) \end{cases} \quad (8)$$

と定義する. ただし, 式(7)(8)から明らかなように, 対象物が仮想球の外部に存在する場合および, 対象物と手先の位置が一致する場合は $F_o = 0$ となる. このとき, マニピュレータの手先の運動方程式は式(2)より,

$$M_e d\ddot{X} + B_e d\dot{X} + K_e dX = F_{int} + F_o \quad (9)$$

となる.

Fig. 2 に非接触型インピーダンス制御 (式(8)(9)) のブロック線図を示す. 図から対象物の位置 $X_o(s)$, 目標手先位置 $X_d(s)$ に対する手先位置 $X_e(s)$ の応答は

$$X_e(s) = \frac{M_o s^2 + B_o s + K_o}{M s^2 + B s + K} X_o(s) + \frac{M_e s^2 + B_e s + K_e}{M s^2 + B s + K} X_d(s) + \frac{-(M_o s^2 + B_o s + K_o) r n + F_{int}(s)}{M s^2 + B s + K} \quad (10)$$

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 $M_o \geq -M_e$, $B_o \geq -B_e$,

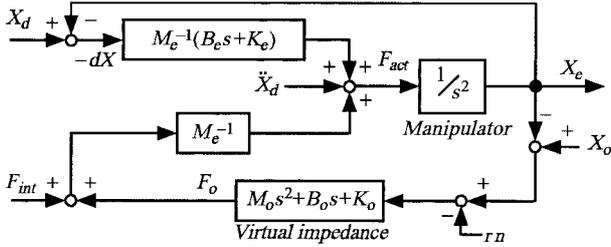


Fig. 2 The block diagram of the non-contact impedance control

$K_o \geq -K_e$ となる (ただし, 等号は三つ同時には成立しないものとする).

非接触型インピーダンス制御では対象とする作業に応じてロボットの手のインピーダンス M_e, B_e, K_e を調節できるという通常のインピーダンス制御の特徴に加えて, 手先と対象物との間に仮想的なインピーダンス M_o, B_o, K_o を設定でき, 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. そこで本論文では作業に適した 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 による仮想インピーダンスの学習

3.1 制御系の構成

本手法では Fig. 2 の制御系の仮想インピーダンスの部分, VSN (Virtual Stiffness Network), VVN (Virtual Viscosity Network), VIN (Virtual Inertia Network) という三つの NN で表現する. VSN, VVN, VIN 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, 仮想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. Fig. 3 に仮想インピーダンスの構成を, Fig. 4 に VSN を示す. なお, VVN, VIN も VSN と同様の構造を有する. いずれの NN も入力層には線形の入力関数を, 中間層, 出力層にはシグモイド型の関数を用いる. すなわち, 各層の入出力を x_i, y_i とすると,

$$x_i = \begin{cases} I_i & (\text{入力層}) \\ \sum w_{ij} y_j & (\text{中間層, 出力層}) \end{cases} \quad (11)$$

$$y_i = \begin{cases} x_i & (\text{入力層}) \\ \frac{1}{1+e^{-x_i}} & (\text{中間層}) \\ \frac{U}{2} \left(\frac{1-e^{-x_i+\theta}}{1+e^{-x_i+\theta}} \right) & (\text{出力層}) \end{cases} \quad (12)$$

である. ただし, w_{ij} はユニット j からユニット i への重み係数, U, θ は正の定数で, それぞれ, ネットワークの出力の最大値, しきい値を表す.

3.2 繰り返し学習法

NN の学習を行う際には, あらかじめ対象とする作業に応じて評価関数 $E(t)$ を定義し, この $E(t)$ を各時刻で最小 (極小) にするように NN の重み係数を更新する. 具体的な手順は以下の通りである.

まず NN の重み係数の初期値を設定し作業を 1 回行う. 次にその作業結果から計算した評価関数 $E(t)$ を減少させる方向にオフラインで NN の重み係数を修正する. そしてこの学習によ

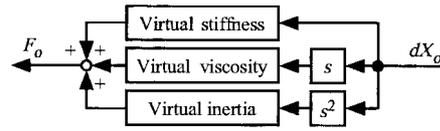


Fig. 3 Virtual impedance represented by three components

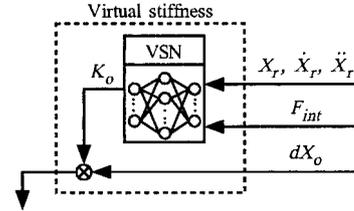


Fig. 4 Virtual stiffness realized by a neural network

り修正した NN を用いて再度作業を行い, 評価関数 $E(t)$ を求めるという手順を繰り返すことにより, NN の出力は評価関数 $E(t)$ を極小化するという意味でより望ましい仮想インピーダンスに近づいていくことになる. もちろん厳密には 1 回の作業につき一度の重み修正しか行うことができないが, 本論文では誤差の修正量が微小であると仮定し 1 回の作業につき複数回の重み修正を行うこととする. ネットワークの重み w_{ij} の修正量 Δw_{ij} は

$$\Delta w_{ij} = -\eta \frac{\partial E(t)}{\partial w_{ij}} \quad (13)$$

$$\frac{\partial E(t)}{\partial w_{ij}} = \frac{\partial E(t)}{\partial F_{act}(t)} \frac{\partial F_{act}(t)}{\partial O(t)} \frac{\partial O(t)}{\partial w_{ij}} \quad (14)$$

で与えられる. η はニューラルネットの学習率を表し, $O(t) \in R^{l \times l}$ は NN の出力である. ここで, $\frac{\partial F_{act}(t)}{\partial O(t)}$ は Fig. 2 および式 (8) 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が, $\frac{\partial E(t)}{\partial F_{act}(t)}$ はマニピュレータのダイナミクスが存在するために直接計算することができない. そこで, 文献 [22] を参考に betterment process [26] を用いて $\frac{\partial E(t)}{\partial F_{act}(t)}$ を近似する. この評価関数が極小になるように学習を行えば VSN, VVN, VIN は作業に適した仮想インピーダンスパラメータを実現していることになる.

4. 接触作業への応用

環境への接触作業に関して, マニピュレータの制御パラメータや安定条件を解析的に求めようとする研究はこれまでも数多く行われてきた [27] ~ [29]. それらの研究に対して本論文では, 仮想インピーダンスパラメータを繰り返し学習的に調節することが接触作業にどの程度有効であるかを示す.

本論文では 2 種類の接触作業を考える. 一つはマニピュレータの手先が環境に近づき環境と接触する作業, もう一つは接近してくる対象物に接触し, その運動をできるだけスムーズに抑制するという作業 (以下, この作業をキャッチング作業と呼ぶ) である.

4.1 評価関数の設定

接触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しに目標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、接触前にあらかじ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．そこで本論文では NN の学習の評価関数を

$$E(t) = E_v(t) + \mu E_f(t) \quad (15)$$

$$E_v(t) = \frac{1}{2}(\alpha(X_r)\dot{X}_r(t_i) - \dot{X}_r(t))^2 \quad (16)$$

$$E_f(t) = \frac{1}{2} \int_0^t (F_d(u) - F_{int}(u))^2 du \quad (17)$$

と設定した． t_i は環境が仮想球に進入した瞬間の時刻で、 μ は正の定数である．式(16)の $E_v(t)$ でマニピュレータと環境との相対速度を、式(17)の $E_f(t)$ で力制御誤差を評価するのである．ただし、本手法では誤差の最急降下方向を PD 型の betterment process [26] を用いて近似しているため、力制御誤差の積分値を用いることで F_{int} の微分計算を回避している．ここで式(16)の $\alpha(X_r)$ には対象物が仮想円に侵入した直後の速度変化を滑らかにする働きがあり、本論文では

$$\alpha(X_r) = \frac{1 - \cos(\frac{\pi}{r}|X_r|)}{2} \quad (18)$$

とした．この $\alpha(X_r)$ を Fig. 5 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 $|X_r(t_i)| = r$ となるため $\alpha(r) = 1$ となり、対象物が仮想球に侵入した瞬間の式(16)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 $\alpha(X_r)$ は 0 に近づくと、 $E_v(t)$ を小さくするためには相対速度 \dot{X}_r を 0 に近づけねばならない．これにより接触前にマニピュレータの手先速度を調節する必要が生じるのである．

4.2 環境への接触作業

バリ取り作業や物体の把握作業などマニピュレータが積極的に環境に接触する作業は少なくない．本論文ではその一例として例えば鉛筆で字を書くときのような把握した物体で環境に接触しその表面を削う作業を考え、そのコンピュータシミュレーションを行った (Fig. 6)．

このような接触作業では環境を対象物とみなし、手先と環境表面との間に仮想インピーダンスが働くと考えればよい．いま、環境表面の接線方向の摩擦はないと仮定し、手先インピーダンス、仮想インピーダンスとも対角行列に限定すると、この問題は環境表面の法線方向の自由度のみを考えればよい．ここで把持物体は剛体であると仮定した．また、環境表面の特性を粘弾性 $B_b, K_b \in \mathbb{R}^{l \times l}$ を用いてモデル化し、マニピュレータの手先と対象物との相対位置から相互作用力 F_{int} を計算する．すなわち

$$F_{int} = \begin{cases} B_b d\dot{X}_b + K_b dX_b & (|X_r| \leq R_b) \\ 0 & (|X_r| > R_b) \end{cases} \quad (19)$$

$$dX_b = X_r - R_b n \quad (20)$$

である．ここで、 B_b, K_b はそれぞれ対象物の粘性行列、剛性行列で、 R_b は対象物の位置 X_o から対象物表面の接触点まで

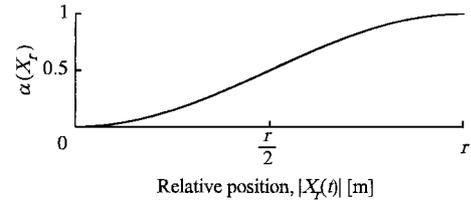


Fig. 5 A gain function $\alpha(X_r)$ in $E_v(t)$

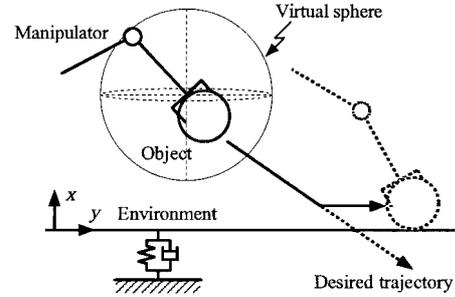


Fig. 6 An example of a contact task

の距離を表す．この R_b により、手先と対象物が接触している場合も仮想インピーダンスが働くことになる．ここでは、環境に接触させるために手先の平衡位置を初期位置 $x = 0.1$ [m] から $x = -0.01$ [m] に時刻 $t = 0$ でステップ状に変化させた．マニピュレータの手先インピーダンスは $K_e = 400$ [N/m], $B_e = 200$ [Ns/m], $M_e = 25$ [kg] と設定し、環境表面の特性は $K_b = 2,000$ [N/m], $B_b = 70$ [Ns/m], $R_b = 0.01$ [m], また仮想インピーダンスの仮想球の半径は $r = 0.05$ [m], 目標相互作用力は $F_d = 1$ [N] とした．

NN は 4 層構造で、ユニット数は入力層 3, 中間層 15×2 層, 出力層 1 である．重み行列 ω_{ij} の初期値は $|\omega_{ij}| < 0.05$ の一様乱数で与え、VSN の学習率を $\eta_p = 10^{-5}$, VVN を $\eta_v = 5 \times 10^{-3}$, VIN を $\eta_a = 10^{-4}$ とした．また、NN の出力値が $-1,000 \sim 1,000$ となるよう NN の出力ユニットのシグモイド関数を調節した．繰り返し作業 1 回につき NN の重み係数を修正する回数は 5 回である．なお、式(15)の $E(t)$ に含まれる定数 μ は $\mu = 1$ とした．

Fig. 7 に学習過程を示す．横軸は作業の繰り返し回数で、Fig. 7(a)の縦軸は $E(t)$ の時間平均

$$\bar{E} = \frac{1}{t_f} \int_0^{t_f} E(t) dt \quad (21)$$

である．ただし、 $t_f = 4$ [s] とした．学習の初期では大きかった評価関数値は作業を繰り返すうちに指数関数的に減少し、100 回目の作業時にはかなり 0 に近づいていることが分かる．本論文で設定した評価関数はその性質上 0 にはならないが、評価関数を最小 (極小) にするという意味で学習がうまく進んでいる様子が分かる．同様に、Fig. 7(b)~(c) に仮想インピーダンスパラメータの平均値 $\bar{K}_o, \bar{B}_o, \bar{M}_o$ を示す． \bar{K}_o は接触後の目標相互作用力を実現する値に、 \bar{B}_o, \bar{M}_o は式(16)で与えられた接近速度をできるだけ実現する値にそれぞれ収束している．

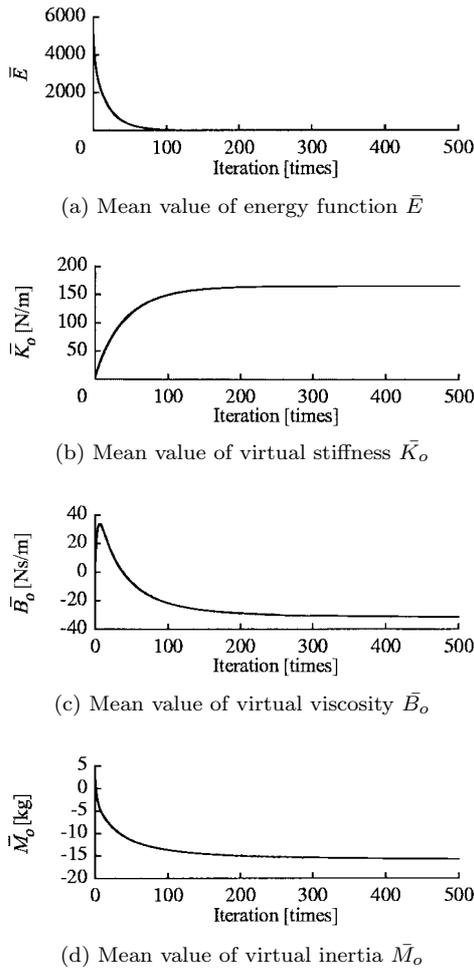


Fig. 7 Learning history of the contact task

Fig. 8 (a) に学習前と学習後（学習回数 500 回後）の手先位置，(b) に相互作用力 F_{int} の時間変化を示す．Fig. 8 (a) の破線は環境が存在しない場合のマニピュレータの手先軌道を示しており，時刻 $t = 0$ [s] で初期位置 $x = 0.1$ [m] を離れ約 2 秒後に目標位置 $x_d = -0.01$ [m] に到達している．環境が存在する場合（図中，実線，点線）は $x = 0$ [m] に到達した時，相互作用力 F_{int} が発生する．学習前は仮想インピーダンスが小さいため接触前にマニピュレータの手先軌道は変化せず，環境に接触する際に大きな相互作用力が生じている．一方，学習後は接触前に手先を減速することで接触力を抑え，同時に仮想ステイフネスを適切な値に調節することにより目標手先力 $F_d = 1$ [N] を実現していることが分かる．

4.3 キャッチング作業

Fig. 9 に 1 自由度マニピュレータ ($l = 1$) によるボールのキャッチング作業を示す．ここではボールは剛体棒で天井からつるされていると仮定する． θ は振り子の角度である．初期手先位置を作業座標系の原点とし，振り子の支点を $X_f = [0.5, 2.1]$ [m]，振り子の支点からボールの中心までの長さを $L = 2.1$ [m]，初期角度を $\theta_0 = -5\pi/36$ [rad]，マニピュレータの手先インピーダンスを $M_e = 25$ [kg]， $B_e = 200$ [Ns/m]， $K_e = 400$ [N/m]

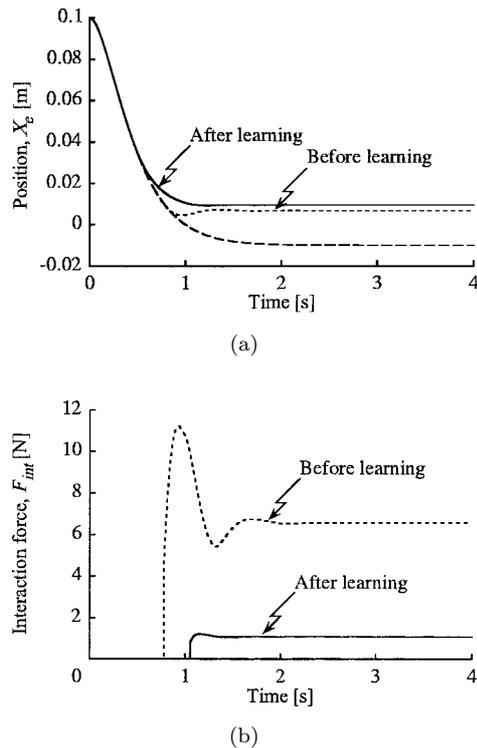


Fig. 8 Learning results of the contact task

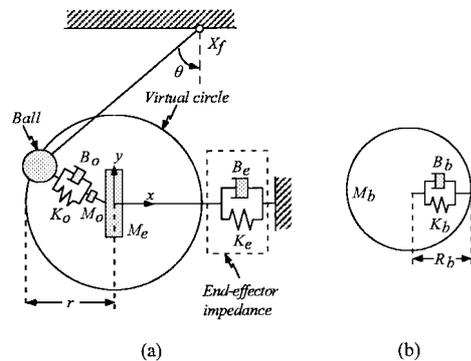


Fig. 9 An example of a catching task

と設定した．またマニピュレータの目標手先位置 X_d は初期手先位置とし，手先の目標相互作用力を $F_d = 5$ [N] とした．

次に，手先を中心とする半径 $r = 0.2$ [m] の仮想円を設定した．ボールは質量 $M_b = 0.6$ [kg] とし，粘弾性特性（式 (19)）は $B_b = 70$ [Ns/m]， $K_b = 2,000$ [N/m] とした．ボールの半径に相当する式 (19) の R_b は $R_b = 0.0322$ [m] である．なお NN の構造は 4.2 で用いた NN と同じにした．

Fig. 10 に学習過程を，Fig. 11 (a) に学習前と学習後（学習回数 500 回後）の手先とボールの挙動，(b) に相互作用力 F_{int} の時間変化を示す．時刻 $t = 0$ [s] で初期位置 $x = -0.4$ [m] を離れたボールは $x = 0$ [m] に存在するマニピュレータの手先に衝突する．図から，学習前では衝突の際の相互作用力が大きいため，ボールが大きく跳ねているが，学習後は VSN, VVN, VIN が速度誤差，力誤差を小さくするように作用するため相

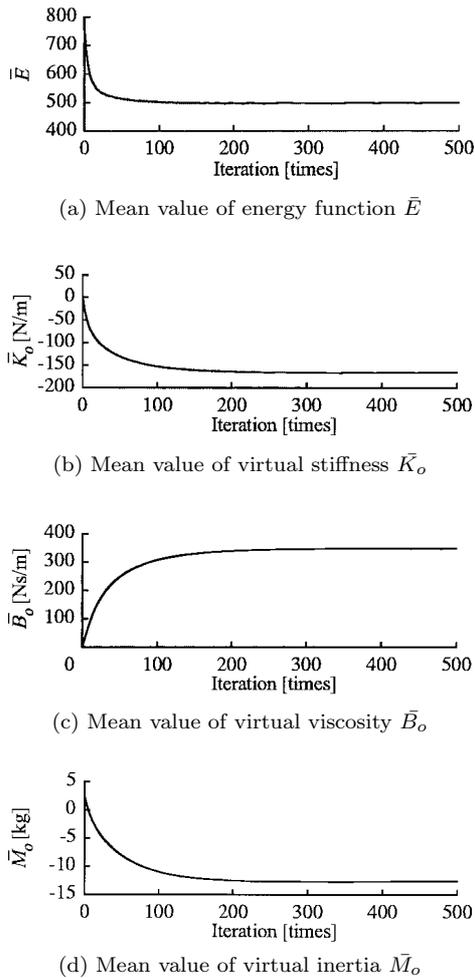


Fig. 10 Learning history of the catching task

相互作用力が小さくなり、手先とボールがスムーズにつりあい状態に移行していることが分かる。学習によりマニピュレータがボールを柔らかくキャッチングできるようになったのである。

次に Fig. 12 に示す DD ロボット (3 関節平面型:(株)神戸製鋼所製) と対象物の位置を測定するための PSD カメラ ((株)浜松ホトニクス製) を用いて、このキャッチング作業の学習実験を行った。マニピュレータとボールが接触する際に発生する力を計測するために DD ロボットの手先にはラケットを設け、そこにロードセル ((株)共和電業) を取り付けた (Fig. 13)。対象物には一辺 0.1 [m] のゴムの立方体 (質量 0.35 [kg]) を用い、天井からアルミ製の支持棒で吊すことにより振り子運動を実現している。ゴム塊には LED が装着してあり水平面上の位置が計測できるようになっている。DD ロボットの制御のサンプリング時間は 1 [ms] である。このサンプリング時間は衝突の際に生じる衝撃力を十分計測可能な時間として定めた。また 1 回の作業につき NN の重み係数の修正を 10 回行うことで繰り返し作業回数を減少させた。なお、この実験では簡単のため $M_o = 0$ とし、VSN と VVN のみの学習を行った。

Fig. 14 (a) に学習前と学習後 (学習回数 3 回後) の手先の挙動を示す。また、Fig. 14 (b) は学習前、(c) は学習後の相互作用

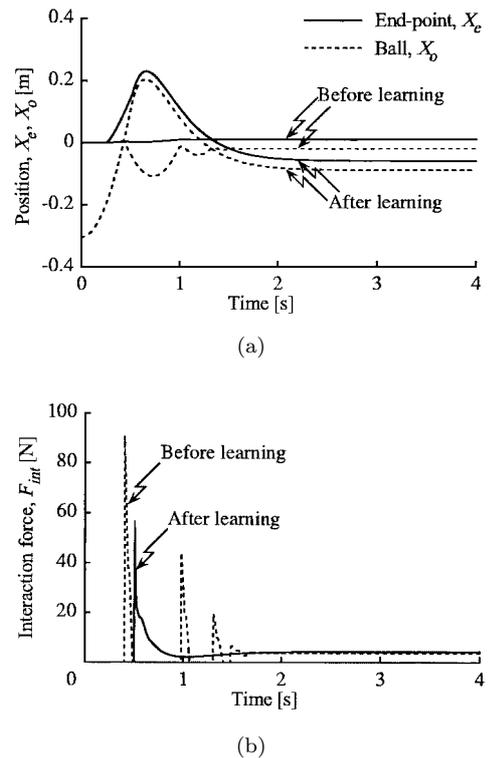


Fig. 11 Learning results of the catching task

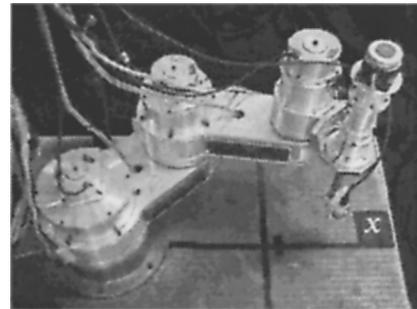


Fig. 12 A direct-drive robot in a planar task space

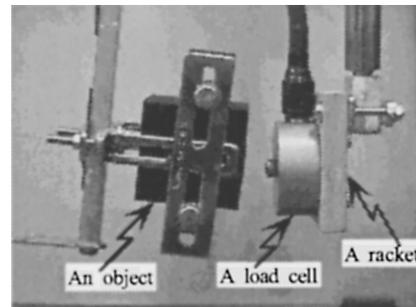
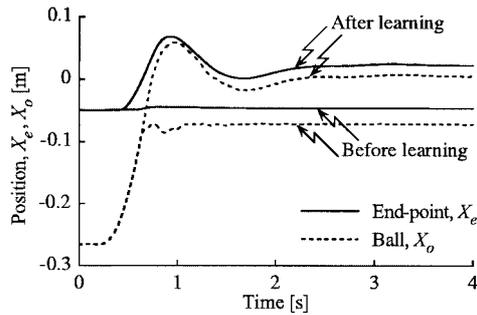
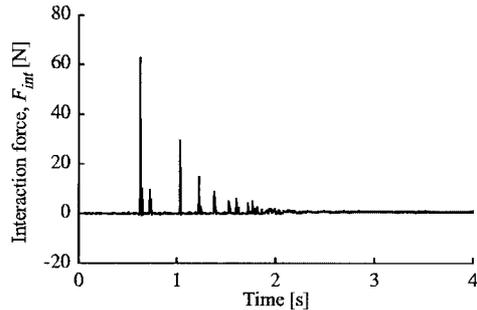


Fig. 13 An object and a load cell used in the experiments

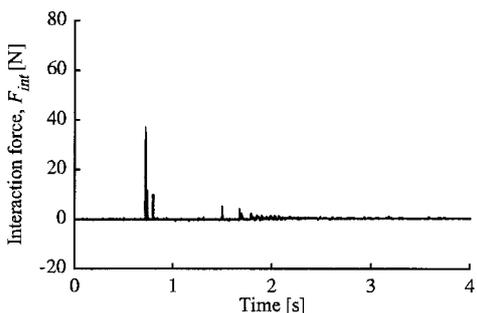
力 F_{int} の時間変化である。学習前は相互作用力が大きいため対象物が大きく跳ね返り、何回も接触を繰り返している。しかし学習後はマニピュレータが接触前に手先を引くことで 1 回目の接触の際に生じる相互作用力が小さくなり、手先と対象物が



(a) Positions before and after learning



(b) Interaction force before learning



(c) Interaction force after learning

Fig. 14 Experimental results of the catching task by the D.D. robot

より早く釣り合い状態に到達していることが分かる．以上により本手法の有効性が明らかになった．

5. まとめと今後の課題

本論文では非接触型インピーダンス制御の仮想インピーダンスパラメータを NN を利用して調節する方法を提案した．この方法は，マニピュレータを繰り返し作業させながら作業の評価関数を最小（極小）にするよう NN を学習するという考えに基づいている．そしてこの方法を接触作業に応用し，実機実験を行うことでマニピュレータや環境に過大な力を加えないで目標の接触力を実現するための仮想インピーダンスパラメータを学習的に獲得できることを示した．

本手法は誤差逆伝播法を用いているため，インピーダンスパラメータの一部を固定するといった拘束条件下においても評価関数を最小（極小）にする仮想インピーダンスパラメータを獲

得することができる．逆に言うと作業を実現するために必ずしも仮想インピーダンスパラメータの剛性項，粘性項，慣性項すべてを学習する必要はない．例えばキャッチング作業の実機実験で行ったように慣性項をあらかじめ設定した値に固定し，慣性項以外のパラメータを学習的に獲得することや，系全体の安定性などを考慮してパラメータの一部のみを学習し他のパラメータは拘束条件から求めることも可能である．

本論文では仮想インピーダンスパラメータのみを調節することで議論を進めてきたため，手先インピーダンスパラメータの調節法については特に触れなかった．しかしながら接触作業においては，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するという方法も考えられる．今後は作業空間を多次元化し，より複雑な作業に対する応用可能性について考察するとともに，手先インピーダンスパラメータの並列学習や学習の効率化，オンライン学習法についての検討を行う予定である．なお，本研究の一部は文部省科学研究費補助金（11650450）によるものでここに改めて謝意を表します．

参考文献

- [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] A. Castano and S. Hutchinson: "Visual Compliance: Task-Directed Visual Servo Control," IEEE Transaction on Robotics and Automation, vol.10, no.3, pp.334-342, 1994.
- [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.616-623, 1997.
- [5] T. Tsuji and M. Kaneko: "Non-contact Impedance Control for Redundant Manipulator," IEEE Transaction on Systems, Man, and Cybernetics - Part A, vol.29, no.2, pp.184-193, 1999.
- [6] 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.
- [7] 鶴田, 光岡, 福田, 栗原: "神経回路モデルによるロボットの力制御(1自由度マニピュレータの制御)", 日本ロボット学会誌, vol.7, no.1, pp.47-51, 1989.
- [8] 福田, 栗原, 鶴田, 光岡: "神経回路網によるロボット・マニピュレータの位置・力制御の研究(第1報)", 日本機械学会論文誌, C, vol.56, no.527, pp.210-216, 1990.
- [9] 福田, 柴田, 鶴田, 光岡: "神経回路網によるロボット・マニピュレータの位置・力制御の研究(第2報)", 日本機械学会論文誌, C, vol.57, no.535, pp.866-873, 1991.
- [10] 柴田, 福田, 小菅, 新井, 鶴田, 光岡: "神経回路網によるロボット・マニピュレータの位置・力制御の研究(第6報)", 日本機械学会論文誌, C, vol.58, no.549, pp.108-115, 1992.
- [11] H.-L. Pei, Q.-J. Zhou and T.P. Leung: "A Neural Network Robot Force Controller," Proc. of the 1992 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp.1974-1979, 1992.
- [12] T.H. Connolly and F. Pfeiffer: "Neural Network Hybrid Position/Force Control," Proc. of the 1993 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp.240-244, 1993.
- [13] J.M. Tao and J.Y.S. Luh: "Application of Neural Network with Real-Time Training to Robust Position/Force Control of Multiple Robots," Proc. of IEEE Int. Conf. on Robotics and Automation, pp.142-148, 1993.
- [14] 木口, D.S. Neculescu, 福田: "ニューラルネットワークを利用した未知環境でのハイブリッド制御", 日本ロボット学会誌, vol.13, no.2, pp.291-296, 1995.

- [15] 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.
- [16] D. Katić and M. Vukobratović: "Learning Impedance Control of Manipulation Robots by Feedforward Connectionist Structures," *Proc. of IEEE Int. Conf. on Robotics and Automation*, pp.45-50, 1994.
- [17] C.C. Cheah and D. Wang: "Learning Impedance Control for Robotic Manipulators," *Proc. of IEEE Int. Conf. on Robotics and Automation*, pp.2150-2155, 1995.
- [18] S. Jung and T.C. Hsia: "On Neural Network Application to Robust Impedance Control of Robot Manipulators," *Proc. of IEEE Int. Conf. on Robotics and Automation*, pp.869-874, 1995.
- [19] S.-T. Lin and H.-C. Tsai: "Impedance Control with On-Line Neural Network Compensator for Dual-Arm Robots," *J. of Intelligent and Robotic Systems*, vol.18, pp.87-104, 1997.
- [20] 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.
- [21] 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.
- [22] 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.
- [23] 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.
- [24] 辻, 赤松, 原田, 金子: "ニューラルネット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.
- [25] B.-H. Yang and H. Asada: "Progressive Learning and Its Application to Robot Impedance Learning," *IEEE Transaction on Neural Networks*, vol.7, no.4, pp.941-952, 1996.
- [26] 川村, 宮崎, 有本: "動的システムの学習的制御法 (Betterment Process) の提案", *計測自動制御学会論文集*, vol.22, no.1, pp.56-62, 1986.
- [27] 北垣, 内山: "外部環境に対するマニピュレータの最適接近速度", *日本ロボット学会誌*, vol.8, no.4, pp.413-420, 1990.
- [28] 正司, 稲葉, 福田, 細貝: "衝突を用いた多リンクマニピュレータの安定制御", *日本ロボット学会誌*, vol.9, no.5, pp.592-600, 1991.
- [29] 正司, 稲葉, 福田: "衝突を含むロボットマニピュレータの統一のアプローチに基づく安定制御", *日本ロボット学会誌*, vol.11, no.5, pp.677-692, 1993.



野口裕史 (Yuji Noguchi)

1975年4月2日生。1998年広島大学工学部第二類(電気系)卒業。同年4月,広島大学大学院工学研究科(博士課程前期)情報工学専攻入学,現在に至る。主にマニピュレータのインピーダンス制御に関する研究に従事。(日本ロボット学会学生会員)



原田研介 (Kensuke Harada)

1968年9月28日生。1997年3月京都大学大学院工学研究科機械工学専攻博士後期課程修了。博士(工学)。同年4月広島大学助手,現在に至る。ロボットハンド,ロボットマニピュレータの力学と制御に関する研究に興味を持つ。IEEE,計測自動制御学会,日本機械学会などの会員。(日本ロボット学会正会員)



辻 敏夫 (Toshio Tsuji)

1959年12月25日生。1985年広島大学大学院工学研究科博士課程前期修了。同年同大学工学部助手,1994年同助教授,現在に至る。工学博士。人間とロボットの運動制御,ニューラルネット,マン・マシンシステムなどの研究に従事。IEEE,計測自動制御学会,日本機械学会,電気学会,電子情報通信学会などの会員。(日本ロボット学会正会員)



金子 真 (Makoto Kaneko)

1954年1月18日生。1981年3月東京大学工学系研究科博士課程卒業。工学博士。同年4月通産省工業技術院機械技術研究所入所。1990年4月,九州工業大学情報工学部助教授。1993年10月広島大学教授,現在に至る。ロボットハンド,力覚センサ,触覚ベースアクティブセンシングなどの研究に興味を持つ。IEEE,計測自動制御学会,日本機械学会などの会員。(日本ロボット学会正会員)