

論文2000-37CI-6-2

셀룰라 비선형 네트워크를 이용한 특징점 궤적 상에서 Optical Flow 검출

(Detection of Optical Flows on the Trajectories of
Feature Points Using the Cellular Nonlinear Neural
Networks)

孫弘樂*, 金炯奭**

(Hongrak Son and Hyongsuk Kim)

요약

거리 변환(Distance Transform)을 수행할 수 있는 셀룰라 비선형 네트워크 구조와 특징 점들의 궤적 상에서 거리 변환을 이용한 optical flow 검출 방법을 제안하였다. 움직이는 물체의 추적이나 카메라의 움직임 파악 같은 응용 분야에서는 수가 적더라도 정확하고 확실한 optical flow가 더 중요하다. 본 연구는 특징점들의 이동 궤적 상에서 거리 변환 기법을 이용하여 거리 변환 필드(Distance Transform Field)를 생성시키고 거리 변환 필드상에서 궤적의 움직인 거리 값과 방향을 추출함으로써 optical flow를 구하는 방법이다. 이 방법은 영상 정보를 거리 정보로 변환하여 사용하게 되므로 잡음의 영향을 적게 받으며 필요한 연산들이 아날로그 회로에 의해 처리되므로 처리 속도가 빠르고, 지역적 처리 특성을 갖기 때문에 하드웨어 구현이 용이하다는 특징이 있다. 또한, 본 연구에서는 제안한 알고리즘의 핵심부분을 하드웨어로 구현하기 위해 셀룰라 비선형 네트워크(Cellular Nonlinear Neural Network)구조를 제안하였다. 제안한 구조와 알고리즘을 검증하기 위해 다양한 영상과 환경에 대한 시뮬레이션을 수행하여 결과를 제시하였다.

Abstract

The Cellular Nonlinear Networks structure for Distance Transform(DT) and the robust optical flow detection algorithm based on the DT are proposed. For some applications of optical flows such as target tracking and camera ego-motion computation, correct optical flows at a few feature points are more useful than unreliable one at every pixel point. The proposed algorithm is for detecting the optical flows on the trajectories only of the feature points. The translation lengths and the directions of feature movements are detected on the trajectories of feature points on which Distance Transform Field is developed. The robustness caused from the use of the Distance Transform and the easiness of hardware implementation with local analog circuits are the properties of the proposed structure. To verify the performance of the proposed structure and the algorithm, simulation has been done about various images under different noisy environment.

* 正會員, 全北大學校 메카트로닉스 研究센터
(Mechatronics Research Center, Chonbuk National U.)
** 正會員, 全北大學校 電子情報工學部
(School of Information and Electronic Engineering,
Chonbuk National U.)

※ 이 논문은 2000년도 정보통신부의 대학기초 연구지원 사업 연구비 지원에 의해 연구되었습니다. 이에 감사드립니다.

接受日: 2000年5月19日, 수정완료일: 2000年8月25日

I. 서론

영상의 움직임은 물체의 이동 상태를 알 수 있게 할 뿐 아니라, 카메라의 움직임을 추정할 수 있기 때문에 동영상의 응용에서 매우 유용한 정보로 활용되어 얼굴의 표정을 인식하거나¹¹⁻³⁾ 3차원 정보를 알아내는 데 활용될 수 있다⁴⁻⁵⁾. 또 이 정보는 도로 상의 optical flow 변화를 이용하여 자동차를 자율 운행하는 데 이용할 수 있으며⁶⁻⁷⁾ 이동하는 사람이나 물체를 추적하는데도 활용될 수 있다⁸⁻¹⁰⁾.

동영상의 각 화소에서의 시간적 변화나 공간적 변화를 계산하면 화소의 이동속도 정보를 알 수 있는데 미분을 이용한 optical flow 계산이 그것이다¹¹⁻¹²⁾. 이 방법은 시간과 공간 축 상에서의 화소 값 변화에 대한 미분 계산을 이용하므로 잡음에 매우 민감하며 복잡한 무늬가 있는 경우나, 넓은 영역에 걸쳐 밝기 변화가 없는 경우 또는 움직이는 물체의 경계선 및 물체와 배경과의 거리 차가 있는 경우에는 오차를 유발한다¹³⁾. 보다 잡음에 강한 방법으로는 속도에 대한 필터들의 반응 강도나 필터 출력의 위상(phase) 등 주파수 공간상의 특성을 이용하는 방법이 있다¹⁴⁻¹⁵⁾. 이 방법들은 잡음이나 앨리어싱(aliasing)문제는 해결할 수 있지만 하드웨어 칩 회로가 복잡하고 특정 속도에만 반응하기 때문에 일반적인 문제 해결에는 미흡하다는 문제점이 있다¹⁶⁾.

움직이는 물체를 추적하거나 카메라의 움직임을 알기 위한 응용에서는 모든 화소의 optical flow가 필요하지 않으며 정확하고 확실한 optical flow가 더 중요하게 사용된다. 물체의 특징들의 움직임을 정합에 의해 파악함으로써 optical flow를 계산하는 방법이 이것이다. 이 알고리즘도 최적의 정합위치를 찾는데 많은 계산량이 요구되며 영상의 유사성이 있는 환경에서는 많은 정합 오류를 유발한다는 문제점이 있다¹⁷⁻¹⁸⁾. 영상의 이동 정보를 활용하는 데는 잡음에 강하고 달라진 환경에서도 동작하는 등의 정확성 외에도 optical flow의 응용 대상이 대부분 실시간 처리를 요구하기 때문에 하드웨어 구성도 중요한 요소이다. 이를 위하여 잡음에 강하고 보다 안정적 움직임 정보를 제공할 수 있는 주파수 기반 방법에 셀룰라 신경회로망(Cellular Neural Networks)의 병렬처리¹⁹⁾와 시간축상의 템플릿(template) 교환으로 프로그램 기능을 갖는 CNN-UM(CNN Universal Machine)을 이용하는 연구도 있었으나²⁰⁾, 중심

주파수가 다른 여러 개의 필터들을 화소 위치마다 장착해야 하며 다 단계의 스위칭 과정을 구현해야 하는 등 하드웨어 구조의 복잡성을 해결하지 못하였다.

제안한 알고리즘은 기존의 방법들과는 다른 방법으로 특징점들의 궤적 상에서 거리 변환을 수행하여, 생성된 거리 변환 필드(Distance Transform Field)를 이용하여 특징점들이 움직이는 궤적의 길이와 방향을 계산하여 optical flow 정보로 활용하는 방법이다.

본 연구에서는 거리 변환을 위한 셀룰라 비선형 네트워크(Cellular Nonlinear Neural Networks for Distance Transform)구조를 제안하였으며 이 구조를 기반으로 optical flow를 추출하기 위한 알고리즘을 제시하였다. 제안한 optical flow 추출 알고리즘의 특징은 실시간 처리를 위한 하드웨어 구성이 용이하며 잡음의 영향을 크게 받지 않는 것이다.

본 논문의 2절에서는 본 연구에서 사용한 거리 변환 기법을 설명하였으며, 3절과 4절에서는 거리 변환을 위한 셀룰라 비선형 네트워크 구조와 알고리즘을 소개하였다. 또한 5절에서는 제안한 알고리즘의 효과를 검증하기 위한 시뮬레이션이고 6절은 이에 대한 결론이다.

II. 거리 변환 기법

거리 변환 기법(Distance Transform 혹은 DT)²¹⁾은 각 화소 점에서 가장 가까운 물체까지의 최단 거리 값을 계산하는 알고리즘으로, 로봇의 장애물 회피 목적으로 많이 사용된다. 이 거리 변환에서는 그림 1과 같은 두 개의 비대칭 거리 테이블을 이용하여 전향과 후향의 연산을 수행함으로써 각 영상 점에서 가장 가까운 장애물까지의 거리를 계산한다. 그림 1의 거리 테이블에서의 각 숫자는 중심 위치(거리 테이블의 0인 위치)로부터 해당 인접 위치 점까지의 거리를 의미한다. 이 알고리즘에서는 거리 테이블을 영상의 모든 화소마다 순차적으로 이동하면서 중심점 위치에서의 가장 가까운 물체까지의 거리를 계산하는데, 거리 테이블의 중심 위치가 물체에 해당되지 않는 화소에 한하여 중심 위치로부터 각 인접 점까지의 거리테이블 값에 해당 인접 점으로부터 물체까지의 최단거리를 더한 것 중 최소 값을 취함으로써 계산한다. 즉, d_{kl} 를 전향 거리테이블의 (k,l) 위치의 거리 값이라고 하고, D'_{ij} 를 위치 (i,j) 로부터 물체까지의 최단 거리 값이라고 하면 D'_{ij} 는 다음과 같이 계산할 수 있다.

$$D_{ij}^f = \begin{cases} \min_{(k+i, l+j) \in R(i, j)} \{d_{kl}^f + D_{(i+k)(j+l)}^f\}, & \text{if } I(i, j) = 0 \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

여기서 min은 최소 값을 선택하는 함수이며, k 및 l은 {-1, 0, 1}중 하나이다. 또, R(i, j)는 전향 거리 테이블의 인접 셀의 위치이고 $D_{(i+k)(j+l)}^f$ 은 (i,j)의 인접 위치 (i+k)(j+l)에서 물체까지의 최단 거리로서 그 인접 위치에서도 (1)의 연산을 수행해야만 구해지는 값이지만, 그림 1(a)와 같이 영상의 좌상 측으로부터 화살표 방향을 따라 순차적으로 이 연산을 수행하면 물체에 인접한 위치 점으로부터 순차적으로 D_{ij}^f 값이 정해지게 된다. 이 D_{ij}^f 값은 좌상 측 방향의 물체로부터의 최단 거리이며 우하 측에 물체가 있을 경우에는 이로부터의 거리가 따로 고려되어야 한다. 우하 측 방향의 물체로부터의 최단 거리는 그림 1(b)와 같은 거리 테이블을 사용하고 그림 1(b)의 화살표와 같이 우하 측으로부터 시작하는 연산을 수행함으로써 구할 수 있다. 이 연산 결과로 구한 거리를 D_{ij}^b 로 할 때, D_{ij}^b 도 우하 측에 위치한 물체로부터의 최단 거리이므로 모든 방향의 물체로부터의 최단 거리는 D_{ij}^f 와 D_{ij}^b 두 값 중의 최소 값을

취함으로서 구할 수 있다. 따라서, 임의의 위치 (i,j)에서 화면상의 모든 물체까지 이르는 최단 거리 값 D_{ij} 는 식 (2)와 같다.

$$D_{ij} = \min\{D_{ij}^f, D_{ij}^b\} \quad (2)$$

III. 거리변환을 위한 셀룰라 비선형 네트워크 구조

거리 변환 알고리즘은 템플릿을 이용한 단순한 연산을 반복함으로써 임의의 위치에서도 물체까지의 최단 거리를 구할 수 있게 하지만, 화면상의 모든 화소 점들에 대해 순차적인 처리를 해야하며 전향과 후향의 반복 연산을 수행해야 하므로 실시장 계산이 필요한 응용에 이용하는데 어려움이 있다. 이 거리 변환 연산은 모든 화소 점에서 템플릿을 이용한 지역적 연산 특징이 있으므로, 지역적 연결망을 이용하여 병렬 연산을 수행하는 셀룰라 신경 회로망이나 이와 유사한 개념의 지역 처리용 회로망을 이용할 수 있다. 셀룰라 신경회로망은 Chua[19-20]등이 아날로그 병렬처리를 위해 개발한 신경회로망으로서 모든 셀이 동일한 구조의 지역적인 연결망을 갖고 있으므로 하드웨어 구성이 용이하다. 이 셀룰라 신경 회로망은 주로 영상 처리에 응용되었으며, 복잡하고 다양한 처리를 필요로 하는 응용을 위해 프로그램 기능과 디지털 로직을 추가하여 CNN-UM(CNN Universal Matching)으로 발전 하였다^[20]. 그런데, 이 셀룰라 신경회로망에 비선형 연산을 채용할 경우, 보다 다양한 처리를 할 수 있는데, 이것을 셀룰라 비선형 네트워크(Cellular Nonlinear Neural Networks)이라 하고 사용 목적에 따라 다양한 회로를 구성할 수 있다^[22-23]. 본 연구도 셀룰라 신경 회로망의 확장 개념으로서의 거리 변환을 위한 셀룰라 비선형 네트워크 구조와 이를 이용한 optical flow 계산에 관한 것이다.

셀룰라 신경회로망은 영상을 지역적 병렬방식으로 처리하기 위해서 각 화소 위치를 담당하는 아날로그 지역처리 셀들을 상호 연결하여 망을 구성한다. 셀룰라 신경회로망의 각 셀에는 바이어스(bias)가 인가되며 입력 및 출력들에 각 각의 템플릿이 곱해져서 인가되는 구조로서 등가회로는 그림 2와 같다. 그림에서 $B_{ij,kl}$ 및 $A_{ij,kl}$ 는 각각 입력과 출력 정보에 곱해지는 템플릿 계수이고 z_{ij} 은 셀 (i,j)에서의 바이어스 값이다. 이 회




그림 1. 거리 변환을 위한 스캔 방향과 거리 테이블
 $(d_{i1} = d_{i-1} = d_{i+1} = d_{i-1} = \sqrt{2}, d_{i0} = d_{i1} = d_{i-1} = d_{i-1} = 1)$

- (a) 전향 스캔 방향과 전향 거리 테이블
- (b) 후향 스캔 방향과 후향 거리 테이블

Fig. 1. Distance table and the scan direction for distance transform.

$$(d_{i1} = d_{i-1} = d_{i+1} = d_{i-1} = \sqrt{2}, d_{i0} = d_{i1} = d_{i-1} = d_{i-1} = 1)$$

- (a) forward scan direction and forward distance table
- (a) backward scan direction and backward distance table

로를 다이내믹(dynamic)방정식으로 표현하면

$$\frac{dx_{ij}}{dt} = -ax_{ij} + \sum_{k,l \in R(i,j)} A_{ij,kl} D_{kl} + \sum_{k,l \in R(i,j)} B_{ij,kl} u_{kl} + z_{ij} \quad (3)$$

이다. 여기서 x_{ij} 와 u_{ij} 는 각각 셀 (ij)의 상태 값과 입력 값을 의미하며 $R(i,j)$ 는 셀 (ij)의 인접 셀들이다. 각 셀의 출력은 상태 값의 비선형 함수로 표현되는데, $f(x_{ij})$ 를 비선형 출력함수라고 하면, 출력 y_{ij} 는

$$y_{ij} = f(x_{ij}) \quad 1 \leq i, j \leq N \quad (4)$$

이다.




그림 2. 셀룰라 신경회로망의 등가회로^[23]
Fig. 2. Equivalent circuit of the Cellular Neural Networks.

d_{-11}	d_{01}	d_{11}
d_{-10}	0	d_{10}
d_{-1-1}	d_{0-1}	d_{1-1}

그림 3. 셀룰라 비선형 네트워크 구성을 위한 거리 변환 테이블
($d_{11} = d_{-11} = d_{-1-1} = d_{1-1} = \sqrt{2}$,
 $d_{10} = d_{01} = d_{-10} = d_{0-1} = 1$)
Fig. 3. Distance Transform table for the proposed Cellular Nonlinear Neural Networks.
($d_{11} = d_{-11} = d_{-1-1} = d_{1-1} = \sqrt{2}$,
 $d_{10} = d_{01} = d_{-10} = d_{0-1} = 1$)

이와 같은 셀룰라 신경회로망의 지역 처리 개념을 거리 변환에 이용하기 위해서 그림 1의 (a)와 (b)의 거리 테이블을 결합하면 그림 3과 같은 한 개의 거리 테이블을 구성할 수 있으며 이 테이블을 이용하여 식 (1)

과 (2)의 연산을 결합하면 식 (5)와 같이 표현 할 수 있다.

$$D_{ij} = \min_{(k,l) \in R(i,j)} \{ d_{kl} + D_{(i+k)(j+l)} \} \quad (5)$$

이 식은 인접 위치 점에서 물체까지의 최소 거리에 해당 인접 점 위치의 거리 값을 합한 값 중 최소 값을 취한다는 의미이다. 각 셀은 이와 같은 연산을 동시에 병렬로 수행하게 되므로, 거리 값은 물체에서 가까운 위치로부터 모든 연결망을 따라 신속하게 확산 전파되어 전 화면내에 거리 변환 필드를 형성해 가게 된다. 임의의 점에 정확한 거리 변환 필드가 형성되는데 소요되는 최대 시간 T_{max} 는 다음과 같이 계산된다.

$$T_{max} = T_{set} \cdot N_{cell} \quad (6)$$

여기서 T_{set} 는 아날로그 min 연산회로의 settling time이고 N_{cell} 은 최단 거리를 따라 물체에 이르는 경로 상에서 거치게 되는 셀의 수이다.

이 연산을 하드웨어로 구현하기 위해 필요한 min 연산 회로는 max 연산 회로에 비해 복잡하기 때문에 거리 값의 보수(complement)값을 사용하면 max 회로를 이용하여 구성할 수 있다. 즉, 물체에서 시작하여 화소 간의 거리를 누적해 나가는 방식 대신, 일정한 큰 값으로부터 경유하는 거리를 감해 나가는 방식을 채용하면 각 화소에서는 식 (5)에서의 최소 값 연산 대신 최대 값 연산을 사용할 수 있다. 따라서 각 화소 위치 (ij)의 출력을 y_{ij} 라고 하면 (5)식은,

$$y_{ij} = \max_{(k,l) \in R(i,j)} \{ z_{ij}, y_{(i+k)(j+l)} - d_{kl} \} \quad (7)$$

로 대신할 수 있다. 여기서 z_{ij} 는 물체 위치에 해당하는 셀에만 인기하는 큰 값으로서 각 셀이 (7)식을 반복적으로 수행하게 되면 결과적으로 각 셀은 물체위치의 z_{ij} 로부터 셀 간의 거리 값을 감한 출력을 갖게된다. 이 연산을 아날로그 회로 식으로 표현 할 경우, 회로 다이내믹 식은

$$\frac{dx_{ij}}{dt} = -ax_{ij} + \max \{ z_{ij}, (y_{kl} - d_{ij,kl}) \mid kl \in R(i,j) \} \quad (8)$$

이다. 이 회로의 다이내믹 식은 원래의 셀룰라 신경회로망 다이내믹 식 (3) 및 (4)와 비교할 때, 매우 비선형 연산이 필요하므로 선형적 템플릿 연산을 사용하는 기준

의 셀룰라 신경 회로방 구조반으로는 구현하기 어렵다.

IV. 셀룰라 비선형 회로 구조를 이용한 Optical Flow 계산

영상에 포착되는 물체의 특징점들은 시간적으로 가 변하지 않으며 물체의 이동 시 물체와 같은 속도로 이동하게 된다. 만약 특징점이 물체의 코너처럼 독립점 이라면, 단위 시간 동안 움직인 특징점의 궤적은 optical flow와 유사한 모양의 벡터를 생성한다. 그런데, 독립된 특징점이 생성시키는 선은 단선이기 때문에 잡음의 영향을 받으면 쉽게 절단되어 실제 보다 짧은 optical flow로 잘못 추출되는 문제가 발생한다. 이를 보완하기 위해 특징점 추출 과정에서의 임계치 (threshold)를 완화함으로써 특징점들의 집단이 형성 하는 클러스터(cluster)를 생성시키고 이 특징점 클러스터들이 만들어내는 넓은 궤적을 이용함으로써 잡음이 있더라도 단절되지 않는 궤적을 얻을 수 있게 하였다. 일단 특징점 궤적을 얻은 후에는 특징점 궤적의 시작점에서부터의 거리를 계산할 수 있는 거리 변환 필드 를 생성시키며, 이를 이용하여 궤적의 시작점과 종점 간의 벡터를 구하여 optical flow로 활용하는 원리이다.




그림 4. 거리변환을 위한 셀룰라 비선형 회로의 구조
Fig. 4. Cellular Nonlinear Circuits(CNC) structure for distance transform.

이 특징점의 궤적을 생성시키기 위해서 본 연구에서 사용한 방법은 Smith^[1]가 제안한 코너점 추출 알고리즘이다. 특징점 추출 알고리즘에 의해 추출된 특징점들의 위치를 단위 시간 ΔT동안 x-y 평면상에 누적하면 특징점들의 움직인 궤적이 형성된다. 이 궤적의 시작점을

원점으로 하여 거리 변환 필드를 형성시키면 궤적의 시작점으로부터의 거리에 비례하는 정보가 분포된 필드를 형성하게 된다. 이를 위해서 특징점 궤적의 시작 점에만 셀의 바이어스를 인가하며 거리 변환 필드가 특징점 궤적을 따라서만 형성되게 하였다. 이를 위한 셀룰라 비선형 회로 구조는 그림 4와 같다.

제안한 셀룰라 비선형 회로 구조에서 각 셀의 입력은 이웃 셀로부터 오는 $n_{i,kl}$ 과 바이어스 z_{ij} , 그리고 셀 입력 u_{ij} 이다. 이웃 셀로부터 오는 $n_{i,kl}$ 정보는 $d_{i,kl}$ 만큼 감소된 거리가 입력된다.

$$n_{i,kl} = y_{kl} - d_{i,kl} \tag{9}$$

여기서, y_{kl} 는 이웃 (k,l) 위치 셀의 출력이고, $d_{i,kl}$ 은 kl과 ij 두 셀의 거리이다. 바이어스 z_{ij} 는 3절에서 언급했던 거리 변환 값의 소스(source)로서, 단위 시간 ΔT의 첫 번째 프레임의 특징점에 해당되는 셀에만 인가한다. 각 셀은 이웃 셀의 출력과 자기 자신의 바이어스 중 최대 값을 취하는 연산을 다음과 같이 수행하게 한다.

$$x_{ij} = \max(z_{ij}, (n_{ki} \text{ for all } kl \in R(i, j))) \tag{10}$$

식 (10)의 출력이 ΔT의 첫 번째 프레임의 특징점에 해당하는 셀인 경우에는 주변의 값이 바이어스 값 z_{ij} 보다 크지 않기 때문에 바이어스 값을 변화 없이 출력하고 다른 셀들은 이 바이어스에서 셀 간의 거리 값을 감한 나머지를 전달하는 역할을 하게된다. 한편 출력 y_{ij} 는 상태 값에 입력 값 u_{ij} 가 곱해져서 출력되는 데, 이것은 입력 값이 있을 때만 다음과 같이 출력으로 전달되는 기능을 갖게 한다.

$$y_{ij} = \begin{cases} x_{ij} & , \text{ if } u_{ij} \text{ is } 1 \\ 0 & , \text{ otherwise} \end{cases} \tag{11}$$

그런데 입력 값 u_{ij} 는 특징점의 궤적에 해당하는 셀만 1이 인가되므로 결과적으로 거리 변환 값이 특징점의 궤적 위에서만 전파되게된다. 이렇게 생성된 거리 변환 필드의 종점들 중에서 지역적으로 최소의 거리 변환 값을 갖는 점을 선택하여 식 (12)와 같이 시작점의 출력과의 차이를 계산하면 시작점으로부터 그 점까지의 벡터의 거리를 구할 수 있다. 즉 선택된 셀의 위치를 (ij)라고 하면 벡터의 길이 D_{ij} 는

$$D_{ij} = z_{kl} - y_{ij} \tag{12}$$

로 계산된다. 여기서 z_{kl} 은 궤적의 시작점 셀에 인가하는 비어스 값으로서 이 셀의 출력이다. 또 optical flow 벡터의 방향은 거리 변환 값이 전과 되어온 방향을 계산함으로써 구할 수 있는데, 선택된 셀의 출력이 y_{ij} 이면 이 값을 전과시킨 셀의 위치는 다음 조건을 만족하는 인접위치 (k,l) 이다.

$$y_{kl} = y_{ij} + d_{ij,kl}, \text{ for all } kl \in R(ij) \tag{13}$$

Optical flow 계산을 위해 사용되는 그림 4의 구조 중 max 회로 구성을 위해서는 구조가 간단하면서도 매우 정밀한 회로들의 연구가 많이 되어 있으며^[24] 간단한 아날로그 합을 위한 회로만 추가하면 구성할 수 있다. 또한, optical flow 벡터 방향 추출을 위한 (13)의 연산도 간단한 아날로그 비교회로를 사용하면 구현할 수 있다.

V. 시뮬레이션 결과

제안한 알고리즘을 검증하기 위해 평면상을 이동하는 골프공 영상과 zoom 되어 확대되고 있는 경치 영상에 대해 제안한 알고리즘과 Smith의 특징기반 알고리즘^[1]의 optical flow 추출 성능을 비교하였다. 또, 잡음에 대한 강건성을 비교하기 위해서 잡음을 인위적으로 인가한 영상에 대해 시뮬레이션하여 두 알고리즘의 성능을 비교하였다. 이 시뮬레이션에서 사용된 영상은 초당 20프레임의 속도로 촬영된 영상 중 15프레임을 사용하였다. 제안한 셀룰라 비선형 네트워크의 각 셀의 상태를 갱신하기 위해서 식 (8)을 이용하여 시간 ΔT 동안의 상태 변화 값 Δx 를 구하여 상태를 반복적으로 갱신하였으며 이 식에서의 α 를 0.9로 하여 계산하였다. 이 실험에서 특징할 사항은 기존의 알고리즘에서는 잡음제거를 위한 전처리를 수행했지만 (전처리 하지 않을 경우 성능이 매우 나빠짐), 제안한 알고리즘에서는 잡음제거를 위한 전처리를 수행할 필요가 없었다.

첫 번째 시뮬레이션은 그림 5와 같이 골프공이 위쪽으로 이동하면서 시계 방향으로 회전하고 있는 영상을 대상으로 하였다. 그림 6은 특징점들의 궤적 위에 제안한 셀룰라 비선형 네트워크에 의한 거리 변환에 의해 생성된 거리 변환 필드를 영상으로 표현한 것이고, 그





그림 5. 이동 중인 골프공
Fig. 5. Golf-ball image while the ball is translating.




그림 6. 제안한 알고리즘 수행과정에서 특징점 궤적상에 생성된 거리 변환 필드.
Fig. 6. Distance potential field developed on the trajectories of feature points.

림 7(a)는 거리 변환된 특징점 궤적 상에서 추출된 optical flow이다. 그림 7(a)에서 보는 바와 같이 특징점들에서 추출된 optical flow들은 대부분이 정확한 길이와 방향을 유지하고 있음을 알 수 있다. 이 optical flow 추출결과에서 아래쪽의 optical flow들이 위쪽의 것들에 비해 더 기울진 것은 골프공이 위쪽으로 이동하면서 시계 방향으로 회전을 하였기 때문이다. 제안한 알고리즘에서 오류가 적은 이유는 특징점 화소들의 움

직접이 영상의 프레임 간격 시간동안 한 화소를 벗어 나지 않기 때문에 그림 6에서와 같이 연결된 궤적을 구성하게 되며 그 궤적내에서 정합쌍을 찾게 되므로 정확성이 보장되기 때문이다.



(a)



(b)

그림 7. 골프공 영상에 대한 optical flow 추출 결과
(a) 제안한 알고리즘의 결과
(b) 기존의 알고리즘의 결과

Fig. 7. Optical flows detected about the golf-ball image.

(a) the results with the proposed scheme
(b) the results with the conventional scheme

제안한 알고리즘을 기존의 특징 기반 방법과 비교하기 위해 같은 영상에 대해 Smith^[1]의 특징 기반 알고리즘을 시뮬레이션하였다. 그림 7(b)는 기존의 특징 기반

방법의 시뮬레이션한 결과로, 그림 7(a)에 비해 오정합으로 인한 잘못된 optical flow들이 많이 나타남을 알 수 있다.

잡음 환경에서의 제안한 기법을 검증하기 위해, 매 프레임마다 그림 8과 같이 랜덤한 위치에 천 개의 salt&pepper 잡음을 첨가한 영상에 대해 제안한 기법을 적용하였다. 제안한 기법은 잡음이 첨가된 영상에 대해서도 그림 9(a)처럼, optical flow 추출 성능이 크게 저하되지 않는 반면 기존 알고리즘의 적용 결과에서는 그림 9(b)와 같이 더욱 많은 optical flow 오류가 나타남을 알 수 있다.






그림 8. 랜덤한 위치에 salt & pepper 잡음이 인가된 영상

Fig. 8. The golf-ball image with salt & pepper noise.



(a)



(b)

그림 9. 잡음 환경에서의 골프공 영상에 대한 시뮬레이션 결과

- (a) 제안한 알고리즘에 의한 시뮬레이션 결과
- (b) 기존의 특징 기반법에 의한 optical flow

Fig. 9. Simulation results about the noisy golf-ball image

- (a) optical flows with the proposed scheme
- (b) optical flows with the conventional scheme

표 1. 골프공 원영상에 대한 기존의 기법과 제안한 기법의 수치적 비교

Table 1. Numerical comparison of simulation results between the proposed and the conventional algorithm.

	optical flow 정확도
기존의 특징 기반 기법	75 %
제안한 기법	99 %

표 2. 골프공 잡음 영상에 대한 기존의 기법과 제안한 기법의 수치적 비교

Table 2. Numerical comparison of the simulation result between two algorithms about noisy image.

	optical flow 정확도
기존의 특징 기반 기법	64 %
제안한 기법	90 %

표 1과 표 2는 위의 시뮬레이션 결과를 수치적으로 비교하기 위한 데이터로써, 표에 제시된 optical flow 정확도는 첫 번째 프레임의 특징점들과 마지막 프레임

의 특징점들의 정합에 추출된 optical flow중 정정합된 optical flow의 비율을 의미한다. 제안한 알고리즘은 수치적인 비교에서 보여주는 바와 같이 기존의 방법에 비해 24 - 30% 정도 나은 정확성을 갖고 있음을 확인할 수 있다.



그림 10. 줌인 중의 경치 영상

Fig. 10. A scenery image while it is being zoomed.




그림 11. 그림 10에 대해 제안한 알고리즘 수행 중 생성된 거리변환 필드


Fig. 11. Distance potential fields developed on the trajectories of the image in Fig. 10.

두 번째 시뮬레이션은 그림 10과 같은 경치 영상이 줌인 되어 확대되어 가는 과정에서 획득한 영상에 대해 동일한 알고리즘을 적용하여 시뮬레이션하였다. 그

림 11은 제안한 알고리즘의 수행과정에서 생성된 특징점 추적 상의 거리 변환 필드를 영상으로 표현한 것이고, 그림 12(a)는 제안한 알고리즘을 이용하여 계산한 optical flow들이다. 줌인 영상에 대해서도 제안한 알고리즘은 거의 모든 optical flow들이 정확하게 추출하고 있음을 확인할 수 있다. 기존의 특징 기반 알고리즘을 줌인 영상에 적용한 결과는 그림 12(b)와 같다. 이 영상에 대해서도 제안한 알고리즘의 결과에 비해 많은 optical flow 추출오류가 발생함을 알 수 있다.



(a)



(b)

그림 12. 줌인 영상에 대한 시뮬레이션 결과
 (a) 제안한 알고리즘에 의해 생성된 optical flow
 (b) 기존의 알고리즘에 의한 optical flow

Fig. 12. Simulation results about the zoom-in image.

- (a) optical flows with the proposed scheme
- (b) optical flows with the conventional scheme

경치 영상에 대해서도 잡음에 대한 강건성을 시험하였는데 골프 공 영상 시뮬레이션과 동일한 조건의 잡음을 첨가하였다. 그림 13은 잡음을 첨가한 영상이고, 그림 14는 이 영상에 대한 optical flow 추출 시뮬레이션 결과이다. 제안한 알고리즘에 의한 시뮬레이션 결과에서 독립된 점들로 표현되는 짧은 optical flow는 마지막 프레임에 인가한 salt & pepper 잡음이 거리 변환의 소스의 인접위치에 나타날 때 검출되는 오류들인데, 크기가 모두 1인 잡음들이므로 쉽게 제거할 수 있다. 이 시뮬레이션 결과에서도 제안한 알고리즘이 기존의 알고리즘에 비해 적은 오류를 포함하고 있음을 알 수 있다. 표 3과 표 4는 줌인 영상에 대해 기존의 방법과 제안한 알고리즘의 결과를 수치적으로 비교한 결과이다. 제안한 알고리즘이 기존의 것에 비해 14 - 17% 정도 우수함을 보여준다.



그림 13. 경치 영상에 salt & pepper 잡음이 첨가된 영상

Fig. 13. A scenery image with additional noise.

표 3. Zoom in 영상에 대해 시뮬레이션 했을 경우, 기존의 알고리즘과 제안한 알고리즘 결과의 수치적 비교


Table 3. Numerical comparison of simulation result about the zooming image between with the proposed scheme and with the conventional algorithm.

	optical flow 정확도
기존의 특징 기반 기법	84 %
제안한 기법	98 %


표 4. Zoom in 잡음 영상에 대해 실험했을 경우, 기존의 알고리즘과 제안한 알고리즘의 수치적 비교

Table. 4. Statistical comparison of the simulation result with the proposed scheme and with the conventional approach about the zooming image with noise.

	optical flow 정확도
기존의 특징 기반 기법	78 %
제안한 기법	95 %



(a)



(b)

그림 14. 잡음 영상에 대한 시뮬레이션 결과
 (a) 제안한 알고리즘에 의한 optical flow 추출 결과
 (b) 기존의 알고리즘에 의한 optical flow 추출 결과

Fig. 14. Simulation results about the noisy zooming image
 (a) optical flows with the proposed scheme
 (b) optical flows with the conventional scheme.

VI. 결 론

특징점들의 궤적 상에서 거리 변환 필드를 생성시켜 optical flow를 구하는 새로운 알고리즘을 제안하였다. 카메라 위치 파악이나 물체 추적 같은 많은 응용 분야에 있어서 매 픽셀마다의 부정확한 optical flow 보다는 수가 적더라도 정확한 optical flow가 유용하다. 제안한 기법은 특징점들의 궤적 위에서만 optical flow를 구하기 때문에 수는 많지 않지만 잡음에 강하고, 하드웨어 구현이 용이한 방법이다.

제안한 optical flow 계산 방법에서 필요한 연산들은 간단한 이진로 회로에 의해 구현할 수 있으며 병렬로 처리되기 때문에 실시간 계산이 가능하다. 이 논문에서는 특징점들의 궤적 상에서 거리 변환을 수행할 수 있는 셀룰라 비선형 네트워크 구조를 제안하였고 이 구조를 이용하여 특징점 궤적의 길이와 방향을 계산하는 방법을 기술하였다. 제안한 기법의 성능을 검증하기 위해 평면상을 회전하면서 이동하는 골프공 영상과 줌인 되어 확대되는 경치 영상에 대해 기존의 알고리즘과 비교 시뮬레이션하였다. 제안한 알고리즘은 잡음 제거를 위한 전처리를 하지 않았음에도 불구하고 전처리를 수행한 기존의 특징 기반 알고리즘에 비해 20% 이상 우수한 성능을 보여 주었다. 인위적으로 잡음이 첨가된 영상에 대한 실험에서도 제안한 기법은 optical flow 추출성능이 크게 저하되지 않는 반면, 기존의 알고리즘을 통해서 얻은 optical flow들은 실용적 응용에 이용이 어려울 정도로 오류가 많음을 확인할 수 있었다.

참 고 문 헌

[1] S. M. Smith, "ASSET-2 : Real-time motion segment and object tracking, Real-Time Imaging," *Academic Press*, Vol.4, (No. 1), pp. 21-40, Feb. 1998.
 [2] M. Black and Y. Yacoob, "Recognizing facial expressions in image sequences using local parameterized models of image motion," *International Journal of Computer Vision*, Vol. 25, No. 1, pp. 23-48, 1997.

- [3] G. Donato, M. S. Bartlett, C. Hagcr, P. Ekman, and T. J. Sejnowski, "Classifying facial actions," *IEEE Tr. on PAMI*, Vol. 21, No. 10, pp. 974-989, Oct. 1999.
- [4] G. Adiv, "Inherent ambiguities in recovering 3-D motion and structure from a noisy flow field," *IEEE Tr. on PAMI*, Vol. 11, No. 5, pp. 477-489, May 1989.
- [5] W. Wang, and J. H. Duncan, "Recovering the tree-dimensional motion and structure of multiple moving objects from binocular image flows," *Computer Vision and Image Understanding*, Vol. 63, No. 3, pp. 430-446, May 1996.
- [6] H. Nagel and M. Haag, "Bias-corrected optical flow estimation for road vehicle tracking," *Proceedings of IEEE 6th International Conference on Computer Vision*, pp. 1006-1011, Bombay, India, Jan. 1998.
- [7] W. Burger, B. Dhanu, "Estimating 3-D egomotion from perspective image sequences," *IEEE Tr. on PAMI*, Vol. 12, No. 11, pp. 1040-1058, Nov. 1990.
- [8] S. Wachter and H. H. Nagel, "Tracking persons in monocular image sequences," *Computer Vision and Image Understanding*, Vol. 74, No. 3, pp. 174-192, June 1999.
- [9] J. Weber and J. Malik, "Rigid body segmentation and shape description from dense optical flows under weak perspective," *IEEE Tr. on PAMI*, Vol. 19, No. 2, pp. 139-143, Feb. 1997.
- [10] D. Kreseski, R. E. Mercer, J. L. Barron, P. Joe and H. Zhang, "Storm tracking in doppler radar images," *Proceedings of 1st International Conference on Image Processing*, pp. 226-230 Vol. 3. Nov. 1994.
- [11] R. A. Deutschmann and C. Koch, "An analog VLSI velocity sensor using the gradient method," *ISCAS '98. Proceedings of the 1998 IEEE International Symposium on Circuits and Systems*, Vol. 6, pp. 649-652, June 1998.
- [12] C. M. Higgins and C. Koch, "Analog CMOS velocity sensors," *Proceedings of Electronic Imaging '97*, pp. 103-114, San Jose, CA, Feb. 1997.
- [13] J. K. Kearney, W. B. Thompson, and D. L. Boley, "Optical flow estimation: An error analysis of Gradient-based methods with local optimization," *IEEE Tr. on PAMI*, Vol. PAMI-9, No. 2, pp. 229-244, March 1987.
- [14] E. H. Adelson and J. R. Bergen, "Spatiotemporal energy models for the perception of motion," *Journal of Optical Society of America A*, Vol. 2, No. 2, pp. 284-299, Feb. 1985.
- [15] A. B. Torralba and J. Herault, "An efficient neuromorphic analog network for motion estimation," *IEEE Tr. on Circuits and Systems-I: Fundamental Theory and Applications*, Vol. 46, No. 2, pp. 269-279, Feb. 1999.
- [16] D. J. Fleet and A. D. Jopson, "Computation of component image velocity from local phase information," *International Journal of Computer Vision*, Vol. 5, No. 1, pp. 77-104, 1990.
- [17] J. J. Little and A. Verri, "Analysis of differential and matching methods for optical flow," *Proceedings of IEEE Motion Workshop*, pp. 173-180, Irvine, 1989.
- [18] S. Barnard and W. B. Thompson, "Disparity analysis of images," *IEEE Tr. on PAMI*, Vol. PAMI-2, No. 4, July 1980.
- [19] L. O. Chua and L. Yang, "Cellular neural networks: theory," *IEEE Tr. on Circuits Systems*, Vol 35, pp. 1257-1272, 1988.
- [20] T. Roska and L. O. Chua, "The CNN universal machine: an analogic array computer", *IEEE Tr. on Circuits Systems II*, CAS-40, pp. 163-173, 1988.
- [21] G. Borgefors, "Distance transformation in digital images", *Computer Vision, Graphics, and Image Processing*, Vol. 34, pp. 344-371, 1986.
- [22] T. Yang, L. Yang, "Fuzzy cellular neural network: A new paradigm for image processing", *International Journal of Circuit theory*

and Application, Vol. 25, pp. 469-481, 1997

- [23] L. O. Chua, T. Yang, G-Q. Zhong and C. W. Wu, "Synchronization of Chua's Circuits with Time-Varying Channels and Parameters," *IEEE Transactions on Circuits and Systems, Part I*, Vol. 43, No. 10, pp. 862-868, 1996.
- [24] I. Baturone, J. L. Huertas, A. Barriga, S. Sanchez-Solano, "Current-Mode Multiple-Input Max Circuit", *Electronics Letters*, Vol. 30, No. 9, pp. 678-679, April, 1994

부록 A : Smith^[1]의 특징점 추출 방법

본 연구에서 사용한 특징들은 코너점들로서 사용된 알고리즘은 SUSAN(Smallest Univalve Segment Assimilating Nuclcus)^[1]이다. SUSAN 알고리즘은 이웃 화소와 비교하여 그레이 레벨 차이가 가장 뚜렷한 코너 점들을 추출하는 방법이다. 이 알고리즘은 입의 위치에서의 화소 값에 대해 주변 화소 값과의 차이를 식(A-1)과 같은 가우시안 함수로 표현하는 방법인데, 화소 값의 차이가 크면, 출력 값은 작고, 화소 값의 차이가 작으면, 큰 값을 출력하게 함으로써 영상 평면상에서 화소 값의 변화를 검출한다.

$$G(ij, kl) = e^{-k_0 (R(k, l) - R(i, j))^n}, \quad r \in R(i, j) \quad (A-1)$$

여기서 $R(i, j)$ 는 화소 위치 (ij)에 인접한 위치의 집합이고, $I(k, l)$ 와 $I(i, j)$ 는 (ij)위치와 (kl)위치의 화소 값이며, $G(ij, kl)$ 은 이 위치들에 대한 가우시안 함수의 출력, k_0 은 상수를 나타낸다. 그리고 n 은 상수로, 가우시안 함수의 기울기를 결정한다.

다음은 $R(i, j)$ 에 포함된 화소들에 대해들을 $G(ij, kl)$ 를 더하는 과정이다. 이 더한 값을 $S(i, j)$ 라고 하면,

$$S(i, j) = \sum_{kl \in S(R(i, j))} G(I_{kl}, I_{ij}) \quad (A-2)$$

이다. 원래의 SUSAN 알고리즘에서는 부분적으로 최대 변화율을 보이는 부분을 코너점으로 결정하기 때문에 식 (A-2)의 다음 과정으로 주변의 $S(i, j)$ 들간에 local minimum 연산을 수행하지만, 본 제한한 알고리즘에서는 다수의 특징점들을 추출하기 위해서 이 과정을 생략하였다. 식 (A-2)의 연산 후에 최종적인 특징점 결정은 thresholding에 의해 이루어지는데 만약 $S(i, j)$ 문턱치 v_{th} 보다 작으면, 위치 (ij)는 특징점으로 결정된다.

저 자 소 개



孫弘樂(正會員)
1973년 5월 26일생. 1996년 전북대 제어계측과 졸업. 1998년 전북대 전기공학과 졸업(석사). 2000년 전북대 전자공학과 박사과정 수료. 2000년 3월~현재 전북대 메카트로닉스 연구원. 주관심 분야는 셀룰라 신경회

로방, 영상처리, analog VLSI

金炯奭(正會員) 第 36卷 S編 第 2號 參照