

第4章 時間軸スムージング学習に基づく 局所センサ信号の統合

4.1 背景

画像理解の分野において、画像情報の空間的な滑らかさという拘束を設けることによって、不良設定問題の正則化が行われている。また、我々生物の視覚システムにも、フィリングインという機能があると言われている。これは、情報が得られない空間的な部分が存在した場合、そのまわりの情報からその部分を補間する働きであり、例えば、網膜上の盲点は通常画像の情報を得ることができないが、我々がこれを自覚しないのはフィリングインの機能によるものであると言われている。この機能は、まさに我々の存在する外界が持つ普遍的な特徴、空間的な拡がりを持つ情報は、「空間的に滑らかに変化している部分が多い」ということを利用したものであるとすることができる。

一方、第2章で述べたように、我々の住んでいる外界から得られる様々な情報は、空間的に滑らかに変化している場合が多いだけでなく、力学系であり、時間と共に連続的に、そして滑らかに変化している場合が多い(空間情報の時間的滑らか仮説)。このことは、一見、極当然のこととして軽視されがちであるが、これは我々の空間認識において非常に大きな情報であることは確かであり、学習において大いに利用できるものと考えられる。

また、これも第2章でも述べたが、我々生物の持つセンサの多くは空間的に局所的な受容野を持ったセンサ細胞をたくさん並べることによって空間情報を獲得している。例えば、目という視覚センサは、たくさんの網膜細胞から構成されているが、個々の細胞は、空間的に局所的な受容野しか持っていない。にもかかわらず、我々の意識の中では、個々の細胞の発火を意識することなく、物体の位置などの空間情報を連続的なものとして知覚することができる。また、1.4節で述べたように、空間的な情報を用いて学習を行うことを考えた場合、微分の情報が重要な役割を果たすことから、空間の情報を連続値として表現することは非常に重要であると筆者は考える。これらのことから、我々の脳の中では、多数のセンサからの信号を統合し、連続的な空間情報を出力するニューロンが存在する可能性が考えられる。

4.2 空間情報の時間的滑らか仮説と空間情報の抽出

前節で述べたように、空間情報は滑らかにしか変化しないように見える。動いている物体は、慣性の法則に従い、突然消えたり、突然現れたり、原因もなく動いている方向が突然変化することはない。だからこそ、我々は物体の動きを予測し、それに基づいて適切な動作を行うことができる。

ここで、図4.1のように、動く物体と視覚センサおよび階層型のニューラルネットから構成されるシステムを考える。視覚センサは、複数の網膜細胞（センサセル）よりなり、各細胞は、受容野の内、投射された物体が占める面積の割合を出力するものと仮定する。そして、その出力を階層型ニューラルネットへの入力とし、ニューラルネットの中の層間のニューロン同士は区別なく全結合させる。従って、ニューラルネットの側から各センサの信号の空間的な位置関係の情報を得ることはできない。




図4.1 時間軸スムージング学習を用いて空間情報を抽出するシステムの構成

この時、物体が視野内を滑らかに動いている、ここでは左右に単振動をしていると仮定すると、投射された物体の位置も徐々に動き、各網膜細胞の出力の時間変化は図4.2(a)のようになる。各網膜細胞は局所的な受容野しか持っていないため、それぞれ矩形波状の発火パターンとなる。この時、ある信号の後にある信号が発火すれば、その2つの信号の源である網膜細胞は隣同士である可能性が高い。従って、我々は図4.2(a)の発火パターンだけ見れば、網膜細胞1、2、3、4がその順番で並んでいることがわかる。

ニューラルネットが内部状態を保持しないと仮定すると、その出力は網膜細胞の出力だけの関数となっており、かつここで変化している空間情報は物体の位置だけである。従って、ニューラルネットの出力が時間と共に滑らかに変化していれば、このニューラルネットの出力は物体の位置を抽出したことになる。そこで、ニューラルネットの出力が時間に対して滑らかに変化するように、つまり時間の2階微分値を減少させるように学習を行う。すると、出力は時間の経過と共に図4.2(b)のように変化するようになる。これを物体の位置と出力の関係に置き換えると、図4.2(c)のように両者の間に1対1の対応がとれて、物体の位置の情報が抽出できることが期待される。

また、物体が前後に動いている場合は、物体が遠くにある時は網膜上では小さく、近い時には大きく映るため、図4.3のように各網膜細胞の出力が変化することが考えられるが、この場合も左右に単身どうさせた場合と同様な学習を行うことにより、図4.2(b)および図4.2(c)のような出力を得ることができると考えられる。

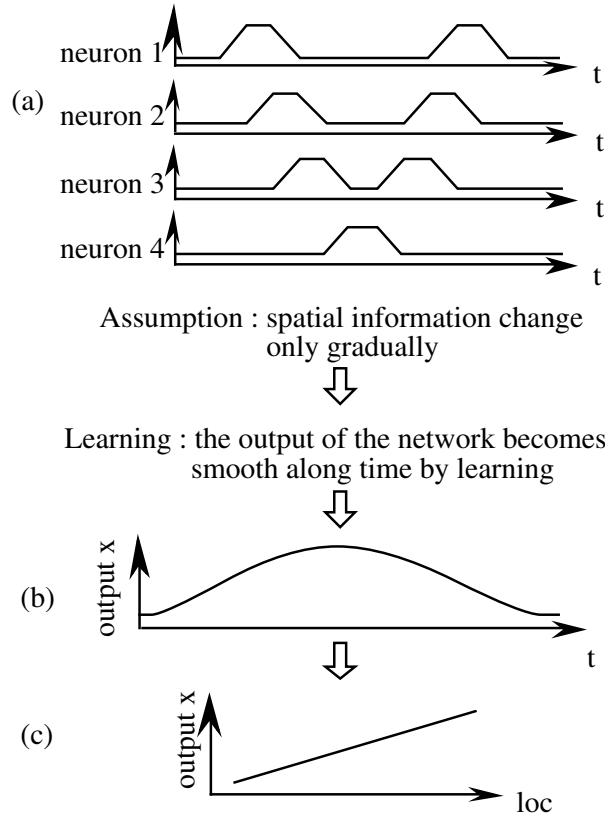


図 4.2 時間軸スムージング学習による局所センサ信号の統合の原理




図 4.3 物体が前後に動作している場合の網膜ニューロンの出力の変化

ここで、「出力を時間的に滑らかにする」ことが空間情報を抽出することにつながる様子をもう少し厳密に考えてみる。ニューラルネットの出力を x とすると、 x の時間軸方向の滑らかさは $\frac{d^2x}{dt^2}$ であらわすことができる。この時、空間情報の内、物体の位置 loc だけが変化しているとする、

$$\frac{dx(t)}{dt} = \frac{dx(t)}{d loc(t)} \frac{d loc(t)}{dt} \quad (4.1)$$

$$\begin{aligned} \frac{d^2x(t)}{dt^2} &= \frac{d^2x(t)}{d \text{loc}(t)^2} \left(\frac{d \text{loc}(t)}{dt} \right)^2 + \frac{dx(t)}{d \text{loc}(t)} \frac{d^2 \text{loc}(t)}{dt^2} \\ &= \frac{d^2x(t)}{d \text{loc}(t)^2} v(t)^2 + \frac{dx(t)}{d \text{loc}(t)} a(t) \end{aligned} \quad (4.2)$$

$v(t)$:物体の速度、 $a(t)$:物体の加速度

と変形することができる。式(4.2)の右辺第1項は、速度の自乗 $v(t)^2$ を係数として $\frac{d^2x}{d \text{loc}^2}$ 、つまり、物体の位置 loc に対する x の曲線の凹凸を表している。一方、第2項は加速度の大きさ a を係数として $\frac{dx}{d \text{loc}}$ 、つまり、物体の位置 loc に対する出力 x の傾きの大きさを表している。従って、 $\frac{d^2x}{dt^2}$ を0に近づける学習を行うということは、物体の速度が大きい場合は、物体の位置 loc に対する出力 x の凹凸を減少させ、加速度が大きい場合には物体の位置 loc に対する出力 x の傾きの絶対値を0に近づけようとするのがわかる。従って、前述のように、物体が視野内を単振動しているとすると、振動中心あたりでは速度が大きく加速度が小さくなるため、 loc に対する x の凹凸を減少させるという学習が進み、端の方では、速度が小さくなって加速度が大きくなるため、 loc に対する x の曲線はフラットになるように学習が進むことになる。そして、この曲線に凹凸がなくなれば、1対1の対応がとれるようになり、ニューラルネットの出力として物体の位置が抽出できることになる。

4.3 学習アルゴリズム

前節の原理より、ニューラルネットは、出力の時間変化の凹凸を減少させるために、

$$E(t) = \frac{\kappa}{2} \left(\frac{d^2x(t)}{dt^2} \right)^2 \quad (4.3)$$

κ : スムージング定数

を誤差信号として学習を行う。つまり、教師信号 $s(t)$ を

$$s(t) = x(t) + \kappa \frac{d^2x(t)}{dt^2} \quad (4.4)$$

としてバックプロパゲーション(BP)法[Rumelhart 86]によって学習を行う。ただし、教師信号は内部生成するため、全システムから見れば外部からの教師信号は必要ない。この学習を時間軸スムージング学習と呼ぶ。また、本論文では、スムージング定数 κ は0.5とした。そして、式(4.4)

を差分近似すると、

$$s(t-1) = \frac{x(t) + x(t-2)}{2} \quad (4.5)$$

という式に変換され、これを実際の学習に用いた。つまり、過去2回分のニューラルネットへの入力値を保持しておき、2単位時間前の入力をニューラルネットへ再入力してでてきた出力と現在の出力の平均値を求め、それを教師信号として1単位時間前の入力に対して学習を行った。ただし、ここでの学習も、同じデータで収束するまで何回も繰り返し学習を行わず、1単位時間あたり与えた教師信号で1回だけ学習した。

しかし、この学習を行うだけでは、出力 $x(t)$ は

$$x(t) = \text{const.} \quad (4.6)$$

となり、情報を抽出できないことになってしまう。そこで、出力の値域を確保するために、過去の出力値の平均 $\overline{x(t)}$ を

$$\tau \frac{d\overline{x(t)}}{dt} = -\overline{x(t)} + x(t) \quad (4.7)$$

τ : 時定数

の時定数 τ を大きくすることにより求め、現在の出力値 $x(t)$ との偏差が非常に大きい場合にのみ、さらにその偏差を大きくするという値域拡大学習を時間軸スムージング学習の代わりに行う。

以下、初期状態からスタートして初めて値域拡大学習が適用された時の実際のデータを図4.4に示しながら、その学習の様子を示す。まず、図4.4(a)に出力値 $x(t)$ およびその平均 E の変化の様子を示す。時定数 τ が大きいため(本論文中では100に設定)、 $x(t)$ の値は変動するものの、平均値 $\overline{x(t)}$ の値はあまり変化しない。

偏差が大きいかどうかの判定は、ここでは、試行錯誤の結果、4次の偏差を用いた。4次の偏差 $dx(t)$ は、

$$dx(t) = (x(t) - \overline{x(t)})^4 \quad (4.8)$$

として求め、さらに、その時間平均 $\overline{dx(t)}$ を次式のように求め、

$$\tau \frac{d\overline{dx(t)}}{dt} = -\overline{dx(t)} + dx(t) \quad (4.9)$$

これによって正規化した $d\tilde{x}(t)$

$$d\tilde{x}(t) = \frac{dx(t)}{\overline{dx(t)}} \quad (4.10)$$

を計算する。 $dx(t)$ および $\overline{dx(t)}$ を図 4.4 (b) に示す。このグラフは縦軸を log スケールで描いてある。4 次の偏差をとっているため、 $dx(t)$ は大きく変化しているが、時定数 τ が大きい (本文中では式 (4.7) と同様 100 に設定)、 $\overline{dx(t)}$ はあまり変化しない。 $d\tilde{x}(t)$ を図 4.4 (c) に示す。4 次の偏差を用いたことによって、偏差が大きいところだけがさらに強調されることになり、20 単位時間のところだけが大きな値となっていることがわかる。

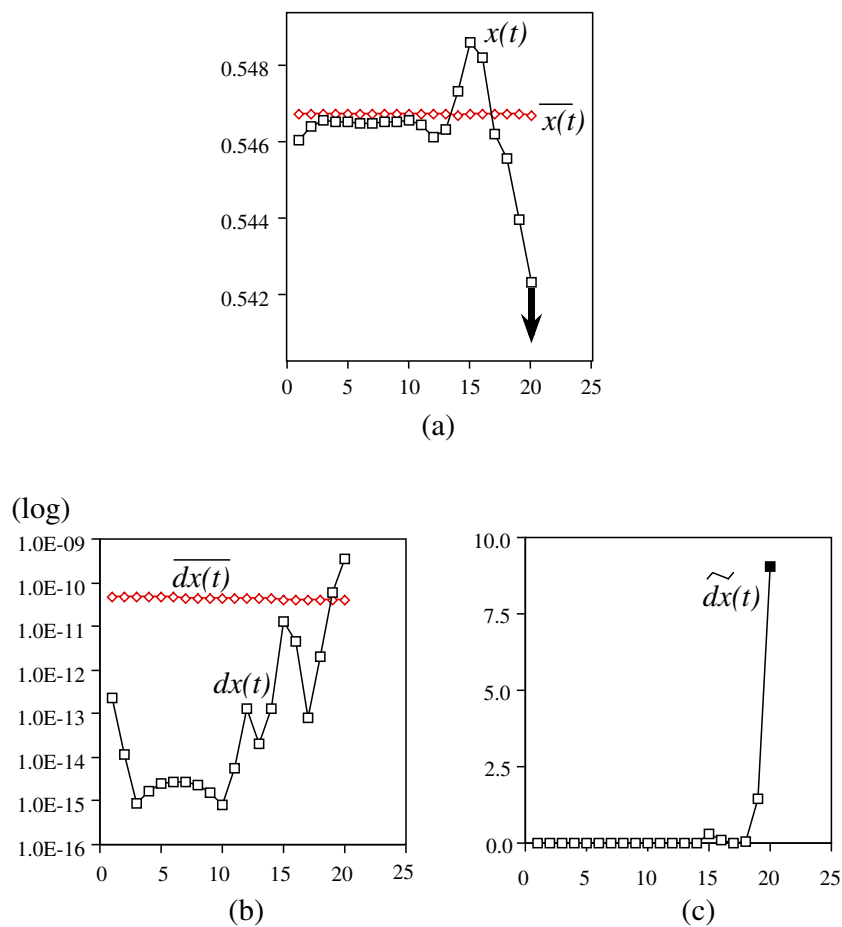


図 4.4 各信号の変化の様子

そして、一様乱数 rnd を用いた

$$d\tilde{x}(t) > \xi * rnd * (1 - \overline{x(t)})^2 \quad \text{if } x(t) \leq \overline{x(t)} \quad (4.11)$$

$$d\tilde{x}(t) > \xi * rnd * \overline{x(t)}^2 \quad \text{if } x(t) > \overline{x(t)} \quad (4.12)$$

ξ : 選択確率の調節用定数

という不等式によって値域拡大学習を適用するか否かを確率的に決定し、不等式が成り立った場合に

$$s(t) = 0.1 \quad \text{if } x(t) \leq \overline{x(t)} \quad (4.13)$$

$$= 0.9 \quad \text{if } x(t) > \overline{x(t)} \quad (4.14)$$

という教師信号で学習を行った。ただし、ここでは、出力関数をシグモイド関数とし、値域は0から1の連続値とし、不等式(4.11)、(4.12)で用いた定数 ξ は、試行錯誤の結果1000とした。図4.4で示した場合では、20単位時間のところで $d\tilde{x}(t)$ の値が大きいため、不等式(4.11)が成り立ち、式(4.13)の値域拡大学習が適用された。不等式(4.11)の $(1-\overline{x(t)})^2$ や不等式(4.12)の $\overline{x(t)}^2$ は、出力値が0や1に偏ることを防ぎ、0から1の間に均等に値をとるように加えた。例えば、出力値の時間平均が1に近い場合は不等式(4.11)で選ばれる確率が高くなり、この時式(4.13)のように教師信号を0.1とすることで、出力全体を小さくすることができる。また、値域拡大学習が適用されると、(特に学習初期においては値域が十分に確保されていないため)出力の値が大きくなり変化する。すると、過去の平均出力値 $\overline{x(t)}$ からの偏差が非常に大きくなり、(4.11)、(4.12)の不等式が成り立つ。これを防ぐために、値域拡大学習が適用された際に、 $d\tilde{x}(t)$ の値を大きな値(ここでは 10^4 とした)にセットし直した。これによって、以下に述べるシミュレーションでは、平均して、ほぼ1000単位時間強に1回の割合で値域拡大学習が適用された。

図4.5に時間の経過に対し、教師信号がどのように与えられるかを模式的に示す。また、図4.6にこの学習のフローチャートを示す。学習は、毎単位時間毎に行われ、不等式(4.11)または(4.12)を満たした時は値域拡大学習、その他の時は時間軸スムージング学習を適用する。ただし、前述のように、BP法による学習は、与えた教師信号に基づいて1単位時間あたり1回だけ学習する。




図4.5 教師信号の模式図

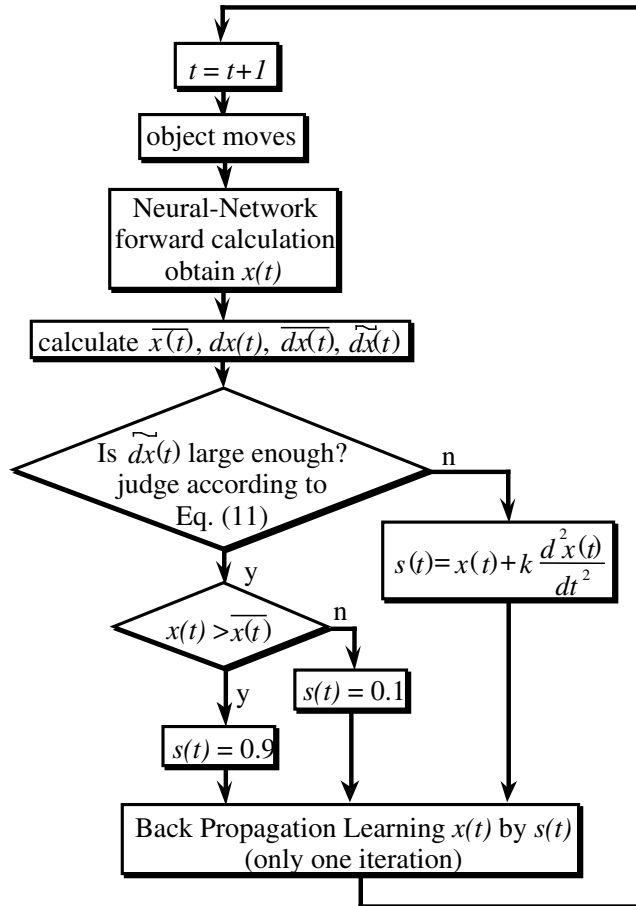


図4.6 学習のフロー

4.4 シミュレーション

4.4.1 物体が左右に動作している場合

ここでは、前述の多数の視覚センサの出力から物体の位置の情報が抽出できるかどうかをシミュレーションによって検証した。シミュレーションは図4.1のような環境で行った。そして、(a) 網膜細胞の数、(b) 物体の動き方、(c) 物体の動作範囲の3つを変化させた。行ったシミュレーションの組み合わせを表3.1に示す。

始めに、表4.1の(1)(2)(3)のように、物体の動き方を単振動、動作範囲をちょうど視野と一致させた場合について、網膜細胞の数を10、20、30個と変化させて学習を行った。その他のパラメータを、表4.2に示す。ニューラルネットの階層は3層とし、中間層のニューロンは30個とした。そして、重み値の初期値は-0.1から0.1の間から乱数によって決定した。また、物体は、93.1単位時間で1周期の運動をするものとした。

表4.1 行ったシミュレーションの条件

	(1) Number of retinal neuron	(2) Way to move	(3) Motion range of the object
(a)	10	simple oscillation	in the visual field
(b)	20	simple oscillation	in the visual field
(c)	30	simple oscillation	in the visual field
(d)	20	constant speed	disappear
(e)	20	random acceleration	in the visual field

表4.2 シミュレーションで用いたパラメータ

Object motion	simple oscillation
Motion range	just in the visual field
Structure of network	Layered
Learning algorithm	Back Propagation
Number of layers	3
Number of hidden neurons	30
Learning rate	0.1 (usually) 1.0 (only when applying expanding operation)
The initial weight value	from -0.1 to 0.1
Oscillating period	93.1 time steps
Time constant τ	100 time steps
Smoothing constant k	0.5
Width of 1 visual cell	1
Number of retinal neurons	30
Size of the object	2.5

学習の結果を図4.7以降に示す。図4.7はシミュレーション(3)、つまり、網膜細胞の数が30個の場合の学習の様子を示したものである。それぞれのグラフは、物体の位置 *loc* に対するニューラルネットの出力をプロットしたものである。学習前は、出力の曲線はほぼフラットであるが、微小な乱数によって決められた重み値によって多少の凹凸がある。図4.7の(a)は、初期の微小な凹凸を示すために、他のグラフと比較して縦軸を100倍拡大して描いてある。学習が進むと、値域拡大学習によって偏差が特に大きいところだけさらに偏差を拡大する学習が行われるため、図4.7(b)のように、曲線上に山と谷が一つづつできる。この時図4.7の(a)と比較すると、初期状態において山と谷であったところが拡大されていることがわかる。ただし、初期状態で最大値をとっているところは、その近くに最小値をとるところがあるため、それに引きずられ、結果的に2番目に大きい値をとっていたところが山となっていることがわかる。さらに学習が進むと、図4.7の(c)のように、さらに値域が拡大し、曲線全体が滑らかになってくる。そして、さらに進むと、山と谷の部分が視野の端の方へ移動して、物体の位置と出力が1対1の対応がとれるようになっている。これは、前

述のように、視野の端の方では物体の速度が0に近づくため、曲線をより平らにしようとする学習が働くためと考えられる。網膜細胞の数を変えたシミュレーション(1)および(2)もほとんど同じような経緯をたどり、最終的に、物体の位置と出力は1対1の対応がとれるようになった。ただし、最終的に得られる曲線が右上がりになるか左上がりになるかは、初期値によって変化する。

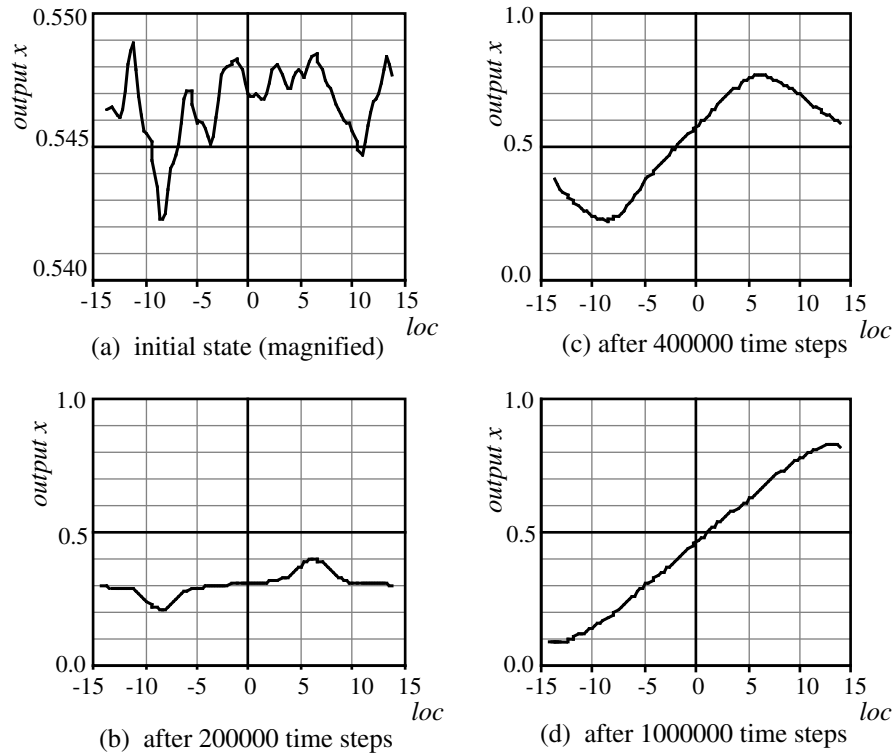


図4.7 学習の進行による出力の変化(網膜細胞30個)

次に、物体の動作が単振動ではなく、一定速度で動作をし、視野からはみ出す場合についてシミュレーションを行った(表4.1の(4))。この時の結果を図4.8に示す。この場合、物体が視野から消えた場合は、網膜細胞のすべての出力、つまり、ニューラルネットへのすべての入力となる。ところが、ここでは、ニューラルネットは記憶を持たず、出力は入力に対して一意に決定されるため、物体が視野の右端から見えようが、左端から見えようが、ニューラルネットへの入力と同じになるので出力も同じ値になる。また、出力を時間に対して滑らかにするという学習を行うことから、物体が視野の右端および左端に見える時は、物体が見えない時と近い出力値となる。従って、物体の位置に対する出力の曲線は、図4.8のように、ちょうど1周期のサインカーブに近い形となり、1対1の対応関係を得ることができない。

次に、物体が単振動ではなく、乱数によって決定された加速度によって動作をする場合(表4.1の(5))のシミュレーションを行った。ここでは、物体が視野の端に到達した時には、逆向きの小さな速度で戻るといった設定とした。この場合、学習後の物体の位置に対する出力は、図4.9のように、前のシミュレーションのようにきれいな曲線にはならず、1対1の対応もとれなかった。これ

は、加速度が乱数で決定されているため、式(4.2)の第2項の影響により、加速度の絶対値が大きい場合にスムージング学習によって傾きを0に近づけようという力が学習によって働いてしまうためと考えられる。このことから、本学習は加速度が小さい運動、つまり滑らかな運動について有効であると言える。

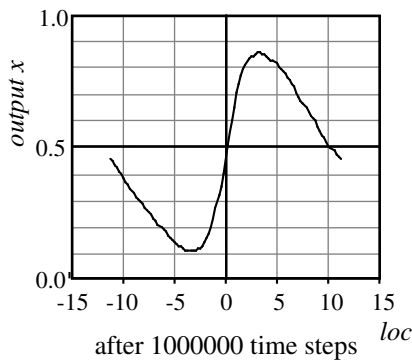


図 4.8 物体が視野から消える場合の出力の様子




図 4.9 物体が乱数で決定された加速度で動作する場合

4.4.2 出力の分布に関するシミュレーション

ここでは、入力データによって出力の分布がどのように変化するかを物体が前後に単振動する場合と、物体の大きさ自体が単振動で変化する場合を比較した。まず始めに、図4.3のように、物体が前後に動く場合にも同様の学習を行うことによってその情報が抽出できるかどうかをシミュレーションによって調べた。物体は前後に単振動するものとし、視野からははみ出ないものとする。図4.10に、学習後の物体の位置 loc および網膜上に映った物体の大きさ $size$ 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示す。この場合も、物体の位置と出力は1対1の対応関係がとれていることがわかる。

次に、物体の位置に対する出力と網膜上の物体の大きさに対する出力を比較してみる。ここでは、物体の位置と網膜上の物体の大きさは反比例をしており、物体との距離が1の時に、網膜上の物体の大きさは4、2の時に2、4の時に1となる。従って、物体の位置が遠くなるほど物体の位置 d の変化に対する網膜上の物体の大きさ $size$ の変化、つまり、 $\frac{d \text{ size}}{d \text{ loc}}$ の値が小さくなる。にもかかわらず、物体の位置が振動中心の2.5付近で出力値が0.5に近い値であるのに対し、網膜上の物体の大きさが2.5付近では出力値は0.5よりかなり小さくなっていることがわかる。

比較のために、網膜上の物体の大きさ自身を単振動させて学習させた場合の物体の大きさに対する出力値を 図4.11に示す。この場合は、物体の大きさの振動中心である2.5付近で出力がほぼ0.5になっていることがわかる。これらから、時間軸に対して出力を滑らかに変化するように学習することによって、出力値の確率密度を均等化する働きがあることがわかる。ただし、

図4.10をよく見ると、物体の位置が4付近で出力値がフラットな領域が広がっている。これは、2章で述べたように、振動の折り返し付近では出力値がフラットになるように学習が進む。すると、この時、物体の境界にある網膜細胞の出力は、ニューラルネットの出力に対し影響を及ぼさないように学習される。ところが、前述のように、物体が遠くにある時は、物体の位置が変化しても、網膜上に映った物体の大きさはほとんど変化をしない。よって、このシステムでは、物体が遠くにある場合、物体の位置が変化してもそれを検出できない状態となる。これは、網膜細胞の数を増大させれば避けることは可能であると考えられる。

さらに、物体が左右に単振動する場合の結果と比較すると、いずれの場合も学習が速く進んでいることがわかる。これは、この場合、各網膜細胞の出力の和という簡単な形で物体の位置が抽出できるため、学習が容易であったことが原因と考えられる。




図4.10 物体が前後に動く場合




図4.11 物体の大きさが変化する場合

4.5 考察および今後の課題

物体が視野の中を1次元の単振動運動をしている場合、提案した教師なし学習によってその位置を抽出することができた。しかし、実際に我々の住んでいる世界では、多くの物体は動かず、また動いても一方向に進んでいくものが多い。そのような意味で、物体が一定速度で視野を通り過ぎるという設定のシミュレーション(4)が最も現実に近いと考えられる。しかし、この場合、物体の位置と出力の間に1対1の対応付けをさせることはできなかった。我々人間の場合を振り返って考えてみると、視野の右端から物体が消えれば、過去の履歴を元にして、視野よりも右の方に物体があるということを脳内に内部表現として獲得し、これに基づいて学習できると考えられる。従って、リカレントニューラルネットを用いて学習を行うことにより、そのような内部表現を形成することのできるのではないかと考えている。ただ、右から消えたものはいつまでも視野の右側にあるとは限らない。従って、時間の経過と共に情報の確信度が減少し、新たな情報を獲得するようにならなければならない。

ばならない。

また、本シミュレーションにおいては、視野内の単振動という設定以外にも、動いている物体が1つであるとか、物体が1次元の運動しかしない等、まだまだ人工的な設定が多い。複数次元の運動を分離することに関しては、前章の相関情報抽出学習と一緒に用いた複数出力の直交化学習と同様な方法によって可能ではないかと考える。また、複数の物体が存在する場合については、注意の機構を導入し、注目すべき物体を切り出す等の対処が必要であると考えられる。これらも含めて、より現実的な環境に適応できるような学習アルゴリズムを考案することが今後の大きな課題である。

さらに、本学習では、うまく学習させるためのパラメータの設定が難しい。特に、値域拡大学習を適用するかどうかを決定する(4.11)、(4.12)式の ξ は、小さ過ぎると物体の位置と出力の間に1対1の関係が得られず山や谷がいくつかできてしまい、大き過ぎると値域拡大学習が適用される回数が減り、学習が遅くなると考えられる。また、 ξ の大きさは物体の運動とも大きくかわる問題であり、物体の運動の振動数が大きければ ξ は小さい方が良く、大きいと学習の速度が遅くなる。また、振動数が小さければ、 ξ は大きくなければ情報を抽出できない。逆に考えると、複数の運動を ξ を調節することで分離するといった可能性も考えられる。また、値域拡大学習の適用を決定する不等式で4次の偏差を用いることも、出力曲線上の余計な凹凸に値域拡大学習を適用しないで、1対1の対応関係を得られやすくするための苦心の策で、4次ということに特に必然性はない。これらをより洗練させていくことは、本学習の妥当性を言う上で必須であると考えられる。

しかし、空間情報は時間的に滑らかにしか変化しないという仮説を利用した学習は不変的、汎用的であり、我々生体が利用している可能性は非常に高いと考えられる。本章の初めにも述べたように、空間的に滑らかであるという拘束については、既に、画像理解の際に、不良設定問題の正則化の際に用いられ、有効であることが示されている[Poggio 85][横矢 91]。空間情報が時間的にも滑らかに変化するという拘束も、さらに研究を進める必要があると考えられる。

しかし、そもそも空間情報の時間的滑らか仮説が理にかなっているのかという議論も考えられる。例えば、動いている物体が壁の後ろに隠れてしまった時、見た目には不連続に変化しているように見える。しかし、この時、物体が連続的に動いていると考えることによって、壁の反対側の端から物体が出てくるのが予測できるのである。また、物体が壁に当たって跳ね返るように、空間情報の変化が滑らかでないように見える場合には、これを連続的な状態の変化として捉えることにより、因果関係の把握につながると考えることができる。そして、逆にもし物体が壁をすり抜けたとすると、通常の連続的な状態変化が起こらないことで違和感を感じるのではあると考えられる。

また、本論文では、多数のセンサ信号を統合し、空間情報をアナログ情報として出力することを学習させている。1.4.1で述べたように、アナログ化された情報は微分情報をとることが容易であり、学習という側面で非常に有効であると考えられる。また、強化学習を行う際に、遅れて得られる強化信号から各状態の評価を学習する際に、本論文で提案したスムージング学習を応用できることも確認されている。従って、本論文で行ったセンサ信号の統合と強化学習を融合させ、より柔軟で知的なシステムの構成が可能であると考えられる。ただ、時間軸スムージング学習を用いて強化学習を行うだけでもある程度センサ信号の統合ができることがわかってきている。そこから考えると、センサ側で時間軸スムージング学習を適用するということは、強化学習を加速させるという効果が考えられる。また、時間軸スムージング学習は適用するものの、値域の確保については強化学習におけ

る学習信号をここまで伝搬させることによって行う方法も考えられる。

ただし、現在の所、生体内で空間情報をアナログコーディングしたようなニューロンが見つかったという報告はない。ただ、図4.12の(a)のように、1ニューロンによるアナログコーディングの代わりに、(b)のように複数のニューロンでファジーのメンバーシップ関数のような形でコーディングしている可能性は高い。このような場合でも、本論文で提案した空間情報の時間的滑らかさを利用した学習を行うことが可能であると考えられる。いずれにせよ、データの表現方法等、生理学等の分野とのすりあわせをしていく必要があると考える。

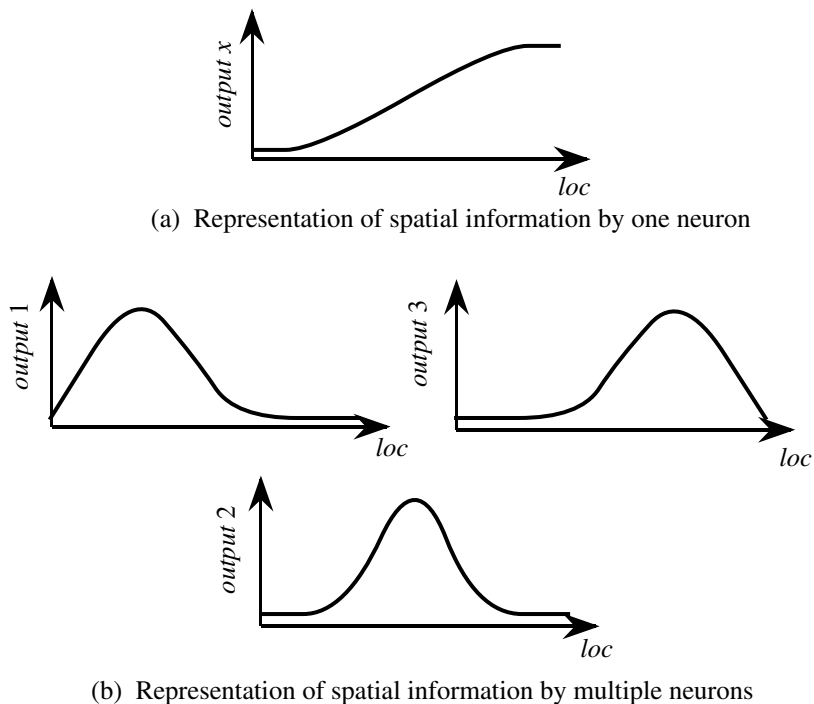


図4.12 物体の位置の表現方法

4.6 まとめ

空間情報が時間的滑らかであるという仮説が多数の局所的な受容野を持つセンサ信号を統合する際に有効であることを示した。そして、階層型ニューラルネットの出力を時間的に滑らかにするという時間軸スムージング学習を行うことによってセンサ信号を統合し、空間情報をアナログ値として抽出できることを示した。さらに、シミュレーションによって、物体が視野内を左右におよび前後に一次元の単振動運動をしている場合について、ニューラルネットの出力が物体の位置に対して滑らかに、かつ1対1の関係が成り立つように学習することができた。しかし、物体が視野から消えてしまう場合や物体の加速度を乱数で決定させた場合は、物体の位置と出力の間に1対1の関係を実現することはできなかった。

それから、本学習も前章の学習と同様に値域拡大学習によって出力値の値域を拡大させるという学習はさせるものの、中間的な値に対する明示的な規定はない。そこで、学習後のデータの分布を調べたところ、入力データの時間変化に依存し、入力データが時間によってあまり変化しない部分では出力の解像度が上がり、入力データが大きく変化するところでは出力の解像度が下がることがわかった。