피셔 분별 사전학습을 이용해 개선된 Sparse 표현 기반 악성 종괴 검출

김성태[†], 이승현^{††}, 민현석^{†††}, 노용만^{††††}

요 약

X-ray를 이용한 여성의 유방암 검사인 유방조영술은 유방암의 초기 단계에서의 진단을 위한 효과적인 방법이다. 컴퓨터 지원 검출(CAD) 시스템은 유방조영술을 통한 진단 시 의사가 놓치기 쉬운 유방암의 징후인 종괴의 검출을 도와 유방암 진단율을 높이는 수단이다. 종괴는 다양한 모양을 지니며 경계가 뚜렷하지 않기 때문에 검출이 어렵고 결과적으로 비-종괴 영역을 포함한 많은 수의 종괴 후보영역이 CAD 시스템에서 검출된다. 따라서 CAD 시스템 설계 시 검출된 많은 수의 종괴 후보영역으로부터 실제 악성 종괴 영역을 분류할 수 있도록 우수한 성능의 분류기가 요구된다. 본 논문에서는 피셔 분별 사전학습을 통해 개선된 Sparse 표현(SR) 기반 분류방법을 제안한다. 개선된 SR 기반 분류기가 기존의 CAD 시스템에서 주로 사용되어온 Support Vector Machine (SVM) 분류기 보다 우수함을 비교실험을 통해 확인했다.

Improvement of Sparse Representation based Classifier using Fisher Discrimination Dictionary Learning for Malignant Mass Detection

Seong Tae Kim[†], Seung Hyun Lee^{††}, Hyun-seok Min^{†††}, Yong Man Ro^{††††}

ABSTRACT

Mammography, the process of using X-ray to examine the woman breast, is the one of the effective tools for detecting breast cancer at an early state. In screening mammogram, Computer-Aided Detection(CAD) system helps radiologist to diagnose cases by detecting malignant masses. A mass is an important lesion in the breast that can indicate a cancer. Due to various shapes and unclear boundaries of the masses, detecting breast masses is considered a challenging task. To this end, CAD system detects a lot of regions of interest including normal tissues. Thus it is important to develop the well-organized classifier. In this paper, we propose an enhanced sparse representation (SR) based classifier using Fisher discrimination dictionary learning. Experimental results show that the proposed method outperforms the existing support vector machine (SVM) classifier.

Key words: Computer-Aided detection(컴퓨터 지원검출), Breast masses(유방 종괴), Sparse representation (Sparse 표현), Dictionary learning(사전학습)

※ 교신저자(Corresponding Author): 노용만, 주소: 대전광역시 유성구 구성동 대학로 291 한국과학기술원 IT 융합센터 418호(305-701), 전화: 042) 350-8094, FAX: 042) 350-7619, E-mail: ymro@ee.kaist.ac.kr
접수일: 2013년 1월 29일, 수정일: 2013년 2월 18일
완료일: 2013년 2월 25일

[†] 준회원, 한국과학기술원 전기 및 전자공학과
(E-mail: stkim4978@kaist.ac.kr)

^{††} 준회원, 한국과학기술원 전기 및 전자공학과
(E-mail: faintblue@kaist.ac.kr)

^{†††} 준회원, 한국과학기술원 전기 및 전자공학과
(E-mail: hsmin@kaist.ac.kr)

^{††††} 중신회원, 한국과학기술원 전기 및 전자공학과

1. 서 론

유방암은 여성에게서 가장 자주 진단되는 암의 하나이다. X-ray를 이용한 유방암 검사인 유방조영술은 이러한 유방암의 조기 진단을 위한 가장 효과적인 방법으로 알려져 있다[1]. 유방의 X-ray영상인 마모그램을 보고 암을 진단하기 위해서는 방사선 전문의의 정밀한 분석이 필요하다.

하지만 한정된 수의 방사선 전문의가 많은 수의 마모그램을 분석하는 것에는 한계가 있다. 특히, 유방암의 병변 중 하나인 종괴의 경우, 다양한 모양을 지니며 경계가 뚜렷하게 나타나지 않아 유방암 진단에 어려움을 가져온다[2]. 이는 방사선 전문의가 종괴를 발견하지 못하고 지나칠 위험이 있다는 것을 의미하며, 또한 의심스러워 보이는 비-종괴 조직의 불필요한 조직검사를 초래해 의료비용의 증가를 가져오기도 한다. 이러한 어려움을 극복하기 위해 CAD 시스템의 연구에 관한 관심이 높아지고 있다. CAD 시스템은 컴퓨터가 마모그램을 분석해 악성 종괴 영역을 표시하는 시스템으로 의사가 놓칠 수 있는 유방암 징후를 진찰할 수 있어 유방암의 진단율을 높인다.

일반적으로 CAD 시스템은 크게 영상을 개선하는 전처리 단계와 종괴로 의심되는 영역을 검출하는 단계, 검출된 영역의 모양이나 구조를 기술하는 특징정보 추출 단계, 이 특징정보를 이용해 검출된 영역이 실제로 암 조직인지 분류하는 단계로 나눌 수 있다. 이 중에서 분류단계는 많은 수의 종괴 후보영역으로부터 실제 악성 종괴를 구분해 내 최종적인 결과를 내기에 전체 시스템에서 매우 중요한 단계이다. 따라서 CAD 시스템을 이용해 유방암의 진단율을 향상시키기 위해서는 종괴의 특성을 잘 반영할 수 있는 분류기의 개발이 필수적이다.

최근 신호처리 분야에서 SR에 기반을 둔 분류기에 관한 연구가 많은 관심을 받고 있다. SR 기반 분류[3]는 입력영상을 적은 수의 학습영상의 선형조합으로 표현할 수 있다는 생각[4], 즉 영상의 sparsity[5]를 이용한 분류방법이다. 일반적으로 많은 수의 학습영상을 이용하여 사전을 구성할수록 sparsity가 증가해 더욱 적은 수의 학습영상으로 입력영상을 표현할 수 있게 되며 분류기의 성능이 증가한다고 알려져 있다[6]. 하지만 임상에서 얻은 영상을 이용하는

CAD 시

스템의 특성상 많은 수의 학습영상을 확보하는데 한계가 있다. 이는 분류기의 성능저하 초래한다. [7]에서 M. Yang은 SR 기반 분류방법에서 피쳐 분별 사전학습을 이용해 주어진 사전의 sparsity와 분별력을 증가시켜 분류기의 성능을 향상시키는 실험결과를 발표했다.

이에 본 논문에서는 영상에 존재하는 sparsity를 이용해 그와 매우 유사한 특성을 갖는 적은 수의 학습영상으로 종괴 영역을 표현함으로써 효과적인 분류를 할 수 있는 SR 기반 분류기를 제안한다. 또, 제한된 수의 학습영상이 주어지는 CAD 시스템의 환경에서 발생하는 분류기의 성능저하를 막기 위해 피쳐 분별 사전학습을 이용해 사전을 학습함으로써 sparsity와 분별력을 높인다.

본 논문의 구성은 다음과 같다. 먼저, 2장에서는 제안하는 피쳐 분별 사전학습을 이용한 SR 기반 분류기와 전체 CAD 시스템에 대해 소개한다. 3장에서는 제안하는 방법의 우수성을 확인하기 위해 공식 마모그램 데이터베이스[8]에서 비교실험을 수행한 결과에 대해 분석한다. 마지막으로 4장에서 결론을 맺는다.

2. 제안하는 SR 기반 분류기를 사용하는 CAD 시스템

그림 1은 제안하는 CAD 시스템을 나타낸다. 전체 시스템은 크게 2단계로 나뉜다: 1) SR 기반 분류기의 사전학습 단계; 2) SR 기반 종괴 분류 단계.

먼저, SR 기반 분류기의 사전학습 단계에서는 학습영상에서 검출된 종괴 후보영역으로부터 특징정보를 추출해 사전을 구성한다. 이렇게 만들어진 사전은 피쳐 분별 사전학습방법을 이용해 sparsity와 분별력이 커지도록 학습된다. 이렇게 학습된 사전을 이용해 SR 기반 종괴 분류 단계에서는 입력영상에서 검출된 종괴 후보영역으로부터 악성 종괴를 분류한다.

2.1 SR에 기반을 둔 악성 종괴의 분류

그림 1에서 볼 수 있듯이 제안하는 CAD 시스템에서 악성 종괴 검출은 다음의 4가지 단계를 통해 이뤄진다: 1)전처리; 2)종괴 후보영역 검출; 3) 종괴 특징

그림 1. 제안하는 피셔 분별 사전학습과 SR 기반 분류기를 사용한 CAD 시스템의 전체적인 구조

정보 추출; 4) SR 기반 종괴 분류. 전처리 단계에서는 입력영상에 있는 종괴 후보영역의 검출을 용이하게 하기 위하여 입력영상을 개선한다[9]. 다음 단계인 종괴 후보영역 검출단계에서는 전처리를 거친 영상(그림 1 (b))에서 윤곽형성(contouring)알고리즘[10]을 이용해 종괴로 의심되는 종괴 후보영역을 검출한다(그림 1 (c)). 이렇게 검출된 종괴 후보영역에는 많은 수의 비-종괴 영역이 포함되어 있다[11]. 따라서 분류과정을 통해 많은 수의 종괴 후보영역으로부터 악성 종괴영역과 비-종괴 영역을 분류해야 한다. 따라서 종괴 특징정보 추출단계에서는 검출된 종괴 후보영역들로부터 악성 종괴를 분류하는데 용이하도록 특징정보를 추출한다[12,13]. 마지막으로 SR 기반 종괴 분류단계에서는 추출된 특징정보를 이용해 구성된 사전을 이용해 SR 기반 분류 방법으로 종괴 후보영역으로부터 악성 종괴를 분류한다.

본 논문에서 사용하는 SR 기반 종괴 분류방법은 다음과 같다. 학습영상에서 검출된 종괴 후보영역중에서 $\mathbf{a}_i^+$ 를 i 번째 악성 종괴 영역의 특징정보 벡터, $\mathbf{a}_j^-$ 를 j 번째 비-종괴 영역의 특징정보 벡터라고 정의하면, 사전 $\mathbf{A}$ 를 다음과 같이 정의할 수 있다.

$$\mathbf{A} = [\mathbf{A}^+ | \mathbf{A}^-] = [\mathbf{a}_1^+, \dots, \mathbf{a}_k^+, \mathbf{a}_1^-, \dots, \mathbf{a}_k^-] \in \mathbb{R}^{d \times k} \quad (1)$$

여기서 $\mathbf{A}^+$ 와 $\mathbf{A}^-$ 는 각각 사전에서 악성 종괴 영역의 특징정보 벡터로 구성된 부분집합, 비-종괴 영역

의 특징정보 벡터로 구성된 부분집합이다. 또한, k^+ 와 k^- 는 $\mathbf{A}^+$ 와 $\mathbf{A}^-$ 의 각 특징 벡터의 수, d 는 특징정보 벡터의 차원이다. 이러한 사전 $\mathbf{A}$ 와 입력영상에서 검출한 종괴 후보영역의 특징정보 벡터 $\mathbf{y}$ 에 대해 다음의 식을 만족시키는 sparse 벡터 $\hat{\alpha}$ 를 구한다.

$$\hat{\alpha} = \underset{\alpha}{\operatorname{argmin}} \{ \|\mathbf{y} - \mathbf{A}\alpha\|_2^2 + \gamma \|\alpha\|_1 \} \quad (2)$$

위 식에서 γ 는 상수 값으로 두 항의 상대적 비중을 조절한다. 또한 $\hat{\alpha} = [\hat{\alpha}^+; \hat{\alpha}^-]$ 로 $\hat{\alpha}^+$ 는 악성 종괴 영역의 특징정보 벡터에 대응하는 sparse 계수를 나타내며, $\hat{\alpha}^-$ 는 비-종괴 영역의 특징정보 벡터에 대응하는 sparse 계수를 나타낸다. 이 때, 다음의 조건을 만족하는 종괴 후보영역 $\mathbf{y}$ 을 악성 종괴라고 분류한다.

$$\|\mathbf{y} - \mathbf{A}^+ \hat{\mathbf{D}}^+\| < \|\mathbf{y} - \mathbf{A}^- \hat{\mathbf{D}}^-\| \quad (3)$$

일반적으로 SR 기반 분류에서는 사전 $\mathbf{A}$ 를 이루는 학습영상의 특징정보 벡터의 수 k 가 충분히 커야 성능이 안정적으로 보장된다 (즉, 사전 $\mathbf{A}$ 가 오버컴플리트 해야 한다) [6]. 하지만 임상 데이터를 사용하는 CAD 시스템의 특성상 학습영상을 확보하는 것은 쉽지 않다. 이는 SR 기반 분류기의 성능저하를 초래할 수 있다.

따라서 본 논문에서는 피셔 분별 사전학습으로 학습된 사전을 이용해 충분한 수의 학습영상을 확보하지 못하는 환경에서도 높은 분류성능을 제공하는 SR

기반 분류 방법을 제안한다.

2.2 SR 기반 분류를 위한 피서 분별 사전학습

피서 분별 사전학습은 학습영상의 특징정보 벡터로 구성된 사전 A 가 주어졌을 때, 식 (4)의 목적함수를 만족하는 sparse 행렬($X=[X^+X^-] \in \mathbb{R}^{k \times k}$)과 새롭게 학습된 사전($D=[D^+D^-] \in \mathbb{R}^{d \times k}$)을 생성하는 것을 목표로 한다. 여기서 D^+ 와 D^- 는 각각 악성 종괴 영역과 비-종괴 영역을 표현하기 위한 사전의 부분집합, X^+ 와 X^- 는 각각 사전 A 에서 악성 종괴 영역으로부터 구성된 부분집합 사전 A^+ 와 비-종괴 영역으로부터 구성된 부분집합 A^- 를 새롭게 학습된 사전 D 를 이용해 부호화한 sparse 행렬이다.

$$J_{(D,X)} = \operatorname{argmin}_{(D,X)} \left\{ r(A,D,X) + \lambda_1 \|X\|_1 + \lambda_2 f(X) \right\} \quad (4)$$

다음으로는 식 (4)의 3가지 항의 의미에 대해 설명한다. 먼저 $r(A,D,X)$ 를 설명하기 위해 다음과 같이 정의한다. X_+^+ 를 A^+ 의 D^+ 에 대한 부호벡터, X_+^- 를 A^+ 의 D^- 에 대한 부호벡터, X_-^+ 를 A^- 의 D^+ 에 대한 부호벡터, X_-^- 를 A^- 의 D^- 에 대한 부호벡터라고 정의할 때, $X^+=[X_+^+X_+^-]$, $X^-=[X_-^+X_-^-]$ 가 된다. 이를 이용해 $r(A,D,X)$ 를 다음과 같이 정의한다.

$$r(A^+,D,X^+) = \|A^+ - DX^+\|_F^2 + \|A^+ - D^+X_+^+\|_F^2 + \|D^-X_+^-\|_F^2 \quad (5)$$

$$r(A^-,D,X^-) = \|A^- - DX^-\|_F^2 + \|A^- - D^-X_-^-\|_F^2 + \|D^+X_-^+\|_F^2 \quad (6)$$

$$r(A,D,X) = r(A^+,D,X^+) + r(A^-,D,X^-) \quad (7)$$

먼저, 악성 종괴 영역인 A^+ 에 관한 식 (5)의 의미를 설명하면 먼저 사전 D 는 A^+ 를 잘 표현할 수 있어야 한다. 즉, $R^+=D^+X_+^+$, $R^-=D^-X_+^+$ 라고 정의하면 A^+ 가 $DX^+=D^+X_+^++D^-X_+^+=R^++R^-$ 와 거의 같아야 하고 이는 식 (5)의 첫 번째 항을 작게 하는 사전 D 를 구해 해결할 수 있다. 하지만 이러한 조건을 만족하는 모든 사전이 항상 좋은 사전은 아니다. 예를 들어 $R^++R^-\simeq A^+$ 를 만족하는 사전 중 그림 2의 (a)와 같은 경우, R^+ 와 R^- 모두 A^+ 를 표현하는데 큰 기여를 하게 되고 $\|y-A^+D^+\| \simeq \|y-A^-D^-\|$ 가 되어 SR 기반 분류 시 어려움을 야기하게 된다. 따라서 A^+ 는 사전 D 에 의해 잘 표현될 뿐 아니라, 사전의

그림 2. $r(A,D,X)$ 에 대한 그림설명. (a) D 에 의해 A^+ 가 잘 표현될 때. (b) $r(A,D,X)$ 를 충분히 작게 할 때 (즉, A^+ 가 D^+ 에 의해 잘 표현되는 경우)

부분집합 D^+ 에 의해서도 잘 표현되어야 한다. 즉, $A^+\simeq R^+$ 와 $R^-\simeq 0$ 를 추가적으로 만족시켜야 한다. 이를 만족 시키는 사전을 찾는 것은 식 (5)의 첫 번째 항뿐만 아니라, 두 번째, 세 번째 항을 작게 하는 사전을 찾아 해결할 수 있다. 즉, $r(A,D,X)$ 는 새로운 사전 D 가 학습영상 A 를 얼마나 잘 나타내는지에 대한 표현력, 및 분별력과 관계가 있다.

식 (5)의 두 번째 항인 $\|X\|_1$ 는 sparse 행렬의 열 성분인 sparse벡터의 sparsity와 관련이 있다. 이를 작게 함으로써 sparsity를 증가 시킬 수 있다.

마지막으로 $f(X)$ 는 피서 분별 항으로 sparse 행렬 X 의 클래스내 분산과 클래스간 분산의 비율을 나타낸다. $f(X)$ 를 작게 하는 것은 클래스간 분산은 크게 하면서 클래스내 분산은 작게 한다. 이것은 악성 종괴 영역과 비-종괴 영역의 sparse 벡터가 잘 분별되도록 한다[14].

식 (4)에서 λ_1 과 λ_2 는 위의 3가지 항의 상대적인 비중을 조절하는 매개변수이다. 실제로 식 (4)의 목적함수를 만족하는 사전은 표 1에 정리된 알고리즘을 통해 구할 수 있다. 이렇게 식 (4)의 세 가지 항의 합을 최소화 하는 사전을 SR 기반 분류에 이용할 경우 sparsity 및 분별력이 증가해 분류기의 성능이 향상되어 CAD 시스템에서 학습영상의 수가 적은 한계를 극복할 수 있게 된다.

3. 실험 및 결과

본 장에서는 피서 분별 사전학습을 이용해 학습된 사전을 사용한 SR 기반 분류방법을 이용해 마모그램에서 검출된 종괴 후보영상 중 많은 수의 비-종괴 영역으로부터 악성 종괴를 분류하는 실험에 대해 설

표 1. 제안하는 사전학습 알고리즘

피쳐	분별 사전학습
[1] 사전 $\mathbf{D}$ 초기화	사전 $\mathbf{D}$ 를 $\mathbf{A}$ 의 l_2 -norm 정규화 시킨 값으로 초기화 한다.
[2] Sparse 벡터 $\mathbf{X}$ 갱신	$J_{(\mathbf{X}^+)} = \operatorname{argmin}_{(\mathbf{X}^+)} \left\{ r(\mathbf{A}^+, \mathbf{D}, \mathbf{X}^+) + \lambda_1 \ \mathbf{X}^+\ _1 + \lambda_2 f(\mathbf{X}^+) \right\}$ $J_{(\mathbf{X}^-)} = \operatorname{argmin}_{(\mathbf{X}^-)} \left\{ r(\mathbf{A}^-, \mathbf{D}, \mathbf{X}^-) + \lambda_1 \ \mathbf{X}^-\ _1 + \lambda_2 f(\mathbf{X}^-) \right\}$ <p>사전 $\mathbf{D}$를 고정시킨 뒤, 위와 같이 sparse 부호벡터 $\mathbf{X}^+$, $\mathbf{X}^-$를 구한다.</p>
[3] 사전 $\mathbf{D}$ 갱신	<p>아래와 같은 목적함수를 만족시키는 사전 $\mathbf{D}^+$와 $\mathbf{D}^-$[15]의 방법을 이용해서 구한다.</p> $J_{(\mathbf{D}^+)} = \operatorname{argmin}_{(\mathbf{D}^+)} \left\{ \begin{aligned} &\ \mathbf{A} - \mathbf{D}^+ \mathbf{X}^+ - \mathbf{D}^- \mathbf{X}^-\ _F^2 \\ &+ \ \mathbf{A}^+ - \mathbf{D}^+ \mathbf{X}_+^+\ _F^2 \\ &+ \ \mathbf{D}^+ \mathbf{X}_+^+\ _F^2 \end{aligned} \right\}$ $J_{(\mathbf{D}^-)} = \operatorname{argmin}_{(\mathbf{D}^-)} \left\{ \begin{aligned} &\ \mathbf{A} - \mathbf{D}^- \mathbf{X}^- - \mathbf{D}^+ \mathbf{X}^+\ _F^2 \\ &+ \ \mathbf{A}^- - \mathbf{D}^- \mathbf{X}_-^-\ _F^2 \\ &+ \ \mathbf{D}^- \mathbf{X}_-^-\ _F^2 \end{aligned} \right\}$
[4] 출력	미리 정한 반복 횟수를 만족할 때까지 과정 2와 3을 반복한 뒤, $\mathbf{X}$ 와 $\mathbf{D}$ 를 출력한다.

명한다. 제안하는 방법의 우수성을 확인하기 위해 사전학습 전 후의 결과를 비교했고 추가로 기존 CAD 시스템에서 분류기로 많이 사용되어 온 RBF-SVM [16]을 이용한 분류결과와 비교하였다. 3.1 절에서는 실험환경을 소개하고, 3.2절에서 실험결과를 분석한다.

3.1. 실험환경

먼저, 실험에서 사용한 마모그램 영상은 MGH-HAWTEK 스캐너로 촬영하여 얻은 공식 데이터베이스인 DDSM[7]영상에서 눈으로 보았을 때, 뚜렷한

침꼴 모양의 종괴를 포함한 134장의 영상을 이용했다. 134장의 영상에서 전처리과정과 종괴 후보영역 검출과정을 통해 총 1473개의 종괴 후보영역이 검출되었다. 이중, 실제 악성 종괴 영역은 134개, 비-종괴 영역은 1339개가 있었다. 사전 $\mathbf{D}$ 에서 악성 종괴에 해당하는 부분집합 $\mathbf{D}^+$ 와 비-종괴 영역에 해당하는 부분집합 $\mathbf{D}^-$ 의 열벡터의 개수를 같게 하기 위해, 1339개의 비-종괴 영역에서 134개를 임의로 선택해 악성 종괴영역 134개와 함께 종괴 후보영역으로 실험에 사용했다. 분류기가 학습영상에 오버피팅되는 것을 피하기 위해 10-fold cross validation [17] 방법으로 실험을 진행했다.

종괴 후보영역으로부터 실제 악성 종괴를 분류하기 위해 LBP 특징과 인텐시티 특징의 두 종류의 특징정보를 추출해 각각의 특징정보를 이용해 악성 종괴를 분류하는 실험을 진행했다. 피쳐 분별 사전학습의 매개변수는 그리드 서치[18]방법을 이용해 최적화된 값을 찾았다. 각각의 특징정보에 대한 차원과 피쳐 분별 사전학습에서의 최적화된 매개변수 값을 표 2에 정리했다. 본 실험에서 식 (1)에서의 사전을 구성하는 열의 개수 (k)는 학습영상의 개수로써 242개이고, 행의 개수(d)는 특징정보의 차원에 의해 결정된다. 표 2의 특징정보의 차원으로부터 LBP 특징정보의 경우 사전의 열의 개수 (k)가 행의 개수 (d)보다 작아 오버컴플리트 조건을 만족시키지 못한다는 것을 알 수 있다.

본 실험의 성능을 측정하기 위하여 악성 종괴 영역을 맞게 분류한 비율인 True Positive rate(TP rate)와 비-종괴 영역을 악성 종괴 영역이라고 잘못 분류한 비율인 False Positive rate(FP rate), 그리고 모든 종괴 후보영역에 관해 분류에 성공한 비율인 정확도를 사용했다. N_p 를 종괴 후보영역 중 악성 종괴의 수, N_N 을 종괴 후보영역 중 비-종괴 영역의 수, N_{TP} 를 분류에 성공한 악성 종괴의 수, N_{TN} 을 분류에 성공한 비-종괴 영역의 수라고하면 TP rate, FP rate, 그리고 정확도는 각각 다음과 같이 정의된다.

표 2. 실험에서 사용된 특징정보 및 피쳐 분별 사전학습방법의 매개변수

특징정보	요 약	차원	λ_1	λ_2
LBP [11]	원모양의 인근 pixel들로부터 LBP histogram 계산	354	1.5	1.25
인텐시티 [12]	해당 영역의 밝기를 인텐시티의 통계적 특성을 이용해 측정	7	2	0.25

표 3. 피서 분별 사전학습을 통한 악성 종괴 분류 실험 결과

특징정보	SR 기반 분류기에 사용된 사전	정확도	TP rate	FP rate
LBP	학습 전 사전(A)	0.776	0.851	0.299
	학습 후 사전(D)	0.821	0.828	0.186
인텐시티	학습 전 사전(A)	0.820	0.857	0.216
	학습 후 사전(D)	0.859	0.858	0.141

$$TP\ rate = \frac{N_{TP}}{N_p} \quad (8)$$

$$FP\ rate = 1 - \frac{N_{TN}}{N_N} \quad (9)$$

$$정확도 = \frac{N_{TP} + N_{TN}}{N_p + N_N} \quad (10)$$

3.2 실험 결과

표 3은 학습영상으로부터 바로 구성한 사전과 제안하는 방법을 이용해 학습된 사전에 관해, 각각을 사용했을 때, SR 기반 악성 종괴 분류 실험의 결과를 나타낸다. 두 종류의 특징정보에서 모두 학습 전 사전을 사용했을 때보다 학습 후 사전을 사용했을 때, 분류에 성공한 비율인 정확도가 증가했다. 인텐시티 특징정보의 경우는 학습된 사전을 사용함으로써 TP rate은 거의 동일하게 유지되며 FP rate은 감소했다. LBP 특징정보의 경우는 학습 전보다 TP rate이 조금 감소하긴 했지만 FP rate이 훨씬 큰 수준으로 감소함을 볼 수 있다. 특히, LBP 특징정보의 경우 오버컴플리트 조건을 만족시키지 못해 학습 전 성능이 불안정했지만 학습을 통해 사전을 개선함으로써 높

은 성능의 분류 결과를 얻은 것을 볼 수 있었다.

이 실험 결과를 기존의 CAD 시스템에서 많이 사용되던 RBF SVM[14]을 이용해 진행한 실험의 분류 결과와 비교했다. 그림 3에서 볼 수 있듯, 두 특징정보에서 모두 학습 후 사전을 사용한 SR 기반 분류의 결과가 SVM의 ROC 곡선보다 위에 있어 같은 FP rate에서 더 높은 TP rate을 얻은 것을 볼 수 있다. 이로부터 두 특징정보에서 모두 사전학습을 통해 SR 기반 분류의 성능이 증가했으며 기존의 분류 방법인 SVM을 통한 분류보다 우수한 성능을 보인다는 것을 알 수 있었다.

4. 결 론

유방암 진단을 위한 CAD 시스템에서 다양한 모양 및 불분명한 경계를 갖는 종괴의 특성으로 인해 많은 수의 종괴 후보영역이 검출된다. 따라서 종괴의 특성을 잘 반영해 종괴 후보영역으로부터 악성 종괴를 잘 분류할 수 있는 우수한 성능의 분류기가 필요하다. 본 논문에서는 피서 분별 사전학습을 통해 개선된 SR 기반 분류기를 이용한 CAD 시스템을 제안

그림 3. SVM 의 분류 결과인 ROC 비교. (a) LBP 특징정보에서의 결과. (b) 인텐시티 특징정보에서의 결과

한다. 제안하는 방법을 이용해 악성 종괴의 분류 실험을 진행한 결과, 기존의 CAD 시스템에서 주로 사용되어온 SVM 분류기를 통한 실험 결과보다 더 높은 분류 성능을 가짐을 확인할 수 있었다. 추후에는 실제 CAD 시스템의 사용 시 실시간으로 얻을 수 있는 임상의 영상들을 이용해 분류기의 성능을 더욱 향상 시킬 수 있는 방법에 관해 연구할 필요가 있다.

참 고 문 헌

- [1] K. Bovis, S. Singh, J. Fieldsend, and C. Pinder, "Identification of Masses in Digital Mammograms with MLP and RBF Nets," *Proc. of the 16-INNS-ENNS Int'l Joint Conf on Neural Networks*, Vol. 1, pp. 342-347, 2000.
- [2] Daniel B. Kopans, "The Positive Predictive Value of Mammography," *American Journal of Roentgenology* Vol. 158, No. 3, pp. 521-526, 1992.
- [3] J. Wright, A.Y. Yang, A. Ganesh, S.S. Sastry, and Y. Ma, "Robust Face Recognition via Sparse Representation," *IEEE Transaction on Pattern Recognition and Machine Intelligence*, Vol. 31, No. 2, pp. 210-227, 2009.
- [4] 김형일, 엄원용, 노용만, "Sparse 표현을 이용한 X선 흡수 영상 개선," *한국멀티미디어학회 논문지*, 제15권, 제10호, pp. 1205-1211, 2012.
- [5] K. Huang, and S. Aviyente, "Sparse Representation for Signal Classification," *Advances in Neural Information Processing Systems*, pp. 609-616, 2007.
- [6] B.A. Olshausen and D.J. Field, "Sparse Coding with an Overcomplete Basis Set: A Strategy Employed by V1?," *Vision Research*, Vol. 37, No. 23, pp. 3311-3325, 1997.
- [7] M. Yang, L. Zhang, X. Feng, and D. Zhang, "Fisher Discrimination Dictionary Learning for Sparse Representation," *Int'l Conf. on Computer Vision*, pp. 543-550, 2011.
- [8] M. Heath, K. Bowyer, D. Kopans, R. Moore, and P.J. Kegelmeyer, "The Digital Database for Screening Mammography," *Proc. of 5th Int'l Conf. on Digital Mammography*, pp. 212-218, 2000.
- [9] D.H. Kim, J.Y. Choi, S.H. Choi, and Y.M. Ro, "Mammographic Enhancement with Combining Local Statistical Measures and Sliding Band Filter for Improved Mass Segmentation in Mammograms," *Proc. of the SPIE Medical Imaging*, Vol. 8315, pp. 83151Z-83151Z-6, 2012.
- [10] B.W. Hong, and J.M. Bready, "A Topographic Representation for Mammogram Segmentation," *LNCS*, Vol. 2879, pp. 730-737, 2003.
- [11] 이승현, 김대회, 최재영, 노용만, "CAD를 활용한 유방 종괴 검출에서 false positive 감소를 위한 특징정보 융합에 관한 연구," *한국멀티미디어학회 추계학술대회 논문집*, 제14권, 제2호, pp. 207-210, 2011.
- [12] J.Y. Choi, D.H. Kim, and Y.M. Ro, "Combining Multiresolution Local Binary Pattern Texture Analysis and Variable Selection Strategy Applied to Computer-Aided Detection of Breast Masses on Mammograms," *IEEE-EMBS Int'l Conf. on Biomedical and Health Informatics*, pp. 496-498, 2012.
- [13] H.D. Cheng, X.J. Shi, R. Min, L.M. Hu, X.P. Cai and H.N. Du, "Approaches for Automated Detection and Classification of Masses in Mammograms," *Pattern Recognition*, Vol. 39, No. 4, pp. 646-668, 2006.
- [14] R.O. Duda, P.E. Hart, and D.G. Stork, *Pattern Classification*, John Wiley, New York, 2000.
- [15] M. Yang and L. Zhang, "Gabor Feature based Sparse Representation for Face Recognition with Gabor Occlusion Dictionary," *LNCS*, Vol. 6316, pp. 448-461, 2010.
- [16] T. Joachims, "Text Categorization with Support Vector Machines: Learning with Many Relevant Features," *LNCS*, Vol. 1398, pp. 137-142, 1998.
- [17] R. Kohavi, "A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection," *Int'l Joint Conf. on Artificial Intelligence*, pp. 1137-1143, 1995.

- [18] C.W. Hsu, C.C. Chang, and C.J. Lin, *A Practical Guide to Support Vector Classification*, Technical Report of University of National Taiwan, 2003.

김 성 태

2012년 고려대학교 전기전자전파
공학전공 공학사
2012년~현재 한국과학기술원 전기
및 전자공학과 석사과정
관심분야: 의료 영상 처리, 패턴
인식

이 승 현

2011년 고려대학교 전기전자전파
공학전공 공학사
2013년 한국과학기술원 전기 및
전자공학과 공학석사
관심분야: 의료 영상 처리, 패턴
인식

민 현 석

2006년 아주대학교 정보 및 컴퓨
터공학전공 공학사
2008년 한국과학기술원 전기 및
전자공학과 공학석사
2008년~현재 한국과학기술원 전
기 및 전자공학과 박사과정

관심분야: 영상 분석, 영상 검색, 패턴인식, 의료 영상
처리

노 용 만

1985년 연세대학교 전자공학과
공학사
1987년 한국과학기술원 전기 및
전자공학과 공학석사
1992년 한국과학기술원 전기 및
전자공학과 공학박사

1987년~1988년 Columbia University 연구원
1996년~1997년 University of California Berkeley 연구원
2006년~2007년 University of Toronto 방문교수
1997년 2월~현재 한국과학기술원 전기 및 전자공학과
정교수
관심분야: 영상 및 비디오 신호처리, 패턴인식, MPEG-
7, Image and Video indexing, Spectral
analysis of image signal