

퍼지 클러스터 기반 디지털 유방 X선 영상 진단 시스템

이 현 숙[†] · 윤 석 민^{††}

요 약

최근 ACS에 따르면 여성에게 유방암은 가장 많이 발병하는 암으로서 그 사망자 수도 두 번째로 많은 암이다. 유방 X선 영상의 종괴나 석회 환부는 진단을 위한 가장 중요한 단서로서 알려져 있으므로 유방암의 조기진단을 위하여 디지털 유방 X선 영상을 컴퓨터에서 처리하는 연구가 진행되고 있다.

본 논문에서는 퍼지 클러스터 지식베이스에 기반을 둔 진단시스템을 제안한다. 제안된 시스템은 듀얼 OFUN-NET에 두 가지 종류의 특징 데이터를 처리하여 진단결과와 그 가능성을 알려준다. 실세계 의료기관으로부터 수집되고 공개적으로 제공되는 유방 X선 데이터베이스 DDSM 으로부터 획득한 종괴와 석회 환부의 데이터를 사용하여 실험한다. 실험결과는 제안된 시스템이 기존의 방법보다 높은 분류 정확도와 유방 X선 영상 진단시스템으로서 전문가의 의사 결정을 도울 수 있는 타당한 결과를 보여준다.

키워드 : 퍼지 클러스터, 유방 X선 영상, 특징선택, 진단시스템

Fuzzy Cluster Based Diagnosis System for Digital Mammogram

Hyunsook Rhee[†] · Seokmin Yoon^{††}

ABSTRACT

According to the American Cancer Society, breast cancer is the second largest cause of cancer deaths and most frequently diagnosed cancer in women. The currently most popular method for early detection of breast cancer is the digital mammography. A mass or calcification lesion has been known as the most important clue for the diagnosis.

In this paper, we propose a diagnosis approach based on fuzzy cluster knowledge base. We combine different two sources of feature data in dual OFUN-NET and produce the diagnosis result with possibility degree. We also present the experimental results on the dataset of mass and calcification lesions extracted from the public real world mammogram database DDSM. These results show higher classification accuracy than conventional methods and the feasibility as a decision supporting tool for diagnosis of digital mammogram.

Keywords : Fuzzy Cluster, Mammogram, Feature Selection, Diagnosis System

1. 서 론

유방암은 여성에게 많이 발병하는 질병으로 2008년 한국 유방암 학회가 발표한 <유방암 백서>에 따르면 해마다 그 환자수가 증가하여 10년 전보다 3배 가까이 증가하였다. 또한 ACS(American Cancer Society)에서 최근 여성에게 유방암은 가장 많이 발병하는 암으로서 그 사망자 수도 두 번째로 많은 암으로 보고하였다[1]. 하지만 유방 X선 영상의 종괴와 석회 환부는 유방암 진단의 중요한 단서로 알려져 있으며 조기에 발견된다면 완치 가능한 질병이다. 그러므로 이를 처리하고 분석하기 위한 컴퓨터 보조 진단 시스템

(Computer Aided Diagnosis)에 대한 연구가 활발하게 진행되고 있다[2,3]. 그리고 디지털 유방 X선 영상에서 환부가 양성인지 악성인지 분류하기 위하여 기존의 인공지능이나 기계학습의 이론이 널리 활용되고 있다. 하지만 그 동안의 연구는 특정병원에서의 개인 데이터베이스를 이용하여 그 가능성을 테스트하여 활용하였기 때문에 연구에 큰 진전을 보지 못했다. 디지털라이저의 선택이나 영상의 해상도 등의 변수로 인하여 연구결과를 분석하거나 비교하기 힘들었다.

본 연구에서는 공개적으로 널리 알려진 세계에서 가장 규모가 큰 Digital Database for Screening Mammography(DDSM)의 데이터를 사용한다[4]. DDSM은 미국의 세 곳의 의료기관인 Massachusetts General Hospital(MGH), Washington University int St. Louis(WU), Wake Forest University School of Medicine(WFUSM) 으로부터 2500 케이스가 넘는 방대한 양의 종괴(mass)와 석회(calcification) 환부 유방 X선 영상을 수집하였다. 이 데이터베이스에서는 두 가지 촬

* 본 논문은 2008학년도 동양공업전문대학 학술연구지원사업의 지원으로 수행되었음.

† 정 회 원 : 동양공업전문대학 전산정보학부 부교수

†† 정 회 원 : 동양공업전문대학 전산정보학부 교수

논문접수: 2009년 3월 10일

수정일: 1차 2009년 3월 31일

심사완료: 2009년 4월 2일

영방법, Cranio-Caudal:CC와 Mediolateral Oblique:MLO, 에 의한 영상이 제공되어 있다. 또한 수집된 영상은 HOWTEK 960, DBA, LUMISYS 등의 디지털라이저에 의한 디지털영상이다.

이렇게 마련된 환자의 유방 X선 영상을 진단에 활용하기 위하여 다음의 세 가지 방법으로 데이터를 획득할 수 있다. 데이터의 획득은 대부분의 진단 시스템에서 그 결과의 유효성을 결정짓는 중요한 요소이다. 첫째는 영상 자체에 대한 데이터이다. 보통 픽셀의 수, 히스토그램, 평균 grey값, 평균 경계 grey값, 대비값, 비대칭값 등 영상자체가 갖는 데이터를 말한다. 이는 컴퓨터의 영상 처리 과정에서 자동적으로 추출되는 정보이다. X선 판독전문가의 시력의 한계에 도움을 주어 유용한 정보를 제공하며 기계적이기 때문에 항상 일관된 정보를 제공해 주는 장점이 있다. 두 번째는 X선 판독전문가에 의한 영상 해석 정보이다. 전문가의 경험지식을 바탕으로 결정에 영향을 주는 요소를 수치적으로 인코딩한 데이터이다. 널리 사용되어온 방법이나 전문가의 지식 및 해석 수준에 대한 기준 등의 여러 변수가 있다. 세 번째는 환자의 개인정보이다. 환자의 개인정보에 대한 해석과 수집에 대한 어려움 때문에 시스템에서는 대부분 환자의 나이 이외의 데이터는 사용하지 않고 의사가 결정을 내리는데 도움이 되는 경험적 데이터로 사용되고 있다.

본 연구에서는 공개데이터베이스인 DDSM으로 부터 수집한 환부의 종류를 종괴와 석회로 나누어 각각 두 유형을 묘사하는 특징 5가지와 환자의 나이 정보를 사용하였다. 이때 사용된 특징은 X선 영상 판독 전문가의 의견을 BI-RADS 기준에 의한 수치 값으로 변경하여 사용하였다[5]. 또한 데이터와 분류에 영향을 끼치는 영상 처리 특징 데이터로 알려진 엔트로피(entropy), 표준편차(standard deviation), 픽셀의수(number of pixels) 등의 14개의 그레이 레벨 특징데이터를 사용하였다[6,7].

이와 같이 획득한 데이터를 가지고 그 동안 연구되어 온 기계학습이나 신경망이론 등을 적용하여 탐지된 영상의 환부가 양성인지 악성인지를 판단하였으며 이는 X선 판독 전문가의 의사결정에 도움을 주었다. 본 논문에서는 제안된 시스템으로부터 퍼지 클러스터링 기법을 활용하여 형성한 퍼지 클러스터를 통하여 환부가 양성인지 악성인지 분류할 뿐 아니라 각 분류 결과의 가능성을 정보로 준다.

이러한 결정과정에서 우리가 예측할 수 있는 오류는 False Positive Errors(FPE)와 False Negative Errors(FNE)의 두 가지로 나눌 수 있다. FPE는 양성 종양이지만 악성으로 분류된 경우를 말하며 FNE는 악성 종양이지만 양성으로 분류된 경우를 말한다. FNE의 경우는 수술이나 처치시기를 지연시켜 치료에 어려움을 겪을 수 있는 치명적인 경우이다. 통계에 의하면 25%가 악성종양을 탐지하는데 실패하는 것으로 알려져 있으며 이러한 오진 율을 낮추기 위하여 의료정보화 분야의 연구가 계속되어야 할 것이다. FPE의 경우는 악성으로 진단되었기 때문에 무조건 조직병리검사를 해야 한다. 하지만 검사과정에서 악성으로 판정되는 경우는 15% 정도이며 진단과 검사과정에서 환자는 정신적, 육체적,

경제적 고통을 가지게 된다. 대부분의 경우 조직병리검사(biopsy) 대신에 추적조사(follow-up)로 진단할 수 있는 경우이다. 본 연구는 이와 같은 두 가지 오류를 줄이기 위하여 의사의 진단을 도울 수 있는 정보를 제공하는 것을 목적으로 한다. 시스템의 결과는 의사의 결정을 도와주는 보조 수단으로 사용될 수 있다. 예를 들면 여러 의사가 한 환자의 증세에 대하여 의견을 모으는 과정에 하나의 의견으로서 사용될 수 있다.

본 논문의 구성은 다음과 같다. 2장에서는 연구 배경으로서 그 동안 연구 되어 온 컴퓨터 보조 진단 시스템의 접근 방법을 소개하고 퍼지 클러스터링을 위한 대표적인 FCM(Fuzzy C-Means) 알고리즘을 소개한다. 3장에서는 제안된 디지털 유방 X선 영상 진단시스템을 제안하고 4장에서는 공개 데이터베이스의 데이터를 가지고 분석한 과정과 결과를 고찰해 본다. 5장에서는 결론적으로 제안된 방법과 실험결과를 요약하고 앞으로의 연구방향을 제시한다.

2. 연구배경

패턴 인식과 컴퓨터 비전분야에서의 연구 결과를 의료 영상의 해석과 분석에 활용하는 일은 점점 가능성 있는 분야가 될 것이다. 특히 의료장비의 발전으로 디지털 유방 X선 영상은 가장 신뢰성 있는 진단기술로서 초기 유방암진단에 기여하고 있다. 본 장에서는 본 연구의 배경으로서 그 동안 연구 되어 온 컴퓨터 보조 진단 시스템의 접근방법을 소개하고 퍼지 클러스터링을 위한 대표적인 FCM(Fuzzy C-Means) 알고리즘을 소개한다.

2.1 컴퓨터 보조 진단(CADx) 시스템

디지털 유방 X선 영상에 나타난 종괴나 석회는 암을 진단하는 가장 중요한 단서가 되어왔다. 그러므로 컴퓨터 보조 진단 시스템은 디지털 유방 X선 영상으로부터 탐지된 환부가 양성인지 악성인지 분류하여 X선 판독전문가의 결정을 돕기 위하여 널리 사용되고 있다. 진단과정은 크게 X선 영상으로부터의 특징추출과정과 분류과정으로 나눌 수 있다. 이러한 과정에서 기존에 연구 되어 온 패턴인식과 컴퓨터 비전의 연구 결과가 의료 영상의 해석과 분석에 활용되어왔다. 또한 분류를 위하여 지지벡터기계(SVM:Support Vector Machine), KNN(K-Nearest Neighbor) 등의 통계학적인 방법에서부터 신경망과 퍼지이론에 이르기까지 광범위한 지능형 데이터 처리기법들이 활용되어왔다[2,3].

이 분야에서도 다른 진단시스템 등의 전문가 시스템과 마찬가지로 데이터 획득에 어려움을 갖고 있다. 관련 연구가 활발히 진행되면 공개 데이터베이스 DDSM을 구축하고 BI-RADS 표준에 의하여 두 가지 유형의 환부의 특징을 규정하고 이를 값으로 표현하였다[4,5].

Baker 등[8]은 이러한 특징값을 활용한 신경망 기반의 분류 모델을 제안하였다. Bovis 등[9]은 Spatial Grey Level Dependency(SGLD) 행렬로부터 추출한 텍스처 특징을 사용

하여 종괴와 정상조직을 분류하였다. 이를 위하여 Back-Propagation Neural Network(BPNN)와 Radial Basis Function Network(RBFN)이 사용되었다. Edwards 등은[10] 환부가 양성인지 악성인지를 분류하기 위한 결정변수를 예측하기 위하여 베이저안 인공신경망(BANN) 기법을 제안하였다. 제안된 BANN은 ANN과는 달리 학습과정에서 사용하는 오류 함수에 정규화 항(regularization term)을 포함시켰다. 정규화 항은 베이저안 사전 확률 값을 신경망의 가중치로서 제공함으로써 정규화된 학습과정을 제공하고 안정적인 분류결과를 가져오는 중요한 요소이다.

환부조직의 구조와 모양이 다양해짐에 따라 분류가 어려워지면서 Wu 등은 앙상블 네트워크 모델을 제안하여 분류의 정확도를 높여려는 연구를 하였다[11]. 제안된 모델은 종괴 환부를 분류하기 위하여 가중치 평균과 퍼셉트론 평균의 두 가지 알고리즘을 사용하였다.

또한 미세석회 환부가 암을 진단하는 중요한 단서가 됨이 알려지면서 이를 분류하기 위한 연구가 진행되었다. [12]에서는 정해진 특징을 사용하여 특징 추출 과정에서 분류에 영향을 주는 특징을 찾아가는 과정을 통하여 역전파 신경망 기반의 컴퓨터 보조진단시스템을 구성하였다. 널리 사용되는 14 가지의 특징을 추출한 후에 하나의 특징을 가지고 분류를 시작한 후 다른 특징을 첨가함으로써 분류율이 증가한다면 그 특징을 선택하고 그렇지 않으면 다음 특징을 고려하는 방식으로 전체 8192 개의 조합에 대하여 상당한 양의 실험을 계속하였다. 이러한 실험의 결과로 14 가지의 특징을 고찰하여 신경망의 구조를 결정하고 미세석회패턴을 탐지하는 퍼지 논리 기반 특징결합방법을 제안하였다. 제안된 시스템은 특징을 선택하고 평가하는 과정에서부터 분류하는 과정까지 퍼지 신경망의 원리를 체계적으로 적용하였으나 20개의 양성환부와 20개의 악성환부 모두 40개의 미세석회 환부가 학습에 사용되어 그 데이터가 작기 때문에 연구의 신뢰도가 높지 않은 것으로 판단되었다. 또한 [13]에서는 여러 가지 특징요소들을 결합하여 Linear discriminant analysis (LDA) 모델에 적용하여 292 DDSM 경우에 대하여 성능을 분석하였다. 분석과정에서 다양한 특징 결합의 시도를 통하여 형태학적인 정보를 가지는 영상처리데이터와 X선 영상 판독 전문가에 의한 데이터가 적절히 결합 되었을 때 성능이 우수한 것으로 분석되었다.

2.2 FCM 알고리즘

컴퓨터가 처리하는 정보의 양이 방대해지고 시스템에 반영되어야 하는 새로운 정보가 계속해서 발생됨에 따라 분류의 기능이 중요시되고 있다. 분류 시스템은 데이터 전처리 모듈, 학습 모듈, 의사결정모듈로 구성되어 있으며 지능형 시스템의 중요한 구성요소로 활용되어왔다. 특히 학습 모듈은 분류를 위한 지식베이스의 역할을 하며 기초적인 통계분야와 기계학습 분야의 이론을 토대로 다양한 형태의 신경망 구조와 학습알고리즘을 개발하고 유전자 알고리즘과 같은 결과를 도출하여 영상 및 음성인식시스템, 웹 에이전트 시

스템, 자동화 시스템 등의 지능형시스템 구축에 활용되어왔다.[14]. 기존의 학습을 위한 기법은 주로 승자독점방식으로 데이터를 처리함으로써 경계가 불분명한 대부분의 실세계 응용에 적합하지 못하다. 특히 X선 의료 영상의 진단 시스템의 경우 결정이 어려운 환자의 영상에 맞는 분류정보를 제공하는 것이 중요하다. 이에 퍼지이론을 적용하여 각 데이터의 클래스 소속값을 함께 학습함으로써 보다 정확하게 데이터를 표현하고 정확한 분류정보를 얻을 수 있도록 하는 퍼지 클러스터링 기법이 도입되었다. 대표적인 클러스터 분석 방법으로 널리 알려진 FCM(Fuzzy C-Means) 알고리즘은 Bezdek에 의하여 개발되어 최적 분할, 패턴분류 및 영상 처리 등의 여러 분야에 활용되었다[15,16]. FCM 알고리즘은 식(1)과 같은 클러스터안의 데이터사이의 거리와 소속 값에 기반을 둔, 최소자승오류함수, J_m 을 목적 함수로 하여 이를 반복최적화 하도록 구성되어있다.

$$J_m = \sum_{j=1}^n \sum_{i=1}^c (u_{ij})^m (d_{ij})^2 \tag{1}$$

여기서 u_{ij} 는 주어진 입력 데이터 집합 $X = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$ 에 대한 퍼지 c 분할을 $n \times c$ 의 벡터 U 로 나타낼 때 그의 한 요소로 데이터 \mathbf{x}_j 의 클러스터 i 에 속하는 소속정도를 표현한다. 또한 $(d_{ij})^2 = \|\mathbf{x}_j - \mathbf{v}_i\|^2$ 이고 $\|\cdot\|$ 은 유클리드 norms, \mathbf{v}_i 는 클러스터 i 의 중심점을 나타내며 $m \in [1, \infty)$ 은 퍼지 정도를 표시하는 파라메터를 나타낸다. 이때 Bezdek은 $m > 1$ 인 경우 J_m 의 국소적 최소점이 되기 위한 필요조건(충분조건은 아니지만)을 유도하여 다음과 같은 FCM 알고리즘을 구성하였다.

단계 1: 클러스터의 수, weighting exponent m 을 정한다.

퍼지 c 분할 $U^{(0)}$ 의 초기치를 설정한다. 반복횟수 $b=0$ 으로 한다.

단계 2: 다음 식(2)를 이용하여 클러스터 중심점 $\{\mathbf{v}_i^{(b)}\}$ 를 계산한다.

$$\mathbf{v}_i = \frac{\sum_{j=1}^n (u_{ij})^m \mathbf{x}_j}{\sum_{j=1}^n (u_{ij})^m}, \quad 1 \leq i \leq c \tag{2}$$

단계 3: 퍼지 c 분할 $U^{(b)}$ 으로부터 다음 단계의 퍼지 c 분할 $U^{(b+1)}$ 을 구한다.

a) 각 데이터 $j=1 \dots n$ 에 대하여 다음을 계산한다.

$$I_j = \{i | 1 \leq i \leq c, d_{ij} = \|\mathbf{x}_j - \mathbf{v}_i\| = 0\}$$

$$\bar{I}_j = \{1, 2, \dots, c\} - I_j$$

b) 각 데이터 $j = 1 \dots n$ 에 대하여 새로운 소속 값 u_{ij} 를 계산한다.

i) If $I_j = \emptyset$,

$$u_{ij} = \frac{1}{\sum_{t=1}^c \left(\frac{d_{ij}}{d_{tj}}\right)^{2/(m-1)}} \quad (3a)$$

ii) Else

$$u_{ij} = 0 \quad \text{if } d_{ij}^2 \neq 0 \quad \text{and} \quad \sum_{i \in I_j} u_{ij} = 1 \quad (3b)$$

단계 4: $U^{(b)}$ 과 $U^{(b+1)}$ 을 비교하여

$\|U^{(b)} - U^{(b+1)}\| < \epsilon$ 이면 알고리즘을 종료하고;

그렇지 않으면, $b = b+1$ 로 정하고 단계 2 로 가서 반복한다.

이와 같이 FCM 알고리즘은 단지 식(2)와 식(3)의 반복에 의하여 수렴점을 찾아가는 과정이다[8]. 위의 유도된 식 (3)을 이용하여 입력 데이터와 중심점 사이의 거리를 통한 퍼지 소속 값(fuzzy membership value)을 결정하게 된다. 식 (3b)를 통하여 알 수 있는 바와 같이 임의의 한 클래스의 중심점과의 거리가 0인 입력 데이터에 대한 그 클래스안의 퍼지 소속 함수 값은 1이 될 것이다. 그리고 식(3)을 고찰하여 알 수 있는 바와 같이 그를 통하여 결정된 퍼지 소속 함수 값은 형성된 각 클래스에 대하여 상대적인 값을 가지며 확실적인 제약을 준수하여 그 클래스에 대한 소속의 확률치나 공유의 정도로 해석된다. 이렇게 형성된 퍼지 클러스터들은 주어진 입력에 대한 소속정도를 결정해 줌으로서 분류를 위한 보다 정확한 정보를 제공해 주고 있다.

3. 디지털 유방 X선 영상 진단 시스템

유방 X선 영상(mammogram)의 종괴(mass)와 석회(calcification) 환부는 유방암 진단의 가장 중요한 단서로서 알려져 있다. 진단 시스템은 디지털 유방 X선 영상으로부터 진단에 필요한 데이터를 추출하는 특징선택과정과 선택된 특징을 활용하여 양성과 악성으로 분류하는 과정으로 구성되어 있다. 이러한 시스템의 목적은 악성을 조기에 발견하여 적절한 조치를 취할 수 있도록 해 주고 양성인 경우 추적조사를 해야 할지, 조직검사를 해야 할지 등의 의사결정을 돕는 것이다.

데이터 집합 Π 를 구성하는 n 개의 입력벡터 $\mathbf{x}_1, \dots, \mathbf{x}_n$ 은 각각 p 개의 특징 값 f_1, f_2, \dots, f_p 으로 표현된다. 즉 i 번째 데이터의 k 번째 특징 값은 x_{ik} 에 의하여 표현된다. 그러므로 입력 Π 는 $n \times p$ 로 표현되며 i 번째 데이터의 출력 $y_i \in \{0, 1\}$ 는 분류 레벨을 제공해준다. 이와 같이 양성과 악성으로 분류하는 것이 진단시스템의 목적이므로 이진정보로 결과를 출력 하게 된다.

유방 X선 영상의 진단은 특징을 결정하는 과정에서 시작된다. 실험데이터로 널리 사용하는 방법으로는 [5]에 제시되어 있는 BI-RADS 기준에 의한 특징들이다. BI-RADS에서 제시한 특징은 X선 영상 판독전문가의 판단에 의하여 주어 진 특징을 표현하였다. 이렇게 표현된 특징은 [4]의 ranking ordering system에 의하여 CADx 시스템에서 사용될 수 있도록 수치 값으로 인코딩 되었다.

이와 같이 X선 영상 판독전문가에 의하여 추출된 특징데이터는 영상처리 알고리즘에 의하여 자동으로 추출된 통계학적 데이터와 함께 유방암 진단시스템에 널리 활용되어왔다. 본 논문에서는 공개 데이터베이스인 DDSM에 수집된 데이터로부터 판독전문가에 의하여 만들어진 특징 데이터베이스와 [6,7]의 논문에서 사용한 영상처리 특징데이터베이스를 활용하여 듀엣 퍼지 신경망을 구성한다.

진단 시스템의 결과도 하나의 의견으로 반영되어 최종 결정에 도움을 주기 위해서는 이진 값에 의한 출력보다는 각 판단에 따르는 가능성의 정도로 표현하는 것이 더욱 유용할 것이다. 또한 서로 다른 관점에서 추출된 특징들을 하나의 모델에서 학습시키는 방법은 데이터를 정규화 해야 하는 등의 가공과정이 학습 전에 부가적으로 필요하고 시스템이 필요로 하는 파라미터를 세팅하기 위하여 많은 실험을 하게 된다.

본 논문에서 제안하는 진단시스템은 서로 다른 관점에서 추출된 특징 데이터베이스의 값을 서로 다른 퍼지 신경망에 의하여 학습시켜 진단 결과의 가능성을 결과로 만들어 낸다. 이미 제안된 특징을 활용하는 방법과 분류하여 의사에게 보다 정확한 정보를 제공할 수 있는 퍼지 클러스터 기반 디지털 유방 X선 영상 진단 시스템을 제안한다.

3.1 퍼지 클러스터링에 의한 지식베이스 구축

FCM 알고리즘과 같은 퍼지 클러스터링 방법은 분류에 의하여 진단시스템의 기본적인 지식베이스를 만들어 준다. FCM 알고리즘의 목적함수 J_m 을 비교사학습신경망에 결합시켜 (그림 1)과 같은 퍼지신경망, OFUN-NET을 구성하였다[17]. 이렇게 구성된 신경망에서 다음의 알고리즘을 통하여 입력 층에 제공된 데이터 $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$ 는 대표정보인 클러스터의 중심점 $(\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_c)$ 을 학습해 간다. 이러한 학습을 통해 형성된 클러스터 층은 데이터 \mathbf{x}_j 의 클러스터 i 에 속하는 소속 값, u_{ij} 을 포함하는 정보 사이의 관계를 표현하는 값인 $(\alpha_1, \alpha_2, \dots, \alpha_c)$ 를 계산하여 그 결과를 다음 학습에 활용한다. 이러한 학습 알고리즘은 클러스터링의 결과가 만들어 내는 오류 값을 요약하는 퍼지 함수를 설정한 후 그 값이 최소가 되도록 학습의 방향을 유도하는 메카니즘에 의해 진행된다. 또한 제안된 방법은 입력과 출력 사이의 관계를 기술하기 어려운 경우도 쉽게 처리하는 비교사 학습신경망의 장점도 함께 가지고 있다.

단계 1 : c, m, ϵ 의 값을 설정하고 입력데이터 셋을 준비한다.

c 는 클러스터의 수, m 은 FCM 알고리즘의 weighting exponent 이다.

단계 2 : 초기 가중치 벡터 $\mathbf{V}=(\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_c)$ 와

퍼지 C 분할 \mathbf{U} 를 0과 1 사이의 난수로 초기화한다. $t=0$.

단계 3 : 다음 식을 이용하여 α_{ij} 를 계산하고

$$\eta_i = \frac{1}{\sum_{j=1}^n \alpha_{ij}}$$

$$\alpha_{ij} = \frac{2m}{m-1} \left\{ \sum_{l=1}^c (u_{lj})^{m+1} \left(\frac{\|\mathbf{x}_j - \mathbf{v}_l\|^2}{\|\mathbf{x}_j - \mathbf{v}_i\|^2} \right)^{\frac{m}{m-1}} \right\}^{-1}$$

단계 4 : 다음 식을 이용하여 가중치 벡터를 수정한다.


$$\Delta \mathbf{v}_i = \eta_i \sum_{j=1}^n \alpha_{ij} (\mathbf{x}_j - \mathbf{v}_i) \quad (4)$$

단계 5 : 다음 식을 이용하여 퍼지 C 분할 \mathbf{U} 를 계산한다.

$$u_{ij} = \frac{1}{\sum_{s=1}^c \left\{ \frac{\|\mathbf{x}_j - \mathbf{v}_i\|}{\|\mathbf{x}_j - \mathbf{v}_s\|} \right\}^{2/(m-1)}} \quad (5)$$

단계 6 : $\mathbf{v}_{i,t}$ 는 현재 가중치 벡터이고 $\mathbf{v}_{i,t+1}$ 는 단계 4 에 의하여 수정된 가중치 벡터 일때 $diff = \sum_{i=1}^c \|\mathbf{v}_{i,t+1} - \mathbf{v}_{i,t}\|^2 < \epsilon$ 이면 알고리즘을 끝내고 그렇지 않으면 단계 3으로 가서 반복한다.

주어진 두 가지의 데이터베이스 FDB1과 FDB2를 퍼지 신경망 OFUN-NET에 학습시켜 분류를 위한 모델을 구축한다. 위의 알고리즘을 바탕으로 OFUN-NET을 학습시키면 각 클러스터에 대한 정보를 지식베이스로 갖게 된다. 본 논



(그림 1) 목적함수기반 퍼지 신경망(OFUN-NET)

문에서는 2가지 종류의 특징데이터집합을 사용하기 위하여 2개의 OFUN-NET을 활용하는 진단시스템을 구성하게 된다.

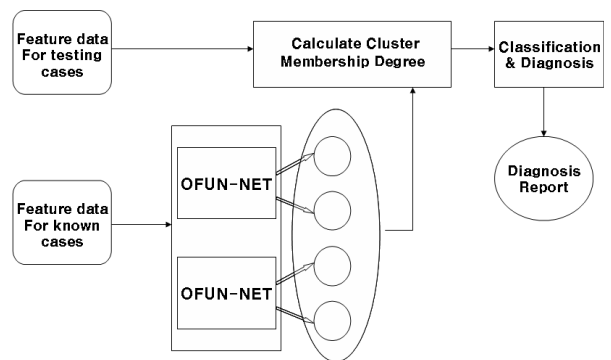
3.2 듀얼 OFUN-NET을 이용한 진단시스템

3.1 절에서 구축된 OFUN-NET을 활용하여 (그림 2)와 같은 퍼지 클러스터 기반 디지털 유방 X선 진단시스템을 제안하였다. 제안된 진단시스템의 의사결정을 돕기 위한 지식베이스는 서로 다른 데이터 집합을 학습하는 2 개의 OFUN-NET에 의하여 구축된다. 지식베이스 구축을 위하여 n 개의 데이터 집합 $\Pi_1=(\mathbf{x}_1, \dots, \mathbf{x}_n)$ 과 $\Pi_2=(\mathbf{y}_1, \dots, \mathbf{y}_n)$ 를 준비한다. 하나의 X선 영상 케이스에 대하여 추출된 \mathbf{x}_j 는 p_1 개의 특징 값을 가지며 \mathbf{y}_j 는 p_2 개의 특징 값을 가진다. 그러므로 준비된 입력은 $n \times (p_1 + p_2)$ 로 표현된다. Π_1 의 데이터는 OFUN-NET1에 학습시켜 두 가지 진단결과에 대한 특징 값의 대표정보를 가지고 있는 \mathbf{v}_i 를 만들어낸다. 마찬가지로 Π_2 의 데이터는 OFUN-NET2에 학습시켜 두 가지 진단결과에 대한 특징 값의 대표정보를 가지고 있는 \mathbf{w}_i 를 만들어낸다. 이렇게 두 개의 OFUN-NET1과 OFUN-NET2의 결과를 이용하여 진단을 원하는 케이스에 대한 특징데이터 \mathbf{x}_j 와 \mathbf{y}_j 를 가지고 퍼지 클러스터 형성과정에서 사용한 식 (6)와(7)에 적용하여 각 진단결과에 대한 가능성 $h_{ij} \in [0, 1]$ 와 $c_{ij} \in [0, 1]$ 를 출력하게 된다. 이러한 결과는 각 클러스터 정보에 일치하는 정도로서 어느 하나의 경우로 분류하는 시스템보다 이를 활용하는 전문가에게 보다 정확한 정보를 제공할 수 있다.

$$h_{ij} = \frac{1}{\sum_{t=1}^c \frac{\|\mathbf{x}_j - \mathbf{v}_i\|^2}{\|\mathbf{x}_j - \mathbf{v}_t\|^2}} \quad (6)$$

$$c_{ij} = \frac{1}{\sum_{t=1}^c \frac{\|\mathbf{y}_j - \mathbf{w}_i\|^2}{\|\mathbf{y}_j - \mathbf{w}_t\|^2}} \quad (7)$$

식 (6)과 (7)에 주어진 데이터 $\mathbf{x}_j, \mathbf{y}_j$ 에 대하여 듀얼 OFUN-NET이 가지고 있는 각 진단결과의 대표정보에 대



(그림 2) 진단시스템 구성도

한 차이에 반비례하는 값을 계산해 준다. 그러므로 이 결과로 출력된 h_{ij} 와 c_{ij} 는 주어진 데이터의 각 관점에 대한 클러스터 대표정보에 일치하는 정도를 말해 주고 있다.

이 때 제안된 시스템은 두 개의 OFUN-NET으로부터 일치도를 계산하기 때문에 두 데이터를 결합하여 하나의 값으로 출력해야한다. 가장 쉽게 생각할 수 있는 것은 두 값의 평균을 내는 것이다.

$$\text{진단결과 1의 일치도는 } u_{0j} = (h_{0j} + c_{0j})/2$$

$$\text{진단결과 2의 일치도는 } u_{1j} = (h_{1j} + c_{1j})/2$$

와 같이 계산할 수 있다. 또는 특징추출과정의 전문가의 의견을 반영하여 각각의 모델에 가중치를 부여하여 다음의 식 (8)과 같이 계산할 수 있다. 위의 경우 α_1 과 α_2 가 각각 0.5인 경우임을 알 수 있다.

$$u_{ij} = (\alpha_1 \times h_{ij} + \alpha_2 \times c_{ij})$$

$$\alpha_1 + \alpha_2 = 1 \tag{8}$$

대부분의 진단 시스템이 양성과 악성으로 분류하는 것이 목적이므로 이진정보로 결과를 출력하게 된다. 하지만 본 시스템에서는 진단결과에 대한 가능성을 0과 1사이의 값으로 줌으로서 의사의 결정을 보다 정확하게 도와 줄 수 있다.

4. 실험 및 고찰

본 장에서는 3장에서 제안한 듀얼 OFUN-NET을 이용한 진단시스템을 여러 환자의 데이터에 적용하여 그 타당성을 검증해 보고자한다. 준비된 각 환자의 디지털 X선 영상의 종괴(mass)와 석회(calcification) 환부로부터 진단에 필요한 데이터를 추출하여 시스템의 입력데이터를 만든다. 본 논문에서는 <표 1>에 요약된 것과 같은 공개적으로 알려진 DDSM의 영상으로 부터의 데이터를 사용하였다. 실험에 사용한 데이터는 MGH(Massachusetts General Hospital), WFUSM(Wake Forest University School of Medicine)으로부터 수집하여 디지털라이저에 의한 영상이다. 이 영상은 듀얼 OFUN-NET의 학습을 위하여 사용되어 진단시스템을 위한 클러스터 기반의 지식베이스를 만들어 주는 중요한 역할을 한다.

준비된 영상이 OFUN-NET에 적용되기 위하여 각 영상으로부터 2가지 방법으로 특징을 추출한다. 우선 American College of Radiology에서 제안한 BI-RADS라는 표준에 따라 X선 영상 판독 전문가에 의한 J. Y. Lo가 제시한 rank

ordering 방법을 활용하여 특징 데이터로 표현한다[5,14]. DDSM 안의 각 영상은 .ics 와 .OVERLAY 파일과 연결되어 있으며 이를 이용하여 분류에 필요한 데이터를 획득할 수 있다. .ics 파일로부터 환자의 나이(patient_age)와 조직의 밀도(density)를 얻을 수 있으며 OVERLAY 파일로부터 각 환부 유형(lesion type)별 각 각 4 가지의 특징데이터를 얻을 수 있다. 본 실험에서는 주어진 환자케이스의 파일로부터 앞선 연구에서 유용한 것으로 알려진[4,5] 종괴 모양(mass shape), 가장자리 모양(margins), 석회 유형(calcification type), 석회 분포(calcification distribution), 밀도(density), 악성인 정도(assessment), 제공 정보의 확실도(subtlety)와 환자의 나이 정보를 사용하였다. 또한 [6,7]에서 연구한 결과인 영상처리에 의한 통계적인 14개의 특징데이터를 추출하여 사용하였다. 그러므로 본 실험에서는 각 환부에 대하여 영상 판독 전문가에 의한 6개의 데이터와 영상처리에 의한 14개의 특징 데이터를 연구에 활용하였다.

이렇게 준비된 데이터를 활용하여 우선 종괴 환부에 대하여 실험해 보았다. <표 2>의 데이터 정보를 통하여 400*(6+14)의 듀얼 OFUN-NET의 입력 데이터 집합을 LDBM이라고 하자. LDBM의 데이터는 특징 추출한 종류에 따라 400*6의 데이터 LDBM1과 400*14의 데이터LDBM2로 나누어 듀얼 OFUN-NET에 학습시켜 클러스터 기반 지식베이스를 만든다. 이를 진단에 활용하여 그 타당성을 보이기 위하여 테스트 데이터 집합 TDBM을 만든다. TDBM은 클러스터 구축을 위하여 사전에 사용한 LDBM으로부터 양성인 경우 50개, 악성인 경우 50개를 선택하고 학습에 사용되지 않은 데이터를 MGH로부터 각각 50개씩, WFUSM으로부터 각각 50개씩 모두 300개의 데이터를 준비하여 테스트 데이터로 사용하였다. 제안된 진단시스템은 각 입력 케이스에 대하여 양성일 가능성과 악성일 가능성을 기반으로 분류한다.

이와 같이 종괴 유형 데이터 TDBM의 테스트한 분류 결과를 분류 정확도를 기준으로 분석한 결과는 <표 2>와 같이 요약할 수 있다. 준비된 테스트 데이터 TDBM(TDBM1+TDBM2)을 가지고 잘 알려진 분류 알고리즘[2,3], KNN (K-Nearest Neighbor), 지지벡터기계(SVM:Support Vector Machine), 과 데이터 LDBM1으로 학습되어 있는 OFUN-NET1, LDBM2로 학습되어 있는 OFUN-NET2를 이용한 방법을 적용하여 제안된 듀얼 OFUN-NET의 분류 정확도와 비교하였다. <표 2>의 분류 정확도를 통하여 본 논문에서 제안하는 듀얼 OFUN-NET의 분류 정확도가 더 높음을 확인할 수 있다.

같은 방법으로 석회 환부에 대하여도 실험해 보았다. [표 1]의 데이터 정보를 통하여 200*(6+14)의 듀얼 OFUN-NET의 입력 데이터 집합을 LDBC이라고 하자. LDBC의 데이터는 특징 추출한 종류에 따라 200*6의 데이터 LDBC1과 200*14의 데이터 LDBC2로 나누어 듀얼 OFUN-NET에 학

<표 1> 데이터 정보

수집기관	종괴 유형		석회 유형	
	양성	악성	양성	악성
MGH	115	100	38	52
WFUSM	85	100	52	58
전체	200	200	90	110

<표 2> 종괴 유형(Mass Type) 데이터의 분류 정확도 비교

KNN	SVM	OFUN-NET1	OFUN-NET2	듀얼 OFUN-NET
90.5%	91.5%	90.2%	89.3%	94.8%

습시켜 클러스터 기반 지식베이스를 만든다. 이를 진단에 활용하여 그 타당성을 보이기 위하여 테스트 데이터 집합 TDBC를 만든다. TDBC은 클러스터 구축을 위하여 사전에 사용한 LDBMC으로부터 양성인 경우 25개, 악성인 경우 25개를 선택하고 학습에 사용되지 않은 데이터를 MGH로부터 각각 25개씩, WFUSM으로부터 각각 25개씩 모두 150개의 데이터를 준비하여 테스트 데이터로 사용하여 실험하였다. 이와 같이 석회 유형 데이터 TDBC의 테스트한 분류 결과를 분류 정확도를 기준으로 분석한 결과는 <표 3>과 같이 요약할 수 있다. 준비된 테스트 데이터 TDBC(TDBC1+TDBC2)을 가지고 잘 알려진 분류 알고리즘[2,3], KNN(K-Nearest Neighbor), 지지벡터기계(SVM:Support Vector Machine), 과 데이터 LDBC1으로 학습되어 있는 OFUN-NET1, LDBC2로 학습되어 있는 OFUN-NET2를 이용한 방법을 적용하여 제안된 듀얼 OFUN-NET의 분류 정확도와 비교하였다. <표 3>의 분류 정확도를 통하여 본 논문에서 제안하는 듀얼 OFUN-NET의 분류 정확도가 더 높음을 확인할 수 있다.

석회 환부의 경우 종괴 환부보다 더욱 진단이 어려운 것으로 알려져 있으며 본 실험의 결과도 종괴환부에 비하여 성능이 좋지 않은 것으로 분석되었다. 하지만 기존의 널리 알려진 방법이나 각각의 특징데이터를 사용한 경우에 비하여 듀얼 OFUN-NET을 사용한 경우 더욱 정확하게 분류하는 것으로 알 수 있다.

위와 같은 실험결과는 데이터 준비과정, 특징추출기법과 처리과정으로부터 많은 영향을 받기 때문에 정량적으로 상대적인 비교를 하는 것은 어렵다. 하지만 두 종류의 데이터를 각각의 학습 신경망에 학습시켜 그 결과를 통합하는 제안된 진단시스템의 성능이 향상된 것을 확인할 수 있다. 또한 신경망의 구조와 퍼지이론을 통합하여 각 진단 결과에 대한 가능성과 진단상태에 대하여 알 수 있으므로 의사의 최종 결정을 돕는 보다 정확한 정보를 제공할 수 있음을 확인할 수 있다.

<표 3> 석회 유형(Calcification Type) 데이터의 분류 정확도 비교

KNN	SVM	OFUN-NET1	OFUN-NET2	듀얼 OFUN-NET
85.4%	88.7%	88.3%	87.8%	89.7%

5. 결 론

여성에게 유방암은 가장 많이 발병되는 암으로서 그 사망자 수도 해마다 증가하고 있다. 또한 유방암 진단을 원하는 환자의 수도 증가되고 있으며 의료정보화가 발달됨에 따라 컴퓨터 보조진단시스템의 활용으로 그 진단의 정확성을 높이는 연구가 계속되고 있다.

유방 디지털 X선 영상의 종괴와 석회 환부는 진단을 위한 중요한 단서로 활용되고 있다. 이를 컴퓨터에서 처리하기 위해서는 다른 응용의 영상처리와 마찬가지로 전처리과정을 통하여 진단에 필요한 특징 데이터를 선택하여야 한다.

본 논문에서는 X선 판독전문가의 BI-RADS 기준에 의하여 추출된 특징데이터와 영상처리에 의한 통계적 특징데이터를 사용하여 제안된 듀얼 OFUN-NET에 학습시켜 퍼지 클러스터 기반 지식베이스를 구축하였다. 이렇게 구축된 지식베이스를 통하여 환부영상의 양성과 악성여부에 대한 분류와 분류정확도를 제공해 주는 시스템을 제안하였다. 이 시스템은 서로 다른 기준으로 준비된 특징 데이터를 OFUN-NET으로 처리하고 그 결과를 결합하는 방법을 사용하였으며 널리 알려진 DDSM의 실제 데이터로부터 여러 종류의 데이터를 처리하여 제안된 시스템의 타당성을 확인하였다.

이러한 시스템의 성능은 디지털라이저의 처리 과정이나 데이터 전처리 과정에 크게 좌우되므로 서로 다른 연구결과를 정량적으로 비교하는 것은 쉽지 않다.. 하지만 보다 다양한 환부 영상에 대한 체계적인 실험이 필요하며 여러 기관으로부터 다양한 데이터에 대하여 분석하고 실험하여 체계화시켜 나가야한다. 또한 진단을 위한 중요한 데이터인 특징선택과 관련된 앞선 연구[7, 18]를 바탕으로 성능에 영향을 미치는 특징을 선택할 수 있는 자동화된 방법을 연구한다면 관련분야의 성능을 향상시킬 수 있을 것으로 기대한다. 특히 최근 환부 조직의 양상이 다양해지고 관련 장비도 많은 발전이 있으므로 유방암진단을 위한 컴퓨터보조진단시스템의 전문화와 연구는 계속 진행되어야 할 것이다.

참 고 문 헌

- [1] A. C. Society, Cancer Facts and Figures. American Cancer Society, 2008.
- [2] L. Wei, Y. Yang, R. Nishikawa, and Y. Jiang, "A study on several machine-learning methods for classification of malignant and benign clustered microcalcifications," IEEE Trans. on Medical Imaging, Vol.24, pp.371-380, 2005.
- [3] I. El-Naqa, Y. Yang, M. Wernick, N. Galatsanos, and R. Nishikawa, "A support vector machine approach for detection of microcalcifications," IEEE Trans. on Medical Imaging, Vol.21, No.12, pp.1552-1563, 2002.
- [4] Heath, M., Bowyer, K., Kopans, D., Moore, R., & Jr. Kegelmeyer, P., The Digital Database for Screening Mammography, 2001, Medical Physics Publishing.
- [5] A.C. of Radiology, Breast Imaging Reporting and Data System(BI-RADS). American College of Radiology, 1998.
- [6] Ping Zhang, Brijesh Verma, Kuldeep Kumar, "Neural vs. statistical classifier in conjunction with genetic algorithm based feature selection," Pattern Recognition Letters26, pp.909-919, 2005.
- [7] S. Kim and S. Yoon, "Mass lesions classification in digital mammography using optimal subset of bi-rads and gray level features," in IEEE proceedings of ITAB2007, pp.99-102, 2007.

[8] Baker, J.A., Kornguth, P.J., Lo, J.Y., Williford, M.E., & Floyd, C.E., Jr., Breast Cancer: Prediction with Artificial Neural Network based on BI-RADS Standardized Lexicon, *Radio-logy*, 1995, 196(3): pp.817-822.

[9] Bovis, K., Singh, S., Fieldsend, J., and pinder, C., Identification of Masses in Digital Mammograms with MLP andRBF Nets, *proc. of the IEEE International Joint Conference on Neural Networks (IEEE-INNS-ENNS'2000)*, 2000.

[10] Edwards, D.C., Lan, L., Metz, C.E., Giger, M.L. & Nishikawa, R.M., Estimating Three Class Ideal Observer Decision Variables for Computerized Detection and Classification of Mammographic Mass Lesions, *Medical Physics*, 2004, 31(1): pp.81-90.

[11] Wu, Y., He, J., Man, Y., & Arribas, J.I., Neural Network Fusion Strategies for Identifying Breast Masses, *proc. of the IEEE International Joint Conference on Neural Networks (IEEE-IJCNN'2004)*, 2004.

[12] R. Panchal and B. Verma, "Characterization of breast abnormality patterns in digital mammograms using auto-associator neural network," in *International Conference on Image Processing 2006, Part III, LNCS, Vol.4234*, pp.127-136, Springer-Verlag, 2006.

[13] Brijesh Verma and John Zakos, A Computer-Aided Diagnosis System for Digital Mammograms Based on Fuzzy-Neural and Feature Extraction Techniques, *IEEE Trans. on Information Technology in Biomedicine*, Vol.5, No.1, March, 2001.

[14] J.Y. Lo, et al., Computer-aided classification of breast microcalcification clusters: Merging of features from image processing and radiologists, 2003.

[15] Yi-Ta Wu, Yoo Jung An, James Geller and Yih-Tyng Wu, "A Data Mining Based Genetic Algorithm", *Proc. of the 4th IEEE workshop on SEUS-WCCIA*, 2006.

[16] Jian Yu and Miin-Shen Yang, "Optimality Test for Generalized FCM and Its Application to Parameter Selection", *IEEE Transactions on Fuzzy Systems*, Vol.13, No.1, Feb., 2005.

[17] 이현숙, "컴퓨터 바이러스 분류를 위한 퍼지 클러스터 기반 진단시스템", *정보처리학회 논문지 제14-B권 제1호*, pp.59-64, 2007. 2.

[18] 이현숙, "퍼지 클러스터 분석 기반 특징 선택 방법", *정보처리학회 논문지 제14-B권 제2호*, pp.135-140, 2007. 4.



이 현 숙

e-mail : hsrhee@dongyang.ac.kr

1989년 서강대학교 전자계산학과(학사)

1991년 포항공과대학교 컴퓨터공학과(석사)

1997년 서강대학교 컴퓨터학과(박사)

1991년~1997년 한국전자통신연구소(ETRI) 연구원

2006~2007 미국 University of Central Florida 방문교수

1997년~현 재 동양공업전문대학 전산정보학부 부교수

관심분야 : 지능형정보처리, 소프트웨어개발방법론 등



윤 석 민

e-mail : smyoon@dongyang.ac.kr

1981년 연세대학교 전자공학과(학사)

1986년 연세대학교 대학원 전자공학과(공학석사)

2002년 충북대학교 대학원 컴퓨터공학과(공학박사)

1986년~현 재 동양공업전문대학 전산정보학부 교수

관심분야 : 소프트웨어 프로세스 심사, 성능평가 등