

# プレディクションサーボイングによる移動物体への追従性向上

## Improving Tracking Function to Moving Target Objects by Prediction Servoing

須浪 唯介 (岡山大) 正 見浪 謹 (岡山大)  
正 矢納 陽 (岡山大)

Yusuke SUNAMI, Okayama University, y-sunami@suri.sys.okayama-u.ac.jp  
Mamoru MINAMI, Okayama University  
Akira YANOOU, Okayama University

Nowadays, in fields of robot vision, a control method called visual servoing attracts attention. The visual servoing is a method to control robots by visual information in a feedback loop, which is obtained by visual sensors. So, this method is expected to be able to have robots adapt to tasks in changing or unknown environment. However, when the target object moves quickly, it happens to be unable for the machine to track it due to robots' motion delay. To decrease the delay time, we have proposed prediction servoing control method, which is the method of predicting the position of the target object based on the past position data of the object and learning of neural networks, and utilize it as a desired position for the visual servoing. In this research we have confirmed how the learning function in neural networks work for precise prediction of target's future position through visual servoing experiments.

**Key Words:** Visual Feedback Control, GA, Prediction Servoing

### 1. 緒言

現在、様々な分野においてロボットが利用されている。近年では、益々自律動作や未知の環境下での動作が要求されるようになった。しかし、ロボットの動作は技術者に教示される必要があるものや、一定の動作を繰り返すものが一般的である。例えば、災害地区や宇宙空間などで作業を行う極限ロボットや、病院や家庭で活躍するロボットにおいては、未知の環境下で、自律的に作業を行なう必要があるため、外界の情報を検出し制御をする機構が必要となる。そこで、ビジュアルサーボイングシステムが必要になる。ビジュアルサーボは視覚センサから得られる視覚情報をフィードバックループに組み込みロボットを制御するため、常に変化する環境や未知の環境でのロボットの活躍が期待される。

しかし対象物を見てから行動するビジュアルサーボでは、対象物の動きが速い場合ロボットの行動に遅れが生じることがある。その問題を解決するために著者の一人は対象物の動きをある程度予測し行動する制御手法を提案した [1]~[5](以下この手法をプレディクションサーボイングと呼ぶ)。対象物の将来位置予測手法としては過去の位置情報を基に将来の点を円軌道に見立てて求める手法である円弧近似によって行う。しかし対象物は必ずしも円運動するとは限らず円弧近似だけでは誤差が発生する場合がある。そのため誤差を零にするようにニューラルネットワーク(N.N.)で学習を行い、円弧近似の予測位置に補正を加え誤差を最小化するようにニューラルネットワークは学習する。本報では実機を用いてビジュアルサーボイングとプレディクションサーボイングで比較実験を行い、またニューラルネットワークの学習によりプレディクションサーボイングにどのような影響が出ているのか調べプレディクションサーボイングの有効性を確認した。

### 2. 円弧近似

対象物の予測位置導出にあたって、対象物の動きを円運動に見立てて予測する。

本手法では図 1 に示すように、過去の位置 2 点  $r_{n-2} = (x_{n-2}, y_{n-2})$ ,  $r_{n-1} = (x_{n-1}, y_{n-1})$ , 現在の位置 1 点  $r_n = (x_n, y_n)$ , 計 3 点の位置情報から円の中心点  $p_n = (p_n, q_n)$ , 半径  $l_n$ , 角速度  $\omega_n$  を導出する(詳細は文献 [1] 参照)。

そして、 $k\Delta t[s]$  後の円弧運動を仮定した円弧予測将来位置

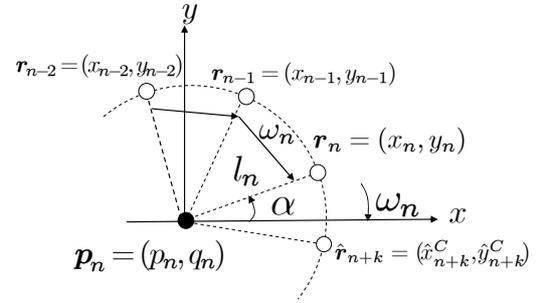


Fig. 1 Circular Approximation by using vector

$\hat{r}_{n+k}^C = (\hat{x}_{n+k}^C, \hat{y}_{n+k}^C)$  は以下の式で表すことができる。

$$\hat{x}_{n+k}^C = p_n + l_n \cos(\alpha + k\omega_n \Delta t) \quad (1)$$

$$\hat{y}_{n+k}^C = q_n + l_n \sin(\alpha + k\omega_n \Delta t) \quad (2)$$

ここで  $\alpha$  は図 1 に示すように現在位置と円の中心点を結んだ直線と  $x$  軸との角度である。

### 3. ニューラルネットワーク

本研究のニューラルネットワークでは誤差逆伝播法を用いている [1][2]。誤差逆伝播法はフィードフォワード型ニューラルネットワークの学習法の一つであり、訓練データが与えられる度、結線重みを微小修正する非線形関数の近似手法として知られている。フィードフォワード型ニューラルネットワークは、ネットワークを構成する素子の結合重み  $w_{ij}$  と閾値  $\theta_i$  の値を変える事により入出力関係を変化させる。ネットワークの入力を  $x_N$ , 出力を  $y_M$  とし、ネットワークの入出力関係を、関数  $y_M = F(x_N)$  で表す。誤差逆伝播法は、この関数が指定された入出力関係を実現するように、ネットワーク内部のパラメータ  $w_{ij}, \theta_i$  を定める手続きを与える。

#### 3.1 円弧近似誤差を補正するニューラルネットワーク

前章で説明した円弧近似の予測位置にニューラルネットワークの補正值を用いることで誤差補正を行う。円弧予測将来位置  $\hat{r}_{n+k}^C$  と  $(n+k)\Delta t$  時刻の実際の位置  $r_{n+k}^M = (x_{n+k}^M, y_{n+k}^M)$  が等しければ誤差は 0 となり、正しい予測が行われているといえる。しかし、対象物は一般的には非線形の行動をするため、実際には  $(n+k)\Delta t$  時刻において予測誤差  $\Delta \hat{r}_{n+k}^C$  が発生する。

$$\Delta \hat{r}_{n+k}^C = r_{n+k}^M - \hat{r}_{n+k}^C \quad (3)$$

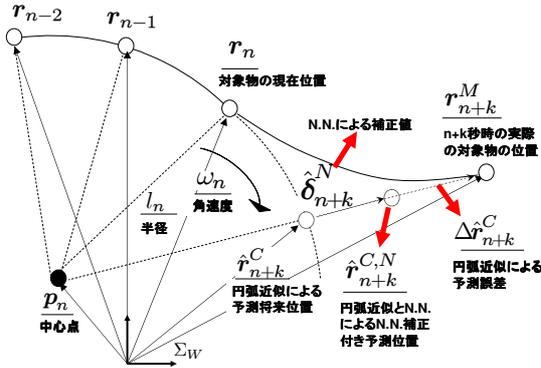


Fig. 2 Circular approximation by using N.N.

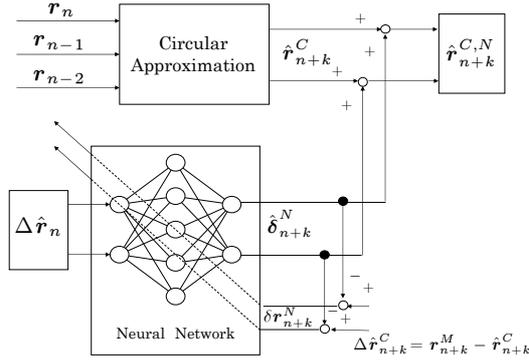


Fig. 3 Block diagram of prediction method

誤差逆伝播法を用いた対象物の行動予測のブロック線図を図3に示す。まず、式(1)、(2)から円弧近似により予測将来位置 \$\hat{r}\_{n+k}^C\$ を算出する。 \$\Delta t \cdot n\$ 時刻の N.N. の入力は \$\Delta t \cdot k\$ 時刻前の時刻 \$(n-k)\Delta t\$ に予測された予測誤差

$$\Delta \hat{r}_n^C = r_n^M - \hat{r}_n^C \quad (4)$$

である。上式は式(3)の時刻 \$(n+k)\Delta t\$ を \$-k\Delta t\$ 時間を遡った時刻の予測を表している。図3に示すように、N.N.の将来時刻 \$(n+k)\Delta t\$ の出力を \$\delta\_{n+k}^N\$ と表し、次式のように円弧近似結果 \$\hat{r}\_{n+k}^C\$ に加算することで N.N. 補正付予測位置 \$\hat{r}\_{n+k}^{C,N} = (\hat{x}\_{n+k}^{C,N}, \hat{y}\_{n+k}^{C,N})\$ を得る。

$$\hat{r}_{n+k}^{C,N} = \hat{r}_{n+k}^C + \delta_{n+k}^N \quad (5)$$

図3のブロック線図では N.N. 補正と円弧近似を用いて、対象物の予測位置 \$\hat{r}\_{n+k}^{C,N}\$ が式(5)の和算により求められるように表現されている。N.N.の教師信号 \$\delta r\_{n+k}^N\$ を、

$$\delta r_{n+k}^N = \Delta \hat{r}_{n+k}^C - \delta_{n+k}^N \quad (6)$$

と定義する。N.N.は \$\delta r\_{n+k}^N\$ を0に近づけるように誤差逆伝播法で学習を行う。この時学習が進み \$\delta r\_{n+k}^N \rightarrow 0\$ を仮定できる状況を考える。この時式(6)より、 \$\Delta \hat{r}\_{n+k}^C = \delta\_{n+k}^N\$ が成り立つ。この時、式(3)は

$$\delta_{n+k}^N = r_{n+k}^M - \hat{r}_{n+k}^C \quad (7)$$

となり上式を式(5)に代入すると、

$$\hat{r}_{n+k}^{C,N} = r_{n+k}^M \quad (8)$$

が得られる。以上の議論は、 \$\hat{r}\_{n+k}^{C,N} \rightarrow r\_{n+k}^M\$ (\$\delta r\_{n+k}^N \rightarrow 0\$)、つまり N.N. 補正付円弧近似予測位置は \$(n+k)\Delta t\$ 時刻の対象物の位置に収束することを示している。

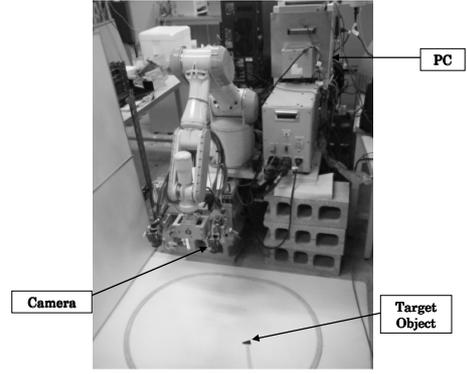


Fig. 4 Photograph of experiment system

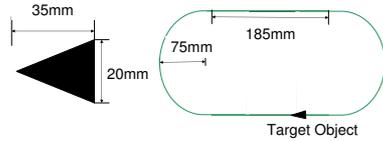


Fig. 5 Target object and its moving course

## 4. 実機実験

### 4.1 実験環境

実験機の概要を図4に示す。アームロボット PA-10(三菱重工製)の手先にはビデオカメラ(ビデオレート 33[fps])が装着されており、画像認識・行動予測及びアームロボットの制御を行う計算機には、DELL Optiplex(CPU:Pentium42GHz)を使用しており、画像入力ボードは、サイバテック製 CT3001Rev2を用いている。また今回の対象物は図5に示すように、円運動と直線運動ができる全長 920mm のコースを平均 10 秒で移動する、高さ 35mm、長さ 20mm の黒色の三角形の対象物である。

### 4.2 ビジュアルサーボイング

最初にビジュアルサーボイングによる追従制御について説明を行う。まず対象物の位置姿勢認識は 1-step GA を用いた注視 GA 認識法によって行われ実時間で対象物の位置姿勢を認識している([6]~[9])。次に図6に注視 GA 認識法を組み込んだビジュアルサーボ系におけるカメラ座標とロボットの関係を示す。カメラの視野範囲は \$x\$ 方向 150[mm]、\$y\$ 方向 120[mm] である。GA の遺伝子の中で各時刻における最良の認識結果 \$\phi\_n = [x\_n^{GA}, y\_n^{GA}]^T\$ はカメラ座標系 \$\Sigma\_C\$ を基準にしたモデルの \$n\Delta t\$ 時刻の位置をピクセル単位で表している。このため対象物の実際の位置 \$r\_n^M\$ を以後 \$C r\_n^M\$ と表す。カメラ画像中心位置 \$C r\_n^H\$ と対象物との位置誤差 \$\Delta^C r\_n\$ は、

$$\Delta^C r_n = C r_n^M - C r_n^H \quad (9)$$

$$C r_n^M = \begin{bmatrix} k_x & 0 \\ 0 & k_y \end{bmatrix} \phi_n = \begin{bmatrix} k_x x_n^{GA} \\ k_y y_n^{GA} \end{bmatrix} \quad (10)$$

と表される。また \$C r\_n^H = 0\$ となるようにカメラの原点と認識位置の原点は一致させており、\$k\_x, k\_y\$ は画像内の [pixel] 単位を実際の [mm] 単位に変換する係数であり、これは実験システムのカメラの取り付け位置や入力画像のズーム倍率により決定される係数である。マンピュレータを対象物方向に動かすためには、カメラ座標系で [pixel] 単位で表された位置誤差 \$\Delta^C r\_n = [\Delta^C x\_n, \Delta^C y\_n]\$ を作業座標系 \$\Sigma\_W\$ で表された [mm] 単位の指示値 \$\Delta^W r\_n\$ に変換する必要がある、その変換式を式(11)

Table 1 Gain parameters

$K_P$	[ 0.75 0.75 ]
$K_V$	[ 0.35 0.35 ]
Link Number [ L1 L2 L3 L4 L5 L6 L7 ]	
$K_{SP}$	[ 3200 3200 1400 1400 1000 1000 1000 ]
$K_{SI}$	[ 1362 1362 596 596 596 426 426 ]

に示す．

$$\Delta^W r_n = {}^W R_C \Delta^C r_n \quad (11)$$

ここで、 ${}^W R_C$  は  $\Sigma_W$  と  $\Sigma_C$  との姿勢変換行列である．ロボットハンドの速度指示値は次式で与えられる．

$$\dot{r}_n^d = K_P \Delta^W r_n + K_V (\Delta^W r_n - \Delta^W r_{n-1}) \quad (12)$$

ロボットハンドの目標速度  $\dot{r}_n^d$  とこれを実現する関節角速度  $\dot{q}_n^d$  との関係は、ロボットの運動力学関係より  $\dot{r}_n^d = J(q)_n \dot{q}_n^d$  と表わされる．ここで  $J(q)_n$  はヤコビ行列である．この関係を用いて式 (12) により定まる  $\dot{r}_n^d$  を実現する  $\dot{q}_n^d$  が定まる．PA-10 に組み込まれているサーボアンプの速度制御系は PI 制御を基本にしており、次式で表わされる．

$$\tau = K_{SP}(\dot{q}_n^d - \dot{q}_n) + K_{SI}(q_n^d - q_n) \quad (13)$$

ここで  $K_{SP}$ 、 $K_{SI}$  は正定対角行列である．GA 探索によって得られる目標関節角度  $q_n^d$  が一定値に収束する場合、つまり対象物が静止し、さらに GA が静止した対象物の位置 / 姿勢に収束する場合、そのとき目標位置  $r_n^d$  は対象物の位置と一致し、ロボットハンドは対象物の直上に制御される．式 (13) のコントローラを組み込んだサーボシステムを図 7 に示す．なお、式 (12)、(13) の  $K_P$ 、 $K_V$ 、 $K_{SP}$ 、 $K_{SI}$  ゲインは表 1 のように決定されている．

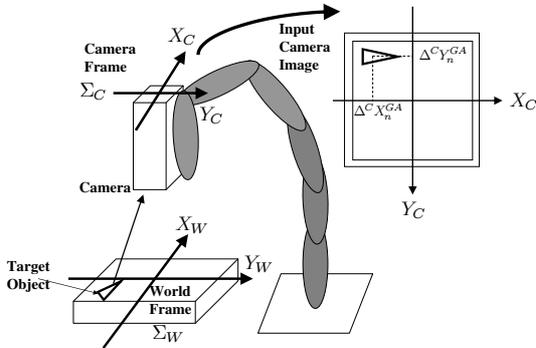


Fig. 6 Coordinates conversion

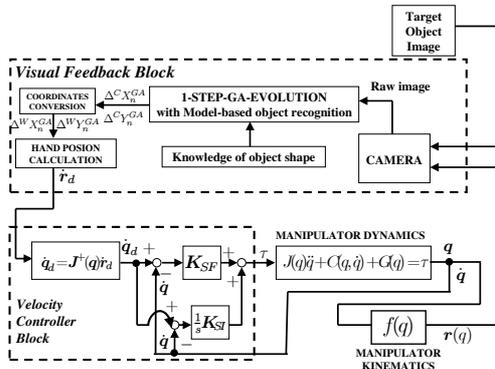


Fig. 7 Block diagram of the controller

### 4.3 プレディクションサーボイング

次に対象物の将来位置を予測し、予測位置にロボットのハンドの手先を制御するプレディクションサーボイングについて説明する．プレディクションサーボイングでは円弧近似とニューラルネットワークより求められた対象物の予測将来位置  $\hat{r}_{n+k}^{C,N}$  を用いてサーボイングしている．具体的には式 (11) において、対象物の位置誤差  $\Delta^W r_n$  を対象物の予測位置に変更して制御を行う．すなわちロボットハンドの速度指示値は以下の式 (14) のようになる．

$$\dot{r}_n^d = K_P \Delta^W \hat{r}_{n+k}^{C,N} + K_V (\Delta^W r_n - \Delta^W r_{n-1}) \quad (14)$$

ここで、

$$\Delta^W \hat{r}_{n+k}^{C,N} = {}^W R_C \Delta^C \hat{r}_{n+k}^{C,N} \quad (15)$$

$$\Delta^C \hat{r}_{n+k}^{C,N} = {}^C \hat{r}_{n+k}^{C,N} - {}^C r_n^H \quad (16)$$

である．しかし、式 (14) において速度偏差項である  $K_V (\Delta^W r_n - \Delta^W r_{n-1})$  内の  $\Delta^W r_n$ 、 $\Delta^W r_{n-1}$  については安定化のための項であり、そのため予測に基づいた制御量としていない． $K_P$ 、 $K_V$ 、 $K_{SP}$ 、 $K_{SI}$  ゲインについては Table 1 と同じ値を使用する．

### 4.4 ビジュアルサーボイングとプレディクションサーボイングの実験による比較

プレディクションサーボイングが有効であるか検証するため、従来のビジュアルサーボイングと比較を行なった．実験には図 5 に示すように、円運動と直線運動ができる全長 920mm のコースを平均 10 秒で移動する、高さ 35mm 長さ 20mm の黒色の三角形の対象物を使用する．追従時間はビジュアルサーボイング、プレディクションサーボイングともに約 160[s] 行った．

各手法により実験を行いその時得ることができたデータを図 8～11 に示す．図 8、図 9 はカメラから取得した画像をビジュアルサーボイング、プレディクションサーボイングそれぞれで 1 秒ごとに並べた．その結果ビジュアルサーボイングよりプレディクションサーボイングで追従を行ったほうが対象物がカメラの中心位置にあることが確認できた．図 10、図 11 は対象物が目標位置であるカメラ画像の中心位置よりどの程度離れたかを表したグラフであり、この誤差を  $|\Delta^C r_n|$  と表す．平均誤差を求めるとビジュアルサーボイングによる誤差  $|\Delta^C r_n|$  の平均は 37.9mm であり、プレディクションサーボイングによる平均誤差は 19.3mm であった．その結果対象物の位置情報から将来位置を予測してハンドを動かすプレディクションサーボイングの方が精度が良いことが確認できた．

### 4.5 ニューラルネットワーク内の変化とそのことによる予測誤差の変化

プレディクションサーボイングにより実際にニューラルネットワーク内でどのような変化が起きているのが調べた．調べた結果図 12 よりニューラルネットワーク内の係数の総和は減っていることが確認できた．図 12 の縦軸はニューラルネットワークの入出力比  $|\delta_n^N| / |\Delta^C \hat{r}_n^C|$  を表している． $|\Delta^C \hat{r}_n^C|$  はニューラルネットワーク内に入力する誤差のノルム (式 (4) 参照)、 $|\delta_n^N|$  はニューラルネットワークの出力値である補正値のノルムである．

またその結果図 13 に示すようにニューラルネットワークと円弧近似を用いた予測将来位置  ${}^C \hat{r}_n^{C,N}$  と実際に認識した位置  ${}^C r_n^M$  との誤差  $|\Delta^C \hat{r}_n^{C,N}|$  は時間が経過する毎に減少していることが確認できた．表 2 に前半と後半の平均誤差を示していることが分かる．このことよりニューラルネットワークの学習が定常偏差を少なくすることを目標に行っていることが確認できた．

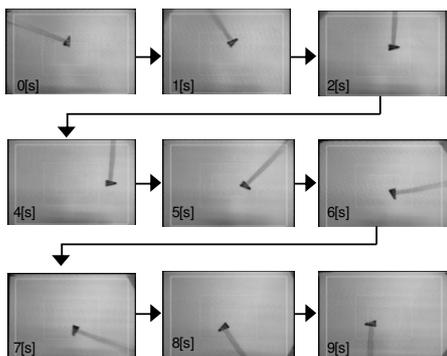


Fig. 8 Target object and hand motion image in visual servoing

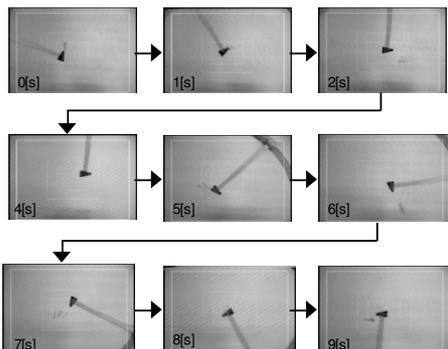


Fig. 9 Target object and hand motion image in prediction servoing

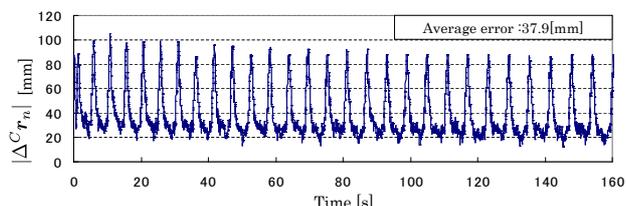


Fig. 10 Target object and hand error in visual servoing

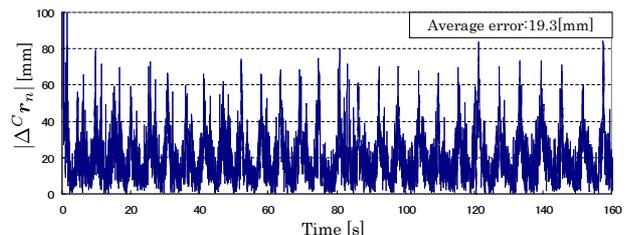


Fig. 11 Target object and hand error in prediction servoing

## 5. 結言

本報では決まった行動をする対象物を円弧近似，ニューラルネットワークを用いてプレディクションサーボイングを行うことにより，ビジュアルサーボイングで追従を行うよりハンドは目標位置に向かって追従を行えていることが確認できた．またニューラルネットワークの学習法，誤差逆伝播法により時間が経過するごとに定常偏差を減少させるように学習していることが確認できニューラルネットワークの有効性が確認できた．今後の課題として今はカメラ認識は単眼で行っているため，複眼で認識を行うことにより対象物の認識の性能を向上することや，対象物を2次元でしか制御を行っていないため3次元でも同様の実験を行えるようにすることが挙げられる．

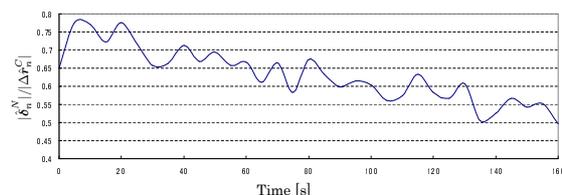


Fig. 12 Output/Input in neural network

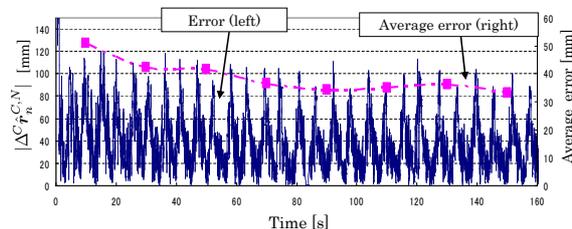


Fig. 13 Error that compared real position with prediction position in prediction servoing

Table 2 Average error that compared real position with prediction position in prediction servoing

	0 ~ 80[s]	80 ~ 160[s]
$ \Delta \hat{x}^{C,N} $ [mm]	31.4	24.9
$ \Delta \hat{y}^{C,N} $ [mm]	24.0	19.3

## 文献

- [1] On-line Prediction of Escaping Fish from Catching Net by Neural Network and Circular Approximation Toshiaki Yoshida, Mamoru Minami, Yasushi Mae, Hidekazu Suzuki Proceedings of SICE-ICCAS International Joint Conference 2006, SP04-1, A1528
- [2] Fish Catching by Visual Servoing using Neural Network Prediction Toshiaki Yoshida, Mamoru Minami and Yasushi Mae SICE Annual Conference 2007, pp. 2372-2378
- [3] Learning of Fish Movement Pattern by Neural Network Yoshiteru Takezawa, Hidekazu Suzuki, Mamoru Minami, Yasushi Mae SICE Annual Conference 2005 in Okayama PROCEEDINGS, TP1-03-2, 2400-2405 (2005)
- [4] Prediction of Fish Motion by Neural Network Y. Li, Y. Takezawa, H. Suzuki, M. Minami, Y. Mae The 3rd International Symposium on Autonomous Minirobots for Research and Edutainment (2005)
- [5] M.Minami, T.Yoshida: "Prediction Servoing to Catch Escaping Fish Using Neural Network", 2008 IEEE/ASME Int. Conf. on Advanced Intelligent Mechatronics Proc., pp.1225-1231, 2008
- [6] R.A.Brooks: "Model-Based Three-Dimensional Interpretations of Two-Dimensional Images", IEEE Transaction on Pattern Analysis and Machine Intelligence, PAMI-5, 2, pp.140-150, 1983
- [7] M.Minami, J.Agbanhan, and T.Asakura: "GA-Model-based Object Recognition Using Real-World Gray-Scale Image", IMEKO-XV, World Congress of Int. Measurement Confederation, No.17.2.4, 1999
- [8] M.Minami, J.Agbanhan, and T.Asakura: "Robust Scene Recognition Using a GA and Real-world Raw-image", Measurement, 29, pp.249-267, 2001
- [9] 見浪 護, 鈴木 秀和, Julien AGBANHAN: "注視 GA ビジュアルサーボを用いたロボットによる魚の捕獲", 機論, C-68-668, pp.1198-1206, 2002