

# 画像移動ベクトル検出の ニューラルネットによる一検討

## An Investigation of Detecting Motion Vectors on Images by Neural Network

巽 久行\*・関 靖夫\*・石井 博章\*

Hisayuki TATSUMI, Yasuo SEKI and Hiroaki ISHII

### Abstract

The optical flow, which is the velocity of image points, will be used for 3-D motion analysis and 3-D structure recovery. In this paper, the optical flow detection is investigated on the neural network from the viewpoints of parallel processing and learning. First, the fundamental operators of computation are constructed as some hierarchical subnets, and their learnings by error back propagation are examined. Second, the subnets for corner point detection, and optical flow detection itself are constituted. The performance of the network is examined for simple object motions.

### 1. ま え が き

画像上の速度場であるオプティカルフローは、3次元構造の復元や3次元運動の解析に使用される。本報告は、並列処理の観点から、ニューラルネットワークでの画像処理とその学習を、オプティカルフローの検出を例に検討している。最初に、計算の基本機能（最大・最小、絶対値、論理演算、算術演算、大小比較等）を多値階層型部分ネットワークで構成し、その結合パラメータの学習を誤差逆伝播アルゴリズムにより正しく行なわれることを示した。次にオプティカルフロー検出に必要なコーナー検出ネットワーク、及びそれに対するオプティカルフロー検出ネットワークを構成し、簡単な物体移動でオプティカルフロー検出の動作を確認した。

### 2. 計算の基本機能

画像処理を多値ニューラルネットワークで構成するために、最初に必要な基本演算をすべてニューラルネットワークで構成しうるかを調べた。各ネットワークは階層的なフィードフォワード型、学習則は誤差逆伝播法を用いた。

$m$ 層のニューラルネットワークにおいて、第 $k$ 層の第 $j$ ユニットへの入力の総和を $i_j^k$ 、出力を $o_j^k$ とし、このユニットの入出力関数を $f_j^k$ とする。また、第 $k-1$ 層の第 $i$ ユニットから第 $k$ 層の第 $j$ ユニットへの結合の重みを $w_{ij}^{k-1,k}$ とすると、

$$o_j^k = f_j^k(i_j^k) \\ i_j^k = \sum_i w_{ij}^{k-1,k} \cdot o_i^{k-1}$$

であり、誤差逆伝播法による結合の重みの修正量 $\Delta w_{ij}^{k-1,k}$ として、次式を用いた<sup>1)</sup>。

$$\Delta w_{ij}^{k-1,k}(t+1) = -\varepsilon \cdot d_j^k \cdot o_i^{k-1} + \alpha \cdot \Delta w_{ij}^{k-1,k}(t) \quad (1)$$

ここで、 $\varepsilon$ は1回の修正の大きさを決めるパラメータ、 $d_j^k$ は結合 $w_{ij}^{k-1,k}$ の修正に使う学習信号、 $\alpha$ は正の

定数,  $t$  は修正の回数を表す。本報告では, ユニットの  
入出力関数  $f^k$  として, 次の 6 種類の関数

- $u_1$ : 恒等関数  $\xi$ ,  $u_2$ : 2 乗関数  $\xi^2$ ,  
 $u_3$ : しきい関数  $u(\xi)$ ,  $u_4$ : 逆しきい関数  $1$   
 $u_5$ : 区分線形関数  $\max(\xi, 0) - u(\xi)$ ,  
 $u_6$ : 逆数関数  $r(\xi)(=1/\xi)$

を用いている。この 6 種類の関数をもとに, 作成した  
計算の基本機能をなす部分ネットは,

- 算術演算 {乗算 ( $MUL$ ), 除算 ( $DIV$ )},  
 論理演算 {積 ( $AND$ ), 和 ( $OR$ ), 否定 ( $NOT$ )},  
 最大 ( $MAX$ ), 最小 ( $MIN$ ), 絶対値 ( $ABS$ ),  
 大小比較 { $GE$ ,  $GT$ ,  $EQ$ ,  $NE$ }

である。例として, 図 1 に  $MUL$  の部分ネットを示す。  
同図において, 伝達線上に記された  $a \sim g$  は結合の重  
み  $w_{i,j}^{k-1,k}$  であり, 点線は同一層のユニットで共通の関  
数を表す。ここで,

$$MUL(x, y) = g(ax + by)^2 + e(cx)^2 + f(dy)^2 \\ = (a^2g + c^2e)x^2 + 2abgxy + (b^2g + d^2f)y^2$$

より,

$$a^2g + c^2e = 0, 2abg = 1, b^2g + d^2f = 0 \quad (2)$$

であれば,  $MUL$  が実現できる。式 (2) より, 結合の重  
みに多様性があることが分かる。実験として, 式 (1) の  
定数を  $\varepsilon = 1 \times 10^{-5}$ ,  $\alpha = 0.9$  として, 学習回数を 500 回  
行なったパラメータ  $b$  の学習の様子を図 2 に, 学習さ  
れたすべての結合の重みを表 1 に, それぞれ示す。

表 1 において,  $(a, b, c, d, e, f, g) = (1, 1, 1, 1, -0.5, -0.5, 0.5)$  は式 (2) の普通考える単純な値であ  
るが, 結果を見ると多少の誤差はあるものの, 学習は  
設定した初期値に依存して, 式 (2) を満たす適当な 1  
つの解にうまく収束し, 目的の基本機能が動作するこ  
とが確認できた。さらに実験の結果, 基本機能すべての  
学習に対して, ローカルミニマムの問題はほとんど




図 2.  $MUL$  の学習の様子

表 1. 学習された結合の重み  $w_{i,j}^{k-1,k}$

$(k-1, k)$					
$(1, 2)$			$(2, 3)$		
$i \backslash j$	1	2	$i \backslash j$	1	2
1	0.7 (c)	-0.3 (a)	1	0.3 (e)	-1.5 (g)
2	--	1.0 (b)	2	-1.5 (g)	1.2 (f)




図 3.  $MAX$  の部分ネット




図 1.  $MUL$  の部分ネット

無かった。

また, 図 3 に  $MAX$  の部分ネットを示す。同図にお  
いて, 2 重丸印のノードは既に作成された基本機能部  
分ネットを表す。これより  $n$  個の  $MAX$  が,  $n$  に依  
らないあまり大きくない一定の段数で構成できるこ  
とが分かる。




図4. 着目点近傍

### 3. オプティカルフロー検出ネットワーク

前節で作成した部分ネットを用いて、オプティカルフローの検出を行なうネットワークを構成する。

物体の角（コーナー点）は明確な弧立特徴点であり、オプティカルフローが安定に求められる。そこで、初期的な検出ネットワークとして、コーナー点検出に基づくネットワークを作成した。コーナー点検出では、まず着目点近傍として図4のような近傍相対座標  $(\Delta x_n(k_s), \Delta y_n(k_s))$  を設定する。ここで、 $k_s$  (但し、 $0 \leq s < 8$ ) は近傍通番で、 $k_0$  が着目点を示す。この着目点近傍を用いて、着目点の評価値  $g_m(i, j)$  を次式のごとく導入する。

$$g_m(i, j) = \sum_{s=1}^4 \text{Max} \{ |p(i + m\Delta x_n(k_s), j + m\Delta y_n(k_s)) - p(i, j)|, |p(i + m\Delta x_n(k_{s+4}), j + m\Delta y_n(k_{s+4})) - p(i, j)| \}$$


上式において、 $p(i, j)$  は点  $(i, j)$  の画素の明るさを、 $m$  (但し、 $0 \leq m \leq n$ ) は弧立点抑御のためのスキップ数でエッジの半幅程度を、 $\Delta x_n(k_s)$  および  $\Delta y_n(k_s)$  は近傍通番  $k_s$  の着目点に対する相対  $x$  座標および相対  $y$  座標を、それぞれ表す。また、式中の Max および絶対値は、前節の部分ネット MAX および ABS で構成される。この  $g_m(i, j)$  を用いれば、コーナー点の条件式は次のように記述される。

$$\exists k_s, k_t \ (1 \leq s, t \leq 4, s \neq t)$$

$$\begin{aligned} g_m(i, j) &\geq g_m(i + m\Delta x_n(k_s), j + m\Delta y_n(k_s)) \\ \wedge g_m(i, j) &\geq g_m(i + m\Delta x_n(k_{s+4}), j + m\Delta y_n(k_{s+4})) \\ \wedge \{ [g_m(i, j) - g_m(i + m\Delta x_n(k_s), j + m\Delta y_n(k_s))] \\ &\quad + [g_m(i, j) - g_m(i + m\Delta x_n(k_{s+4}), j + m\Delta y_n(k_{s+4}))] \} / 2 \geq g_{mth} \\ g_m(i, j) &\geq g_m(i + m\Delta x_n(k_t), j + m\Delta y_n(k_t)) \\ \wedge g_m(i, j) &\geq g_m(i + m\Delta x_n(k_{t+4}), j + m\Delta y_n(k_{t+4})) \\ \wedge \{ [g_m(i, j) - g_m(i + m\Delta x_n(k_t), j + m\Delta y_n(k_t))] \\ &\quad + [g_m(i, j) - g_m(i + m\Delta x_n(k_{t+4}), j + m\Delta y_n(k_{t+4}))] \} / 2 \geq g_{mth} \end{aligned}$$

但し、 $g_{mth}$  はしきい値とする。しきい値  $g_{mth}$  により、平らな部分との区別および画像の乱れや雑音等で明度に変化が起きた場合の、コーナー点の誤判断を防ぐ。上式で、コーナー点は少なくとも2方向で  $g_m(i, j)$  が極大となることを表している。コーナー点検出ネットワークを、図5に示す。

このように検出されたコーナー点に対するフロー検


 図5. コーナー点条件式のネットワーク {但し、 $\bar{g}_m(s) \equiv g_m(i + m\Delta x_n(k_s), j + m\Delta y_n(k_s))$ }




図 6. フロー検出ネットワーク

出を行なうネットワーク（前フローの着目コーナー点に対するもの）として、現フレームの画像平面上の着目点 P の位置を中心とした図 6 のような  $(2n+1) \times (2n+1)$  のウィンドウを、次フレームのコーナー点画像(2 値)上に設定し、フローの変化を検出する。但し、ウィンドウ中に現フレームのコーナー点は 1 個しかないと仮定した。図中、ウィンドウ内の各画素より右の 2 つのノードに各 1 個ずつ結合線が入っているが、図は 2 つの画素についての例を示している。

簡単な物体の運動を仮定して、以上の構造のネットワークでオプティカルフローの検出実験を行なったところ、コーナー点としてその移動ベクトルの抽出が正しく動作することが確認できた。

#### 4. あとがき

ニューラルネットを用いた画像処理を行なうために必要な計算の基本機能を実現する部分ネットを構成し、それをもとに初期的なオプティカルフロー検出のネットワークを作成した。各基本機能は最大 30 秒程度(パソコン上)で正しく学習し、簡単な物体を仮定したコーナー点の移動ベクトルを約 2 分程度で正しく検出した。エッジ点及び非エッジ点に対するニューラルネットの構成は、現在検討中である。

#### 参 考 文 献

- 1) 麻生: ニューラルネットワーク情報処理, 産業図書, (1988).
- 2) 渥美, 横澤, 安田: ニューラルネットによる動き検出, 信学会 1992 年秋季大会, D-23 (1992.9).
- 3) 山根, 大西, 杉江: エッジの群化によって移動物体の分離抽出を行なうニューラルネットワーク, 信学会 1993 春季大会, SD-2-2, (1993.3).