

# 신경회로망을 이용한 흉부 X-선 영상에서의 폐 영역분할

<sup>\*,\*\*</sup> 김 중효, <sup>\*</sup> 박 광석, <sup>\*</sup> 민 병구, <sup>\*\*\*</sup> 임 정기, <sup>\*\*\*</sup> 한 만정, <sup>\*\*</sup> 이 충용

<sup>\*</sup> 서울의대 의공학교실, <sup>\*\*</sup> 서울 대학교 전자공학과, <sup>\*\*\*</sup> 서울의대 방사선학 교실

## Lung Area Segmentation in Chest Radiograph Using Neural Network

<sup>\*,\*\*</sup> Jong Hyo Kim, <sup>\*</sup> Kwang Suk Park, <sup>\*</sup> Byoung Goo Min, <sup>\*\*\*</sup> Jung Gi Im, <sup>\*\*\*</sup> Man Cheong Han, <sup>\*\*</sup> Choong Woong Lee

<sup>\*</sup> Dept. of Biomed. Eng., college of Med., SNU. <sup>\*\*</sup> Dept. of Elec. Eng., SNU. <sup>\*\*\*</sup> Dept. of Radiology, college of Med., SNU.

### Abstract

In this paper, a new method for lung area segmentation in chest radiographs has been presented. The motivation of this study is to include fuzzy informations about the relation between the image data structure and the area to be segmented in the segmentation process efficiently.

The proposed method approached the segmentation problem in the perspective of pattern classification, using trainable pattern classifier, multi-layer perceptron.

Having been trained with 10 samples, this method gives acceptable segmentation results, and also demonstrated the desirable property of giving better results as the training continues with more training samples.

#### 1. 서론

흉부 X-선 영상은 의학 영상중에서 가장 많은 정보를 포함한 영상으로서 임상적으로 대단히 광범위한 질병의 초기 진단의 수단으로 이용되고 있다.

그러므로 이러한 흉부 X-선 영상의 판독과정에 컴퓨터를 이용하고자 하는 노력이 일찍부터 있어왔다. 흉부 X-선 영상의 가장 기본적인 특징인 폐영역의 분할은 이러한 자동진단 문제에 있어서 기초를 이루면서 동시에 그 자체로서 심장질환의 진단에 직접적으로 이용되기도 한다[1].

Ernest L. Hall 등은 체단 노동자들의 진폐증의 자동진단의 전 처리과정으로서 histogram thresholding 기법을 이용하여

폐 영역을 구분하였다[2]. Dana H. Ballard 등은 tumor 의 자동 진단 과정의 첫 단계로서 heuristic search 을 사용하여 먼저 저 해상도 영상 에서 대략의 폐 윤곽을 정한다음 상위 해상도 영상에서 자세한 윤곽을 결정하고 이 폐영역 내에서 tumor 의 검출 과정을 수행하였다[3]. E. X. Roellinger 등은 곡선에 제한을 준 line 별 최대 edge 값 검출방법으로 심장 윤곽을 얻고, 이로부터 Fourier 파라미터를 추출하여 선형성 심장질환의 진단에 응용하였다[4].

이밖에 J. W. Modestino 등은 heuristic tree search 인 ZJ algorithm 을 이용하여 폐 윤곽검출을 하였는데, 여기서는 edge 값, 곡부 곡률, 그리고 prototype outline 과의 거리등을 인수로 하는 누적 경로 측정자(cumulative path metric)를 정의하고 이 값을 최대로 만드는 pixel 을 추적함으로써 폐 윤곽을 검출하였고[5], Charlse Harow 는 하향 접근 개념을 도입하여, 구하려는 영역들의 전형적인 위치들에서부터 region growing 을 시작하여 서로 마주치는 지점에서 경계를 정하는 방식으로 하여 폐, 종격부, 팔부위등으로 영역분할을 하였다[6].

이상과 같이 다양한 방법들이 X-선 영상의 폐영역 분할을 위하여 제시되어왔다. 이러한 기존의 방법의 공통적인 기본 개념은 그림 1과 같이 정리할 수 있다. 즉, 각 화소의 주변의 분포로부터 국부적 특징을 구하는 과정, 영상전체의 분포로부터 전체적 특징을 구하는 과정, 그리고 이들의 상호관계를 고려하여 각 화소가 어느 영역에 속할 것인지를 결정하는 판정과정으로 구성되어 있는 것이다. 이렇게 볼때 영역분할은 넓은 의미에서 패턴분류의 범주에 속한다고 볼수 있다.




그림 1. 폐면 분류의 구조로 표현한 폐 영역분할과정.

Fig. 1. The lung area segmentation process represented with the structure of pattern classification.

그런데 기존의 방법들에서는 각 과정에서의 rule 과 parameter 그리고 threshold 들이 설계자의 경험적 지식에 의해 미리 정해진 값을 가지게 되어있다. 따라서 각 방법의 성능이 설계자의 경험에 좌우될수 밖에 없고, 미리 고려하지 못한 경우에는 결과가 예상보다 썩 좋지 않게 나오기도 하였다.

본 논문에서는 이와 같은 기존 방법의 기본개념을 탈피하여, 영상의 data로부터의 특징추출, 특징들간의 상호 연계및 합산, 판정등의 모든 과정을 컴퓨터가 자율적으로 수행하도록 하며, 학습을 통하여 그 성능을 향상시킬수 있도록 하는 새로운 영상 영역분할 방법을 제시하고자 한다.

그 구체적인 방법으로는 영역분할 문제를 패턴분류의 문제로 취급하고 최근 그 탁월한 패턴분류성능으로 각광을 받고 있는 신경 회로망을 이용하여 입력 영상의 각 화소들 폐 내부, 또는 외부 영역으로 분류하는 것이다.

## 2. 패턴분류로서의 영역분할

앞서 제기한 바와 같이 기존의 영역분할 방법 자체가 패턴분류 형식을 취하고 있다. 예를 들어 histogram thresholding 방법의 경우 threshold를 구하는 것은 주어진 data set로부터 decision threshold 를 구하는 과정이고, 이후의 과정은 각 data 를 분류하는 과정이며, tree search방법 역시 각 화소의 edge값, 국부 곡률, prototype outline 과의 거리등의 누적이므로부터 path의 cost 를 얻어내는 과정은 특징 추출 과정에 해당하고, 여러개의 가능한 path 들중 최소cost 를 갖는 path 를 결정하는 과정은 판정 과정에 해당하는 것이다. 다만 이경우는 각 화소단위가 아닌 path 단위로 판정된다는 점이 다른 뿐이다.

영역분할 문제를 포함하여 모든 패턴분류 문제에 있어서 가장 중요한 것은 data set 의 패턴의 분포에 관한 지식을 어떻게 분류과정에 적용시키느냐 하는것인데, 그 방법은 크게 두가지로 분류된다. 첫번째는 입력되는 data 들의 특징, 분포등에 관한 지식을 설계자가 미리 함수나 파라미터 등의 형태로 분류

과정속에 내장시키는 방법이고, 다른 하나는 sample data를 이용한 training의 형태로 분류기 내에서 그 분류과정에 필요한 지식이 스스로 형성되도록 하는것이다.

두 방법모두에 일장 일단이 있으나 입력 data에 관한 특징과 분포를 정확하게 알수 없고, 충분한 training sample 을 얻을수 있을 경우는 후자의 방법을 택하는 것이 안전하다.

영역 분할문제에 있어서 이제까지 제시되었던 방법들은 모두 전자의 방법, 즉 영역 분할에 필요한 지식을 설계자가 분할과정에 내장시키는 형태를 취하였다. 그런데 흉부 X-선 영상의 폐 영역 분할 문제에 있어서 입력 영상들의 대체적인 분포와 특징에 관한 지식은 얻을수 있으나 그 분포의 범위가 넓고 그 지식을 구체적인 함수나 파라미터로 표현하기에는 애매한 것이 많으며, 반면에 training sample 은 충분히 확보할수 있는 경우이다.

본 논문에서는 이와같은 점에서 이제까지의 흉부영역 분할 방법과는 달리training 식의 분류기를 사용함으로써 수식으로 표현하기에 애매한 지식까지도 무리없이 분류기내에 형성되도록 하여 개선된 분할성능을 얻는 새로운 흉부영역 분할방법을 시도하였다. 분류기로는 그 탁월한 분류성능과 잡음에 강한 특징등으로 각광을 받고 있는 신경회로망 분류기 multi-layer perceptron(MLP) 을 사용하였다.

## 3. 신경회로망 분류기

본 연구에 사용한 신경회로망 분류기 multi-layer perceptron의 구조를 그림 2 에 보였다. MLP 는 잘 알려진 바와 같이 단순한 기능을 가진 neuron 들이 feed-forward 형태로 상호연결된 회로망이며 반복학습에 의해 이 시냅스들의 연결강도가 적절한 형태로 정착되면 이 연결강도의 분포가 학습된 지식을 포함하게 된다. 입력 data 분포의 경계가 복잡할수록 더 많은 수의 은닉 node가 요구되고, 만일 한 범주의 data 의 분포가 분리되어 있는 경우에는 2 단의 은닉층이 요구되는데 흉부 영역 분할의 경우에는 분리된 분포가 아니라고 생각되므로 본 실험에서는 1 단의 은닉층을 갖는 2 layer perceptron 이 사용되었다.

일반적인 패턴분류 방법에서는 처리 시간을 줄이기 위하여 입력 data 로부터 특징성분만을 추출하여 분류하는 것이 상례이나 본 연구에서는 이러한 특징 추출과정 까지도 포함된 분류기를 목적으로하므로 영상 data 자체를입력하도록 하였다.




그림 2. 2 층 퍼셉트론의 구조.

Fig. 2. The structure of 2 layer perceptron.

다만 사용한 컴퓨터의 용량을 고려하여 해상도를 32 x 32로 줄여 사용하였는데, 시각적으로 판단할때 이 정도의 해상도로서도 폐 영역의 식별에는 큰 무리가 없었다.

이와같이 32 x 32 크기의 영상이 입력되면 출력 node 에는 폐 영역만이 분할된 2 진 영상이 출력된다. 만일 그영상이 미리 사람이 수동으로 분할하여 제공한 학습기준 2 진 영상과 오차가 있을 경우에는 오차가 수정되는 방향으로 연결강도를 수정토록 반복학습시킨다.

학습방법으로는 다음과 같은 generalized delta rule 을 사용하였다.

Step 1: 먼저 각각의 연결강도  $w_{ij}$  와 threshold  $\theta_i$ 를 -0.5 에서 +0.5 사이의 랜덤한 값으로 초기화 시킨다.

여기서  $w_{ij}$  는  $i$  번째 하위 node 로부터 상위  $j$  번째 node로 의 연결강도를 나타낸다.

Step 2: 하위 node 들의 입력으로부터 각 node 들의 출력값을 다음과 같은 관계로 계산한다.

$$S_j = \text{sigmoid}(\sum_i w_{ij} s_i + \theta_j)$$

단  $\text{sigmoid}(x) = 1 / (1 + \exp(-x))$ .

Step 3: 각 node에 대하여 현재의 출력값과 학습기준치의 오차를 다음식으로 구한다.

$$\delta_j = (t_j - S_j) S_j (1 - S_j) \quad \text{출력 node}$$

$$\delta_j = S_j (1 - S_j) \sum_k \delta_k w_{kj} \quad \text{은닉 node}$$

여기서  $t_j$  는 출력의 학습 기준값.

Step 4: 출력 node 로부터 시작하여 각 하위 node 와의 연결 강도를 다음 식과같이 조정함으로써 오차를 하위 node 들로 back propagate 시킨다.

$$w_{ij}(n+1) = w_{ij}(n) + \mu \delta_j S_i$$

여기서  $\mu$  는 학습률을 결정짓는 파라미터로서 본 실험에서는 그 값을 0.3 으로 정하였다.


이때 한 sample 에 대한 학습오차를 다음식과 같이 구하고 그 값이 주어진 기준치이하로 감소될때까지 Step 2 로부터 4 까지의 학습과정을 반복한다.

$$E_t = \sum_i (t_i - S_i)^2$$

이와같이 하여 학습이 끝난 신경회로망에는 학습시 입력되었던 영상과 그 폐영역의 2 진 영상과의 관계로 부터 영역분할에 필요한 지식들이 연결강도의 형태로 자체내에 습득되어 있다.

#### 4. 실험

본 연구에 사용된 흉부 X-선 영상들은 서울대학교 병원에 설치되어 있는 디지털 X-선 촬영장치를 이용하여 촬영한 환자 및 직원들의 영상이다. 본래의 해상도는 700 x 700 정도 이었으나 MLP 에는 32 x 32 로 줄인 영상을 입력하였다. 또한 영상별 휘도의 상이를 고려하여 먼저 histogram equalization 의 전처리 를 하였다. 학습에 사용한 영상의 수는 모두 10 sample 이었으며 각각에 대해 고해상도로 display 된 상태에서 mouse 를 가지고 수동 tracking 하여 폐 영역에 대한 2진 영상을 얻고 이를 학습의 기준으로 삼았다. 학습에 사용한 한 sample 영상의 원 영상을 그림 3(a)에, 이를 수동 tracking하여 얻은 폐 영역의 2진 영상을 그림 3(b)에 각각 보였으며 이들을 32 x 32 의 저해상도로 처리한 영상들을 그림 4(a),(b)에 각각 보였다.




(a)

(b)

그림 3 학습에 사용된 sample 영상의 원 영상(a)및 이를 mouse 로써 수동 분할한 영상(b)의 예.

Fig. 3 shows an example of original image(a),and the binarily segmented lung area image(b) obtained through manual tracking with mouse.



(a) (b)

그림 4. 그림 3에 보인 영상(a),(b)를 32 x 32의 저해상도로 변환 시킨 MLP 입력용 영상.

Fig. 4 (a),(b) show consolidated version of Fig.3(a), (b) respectively in 32 x 32 resolution, for use in training the multi layer perceptron.

학습시에 처리시간의 단축을 위하여 영상을 4 상안으로 분할하여 각각 다른 MLP로 학습시켰다. 이에 따라 MLP의 입력 및 출력 node 수는 각각 256개가 되었다. Hidden node의 수는 40개로 하였는데 이 정도로도 입력영상들은 잘 분리되었다.

처리에 사용한 컴퓨터는 clock 주파수 25 MHz인 IBM PC /386으로서 80387 floating point processor가 내장된 것이며 작업 환경은 MS-DOS 상에서 수행되었다.

학습시 분류 경계와 sample 간에 적정거리를 확보하기 위해 20 grey level 이내에서 독립 균일 분포하는(i.i.d.) 랜덤 잡음을 매 학습마다 다르게 영상에 첨가하여 학습시켰다.

학습시 학습종료 여부는 학습오차가 sample 영상당 0.01 미만인가에 따라 결정하였으며 이 상태로 수렴하는데 sample 당 약 1000 회의 학습이 필요하였다.

본 연구에 사용한 MLP와 같은 학습식 분류기의 성능은 그 학습량에 따라 달라지므로 그 영향을 관찰하기 위해 학습 sample의 수를 각각 3, 7, 10개로 변화시켜가며 학습 set에 들지 않은 3개의 영상에 대하여 분할 성능을 측정하였다. 분할 성능을 나타내는 분할 오차  $E_s$ 를 다음과 같이 정의한다.

$$E_s = \frac{\sum x_i(*)x_i'}{\sum x_i}$$

여기서  $x_i$ 는 수동 분할된 2진영상의 화소값이며,  $x_i'$ 는 MLP에 의해 출력된 분할영상의 화소값으로서 이들은 모두 0과 1, 0의 값에 대해 각각 1, 0의 값을 갖는다. 또한 (\*) 표시는

exclusive OR 연산을 뜻한다.

## 5. 결과

이와같이 학습된 MLP는 학습 sample set 중의 모든 영상에 대해서는  $E_s=0.0$ 으로서 학습기준과 완벽하게 동일한 폐 영역 분할영상을 출력하였고 새로운 입력영상에 대해서는 영상에 따라 조금씩 다른 오차값을 보였다. 표 1에 그 결과를 보였는데 처음 column은 모두 10개의 학습 sample 중 3개의 학습 sample만으로 학습시킨 뒤 3개의 새로운 영상을 분할출력한 결과이고 둘째와 셋째 column은 각각 7개, 10개의 학습 sample로 학습시킨 뒤 분할출력한 결과를 나타낸 것이다.

표 1. 학습 sample 수 증가에 따른 분할오차 비교.

Table 1. The comparison of segmentation errors according to the increasing number of samples.

	3sample 학습	7sample 학습	10sample 학습
영상 1	0.219	0.196	0.170
영상 2	0.286	0.229	0.213
영상 3	0.222	0.193	0.189

이 결과를 보면 3개의 시험 영상 모두에 대해서 학습 sample의 수가 증가할수록 분할오차는 작아짐을 알 수 있으며, 영상별 분할오차의 크기순은 학습의 진행에 따라 조금씩 달라지는 것을 볼 수 있다. 이는 새로운 sample을 학습함에 따라 영상의 영역분할에 관해 더 많은 정보가 MLP 내부에 획득되고 있음을 보여주는 것이며, 또한 영상별 분할오차의 크기순이 바뀌는 현상은 특정 시험 영상과 비슷한 sample이 학습되면 이 학습결과로 인해 그 시험 영상에 대해서는 좀 더 나은 분할 성능을 나타내기 때문으로 해석된다.

그림 5, 6, 7에 이와같이 학습량에 따른 성능개선의 실태를 보였다. 그림 5(a)는 시험영상 1의 입력영상이고 (b)는 이를 수동 분할한 2진영상이며, (c), (d), (e)는 각각 3, 7, 10개의 sample로 학습시킨 뒤 분할출력한 2진 영상이다. 그림 6, 7은 마찬가지로 시험영상 2, 3에 대한 결과를 보인 것이다.

학습진행도에 따라 조금씩 그 형태가 개선되어감을 알 수 있다. 현재까지의 결과로는 충분히 정확한 분할을 하지 못하고 있지만 앞서 언급한대로 이 방법은 학습량에 따라 개선된 성능을 갖게 되므로 앞으로 계속되는 학습에 의하여 충분히 정확한 폐 영역 분할의 성능을 나타내리라고 기대된다.

본 실험에서는 사용 컴퓨터의 메모리 용량의 제약때문에 32 x 32 의 저 해상도 영상에 대해 적용하였지만 메모리 확장이 되면 64 x 64 또는 128 x 128 정도의 영상도 직접 입력하여 분할할수 있을 것이다.

6. 결론

흉부 X-선 영상의 폐 영역 분할문제를 일반적인 패턴 분류 문제로 보고 접근하였으며, 학습을 통하여 애매한 지식까지도 무리없이 수용함으로써 기존의 분할 방법보다 향상된 분할이 가능한 새로운 분할방법을 제시하였다.

분류기로서는 학습이 가능한 신경회로망인 MLP 튜브 사용하여 10 개의 학습 sample 로서 학습시키고 3개의 시험 영상을 분할 시험하였다. 이때의 분할 오차는 평균적으로 0.19 정도였으며 이는 학습 sample 수의 증가에 따라 감소함으로써 계속적인 학습에 따라 그 성능이 향상됨을 알수있었다.

참고 문헌

- 1 ] Y. P. Chien, et al., Recognition of X-ray Picture Patterns, IEEE trans. SMC, vol. SMC-4, No.2, 1974.
- 2 ] Ernest L. Hall, et al., Computer Classification of Pneumoconiosis from Radiographs of Coal Workers, IEEE trans. BME, vol. BME-22, No. 6, Nov. 1975.
- 3 ] Dana H. Ballard, et al., A Ladder Structured Decision Tree for Recognizing Tumors in Chest Radiographs, IEEE trans. computers, vol. C-25, No. 5, May 1976.
- 4 ] F. X. Roellinger, et al., Computer Analysis of Chest Radiographs, CGIP, vol.2, 232-251, 1973.
- 5 ] G. P. Ashkar and J. W. Modestino, The Contour Extraction Problem with Biomedical Applications, CGIP, vol. 7, 331-335, 1978.
- 6 ] Charlse Harow and Sharon A. Eisenbeis, The Analysis of Radiographic Images, IEEE trans. computers, vol. C-22, No. 7, July 1973.




그림 5.




그림 5. 시험영상 1의 입력영상(a), 수동 분할한 영상(b), (c),(d),(e)는 각각 MLP가 3,7,10 개의 sample로 학습된때 이 입력영상을 분할출력한 영상.

Fig. 5 shows the MLP input image of test sample 1(a), and the manually segmented image(b), and the MLP output images(c),(d),(e) when trained with 3,7,10 samples, respectively




그림 6. Fig. 6.





그림 7. Fig. 7.

