

6L-8

## ニューラルネットによる オプティカルフロー検出の検討

巽 久行, 関 靖夫, 石井 博章

神奈川工科大学 工学部 情報工学科

## 1. まえがき

画像上の見かけ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）を階層型部分ネットで構成し、そのパラメータの学習を誤差逆伝播アルゴリズムで検討した。次にオプティカルフロー検出に必要なコーナー点検出ネットを構成し、簡単な物体移動でオプティカルフローの検出を行なった。

## 2. 計算の基本機能

単純な素子でオプティカルフロー検出を行なうネットワークを構成するために、最初に検出計算の基本機能をなす部分ネットを作成した。各ネット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 $w_{i,j}^{k-1,k}$ とすると、

$$o_j^k = f_j^k(i_j^k) \quad i_j^k = \sum_i w_{i,j}^{k-1,k} o_i^{k-1}$$

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

$$\Delta w_{i,j}^{k-1,k}(t+1) = -\epsilon \cdot d_j^k \cdot o_i^{k-1} + \alpha \cdot \Delta w_{i,j}^{k-1,k}(t) \quad \dots(1)$$

ここで、 $\epsilon$ 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 $w_{i,j}^{k-1,k}$ 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 $f_j^k$ 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  $1-u(\xi)$ ,
- $u_5$  : 区分線形関数  $\max(\xi, 0)$ ,
- $u_6$  : 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}

Experiments of Optical Flow Detection by Neural Network

Hisayuki TATSUMI, Yasuo SEKI, Hiroaki ISHII,  
Kanagawa Institute of Technology

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、

$$\begin{aligned} MUL(x, y) &= g(ax + by)^2 + e(cx)^2 + f(dy)^2 \\ &= (a^2g + c^2e)x^2 + 2abgy + (b^2g + d^2f)y^2 \end{aligned}$$

より、 $a^2g + c^2e = 0$ ,  $2abg = 1$ ,  $b^2g + d^2f = 0$ , …(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 $\epsilon = 1 \times 10^{-5}$ ,  $\alpha = 0.9$ 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、 $(a, b, c, d, e, f, g) = (1, 1, 1, -0.5, -0.5, 0.5)$ 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無かった。

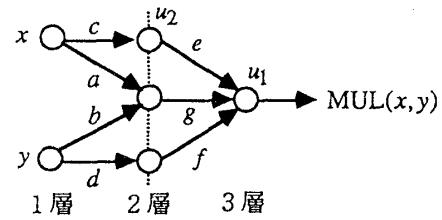


図1. MULの部分ネット

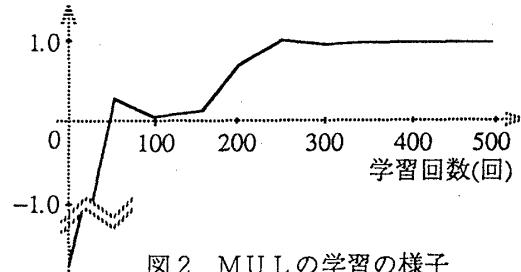


図2. MULの学習の様子

(k-1, k)			
(1, 2)			(2, 3)
<i>i</i>	1	2	3
<i>j</i>	0.7 (c)	-0.3 (a)	--
	1	0.3 (e)	2 -1.5 (g)
2	--	1.0 (b)	1.1 (d)
	3	1.2 (f)	

表1. 学習された結合の重み  $w_{i,j}^{k-1,k}$

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に依存しないあまり大きくなり一定の段数で構成できることが分かる。

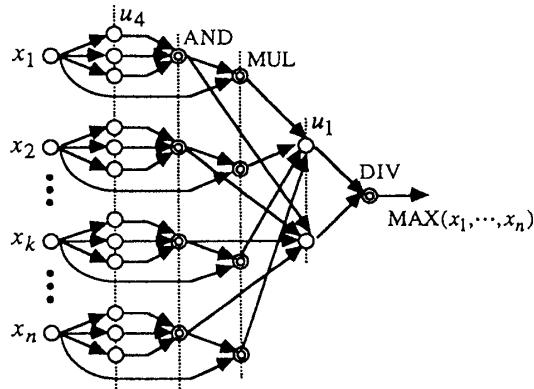


図3. MAXの部分ネット

### 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、オブ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）は明確な孤立特徴点であり、オブ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を設定する。ここで、 $k_i$ （但し、 $0 \leq i \leq 8$ ）は近傍番号で、 $k_0$ 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。

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

上式において、 $p(i, j)$ は点 $(i, j)$ の画素の明るさを、 $m$   
 (但し、 $0 \leq m \leq n$ )は孤立点抑制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。

### [コーナー点条件式]

$$\begin{aligned}
& \exists k_s, k_t \ (1 \leq s, t \leq 4, s \neq t) \\
& g_m(i, j) \geq g_m(i + m\Delta x_n(k_s), j + m\Delta y_n(k_s)) \\
& \wedge g_m(i, j) \geq g_m(i + m\Delta x_n(k_{s+4}), j + m\Delta y_n(k_{s+4})) \\
& \wedge [ \{g_m(i, j) - g_m(i + m\Delta x_n(k_s), j + m\Delta y_n(k_s))\} \\
& + \{g_m(i, j) - g_m(i + m\Delta x_n(k_{s+4}), j + m\Delta y_n(k_{s+4}))\} ] \\
& / 2 \geq g_{mth} \\
& g_m(i, j) \geq g_m(i + m\Delta x_n(k_t), j + m\Delta y_n(k_t)) \\
& \wedge g_m(i, j) \geq g_m(i + m\Delta x_n(k_{t+4}), j + m\Delta y_n(k_{t+4})) \\
& \wedge [ \{g_m(i, j) - g_m(i + m\Delta x_n(k_t), j + m\Delta y_n(k_t))\} \\
& + \{g_m(i, j) - g_m(i + m\Delta x_n(k_{t+4}), j + m\Delta y_n(k_{t+4}))\} ] \\
& / 2 \geq g_{mth}
\end{aligned}$$

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及び画像の乱れや雑音等で明度に変化が起きた場合の、コーナー一点の誤判断を防ぐ。上式で、コーナー一点は少なくとも2方向で $g_m(i,j)$ が極大となることを表している。

図4. 着目点近傍

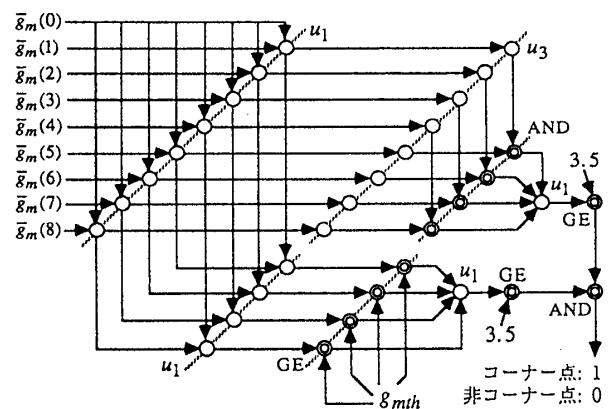


図5. コーナー点条件式のネットワーク

但し、 $\bar{g}_m(s) \equiv g_m(i + m\Delta x_n(k_s), j + m\Delta y_n(k_s))$

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 $(2n+1) \times (2n+1)$ のウインドウを、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。図中、ウイ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ブティカルフローの検出実験を行なったところ、コーナー点とその移動ベクトルの抽出が正しく動作することが確認された。

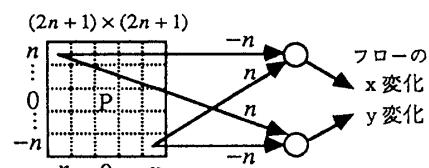


図6 フロー検出ウインドウ

#### 4. あとがき

ニューラルネットを用いた画像処理として、計算の基本機能を学習させた簡単な部分ネットをもとに、初期的なオブティカルフロー検出のネットワークを構成した。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)。