

ニューラルネットを用いた強化学習による行動の学習を通じた 色恒常性の創発

柴田 克成[†] 栗崎 俊介^{†,‡}

[†] 大分大学工学部電気電子工学科 大分市大字旦野原 700 番地

[‡] 現在, 東京エレクトロン九州(株) 勤務

E-mail: †shibata@oita-u.ac.jp

あらまし 本論文では, “錯視” を並列で柔軟な脳の無意識下での処理の結果と捉え, 「日常生活の中でより適切に行動するための学習によって獲得, 強化される」との仮説を立てる。そして, 「色の恒常性」に焦点を当て, フィールドの半分を半透明のカラーフィルタで覆った状態で物体色によってゴールが異なる “カラー物体移動タスク” を, ニューラルネットを用いた強化学習によって学習した。学習後, 中間層ニューロンにカラーフィルタによらず, 元の物体色を表すニューロンを観察した。さらに, 新しい出力ニューロンを付加し, フィルタがない状態で物体色を出力するように教師あり学習をしたところ, カラーフィルタが掛かっている状態でも, 元の物体の色に近い出力を出すようになった。

キーワード 強化学習, ニューラルネット, 錯視, 色の恒常性, 機能創発

Emergence of “Color Constancy” through Learning of Behaviors by Reinforcement Learning with a Neural Network

Katsunari SHIBATA[†] and Shunsuke KURIZAKI^{†,‡}

[†] Oita University, 700 Dannoharu, Oita, JAPAN

[‡] Currently, Tokyo Electron Kyushu Ltd.

E-mail: †shibata@oita-u.ac.jp

Abstract In this paper, “Optical Illusion” is considered as the result of unconscious process in our parallel and flexible brain, and the hypothesis is formed that it can be acquired through the learning to behave more appropriately. “Color constancy” is focused on and reinforcement learning is applied to a simple “colored-object guidance” task in which goal location depends on the object color with the condition that a translucent color filter covers a half of the field. It was observed that some hidden neurons came to represent the object color not depending on the filter color after learning. Furthermore, the neural network with new output neurons was trained to output the object color (RGB values) only under the condition of no filter, and then, when images covered by colored filter were provided as test inputs, the color represented by the network outputs was very close to the object color.

Key words reinforcement learning, neural network, optical illusion, color constancy, function emergence

1. はじめに

ロボットの知能化が進んでいるが, こと柔軟性に関してはまだまだ人間にお呼びも付かないと言っても過言ではないだろう。人間とロボットでは, その処理の仕方が全く異なっている。われわれの脳は超並列かつ柔軟であり, 様々なことを包括的に考えて適切な行動を生成することができる。一方, ロボットの処理においては, 通常, 人間によって開発された柔軟性のあまりない認識, 制御などの機能モジュールを逐次実行しており, いわゆる「フレーム問題」[1] は未だに解決されていない。サブサ

ンプションアーキテクチャ[2] と呼ばれる並列にモジュールを配置する方法も提案されているが, モジュール間のインターフェイス設計が困難であり, 簡単なロボットの域を脱していない。

脳は超並列処理システムであるが, われわれの意識は逐次的であるため, 自分の脳の中で行っていることであるにもかかわらずわれわれはそれを正確に知ることは難しい。われわれはしばしば, 意識できることが行っていることのすべてであると勘違いしがちであるが, 個々のニューロンの応答を意識できないことからわかるように, 恐らく, 意識を通しては理解できないたくさんの「無意識の処理」が実際には脳の処理を占めてお

り、気付かないうちにわれわれの柔軟さを支えていると考えられる。にもかかわらず、われわれは「意識」を通して理解した脳の機能に基づいてロボットを開発する。それが人間とロボットとの間の乗り越えられない壁の原因であると筆者らは考える。

知覚される特性は、元の物理的な特性から無意識の処理によって変換される。その処理は、われわれの日常生活の中では柔軟な認識に役に立つが、その変化に気が付かないため、改めて元の物理的な特性と比較したときに感じてしまう矛盾が「錯視」であると考えられる。

[3][4]等にあるように、たくさんの驚くべき錯視が報告されている。図1(実際はカラー画像)はそのうちの一つで、女性の顔の左半面に赤いフィルタが掛かっている。両目とも実際にはグレーであるが、どう見ても左目の色はシアンに見える。



図1 驚くべき錯視の一つ [3] (実際にはカラー画像)。立命館大学北岡正佳教授より転載許可。

Fig. 1 One of the amazing optical illusions [3] (Actually Color Image). Copy permission from Prof. Kitaoka.

たくさんの研究者が新しい錯視を見つけるだけでなく、モデリングしたり、時には、脳の画像を見たりして、背後にある柔軟な人間の視覚システムの解明を試

みて来た [5][6][7]。著者らは、柔軟な視覚システムがどのように機能しているかということよりも、それがどのように創発するかに興味がある。なぜならば、並列な脳は、われわれが思っている以上に様々なことを並列かつ複雑に考えており、脳のような柔軟なシステムを実現するためには、手で設計するよりも「創発」させる方が遠回りに見えて実は実現可能性が高い手法であると考えからである。

Lotto R. B. らは、われわれが知覚しているものは、網膜の刺激やそこにある物体の特徴そのものではなく、同様な刺激が種や個体の経験において意味する典型的なものであるとし、過去の経験に基づく統計情報の重要性を指摘している [4]。確かに、2つの線分が同一直線上に配置されていれば、一つの線の一部を何か隠している可能性が高いであろうし、赤い夕陽に彩られてグレーに見える物体の元々の色はシアンである可能性が高いだろう。それらは、錯視が人間の経験を通して形作られることを示唆しており、その処理は一見、ベイズ推定のような統計的な方法を用いることで簡単にモデル化できるように見える。

しかしながら、「0からの創発」という観点から見ると、重大な問題点が浮かび上がる。ベイズ推定を適用するためには、まずターゲットとなる仮説を立てる必要がある。しかし、誰が確率を見積もる事象は「赤い照明下でグレーに見える物体の色は、元々シアンである」と教えてくれるのであろうか?適切な仮説を立てるためには、実際には十分な知識に裏打ちされた高度な知能を必要とする。「フレーム問題」[1]でも見られるように、可能な仮説は無数にあり、知識がない状態で、経験ベースで適切な仮説を見つけようとしても、無意味な仮説を否定することに

時間を費やしてしまう。したがって、直接的に設計したりそれを実現しようという意図がなくても、高次の自由度を持つシステムの中で機能が創発するようなモデルが強く望まれる。

そこで本論文では、錯視を並列で柔軟な無意識下の処理の一つと考え、「日々の生活の中でより適切に振る舞うための学習を通して獲得、もしくは強化されている」という仮説を立てる。そして、「錯視を再現する」という明示的な意図を取らずに、ニューラルネットを用いた強化学習によって、より多くの報酬を得ることだけを目的とした学習モデルを考える。本論文では、「色の恒常性による錯視」に注目し、日常生活のシンプルなモデルとして「色物体の移動タスク」を導入することで、照明条件によらない物体認識の必要性から、学習を通して「色の恒常性」の機能が意図せず獲得されることを示す。

なお、本論文の内容は、物体、フィルタの色にグレーを加えた以外は細かい設定等を除いて基本的に [8] と同様である。

2. 強化学習による機能創発 [9] [10]

一般的にロボットに強化学習を適用する際には、処理全体を、画像認識、行動計画、制御のようにいくつかの機能モジュールに分割し、強化学習は行動計画のための状態空間と行動空間のマッピングの学習として使われる。著者らは、自律的な機能獲得を目指し、図2のような簡単でユニークなアプローチを提案して来た。システムは1つのニューラルネットから成り、センサ信号を直接入力し、モータ信号をその出力とし、その他の人間による機能付与はできるだけ排除する。ニューラルネットは強化学習に基づいて生成された教師信号によって毎ステップ学習される。つまり、強化学習がセンサからモータまでの処理全体を外外部から直接教師信号を与えることなく、報酬や罰から自律的に学習する。それは一見非効率に見え、実際に学習は非常に遅い。しかし、このアプローチは認識や記憶などを含む機能をその境界なく調和的に、また、必要に応じて柔軟に創発することを可能にする。それは、システムがより多くの報酬を得て、罰を避けるという最適化をするためには、必要な機能を獲得し

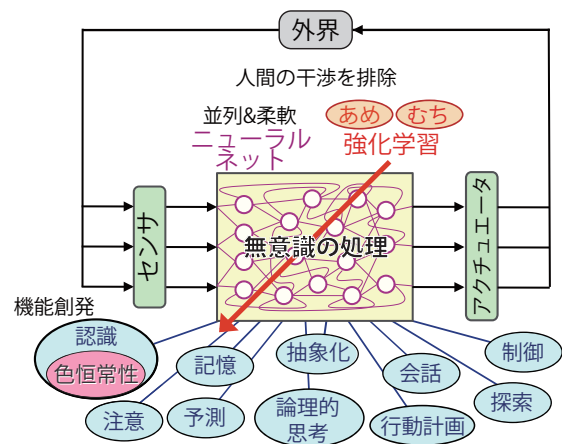


図2 並列で柔軟な学習システムとしてのニューラルネットを用いた強化学習を通じた機能創発

Fig. 2 Function emergence through reinforcement learning using a neural network as a parallel and flexible learning system.

なければならないからである。このアプローチは、実際の生物において、神経系がセンサからモータまでをつないでいることとも整合性が取れる。本論文では、「色の恒常性」の能力が「色物体移動タスク」の学習を通して獲得されることを期待する。

本論文では、連続値入出力を扱うため、強化学習の手法として Actor-Critic [11] を用いる。したがって、ニューラルネットの出力は、状態評価をする Critic の出力と行動を生成する Actor の出力に分けられる。まず、TD 誤差が

$$\hat{r}_{t-1} = r_t + \gamma P(\mathbf{s}_t) - P(\mathbf{s}_{t-1}) \quad (1)$$

と表される。ここで、 r_t は時刻 t で与えられる報酬、 γ は割引率、 \mathbf{s}_t は時刻 t でのセンサ信号ベクトル、 $P(\mathbf{s}_t)$ は \mathbf{s}_t をニューラルネットの入力とした場合の Critic の出力を表す。Critic の出力の教師信号 $P_{d,t-1}$ は

$$P_{d,t-1} = P(\mathbf{s}_{t-1}) + \hat{r}_{t-1} = r_t + \gamma P(\mathbf{s}_t), \quad (2)$$

と計算し、Actor の出力の教師信号 (ベクトル) $\mathbf{a}_{d,t-1}$ は

$$\mathbf{a}_{d,t-1} = \mathbf{a}(\mathbf{s}_{t-1}) + \hat{r}_{t-1} \mathbf{rnd}_{t-1} \quad (3)$$

と計算する。ここで、 $\mathbf{a}(\mathbf{s}_{t-1})$ は \mathbf{s}_{t-1} がニューラルネットの入力の場合の Actor の出力ベクトル、 \mathbf{rnd}_{t-1} は探索成分として Actor の出力 $\mathbf{a}(\mathbf{s}_{t-1})$ に加える乱数ベクトルである。 $P_{d,t-1}$ (実際には、値域調整のために 0.5 を引いた値) と $\mathbf{a}_{d,t-1}$ を教師信号として、 \mathbf{s}_{t-1} を入力とするニューラルネットを BP(Error Back Propagation) 法 [12] に基づいて毎ステップ 1 回学習する。ここで、学習方法が非常に単純で汎用的であり、色の恒常性のための特別な学習は用いていないことに注意して頂きたい。

3. シミュレーション

まず始めに、強化学習によって「色物体の移動タスク」の学習を行う。その後、中間層ニューロンに色恒常性の機能が創発したかどうかを観察し、さらに、色恒常性錯視が実際に起きるかどうかを見るために、追加の教師あり学習とテストを行う。

3.1 「カラー物体移動タスク」の学習

タスクは非常に簡単である。図 3(a) のように、 20×20 のフィールドがあり、各試行 (エピソード) の最初に半径 2 の円形の物体をその中央に置く。物体の色は、図 3(b) に示す 7 色 (赤, マゼンタ, 青, シアン, 緑, 黄, グレー) から各試行ランダムに選択される。物体は 2 次元の Actor の出力ベクトル $\mathbf{a}(\mathbf{s}_t)$ と探索のための乱数ベクトル \mathbf{rnd}_t の和にしたがって移動する。ゴールの位置は、図 3(c) のように物体の色によって異なるが、実際にはゴールの位置は見えない。物体がゴールに触れると一定の報酬がもらえ、試行は終了する。罰は与えなかった。

フィールドの半分は半透明のカラーフィルタで覆われる。フィルタ領域の境界は常にフィールドの中央を通るが、その角度は 0 から 360° の間でランダムに選択される。 0° は右半分、 90° は上半分がフィルタに覆われた状態である。フィルタの色は物体の色と同じ 7 色で、やはり毎試行ランダムに選ばれる。フィルタの透過率は 50% とし、フィルタに覆われた部分の色はフィルタと物体の色の平均値とした。よって、物体の色がシアンで




図 3 カラー物体移動タスク。各物体とフィルタの色は毎試行 7 色からランダムに選ぶ。ゴールの位置は物体の色によって異なる。
Fig. 3 Colored-object guidance task. Each object or filter color is chosen randomly among 7 colors at each episode. The goal location is different depending on the object color.

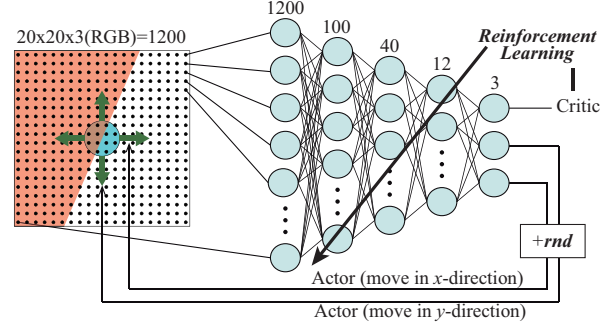


図 4 ニューラルネットを用いた強化学習によるカラー物体移動タスクの学習。物体の移動量は 2 つの Actor 出力によって決定する。
Fig. 4 Learning of “colored-object guidance” task by reinforcement learning using a neural network.

フィルタの色が赤であれば、フィルタに覆われた物体部分の各画素からのセンサ信号は、赤 (R, G, B) = (255, 0, 0) とシアン (0, 255, 255) の平均であるグレー (127, 127, 127) となる。物体をゴールに動かすためには、このフィルタの影響を取り除き、元の物体の色を認識する必要がある。

図 4 はこのタスクにおける学習システムと信号の流れを示す。ニューラルネットの入力は、フィールド上の 20×20 の格子点からの色の信号を 0 から 1 の間に正規化し、さらに 0 と 1 を反転させたものを入力とした。したがって、白いところでは RGB のすべての入力が 0 となる。初期状態では、400 個の格子点のうち、中心付近の 12 個の格子点が物体を捉えている。ネットワークの出力は、1 個の Critic と 2 個の Actor の出力からなり、各ニューロンの出力関数として -0.5 から 0.5 の値域のシグモイド関数を用いた。それぞれの教師信号は、シグモイド関数の飽和領域を避けるために、 -0.4 から 0.4 の範囲に限定して与えた。ニューラルネットの出力と Critic の間では、値域を調整するために、0.5 の加算または減算を行った。2 つの Actor 出力は、物体の水平と垂直方向の移動量を表し、 $2.5\sqrt{2}(\mathbf{a}(\mathbf{s}_t) + \mathbf{rnd}_t)$ を実際の移動量とした。ただし、移動量 (ベクトル) の大きさの最大値を $\sqrt{2}$ とし、移動可能領域を円形とした。また、Actor の教師信号もベクトルとしての大きさを 0.4 に制限した。ニューラルネットは 5 層とし、入力層から出力層までのニューロン数を 1200 ($20 \times 20 \times 3$)-100-40-12-3 とした。出力ニューロンへの結合の初期重み値は 0.0 とし、その他の初期重み値は -1.0 から 1.0 の範囲の乱数で決定した。ゴール到達時、つまり、物体の中心とゴールとの距離が 2.0 以下の

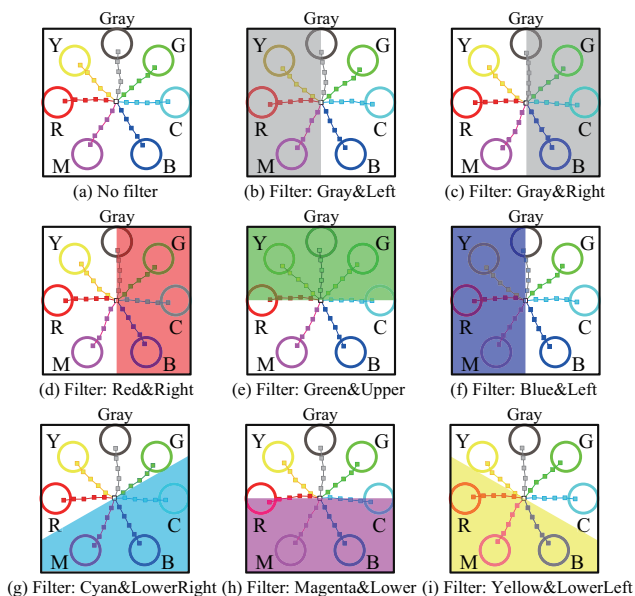


図5 いくつかのカラーフィルタ条件に対する学習後の物体の経路例
Fig. 5 Some sample object trajectories after learning.




図6 一試行中の Critic と Actor の出力の変化例 (黄色の物体の場合)
Fig. 6 Samples of Critic and Actor outputs in one episode.

場合に 0.9 の報酬を与えた。つまり、ゴール時の Critic の理想値は 0.9 (ニューラルネットの出力は 0.4) である。割引率 γ は 0.96 とした。Actor の出力に付加する試行錯誤用の乱数ベクトル \mathbf{rnd} の各成分は、最初は ± 2.0 の範囲の一様乱数とし、その後直線的に 0.0 まで減らした。

300,000 試行の強化学習を行った。図 5 は学習後の、いくつかのフィルタ条件での物体の軌道例を表す。いずれの場合も、物体はその色によって決められたゴールに最適の 5 ステップで到達している。また、物体の軌道はフィルタの条件によって多少異なるが、良く似ていることがわかる。

図 6 は、1 試行中の Critic と Actor の変化の例を示す。物体の色は黄色で、一つはフィルタがない場合、他の 2 つはフィルタがあり、物体と反対色の青いフィルタが左半分にある場合と物体と同色の黄色いフィルタが上半分にある場合である。いずれの場合も Critic は滑らかに上昇し、報酬 $r = 0.9$ 、割引率 $\gamma = 0.96$ から計算した理想値とあまり差がない。Actor の出力は、3 つの場合で少し違いが見えるものの、左上に物体を動かすために、 x 成分は負、 y 成分は正の値となっている。

3.2 中間層ニューロンが獲得した内部表現

物体をフィールドの真ん中に置いて様々な条件でカラーフィルタを掛けた際の、出力層に最も近い最上位の中間層の 12 個のニューロンの出力を観察した。Fig. 7 に、いくつかの中間層ニューロンの 105 通り (物体の色 $7 \times$ (フィルタの色 $7 \times$ フィ

ルタの角度 $2 +$ フィルタなし 1)) の場合の出力をプロットしたものを示す。比較のため、「フィルタなしで強化学習を行った場合」「強化学習を行う前」の中間層ニューロンの出力も示す。いずれも学習前の初期重み値は同じであるため、(1-1) と (2) の場合も、強化学習前は (3) と同じ出力分布であった。

「フィルタあり強化学習後」の場合、半数弱のニューロンは全体的にあまり変化がなかったが、半数強のニューロンが (1-1)(1-2) のように、フィルタの色や位置にはあまり影響されず、物体の色を表現していた。フィルタの色によって主に変化するニューロンは見られなかった。一方、「フィルタなし強化学習後」の場合、不規則に反応するニューロンも見られたが、(2) のように、物体の色にはあまり反応せず、フィルタの色に反応するニューロンが多く存在した。「強化学習前」では、微小な初期重み値によってその表現が決定されるため、全体的に出力の絶対値は小さく、(3) では特定の部分で出力が少し大きくなっているが、より不規則な分布のものが多かった。

この傾向を定量的に示すため、Fig. 8 に強化学習に関する条件が異なる 3 つの場合について、物体の色が同じ場合のフィルタの色や位置による最上位中間層ニューロンの出力のばらつき (標準偏差) の平均と、逆にフィルタの色と位置が同じ場合の物体の色によるばらつき (標準偏差) の平均をプロットした。「フィルタあり強化学習後」の中間層ニューロンはフィルタの色に影響されることなく物体の色を表現しており、一方で、「フィルタなし強化学習後」は逆に物体の色ではあまり変化せず、主にフィルタの色によって出力が変化していることがわかる。

3.3 「色の恒常性」のテスト

「色の恒常性の錯視」のテストのために、強化学習後のニューラルネットにさらに教師あり学習を行った。まず、3 つの出力ニューロンを中間層ニューロンとの重み値がすべて 0 のニューロンに置き換え、フィルタなしの状態領域中央にランダムに色を決定した物体を置き、その画像をニューラルネットに入力した。そして、物体の色の RGB の値を -0.4 から 0.4 に変換して 3 つの出力ニューロンの教師信号としてそれぞれ与え、ニューラルネットを教師あり学習させた。20,000 回物体を提示して学習し、誤差はほぼ 0 となった。その際、中間層ニューロンへの重み値も学習によって更新した。学習後、今度はテストとして領域の半分にはフィルタを掛けて出力を観察した。もし物体移動タスクを通して色の恒常性の機能が中間層に獲得されていれば、フィルタがない状態で学習するだけで、テストの際にフィルタが掛かった状態で物体を提示してもフィルタの影響を除去して元の物体の色を出力すると期待される。Fig. 9 に、Fig. 1 のように赤いフィルタが右または左半分には掛かった状態でシアン色の物体の半分が実際にはグレーになった場合とグレーの物体の右半分にシアンのフィルタが掛かっている場合のそれぞれについて、物体部分の左半分と右半分の RGB 値とフィルタの RGB 値を左側のグラフに、前述の 3 つの強化学習条件のニューラルネットの出力から求めた RGB の値を右側のグラフに示す。

「フィルタあり強化学習後」のニューラルネットの場合、フィルタの位置を変化させた場合も含めて、他の 2 つの場合と比較し、明らかに物体の RGB 値に近い値を出力していること

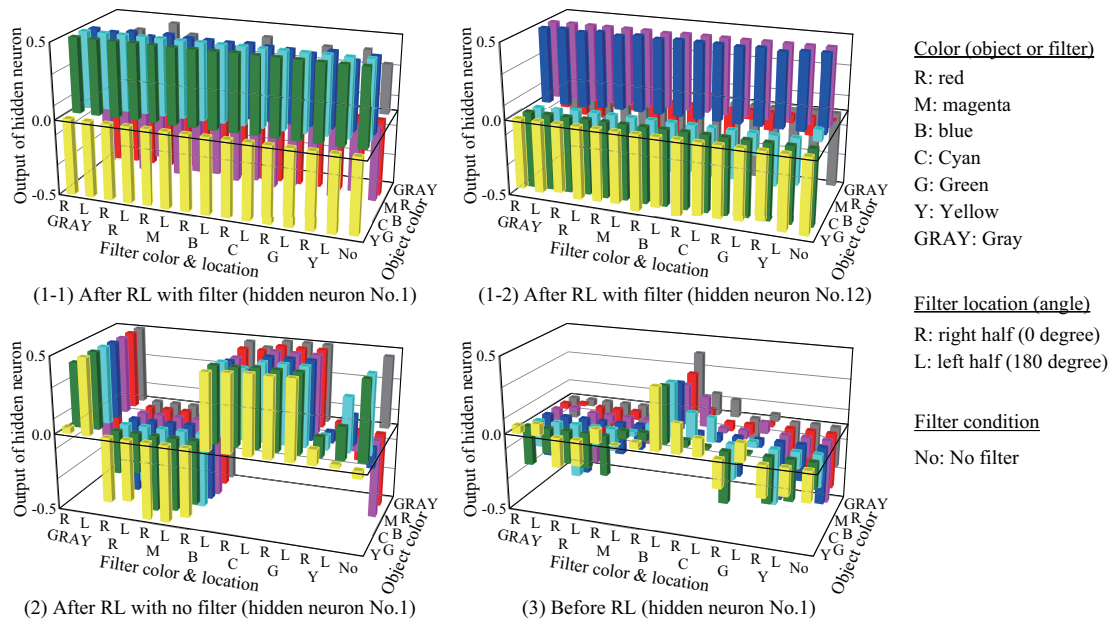


図7 物体色およびフィルタの色と位置の組み合わせに対する最上位中間層ニューロンの出力の3つの強化学習条件での比較

Fig. 7 Comparison of the output of one or two typical top hidden neurons depending on the object color, filter color and angle among the three reinforcement learning conditions.

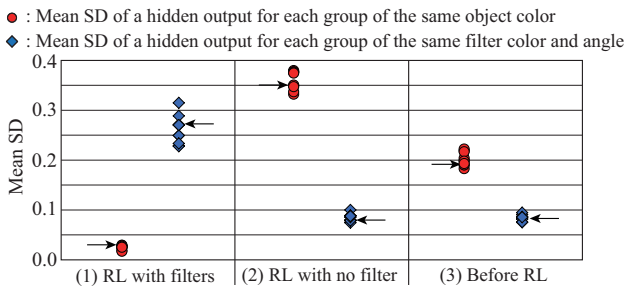


図8 最上位中間層ニューロンの出力の同一物体色グループ内の標準偏差の全物体色、全ニューロンでの平均と同一フィルタ色と位置のグループ内での標準偏差の全フィルタ色と位置および全ニューロンでの平均の各強化学習条件での比較。それぞれ乱数系列を変えて10個の点をプロットした。たとえば、一番左の○のプロット点の値が小さいということは、同じ物体の色であればフィルタの色や角度が変化してもばらつきが小さいことを表す。小さい矢印は図7および図9で使用したデータを示す。

Fig. 8 Comparison of mean standard deviation(SD) of an top hidden neuron output in the same object color group and that in the same filter color and angle group among three reinforcement learning conditions.

がわかる。また、下の2つの例では、物体部分の見え方は良く似ているが、出力はフィルタの効果を除いた出力となっていることがわかる。また、「フィルタなし強化学習後」の場合には、「強化学習前」よりもフィルタの色に反応するようになっている。これは、フィルタなしで強化学習を行う場合、フィールドには物体しかない状態でその色からゴールを識別するため、フィルタの色を物体の色と誤解することでより広い範囲をカバーするフィルタの色に大きく影響されたものと考えられる。「強化学習前」の出力は、実際に見える物体の色に少し近いが、教師あり学習時にフィルタは出て来ない上、物体も中央部以外に現れ

ることはないため、中央部以外のピクセルからの入力に対する結合はランダムに設定した初期重み値のままとなり、テスト時にフィルタが出現しても、その影響を排除することはできない。

この傾向を定量的に評価するために、Fig. 10に、教師あり学習後に物体色、フィルタ色、フィルタ角度(4通り)を変化させた時のニューラルネットの出力と物体のRGB値との差の平均およびフィルタのRGB値との差の平均を、乱数系列を変えて取った10個のデータを示す。3つの強化学習条件のいずれも、フィルタのない場合の物体の色との誤差はほぼ0であった。「フィルタあり強化学習後」の場合は、物体のRGB値に近い値を出力し、「フィルタなし強化学習後」の場合は、フィルタのRGB値に近い値を出力していることが顕著に現れている。

これらの結果から、われわれ人間も「色の恒常性」つまり「フィルタ色の補償」が、赤い夕日が当たるところでバナナを食べるなどの日常生活での行動の学習を通して創発、もしくは、強化される可能性があるのではないかと筆者らは考えている。

4. 結論および議論

本論文では、並列処理システムとしての脳による無意識下の処理と日常生活での学習を通じたそのような処理の創発の重要性を指摘し、われわれがその処理に気付かないがために、その処理の結果を矛盾、つまり、錯覚として感じられるとの見方を示した。錯視とその背後にある柔軟な機能の創発の可能性を示すことを目指し、様々なカラーフィルタがかかる状態で物体色によってゴールが変わる物体移動タスクをニューラルネットを用いた強化学習によって学習させた。学習後のニューラルネットの中間層の表現を観察したり、追加の教師あり学習とテストを行った結果から、物体の色によって異なるゴールへ物体を移動させる必要性から、色の恒常性の機能が発現することを確認




図9 強化学習後に出力ニューロンを入れ替えてフィルタなしで物体のRGB値を教師あり学習した後でのフィルタありの状態での出力(右のグラフ)の3つの強化学習条件での比較。左のグラフは出力と比較するための物体部分の左半分と右半分の実際の色とフィルタの色。

Fig.9 Comparison of the network outputs (right graphs) after supervised learning of object color with no filter among three reinforcement learning conditions. Left graphs show the actual color of left or right half of the object and filter color for reference.

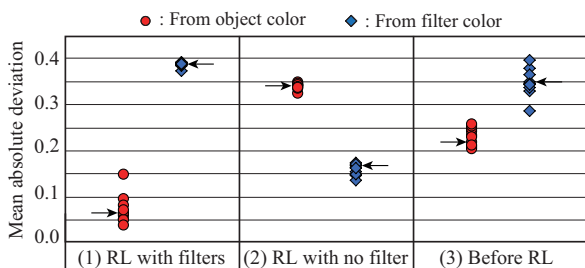


図10 物体色、フィルタ色とニューラルネット出力との差の絶対値の比較。乱数系列を変えて10点をプロット。矢印は図8と同様。
Fig.10 Comparison of mean absolute deviation from the network outputs to the RGB values of the object color or filter color among three reinforcement learning conditions.

した。この方法によって、タスクに関する知識やベイズ推定などの統計的手法で必要になる仮説を立てる必要なく、並列処理システムとしてのニューラルネットの中に報酬を得るための最適化の結果として有用な表現がニューラルネット内に発現することを示した。このことは並列処理システムを効果的に用い、「フレーム問題」を回避するための非常に重要な側面である。

本論文で示した「色の恒常性の錯視」は、周辺の色による補正等からある程度説明できるが、実際に画像を扱うソフトで錯視の確認をしてみると、錯視が起こる条件の記述は非常に難しいことがわかる。たとえば、左半面を薄い赤色で覆い、その中央に小さなグレーのパッチを置いても図1のような錯視はほとんど起こらない。しかし、右半面にもグレーのパッチを置いたり、右と左に股がる複数色の背景が、いずれの色も左半面で同様に赤っぽくなっていると、元のグレーのパッチの色がシアンに見えてくる。つまり、色の恒常性は様々な要因に影響されており、図1の画像はそれらを巧みに組み合わせて作られていることがわかる。著者らは、このような複雑な処理も赤い紙の上にグレーの物体が置かれた状況も含めた様々な状況において、並列処理が可能なニューラルネットを学習させることで人の手で記述することなく形成されるのではないかと期待している。

人間にとって錯視は生後獲得される能力ではなく、生得的な機能であるかもしれない。もしそうであるならば、進化の過程

にも似たようなメカニズムがあるのかもしれない。また著者らは、進化の過程を通して誕生前にすでに錯視が脳の中に形成されていても、生後の学習によってそれが維持・強化され、柔軟で適応的な視覚認識を実現している可能性もあると考えている。

謝 辞

驚くべき錯視で研究のトリガを掛けて頂くとともに、有用なコメントを頂きました立命館大学の北岡明佳先生に感謝致します。本研究は科学研究費補助金 #19300070, #23500245 の補助を受けて行われた。

文 献

- [1] Dennett, D.: Cognitive Wheels: The Frame Problem of AI, *The Philosophy of Artificial Intelligence*, M. A. Boden, Oxford University Press, pp. 147-170 (1984)
- [2] Brooks, R. A.: Intelligence Without Representation. *Artificial Intelligence*, Vol. 47, pp.139-159 (1991)
- [3] 北岡明佳, 北岡明佳の錯視のページ, <http://www.ritsumeiji.ac.jp/~akitaoka/>, または, 錯視入門, 朝倉書店 (2010)
- [4] Lotto, R.B., Purves, D., Nundy S.: Why We See What We Do, *American Scientist*, Vol. 90, No. 3, pp. 236-243 (2002)
- [5] Inui, T., Hongo, S. & Kawato, M.: A computational model of brightness illusion and its implementation, *Perception*, Vol. 19, pp. 401 (1990)
- [6] Robinson, A. E, et al.: Explaining brightness illusions using spatial filtering and local response normalization, *Vision Research*, Vol. 47, pp. 1631-1644 (2007)
- [7] Kuriki, I., Ashida, H., Murakami, I & Kitaoka, A.: Functional brain imaging of the Rotating Snakes illusion by fMRI, *J. of Vision*, Vol. 8, No. 10, pp. 1-10 (2008)
- [8] Shibata, K., & Kurizaki, S.: Emergence of Color Constancy Illusion through Reinforcement Learning with a Neural Network, *Proc. of ICDL-Epirob2012* (2012)
- [9] 柴田克成: 強化学習とニューラルネットによる知能創発, 計測と制御, Vol. 48, No. 1, pp. 106-111(2009)
- [10] Shibata, K.: Emergence of Intelligence through Reinforcement Learning with a Neural Network, *Advances in Reinforcement Learning*, InTech, pp. 99-120 (2011)
- [11] Barto, A.G., Sutton, R.S., & Anderson, C.: Neuron-like adaptive elements that can solve difficult learning control problems, *IEEE Trans. on SMC*, Vol. 13, pp. 834-846 (1983)
- [12] Rumelhart, D.E, Hinton, G.E., and Williams, R.J.: Learning Internal Representations by Error Propagation, *Parallel Distributed Processing*, The MIT Press, pp. 318-362 (1986)