

뉴럴네트워크를 이용한 축구경기에 있어서의 공격패턴 자동분류 기법

(Automatic Classification Technique of Offence Pattern in
Soccer Game using Neural Networks)

김현숙^{*} 김광용^{**} 남성현^{***} 황종선^{****} 양영규^{*****}
(Hyun Sook Kim) (Kwang Yong Kim) (Sung Hyun Nam) (Chong Sun Hwang) (Young Kyu Yang)

요약 본 논문은 팀 스포츠(team sports)의 일종인 축구경기 하이라이트 장면의 자동색인을 위해 뉴럴네트워크 기법을 이용하여 그룹 포메이션(group formation) 중의 공격패턴 자동분류 기법을 개발하고 이를 검증하였다.

본 연구에서는 축구경기의 대표 프레임 상에서 선수들과 공의 위치정보를 추출하고 그룹 포메이션 정보를 기초로 뉴럴네트워크의 BP(Back-propagation) 알고리즘을 사용하여 축구경기 하이라이트 장면의 자동추출을 위한 공격패턴 자동분류 기법을 개발 및 검증하였다. 또한, 실험에는 '98 프랑스 월드컵 축구경기의 다양한 공격패턴에 대한 비디오 영상에서 각각 좌측공격 60개, 우측공격 74개, 중앙공격 72, 코너킥 39, 프리킥 52개의 총 297개의 데이터를 추출하여 사용하였다. 실험결과는 좌측공격 91.7%, 우측공격 100%, 중앙공격 87.5%, 코너킥 97.4%, 프리킥 75%로서 매우 양호한 인식률을 보였다.

Abstract In this paper, we suggest and test a classification technique of offence pattern from group formation to automatically index highlights of soccer games. A BP (Back-propagation) neural nets technique was applied to the information of the position of both the player and the ball on a ground, and the distance between the player and the ball to identify the group formation in space and time. The real soccer game scenes including '98 France World Cup were used to extract 297 video clips of various types of offence patterns; Left Running 60, Right Running 74, Center Running 72, Corner-kick 39 and Free-kick 52. The results are as follows : Left Running comes to 91.7%, Right Running 100%, Center Running 87.5%, Corner-kick 97.4% and Free-kick 75%, and these showed quite a satisfactory rate of recognition.

1. 연구배경 및 연구사례

1.1 연구배경

· 본 연구는 한국과학재단 특정기초연구(97-01-02-01-01-3)지원으로 수행되었음.

* 정회원 : 신성대학 컴퓨터계열 교수
khyuns@shinsung.ac.kr

** 비회원 : 한국전자통신연구원 영상처리연구부 연구원
kykim@computer.etri.re.kr

*** 비회원 : 두원공과대학 소프트웨어개발과 교수
shnam@doowon.ac.kr

**** 종신회원 : 고려대학교 컴퓨터학과 교수
hwang@disys.korea.ac.kr

***** 정회원 : 한국전자통신연구원 영상처리연구부 연구원
ykyang@etri.re.kr

논문접수 : 1999년 9월 27일

심사완료 : 2000년 5월 26일

멀티미디어 환경이 우리 생활 속에 깊숙히 정착하면서 영상처리 기술의 발전이 더욱 급속하게 이루어지고 있다. 이러한 영상처리 기술은 인간의 인체와 관련하여 얼굴인식, 제스처 인식에 관한 응용과 더불어 스포츠 관련 분야로도 이어지고 있고[1], 서기 2002년 월드컵 경기를 앞두고 축구경기 분석에 관한 연구가 많은 관심을 불러일으키고 있다. 그러나 입력 영상으로부터 움직이고 있는 선수들을 추출·추적하는 일은 컴퓨터비전 연구의 난 문제중의 하나로 알려져 있다[1]. 이러한 축구경기의 TV 중계에 있어서 하이라이트 장면의 자동추출(자동색인)은 그 경기의 가장 집약적인 표현이며, 축구경기 전체를 한눈에 파악 할 수 있도록 해주는 요약(summaries)이자 intensive actions이고 경기의 진수이다[4]. 따라서 축구경기와 같이 비교적 긴 시간(대체로 1시간

30분 이상) 동안 다수의 선수(양 팀 합해서 22명)들이 경기장 내에서 복잡하게 뒤얽히면서 벌이는 경기의 경우, 하이라이트 장면을 효과적으로 포착하여 표현해 주는 일은 매우 중요한 일로서, TV를 통해서 경기를 관람하는 시청자들에게는 경기의 진행상황을 한눈에 효과적으로 파악할 수 있게 해주어 지루하지 않은 경기 관람을 가능하게 하고, 경기 진행자들(감독, 코치, 선수 등)에게는 고차원적이고 과학적인 정보를 제공함으로써 보다 진보된 경기기법을 개발하고 과학적인 경기전략을 세울 수 있게 해준다.

또한 축구경기 하이라이트 장면은 경기의 길이에 비해 비교적 짧은 순간에 포착되고, 전체 경기를 통해서 동일한 장면은 거의 찾아볼 수가 없다. 따라서 운동경기 관리에 있어서 특정 경기의 비디오 라이브리리에 대한 검색 및 조회시에 매우 효과적인 브라우징 기법(Browsing Mechanism)이 될 수 있다[4].

1.2 연구사례

축구경기 하이라이트 장면의 자동색인을 위한 그룹행동이나 팀워크(team-work)과 관련된 논문[1]~[9]들이 다수 발표되고 있으나, 대부분 개인별 선수의 동작인식에 머무르고 있고, 팀워크이나 그룹행동과 관련된 내용들은 비교적 드문 편이며, 특히 공격패턴 분류기법에 관해서는 제안되고 있지 않다. 개인별 선수들의 개별동작의 인식에 비해 그룹이나 팀워크를 고려한 그룹행동 인식이나 공격패턴 분류의 경우는 선수동작은 물론이고 그룹 멤버들의 위치정보를 이용하여 무작위로 형성되는 선수들의 그룹정보 및 선수 유니폼의 색상정보까지를 고려해야 하기 때문에 선수 개인동작의 인식에 비해서 더욱 난해한 문제에 속한다[1].

기존의 연구 종에서 팀워크이나 그룹 행동의 분석 및 평가에 관련된 연구에는 국내의 경우, 포항공대에서 연구가 이루어지고 있으나[12][13], 아직은 공의 궤적계산이나 개인별 선수의 동작인식에 중점을 두고 있다. 일본의 경우는 축구경기 분석을 위한 개체의 동작인식과 더불어 그룹행동의 인식에 관한 연구가 활발하게 진행되고 있다. 또한 미국의 MIT에서도 많은 연구가 이루어지고 있으나 축구(soccer) 보다는 미식축구(football)의 포메이션에 관한 연구[14][15]가 주류를 이루고 있으며 실용적인 응용에 적용이 가능할 정도로 많은 진전을 보고 있다. 다음은 축구경기의 하이라이트 장면 자동색인을 위한 팀워크이나 그룹행동에 관련된 내용들이다.

(1) Gawashima[1]의 color histogram backprojection[11],[12]을 이용한 축구선수들의 그룹행동(group behavior) 분석에 관한 연구.

(2) Taki[2],[3]의 고정된 여러대의 카메라에서 촬영한 축구경기 영상에 대해 집단행동 중에 각 선수들이 만드는 일종의 세력범위(motion trajectories; 공 패스를 유지하기 위한 동작, 또는 팀워크)를 특징량으로 하여 집단행동을 분석하는 연구.

(3) Yow[4]의 모자이크 기법을 이용하여 입력 영상 열로부터 파노라mic 영상을 생성하여 축구경기 하이라이트 장면을 생성하는 방법에 관한 연구.

여기서, (1)은 양 팀 선수들의 유니폼의 색상 정보를 기초로 전체적인(multi-scale)분석을 통해 그룹의 동작을 분석하고 있으나, 그룹의 동작보다는 선수 개인의 개체동작 인식에 중점을 두고 있고 선수들의 상대적 위치관계가 고려되고 있지 않다. (2)는 선수들의 동작을 그룹으로 평가하기 위해 우세영역(dominant area)이라는 특징량(prominent feature)을 정의하고 팀 전체의 동작 및 선수 개인의 동작을 정량화하여 팀 플레이(team play)를 분석 및 평가하고 있으나, 옆에서 본(촬영된) 영상을 사용하고 있고 지역적인 정보에 치우치고 있어서 카메라의 움직임에 따른 보정의 어려움으로 인해 전체적인 경기의 흐름이나 그룹 포메이션 정보의 정확한 획득에는 한계가 있다.

이밖에도 Collins[5], Bobick[6], Gong[7], Yoshida[8], Iwasa[9] 등이 있으나 이들 연구 역시 각 선수들이 만드는 상호 연관적인 동작의 특징에 기초한 그룹 포메이션 보다는 선수 개인의 인식에 그치고, 2차원 화상 상에서의 분석에 머무르고 있다. 또한 축면에서 촬영한 영상 만을 사용하고 있어서 카메라의 움직임에 따른 보정이 어렵고 동일 장면이라 하더라도 배경이 바뀌면 다른 장면으로 잘못 인식할 수 있는데, 그에 대한 대책이 강구되어 있지 않다. 또한 선수와 공의 위치 등을 추적하기 위해 컬러 기반(color base) 기법[17]~[20]을 토대로 특징점에 기초해서 입력영상을 경기장 모델로 변환하고 실제 경기장 상에서의 위치로 대응시키는 연구도 많은 연구자들의 관심을 끌고 있다.

본 논문에서는 [10]에서와 같은 공간관계의 정성적 분석을 기반으로 시공간상에서 창출된 그룹 포메이션을 기초로 축구경기의 하이라이트 장면을 뉴럴네트워크 기법을 토대로 자동으로 추출하기 위한 공격패턴 분류 방법에 대해서 기술한다.

2장에서는 축구경기의 포메이션에 대한 정의와 경기의 전술에 대해서 설명하고, 3장에서는 그룹 포메이션 및 공격패턴을 정의하고, 공격패턴 분류를 위한 뉴럴네트워크의 구조와 알고리즘을 설명한다. 4장에서는 실험 및 평가에 있어서의 문제점을 분석하고 실험결과를 평

가하여 본 논문에서 제안한 방법의 유효성을 보이고, 5장에서 결론을 맺는다.

2. 축구경기의 전술 및 전략

축구경기는 1863년 영국에서 최초로 시작된 이래 수많은 전법이 개발되면서 꾸준히 발전해 온 경기로서 축구경기는 상황판단의 경기라고 할 수 있으며, 적군과 아군이 복잡하게 뒤섞여서 한 개의 공을 다투는 경기이다. 이렇듯 예측이 불허한 상황 속에서 승리를 목표로 양 팀 선수들은 다양한 전술이나 전략을 사용하게 된다. 따라서 이러한 양 팀의 승리를 겨냥한 갖가지 동작을 전체적인 또는 부분적인 측면에서 관측하는 것이 포메이션이며, 포메이션 중의 공격패턴들을 인식하고 분류하는 일이 축구경기 하이라이트 장면의 자동색인을 위해서는 필수적인 요소이다.

표1은 다양한 축구경기 전법을 보여주고 있다. 표1의 여러 가지 전법 중에서 현재 가장 널리 사용되고 있는 전법은 2-3-5, 4-2-4, 4-3-3, 4-4-2, 3-5-2, 3-4-3 전법 등이다.

아래의 그림1과 그림2는 1992년 바로셀로나 올림픽에서 우승을 거둔 파라과이 팀의 3-4-3 전법과 스페인 팀의 3-5-2 전법을 보여주고 있다. 그림1과 그림2에서 축구경기의 포지션(position)과 기능을 알아보면, 스페인 팀과 파라과이 팀의 전법의 차이는 스페인 팀의 경우 수비형 하프의 위치에 있는 선수가 한명인데 비해 파라과이 팀은 2명이라는 점이다. 스페인 팀의 하프진은 9번이 아래쪽에 위치하고, 7번과 8번이 양 사이드의 위쪽에 위치하게 되는데, 파라과이 팀의 하프진은 7번과 8번이 양 사이드의 위쪽에 위치하며, 9번은 정 중앙에서 위치

표 1 축구경기 전법의 흐름

연도	전법	내 용
1863~1900	1-1-8 전법 1-2-7 전법	forward 진에 많은 인원을 배치
1900년대	2-2-6 전법 2-3-5 전법	pass기술의 발전에 따라 수비진의 인원 배치가 중요시 됨
1925~1958	3-2-2-3 전법	three full back 시스템이 유행
1958년 이후	4-2-4 전법	World Cup에서 브라질 팀이 4-2-4 전법을 사용하여 눈길을 끌었다.
1960년대	4-3-3 전법 1-4-2-3 전법 1-4-3-2 전법	4-3-3전법과 Sweeper를 배치한 1-4-2-3 전법 및 1-4-3-2 전법이 유행
1970년대	4-4-2 전법	현재까지 많이 사용되는 전법
1980~1990년대	3-5-2 전법 3-4-3 전법	현재까지 많이 사용되는 전법

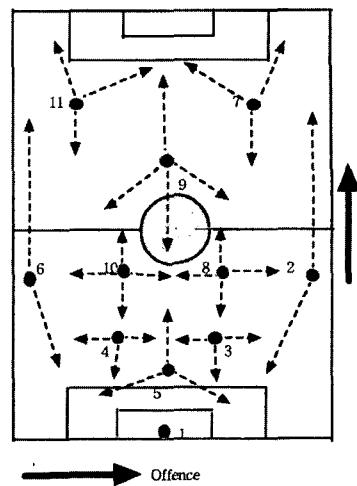


그림 1 파라과이 팀의 3-4-3 전법의 formation

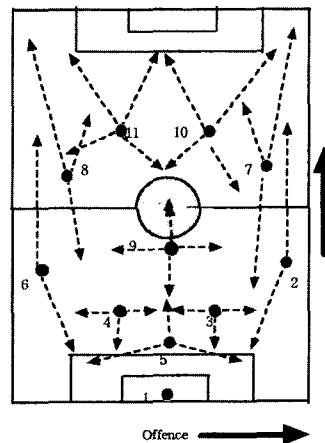


그림 2 스페인 팀의 3-5-2 전법의 formation

에 위치하여 센터포드의 역할을 하는 점이 다르다. 앞으로 이상과 같은 축구경기의 전술/전략의 자동 추출 및 분석을 위한 하이라이트 장면의 자동색인을 위해서는 그룹 포메이션 분석이 필요하며, 이를 위한 기초작업으로 공격패턴 자동 분류기법을 제안한다.

3. 뉴럴네트워크 기법을 이용한 공격패턴 분류

3.1 공격패턴 구분

비디오 영상 열(video image sequence)로부터 빈번하게 변화하는 장면들을 자동으로 분할하고, 분할된 장면에서 경기장 상황과 공 및 객체들의 위치 관계를 입력정보로 받아서 선수 및 공의 좌표를 생성하고 그 패

턴 관계를 파악하는 것이 중요하다. 또한, 축구 비디오 영상의 분류에 의해 관련된 객체들끼리의 클러스터링 (clustering)이 이루어지고, 그 내용을 기초로 포메이션에 있어서의 공격패턴을 자동으로 분류하는 것이 중요하다. 축구의 공격패턴은 다양하지만 공격수들의 위치, 공의 위치 등을 고려하면 다음의 다섯 가지로 구분할 수 있다.

▲ 좌측공격 : 공의 나가는 방향이 좌측이며, 선수들의 움직임(에너지)이 좌측으로 쏠리는 경우. (즉, 좌측으로 에너지 밀도가 높아지는 경우).

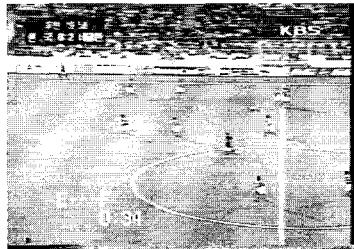
▲ 우측공격 : 공의 나가는 방향이 우측이며, 선수들의 움직임(에너지)이 우측으로 쏠리는 경우. (즉, 우측으로 에너지 밀도가 높아지는 경우).

▲ 중앙공격 : 공이 나가는 방향이 중앙이며, 선수들의 움직임(에너지)이 중앙으로 쏠리는 경우. (즉, 중앙으로 에너지 밀도가 높아지는 경우).

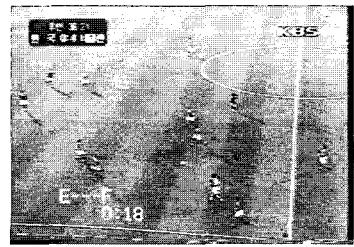
▲ 코너킥 : 공이 코너에 있고, 골(goal) 앞에 선수들의 벽이 길게 분포(고밀도의 에너지가 길게 뻗음)되는 경우.

▲ 프리킥 : 공 앞쪽에 선수들의 벽이 형성되고 골 앞에 수비수들의 벽이 형성된다.

다음 그림들은 위에서 정의한 공격패턴들을 보여준다.



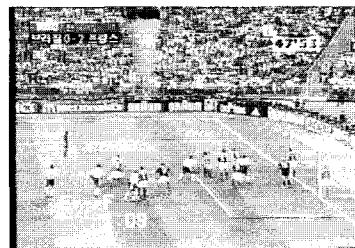
『'98 프랑스월드컵』 한국-네델란드전의 네델란드 팀의 좌측공격



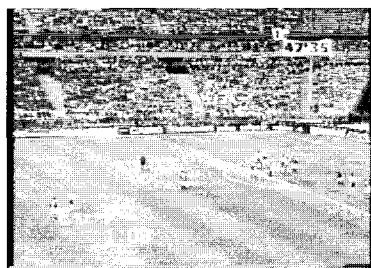
『'98 프랑스월드컵』 한국-네델란드전의 네델란드 팀의 우측공격



『'98 프랑스월드컵』 한국-네델란드전의 네델란드 팀의 중앙공격



『'98 프랑스월드컵』 브라질-프랑스전의 프랑스 팀의 코너킥



『'98 프랑스월드컵』 한국-네델란드전의 네델란드 팀의 프리킥

3.2 공격패턴의 인식 및 분류를 위한 뉴럴네트워크 구조

본 연구에서는 한 3층구조의 뉴럴네트워크 기법 중의 BP 알고리즘을 사용한다. 경기중의 어떤 공격패턴이 같은 좌측공격이나 우측공격이라 해도 시점(視點)에 따라 선수들의 위치가 달라질 수 있어서 그러한 상황을 BP 알고리즘을 사용하여 학습을 시킴으로써 최적하게 인식 할 수 있었다.

네트워크의 입력층의 뉴론(neuron)수는 국제축구협회 (FIFA : Federation Internationale de Football Association) 규정의 축구장 크기($120m \times 90m$)를 기준으로 가로 $12 \times 9 = 108$ 개, 은익층(hidden layer) 뉴론 수는 입

력층 뉴론 수의 약 1/10에 해당하는 11개, 출력층 뉴론의 수는 인식패턴의 종류가 5가지이므로 출력 뉴론의 수도 5개로 결정하여 설계했다. 그림3은 본 연구에서 사용된 뉴럴네트워크의 구조이다.

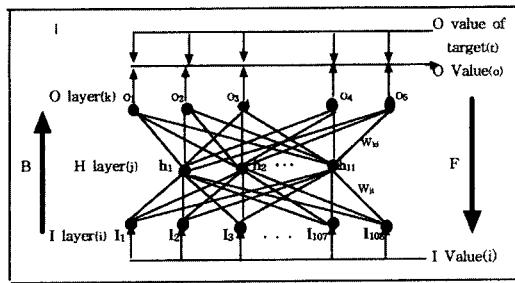


그림 3 공격패턴 분석을 위한 3층 구조의 뉴럴네트워크

축구경기 하이라이트 장면 자동색인을 위한 그룹 포메이션 분석 알고리즘의 동작과정은 다음과 같다.

단계1 : 연결강도 W_{ji} , W_{kj} 와 옵셋(offsets) θ_j , θ_k 를 각각 임의의 작은 수(-0.5~0.5 사이)로 초기화.

단계2 : 학습패턴 설정.

단계3 : 1) 학습패턴 값을 입력층 유닛에 제시하여 출력되는 값 O_{pj} , 입력층과 중간층 사이의 연결강도 W_{ji} , 중간층 유닛 j 의 옵셋 θ_j 를 이용하여 중간층 유닛 j 의 입력 net_{pj} 를 계산.

$$net_{pj} = \sum_i W_{ji} O_{pi} + \theta_j \quad (1)$$

2) net_{pj} 와 시그모이드 함수 f 를 이용하여 중간층 유닛 j 의 출력 O_{pj} 를 계산.

$$O_{pj} = f_j(net_{pj}) \quad (2)$$

단계 4 : 1) 중간층 유닛의 출력 O_{pj} , 중간층과 출력층 사이의 연결강도 W_{kj} 와 출력층 유닛 k 의 옵셋 θ_k 를 이용하여 출력층 유닛 k 의 입력 net_{pk} 를 계산.

$$net_{pk} = \sum_j W_{kj} O_{pj} + \theta_k \quad (3)$$

2) net_{pk} 와 시그모이드 함수 f 를 이용하여 출력층 유닛 k 의 출력 O_{pk} 산출.

$$O_{pk} = f_k(net_{pk}) \quad (4)$$

단계5 : 학습패턴의 목표출력 t_{pk} 와 실제 출력 O_{pk} 의 차로부터 출력층 유닛 k 에 연결된 연결강도와 출력층 유닛 k 의 옵셋에 대한 오차 δ_{pk} 계산.

$$\delta_{pk} = (t_{pk} - O_{pk}) f'_k(net_{pk}) =$$

$$(t_{pk} - O_{pk}) O_{pk} (1 - O_{pk}) \quad (5)$$

단계6 : 오차 δ_{pk} 와 중간층과 출력층 간의 연결강도 W_{kj} 와 중간층의 출력 net_{pj} 로부터 중간층 유닛 j 에 연결된 연결강도와 중간층 유닛의 옵셋에 대한 오차 δ_{pj} 계산.

$$\delta_{pj} = f'_j(net_{pj})$$

$$\sum_k \delta_{pk} W_{kj} = \sum_k \delta_{pk} W_{kj} O_{pj} (1 - O_{pj}) \quad (6)$$

단계7 : 1) 단계5에서 구한 오차 δ_{pk} , 중간층 유닛 j 의 출력 O_{pj} , 정수 α 와의 곱을 더하여 중간층 유닛 j 와 출력층 유닛 k 에 연결된 연결강도 W_{kj} 를 수정.

$$W_{kj} = W_{kj} + \alpha \cdot \delta_{pk} O_{pj} \quad (7)$$

2) 오차 δ_{pk} 와 정수 β 와의 곱을 더하여 출력층 유닛 k 의 옵셋 θ_k 를 수정.

$$\theta_k = \theta_k + \beta \cdot \delta_{pk} \quad (8)$$

단계8 : 1) 중간층 유닛 j 의 오차 δ_{pj} , 입력층 유닛 i 의 출력 O_{pi} , 정수 α 와의 곱을 더하여 입력층 유닛 i 와 중간층 유닛 j 에 연결된 연결강도 W_{ji} 를 수정.

$$W_{ji} = W_{ji} + \alpha \cdot \delta_{pj} O_{pi} \quad (9)$$

2) 오차 δ_{pj} 와 정수 β 와의 곱을 더하여 중간층 유닛 j 의 옵셋 θ_j 를 수정.

$$\theta_j = \theta_j + \beta \cdot \delta_{pj} \quad (10)$$

단계9 : 학습패턴의 끝이면 종료. 아니면, 단계2로 되돌아가서 학습을 반복한다.

3.3 공격패턴 분류 알고리즘

(1) 자동 분할된 대표 프레임의 공격패턴을 입력 정보로 이용한다.

(2) 공과 공을 가진 선수의 주변영역을 계산한다.

(3) 공을 가진 선수에게 접근하는 주변선수들의 위치를 계산한다.

(여기서, 주변이란 공을 가진 선수의 위치를 기준으로 하여 앞 뒤로 10미터 이내를 의미)

(4) 공을 가진 선수의 위치를 기초로 뉴럴네트워크 기법의 BP 알고리즘을 사용하여 이동위치 패턴을 분류 한다.

ⓐ 입력값 : 각 선수의 위치 및 공의 위치.

ⓑ 클러스터링을 기반으로 한 패턴분류.

ⓒ (1)의 입력정보를 오차와 비교.

여기서, 분할 및 추출된 장면들의 대표 프레임 상의 위치정보는 경기 진행 중에 이동변화가 크지 않다는 가정을 전제로 하고, 각 입력의 위치 패턴값을 기초로 하여 형성되는 클러스터링 결과값의 분포도를 분

석한다. 다음은 하이라이트 장면 자동추출을 위한 흐름도의 단계별 진행과정이다.

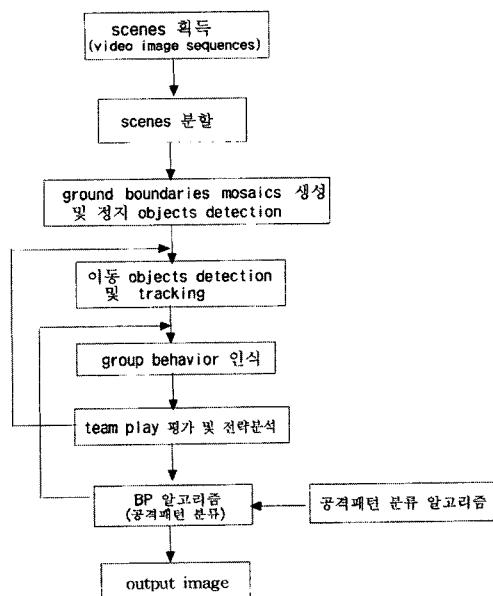


그림 9 축구경기 공격패턴 분석에 대한 흐름도

단계 1 : 비디오 영상열 획득

단계 2 : 경기장 상의 scenes 분할

단계 3 : 경기장의 경계검출 및 경기장 상의 정지 객체 검출

단계 4 : 경기장 상의 이동객체 검출 추적

단계 5 : 경기장 상의 이동객체의 그룹행동 인식

단계 6 : team play 평가 및 전략 분석 : 단계 4로 간다

단계 7 : BP 알고리즘/공격패턴 분류 알고리즘 : 단계 5로 간다(공격패턴 분류)

단계 8 : 출력 영상

이상과 같은 순서로 축구경기 하이라이트 장면의 공격패턴 자동 분류가 이루어진다.

본 연구에서는 선수와 공의 위치가 경기 장면으로부터 검출되어야 하지만 현재 방송되는 비디오 영상에 의해서는 선수의 위치의 자동측정이 실질적으로 어렵고 방대한 시간이 요하는 작업이므로 논외로 하고 대표 프레임을 분석하여 수작업으로 선수와 공의 위치를 측정하였다. 경기장의 경계검출, 선수의 추출 및 움직임 추적은 또 다른 중요한 과제로서 향후 경기장의 연구를 통하여 반드시 해결되어야 할 문제이다.

4. 실험 및 분석

4.1 실험환경

(1) 뉴럴네트워크에서의 입력층, 은의층, 출력층 뉴론(노드)의 encoding 방법

- 알고리즘 : 3층구조 뉴럴네트워크의 BP 알고리즘

- 3개 층의 뉴론배치 : 입력층 108개, 은의층 11개, 출력층 5개

- 경기장 모델의 크기 : 가로 12 × 세로 9 (가로 120 × 세로 90의 FIFA 경기장 모델의 규격을 기준으로 함)

- 입력 뉴론의 수 : 108개(경기장 모델의 x, y 좌표값을 x=12, y=9로 설정)의 뉴론 배치

- 경기장 모델에서 선수 및 공의 위치벡터 사용

- 공 및 선수의 위치벡터의 가중치 할당 방법

- { 공 = 1.0 및 공을 가진 선수 = 0.5

- { 중복되는 위치는 0.5 씩 가산해 나간다

- 가중치 할당방법에 의해 얻어진 값을 0~1 사이의 값으로 정규화(normalization)하여 학습 및 실험 데이터로 작성 축구경기 하이라이트 장면 자동추출을 위한 공격패턴 자동분석은 3층구조 뉴럴네트워크의 BP알고리즘을 사용했다. 알고리즘의 구성 및 실험에 필요한 경기장 모델은 가로 12×세로 9(실제 경기장 크기인 가로 120 ×세로 90의 FIFA 규격을 기준으로 함)로 설정했다. 따라서 경기장 모델의 x, y 좌표값은 x=12, y=9가 된다. 설정된 경기장 모델을 기반으로 하여 3개층의 뉴론의 배치는 입력층에 108개, 중간층인 은닉층에 11개, 출력층에 5개를 배치했다. 여기서, 입력층의 뉴론수는 경기장 모델의 크기를 기준으로 했다. 은닉층의 뉴론수는 다양한 실험을 통해서 경험적으로 얻어진 값을 기준으로 11개의 뉴론(입력층 뉴론 수의 약 10분의 1에 해당)을 배치했다. 마지막으로 출력층의 뉴론의 개수는 인식패턴의 수가 5가지이므로 5개를 배치했다. 5개의 뉴론을 각각은 좌측공격, 우측공격, 중앙공격, 코너킥, 프리킥 등 5가지 공격패턴을 인식하고, 표현하기 위해서이다.

이상과 같은 환경 설정을 기반으로 경기장 모델에 표현된 선수 및 공의 위치벡터 값은 실험에 의해서 경험적으로 얻어진 최적한 값을 다음과 같이 부여한다. 공=1.0, 공을 가진 선수=0.5, 중복되는 위치=0.5와 같이 위치벡터 값을 가산해 나간다. 또한 가중치 할당 방법에 의해 얻어진 값을 0과 1사이의 값으로 정규화하여 학습 및 실험 데이터로 사용했다. 다음 그림10.은 FIFA 규격의 경기장 모델이다.

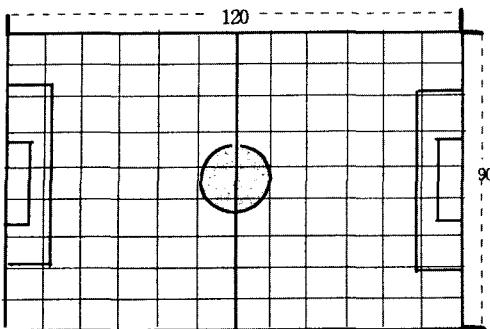


그림 10 FIFA 규격의 경기장 모델

(2) 학습 및 실험데이터 추출방법

공격패턴으로는 좌측공격, 우측공격, 중앙공격, 코너킥, 프리킥 등의 5종류를 사용하였는데, 이유는 다양한 축구 패턴들 중에서 이 5종류의 공격패턴들이 비교적 특징점 추출이 용이하면서도 경기의 흐름파악이 쉽고 득점취득에 중요한 영향을 미칠 뿐만 아니라, 축구 경기 포메이션 식별을 명확하게 할 수 있고 공격패턴 분류가 용이하기 때문이다. 다음은 실험 데이터의 추출내용이다.

◇『98 프랑스 월드컵』 경기의 3-4위 전

▲ 프랑스-크로아티아 전 : 좌측공격 5 장면, 우측공격 5 장면,

중앙공격 5 장면, 코너킥 4 장면, 프리킥 5 장면

▲프랑스-브라질 전 : 좌측공격 5 장면, 우측공격 6 장면,

중앙공격 7 장면, 코너킥 5 장면, 프리킥 5 장면

▲한국-벨기에 전 : 좌측공격 5 장면, 우측공격 7 장면,

중앙공격 7 장면, 코너킥 5 장면, 프리킥 5 장면

▲한국-네델란드 전 : 좌측공격 5 장면, 우측공격 7 장면,

중앙공격 5 장면, 코너킥 2 장면, 프리킥 2 장면

◇『99 바이코리아 컵』

▲전남-수원 전 : 좌측공격 5 장면, 우측공격 5 장면, 중앙공격 7 장면, 코너킥 2 장면, 프리킥 5 장면

◇『한-일 프로축구 정상 전』

▲대우-베르디 전 : 좌측공격 5 장면, 우측공격 7 장면,

중앙공격 7 장면, 코너킥 2 장면, 프리킥 4 장면

4.2 실험방법

(1) 학습환경을 위한 encoding 방법

코너킥을 제외한 4가지 공격패턴(좌측공격, 우측공격,

중앙공격, 프리킥)의 학습 데이터는 각각 20개씩 설정하고, 코너킥은 4개의 모서리에서 대표 패턴이 발생할 수 있어서 40개의 학습 데이터를 설정하였다. 학습에 사용되는 학습데이터의 수는 120개($20+20+20+20+40$)이며, 인식의 결과값에 있어서는 5개의 패턴 중에서 가장 큰 값을 가진 출력값을 인식유형으로 한다. 단, 그 값이 0.1 이하이면 인식 못한 것으로 판단한다.

(2) 실험환경을 위한 encoding 방법

실험 데이터의 경우는 팀별로 구별된 인식패턴 좌측공격(30상=60개), 우측공격(37상=74개), 중앙공격(36상=72개), 코너킥(19.5상=39개), 프리킥(26상=52개) 등 총 297개(60개 + 74개 + 72개 + 39개 + 52개)를 사용했다. 또한 실험 환경의 범위설정을 위한 실험인자 값은 오차허용 범위는 0.001(한 사이클 당 1개 패턴의 평균오차), 학습상수는 0.001, 학습가속 인자값(모멘텀 : 학습속도 개선 인자)은 0.001, 오차탈출 인자값(지역 최소값에서 탈출하는 범위)은 0.001, 최대 학습횟수는 15000번으로 설정하여 실험을 수행했다.

(3) 가중치 부여 방법

특정 장면의 대표 프레임에서 각 객체(각 선수들, 공 등)들의 위치좌표 값 및 제약조건은 공의 위치좌표 값으로 ++1.0, 선수의 위치좌표 값으로는 ++0.5를 설정하였다. 또한, 학습 및 실험 데이터의 패턴유형은 좌측공격, 우측공격, 중앙공격, 코너킥, 프리킥 등 5종류이다. 실험에 사용된 패턴의 진행 유형은 좌에서 우로 진행하는 한 팀의 유형이 기본이며, 데이터의 코딩을 위한 가공은 실제값을 정규화 하여 사용하였다. 여기서, 실험 데이터에 대한 뉴론의 출력값이 0.1 보다 큰 값 중에서 가장 큰값을 인식패턴 값으로 결정한다.

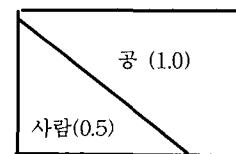


그림 11 가중치 부여 방법

(4) 인식(출력)패턴 분류를 위한 encoding 방법

뉴럴 네트워크에서 처리가 이루어지는 각 인식패턴들의 구분을 위한 색인은 다음과 같다.

① 좌측공격 : 1 0 0 0 0 ④ 코너킥 : 0 0 0 1 0

② 우측공격 : 0 1 0 0 0 ⑤ 프리킥 : 0 0 0 0 1

③ 중앙공격 : 0 0 1 0 0

(5) 학습시의 제한조건

팀의 진행패턴은 좌에서 우로 흐른다고 가정한다. 단, 코너킥의 진행패턴은 운동장의 4개 모서리가 원칙이므로 가정에서 제외한다.

(6) 실험 방법 및 결과

본 실험에서의 실험인자들은 오차허용 범위=0.001(한 사이클 당 1개 패턴의 평균오차), 학습상수=0.001, 학습 속도 개선 인자인 학습가속 인자값(모멘텀)=0.001, 지역 최소값에서 벗어나는 범위인 오차 탈출 인자 값=0.001, 최대 학습횟수=15000이다. 이상과 같은 조건에서 공과 사람에 대한 가중치를 여러 가지로 변화시키면서 실험을 진행하고, 은익층의 노드수(뉴론 수)를 다양하게 변화시키면서 그 변화를 관찰했다. 실험기준은 다음과 같다.

▲ 공과 사람의 가중치 결정

축구경기의 대표 프레임에 있어서는 공의 위치는 매우 중요하다. 공의 위치가 코너에 있고 공격측의 선수가 공과 같은 위치좌표를 갖게 되면 프리킥 패턴의 가능성성이 높다. 또한

공이 공격측을 중심으로 하여 경기장의 우측에 있고 선수들의 위치좌표가 우측에 몰려있으면 우측공격의 확률이 높다. 따라서 공과 사람에 대한 가중치 설정은 다음과 같이 다섯가지 경우에 대해서 은익층=11, 오차 허용도=0.001을 설정하고 공과 사람의 가중치를 변경시키면서 가면서 실험했다(표2).

$$\begin{cases} \text{공} = 1.0 \\ \text{선수} = 0.3 \end{cases} \quad \begin{cases} \text{공} = 1.0 \\ \text{선수} = 0.5 \end{cases} \quad \begin{cases} \text{공} = 1.0 \\ \text{선수} = 0.7 \end{cases} \quad \begin{cases} \text{공} = 1.0 \\ \text{선수} = 1.0 \end{cases}$$

표 2 공과 공을 가진 선수의 가중치에 따른 실험 결과

가중치 공격패턴	공 = 1.0 선수 = 0.3	공 = 1.0 선수 = 0.5	공 = 1.0 선수 = 0.7	공 = 1.0 선수 = 1.0
좌측공격	95 %	91.7 %	88.3 %	81 %
우측공격	97.9 %	100 %	93.2 %	95.9 %
중앙공격	84.7 %	87.5 %	87.5 %	84.7 %
코너킥	100 %	97.4 %	97.4 %	94.9 %
프리킥	67.3 %	75 %	73.1 %	78.8 %

▲ 은익층 노드의 개수 결정

공과 공을 가진 선수의 가중치를 공=1.0과 선수=0.5로 고정시키고, 은익층의 노드 수를 {6개, 10개, 11개, 12개, 14개, 20개, 30개, 50개, 70개}로 변화시켜가면서 실험을 한 결과 표3에서 볼 수 있듯이 입력층 노드 개수의 약 1/10인 11개로 하는 것이 최적하다는 것을 알 수 있다(표3).

표 3 은익층 노드 개수에 대한 실험 결과

은익층수 공격패턴	은익층=1	은익층=3	은익층=5	은익층=7
좌측공격	91.7 %	88.3 %	91.7 %	88.3 %
우측공격	100 %	95.9 %	91.9 %	98.6 %
중앙공격	87.5 %	90.3 %	90.3 %	90.5 %
코너킥	97.4 %	94.9 %	97.4 %	94.9 %
프리킥	75 %	69.2 %	67.3 %	73.1 %

▲ 오차 허용도 결정

오차 허용도의 경우는 학습시간과 밀접한 연관이 있어서 매우 세심한 배려가 필요하다. 본 실험에서는 오차 허용도를 0.001, 0.002, 0.003, 0.004, 0.005, 0.006의 경우 각각에 대해서 (1)과 (2)를 크로스 시켜가면서 실험을 수행했다. 그 결과 0.003에서 0.006까지는 시간상으로 크게 단축이 되지만 학습 정밀도가 크게 떨어진다는 것을 알 수 있었다. 오차허용도를 0.002로 설정하면 시간상으로는 0.001에 비해 학습시간이 단축이 되지만 실험결과가 0.001 보다 좋지 않다는 것을 알 수 있다. 다음의 표4는 실험결과이다.

표 4 오차 허용도를 기준으로 한 실험 결과

오차 허용도 공격패턴	오차 허용도 0.001	오차 허용도 0.002	오차 허용도 0.003	오차 허용도 0.005
좌측공격	91.7 %	93.3 %	81.9 %	88.3 %
우측공격	100 %	94.6 %	95.9 %	97.3 %
중앙공격	87.5 %	88.7 %	87.5 %	86.1 %
코너킥	97.4 %	00 %	100 %	94.9 %
프리킥	75 %	63.5 %	67.3 %	63.5 %

이상과 같은 실험결과를 기준으로 본 논문에서는 경험적으로 가장 최적한 실험인자를 다음과 같이 결정했다.

(1)의 경우 : 공과 공을 가진 선수의 가중치는 공=1.0, 선수=0.5가 최적

(2)의 경우 : 은익층 노드수는 입력층 노드 108개의 약 1/10인 11개가 최적

(3)의 경우 : 학습시의 오차허용도는 시간상으로 부담이 되지만 학습성과의 경우 0.001이 최적

이상과 같은 결과를 기초로 본 연구에서는 뉴럴네트워크의 학습 실험인자를 다음과 같이 설정한다. 공과 선

수의 가중치는 ($\text{공}=1.0$, 선수=0.5)로 결정하고, 은익층의 노드수는 11개, 오차허용도의 경우는 0.001로 설정하여 실험을 했다(표5).

표 5 실험 결과 및 분석 표

공격패턴 종류	데이터 수	인식 패턴					인식율
		좌측 공격	우측 공격	중앙 공격	코너 �ick	프리 킥	
좌측공격	60	55	0	4	0	1	91.7%
우측공격	74	0	74(All)	0	0	0	100.0%
중앙공격	72	0	5	63	0	4	87.5%
코너킥	39	0	0	1	38	0	97.4%
프리킥	52	5	6	1	1	39	75.0%

4.3 실험결과의 분석 및 평가

과거의 연구 중에서 본 연구와 연구방법과 방향은 다르지만 관심을 가지고 검토한 연구들은 주로 개체의 동작인식을 기반으로 하고 있으며, 일부는 유니폼의 색상정보를 기초로 전체적인 분석을 통해 그룹의 동작을 분석하고 있으나 유니폼의 색상정보만으로는 주변환경과의 관계 등에서 오는 노이즈 등에 의한 양호한 인식이 어렵다. 또한 옆에서 본 영상을 사용하고 있어서 지역적인 정보에 치우치고, 카메라의 움직임에 따른 보정의 어려움으로 인해 전제적인 경기의 흐름이나 그룹 포메이션 정보의 정확한 획득에는 한계가 있다. 본 연구에서는 뉴럴네트워크 학습 기법을 활용하여 매우 우수한 인식율을 얻었다. 축구경기의 경우 동일한 공격패턴이라 할지라도 선수들의 위치가 다양하게 변화될 수 있으므로 뉴럴네트워크의 학습기능을 이용하여 다양한 패턴들을 학습할 수 있고 그 학습의 결과 분류의 정확성을 기할 수 있었다.

실험결과에서도 알 수 있듯이 인식 결과는 양호한 편이다. 위의 실험에서, 표5와 같이 우측공격의 경우는 100%의 인식율을 나타내어 거의 완벽한 인식이 가능했으나, 프리킥의 경우는 인식율이 낮은 편이다. 좌측공격의 경우는 중앙공격 쪽으로 오인식이 되는 경향이 있는데, 실제의 대표 프레임 상에서의 육안 관찰시에도 그렇게 오인할 소지가 있다는 것을 알수 있다. 문제는 프리킥의 경우인데, 주로 좌측공격이나 우측공격 쪽으로 오인식되는 경향이 나타나고 있다. 프리킥의 경우, 대표 프레임 상에서는 실제로 사람의 육안으로도 구분이 명확하지 않은 경우가 많아서 시스템 상에서도 그러한 상황을 그대로 반영하고 있다. 해결책으로는 프리킥의 경

우 데이터 채취시에 프리킥이 시작되는 찰나의 순간을 대표 프레임으로 취하게 되면 공과 공을 가진 선수의 좌표가 동일한 좌표값을 갖게 되고 인식율은 크게 향상될 것으로 생각한다.

공과 선수에 대한 가중치 설정은 ($\text{공}=1.0$ & 선수=0.5)의 경우가 가장 최적한 결과를 산출한다는 것을 알 수 있고, 은익층의 뉴론 수는 11개가 최적했으며, 오차허용도는 0.001일 때는 다른 경우 보다 비교적 좋은 결과를 산출하지만, 학습시간이 너무 오래 걸리는 문제가 있다(학습 상한 1,5000에 대해서 4000~1,5000번의 학습). 오차허용도를 0.002 이하(0.002의 경우 최고 3~4000에서 최하 500회)로 할 경우 학습시간에서 대폭적인 감소를 가져오지만, 정밀도 측면에서 오차허용도를 0.001로 했을 때 보다 인식율에서 평균 2~4 % 정도 낮다는 것을 알 수 있다. 따라서 본 실험에서는 움직이는 객체의 가중치를 ($\text{공}=1.0$, 선수=0.5), 은익층의 노드수는 11개, 오차허용도의 경우는 학습시간의 부담을 감수하고 0.001로 경험적으로 설정했다. 다음은 실험결과에 의해서 얻어진 각 공격패턴들의 오인식에 대한 분석이다.

▲ 좌측공격 : 좌측공격의 경우는 주로 중앙공격으로 오인식이 이루어지는데, 영상획득 방법 상의 문제점으로 생각한다. 원래 비디오 영상 자체를 옆에서 본 영상과 위에서 본 영상을 동시에 사용할 계획이었지만, 사정이 여의치 못하여 옆에서 본 영상 만을 사용하였는데, 이 경우 우측 공격과는 달리 각 객체들의 위치좌표가 중앙에 가깝게 잡히는 경향이 있었다. 앞으로 위에서 본 영상과 동시에 사용할 경우, 우측공격과 마찬가지로 거의 완벽한 인식이 가능할 것으로 생각된다.

▲ 우측공격 : 완벽한 인식

▲ 중앙공격 : 중앙공격의 경우는 주로 프리킥으로 오인식이 되는 경향이 있다. 대표 프레임 상에서 육안 판별 시에도 중앙공격과 프리킥은 매우 식별이 어려운 경우가 있다. 시스템 상에서도 역시 그러한 판별의 어려움이 반영된 것으로 생각된다. 해결책은 프리킥에 대해 특정한 특징의 패턴(프리킥 참조)을 인식할 수 있도록 조치를 하면 중앙공격이나 프리킥 모두 크게 인식율이 높아질 것으로 생각된다.

▲ 코너킥 : 코너킥의 경우는 1개의 데이터를 프리킥으로 오인식 하고 있다.

▲ 프리킥 : 프리킥의 경우는 주로 중앙공격과 코너킥으로 오인식을 하고 있다. 이 경우는 대표 프레임 상에서 육안으로 식별할 때도 명확하지 않고, 중앙공격이나 코너킥의 경우와 명확하게 차이가 가지 않는다. 해결책은

대표 프레임 선정시에 프리킥의 순간 즉, 킥을 하는 선수가 공을 킥하려고 하는 순간을 대표 프레임 선정시에 반영하게 되면 크게 인식율이 높아질 것으로 생각한다.

5. 결 론

본 논문에서는 축구경기의 비디오 영상 열을 대상으로 뉴럴네트워크 기법을 이용하여 축구경기의 하이라이트 장면을 자동으로 추출하기 위한 그룹 포메이션 중의 공격패턴 분류기법을 개발하고 이 기법의 유효성을 검증했다.

본 연구와 연구방향은 다르지만 관심을 가지고 검토한 과거의 연구들은 주로 선수 개인의 동작인식에 관한 연구가 많았고 팀 전체의 공격 또는 작전 패턴의 인식에 관한 연구는 거의 없었다. 일부 그룹 행동에 관한 연구의 경우도 본 연구와 방향이나 연구기법도 다르고 연구결과에 대한 실험치 등이 나와있지 않아서 수치적인 비교분석이나 방법론의 비교 분석 등을 사실상 어려웠다.

본 연구에서는 축구경기장 내의 빈번하게 변화하는 장면들을 자동으로 분할하여 대표 프레임을 선정하고, 대표 프레임 상에서의 선수의 위치정보와 공의 위치정보 등을 기초로 하여 경기 중에 이루어지는 그룹 포메이션을 추적하여 그룹행동(group behavior)을 분석하고, 뉴럴네트워크 기법의 역전파(BP : Back-propagation) 알고리즘을 이용하여 공격패턴을 자동으로 인식 및 분류함으로써 축구경기의 하이라이트 장면 자동추출을 위한 기반을 마련하였다.

본 연구의 실험환경은 440MHz의 CPU, 64메가 RAM을 갖춘 IBM 호환용 팬티엄-III급 PC를 사용했다. 실험에 소요된 시간은 학습시간이 5~7분이 걸리고, test는 on-line으로 5~6초가 소요되었다. 또한 본 실험에서 대표 프레임으로 사용한 데이터는 좌측공격 60개, 우측공격 74개, 중앙공격 72개, 코너킥 39개, 프리킥 52개의 총 297개이다. 실험결과는 좌측공격 91.73%, 우측공격 100%, 중앙공격 87.5%, 코너킥 97.4%, 프리킥 75%로서 매우 양호한 인식율을 보였다. 향후의 연구과제로는 선수 능력평가 기법, 자연환경에서의 데이터 자동추출 기법, 그룹 포메이션의 자동 추적 등이 있으며, 이러한 연구를 통해서 신뢰성 있는 축구경기의 하이라이트 장면 자동추출 시스템의 실용 시스템을 구축하는 것이다. 또한, 본 논문에서 이룬 연구결과를 토대로 농구, 배구, 핸드볼 등과 같은 다른 팀 플레이 스포츠(team play sports)에 대한 응용도 향후과제의 하나이다.

참 고 문 현

- [1] T.Kawahsima, K.Yoshino and Y.Yoshinao; "Qualitative Image Analysis of Group Behaviour," In Proc. of IEEE conf. on Computer Vision and Pattern Recognition, pp.690-693, 1994.
- [2] T.Taki, J.Hasegawa and T.Fukumura;"Development of Motion Analysis system for Quantitative Evaluation of Teamwork in Soccer Games," In Proc. of IEEE International Conference on Image Processing, pp. III815-III818, 1996.
- [3] T.Taki and J.Hasegawa, "A Feature for Group Behavior Analysis in Sports and Its Application," The Transactions of the Institute of Electronics, Information and Communication Engineers D-II, Vol. J81-D-II, No.8, pp.1802-1811, 1998.8
- [4] T.Taki, T.Matsumoto, J.Hasegawa and T.Fukumura; "Evaluation of Teamwork from Soccer Scenes," In Proc. of IEEE Int. Conf. on Image Processing, pp. III815-III818, 1996.
- [5] D.Yow, B.L.Yow, M.Yeung and B.Liu : "Analysis and Presentation of Soccer Highlight from Digital Video, In Proc. of 2nd Asian Conf. on Computer Vision, pp. II499-II503, 1995.
- [6] G.Collins, "Plan Creation : Using Strategies as Blueprints," Science Dept., Report RR 599, Yale University Department Computer Science, May 1987.
- [7] A.F.Bobick, "Video Annotation : Computer Watching Video," In Proc. of 2nd Asian Conf. on Computer Vision, pp. 119-123, 1995.
- [8] Y.Gong, T.S.Lim, C.Chuan, H.Zhang and M.Sakauchi, "Automatic Parsing of TV Soccer Program," In Proc. of 2nd Int. Conf. on Multimedia Computing and Systems, pp. 167-174, 1995.
- [9] T.Yoshida, S.Ozawa, "Scene Analysis of Soccer Telecast," In Proc. of the 2nd Symposium on Sensing via Image Information. pp. 183-188, 1994.
- [10] M.Iwase, T.Tanaka and N.Ohnihs, "Image Synthesis from a Soccer Player," Technical Report of IEICE, PRU95-72 (1995.7).
- [11] M.J.Swain and D.H.Ballard : "Color Indexing," Int. J. of Computer Vision, 7-2, pp.11-32, 1991.
- [12] M.J.Swain and D.H.Ballard : "Indexing via Color Histogram," DARPA Image Understanding Workshop, pp.623-630, 1990.
- [13] S.Chi, Y.Seo, H.Kim and K.Hong "Where are the Ball and Players? : Soccer Game Analysis with Color-based Tracking and Image Mosaic," Dept. of EE, Pohang University of Science and Technology, 1996.

Technology, San 31 Hyoja Dong, Pohang, 790-784,
Republic of Korea

- [14] T.Kim, Y.Seo and K.Hong : "Physics Analysis of Soccer Ball from Monocular Image Sequences," Dept. of EE, POSTECH, San 31 Hoyja Dong, 790-784, Republic of Korea.
- [15] A.Gelb: "Applied Optimal Estimation," MIT Press., pp.102-119, 1979.
- [16] S.S.Intille and A.F.Bobick : "Tracking Using a Local Closed-World Assumption : Tracking in the Football Domain," MIT Media Lab Perceptual Computing Group Tech. Report No. 296, Massachusetts Institute of Technology, August 1994.
- [17] B.K.P.Horn, "Robot Vision," MIT Press., Cambridge Massachusetts, 1986.
- [18] M.Irani, B.Rousso and S.Peleg : "Computing Occluding and Transparent Motions," Int. J. of Computer Vision 12:1, pp. 5-16, January 1994.
- [19] M.Irani, D.Anandan and S.Hsu : "Mosaic Based Representation of Video Sequences and Their Applications," In Proc. of Int. Conf. on Computer Vision, pp. 605-611, 1995.
- [20] H.Mo, S.Satoh, and M.Sakauchi : "A New Type of Video Scene Classification System based on Typical Model Database," IAPR MVA '96, pp.239-332, 1996.



김 현 숙

1989년 2월 동국대학교 공과대학 전산과 졸업(공학사). 1991년 8월 서강대학교 정보대학원(이학석사). 1994년 2월 고려대학교 대학원 컴퓨터학과 박사과정 수료. 1994년 3월 ~ 1995년 2월 고려대학교 자연과학대학 전자계산학과 강사. 1994년 2월 ~ 1995년 2월 한성대학교 교양학부 강사. 1994년 8월 ~ 1995년 2월 경원대학교 공과대학 전자계산학과 강사. 1995년 ~ 현재 신성대학 컴퓨터계열 교수.



김 광 용

1991년 2월 충남대학교 공과대학 컴퓨터 공학과 공학사. 1993년 2월 충남대학교 대학원 컴퓨터공학 공학석사. 1998년 2월 충남대학교 대학원 컴퓨터공학 공학 박사. 1998년 5월 ~ 현재 한국전자통신 연구원 선임연구원.



남 성 혼

1987년 2월 충남대학교 수학과 졸업(이학사). 1991년 2월 한국외대 응용전산과 졸업(이학석사). 1991년 1월 ~ 1993년 3월 현대전자 소프트웨어 연구소 근무. 1995년 2월 고려대학교 전산과학과(박사수료). 1995년 3월 ~ 현재 두원공과대학 소프트웨어개발과 조교수. 관심분야는 영상처리, 멀티미디어 등



홍 종 선

1978년 Univ. of Georgia, Statistics and Computer Science 박사. 1978년 South Carolina Lcander 주립대학 조교수. 1981년 한국표준연구소 전자계산실 실장. 1995년 한국정보과학회 회장. 1982년 ~ 현재 고려대학교 컴퓨터학과 교수. 관심분야는 알고리즘, 데이터베이스, 분산시스템



양 영 규

1972년 서울대 농공학과 학사. 1974년 서울대 도시 및 지역계획학 석사. 1984년 미국 Texas A&M 박사(영상처리). 1973년 ~ 1996년 시스템공학연구소(인공지능연구부장, 영상처리연구부장 겸 슈퍼컴퓨터센터장 겸 지구환경연구부장 역임). 1997년 ~ 현재 ETRI 컴퓨터, 소프트웨어연구소 영상처리연구부장, 한국컴퓨터그래픽스학회 부회장, 대한원격탐사학회 부회장. 관심분야는 영상처리 및 패턴인식, 리모트센싱, GIS