

有限資源配分による認識応答時間の改善

Improvement of Recognition Response by Resource Allocation

○ 小澤 良平, 見浪 譲 (福井大学)

Ryohei Ozawa, Mamoru Minami

Fukui, University of Fukui, {ozawa,minami}@rc.his.fukui-u.ac.jp

The paper proposes a method of allocation of cognitive resources for real-time multiple object recognition in robot vision. In human beings and even high-performance computers, recognizable number of objects is limited at a time, since cognitive and computational resources are limited. For robot vision, real-time distribution of computational resources is effective for recognition of multiple objects in dynamical changing environment. In the proposed method, recognition process is performed by model-based matching using Genetic Algorithm (GA). Positions of object models are represented by the genes of GA. The individuals of GA are allocated for recognizing multiple landmarks efficiently depending on the situation and priority of the object recognition. The proposed method improves recognition rate of multiple objects.

Key Words: Cognitive resources allocation, Multiple object recognition, GA

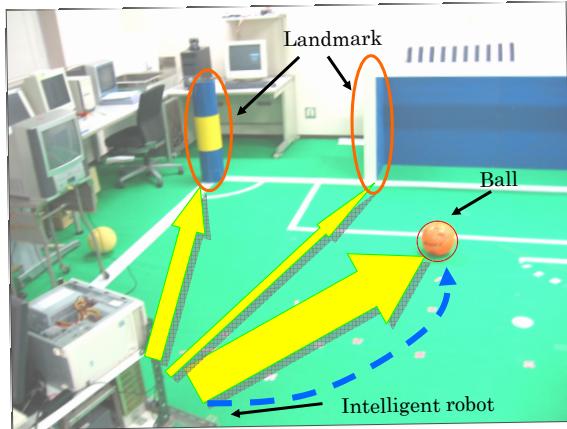


Fig. 1: Resource Allocation of Visual Attention Mobile Robots (The thickness of arrows mean the quantity of recognition resources.)

1. 緒言

計算機による物体認識を実現する場合、環境が複雑になり認識すべき対象物の数が増えていくにつれ、計算機の演算量が比例的に増える [1]。しかし、現在のハードウェアシステムは演算能力が限られており、処理することができる情報量に限りがある。一方で、動画像に対する物体認識では画像処理に要する計算時間が短いこと（リアルタイム性）が重要である。そのため、画像データは膨大な量になるため、限られたハードウェアシステムにおいて高解像度での処理ができないなどの問題点がある。

人間の視覚システムに目を向けてみると、人間の視覚情報処理システムは、取り巻く情報をすべてを処理するだけの能力を持ち合わせていないにもかかわらず、時々刻々と変化する環境下において複数対象の認識をいつも簡単に実行している。これは人間の視覚システムが非常に効率良く情報を取捨選択して処理量を低減する“注意”という機能を持っているからである。これは、普段我々が「注意を払う」「注意を引く」などと使っている注意のことであり、近年注意が2つの異なる特徴をもつ成分により構成されている事が報告されている。1つは受動注意と呼ばれ、人間が意図的に注意を払う知識駆動的な成分であり、もう1つは能動注意と呼ばれ、人間が無意識に注意を引かれる刺激

駆動的な成分である。また、人間が瞬時に把握できる対象物数が限られているという事実から、人間は短時間の視覚的注意により取得した物体の情報を統合し全体の周囲状況を把握している。本報告では、人間の受動注意に注目し、受動注意の切り替えによる高速な複数物体認識手法を提案する。

既存の研究において受動注意と能動注意にもとづいた選択的注視手法が提案されている [2]。これは探索で得られた対象物の適合度が上昇することにより、対象物を検出できたとみなし、探索範囲を縮小させ、対象物近辺のみを探索するものである。ここで、本研究では認識資源の数をリアルタイムで変化させ配分することにより認識の精度が良くなるのではないかと考えた。つまり、注意対象の物体を変えることで、知能ロボットが高速に複数の物体を認識できると考える。さらに、人間は状況に依存して注意を向ける物体の優先順位を意識的あるいは無意識に定め、認識資源を配分しているという事実から、最適な優先順位をパラメータ空間を用いて調べる。こうすることで優先度に従った対象物認識の精度を得る事ができロボットの行動の正確さにつながる。

提案手法では、Model-based Matching 法を用いて入力画像と対象物に対する評価を行う。遺伝的アルゴリズム (GA) を用いた探索法にて最適解を探索し、GA の遺伝子コードによる対象物の位置/大きさ・姿勢を検出する。そして、GA の総個体数を総認識資源とみなし、対象物認識で得られた尤度、認識の優先度に従い、各対象物の探索個体数を変化させる。

2. 認識資源配分

本研究では、以下に示した2つの場合に認識資源を配分し、複数対象物検出のための状況に応じた認識資源の配分を実時間で行う。

まず、対象物を検出している場合と検出していない場合によって、対象物の探索資源数を変える。対象物を検出していない時は画像全体を探索する必要がある為、対象物を探索する資源を増やし、より速く対象物を検出できるようにする。また、一度対象物を検出してしまうと対象物近辺のみの探索で良いため、本研究で用いる探索手法で追跡可能な分に減らす。そうすることで減らした認識資源を他の対象物探索に用いことができる。

次に、ロボットの状況に依存して決まる対象物認識の重要度に従い、各対象物の探索資源を変える。例えば、Fig.1 のようにサッカーロボットがボールを取りに行くとき、ゴールの認識は

それほど重要ではなく、ボールを見失なわないようにする為の正確なボールの認識が重要である。また、ドリブルをしてゴールに向かうときは、ボールの認識だけでなくゴール認識が重要になる。このように、対象物認識にはその時のロボットがおかれた状況に依存した認識資源を分配する重要度がある事が分かる。本研究では、様々な状況による対象物の重要度をあらかじめ定め、その対象物認識の重要度に従って、認識資源を変化させ複数対象物認識を行う。

2.1 指数関数と重要度を用いた資源配分

本研究では、Fig.2 に示すように、GA の $k+1$ 世代の認識資源数を k 世代での認識適合度に応じた関数により一時的に決定し、さらに余った資源を再分配することによって配分資源を決定し多物体認識を行う。以下に配分資源を決定する計算式を示す。ここで、 n 個の物体認識を行う場合、第 i 物体に用いることのできる最大資源数を \bar{p}_i 、探索に必要な最小資源数を \underline{p}_i とする ($i=1,2,3,\dots,n$)。

まず総資源数 P_{max} は均等に n 当分され、

$$\bar{p}_i = \frac{P_{max}}{n} \quad (1)$$

となる。次に \bar{p}_i 、 \underline{p}_i を用い、一時的に配分される個体数 $p_i(k+1)$ は、 k 世代での最大適合度 $f_i^{max}(k)$ の値の関数として

$$p_i(k+1) = (\bar{p}_i - \underline{p}_i) \exp(-a f_i^{max}(k)) + \underline{p}_i \quad (2)$$

と決定する。 a は関数の横軸の値を調節するパラメータである。さらに、余った資源数 $P_{rest}(k+1)$ は

$$P_{rest}(k+1) = \sum_{i=1}^n (\bar{p}_i - p_i(k+1)) = P_{max} - \sum_{i=1}^n p_i(k+1) \quad (3)$$

となり、重要度 $w_i (\sum_{i=1}^n w_i = 1)$ を用いて再分配される。ただし、認識が行えたと判断する適合度の閾値を \bar{f} とすると、重要度 \hat{w}_i は以下の判別式によって更新される。

$$\hat{w}_i = \begin{cases} w_i (f_i^{max}(k) < \bar{f}) \\ 0 (f_i^{max}(k) \geq \bar{f}) \end{cases} \quad (4)$$

また、 $\sum_{i=1}^n \hat{w}_i = 1$ を満たすために、最終的に用いる重要度 \bar{w}_i は

$$\bar{w}_i = \frac{\hat{w}_i}{\sum_{i=1}^n \hat{w}_i} \quad (5)$$

となる。最終的に配分される資源数 $q_i(k+1)$ は、重要度 \bar{w}_i を用いて、

$$q_i(k+1) = p_i(k) + P_{rest} \bar{w}_i \quad (6)$$

となる。

2.2 対象物認識手法

本節では、本研究で用いている遺伝的アルゴリズムを用いた Model-based Matching 法による物体認識について、その概要を述べる。本研究ではあらかじめ認識対象となる物体の 2 次元形状をモデルとして与えた Model-based Matching 法によって、本研究の対象物を検出・追跡する。また、本研究ではビデオレートで物体を検出、追跡するために遺伝的アルゴリズム (GA) を用いて最大値探索を行う。しかし、GA の収束を待ち、その収束結果から位置を認識する場合、フレームレートを超えてしま

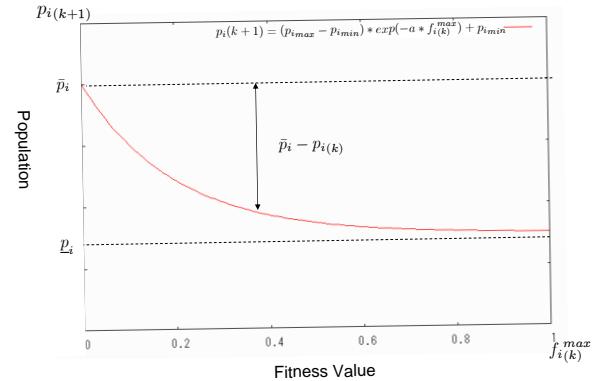


Fig. 2: Exponential Graph of This Method

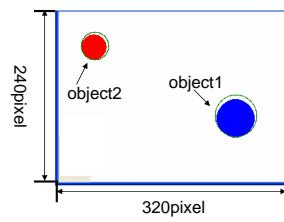


Fig. 3: Environment of 2 Object-Recognition Simulation

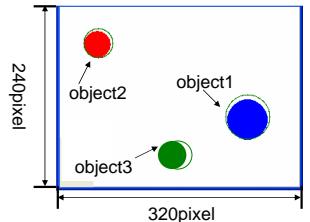


Fig. 4: Environment of 3 Object-Recognition Simulation

う恐れがある。そこで本研究では、GA の収束を待たず、進化の各段階において最良の個体を GA の認識結果として出力する。また、通常 GA による探索は局所的探索能力が十分でないことが多いため、探索の進行に応じて大域的空間から局所的空間へと探索領域を自然に収束させる注視 GA 探索法を提案している。

本研究では、GA の総個体数を認識の総資源数として用い、GA の進化毎に個体を配分することによって認識資源配分の有効性を示す。

2.3 認識資源配分シミュレーション

2.1 章の式 (6) を用いて GA の総個体数を認識の総資源数とした認識資源配分シミュレーションを行った。シミュレーションの環境は Fig.3, Fig.4 のように、320 × 240(pixel) の静止画像中に対象物として異なる色と大きさの円を配置した。認識資源配分ありなしでの、すべての物体を認識するまでの“時間”と“GA の進化回数”的 30 回平均を比較する。対象物を認識したとみなす適合度は 0.8 以上とした。認識資源配分を用いない場合の GA の個体配分は

$$q_i(k+1) = \bar{p}_i \quad (7)$$

とした。

Table. 1: Parameter of 2 Object-Recognition Simulation

Parameter	i	value
P_{max}	-	24
$p_{i\min}$	1	4
	2	4
w_i	1	1/2
	2	1/2
f_{min}	-	0.4
a	-	5

Table. 2: Comparison of Average Processing Time and Number of Times of Evolution with Allocation or not in 2 Object-Recognition Simulation

Cognitive resource allocation	True	False
$T_{ave}(s)$	0.69	1.20

Table. 3: Parameter of 3 Object-Recognition Simulation

Parameter	i	value
P_{max}	-	24
$p_{i\min}$	1	4
	2	4
	3	4
w_i	1	$1/3$
	2	$1/3$
	3	$1/3$
f_{min}	-	0.4
a	-	5

まず、対象物体を 2 つ ($n = 2$) としたシミュレーションを行つた。シミュレーションに用いたパラメータの値を Table1 に示す。今回重要度は均等に $[w_1, w_2] = [0.5, 0.5]$ とし、GA の総個体数はフレームレート (33ms) とパソコンの処理能力に合わせて 24 個とした。

配分なしの場合、2 つの対象物それぞれの適合度の変化の一例を Fig.5 に、同様に配分ありの場合の、適合度の変化と、GA の進化毎の個体数の変化の一例を示したもの Fig.6 に示す。また、配分ありとなしで 2 物体の認識にかかる時間の平均を T_{ave} とし、30 回認識を行つたものを Table2 に示す。Fig.5 と 6 を比較すると、配分を行うことによって、1 物体の適合度の上昇は遅いが、複数の対象物に対して高率良く探索が行えていることが分かる。また、Table2 の T_{ave} を見ると、認識資源配分を行うことによって約 1.7 倍の早さで 2 物体を認識していることが分かる。

次に、対象物体を 3 つ ($n = 3$) としたシミュレーションを行つた。シミュレーションに用いたパラメータの値を Table3 に示す。今回も重要度は均等に $[w_1, w_2, w_3] = [\frac{1}{3}, \frac{1}{3}, \frac{1}{3}]$ とし、GA の総個体数は 24 個とした。

配分なしの場合の、3 つの対象物それぞれの適合度の変化の一例を Fig.7 に、同様に配分ありの場合の、適合度の変化と、GA の進化毎の個体数の変化の一例を示したもの Fig.8 に示す。また、配分ありとなしで 3 物体の認識にかかる時間の平均 (T_{ave}) を Table4 に示す。Fig.7 と 8 を比較すると、2 つの対象物の時と同様に、配分を行うことによって、1 物体の適合度の上昇は遅いが、複数の対象物に対して高率良く探索が行えていることが分かる。また、Table4 の認識時間を見ると、認識資源配分を行うことによって約 2.2 倍の早さで 3 物体を認識していることが分かる。

Table. 4: Comparison of Average Processing Time with Allocation or not in 3 Object-Recognition Simulation

Cognitive resource allocation	True	False
$T_{ave}(s)$	1.45	3.25

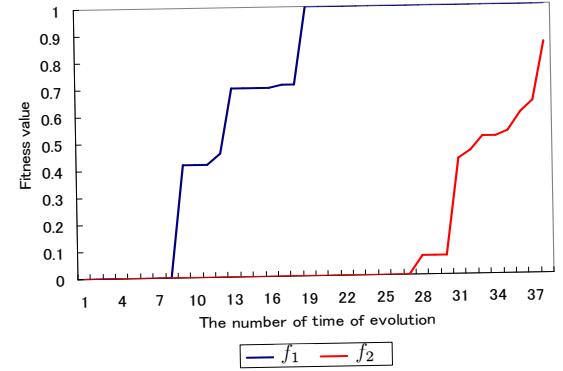


Fig. 5: Change of Fitness without Cognitive Resource Allocation Using Parameter of Table1 in 2 Object-Recognition Simulation

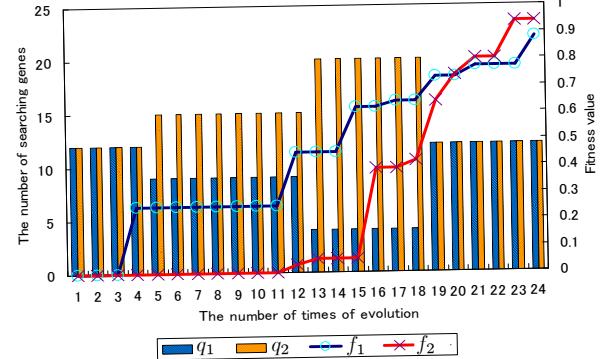


Fig. 6: Change of Fitness and Individual with Cognitive Resource Allocation Using Parameter of Table1 in 2 Object-Recognition Simulation

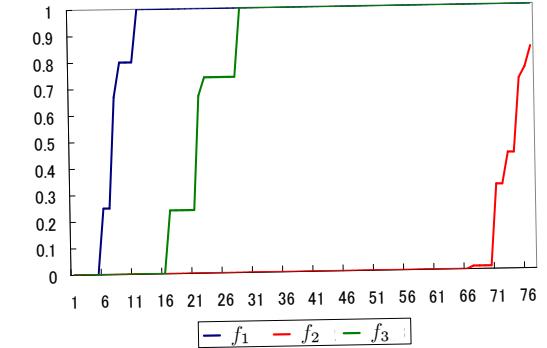


Fig. 7: Change of Fitness without Cognitive Resource Allocation Using of Table3 in 3 Object-Recognition Simulation

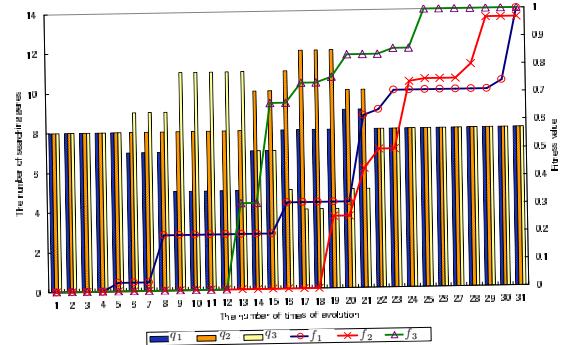


Fig. 8: Change of Fitness and Individual with Cognitive Resource Allocation Using of Table3 in 3 Object-Recognition Simulation

3. 重要度最適化

2章で説明したように本研究の認識資源配分法は、ロボットの状況に応じた重要度 $w_i (i = 1, 2, \dots, n)$ によって認識資源の再配分を行っている。また、認識対象物体の大きさが大きいほど認識し易いという関係があり、対象物の認識し易さに基づき効率良く再分配することによりさらに認識速度を向上させることができる。そこで、重要度と複数物体の認識速度の関係を調べるために、2.3章の認識資源配分シミュレーションと同じ環境を用いて、重要度の比率 $w = [w_1, w_2, \dots, w_n], \sum_{i=1}^n w_i = 1$ による、GAの l 回進化時での n 個の物体が認識できている確率 P を調べた。なお、ここでの確率とは n 物体認識を j 回 ($j = 1, 2, \dots, T$) 行い統計的に求める。以下で認識確率 P の算出法について説明する。

まず、 j 回目の試行で k 世代の物体 i に対する最大適合度を $f_j^i(k, w)$ とする。 n 個の認識対象物体すべてを認識した時点での GA の世代数 $p_j(w)$ は、認識が行えたとみなす適合度の閾値 F を用いて

$$p_j(w) = \{k \mid (f_j^1(k, w) > F) \cap (f_j^2(k, w) > F) \cap \dots \cap (f_j^n(k, w) > F)\} \quad (8)$$

となる。次に、 l 世代以内で n 個の物体認識が行うことができた $p_j(w)$ の集合 $Q(l, w)$ は

$$Q(l, w) = \{p_j(w) \mid p_j(w) < l, \quad j = 1, 2, \dots, T\} \quad (9)$$

となり、集合 Q 中の要素の数を与える関数を f とすると、認識確率 P は以下の式で表すことができる。

$$P(l, w) = \frac{1}{T} f(Q(l, w)) \quad (10)$$

3.1 認識確率シミュレーション

2.3章の認識資源配分シミュレーションと同じ環境を用い、2パターンの認識シミュレーションを行った。2つのシミュレーションとも、認識を行う回数 $T=1000$ とし、総資源数 $P_{max}=40$ 、配分される個体数 q_i は常に

$$q_i = P_{max} w_i \quad (11)$$

としている。まず、2物体の大きさの比率を [4:1] とした場合の重要度割合別 ($w = [0.1, 0.9], [0.5, 0.5], [0.9, 0.1]$) での認識確率 $P(l, w)$ の推移を Fig.9 に示す。Fig.9 より、重要度割合別によって認識確率は変化していることがわかる。

また、2物体の大きさの比率を [object1:object2]=[1:1], [4:1], [6:1] とし、それぞれの比率時の配分の重要度の比率 $w (w = [w_1 : w_2])$ による GA の進化回数 $l = 40$ での $P_{(40, w)}$ の分布を Fig.10 に示す。Fig.10 より、最も効率の良い配分のピークが、2物体の大きさの比率 [1:1] 時で [0.4:0.6], [4:1] 時で [0.3:0.7], [6:1] 時で [0.2:0.6] と、それぞれの物体の大きさの比率に対して効率の良い配分の割合が異なることが分かる。

今回は配分される個体数を 40 個と設定したが、2章で説明した本手法は配分される個体数が時々刻々と変化する。今後は時々刻々と変化する個体数を効率よく配分する重要度の最適化を行う。

4. 結言

本報告では、ロボットの状況にもとづいて定めた物体認識の優先度に応じて認識資源のリアルタイムの配分を行い、複数対象物認識の精度を向上させる手法を提案した。

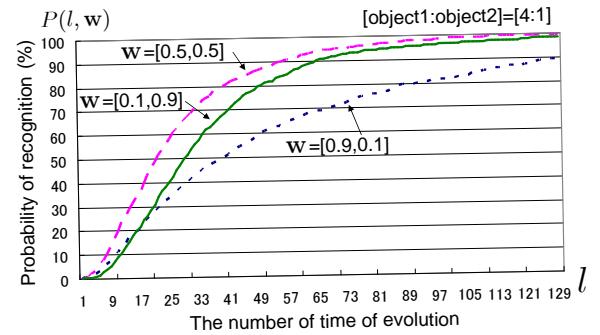


Fig. 9: Probability of recognition of 2 Object-Recognition Simulation ([object1:object2]=[4:1])

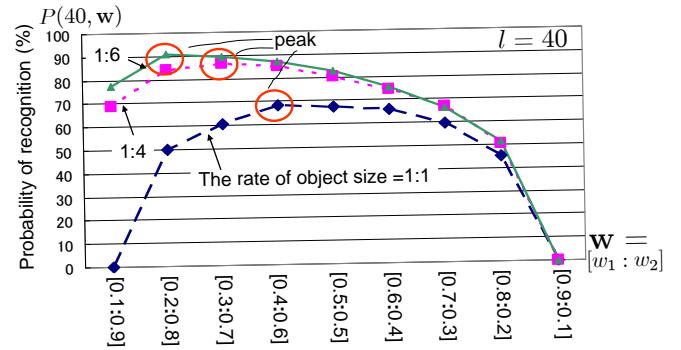


Fig. 10: Parametric Space of 2 Object-Recognition Simulation

対象物認識には、Model-based Matching 法と遺伝的アルゴリズム (GA) を用い、GA の遺伝子コードにより、対象物探索モデルの位置/姿勢を表した。また、GA の個体の総数を全認識資源とし、対象物の適合度、対象物認識の優先度に従い、各対象物の探索個体数を変えることによって効率よく複数物体の認識が行えることをシミュレーションを用いて示し、本手法の有効性を確認した。

また、複数の物体を認識する上での効率の良い配分の比率が存在することを示した。今後は本手法を用いて重要度の最適化を行う。

参考文献

- [1] T.Mizushima, Y.Sakamoto, W.Song, M.Minami, Y.Mae, "Generation of Adaptive Motion Using Quasi-simultaneous Recognition of Plural Targets", Proc. International Conference on Control, Automation and Systems, CD-ROM, (2005).
- [2] 鈴木 秀和, 見浪 譲, "車載カメラを用いた複数歩行者の実時間認識", 電子情報通信学会論文誌, Vol. J88-A, No. 2, (2005).