

恒常性機構を用いたニューラルネットワークモデルの 拡張と適応性の比較

飯塚 博幸

公立はこだて未来大学システム情報科学部

〒041-8655 北海道函館市亀田中野町 116 番地 2

E-mail: ezca@fun.ac.jp

あらまし 恒常性を用いたニューラルネットワークモデルの拡張を行う。従来のモデルでは、内的な恒常性と振る舞いの安定性は必ずしも関連性を形成して進化するとは限らない。つまり、振る舞いが壊れてしまったとしても、内的な恒常性が影響を受けないことがある。提案方法では、それを静止膜電位と評価方法を改良することによって、振る舞いと恒常性が密接な関連性をもった構造が進化するように拡張する。この拡張したニューラルネットワークモデルをシミュレートされた移動体に実装し、環境変動に対する適応能力を検証する。結果として提案手法はより適応的振る舞いを示し、複数回起こる環境変動に対しても飽和することなく適応し続けることを示す。

キーワード 恒常性、適応行動、進化的計算、創発

Extending homeostatic neural controller for adaptive behaviour

Hiroyuki Iizuka

Department of Media Architecture, Future University-Hakodate

116-2 Kamedanakano-cho, Hakodate, Hokkaido, 041-8655 Japan

E-mail: ezca@fun.ac.jp

Abstract A homeostatic neural controller is extended by exploiting the internal dynamics of a neural network in the absence of sensory input and also by avoiding the loss of internal variability that is caused by a local plastic mechanism. The extended method can solve a contingent link between internal and behavioral stability where homeostasis remain unaffected even under disruptions of behaviours. The method allows the generation of reliable adaptation to morphological disruptions in a simple simulated vehicle using a homeostatic neurocontroller that has been selected to behave homeostatically while performing the desired behaviour but non-homeostatically in other circumstances. The performance of the extended method is compared with simple homeostatic neural controllers. As a result, it is shown that the extended homeostatic networks are more adaptive and can adapt to the environmental changes that happen more than once.

Keyword homeostasis, adaptive behaviour, evolutionary robotics, emergence

1.はじめに

恒常性を利用したニューロンの特性と進化的手法を組み合わせた恒常性適応モデル[2]は、生命のもつ適応能力を模倣し、従来の単なるフィードバックによる適応とは異なる新しい適応の概念の構築を目指している。その恒常性を用いた適応方法のアイデアは、Ashbyの超安定システム (ultrastable system) に基づいている[8]。このシステムは、ある安定状態が失われたときに、またその時に限り、新しい安定状態が保たれるまで自分自身の構造を変えていくシステムである。このアイデアに基づく恒常性を用いた適応ニューロンの方法は今までに、6足歩行モデル[4]、鋭敏性を高めるために異なる可塑性関数を用いた拡張モデル[5]、振る

舞いから創発する選好の基本モデル[6]、A-not-B課題での固執的リーチングに対するモデル[10]へと応用されてきた。

恒常性適応モデルは、進化ロボティクスの方法と融合したニューラルネットワークモデルとして提案された。提案モデルでは、ニューロンの発火率がある決められた範囲外になったときのみ、可塑性メカニズムが局所的に働き、そのニューロンへと入ってくるシナプスの結合係数がヘップ則タイプのルールに従って変わっていく。その可塑性メカニズムは、そのニューロンの発火率がその決められた範囲内に戻るまで続けられる。つまり、発火率が範囲内にあるときは、シナプスの結合係数が変わらないという意味においてそのとき

構造は“安定”であるといえる。このメカニズムは、特殊な評価関数とともにシミュレーション上において移動ロボットに実装された。その評価関数は、移動ロボットが光に近づく（走光性）ように進化することと同時にその決められた恒常性領域に発火率が常に保たれるように進化するように設定された。この断続的な可塑性の導入と評価関数を用いた方法は、ニューラルネットワークの内部的な恒常性と望まれた振る舞い（走光性）との間の関連付けを形成する。この恒常性と望まれた振る舞いとの関連性を正の関連性と呼ぶ。この方法を用いると、その移動ロボットは与えられた環境において、恒常性を保ちながら光に近づくことができる。つまり、シナプスの結合変化を生じることなく、望まれた振る舞いを環境との相互作用のなかにおいて作り出すことに成功する。そして、もし逆さメガネをかけるようにセンサーの位置が変えられると、この調和状態は崩れる。このような非調和状態において、いくつかの進化したロボットは、内的な恒常性も崩れる。これを恒常性と振る舞いの負の関連性と呼ぶ。この負の関連性が生じると、環境との相互作用を通して内的恒常性が再び保たれる構造を見つけるまで、局所的可塑性メカニズムは働き続ける。これらの条件のもと、いくつかの進化した移動体は、恒常性を復活させるとともに、望ましい行動（走光性）も回復する。この適応は例え進化する上で未経験のイベントでも生じる。すなわち、これらの進化した移動体は、負の関連性を通して、恒常性を回復するとともに正の関連性をも再形成することが可能なのである。

しかしながら、内的な恒常性と望ましい振る舞いをつないでいる関連性は必ずしも確かなものではないという問題がオリジナルのモデルにはある。その関連性は生成されるかもしれないが、生成されないかもしれない。この不確かさは、走光性が壊れても恒常性が影響を受けずに安定状態を保ち続けてしまうという進化例にみてとれる。この問題は初めに[3]において示され、より Ashby のホメостップに近い形でその解決方法が提案された。しかし、その解決方法は、ブライテンベルグ[1]タイプの簡単なコントローラにおいてであり、この問題点を解消できるニューラルネットワークモデルの方法は重要なオープンクエスチョンとして残っている。

そこで、本論文では、オリジナルのモデルをいくつかの点において改良を加え、この関連性をより強固に形成できるモデルの提案を行う。また、適応能力と進化可能性の観点から提案モデルと従来のモデルとを比較し、その有効性について述べる。

2. モデル

提案する方法は、オリジナルの論文と同様に、シミュレーション上で空間を移動する車両（エージェント）に実装され、その効果を調べる。空間上にはエージェントと一つの光源があり、エージェントのタスクはその光源に近づくこと（走行性）を実現することである。このタスクは敢えて単純にすることで、ニューラルダイナミクス、恒常性、可塑性、淘汰圧の基本的な相互作用を理解し、より複雑な環境での応用へと繋げていくことが目的である。

オリジナルのモデルでは、ネットワークの結合係数の初期値は固定で与えられるが、本モデルでは初期値はランダムに与えられる。つまり、エージェントは環境との相互作用を通して、恒常性、可塑性、ニューラルダイナミクスの関係からランダムな結合係数に適応する必要がある。

2.1. エージェント

エージェントは半径 4 の円形の体と 2 つのモータで移動体を構成している。2 つのモータを使うことで、エージェントは無限に広がった 2 次元空間を移動することができる。また、エージェントは正面から土 $\pi/4, \pm 3\pi/4$ の位置に光の強さに反応する 4 つのセンサーを持っている。光源から出た光は距離に反比例しながら減衰する。ここでモデルはエージェントの体による影の効果も考慮している。

2.2. ニューロコントローラ

ニューロンが全結合した連続時間のリカレントニューラルネットワーク (continuous-time recurrent neural network: CTRNN) をエージェントの動き制御するコントローラとして使う[9]。ここでは、恒常性をつくりあげる可塑性のメカニズムがエージェントの望む振る舞い（走光性）と密接に結びつくように、通常の CTRNN の式に変更を加える。特に、本目的である望ましくない振る舞い、つまり、光から遠ざかる振る舞いをしながら恒常性が保たれてしまう関連性を意図的に進化させないようにする必要がある。つまり、センサーの刺激が少ないときには、恒常性が保つことができない性質が必要である。センサー刺激がない場合に恒常性が保てるか保てないかは、結合の強さ、静止膜電位と恒常性領域の範囲を適切に選ぶことによって、コントロールすることが可能である。そこで、 α と β の二つのパラメータが CTRNN に導入される。また、恒常性領域を設定するパラメータ γ も可塑性のルールに導入される。

また、可塑性をもったニューラルネットワークの共通の問題として、結合係数が簡単に飽和してしまうことがある。これは、係数をダンプさせることによって、部分的に解決することは可能であるが、問題は、飽和

を起こす過程において、結合係数の多様性を失うことである。これを回避する方法として、可塑性ルールで変わっていく結合係数の値を連続で非単調な空間へとマッピングすることである。ここでは、より単純なモデルを提案することが目的なので、sin 関数を使う。改良した CTRNN の時間発展の式は以下のようになる。

$$\tau_i \dot{y}_i = -(y_i - \beta) + \sum_{j=1}^N \alpha \sin(w_{ji}) z_j(y_j) + I_i, \quad (1)$$

$$z_i(x) = 1/(1+e^{-x}), \quad (2)$$

ここで、 y_i はニューロン i のボテンシャル、 z_i はその発火率、 τ_i は時定数、 I_i は各センサーから各 1 つのセンサーニューロンに与えられるセンサー入力を表わす。センサー入力は光の強さに増幅率をかけることによって得られる。一方、出力は各モータをコントロールするためにそれぞれ二つのニューロンが使われる。モータ出力は、二つのニューロンの発火率の割合を [-5:5] の値へと変換し、さらに、増幅率をかけることにより実際の値が求まる。ニューロン j から i への結合の強さは、 $\alpha \sin(w_{ji})$ によって決定される。 α の値はニューラルネットワーク全体で一つの値で、遺伝的に決定される。このパラメータは、そのネットワークにおいて、シナプス前ニューロンがシナプス後ニューロンにどの程度影響を与えるかを決定する。パラメータ β (静止膜電位) は完全に入力がない状態での均衡点の値を決定している。ここで、パラメータ α と β の値のバランスは重要になる。なぜなら、もし α が小さすぎるとニューロンの発火率は静止膜電位へと収束していく。もし α が大きすぎると β はダイナミクスに対して影響を与えるなくなる。そこで、もし β が負の値で適切な α の値をとれば、十分なセンサー入力がないときには発火率は 0 に近い小さな値へと収束していく。かつ、十分な入力がある時にはその値へと収束することなく、結合係数にもとづくニューラルダイナミクスを作ることが可能である。この性質と適切に設定された恒常性領域を用いることで、センサー入力のない状態で恒常性を保つことを難しくすることが可能となる。

ニューロン間の結合係数である w_{ij} は各トライアルの始めにランダムに決められ、可塑性メカニズムはその結合係数を環境との相互作用をしながら変えていく。恒常性領域は可塑性の強さを決定する関数の 0 の値の領域として表現される。可塑性の強さは、シナプス後細胞の発火率によって決まる。この関数はパラメータ γ によって調節される。ニューロン i から j へ結合係数は以下の式を用いて更新していく。

$$\Delta w_{ij} = \eta_{ij}(1 - z_i)p(z_j), \quad (3)$$

$$p(x) = \begin{cases} 0 & x > \gamma, \\ 1-x/\gamma & \text{else}, \end{cases} \quad (4)$$

ここで、 z_i と z_j はそれぞれシナプス前ニューロンとシナプス後ニューロンの発火率、 Δw_{ij} は各タイムステップに w_{ij} を更新する量、 η_{ij} は学習係数、 $p(x)$ はシナプス後ニューロンの発火率に応じて変化する可塑性の強さを与える関数であり、恒常性領域を定める (Fig. 1)。恒常性領域と呼ばれる理由は、 z_j が γ よりも大きいと結合係数は変化せず、もし、その値が γ より小さいと、 z_j が γ より大きくなるまで (つまり、恒常性領域に入るまで) その結合係数が変化し続けるためである。ここで、 α 、 β 、 γ のパラメータが適切に設定されれば、センサー入力がない時に収束する値が γ より小さくなって、望まれない振る舞いをしたときに積極的に恒常性から外れるダイナミクスを作ることが可能となる。

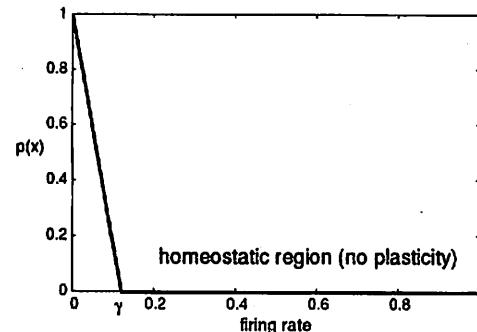


Fig. 1. シナプス後ニューロンの発火率に応じた可塑性の強さの関数 $p(x)$

3. 進化アルゴリズム

エージェントがもつすべての固定パラメータ τ_i 、 η_{ij} 、 α 、 γ 、入出力のための増幅率はエリート戦略とランクを用いた遺伝的アルゴリズム(GA)によって進化的に獲得される。その固定パラメータは 0 から 1 の実数で遺伝子上に表わされ、1 つの実数ベクトルによって 1 つのエージェントが表わされる。0 から 1 の各値は、線形に各パラメータの最大値、最小値の間の値へとマッピングされる。遺伝オペレータとしては、各世代で多点交叉と突然変異が使われる。

提案する方法では、オリジナルのモデルを拡張した評価方法を用いる。評価するプロセスにおいて半分のトライアルは、光のある環境において行動を評価され(光条件)、残りの半分は光のない環境で評価が行われ

る（暗闇条件）。光条件では、一定時間光源が点灯した後に、新しい光源が別の場所に点灯する。エージェントは、8つの光源と相互作用し、常に恒常性を維持しながら光に近づき、光の側に滞在する行動が評価される。一方、暗闇条件では、光のない環境でエージェントは自由に動くことができるが、恒常性を常に保たないということで評価される。これは光から遠ざかったときには恒常性が壊れるような関係を作るためである。これらの設定の上で、具体的に評価値は次の3つの要素で与えられる。1)エージェントが光源のそば（距離20以下）に滞在していた時間の割合、 f_s 、2)光条件で各ステップでの発火率が恒常性領域にあるニューロンの割合、 f_h 、3)暗闇条件で発火率が恒常性ではないニューロンの割合、 f_{nh} 。評価関数は $F = f_s \cdot f_h + avg(f_s) \cdot f_{nh}$ で与えられる。

4. 結果

提案手法である負の静止膜電位と光条件と暗闇条件を用いた評価を組み合わせた方法は、適応能力や進化可能性観点から、負の静止膜電位を用いず、評価は光条件のみを用いた方法と比較される。この比較対象である方法は、オリジナルの方法と同じではないが、基本的な恒常性を用いた方法と見做すことができる。

4.1. 進化と適応能力

両方の方法ともに4,000世代まで進化させ、それぞれ独立な10回の進化を観察し、そのときの評価値の変化を比較する。Fig. 2にその結果を示す。明らかに提案手法は比較対象の方法よりも高い評価値を獲得していることがわかる。これは、ランダムに与えられる初期結合係数に対して、光源に近くづく振る舞いを作り出すネットワークの構造を安定して作りだすことができるかどうかの違いによるものである。それは、Fig. 3にみることができる。それぞれの最も優れたエージェントがランダムな結合係数に対して、どの程度走光性と恒常性を実現することができるかが示されている。走光性は、初期値からの学習過程であるトランジエントも含むため提案手法では0.6ぐらいの値をとっているが、基本方法よりもより高い信頼度で走光性を成立させることができるとなっている。また、この図より基本方法では、最初に述べた、望まれた振る舞いと恒常性の関連性が正しく結びついていないことがわかる。走光性が獲得されていないにもかかわらず、恒常性が常に高い割合で保たれてしまっている。つまり、振る舞いが壊れているにもかかわらず、恒常性が保たれてしまっているがゆえに、それ以上ネットワークの構造が変化せず、振る舞いも壊れたままになっている。この点、提案手法は光から遠ざかる振る舞いをしながら恒常性が保つことが難しいため、この状態に陥ること

が少ない。

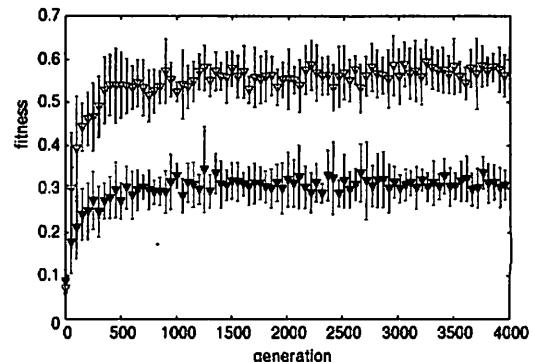


Fig. 2. GAの各世代における最も良い評価値。独立な10試行の平均と標準偏差。空白の三角が提案手法の結果で、塗潰した三角は光条件のみと静止膜電位である β を0にした結果。

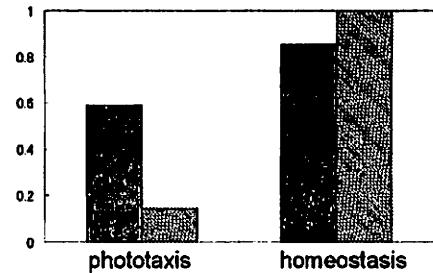


Fig. 3. ランダムな結合係数から始めたときに、50個の光源（計50,000ステップ）と相互作用したときの光の側に滞在した時間の割合(phototaxis)とニューロンの発火率が恒常性領域に入っている割合(homeostasis)。100試行の平均結果。灰色（左側）のバーが提案手法、斜線（右側）のバーが光条件のみと $\beta = 0$ で進化したエージェントの結果。

4.2. 恒常性適応プロセス

上記の結果より、提案手法では内的恒常性と振る舞いの安定性が正しく関連性をもって結び付けられていることが示された。本節では、オリジナルの方法では、見られることのなかった複数回の環境変動への適応プロセスを示す。提案手法では、結合係数が飽和することができないので、多様性を保ちつつ可塑性が働くことができる。また、恒常性と振る舞いが正しくその関連性が結び付けられていれば、振る舞いの崩壊は内的恒常性の崩壊を導くので、複数回の環境変動があったとしても、それぞれの状態で環境との相互作用を通して、適応が可能であることが期待できる。ここでは、環境変動としてセンサーの位置の取替えを行う。これはオリジナルの論文でも逆さメガネの実験に対する適応の

モデルとして行われた。現在の設定では、エージェントは4つのセンサーを持っているので、 $\pm\pi/4 \leftrightarrow \mp3\pi/4$ の組でセンサーの位置を交換する。つまり、交換前には前方にあったものは、交換後には後方に“見え”，左側にあったものは右側に“見える”。

提案手法で進化した最も優れたエージェントに対して、このセンサー位置交換操作を2回(13番目の光源と29番目の光源のとき)行う。そのときの結果をFig. 4(光源までの距離)とFig. 5(結合係数の変化)に示す。まず、最初の操作が行われる前に(12番目の光源まで)，ランダムな結合係数への適応をみることができる。初めのうちはランダムに係数が与えられるため正しく光に近づくことはできないが、いくつかの光源と相互作用していくうちに走光性を獲得している

(Fig. 6(a))。一度、走光性と恒常性を同時に獲得するとそれ以降ネットワークの構造が変わらず、走光性を保ち続ける。次に、13番目の光源が出現すると同時にセンサーの位置が交換された。すると、前後左右逆に“見える”ので、光に近づくつもりが光から遠ざかってしまう(Fig. 6(b))。しばらく振る舞いが壊れた状態が続くが、再び新しい恒常性と走行性を同時に満たすネットワーク構造を獲得している。さらに、29番目の光源の出現とともにセンサーの位置は元に戻されるが、この操作に対しても適応し、最終的に走光性が復元されているのがわかる(Fig. 6(c))。

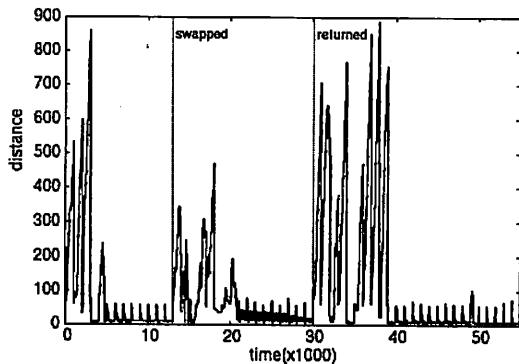


Fig. 4. センサーの位置を複数回途中で交換したときの光源までの距離。1000ステップ毎に新しい場所に光源が出現する。13番目の光源が出現したときにセンサーの位置を $\pm\pi/4 \leftrightarrow \mp3\pi/4$ の組で交換し、29番目の光源の出現で元に戻す。

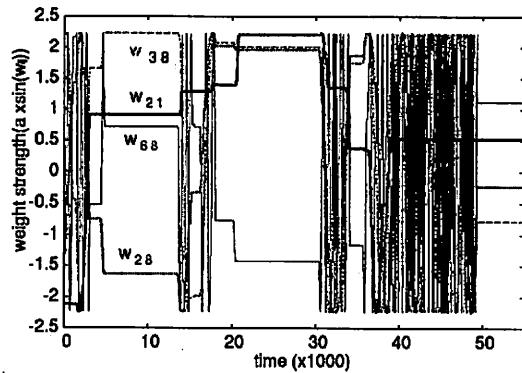
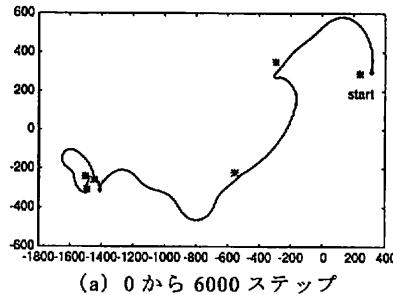
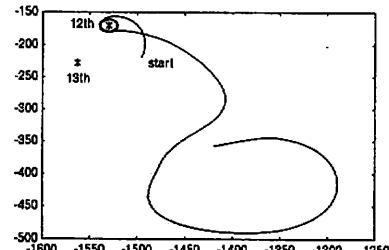


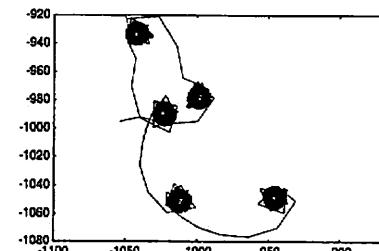
Fig. 5. Fig. 4と対応したシナプス結合の変化。見やすくするために4つの結合係数のみ表示。



(a) 0から6000ステップ



(b) 11000から13000ステップ



(c) 50000から55000ステップ

Fig. 6. エージェントの軌跡。各タイムステップはFig. 4とFig. 5のタイムステップと対応している。*は1000ステップごとに点灯する光源の位置を示す。

5. 議論

本論文において、より適応能力をもった恒常性を用いたニューラルネットワークの拡張モデルを提案した。提案手法は、オリジナルの論文にある内的な恒常性と望まれた振る舞いの安定性の間に生じる不確かな関連性の問題を解決する方法を与える。不確かな関連性は、振る舞いの壊れが必ずしも内的な恒常性の崩壊を招かないことによって生じる。このような状況は、実際の生物においては簡単には起きないと考えられる。なぜなら、実際の生物の望まれない行動は飢餓や捕食される危険性等、その生物の存在にかかることであり、内的な恒常性は自然と破れる。この意味で、提案する手法は、明示的に望まれない行動と内的な恒常性の崩壊を関連付けさせている点において、実際の生物のように環境に対して立脚した存在となる方法であるといえる。また、適応プロセス中に多様性を失わない点において、超安定性の概念により近づいている。結果として、この手法のもとに進化したエージェントは、以前の方法よりもより適応的な振る舞いを示した。ネットワークの結合係数の初期値に依存せず、複数回の環境変動にも、内的な恒常性と振る舞いの正と負の両面の関連性を獲得することによって、適応が可能であることを示した。

謝辞

本研究は日本学術振興会の特別研究員奨励費(17-04443)の助成を得た。

文献

- [1] Braintenberg, V., *Vehicles: Experiments in synthetic psychology*. Cambridge, MA: MIT Press, 1984.
- [2] Di Paolo, E.A., Homeostatic adaptation to inversion in the visual field and other sensorimotor disruptions, From Animals to Animats VI: Proceedings of the 6th International Conference on Simulation of Adaptive Behavior, pp.440-449, 2000.
- [3] Di Paolo, E.A., Spike timing dependent plasticity for evolved robots, *Adaptive Behavior* 10 (3/4), pp243-263, 2002.
- [4] Hoinville, T. Henaff, P., Evolving plastic neural controllers stabilized by homeostatic mechanisms for adaptation to a perturbation, *Proceedings of the Ninth international Conference on the Simulation and Synthesis of Living Systems*, pp.81-87, 2004.
- [5] Williams, H., Homeostatic plasticity in recurrent neural networks, From Animals to Animats 8: Proceedings of the 8th International Conference on the Simulation of Adaptive Behavior, pp344-353, 2004.
- [6] Iizuka, H., Di Paolo, E.A., Toward Spinozist robotics: Exploring the minimal dynamics of behavioural preference, *Adaptive Behavior*, Vol. 15, No. 4, pp.359-376, 2007.
- [7] Iizuka, H., Evolving homeostatic neural controller

without depending on initial weights, *Proceedings of 13th International Symposium of Artificial Life and Robotics*, pp.551-554, 2008.

- [8] Ashby, W.R., *Design for a brain: The origin of adaptive behaviour*. London:Chapman and Hall, second edition, 1960.
- [9] Beer, R.D., *Intelligence as adaptive behavior: An experiment in computational neuroscience*, San Diego: Academic Press, 1990.
- [10] Wood, R., Di Paolo, E.A., New models for old questions: Evolutionary robotics and the 'A Not B' error, *Proceedings of 9th European Conference on Artificial Life*, pp.1141-1150, 2007.