

경쟁학습 신경망과 퍼지추론법을 이용한 움직임 분석

Motion Analysis Using Competitive Learning Neural Network and Fuzzy Reasoning

이 주 한*, 오 경 환*
Joohan Lee*, Kyunghwan Oh*

본 연구는 '91년도 한국과학재단 목적기초연구비 지원에 의한 것임 (과제번호 : 91-0100-08)

요 약

본 논문에서는 ART-II 경쟁학습 신경망과 퍼지추론을 이용하여 동일한 물체를 연속적인 영상열에서 정합 시킴으로서 움직임을 분석하는 방법을 제시한다. 영상분할을 통해 얻을 수 있는 영역의 크기와 평균광도를 이용하여 영역단위의 정합을 수행하고, 영역의 모양을 표현하기 위한 특징점을 선택하기 위하여 입력패턴들의 위상을 나타낼 수 있는 ART-II 경쟁학습 신경망을 사용하였다. 선택된 특징점들의 정합을 통해 각 물체에 대한 움직임 벡터를 구한다. 그러나, 3차원적 실제세계의 사영인 2차원 영상은 영상 자체의 불완전성과 물체에 대한 정보를 얻기 위하여 사용되는 영상분할의 잘못으로 인한 오류 때문에 움직임 추정 과정에서 모호성이 발생한다. 이러한 움직임 분석과정에서 나타나는 불확실성을 처리하기 위하여 퍼지추론을 사용하여 신뢰도를 표현함으로써 이동 물체와 움직임 벡터를 추출하였다.

ABSTRACT

In this paper, we suggest a motion analysis method using ART-II competitive learning neural network and fuzzy reasoning by matching the same objects through the consecutive image sequence. we use the size and mean intensity of the region obtained from image segmentation for the region matching by the region and use a ART-II competitive learning neural network which has a learning ability to reflect the topology of the input patterns in order to select characteristic points to describe the shape of a region. Motion vectors for each regions are obtained by matching selected characteristic points. However, the two dimensional image, the projection of the the three dimensional real world, produces fuzziness in motion analysis due to its incompleteness by nature and the error from image segmentation used for extracting information about objects. Therefore, the belief degrees for each regions are calculated using fuzzy reasoning to manipulate uncertainty in motion estimation.

*서강대학교 전자계산학과
Sogang Univ. Computer Science dept.

I. 서 론

1980년대 이전에는 동영상보다 정지영상에 대한 이해와 분석에 더 많은 관심과 연구가 진행되었지만 최근에는 동영상에서 얻은 정보를 이용한 영상분할, 경계선의 추출 및 영상의 이해에 대해 연구가 진행되고 있다[1, 2]. 일반적으로 동물들이 움직임 정보에 기반한 지각체계를 가지고 있다는 점에서 인간의 뇌의 학습과정을 모델로 하는 신경망을 이용하여 영상의 움직임을 분석하려는 많은 노력들이 시도되어 왔다[3, 4]. 실용적인 관점에서 움직임 해석은 보안 시스템, 이동물체의 추적 및 미래의 이동방향의 예측, 도시교통량 분석, 연속적인 기상 데이터를 이용한 구름의 추적 등에 사용이 된다.

움직임 분석은 크게 영상 내에 있는 물체에 종속적인 경우와 독립적인 경우로 나눌 수 있다. 물체에 종속적인 움직임의 계산은 관심이 있는 점들이나 영역들에 대해 연속적인 영상열들에서 일치되는 점들이나 영역들을 찾는 것이다. 반면 물체에 독립적인 움직임의 계산은 보통 차영상(difference image)나 광류(optical flow)를 이용하여 계산한다. 실제 세계가 투영된 2차원 영상 자체에 내포된 모호성과 3차원적인 공간정보의 부족, 물체를 구별하기 위한 특징 표현의 어려움 등으로 인한 움직임 분석의 한계를 극복하기 위하여 일반적으로 물체의 이동속도, 물체의 성질 등에 대한 여러가지 제약들을 이용하여 물체의 위치추정에 이용한다.

물체에 종속적인 움직임 분석은 보통 다음과 같은 세 단계로 수행된다. 첫째, 영상열의 각각의 영상들을 영역분할 한다. 둘째, 영상들 사이의 차이 또는 유사점을 계산하거나 표현한다. 셋째, 각각의 영상에 대한 설명들을 이용하여 영상열에 대한 가설을 만든다. 그러나, 이 방법은 각 영역을 구별하기 위한 특징 추출 및 학습에 많은 시간이 걸리고 인간의 움직임 해석이 정확한 특징을 통한 물체의 구분에 의존하지 않는다는 점에서 문제점이 있다. 또한 물체의 형태에 기반한 영상의 이해 및 움직임 분석방법은 물체의 외곽선이나 면 등의 모양표시 방법들[5]을 이용하여 물체를 구분하고 그에 따라 연속적인 영상열에서 물체들을 정합 시키고 움직임 추정을 한다. 그러나 모양표시 방법의 복잡성과 배경영역의 경우 이동물체에 의한 중첩으로 인하여 배경에 대한 움직임 추정이 힘들다.

기존의 방법들에서의 움직임 분석 결과는 움직인 물체에 대한 속도벡터를 구함으로써 움직인 물체의 움직임 방향과 크기를 제시하였다. 그러나, 움직임 추정을 하더라도 영상 자체의 모호성으로 인해 움직임 분석결과에는 불확실성이 항상 존재하게 된다. 따라서, 본 논문에서는 위에 언급한 문제점들을 해결하기 위하여 물체에 종속적인 움직임 분석방법 중 영상의 유사성에 의한 움직임 분석방법의 개선방안 및 움직임 분석결과에 대한 신뢰도를 어떻게 부여할 것인지에 대한 방법을 제시하고 여러 개의 움직이는 물체가 있는 실험영상에 대한 적용을 통해 타당성을 보인다. 제안된 방법에서는 2개의 영상열에 대하여 각각 영상분할을 수행하고 생성된 영역들을 연속적인 영상열에서 ART-II 경쟁학습 신경망(competitive learning neural network)을 이용하여 물체영역 및 배경영역의 모양을 나타낸다. ART-II 신경망은 입력패턴의 특징을 나타낼 수 있는 성질이 있기 때문에 표현하려는 영역을 ART-II의 입력으로 사용하여 학습 후 생성된 뉴런들을 이용하여 임의의 형태를 갖는 영상내의 영역을 표현하기에 적합하다. 이렇게 표현된 영역들을 연속적인 영상에 대해 정합 시킴으로써 동일한 영역들을 구분한다. 그러나, 영상자체의 불완전성과 움직임 추정과정에서의 오류 등에 의한 불확실성을 처리하기 위하여 퍼지추론을 사용하여 움직임 분석에 대한 신뢰도를 부여한다.

본 논문의 구성은 다음과 같다. 2장에서는 연구배경으로 기존의 움직임 추론방법, ART-II 경쟁학습 신경망 그리고 퍼지추론에 대해 살펴보고, 3장에서는 본 논문에서 제안된 경쟁학습 신경망과 퍼지추론을 이용한 움직임 분석방법에 대해 기술한다. 4장에서는 제안된 방법을 이용한 실험 결과 및 분석을 보이고 5장에서는 결론과 앞으로의 연구과제에 대해 언급한다.

II. 연구배경

2.1. 영상의 분할

영상에 대해 동일한 성질 및 특징을 갖는 부분들을 분리하기 위해 사용되는 영역분할 방법에는 어떠한 성질을 기준으로 할 것인지에 따라 여러 가지가 있다. 영역에 기반한 방법에는 대표적으로 분할 및 병합(split-and-merge) 방법과 영역성장(region growing) 방법이 있다[6]. 본 논문에서는 영상내의 특정한 pixel을 기준점(seed)으로 하

여 인접한 pixel들에 대해 비슷한 광도를 갖는 pixel들을 포함할 때까지 영역을 성장시키고 광도가 일정한 양 이상 차이가 나는 pixel들이 발견되면 새로운 영역을 만드는 방법인 영역성장 방법을 사용하였다.

2.2 움직임 추정 방법

움직임을 분석하는 방법은 크게 물체에 독립적인 움직임 분석방법과 물체에 종속적인 움직임 분석방법이 있다. 각각의 방법은 움직임 분석을 위해 영상내의 물체에 대한 정보를 사용하는지 안하는지에 따라 나뉘며 각각의 방법 및 장단점은 다음과 같다.

2.2.1. 물체에 독립적인 움직임 분석방법

물체에 독립적인 움직임 분석방법에는 차영상을 이용하는 방법과 광류를 이용하는 방법이 있으며 영상내의 물체의 모양, 위치, 특성 등에 대한 사전 지식없이 각 점에서의 광도의 변화에 기반한 움직임 분석을 하는 것이다. 따라서 입력 영상열에 대한 여러 가지 제약가정들이 있게 된다.

차영상을 이용하는 방법은 두개의 연속적인 영상에 대해 영상의 각 점들에 대한 광도의 차이를 구하는 것이다. 이 방식은 두 영상의 동일한 위치의 광도의 차이가 임계값보다 크면 그 위치에 움직임이 있는 것으로 해석을 한다. 이 방법으로는 움직임 영역에 대한 방향은 결정할 수 없으므로 각 점에 대한 명암의 차를 이용하여 움직임을 나타내는 차영상의 축적방법 등을 통해 방향을 결정한다[7].

광류는 짧은 시간 dt 동안의 영상 이미지의 변화를 나타내며 2차원적 영상의 모든 점에 대해서 속도 벡터를 결정한다[8]. 이러한 광류계산의 가장 큰 문제점은 조명의 변화도 움직임으로 나타날 수 있다는 것이다.

2.2.2. 물체에 종속적인 움직임 분석방법

물체에 종속적인 움직임 분석방법은 물체의 특징점을 이용하는 방법과 물체의 영역을 이용하는 방법이 있으며 연속적인 영상열의 각각의 영상에서 물체에 대한 영역을 각각 구분 지어줄 수 있는 특징들을 추출하여 정합 시킴으로써 움직임을 분석한다. 물체를 나타낼 수 있는 특징점 또는 특징선 등을 이용하거나 물체의 외곽선, 모양표시자 등을 이용하여 물체의 특징들을 표현한다. 그리고, 물체의 영역을 표시할 수 있는 texture 정보, 평균광도 등도 특징을 나타내기 위해 이용된다.

물체의 특징점들을 이용한 움직임 분석은 영상내의 각 물체를 나타내는 특징점들을 이용한다. 특징점의 추출은 여러 가지 특징 표시자들[9]을 이용하여 나타낼 수 있고 특징점들을 연속적 영상에서 동일한 점들끼리 정합을 시킴으로써 움직임을 분석할 수 있다.

물체의 영역을 이용한 움직임 분석은 영상을 영상분할하고 이 때 생긴 영역들의 외곽선 또는 영역내부의 특성을 이용하여 연속된 영상에서 동일한 영역을 정합 시키고 움직임을 분석한다. 이 분석방법은 영역정합 방법에 따라 유사성을 분석하고 차이점을 분석하는 방법[10]과 차이점을 분석하고 유사성을 분석하는 방법[11]으로 나뉠 수 있는데 전자는 영상에 대한 정보가 부족한 경우에 주로 사용하고 후자는 영상에 대한 사전 정보가 있는 경우에 사용한다.

2.3. ART-II 경쟁학습 신경망

물체에 종속적인 움직임 분석방법에서는 영상에 나타난 물체의 특징점, 외곽선 모양, 영역내부의 특징, 평균밝기 등 각 물체 고유의 특성을 이용하여 영상내의 물체들에 대한 구분을 한 후 연속적인 영상열에서 동일한 특성을 갖는 물체들을 정합 시킴으로써 움직임을 분석한다. 이러한 물체의 모양에 대한 표시방법들은 물체의 기하학적인 모양에 기초를 하기 때문에 다양한 실제세계의 물체의 모양에 대한 표시가 쉽지 않다.

따라서 본 논문에서는 ART-II 신경망을 이용하여 각 물체의 영역에 대한 모양표현을 하였다. ART-II 신경망은 경쟁학습의 약점인 안정성을 보장하여 1976년 Stephen Grossberg에 의해 제안된 신경망[12]이다. ART-II의 기본적인 구조는 그림 1과 같다. Teuvo Kohonen에 의해 제안된 또 다른 경쟁학습 신경망인 자기조직화 형상지도(self-organizing feature maps)[13]는 입력영역이 불룩한 다각형의 형태가 아닌 경우 입력패턴을 대표하지 못하는 뉴런들이 생기기 쉽고 나타내려는 패턴이 복잡한 경우 적절히 나타내지 못하는 단점이 있다. 그러나, ART-

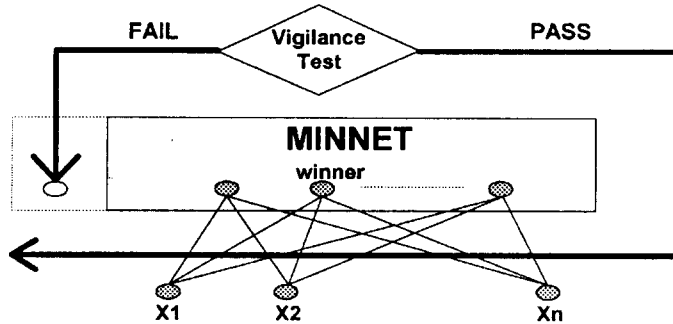


그림 1. ART-II 신경망의 구조

II 신경망은 입력패턴에 대한 비지도 학습방법(unsupervised learning)이면서 모든 뉴런들이 각 클러스터를 나타낼 수 있다. 영상내의 각 영역에 대해 ART-II 신경망을 이용하여 학습을 시키면 임계치 값 ρ 의 크기에 따라 어느 정도 일정한 반경을 갖는 클래스(class)들이 생성이 되며 이 생성된 클래스들의 중심점을 이용하여 물체의 대략적인 모양을 나타낼 수 있다.

2.4. 퍼지추론

연속된 영상에 대한 움직임 추론은 입력영상 자체의 모호성과 움직임 분석 자체의 불완전성 때문에 움직임 분석의 결과에는 항상 불확실성이 내포되어 있다. 이러한 불확실성을 나타내기 위해서 퍼지추론 방법이 사용될 수 있다. 최근의 영상인식 분야에서는 영상인식의 각 단계에서 발생할 수 있는 모호성과 불확실성을 나타내기 위하여 퍼지논리를 많이 이용하고 있다. 본 논문에서는 움직임 분석결과에 대해 어느 정도의 신뢰도를 부여할 것인지를 결정하기 위하여 퍼지추론 방법을 사용하였다. 본 논문에서는 Max-Min 추론법을 이용하였고 결과의 비퍼지화는 무게중심법을 사용하였다. 일반적인 퍼지추론 시스템의 구조는 그림 2와 같다[14].

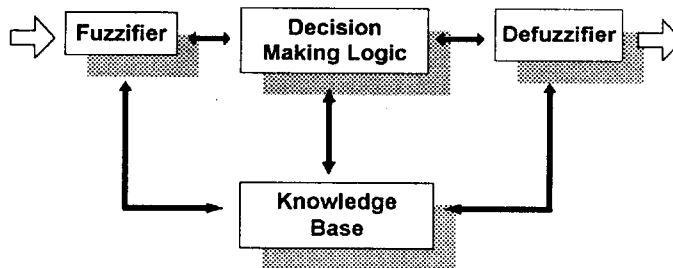


그림 2. 퍼지추론 시스템의 구조

III. 경쟁학습 신경망과 퍼지추론을 이용한 움직임 분석

연구배경에서 살펴본 바와 같이 물체에 종속적인 움직임 분석은 영상내의 물체에 관한 사전정보를 많이 가지고 있거나 사전정보가 없더라도 물체의 특징들을 잘 추출해낼 수 있다면 매우 좋은 성능을 낼 수 있다. 그러나 사전정보와 특징추출 및 분석을 위한 부분들이 많아질수록 그에 따른 움직임 분석에 시간과 노력이 많이 들고 영상에 대한 사전지식이 없는 경우가 많다. 일반적으로 이러한 문제점들을 해결하기 위하여 입력 영상에 대한 여러 제약들을 둬으로써 영상내의 물체에 대한 적은 양의 정보와 특징을 이용하여 빠른 시간 안에 움직임 분석을 수행한다.

본 논문에서는 기존의 물체에 종속적인 움직임 추정을 위해 사용되는 여러 제약들을 완화하고 물체의 표현을 간단하게 함으로써 영상내의 물체에 대한 정보가 없는 상태에서 빠른 시간 내에 움직임 추정을 수행할 수 있는 방법을 제시한다. 제안된 방법에 대한 전체적인 시스템 구성은 그림 3과 같다.

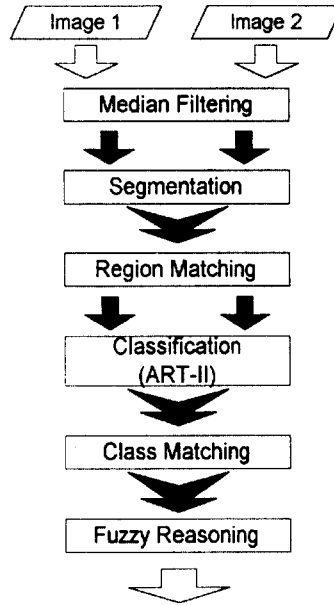


그림 3. 제안된 방법의 시스템 구성도

3.1. 영역의 평균광도 및 크기를 고려한 영역정합 방법

영역정합은 두 개의 연속적인 영상열에서 동일한 영역을 정합 시키는 과정으로서 영역정합이 완벽하게 이루어지기 위해서는 이전의 영역 분할과정에서 각각의 영역이 특성에 따라 완전하게 분할이 되어야만 한다. 그러나, 움직임 있는 영상에서는 두 입력영상에서 움직이는 물체의 위치에 따라 중첩이 발생하고 영역분할 자체의 불완전성으로 인하여 영역의 특징에 따른 완전한 분할이 이루어지기 힘들다. 따라서 움직이는 물체와 움직이지 않는 배경과의 중첩, 영역분할 과정의 오류 등을 고려하여 영역분할 과정에서 얻을 수 있는 기본적인 정보인 영역의 크기와 영역의 평균광도를 이용하여 영역정합을 수행한다.

N_n : 영상 n 의 영역의 갯수	$I_n(m)$: 영상 n 의 m 번째 영역의 평균광도
R_M : 일치된 영역	$S_n(m)$: 영상 n 의 m 번째 영역의 크기
<pre> for $i = 1$ to N_1 for $j = 1$ to N_2 if $(I_1(i) - 5 \leq I_2(j) \leq I_1(i) + 5)$ if $(S_1(i) * 0.9 \leq S_2(j) \leq S_1(i) * 1.1)$ $R_M = j$ else 움직임 분석에서 제외 </pre>	

알고리즘 1. 영역의 평균광도 및 크기를 고려한 영역정합 알고리즘

이러한 두 가지 기준에 의해 정합 되는 영역이 발견되지 않는다면 이 영역은 모호성을 갖는 영역이라고 할 수 있고 이러한 영역들을 움직임 분석에 이용하면 그에 대한 결과도 모호성을 가지므로 이후의 움직임 분석과정에서 제외한다.

3.2. 클래스정합 방법

본 논문에서는 영역정합 과정을 통과한 분할된 영역들의 모양 즉, 특징점들을 찾기 위하여 ART-II 경쟁학습 신경망을 이용하였다. ART-II를 이용하여 생성되는 클래스들의 중심점을 해당 영역에 대한 특징점으로 삼았다. 시간 t일 때 구해진 특징점들을 시간 t+1일 때 구해진 특징점과 어떤 식으로 정합을 시킬 것인가를 결정하는 것이 클래스정합 과정이다. 클래스정합 과정을 통해 특징점들의 움직임 벡터를 구하여 영역전체에 대한 움직임 분석을 한다. 여기서는 이에 관한 방법들을 살펴보고 어떤 것이 가장 적합한지를 보인다.

3.2.1. 영역의 중심점을 이용한 정합 방법

이 방법은 시간 t일 때의 영상과 시간 t+1일 때의 영상에 대하여 영역정합 과정을 통과한 영역들의 각각의 중심점을 구하고 그 영역과 정합 되는 영역의 중심점과의 차이를 계산함으로써 각 영역에 대한 움직임 벡터를 구한다. 이 방법은 중첩이 발생하는 배경의 경우 올바른 결과를 얻기 힘든 단점이 있다.

3.2.2. 영역내의 클래스의 번호를 이용한 정합 방법

이 방법은 ART-II 신경망을 통하여 생성된 뉴런들의 번호를 특징점으로 사용한다. ART-II 신경망은 입력 패턴에 따라 뉴런들을 생성하기 때문에 입력 패턴이 비슷한 경우 동일한 순서로 뉴런들이 생성된다. 이러한 특성을 이용하여 시간 t일 때 영역내의 뉴런들의 번호를 이용하여 시간 t+1일 때 영역내의 뉴런들을 정합 시킨다. 그러나, 일반적으로 동일한 물체라도 영상분할 과정에서 약간씩의 변형이 생길 수 있으며 특히 배경과 같이 중첩이 발생하는 지점에서는 두 영역의 모양이 변하게 되면 학습결과도 달라지므로 문제점이 있다.

3.2.3. 영역중심에 대한 클래스의 상대적 위치를 고려한 정합 방법

클래스들은 그 클래스가 속해 있는 영역내에서 정의되고 클래스의 중심점은 뉴런으로 표시된다. 뉴런들이 영역의 모양을 나타내는 특징점들이 되기 위해서는 영역 내에서 뉴런들이 어떠한 모양을 갖는지를 나타낼 필요가 있다. 이러한 구조를 나타내기 위하여 Tree구조나 Graph구조를 이용하여 나타낼 수 있다. 본 논문에서는 영역의 중심점에 대한 상대적인 위치를 이용함으로써 영역내의 뉴런들이 갖는 특징을 표현하였다. 뉴런들의 이러한 특징을 이용하여 영역정합된 영역내의 클래스들을 정합 시킨다. 이 방법에 대한 알고리즘은 다음과 같다.

```

Classnumi      : i번째 영역내의 클래스의 개수
RELk          : 클래스 k의 중심점에 상대적인 클래스 위치
NR           : 영상내의 영역의 개수      RCij(x, y) : 영상j의 영역i의 중심점
Neuronk(x, y) : 뉴런 k의 중심값          Γi(x, y)   : 영역 i의 움직임 벡터
VELkC(x, y)  : 클래스 k의 움직임 벡터    VELkR(x, y) : 영역 k의 움직임 벡터

for i = 1 to NR
  if(Region i is valid)
    begin
      for k = 0 to Classnumi
        begin
          RELk = Neuronk(x, y) - RCi1(x, y)
        end
      end
    end
  end

```

$$\begin{aligned}
 Match_{class} &= \underset{m \in Region_2}{Min} [REL_m - REL_k] \\
 VEL_k^c(x, y) &= REL_{Match_{class}} - REL_k \\
 end \\
 VEL_i^k(x, y) &= \sum_{n=0}^{Class_{num}^k} \frac{VEL_k^c(x, y)}{Class_{min}^k} \\
 end
 \end{aligned}$$


알고리즘 2. 영역중심에 대한 클래스의 상대적 위치를 고려한 클래스 정합 방법

ART-II 신경망을 이용한 영역의 표현은 임계치 α 에 따라 클래스의 정합에 걸리는 시간이 차이가 난다. 임계치 α 값을 아주 작게 주면 영역을 매우 많은 수의 클래스들로 나누고 그에 대한 정합을 수행하기 때문에 클래스정합 과정에 시간이 많이 걸린다. 반면, 임계치 α 값을 아주 크게 주면 효과를 지니며 상대적으로 적은 시간 안에 정합 과정을 수행할 수 있다. 따라서 임계치 α 를 적절한 값으로 선택해야만 적절한 시간 내에 적절한 결과를 보장할 수 있다.


3.3. 퍼지추론을 이용한 신뢰도의 표현

클래스정합 과정의 결과는 각 클래스의 움직임 벡터와 움직임 방향이다. 영상의 좌측상단을 원점으로 하여 우측방향을 COL+, 좌측방향은 COL-, 아래방향은 ROW+, 윗방향은 ROW- 등으로 표시하고 움직임이 없는 클래스는 ROW_ZERO, COL_ZERO 등으로 표시하였다.


퍼지추론에서는 ROW와 COL방향에 대해 각각 추론을 하며 퍼지입력변수는 NEG, ZERO, POS로 구성된다. ROW+와 COL+의 전체 클래스의 개수에 대한 비율은 각각 POS에 대응되고, ROW-와 COL-의 전체 클래스에 대한 비율은 각각 NEG에 대응되며, ROW_ZERO와 COL_ZERO의 전체 클래스에 대한 비율은 ZERO에 대응된다. 즉, 퍼지입력변수 NEG, ZERO, POS는 [0, 1]의 범위 내에서 정의된다. 퍼지입력변수들은 각각 N(Negative)와 P(Positive) 두개에 대한 퍼지소속함수를 갖고 추론결과는 퍼지변수 DIR(Direction)을 통해 나타내지며 DIR은 L(Left), ZERO, R(Right) 등에 대한 퍼지소속함수를 갖는다. NEG, ZERO, POS, DIR에 대한 퍼지소속함수의 정의는 그림 4와 같다.



(a) 퍼지입력변수 POS, NEG의 퍼지소속함수



(b) 퍼지입력변수 ZERO의 퍼지소속함수



(c) 퍼지출력변수 DIR의 퍼지소속함수

그림 4. 퍼지입출력 변수에 대한 퍼지소속함수의 정의

퍼지추론을 위한 퍼지규칙(fuzzy production rule)들은 지식베이스(knowledge base)를 구성하며 이러한 규칙들은 전문가의 지식 또는 실험 및 경험을 통해 얻어진다. 본 논문에서는 움직임 분석을 위해 다음과 같은 퍼지규칙들을 정의한다.

규칙 1: *If NEG = N, ZERO = N, POS = P then DIR = R*

규칙 2: *If NEG = N, ZERO = P, POS = N then DIR = ZERO*

규칙 3: *If NEG = P, ZERO = N, POS = N then DIR = L*

규칙 4: *If NEG = N, POS = N then DIR = ZERO*

위의 규칙들은 여러 가지 영상에 대해 영역정합 방법의 특성, 즉 ART-II의 임계치 α 값에 대한 실험 및 특성을 기초로 하여 얻어진다.

퍼지추론의 결과로 얻어진 출력변수에 대한 퍼지소속함수를 무게중심법을 이용하여 비퍼지화 값 DF를 구하고 이를 이용하여 하나의 확실한(crisp)한 값인 $[-1, 1]$ 사이의 실수값으로 표현되는 신뢰도(belief degree)를 다음의 식에 의해 구한다.

$$Bel = DF \cdot 2.0 - 1.0$$

Bel의 값이 -1에 가까울수록 -쪽의 움직임을 나타내고 1에 가까울수록 +의 움직임을 나타내며 0에 가까울수록 움직임이 없음을 나타낸다.


IV. 실험결과 및 분석

본 논문에서 제안된 방법의 실험을 위해 CCD 카메라를 이용하여 촬영된 연속적인 영상들을 Image Grabber를 이용하여 연속적인 영상열로 만든 후 제안된 방법의 입력으로 사용하였다. 입력영상들은 312×215 의 크기를 갖고 128단계의 명암도를 갖는다. 제안된 방법은 Sun Sparc Classic 워크스테이션 상에서 실험되었다.

이 실험은 실제도로의 영상에 대해서 영역성장 방법을 이용하여 영상을 분할한 후 영역의 평균광도 및 크기를 고려한 영역정합 방법과 영역중심에 대한 클래스의 상대적 위치를 고려한 클래스정합 방법을 이용하여 입력 영상열에 대한 움직임 분석 결과를 나타낸 것이다. 움직임 분석의 목적은 실제 영상에서 움직이는 물체 영역에 대한 움직임 벡터 및 신뢰도를 구하는 것이다.




(a) 입력영상1



(b) 입력영상2

그림 5. 입력영상열

그림 7에서 검은 색으로 표시된 부분이 표 2의 영역정합 과정에서 제외된 부분들이다. 제외된 부분들은 중첩된 배경의 차선들과 빛의 반사에 의해 영역의 모양이 변하는 부분들임을 알 수 있다. 반면 영상에서 움직임 분석에 중요한 정보를 가지고 있는 영역들은 영역정합 과정에서 대부분 통과하였음을 알 수 있다. 영역정합된 각 영역들에 대한 클래스정합 과정과 퍼지추론을 이용한 움직임 분석결과는 표 3과 같다.



(a) 입력영상1의 영상분할

(b) 입력영상2의 영상분할

그림 6. 입력영상열 3의 영상분할



그림 7. 입력영상열 3의 영역정합 과정에서 제외된 영역의 표시

표 1. 입력영상열의 영역의 특성

(a) 영상1

영역	평균광도	크 기
1	22	430
2	88	48787
3	34	6199
7	37	8196
9	36	596
13	81	253
15	37	535
17	119	1458

(b) 영상2

영역	평균광도	크 기
1	23	430
2	90	42118
3	35	6160
8	37	598
11	37	9610
14	39	573
17	80	251
20	120	1495

표 2. 영역정합 결과

영상 1 영역	영상 2 영역
1	1
2	2
3	3
7	11
9	8
13	17
15	14
17	20

표 3. 클래스정합 및 퍼지추론 결과

(a) 도로영역

영역 2	영상 1	(115.47, 174.58)	
중심점	영상 2	(100.20, 167.60)	
총 클래스의 개수		722	
	ROW	COL	
NEG	277	441	
ZERO	60	57	
POS	285	124	
NOT	100	100	
움직임 벡터		-1.27	-5.80
DF		0.50	0.50
BEL		0.0	0.0

(b) 정지한 자동차 영역

영역 3	영상 1	(37.16, 76.25)	
중심점	영상 2	(36.01, 76.51)	
총 클래스의 개수		98	
	ROW	COL	
NEG	39	55	
ZERO	1	0	
POS	54	39	
NOT	4	4	
움직임 벡터		0.37	0.05
DF		0.50	0.50
BEL		0.0	0.0

(c) 이동 자동차 영역

영역 7	영상 1	(102.51, 136.57)	
중심점	영상 2	(137.26, 103.14)	
총 클래스의 개수		128	
	ROW	COL	
NEG	0	128	
ZERO	0	0	
POS	128	0	
NOT	0	0	
움직임 벡터		35.53	-34.01
DF		0.94	0.06
BEL		0.87	-0.87

영역 13	영상 1	(104.71, 144.58)	
중심점	영상 2	(140.19, 109.09)	
총 클래스의 개수		7	
	ROW	COL	
NEG	0	6	
ZERO	0	0	
POS	6	0	
NOT	1	1	
움직임 벡터		36.76	-35.03
DF		0.936	0.06
BEL		0.87	-0.87

(d) 나무영역

영역 9	영상 1	(70.71, 307.97)	
중심점	영상 2	(71.16, 308.62)	
총 클래스의 개수		11	
	ROW	COL	
NEG	7	8	
ZERO	0	0	
POS	4	3	
NOT	0	0	
움직임 벡터		0.45	0.66
DF		0.49	0.26
BEL		-0.03	-0.49

영역 15	영상 1	(138.62, 314.99)	
중심점	영상 2	(136.04, 314.96)	
총 클래스의 개수		9	
	ROW	COL	
NEG	8	5	
ZERO	0	0	
POS	1	4	
NOT	0	0	
움직임 벡터		-1.69	-0.19
DF		0.06	0.50
BEL		-0.87	0.0

위의 움직임 분석결과에서 대표적인 배경영역인 도로의 움직임 벡터는 (-1.27, -5.80)으로 움직임 추정이 되지만 퍼지추론을 이용한 신뢰도의 표현에서 매우 높은 신뢰도를 가지고 정지영역으로 분류가 되었다. 또한 정지한 자동차 영역인 영역3도 매우 높은 신뢰도를 가지고 정지영역으로 분류가 되었다.

이동 자동차 영역인 영역7과 영역13은 모두 매우 높은 신뢰도를 가지고 움직임 영역으로 분석되었으며 이 두 영역의 움직임 벡터는 거의 동일하다.

입력영상의 우측하단에 있는 나무의 영역인 영역9와 영역15는 실제의 두 입력 영상열에서 바람의 영향으로 부분적으로 미세한 움직임이 있었고 움직임 분석 결과인 움직임 벡터도 약간의 움직임이 나타난다. 그러나 이에 대한 신뢰도 표현은 표 3 (c)와 같이 매우 낮은 수준으로서 정지영역의 성격이 더 강한 것으로 나타난다.

V. 결 론

본 논문에서는 인간의 움직임 분석방법과 유사한 경쟁학습 신경망과 퍼지추론을 이용한 움직임 분석방법을 제안하고 이를 실제영상에 적용해보았다. 제안된 방법은 움직임 분석을 위해 사용되는 정보가 각 영역에 대한 크기와 평균광도로서 영상의 분할과정에서 얻을 수 있는 기초적인 정보들을 이용하여 움직임 분석을 수행하였다.

제안된 움직임 분석방법은 입력영상의 영상분할 방식에 따라 움직임 분석 능력이 많이 좌우되었으며 분할 및 병합 방식보다는 영역성장 방식이 애매한 움직임을 나타내는 영역에 대해 좀 더 나은 성능을 나타내었다. ART-II 경쟁학습 신경망을 이용한 영역의 특징점 추출 방법은 물체의 모양에 대한 사전 지식이 없이도 임의의 형태를 갖는 영역의 모양을 나타내기 위한 특징점들을 비교적 쉽게 얻을 수 있다는 점에서 유용하다. 또한 움직임 추정 결과에 대해 퍼지추론을 함으로써 영상분할 과정과 2차원적 영상자체의 모호성에서 올 수 있는 오류를 줄이도록 하였다. 이러한 방법은 나무, 구름 등과 같이 국부적으로 산발적인 움직임이 있는 영역들의 움직임 분석에 대한 오류를 줄일 수 있는 장점이 있다.

실제 임의의 영상들에 대한 보다 나은 움직임 분석을 위해서는 영상내의 물체들에 대한 표현 방법 및 정합 방법에 대한 방법들이 개선되어야 한다. 또한 움직임 분석 대상이 강체의 성질을 갖지 않고 변형이 가능한 물체의 경우에 대한 움직임 분석방법이 필요하며 궁극적으로는 2차원적 움직임을 이용한 3차원적인 정보의 추출과 물체의 인식에 대한 연구가 필요하다.

참 고 문 헌

1. Snyder, W. E. "Computer analysis of time varying images," *IEEE Computer* Vol. 14, 8, August, 1981.
2. Dana H. Ballard, Christopher M. Brown, *Computer Vision*, Prentice-Hall, pp. 195-225, 1982.
3. S. H. Courellis and V. Z. Marmarelis, "An Artificial Neural Network for Motion Detection and Speed Estimation," *IEEE International Joint Conference on Neural Networks*, Vol. I, pp. 407-421, 1990.
4. S. H. Courellis and V. Z. Marmarelis, "Velocity Estimators of Visual Motion in Two Spatial Dimensions," *IEEE International Joint Conference on Neural Networks*, Vol. III, pp. 72-83, 1992.
5. William K. Pratt, *Digital Image Processing*, Wiley-interscience publication, Newyork, pp. 629-647, 1991.
6. Ioannis Pitas, *Digital Image Processing Algorithms*, Prentice Hall, pp. 254-297, 1993.
7. R. Jain, "Difference and accumulative difference pictures in dynamic scene analysis," *Image and Vision Computing*, Vol. 2(2), pp. 99-108, 1984.
8. Milan Sonka, Vaclav Hlavac and Roger Boyle, *Image Processing, Analysis and Machine Vision*, Chapman & Hall Computing, pp. 512-542, 1993.
9. R. Mehrotra and S. Nichani, "Corner detection," *Pattern Recognition Letters*, Vol. 23(11), pp. 1223-1233, 1990.
10. Price, K. E., and Reddy, "Change detection and analysis in multi-spectral images," *Proceedings of 5th International Joint Conference on Artificial Intelligence*, pp. 619-625, August, 1977.
11. Jain, R and H. H. Nagel, "On a motion analysis process for image sequences from real world scenes," *Proceedings of IEEE Workshop on Pattern Recognition and Artificial Intelligence*, Princeton, NJ, 1978.
12. Gail A. Carpenter and Stephen Grossberg, "ART-2: Self-organizing of stable category recognition codes for analog input patterns," *Applied Optics*, Vol. 26(23), pp. 4919-4930, December, 1987.
13. T. Kohonen, "Self-organized formation of topologically correct feature maps," *Biological Cybernetics*, pp. 59-69, 1982.
14. Mamdani, E. H, "Applications of fuzzy logic to approximate reasoning," *IEEE Transactions on Computer*, Vol. 26, pp. 1182-1191, 1977.