

# 정규화된 형상 모델을 이용한 뼈 나이 측정 방법

유주완<sup>†</sup>, 이종민<sup>‡</sup>, 김희율<sup>\*\*\*</sup>

## 요약

뼈 나이 측정은 소아의 내분비계 관련 질병 진단을 위해 소아과에서 널리 사용되는 방법이다. 그러나 전문 인력이 부족하여 자동화된 측정 방법에 대한 꾸준한 요구가 있었다. 따라서 본 논문에서는 패턴 인식 기법을 이용한 자동화된 뼈 나이 측정 알고리즘을 제안한다. 제안하는 알고리즘은 X-ray 영상에서 손가락 뼈의 각 부분을 자동으로 분류하는 과정과 분류된 뼈 영상으로부터 정규화된 형상 모델을 추출하는 과정, 그리고 정규화된 형상 모델로부터 뼈 나이를 측정하는 과정으로 구성된다. 제안하는 알고리즘은 능동 형상 모델(Active Shape Model: ASM)을 이용하여 나이 측정에 사용되는 특징값 추출의 정확도를 향상시켰으며, 뼈 나이 분류를 위해 사용된 Support Vector Machine(SVM)의 입력으로 정규화된 형상 모델로부터 얻어진 각 뼈의 크기와 비율을 특징값으로 사용하였다. 성능 평가를 위해서 한양대학교 부속병원에서 제공한 영상에 대해 전문가가 평가한 나이와 제안한 알고리즘을 이용하여 측정된 나이를 통계적으로 비교 분석하였다. 실험을 통하여 본 논문에서 제안한 특징값과 알고리즘으로 뼈 나이를 진단한 결과, 전문가에 의한 결과와 평균 0.679살의 오차 이내의 뛰어난 뼈 나이 측정 성능을 보였다.

## A Bone Age Assessment Method Based on Normalized Shape Model

Ju-woan Yoo<sup>†</sup>, Jong-min Lee<sup>‡</sup>, Whoi-yul Kim<sup>\*\*\*</sup>

## ABSTRACT

Bone age assessment has been widely used in pediatrics to identify endocrine problems of children. Since the number of trained doctors is far less than the demands, there has been numerous requests for automatic estimation of bone age. Therefore, in this paper, we propose an automatic bone age assessment method that utilizes pattern classification techniques. The proposed method consists of three modules; a finger segmentation module, a normalized shape model generation module and a bone age estimation module. The finger segmentation module segments fingers and epiphyseal regions by means of various image processing algorithms. The shape model abstraction module employ ASM to improves the accuracy of feature extraction for bone age estimation. In addition, SVM is used for estimation of bone age. Features for the estimation include the length of bone and the ratios of bone length. We evaluated the performance of the proposed method through statistical analysis by comparing the bone age assessment results by clinical experts and the proposed automatic method. Through the experimental results, the mean error of the assessment was 0.679 year, which was better than the average error acceptable in clinical practice.

**Key words:** Bone Age Assessment (뼈 나이 진단), ASM(능동형상모델), SVM

※ 교신저자(Corresponding Author): 김희율, 주소: 서울시 성동구 행당동 산 17(445-743), 전화: 02)2220-0561, FAX: 02)2292-6316, E-mail: wykim@hanyang.ac.kr  
접수일: 2008년 7월 22일, 완료일: 2009년 1월 12일  
† 정회원, 한양대학교 전자통신컴퓨터공학과 석사  
(E-mail: juwoan@gmail.com)

\*\* 한양대학교 전자컴퓨터통신공학과 박사  
(E-mail: lcejongmin@vision.hanyang.ac.kr)

\*\*\* 종신회원, 한양대학교 전자통신컴퓨터공학부 정교수  
※ 본 연구는 한양대학교 과학장학기술금의 지원으로 이루어 졌습니다.

## 1. 서 론

뼈 나이 평가는 소아의 성장 정도를 측정하는 중요한 방법으로써 소아과와 정형외과에서 널리 시행되고 있는 진료 항목이다. 일반적으로 사람의 성장은 1~20세 사이에 이루어지며 이후에는 성장을 멈추기 때문에 뼈 나이 평가의 대상은 1~20세 사이의 유아 및 청소년이다. 이 시기에 정상적인 신체 발육이 이루어질 경우, 뼈 나이는 실제 나이와 비슷한 결과를 보인다. 그러나 내분비계 질환, 생식기계 호르몬 문제, 전신 발육 지연 등의 이유로 발육이 정상적으로 이루어지지 못해서 뼈가 정상적으로 성장하지 못하게 되면 측정된 뼈 나이는 실제 나이와 차이를 보이게 된다. 이러한 차이를 근거로 하여 뼈 나이 평가는 실제 나이와 뼈 나이와의 차이를 통해 각종 질병에 관한 지표를 제시한다. 임상에서 가장 일반적으로 사용되는 뼈 나이를 평가 방법으로는 왼쪽 손목뼈의 X-ray 영상을 이용하는 Atlas 매칭 방법과 TW방법이다[1-5]. Atlas 매칭 방법은 기준이 되는 Atlas 패턴 그룹의 기준 X-ray 영상과 환자의 X-ray 영상을 의사가 육안으로 비교하면서 뼈 나이를 측정하는 방법이다[1,2]. 다른 평가 방법인 TW 방법은 왼쪽 손목뼈를 20개의 부분으로 분할하여 각각을 각 연령대의 표준 뼈 영상과 비교를 통해 각 단계별로 점수를 채점한 후, 각 부분의 나이를 합산한 평균으로 뼈 나이를 산정하는 방법이다[3-5]. 그러나 현재 사용되는 두 가지 방법 모두 의사의 숙련도에 따라 평가의 오차가 발생할 확률이 매우 높고 Atlas 매칭 방법의 경우 비교 부위에 따라 서로 다른 결과가 나오는 단점이 있다.

최근 들어 뼈 나이 평가에 대한 수요 및 관심이 많아지고 있으며 X-ray 장비의 현대화와 영상 처리 기술의 발전으로 인해 컴퓨터를 이용한 자동화된 뼈 나이평가 방법이 다양하게 연구되고 있다[6-11]. 뼈 나이 진단을 위한 특징을 추출하는 방법으로는 경계선 검출 방식과 능동형상모델(Active Shape Model: ASM) 등을 사용하는 방법이 주를 이루고 있으며, 특정값으로부터 뼈 나이를 측정하는 방법으로는 신경망(newral network)이 주로 이용되고 있다. 영상 처리 기법을 이용한 대표적인 뼈 나이 자동 측정 방법으로는 E. Pietka가 제안한 방법이 있다[6-9]. E. Pietka는 경계선 정보를 이용하여 세 개의 손가락에

서 6개의 골단판 부분을 자동으로 추출하여 골단판의 직경과 손가락뼈까지의 거리등을 계산하여 특정값으로 사용한다. TW 방법으로 뼈 나이를 측정하는데 중요한 요소인 골단판은 손가락 각 마디에 위치하는 성장판으로서, 연령에 따라 그 형상이 확연히 구분되기 때문에 영상처리를 이용해서 뼈 나이를 측정하기 위한 특징으로써 적합하다. 영상 처리 기술을 이용한 다른 뼈 나이 평가 방법으로 B.C. Fan이 제안한 방법이 있다[10]. 이 방법은 손가락뼈가 아닌 손목뼈를 이용하는 방법으로써 손목뼈의 점유율, 길이, 무게 중심, 꼬를 등의 지표를 이용하였다. 그러나 이 방법은 손목뼈 영역을 추출하기 위해서 X-ray를 활영할 때 철침 등의 도구를 손등 부분에 정확히 놓고 활영해야 하는 단점이 있다. 또한 손목뼈는 6~7세 이상이 되면 서로 겹쳐져서 정확한 경계 추출이 어려운 단점이 있다. 네덜란드의 M. Niemeijer는 능동형상모델을 이용한 뼈 나이 평가 방법을 제시하였다 [11]. 능동형상모델은 T.F Cootes가 제안한 모양 추출 방법으로 기존의 능동윤곽선(active contour)이 가지고 있던 단점을 극복한 새로운 방법이다[12-14]. 이 연구에서는 TW에 수록된 표준영상과 유사한 템플릿 영상을 생성하고 생성된 표준 템플릿을 이용하여 뼈 나이 평가를 실시하였다. 그러나 이 방법을 사용한 뼈 나이 평가는 낮은 정확도의 결과를 보여주어 실용화에는 어려움을 보였다.

본 논문에서는 기존의 TW 방법을 기반으로 하여 자동화된 뼈 나이 측정 방법을 제안한다. 제안하는 방법은 손 영역에서 분할된 각 부분에 대하여 능동형상모델을 사용하여 손가락의 하위 모델을 생성함으로써, 특정값 추출의 정확도를 향상시켰다. 또한 뼈 나이를 추정하기 위한 특징벡터에 있어서도, 본 논문에서 손가락 뼈 및 골단판의 절대 길이 및 상대적인 비율을 복합적으로 이용하였다. 이로써 골단판이나 뼈의 특정 지점들의 상대 또는 절대 길이만을 따로 이용하여 뼈 나이를 추정하는 기존 방법들 보다 뼈 나이 측정의 정확도를 향상시켰다. 뼈 나이의 판정은 손영상 데이터를 확보하기 어려운 한계를 극복하기 위해 SVM을 이용하였다. SVM은 고차원의 벡터를 가지는 적은 수의 훈련 데이터를 이용하여 데이터를 분류하는데 적합한 방법이다[15-18].

본 논문은 2장에서 제안하는 방법을 간략히 기술하고, 3장에서 정규화된 손가락뼈 모델 생성 알고리

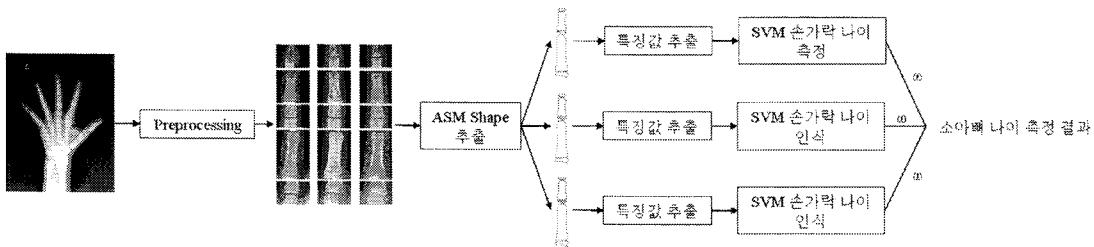


그림 1. 뼈 나이 측정 알고리즘 개요

증에 대해 기술한다. 4장에서는 나이 인식에 사용할 특징벡터의 정의 및 인식 알고리즘에 대해 기술한다. 5장에서는 실험 및 실험 결과에 대해 기술하고, 6장에서 결론 및 향후 연구과제에 대해서 기술한다.

## 2. 제안하는 방법

본 논문에서 제안하는 뼈 나이 측정 방법은 5세에서 15세 사이 대상자들의 원손을 촬영한 X-ray 영상에서 검지, 중지, 약지 세 손가락의 뼈 나이를 각각 측정하여 측정된 뼈 나이들의 평균을 이용하여 입력된 영상의 뼈 나이를 결정한다. 전처리 과정을 통해서 배경과 손 영역을 분할하고, 하위 모델 분할 알고리즘을 이용해서 검지, 중지, 약지에서 골단판과 손가락뼈를 각각 추출한다. 입력영상은 손바닥의 방향이 모두 동일하며, 반지나 시계 등의 장신구에 의한 노이즈가 없는 영상이다. 뼈 나이 측정은 추출된 각 골단판과 손가락뼈에서 특징벡터를 추출하기 위한 특징 추출 과정과 특징벡터를 이용하여 뼈 나이를 진단하는 뼈 나이 진단 과정으로 이루어진다. 각 손가락의 특징벡터를 구하는 과정은 정규화된 뼈 모양 모델 생성을 통해서 이루어진다. 세 손가락 뼈의 형상 모델 생성은 능동형상모델 알고리즘을 이용하였다[12-14]. 기존의 능동형상모델 알고리즘은 하나의 형상 모델을 생성하기 위해 전체를 하나의 형상 모델로 보고 훈련하고 추정한다. 반면, 본 논문에서 제안하는 방법은 하나의 형상 모델을 여러 개의 하위 모델로 분할하여 훈련하고 추정함으로써 각각의 모델 추정에 정확도를 향상시킨다. 모델 추정의 정확도가 향상됨에 따라 전체 모델의 특징값 측정의 정확도도 향상된다. 능동형상모델 훈련에 사용되는 기준점(landmark)들은 손가락뼈와 골단판에서 형태적 특징을 갖는 외관선의 지점을 수동으로 추출하였다.

각각 추정된 하위 모델들은 정규화 과정을 통해 최종적으로 하나의 손가락 모델로 합해진다. 모델의 정규화 과정은 하위 모델의 회전 및 이동을 통해서 좌표계를 통일하는 과정이다.

하나의 손가락 모델이 생성되면 논문에서 제안하는 각 골단판과 손가락뼈의 각 부분의 길이와 비율들로 구성되는 하나의 특징벡터를 추출할 수 있다. 제안하는 방법은 최종적으로 세 개의 손가락에 대해 각각 추출한 세 개의 특징벡터를 이용하여 SVM을 통해 각각의 손가락 나이를 진단한다.

본 논문에서 제안하는 방법을 요약하면 그림 1과 같다.

## 3. 정규화 된 뼈 모델 생성 방법

### 3.1 전처리 (하위 모델 분할 방법)

하나의 손가락을 여러 개의 하위 모델로 분할하기 위해서는 각 뼈의 정확한 위치 추출이 필요하다. 본 논문에서 사용한 뼈 모델 생성을 위한 하위 모델은 그림 2와 같은 단계를 가지는 전처리 알고리즘을 이

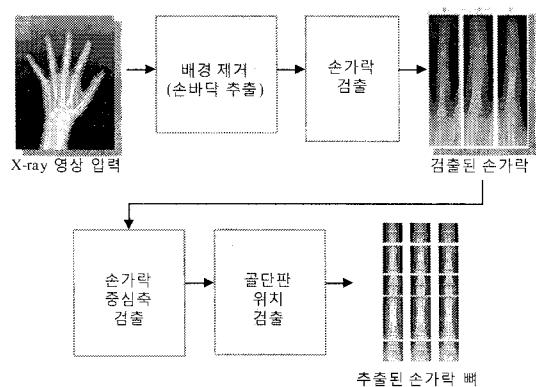


그림 2. 손가락 뼈 검출을 위한 전처리

용하여 각 뼈의 위치를 검출하고 검출된 위치를 기준으로 5개로 분류된 뼈 및 골단판 영상을 이용해서 생성된다.

### 3.1.1 손가락 분할 및 하위 영상 추출 방법

손가락 분할 과정에는 입력 영상에서 배경을 분리하여 손바닥 영역만을 추출하고, 뼈 모델 생성을 위해 검지, 중지, 약지 세 손가락을 각각 추출하는 과정이 포함된다. 먼저 배경 성분 분리를 위해 배경 성분 예측이 필요하다. 일반적인 X-ray 영상은 방사선 조사 방식에 따라 비균일 배경 성분이 존재한다. 본 논문에서는 영상 내에 존재하는 비균일 배경 성분을 3차원 다항식으로 계산되는 곡면으로 가정하고 배경 곡면을 추정하여 제거하는 방법을 사용하였다[19]. 그림 3은 배경 추정 알고리즘의 블록 다이어그램이며, 원 영상에서 배경 성분이 제거된 손 영상은 그림 4와 같다.

그림 4 (b)와 같이 손바닥이 정확하게 분리된 영상에서 뼈 나이 측정에 사용되는 가운데 세 손가락 부분을 검출하기 위해서는 먼저 경계선 추적 알고리즘 [20]을 사용해서 손의 영역의 외곽선을 검출한다. 손의 외곽선은 그림 4와 같이 손가락 끝, 손가락 사이 지점들에 해당하는 급격한 곡선 부분과 손가락 길이

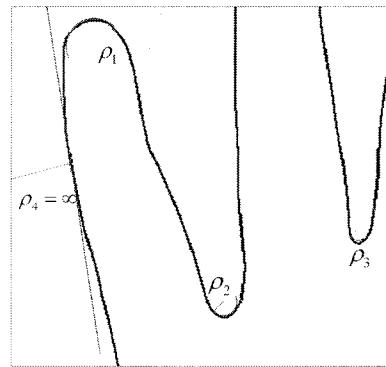


그림 5. 손가락 경계선의 형태적 특징

부분에 해당하는 직선에 가까운 곡선 부분으로 이루어진다. 이러한 손의 형태적 특성을 이용하면 각각의 손가락의 위치를 찾아낼 수 있다[21]. 검출된 손가락의 외곽선을 이루는 픽셀을 따라서 곡률 식 (1)을 이용해서 계산하고, 경계선을 이루는 각 픽셀마다 계산된 값들의 지역적인 최대값과 최소값을 검출하면 그림 (6) a, b와 같이 9개의 손가락의 사이점과 손가락의 끝점을 검출할 수 있다. 검출된 9개의 점들을 이용하여 최종적으로 그림 6 (c)와 같이 각 손가락들의 영역을 얻는다.

$$K = 1/\rho = \frac{y''}{\sqrt{(1+y'^2)^3}} \quad (1)$$

추출된 손가락 영역에서 뼈 및 골단판 영역의 정확한 위치 검출을 위해서는 수직 투영방법을 사용하였다 [19]. 분할된 손가락 영역에서 수직 방향으로 투영된 값을 구하여 그 변화량으로 골단판의 좌표를 구하게 된다. 그림 7은 분할된 손가락과 손가락의 수직 투영 및 미분 결과이다. 그림 7의 (b)에서 보는 바와 같이 손가락의 골단판 부분에서 손가락 부분의 픽셀들의 수직 투영 값의 변화량이 큰 것을 알 수 있다. 미분 결과를 보면 영점교차 지점이 골단판 부분인 것을 알 수 있다. 따라서 제안하는 방법은 골단판 위치를 검출하기 위해 먼저 각 구간이 한 개씩의 골단판 영역을 포함하도록 손가락을 통계적인 방법을 이용하여 세 구간으로 나눈다. 나누어진 각 구간의 수직 투영 값의 미분을 계산하여 영점교차되는 점들 중에서 손바닥에 가깝게 위치한 점을 골단판의 위치로 지정하게 된다. 추출된 골단판 위치를 기준으로 우측으로 가장 큰 변화량을 보이는 지점을 골단판의

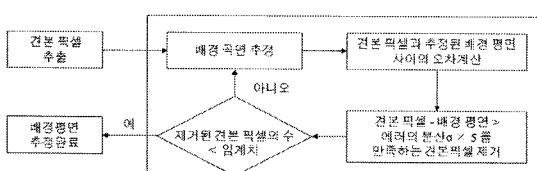


그림 3. 배경 곡면 추정 알고리즘

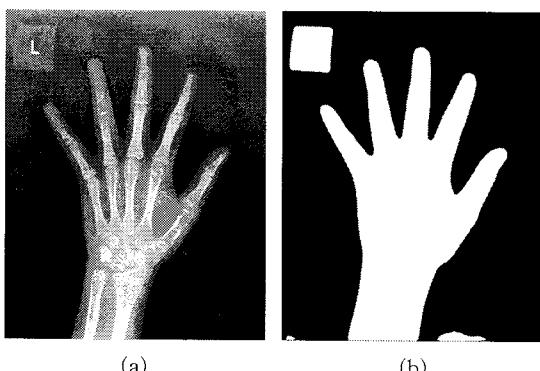


그림 4. 배경 곡면 추정을 통한 임계값 적용 결과. (a) 원 영상, (b) 배경 성분이 제거된 영상

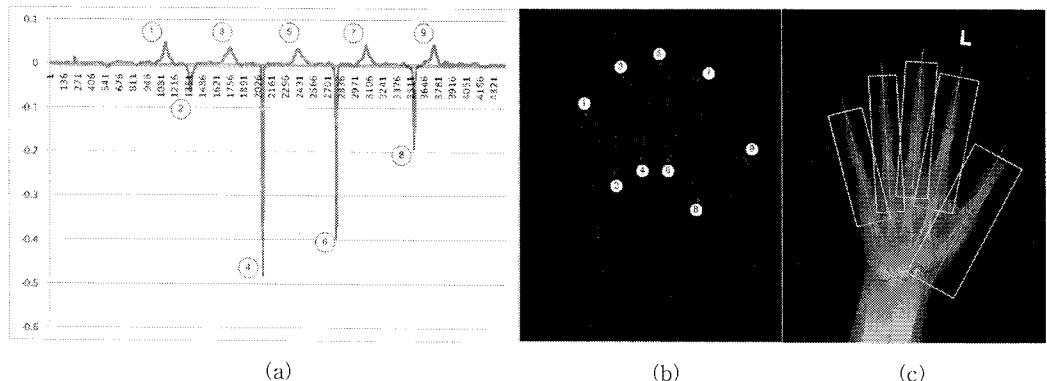


그림 6. 손가락 영역 검출. (a) 경계선을 따라 계산한  $K$  값의 변화 (b) 검출된 지역적 최대값 및 최소값 (c) 검출된 각 손가락 영역

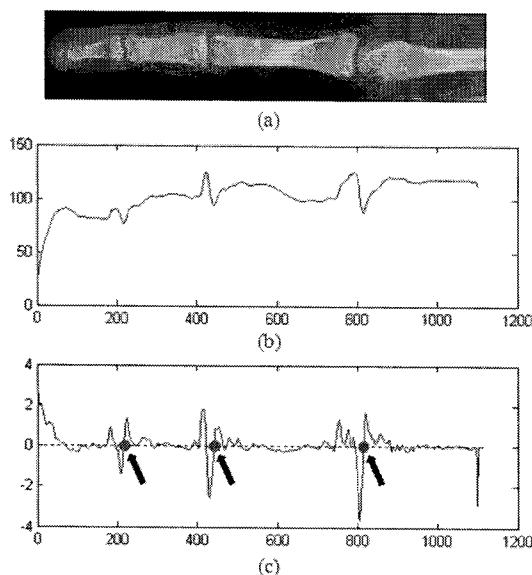


그림 7. 손가락 수직 투영 결과 (a) 손가락 영상 (b) 손가락 수직 투영 결과 (c) 수직투영의 미분 결과 (화살표: 영점교차점)

끝 지점으로 검출하면 각 뼈의 위치를 추출할 수 있다. 최종적으로 각각의 기준 위치를 통해 그림 8과 같은 5개의 분할된 뼈 및 골단판 영상을 추출할 수 있다.

### 3.2 형상 모델 추출 알고리즘

뼈 나이 인식을 위해 뼈의 각 구간의 크기 및 비율을 정확하게 추출하기 위해서는 영상에서 뼈의 특정 지점을 정확하게 추출하여야 하며, 각 지점을 추출하는 것은 뼈의 형상을 정확하게 추출함으로써 가능하다. 따라서 입력 영상에서 나이 인식에 필요한 특징 벡터를 추출하기 위해서는 입력 영상의 정확한 모델화가 선행되어야 한다. 앞 절에서 전처리 과정을 통해 얻은 여러 사람의 손가락뼈의 각 하위 영상들은 전체적으로는 서로 비슷하지만 지역적으로 조금씩 다른 형태를 갖는다. 이렇게 전체적인 윤곽은 비슷하지만 부분적으로 다양하게 다른 모양을 가지는 형상을 추출하는데 유용하게 사용되는 방법이 능동형상모델이다[12-14]. 본 논문에서는 복잡하고 다양한 형태의 하위 영상들의 형상을 정확하게 추출하기 위해서 능동형상모델을 사용하였다. 능동형상모델은 다양한 형태의 형상들을 훈련하여 입력 영상 대해 정확한 형상 모델을 추출한다. 최종적으로 능동형상모델을 통해 추출된 각 하위 형상 모델들은 본 논문에서 제안한 특징벡터 추출에 사용된다.

#### 3.2.1 통계적인 모델 생성

능동형상모델은 하나의 모델을 나타내는 다양한

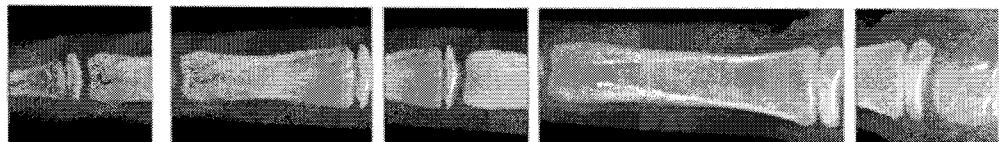


그림 8. 분할된 각 손가락뼈와 골단판 부분들

형상들의 통계적인 특성을 분석하여 통계적인 형상 모델을 생성하고 영상에서 유사한 형태의 형상을 추출하는 방법이다. 통계적인 형상 모델을 추출하기 위해서 각각의 훈련 영상에 대해 추출하고자 하는 객체의 형태에 따라 정해진 기준점(landmark)을 기록한다. 하나의 영상에 대해 개의 기준점 집합은 식 (2)와 같은 하나의 벡터로 표현될 수 있다.

$$\mathbf{x} = \{\mathbf{x}_1, \dots, \mathbf{x}_n, \mathbf{y}_1, \dots, \mathbf{y}_n\}^T \quad (2)$$

$s$  개의 영상에서 얻은 각각의  $\mathbf{x}_i$  ( $i=1, 2, \dots, s$ )를 학습에 사용하기 위해 각기 다른 좌표계를 가지는  $\mathbf{x}_i$ 를 하나의 공통된 좌표계로 변환하여 주어야 한다. 이를 위해서 각각의  $\mathbf{x}_i$ 에 대해 평균( $\bar{\mathbf{x}}_i$ )간의 거리의 합 ( $D = \sum |\mathbf{x}_i - \bar{\mathbf{x}}_i|^2$ )이 최소가 되는 좌표 변환식을 구하여 공통 좌표계로 변환한다. 공통 좌표계로 변환된  $s$  개의 집합으로부터 하나의 모델을 추출하기 위해 다음과 같은 과정을 거치게 된다. 먼저 공통 좌표계로 변환된 집합으로부터 평균 벡터를 다음과 같이 구할 수 있다.

$$\bar{\mathbf{x}} = \frac{1}{s} \sum_{i=1}^s \mathbf{x}_i \quad (3)$$

데이터 집합으로부터 공분산 행렬은 다음과 같이 계산된다.

$$\mathbf{S} = \frac{1}{s} \sum_{i=1}^s (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T \quad (4)$$

이때 공분산 행렬  $\mathbf{S}$ 의 고유 벡터  $\Lambda_i$ 와 고유값  $\lambda_i$ 를 구할 수 있으며 각각의  $\mathbf{x}$ 는 다음과 같이 근사할 수 있다.

$$\mathbf{x} \approx \bar{\mathbf{x}} + \mathbf{P}\mathbf{b} \quad (5)$$

이때  $\mathbf{P}$ 는 공분산 행렬의 고유값 중  $t$ 개를 가지는  $\mathbf{P} = (\Lambda_1, \Lambda_2, \dots, \Lambda_t)$ 이고  $\mathbf{b}$ 는 다음과 같은  $t$  차원의 벡터이다. 차원  $t$ 는 대응하는 고유값의 합이 전체 고유값의 95%에 이르는 고유값의 개수이다.

$$\mathbf{b} = \mathbf{P}^T (\mathbf{x} - \bar{\mathbf{x}}) \quad (6)$$

결과적으로 벡터  $\mathbf{b}$ 는 변형 가능한 모델의 매개 변수의 집합이며  $\mathbf{b}$ 의 구성 요소를 변경함으로써 훈련된 형태에서 큰 변화 없이 입력 영상에 적합하게 형상모델의 형태를 변형할 수 있다.

제안하는 알고리즘에서는 검지, 중지, 약지 세 개

의 손가락에서 각 한 개의 손가락마다 골단판1, 골단판2, 골단판3, 중간마디뼈 및 끝마디뼈의 5개의 능동 형상모델을 생성하여, 총 15개의 능동형상모델을 생성한다. 각 15개의 능동형상모델은 정규화 과정을 거쳐 각 위치의 손가락뼈와 골단판들의 정규화된 능동 형상모델이 만들어진다. 그러므로 최종적으로 손가락의 손가락뼈 2개, 골단판 3개를 합친 총 5개 부분의 능동형상모델을 가지는 1개의 정규화된 능동형상모델이 생성된다.

그림 9는 골단판과 손가락뼈의 형상모델을 생성하기 위해 사용되는 기준점들을 보여준다. 뼈의 형상모델을 생성하기 위해서 60개의 기준점이 사용되었으며 골단판의 형상 모델을 생성하기 위해서는 26개의 기준점이 사용되었고, 그림 8과 같이 좌측하단부터 반시계 방향의 순서로 구성하였다. 기준점 각 나마다 5장의 영상들에서 수동으로 추출한 후, 중간 마디 뼈는  $200 \times 300$ , 끝 마디 뼈는  $200 \times 500, 골단판은  $200 \times 200$ 의 크기로 정규화하여 5개의 각 부분마다 능동형상모델을 훈련하였다.$

### 3.2.2 특징벡터와 적합 함수 (Fit function)

입력 영상에서 훈련된 형태의 모델을 찾기 위해서는 입력 영상에서 찾은 모델이 영상에서 위치하는 지역적인 정보를 이용하여 원래 찾고자 하는 모델과의 유사성을 결정할 수 있는 적합 함수(fit function)가 필요하다. 본 논문에서는 뼈 영상의 특징을 이용하여 각 기준점에 대해 다음과 같은 특징벡터  $\mathbf{g}$ 와

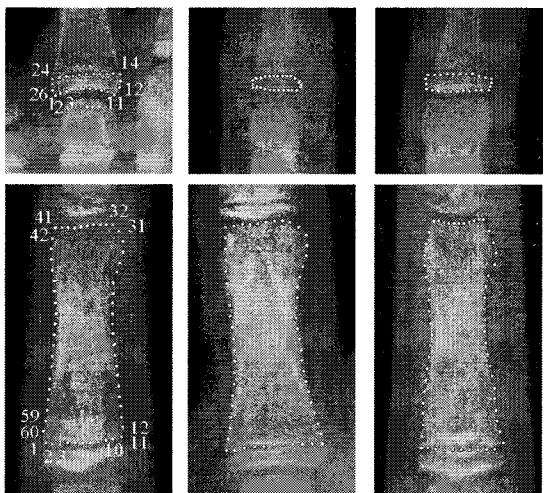


그림 9. 뼈 및 골단판의 기준점 영상

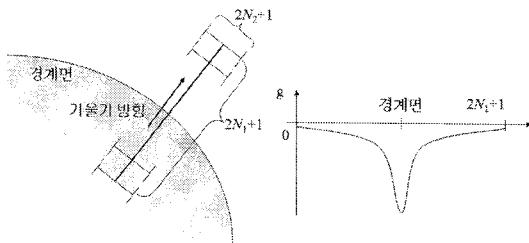


그림 10. 경계면에서 특징벡터

적합 함수를 다음과 같이 정의한다.

특징벡터  $\mathbf{g}$ 를 계산하기 위해 식(7)을 이용하여 그림 10과 같이 모델의 경계면의 안과 밖으로 경계면에 수직인  $2N_1+1$ 개의 픽셀값들에 대해서 평균 밝기  $I_{AVG}^i$ 를 계산한다. 이 때, 평균밝기는 경계면에 수직 직선의 좌우방향으로  $2N_2+1$ 개의 픽셀값을 평균하여 수직 직선에 대한 픽셀값으로 사용한다. 경계면과 특징벡터 추출 방향과의 관계는 그림 10 (a)와 같으며 그림 10 (b)는 법선 성분으로부터 구한 특징벡터의 값을 보여준다.

$$I_{AVG}^i(2N_2+1) = \frac{\sum_{k=1}^{2N_2+1} I^i(k)}{2N_2+1}, \quad (7)$$

$$i = 1, 2, \dots, 2N_1+1$$

$$I_{AVG} = I_{AVG}^1(2N_2+1), I_{AVG}^2(2N_2+1), \dots, I_{AVG}^{2N_1+1}(2N_2+1) \quad (8)$$

능동형상모델 훈련을 위한 특징벡터  $\mathbf{g}$ 는 영상 전체의 명암값 차이를 고려하기 위해서 식 (9)와 같이 각 샘플 픽셀의 경계면의 법선 방향(G)으로의 미분을 계산하여 얻어진다.

$$\mathbf{g} = \frac{dI_{AVG}}{dG} \quad (9)$$

훈련 데이터로부터 통계적 형상 모델을 생성하기 위한 방법은 다음과 같다. 하나의 기준점에 대하여  $i$ 번째 훈련영상에서 얻은 특징벡터를  $\mathbf{g}_i$ 라 하면 이 기준점에 대하여 훈련 영상 개수만큼의 원소를 가지는 집합  $\{\mathbf{g}_i\}$ 를 구할 수 있다. 이 집합으로부터 특징 벡터의 평균  $\bar{\mathbf{g}}$ 와 공분산 행렬  $S_g$ 를 구하여 기준점의 통계적인 모델을 만든다. 이와 같은 과정을 전체 기준점에 대하여 반복하여 전체 기준점에 대한 통계적 모델을 생성한다.

입력 영상에서 임의의 위치  $(x, y)$ 에 대한 훈련된 모델과의 유사도 측정을 위한 적합 함수는 식 (9)과 같이 정의한다. 적합 함수는 입력 영상과 훈련된 모델과의 유사도 측정을 위해 훈련된 특징벡터와  $(x, y)$ 에서의 특징벡터간의 마할라노비스(mahalanobis) 거리를 포함한다. 또한 뼈 영상에서 찾고자 하는 형상이 영상에서 밝기값의 차이가 큰 부분에 존재하도록 정규화된 밝기값의 차이를 포함한다.

$$f(x, y) = \frac{(\mathbf{g}_s - \bar{\mathbf{g}})^T S_g^{-1} (\mathbf{g}_s - \bar{\mathbf{g}})}{((\nabla(x, y) - \nabla(x, y)_{MIN}) \Gamma_g)^2} \quad (10)$$

이때  $\nabla(x, y)$ 는  $(x, y)$ 좌표에서의 인접픽셀과의 밝기값의 경사도이다.

$$\Gamma_g = \frac{1}{\nabla(x, y)_{MAX} - \nabla(x, y)_{MIN}}$$

$f(x, y)$  값이 작을수록  $(x, y)$ 좌표가 훈련된 형태의 모양을 형성하는 기준점의 위치일 확률이 높다는 것을 의미한다.

### 3.2.3 형상 모델 추출

입력영상을 앞 절에서 생성한 모델의 형태로 변환하기 위해서 입력 영상에 적합한 벡터  $\mathbf{b}$ 를 찾아야 한다. 능동형상모델 알고리즘에서는 다음과 같은 단계의 작업을 수행함으로써 적합한 벡터  $\mathbf{b}$ 를 찾아 입력 영상에 근사한 형상 모델을 구한다.

- 초기 모델을 생성한다 :

$$\mathbf{x}_m \rightarrow \bar{\mathbf{x}}, \mathbf{b}_m = 0, m = 0$$

- $\mathbf{x}_m$ 에 인접한 픽셀을 검색하여 현재 영상에 가장 적합한 형태 모델 찾아 새로운  $\mathbf{x}_m$ 을 생성한다 :

$$\mathbf{x}_m \rightarrow \hat{\mathbf{x}}_m$$

이때 모든 기준점에 대해 현재의 위치  $(x, y)$ 를 중심으로 양 옆의  $2.5 * N_1 * (m_{max} - m) / m_{max}$  범위 안에 있는 모든 픽셀의  $f(x, y)$ 값을 구하여 가장 작은 값을 가지는 위치를 새로운 기준점 위치  $(x', y')$ 로 한다. ( $m_{max}$ 는 최대 반복회수이다.)

- $\mathbf{b}_m$ 을 생성한  $\hat{\mathbf{x}}_m$ 을 이용하여 갱신한다 :

$$\mathbf{b}_m = P^T (\hat{\mathbf{x}} - \bar{\mathbf{x}})$$

이때  $\mathbf{b}_m$ 의 각 구성 요소에 제약 조건 ( $|\mathbf{b}_k| \leq 3\sqrt{\lambda_k}$ ) 을 적용하여 형태의 과도한 변형을 피한다.

- $\mathbf{b}_m$ 을 이용하여 새로운 모델을 생성한다 :

$$\mathbf{x}_{m+1} = \bar{\mathbf{x}} + P \mathbf{b}_m$$

- 모델이 수렴할 때까지 2~4를 반복한다

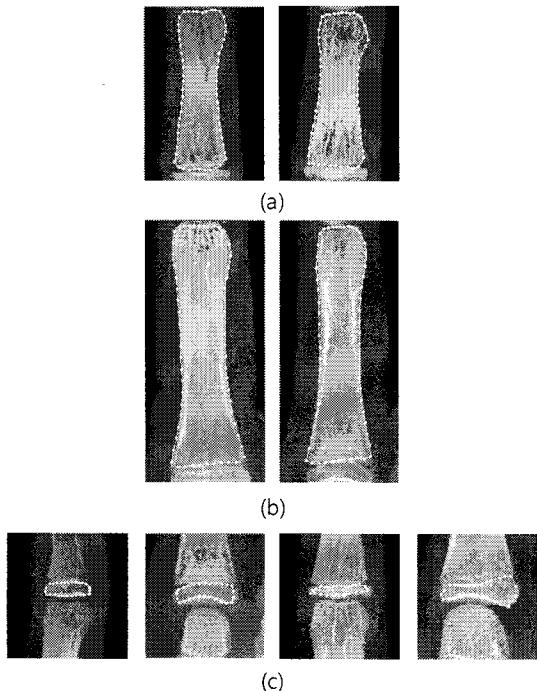


그림 11. 형상 추출 결과 영상 (a) 중간 마디 뼈 (b) 끝 마디 뼈 (c) 골단판

위의 알고리즘과 제안한 적합 함수를 이용하여 뼈 및 골단판 하위 영상에 대해 형상 모델을 추출한 결과는 그림 11과 같다.

### 3.2.4 입력 영상에 대해 정규화된 모델 생성

정규화된 모델 생성 단계에서는 앞 단에서 각 손가락 별로 생성한 5개의 형상들을 모아 하나의 손가락 모델을 만드는 것을 목적으로 한다. 본 논문에서는 5개의 모델들을 하나의 손가락 모델로 종합하기 위해 각 모델들 간의 지역적인 상관관계를 도입하였다. 이때 각 모델들 간의 무게 중심 및 인접 지역 간의 거리 측정을 통하여 정규화된 손가락의 뼈 모델을 생성하게 된다. 대부분의 입력 영상의 손가락뼈들은 직선으로 바로 선 형태를 취하지 않고 약간씩 휘어 있게 된다. 그러나 정확한 특징값 추출을 위해서는 손가락이 직선의 형태를 취하고 있어야 한다. 이를 위해 각 하위 모델들의 PCA분석[19]을 통해 하위 모델 별로 가장 큰 축을 찾는다. 기준 축을 추출한 후에는 뼈 모델의 경우 형상의 가장 큰 축이 수직으로 정렬되도록 하고, 골단판의 경우 형상의 가장 큰 축이 수평 정렬이 되도록 형상 모델을 회전한다. 각각

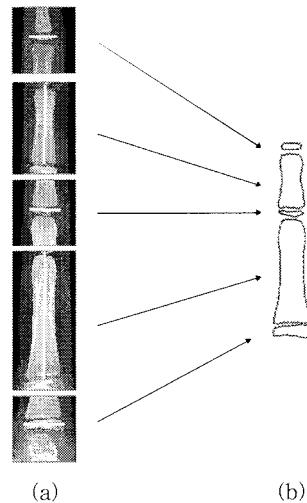


그림 12. 정규화된 손 모델 생성 결과 (a) 하위 모델들의 능동 형상모델 적용 결과 및 기준축 (b) 정규화된 최종 결과

의 모델들이 수직 수평 정렬되면 각 모델들의 무게중심을 구하여 원본 영상에서 무게중심 간의 거리를 측정한다. 이 무게중심 간의 거리를 바탕으로 형상 모델들을 수직 정렬하면 그림 12와 같이 하나의 정규화된 손가락 모델이 생성된다. 그림 12의 (a)는 각각의 하위 모델에 대한 능동형상모델 추출 결과와 기준축이고, (b)는 하위 모델간의 좌표계를 통일한 손가락의 정규화된 형상 모델이다. 각 손가락의 정규화된 모델들은 지정된 위치간의 거리 측정을 통해 특징값을 추출하는데 이용된다.

## 4. 뼈 나이 인식 알고리즘

### 4.1 특징값

기존의 뼈 나이 인식 논문에서는 뼈 나이를 측정하기 위한 특징값으로 뼈의 절대 길이 또는 뼈에서 2개의 특징이 되는 길이를 측정하여 그 길이의 비를 사용하였다. 그러나 뼈의 절대 길이는 뼈 성장에 따른 개인 차이를 반영하기 때문에 나이 인식에는 적합하지 않고 부분적인 비율만으로는 전체적인 뼈 성장 정도를 측정하기 어렵다. 따라서 본 논문에서는 하나의 손가락뼈에서 특징되는 모든 구간의 절대 길이와 각 길이간의 비를 특징값으로 사용하여 뼈 나이 측정 정확도를 향상시켰다.

본 논문에서 뼈 나이 인식을 위해 사용한 특징값

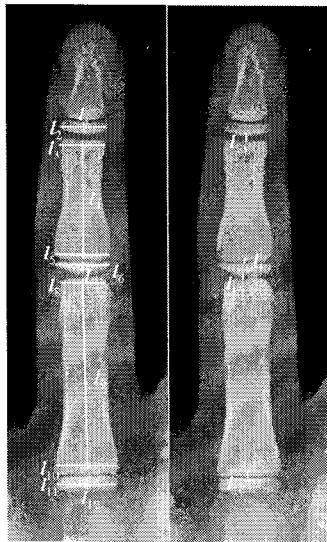


그림 13. 손가락의 특징값

벡터는 뼈의 절대 길이와 절대 길이 간의 비율로 구성된다. 그림 13과 같이 각 손가락 뼈 사이의 거리를 이용하여  $l$ 을 구성하였으며  $l$ 간의 비율을 이용하여 식 (12)과 같이  $r$ 을 구성하였다. 뼈 특징값의 학습 집합( $F$ )를  $m$ 개의 집합으로 표현하면 식 (11)과 같고 각각의 벡터는 27개의 원소를 가지는 식 (12)와 같다.

$$F = \{f'_1, f'_2, \dots, f'_m\} \quad (11)$$

$$f_m = \{l_1, \dots, l_{16}, r_1, \dots, r_{11}\} \quad (12)$$

$$\begin{aligned} r_1 &= \frac{l_2}{l_1}, r_2 = \frac{l_2}{l_{13}}, r_3 = \frac{l_3}{l_4}, r_4 = \frac{l_5}{l_4}, \\ r_5 &= \frac{l_5}{l_{14}}, r_6 = \frac{l_6}{l_{15}}, r_7 = \frac{l_6}{l_{15}}, r_8 = \frac{l_8}{l_9}, \\ r_9 &= \frac{l_{10}}{l_9}, r_{10} = \frac{l_{10}}{l_{16}}, r_{11} = \frac{l_{11}}{l_{12}} \end{aligned}$$

훈련 시 각 특징값의 절대값의 크기에 따른 오차를 최소화하기 위해서 식 (13)과 같이 정규화된 값이 사용되며 사용된 식은 식 (14)와 같다.

$$f'_m = \{l'_1, \dots, l'_{16}, r_1, \dots, r_{11}\} \quad (13)$$

$$l'_i = \frac{l_i - l_i^{\min}}{l_i^{\max} - l_i^{\min}}, i = 1, 2, \dots, 16 \quad (14)$$

이때  $l_i^{\max}$  와  $l_i^{\min}$ 는 전체 훈련 데이터 중에서 각각 최대값과 최소값을 의미한다.

## 4.2 SVM (Support Vector Machine)

SVM은 두 개의 그룹을 분류하기 위한 제한된 알고리즘으로써 두 그룹 간에 가장 큰 마진을 가지는 초평면(hyperplane)을 찾아 그룹을 분류하는 기법이다[15-18]. 특히 SVM은 훈련하고자 하는 개체의 수가 적고 특징ベ터의 차원이 높은 경우에 효과적인 방법이며 처리속도가 빠르고 인식 성능이 뛰어나 다양한 분야에서 응용되고 있다. 본 논문에서는 훈련 영상의 개체수가 적음을 극복하고 효과적인 인식 성능 보장을 위해 SVM을 사용하여 뼈 나이를 추정하였다.

### 4.2.1 Support Vector Machine 학습

식 (14)과 같은  $N$ 개의 훈련 데이터가 있다고 가정할 때 SVM은 가장 효과적인 초평면을 구하여 두 개의 범주를 구분하는 샘플들을 나눈다.

$$\begin{aligned} &\{\mathbf{x}(1), \mathbf{y}(1)\}, \{\mathbf{x}(2), \mathbf{y}(2)\}, \dots, \\ &\{\mathbf{x}(N), \mathbf{y}(N)\} \end{aligned} \quad (15)$$

이때  $\mathbf{x}(i)$ 는  $n$  차원을 가지며 훈련 데이터 중  $i$  번째인 식 (16)과 같은 벡터이고

$$\mathbf{x}(i) = [a_1, a_2, \dots, a_n]^T \quad (16)$$

$\mathbf{y}(i)$ 는 +1 또는 -1의 값을 가지는 그룹 분리 레이블이다.

그림 14에서와 같이 두 범주를 분리하는 초평면을 벡터의 내적으로 표현하면 식 (17)과 같다.

$$\mathbf{w}^T \mathbf{x}(i) + b = 0 \quad (17)$$

이때  $\mathbf{w} = [w_1, w_2, \dots, w_n]^T$ 이고  $b$ 는 스칼라 값이다. 가

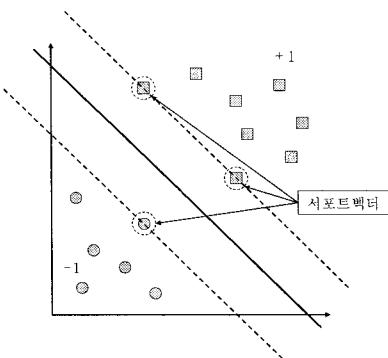


그림 14. 최적 초평면

중치 벡터  $\mathbf{w}$ 는 식 (19)를 제약 조건으로 하는 식(18)과 같은 최적화 문제를 통해 결정된다[18].

$$\mathbf{w}^* = \arg \min_w \frac{1}{2} \|\mathbf{w}\|^2 \quad (18)$$

$$\text{제약 조건 : } \mathbf{y}(i)[\mathbf{w}^T \mathbf{x}(i) + b = 0] \geq 1, i = 1, 2, \dots, N \quad (19)$$

일반적으로 선형 초평면으로 데이터 범주의 구분이 가능한 경우 식 (18)의 최적화 문제를 통해 해결이 가능하나 선형 초평면으로 범주의 구분이 불가능할 경우에는 훈련 데이터에서 에러의 개수를 최소로 하는 초평면을 찾는 것으로 식 (18)을 변형하여야 한다. 선형 초평면에 대한 범주 구분 오차를 최소화하기 위해서 가중치 벡터  $\mathbf{W}$ 는 식 (20)과 같이 변형된 최적화 문제로 결정한다.

$$\mathbf{w}^* = \arg \min_w \frac{1}{2} \|\mathbf{w}\|^2 + c \sum_{i=1}^N \zeta(i) \quad (20)$$

$$\text{제약 조건 : } \mathbf{y}(i)[\mathbf{w}^T \mathbf{x}(i) + b = 0] \geq 1 - \zeta(i) \quad (21)$$

이때  $c > 0$ ,  $\zeta(i) > 0$ 이다. 최적화 문제 식 (18), 식 (20)은 라그랑지(lagrange) 방법으로 해결 가능하며 최적화된 결정 함수(decision function)는 식 (22)와 같다.

$$\begin{aligned} \hat{\mathbf{y}} &= \text{sgn}[\mathbf{w}^T \mathbf{x} + b] \\ &= \text{sgn} \left[ \sum_{i=1}^L \alpha(i) \mathbf{y}_s(i) s^T(i) \mathbf{x} + b \right] \end{aligned} \quad (22)$$

이때  $\alpha(i), i = 1, 2, \dots, L$ 는 라그랑지 계수,  $s(i), i = 1, 2, \dots, L$ 는  $\alpha(i) > 0$ 인 샘플,  $\mathbf{y}_{s(i)}, i = 1, 2, \dots, L$ 는  $\alpha(i) > 0$ 인 표본에 대응하는 그룹 레이블이다. 식 (22)에서 주목할 것은 결정 함수를 구성하는데 단지  $L$ 개의 표본만이 사용된다는 것이다. 이  $L$ 개의 표본은 서포트 벡터(support vector)라고 불리며 초평면에서 가장 가까이에 위치한 데이터이다.

비선형 SVM은 데이터들이 선형적으로 분리가 불가능할 때 입력 벡터를 비선형 투영 함수( $\phi$ )를 이용하여 고차원으로 투영시켜 데이터를 선형적으로 분리 가능하게 한 다음 고차원에서 최적화된 초평면을 찾는 방법이다. 일반적으로 비선형 SVM에서는 고차원에서 서포트 벡터( $\phi(s)$ )와 패턴 벡터( $\phi(x)$ )와의 내적 계산에 커널 함수( $K$ )를 이용하여 계산을 단순화 시킨다. 비선형 SVM에서 입력 벡터  $X$ 에 대하여 결정함수는 식 (23)과 같으며 일반적으로 사용되는

커널 함수는 식 (24)와 같다.

$$\hat{\mathbf{y}} = \text{sgn} \left\{ \sum_{i=1}^L \alpha(i) \mathbf{y}_s(i) K[s(i), \mathbf{x}] + b \right\} \quad (23)$$

$$\text{가우시안 커널 : } K[s(i), \mathbf{x}] = \exp \left[ -\frac{\|s(i) - \mathbf{x}\|^2}{2\sigma^2} \right], \sigma \geq 0$$

$$\text{다항식 커널 : } K[s(i), \mathbf{x}] = [s^T(i) \mathbf{x} + 1] \quad (24)$$

#### 4.2.2 훈련 및 나이 인식

본 논문에서는 각각의 전문의에 의해 뼈 나이가 진단된 영상들 중에서, 각 나이 별로 5씩의 영상을 사용하여 약지, 중지, 검지 세 손가락에 대해 각각 4.1절에 기술된 특징값을 추출해 손가락 별로 SVM 훈련을 실시하였다. 이 때, 이진 분류기인 SVM을 이용해서 5~15살의 나이를 분류하기 위해서 일대다방식의 SVM 훈련을 사용하였다. 일대다 방식은 하나의 클래스와 나머지 모든 클래스를 분류하는 초평면을 각각의 클래스에 대해 구하고 입력 벡터를  $N$ 개의 SVM 결과에 대해 가장 높은 값을 가지는 클래스로 분류하는 방식이다. 즉,  $N$ 장의 훈련 데이터에서 각각 추출된 세 손가락에 대해서 능동형상모델을 이용해서 특징값을 추출하고, 세 손가락에 대해서 각각 하나씩의 식 (23)의 결정함수를 훈련을 통해서 얻는다. 이후, 뼈 나이 인식은 입력된 영상에서 추출된 세 손가락의 특징벡터에 대해서, 각각의 결정함수를 계산하여 최대값을 갖는 나이를 각 손가락의 나이로 결정하며, 한 영상에 대한 최종적인 뼈 나이는 세 손가락의 평균 나이를 사용하였다. SVM의 훈련과정에서 각 손가락마다 최적의 결정함수를 얻어내기 위해서, 각각의 값을 변화시켜면서 훈련과 인식을 반복하면서, 가장 좋은 성능을 보이는 식 (23)과 식 (24)의 커널의 파라미터와, 패널티  $c$ 의 값을 실험적으로 결정하였다.

## 5. 실험 및 결과

본 논문에서 사용된 뼈 나이 측정 알고리즘의 검증을 위해 사용된 데이터베이스는 한양대학교 부속 병원의 소아과에서 뼈 나이 측정을 위해 촬영된 317 장의 5~15세 사이의 여아의 X-ray 영상을 이용하여 구축하였다. 데이터베이스 내의 모든 영상은 고해상

도의 DICOM 영상으로 구성되었으며 소아내분비학회 전문가가 평가한 뼈 나이를 실험 결과의 검증에 사용되었다.

ASM 훈련에는 각 나이를 대표하는 X-ray 영상에서 추출한 뼈 영상을 이용하였으며 5개 각각의 형상 모델을 생성하기 위해 190개의 뼈 영상이 사용되었다. 학습 영상의 중간 마디 뼈는 200\*300, 끝 마디 뼈는 200\*500, 각 골단판은 200\*200의 크기로 정규화하였다. 뼈 나이 인식을 위한 SVM 훈련을 위해서는 전체 데이터베이스 중 나이별로 5장씩 임의로 선택된 55장의 영상에서 얻은 특징값을 사용하였다. 훈련을 위해 가장 좋은 결과를 보여주는  $\sigma = \sqrt{28}$  인 가우시안 커널을 이용하고 패널티  $c=100$ 을 적용하였다.

본 논문에서 제안한 특징값과 뼈 나이 측정 방법의 타당성을 검증하기 위해서 능동형상모델을 이용하여 뼈 나이를 추정하는 M. Niemeijer가 제안한 방법과 뼈 나이 추정 결과를 비교하였다.

그림 15는 데이터베이스 내의 전체 영상을 전문가

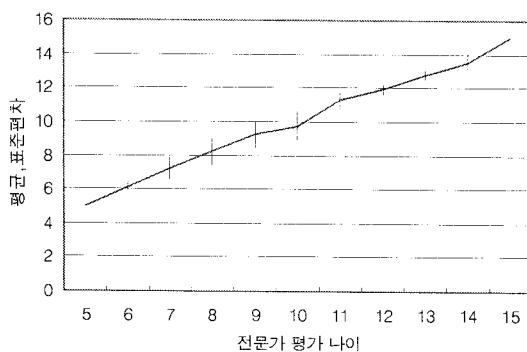


그림 15. 제안한 특징값을 사용하여 측정한 뼈 나이와 전문가 평가 나이와의 비교

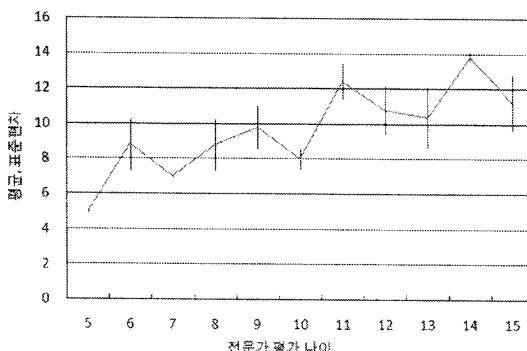


그림 16. M. Niemeijer의 방법을 사용하여 측정한 뼈 나이와 전문가 평가 나이와의 비교

측정 나이별로 구분하여 각 나이별로 제안한 특징값을 이용하여 추정한 나이의 평균과 표준 편차를 구한 것이다. 가로축은 전문가가 측정한 나이이며 세로축은 제안한 특징값을 사용한 결과이다. 그래프의 가운데 선은 나이별 평균을 연결한 것이며 세로선은 나이별 표준편차의 크기를 나타낸 것이다. 전체 데이터에 대하여 전문가 평가 나이와 제안한 특징값에서 추출한 뼈 나이 사이에는 평균 0.54살(표준편차 0.21)의 차이가 발생했다. 일반적으로 임상에서 시행되는 뼈 나이 평가 방법에서는 평가 방법에 따라 1~1.5살의 평가 오차가 차이가 발생하는데 이것은 뼈 나이 평가에 있어서 무시할 수 있는 오차 범위로 간주하고 있다. 따라서 본 논문에서 제안하는 특징값을 사용한 결과가 오차 범위 1살 안에 들어가므로 제안한 특징값을 이용한 뼈 나이 평가 방법이 타당하다고 볼 수 있다.

그림 16은 제안한 방법과 동일한 전처리를 하여 M. Niemeijer의 뼈 나이 측정 방법을 이용하여 뼈 나이를 측정한 것으로, 제안하는 방법과 굳이 비교하지 않더라도 실험 데이터 셋에서 좋지 않은 결과를 보여 주고 있다. M. Niemeijer의 방법이 [11]에서 주장한 것에 비하면 상당히 좋지 않은 결과를 나타내었는데, 이것은 영상의 관심영역에서 두 영상의 유사도를 이용하는 M. Niemeijer의 방법은 손가락 뼈와 골단판이 분리되어 있는 5세에서 10세 사이의 연령에만 적용 가능하고, 유사도 계산 방법이 영상의 노이즈에 취약하기 때문에 발생한 결과로 판단된다. 그러나 본 논문에서 제안하는 방법은 보다 넓은 연령대에 적용 가능하며 전문가의 뼈 나이 측정 결과와 비교하였을 때 수용 가능한 오차를 보임으로써 M. Niemeijer의 방법보다 우수하다고 할 수 있다.

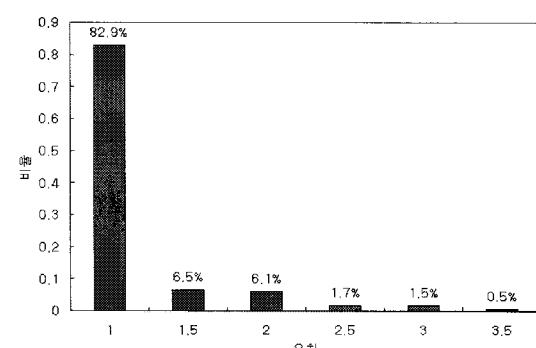


그림 17. 오차 범위에 따른 개체 비율

표 1. 제안하는 방법의 나이 측정 결과와 전문가 평가간의 오차

	평균	Case1	Case2	Case3	Case4	Case5	Case6	Case7	Case8	Case9	Case10
평균오차	0.679	0.327	0.842	0.883	0.743	0.737	0.326	0.667	0.626	0.681	0.955
표준편차	0.774	0.543	0.837	0.905	0.860	0.864	0.563	0.749	0.737	0.763	0.921

최종적으로 뼈 나이 인식 성능 측정을 위해 데이터베이스에 포함된 전문가가 평가한 뼈 나이와 알고리즘을 통해 나온 결과를 비교하여 통계적인 특성을 분석하였다. 성능 평가는 전체 데이터를 10개의 집단으로 무작위로 나누어 각각을 훈련 데이터 및 테스트 데이터로 번갈아 가면서 측정하는 교차검증(Cross validation)방식을 사용하였다. 표 1은 10개의 훈련 집단에 대한 테스트 집단의 정확도와 평균값이며 그림 17은 실험 결과에 따른 오차 범위가 1~3.5살에 해당하는 개체의 비율이다.

표 1에서 보는 바와 같이 제안한 방법은 평균 0.679(표준편차 0.774)의 오차를 보였으며 실험 결과 비교 대상인 E. Pietka가 제안한 방법은 평균 1.13살의 오차를 보였다. 실험에 사용된 영상이 다르기 때문에 직접적인 비교는 불가능하지만, E. Pietka 알고리즘이 평균 1살 이상의 오차를 나타내는 것에 비해, 제안한 방법은 평균적으로 0.679살의 오차를 보였으며, 최악의 경우 최대 측정 오차는 3.9살 이었다. 또한 그림 13에서 보는 바와 같이 오차 범위가 1살 이내에 있는 개체의 비율이 82% 이상이고 2살 이내의 개체 비율이 95%를 넘는 것은 제안한 방법의 신뢰도가 매우 높다는 것을 보여준다.

## 6. 결 론

본 논문에서는 원손을 촬영한 X-ray 영상에서 능동형상모델을 이용하여 뼈 나이를 자동으로 평가하는 방법을 제안하였다. 제안하는 방법은 손가락뼈의 각 부분을 자동으로 분류하는 과정과 분류된 뼈 영상으로부터 정규화된 형상 모델을 추출하는 과정, 그리고 정규화된 형상 모델로부터 뼈 나이를 측정하는 과정으로 구성된다. 정규화된 손가락의 형상모델은 능동형상모델을 이용하여 원손 X-ray로부터 추출되며, 이를 위해 손가락뼈를 5단계로 나누어 회전이나 휘어짐을 보정한 정규화된 하위 모델을 생성함으로써 전체를 하나의 모델로 추출하는 것에 비해 보다 정교한 결과를 얻었다. 또한 본 논문의 알고리즘에서

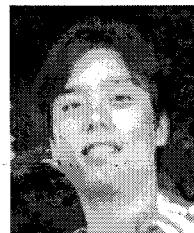
는 각 뼈의 중요한 절대 길이뿐만 아니라 각 길이간의 상대 길이를 모두 사용하여 평균 0.679살의 진단 오차를 보임으로써 자동 뼈 나이 진단이 실제 의료활동에 적용될 수 있는 가능성을 확인하였다.

현재 뼈 나이 인식에 있어 가장 중요한 부분은 특징값을 정확하게 측정하는 것이다. 제안한 알고리즘이 능동형상모델을 사용하여 특징값을 기준의 방법에 비해 정확하게 측정하고 있지만 앞으로 뼈 영상의 특징을 이용한 더욱 정확한 특징값 추출 방법의 연구가 필요하다. 또한 실제 의료 활동에 사용되기 위해서는 제안한 방법으로 측정된 뼈 나이와 전문의에 의해 측정된 뼈 나이간의 신뢰도에 관한 연구도 이루어져야 한다.

## 참 고 문 헌

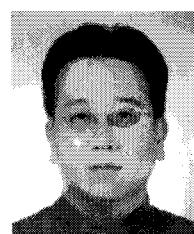
- [1] W. W. Greulich and S. I. Pyle, Radiographic Atlas of Skeletal Development of the Hand and Wrist, Stanford University Press, San Francisco, Calif., 1959.
- [2] W. W. Greulich and S. I. Pyle, Radiographic Atlas of Skeletal Development of the Hand and Wrist 2nd ed., Stanford University Press, San Francisco, Calif., 1971.
- [3] J. M. Tanner and R. H. Whitehouse, Assessment of Skeletal Maturity and Prediction of Adult Height (TW Method), Academic Press, London, 1962.
- [4] J. M. Tanner and R. H. Whitehouse, Assessment of Skeletal Maturity and Prediction of Adult Height (TW2 Method), Academic Press, London, 1975.
- [5] J. M. Tanner and R. H. Whitehouse, Assessment of Skeletal Maturity and Prediction of Adult Height 2nd ed., Academic Press, London, 1983.
- [6] E. Pietka and Lotfi Kaabi, "Feature Extraction

- in Carpal-Bone Analysis," IEEE Transactions on Medical Imaging, Vol.12, No.1, pp. 44-49, 1993.
- [7] E. Pietka and M. F. McNitt-Gray, "Computer-Assisted Phalangeal Analysis in Skeletal Age Assessment," IEEE Transactions on Medical Imaging, Vol.10, No.4, pp. 616-620, 1991.
- [8] E. Pietka and A. Gertych, "Computer-Assisted Bone Age Assessment: Image Preprocessing and Epiphyseal/Metaphyseal ROI Extraction," IEEE Transaction on Medical Image, Vol.20, No.8, pp. 715-729, 2001.
- [9] E. Pietka and S. Pospiech-Kurkowska, "Integration of Computer Assisted Bone Age Assessment with Clinical PACS," Computerized Medical Imaging and Graphics, Vol.27, No.2-3, pp. 217-228, 2003.
- [10] B. C. Fan and C. W. Hsieh, "Automatic Bone Age Estimation Based on Carpal-bone Image: A Preliminary Report," Chinese Medical Journal(Taipei), Vol.64, No.4, pp. 203-208, 2001.
- [11] M. Niemeijer and B. van Ginneken, "Assessing the Skeletal Age from a Hand Radiograph: Automating the Tanner-Whitehouse Method," Proceeding of SPIE Medical Imaging, Vol.5032, pp. 1197-1205, 2003.
- [12] T. F. Cootes and C. J. Taylor, "Active Shape models - Their Training and Application," Computer Vision and Image Understanding, Vol.61, No.1, pp. 38-59, 1995.
- [13] T. F. Cootes and A. Hill, C. J. Taylor, "The Use of Active Shape Models for Locating Structures in Medical Images," Image and Vision Computing, Vol. 12, No. 6, pp. 355-366, 1994.
- [14] M. Kass and A. Witkin, "Snakes: Active Contour models," International Journal of Computer Vision, Vol.1, No.4, pp. 321-331, 1988.
- [15] V. Vapnik, The Nature of Statistical Learning Theory, Springer-verlag, New York, 1995.
- [16] C. J. C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition," Data Mining and Knowledge Discovery, Vol.2, No. 2, pp. 121-167, 1998.
- [17] B. Scholkopf, Support Vector Learning, Oldenburg-Verlag, Munich, 1997.
- [18] E. Osuna and R. Fereund, "Training Support Vector Machines : An Application to Face Detection," Proceeding IEEE. Computer Vision and Pattern Recognition, pp. 130-136, 1997.
- [19] 황재문, 장석환, "컴퓨터 비전 기법을 이용한 자동 뼈 나이 측정 시스템," 신호처리합동학술대회, 제17권, 1호, pp. 91-91, 2004.
- [20] R. C. Gonzalez, Digital Image Processing, Pearson Prentice Hall, New Jersey, 1992.
- [21] J.M. Lee, W.H. Kim, "Epiphyses Extraction Method Using Shape Infromtion for Left hand Radiography," International Conference on Convergence and Hybrid Information Technology 2008, pp. 319-326, 2008.



유 주 완

2005년 한양대학교 전자전기공학부 학사  
2007년 한양대학교 전자통신컴퓨터공학과 석사  
2007년 현재 삼성전자 TN 재직중  
관심분야 : 영상처리, 의료영상, 뼈 나이



이 종 민

1994년 경원대학교 토목공학과 학사  
2003년 한양대학교 정보통신대학원 소프트웨어공학과 석사  
2004년~현재 한양대학교 전자컴퓨터통신공학과 박사  
관심분야 : 머신비전, 의료영상, 세그멘테이션,



김 회 율

1980년 한양대학교 전자공학과  
졸업 (공학사)  
1983년 Pennsylvania State  
University 전기공학과  
졸업 (공학석사)  
1989년 Purdue University 전기  
공학과 졸업 (공학박사)

1989년 9월~1994년 2월: University of Texas 조교수

1994년~현재 한양대학교 전자통신컴퓨터공학부 정교수

관심분야 : 영상처리, 컴퓨터비전, 패턴인식, 머신비전,  
MPEG-7 등