

第5章 局所センサ信号統合化学習による 視覚系機能の学習モデル

本章では、前章で提案した時間軸スムージング学習による局所センサ信号統合化学習を基本として、頭部位置によらない物体位置認識の学習モデル、動眼前庭反射の学習モデル、物体追跡の学習モデルが説明できることを示す。これらは主に、時間軸スムージング学習による局所センサ信号統合化学習の有効性を肉付けする立場で進めた研究であり、生体のモデルとしては必ずしも適切でない部分が多々あるが、最終的には両者が収束することを期待している。

5.1 頭部位置によらない物体位置認識の学習モデル

我々生物は、頭や目が動いても正しく物体の位置を認識することができる。例えば頭を大きく動かしてもまわりの物体が動いているとは感じない。ところが、前章で提案したシステムでは、頭や目の位置に関する信号の入力がないため、このような機能を実現することが不可能であった。ところが、頭や目の動きが滑らかでないと仮定すれば、前章のシステムに頭や目の位置を入力として加えてやれば、出力を時間に対して滑らかに変化するようにという前章で提案した学習アルゴリズムによって頭や目の位置によらない物体の位置の認識ができるようになると考えた。

具体的な例を挙げて説明する。図5.1のように、頭部位置が可変の視覚センサを考え、頭部の位置および視覚センサからの出力を階層型ニューラルネットへの入力とした。

物体と視覚センサ（網膜）との位置関係は、図5.2のように、物体の位置および頭部の位置の差によって表され、視覚センサの出力もその値に従って変化する。頭部位置は、ここでは乱数で決定

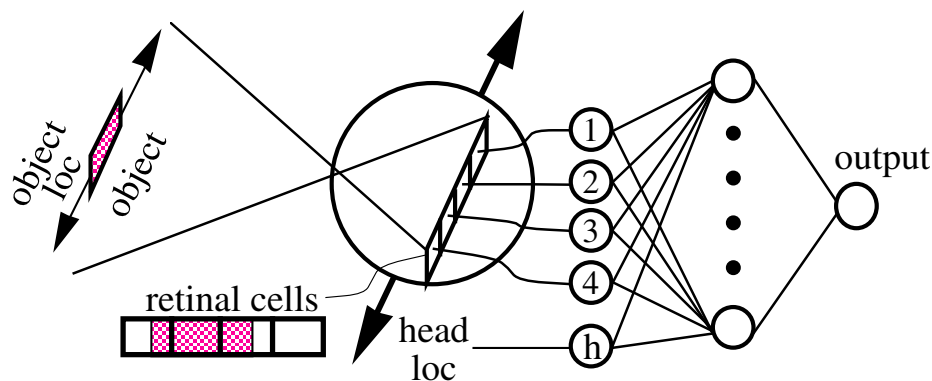


図5.1 頭部位置によらない物体の位置認識を学習するシステムの構成

するものとし、物体は前章と同じく、視覚センサの視野からはみ出ない範囲で左右に単振動をしているものとする。シミュレーションの環境は、前章のものとほとんど同じで、視覚センサのセンサセル数は30個とし、各センサセルの幅は1とした。投射された物体の大きさは2.5とし、頭部の位置は、中心から左右に4.0の間で毎単位時間乱数で決定した。また、物体は視野から消えない範囲（振幅9.75）で左右に単振動しているものとする。

学習後、物体の位置と頭部の位置を変化させた時の、物体の位置に対するニューラルネットの出力値をプロットしたものを図5.3に示す。この図から、頭部の位置が変化しているにもかかわらず、物体の位置と出力が1対1の関係になっていることがわかる。また、頭は動いているにもかかわらず、頭部位置の入力を0に固定した場合の出力を図5.4に示す。この場合は、頭部位置を補正することができず、物体の位置と出力の間に1対1の関係を得ることができなかった。以上より、頭部位置をニューラルネットに入力することにより、頭部位置によらない物体位置認識を学習することが確認できた。

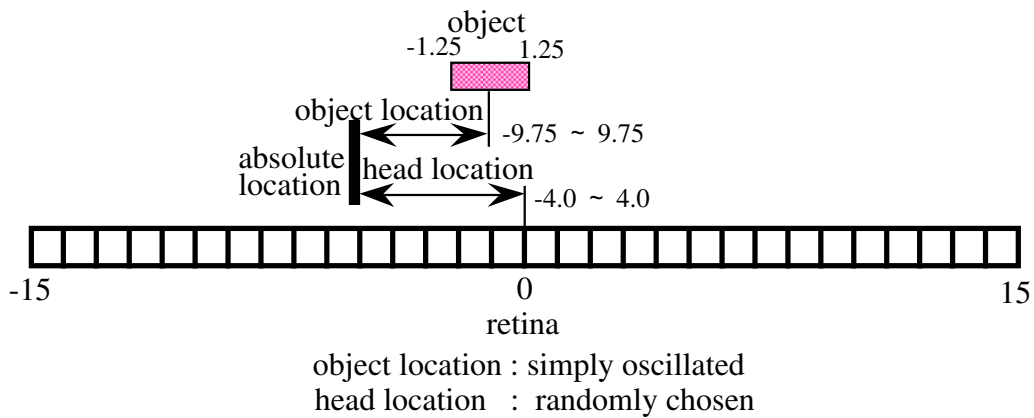


図5.2 物体と網膜との位置関係




図5.3 学習後の物体の位置に対する出力




図5.4 頭部位置の入力値を0にした場合の
物体の位置に対する出力

5.2 前庭動眼反射の学習モデル

我々生物が行っている頭部位置の補償には、前節のように頭の中で補償するという機能の他に、前庭動眼反射（VOR Vestibulo-Ocular Reflex）という機能があることがよく知られている。これは、頭部の位置が変化した場合、それと逆の方向に目が移動することによって、網膜上に映る物体がぶれないようにする機能である。また、この前庭動眼反射では、環境を操作してやることにより、頭部の動きと目の動きの間のゲインが適応的に変化することも知られている[Gonshor 76]。

そこで、図5.5のように、前章のシステムに、さらに目の動きを学習するニューラルネット（eye movement net）を設け、そこに頭部の位置を入力し、その出力に従って目を動かすというシステムを構成した。この時の物体と網膜の位置関係は、図5.6のように、頭部の位置、目の位置、そして物体の位置を用いて表すことができる。物体の位置を抽出するニューラルネット（LSSIネットと呼ぶ）は前章と同様な学習を行い、目の動きを決定するニューラルネットに関しては、LSSIネットの時間軸の滑らかさを強化信号として、より滑らかになるように学習を行った。

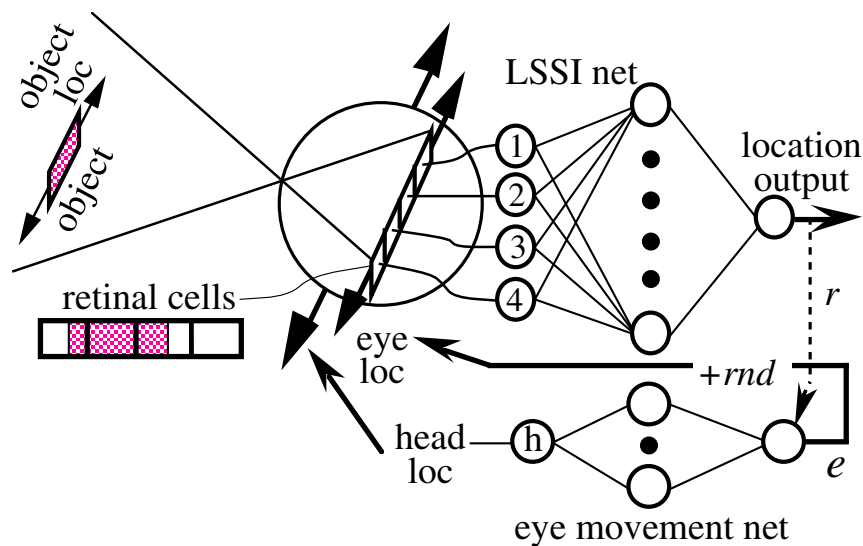


図5.5 前庭動眼反射の機能を学習するシステムの構成

具体的には、まず、目の動きのニューラルネットの出力に乱数 rmd を加えて目を動かす。そして、LSSIネットの出力の凹凸の度合い v およびその時間平均 \bar{v} を

$$v(t) = \left\{ \frac{x(t-1) + x(t+1)}{2} - x(t) \right\}^2 \quad (5.1)$$

$$\tau \frac{d\bar{v}}{dt} = -\bar{v} + v \quad (5.2)$$

x : LSSIネットの出力

と計算する。この時、時間平均と比較した現在の出力の時間変化の滑らかさ、つまり、出力の時間変化の凹凸の小ささを強化信号とするため、強化信号 r を

$$r = \bar{v} - v \quad (5.3)$$

と計算する。そして、目の動きを決定するニューラルネットに対し、2.2節で述べたように

$$s_2 = x_2 + \eta \cdot rnd \cdot r \quad (5.4)$$

x_2 : 目の動きのニューラルネットの出力

η : 学習のための定数

という教師信号を内部生成して学習を行う。具体的に用いた数値は、ほぼ前節と同様である。ただし、目の動きに加えた乱数 rnd は ± 0.04 の範囲の一様乱数とし、 η は試行錯誤から 100 とした。

学習した結果、頭の位置が動いているにもかかわらず、物体の位置に対する L S S I ネットの出力は、図 5.7 のようにほぼ 1 対 1 の対応がとれるようになった。また、目の位置を中央 (0.0) に固定すると、図 5.8 のように 1 対 1 の対応がとれなくなる。また、頭の動きと目の動きの関係を調べると、図 5.9 のようにちょうど符号が反対になっていることがわかる。このことから、目の動きによって頭の動きが補償されていることがわかる。

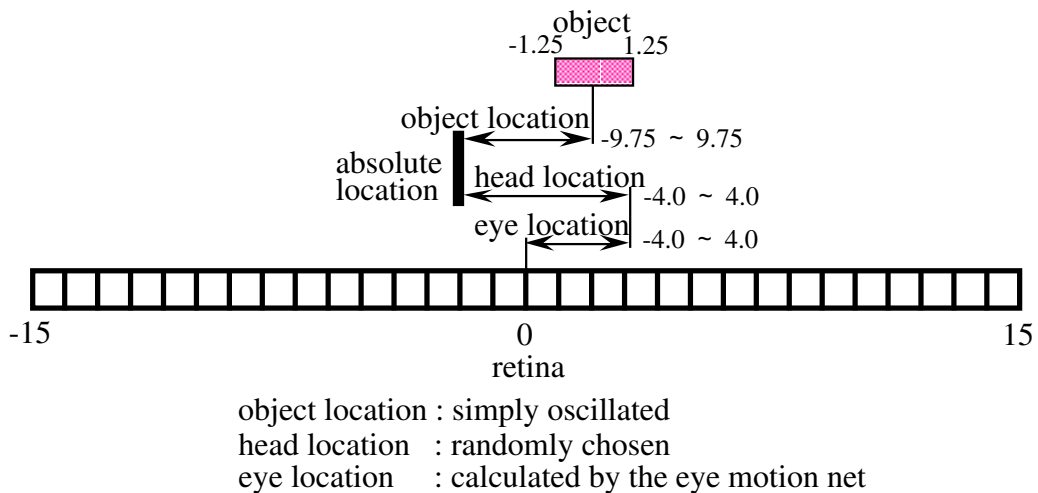


図 5.6 物体と網膜との位置関係




図 5.7 学習後の物体の位置に対する出力




図 5.8 目の位置を固定した場合の物体の位置
に対する出力

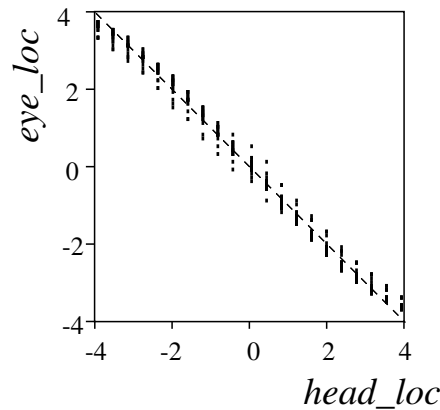


図 5.9 学習後の頭の位置に対する目の位置

5.3 物体追跡の学習モデル

我々生物は、常にできるだけ多くの外界の情報を取り込み、それに対して適切な対応をとらなければならない。ところが、もしセンサからの入力時間が時間によって変化しなければ、これは新しい情報が得られていないということになる。従って、我々生物は、例えば、物体が見えなくなったらそれを追跡するというように、より多くの情報を得るように行動する必要がある。つまり、我々の行動が、センサを通じてより多くの外界の情報を得るよう学習されているのではないかと考えることができる。ここでは、得られる情報の多さを、局所センサ信号統合化学習によって統合された空間情報の時間微分値の絶対値で表されるものと考え、強化学習を用いて、この時間微分値を最大化するよう行動を決定する方法を考えた。そして、これによって、物体を追跡するという動作が学習できるかどうかを確認した。

まず、図5.10のように、視覚センサからの信号と目の位置の情報を受け取り、物体の位置（出力1、物体の位置出力）、物体の位置出力の変化量（出力2、物体の位置微分出力）、新しい目の位置（出力3、目の位置出力）の3つの出力を出すニューラルネットを考える。そして、物体の位置出力に対しては、前章と同様の方法で学習を行い、物体の位置微分出力に対しては、(1)1番目の物体の位置の出力の変化量と(2)2番目の出力自身の時間変化が滑らかになるような値を足し合わせて教師信号として与え、学習をさせる。そして、3番目の目の位置を決定する出力に対しては、2番目の出力が大きくなるように強化学習を行うと共に、振動を防止するため時間変化が滑らかなほど良いという学習も合わせて行う。これによって、物体の位置出力が時間的に大きく変化する場合は2番目の出力が大きくなり、結果的に物体の位置が時間的により変化するように目が動くという仕組みになっている。直接物体の位置の出力の微分値を学習に用いると、その変化が急峻になってしまい、目の動きをうまく学習することができなくなる。そこで、2番目の出力ニューロンを設け、ニューラルネットの出力が、入力の変化に対して滑らかに変化する特徴と、上記のように時間に対して滑らかに変化するようにという項による学習によって、物体が視野から消えそうになるとその値がだんだん小さくなるようにする。

具体的な式および数値を示す。ある時点での位置出力の傾き $slope$ は、

$$slope(t) = \frac{|x(t) - x(t-1)| + |x(t+1) - x(t)|}{2.0} \quad (5.5)$$

と計算し、その時間平均 \overline{slope} を

$$\tau \frac{dslope}{dt} = -\overline{slope} + slope \quad (5.6)$$

と求める。ただし、時定数は1000とする。そして、位置微分出力 s_2 を、出力が滑らかになるための教師信号 $s_{2,smooth}$ と位置出力の微分値の教師信号 $s_{2,slope}$ を混ぜ合わせた

$$s_2 = \alpha s_{2,smooth} + (1-\alpha) s_{2,slope} \quad (5.7)$$

とした。ここでは、 α を0.9とし、それぞれの教師信号は

$$s_{2,smooth} = \frac{x_2(t-1) + x_2(t+1)}{2.0} \quad (5.8)$$

$$s_{2,slope} = \frac{1.6}{1 + \exp(-slope / \overline{slope})} \quad (5.9)$$

によって求めた。さらに目の位置出力に対しては、

$$s_3 = \frac{x_3(t-1) + x_3(t+1)}{2.0} \quad (5.10)$$

を教師信号として、時間に対して滑らかになる学習を行うと共に、さらに、

$$s_3 = x_3 + \zeta \frac{dx_2}{dsensor} \quad (5.11)$$

sensor : 目の位置、 ζ : 学習の定数 (ここでは、0.01)

によって、位置微分出力が大きくなるように強化学習を行った。この式における偏微分は、

$$sensor = x_3 + \Delta$$

$$sensor = x_3 - \Delta \quad (5.12)$$

の2点 (ここでは、 $\Delta=0.01$) における x_2 の値を計算し、その差に $1/\Delta$ をかけたものとした。また、このシミュレーションでは、図5.11のように目の最大振幅を ± 15 、物体の単振動運動の振幅を 25.75 とし、目を動かさなければ物体が視野からはみ出るように物体を動かして学習を行った。例えば、物体が最大振幅の位置にある場合は、目を反対側に 12 動かさなければ、物体の一部または全部が見えなくなる。

図5.12に学習後の物体の位置に対するニューラルネットの3つの出力値の値をプロットしたものを示す。この時、物体は学習時と同様に単振動をしている。これより出力1が物体の位置を学習でき、さらに出力2がその変化量をほぼ学習していることがわかる。また、出力2の値が、物体の位置の絶対値が大きい時に小さくなっている。これは、物体の位置の絶対値がさらに大きくなって物体が視野から消えると出力1は一定値となり、出力2が0に近づくような学習が働き、さらに、前述のように出力2の時間変化が滑らかになるように学習されているため、物体が見えている場合でも端に行くほど出力が0に近づくことになる。そして、出力3は、出力2が大きくなるように強化学習を施しているため、物体がはみ出さないように動作するような出力となっている。また、出力3は物体の位置に対して単調に増加せず、物体が中心から離れた場所では最大でフラットにな




図5.10 物体追跡を学習するシステムの構成

っている。これは、物体をより真ん中で捉えようとしていることになる。これは、出力2の出力が滑らかになるように学習されているため、真ん中付近の値が最大になるため、これをもとに学習した出力3はより真ん中にセンサを持っていかこうとすると考えられる。また、物体の位置に対するセンサ及び物体とセンサの相対位置関係を図5.1.3に示す。ここで、物体と目の相対位置の絶対値16.25を越えると物体が視野から完全に消えることになるが、目が物体の方へ動くことによって物体が視野から消えないようになっていることがわかる。また、本学習では、現在の目の位置がニューラルネットの入力となり、次の時刻の目の位置がニューラルネットの出力として得られるというフィードバックループを有する上、物体の位置出力の時間変化量の絶対値が大きいほどよいということになっているため、目の位置が大きく振動してしまうという不安定な解に陥りやすい。ここでは、目の位置出力に対しても時間変化が滑らかなほどよいという拘束を設けて学習をさせているが、より明確な学習アルゴリズムが必要であると考える。

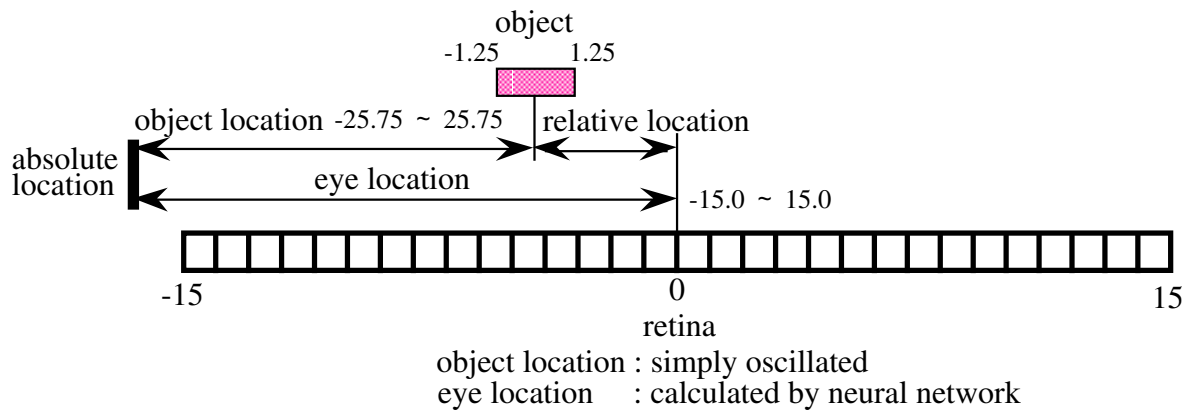


図5.1.1 物体と網膜との位置関係

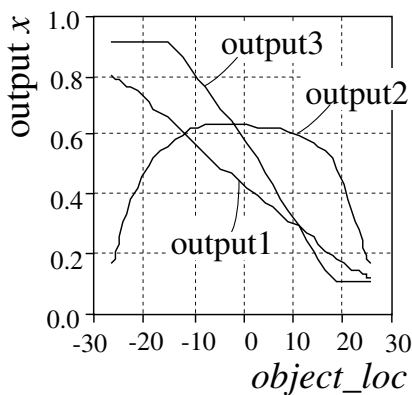


図5.1.2 学習後の物体の位置に対する各出力

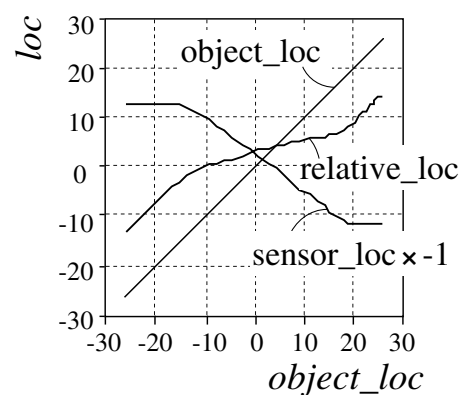


図5.1.3 学習後のセンサの絶対値と物体との相対位置




図 5.14 学習後に物体を提示した時の網膜上での物体の動き

図 5.14 に物体をある位置に固定した時のセンサの動きの様子を表す。この図では、物体の位置と初期センサの位置を変えた 3 つの場合が示して

ある。この場合、物体の位置を 0 に固定した場合は、センサの初期位置を変化させてもセンサは同じ場所に収束することがわかる。ただし、収束点は真ん中付近になるが、学習によって多少変動をするため、学習をストップさせる時刻によってこの値は変動する。この場合は、右にずれている。また、物体と網膜の相対位置関係が等しい場合でも、物体の位置を違うものと認識し、収束点も違っていることがわかる。

5.4 他のモデルおよび生理学的、心理学知見との対応

本章で述べた 3 つのモデル、特に前庭動眼反射に関しては、他にもモデルや多くの知見がある。本節では、これらとの比較をおよび対応付けを行う。

頭部位置によらない認識に関しては、頭を大きく左右、上下に動かしても、まわりの空間が動いているように感じないという我々の感覚に基づくものである。また、これに関連した話として、Andersen らは、サルの後部側頭葉の皮質部において、網膜上の物体の位置だけでなく、物体の位置と眼球の位置の両方によって興奮の度合いが変化するニューロンが存在することが確認されている [Andersen 85]。この実験では頭部は固定して行われているが、いずれにせよ、頭部および眼球の位置情報と物体の位置情報を脳内で統合して空間の情報を得ている可能性は高いと考えられる。また、頭部、眼球の位置と物体の位置の正確な関係を生得的に持っていることは不自然であり、この機能を学習によって獲得、または調節している可能性は高いと考える。

前庭動眼反射に関しては、特に、その適応性が小脳における学習と関連しているということが言われており、よく研究されている分野である。この機能は、三半規管による頭の回転の検知 前庭神経核 外眼筋の運動ニューロン 外眼筋による眼球の運動という 3 つのニューロンを介した経路によって実現されていることが知られている。これに対し、伊藤は、前庭神経核への小脳片葉からの投射に注目し、小脳における学習が前庭動眼反射における適応の機能を担っているというモデルを提案し [Ito 70]、これを裏付ける実験も行った [Ito 82]。さらに、川入らは、フィードバック誤差から制御系の逆ダイナミクスモデルを階層型ニューラルネットで学習し、フィードフォワード制御を

行うというフィードバック誤差学習[Kawato 87]によってこの機能の説明が付くことを示し[川人 94]、前庭動眼反射の適応実験のデータが再現できることを確かめている[Gomi 92]。

川人らのモデルでは、網膜像におけるぶれの速度を検出し、これを誤差信号として小脳片葉における学習によって適応的な前庭動眼反射が実現されるとしている。しかし、この網膜像におけるぶれの速度の検出については触れられていない。これに対し、本章で提案した前庭動眼反射のモデルは、このぶれを、視覚センサ信号を統合した出力値の滑らかさというもので置き換えることによってよりその機能を明確化したものであるとすることができる。

次に、目が物体や背景の動きを追跡する運動として2種類の運動が知られている。1つは、追従性眼球運動(OFR: Ocular Following Response)、もう一つが平滑性追跡眼球運動(Smooth Pursuit Eye Movement)である。前者は、背景などの広い視野を占めるものがゆっくりと動作すると、目がそれにつれて反射的に同じ方向に動くというものである。後者は、興味ある物体を目で追いかける随意的な運動である。本章の物体追跡のモデルは、何か一つの物体に注意している場合を想定しており、平滑性追跡眼球運動に近い。しかし、随意的という点を本モデルではあまり考慮しておらず、また、生理学的、心理学的知見とのすりあわせもあまり行っていないため、今後検討していく必要がある。

5.5 まとめおよび考察

本章では、前章で提案した時間軸スムージング学習を用いた局所センサ信号統合化学習を拡張することにより、視覚システムの(1)頭部位置によらない認識(2)前庭動眼反射(3)物体追跡といった機能が学習によって獲得できることがある程度説明できることを示した。(1)および(2)では、物体の位置を抽出する出力が時間に対して滑らかに変化するようにという学習によって、頭部の位置を(1)ではニューラルネット内で補償し、(2)では目の動きをニューラルネットで学習させることで補償した。(3)では、外界の情報をより多く獲得するようにという学習によって実現した。ここでは、局所センサ信号統合化学習を行っているニューラルネットの出力の時間変化量の絶対値を得られる外界の情報量として用いた。

ただ、前章で述べた局所センサ信号統合化学習自体の問題点や、前庭動眼反射のモデルで頭部の位置を各単位時間毎に乱数で決定するなど不自然な点が多い。実際は、頭部の位置も何らかの運動指令に基づいて動いているはずであり、それをどう扱うかは大きな問題として残る。また、物体追跡の学習モデルでも出力の時間変化量の絶対値を大きくしようとしているため、目の動きが振動を起こしやすいという本質的な問題を抱えている。本論文では、目の動きを決定する出力も合わせた核出力が時間と共に滑らかに変化するようにという学習によって振動を抑えている。しかし、それでも目が小さな振動を起こすことがある等モデルとしてまだまだ不十分な点が多い。また、生理学的、心理学的な裏付けもあまり得られていない。これらの問題点を検討し、より妥当性のあるモデルを作っていくことは今後の課題である。

ただ、これらを通して、局所センサ信号統合化学習、時間軸スムージング学習および空間情報の時間的連続性が我々の生体の認識機構、特にその学習において大きな役割を果たしているのではないかと可能性をわずかながらも示すことができたのではないかと考える。