

다중 거칠기 벡터와 통계적 분류기를 이용한 초음파 간 영상 분류에 관한 연구

정 정 원·김 동 윤

= Abstract =

A Study on the Classification of Ultrasonic Liver Images Using Multi Texture Vectors and a Statistical Classifier

Jeong-Won Jeong, Dong-Youn Kim

Since one texture property(i.e coarseness, orientation, regularity, granularity) for ultrasound liver images was not sufficient enough to classify the characteristics of livers, we used multi texture vectors extracted from ultrasound liver images and a statistical classifier.

Multi texture vectors are selected among the feature vectors of the normal liver, fat liver and cirrhosis images which have a good separability in those ultrasound liver images. The statistical classifier uses multi texture vectors as input vectors and classifies ultrasound liver images for each multi texture vector by the Bayes decision rule. Then the decision of the liver disease is made by choosing the maximum value from the averages of a posteriori probability for each multi texture vector.

In our simulation, we obtained higher correct ratio than that of other methods using single feature vector, for the test set the correct ratio is 94% in the normal liver, 84% in the fat liver and 86% in the cirrhosis liver.

Key words : Texture, Multi texture vectors, A statistical classifier, Ultrasound liver images

서 론

간질환중 흔히 발생되는 지방간이나 간경화와 같은 질환들은 주로 초음파 단층 영상에 의해 간 실질 및 표면의 변성 상태나 간의 형태 변형, 관상 구조물의 상태 등을 관찰함으로서 진단을 내린다. 이러한 진단 요소 중에서 간 실질의 변성에 따른 초음파 반향의 세기와 분포 변화는 초음파 영상의 거칠기를 특징 지우므로 초음파 실질영상의 거칠기 특성을 간 질환의 분류에 중요한 파라메타가 된다[1].

초음파 간 영상의 거칠기는 간 실질의 형태, 구성, 상태에 따라 크게 달라진다. 예를 들어 정상 실질의 초음파 영상은 전체적으로 균일하고 미세한 거칠기를 갖는 반면, 미만성 실질(diffuse parenchyma)의 초음파 영상은 병변

이나 진행정도에 따라 미세한 흰 점들이 빼빼하게 분포하여 국부적으로 밝게 나타나거나, 그물 모양의 굽은 점들이 불규칙하게 분포하는 등 정상간에 비해 일반적으로 거칠게 보여진다[2]. 따라서 초음파 간영상의 분류에 관한 연구들은 주로 초음파 영상의 거친 정도와 같은 거칠기 특성을 정량화 하는 다양한 특징 벡터들의 검출 방법에 초점을 두고 진행되어 왔다[3-13].

1992년에 Wu[13]등은 정상간, 간염, 간경화 초음파 영상을 분류하기 위하여 다해상도 프랙탈 특징 벡터와 퓨리에 파워 스펙트럼 특징 벡터 등을 결합하여 Bayes 분류기로 분류하는 방법을 제안하였고 실험 결과 초음파 간 영상을 하나의 특징 벡터로 분류했을 때 높은 분류 정확도를 얻을 수 있었다. 그러나 Wu[13] 등이 제안한 분류 알고리듬을 이용하여 지방간과 간경화와 같이 간 실질의

특 징 벡 터	Amplitude 기법 : 밝기의 평균 M, 밝기의 분산 V[9,10] 히스토그램의 에너지 SN, 엔트로피 SE[3,11]
	Statistical 기법 : spatial gray level matrix[4,5,13] SE(i, j; d, θ°) gray level difference statistics[6,13] ENT auto correlation function[10] s(u, v)
	Structural 기법 : 윤곽선 밀도[4,10] range연산자의 R, robert연산자의 R 윤곽선 run 길이 행렬[4] SRE, LRE, GLN, RLN Template matching[7] template 1, template 2, template 3
	Spectrum 기법 : 2차원 DFT[7] SFL, SFH 2차원 DCT[7] SCL, SCH
	Fractal 기법 : 밝기차 평균에 의한 Hurst 계수[7] $H_{n=32} = 0.16$, $H_{n=8} = 0.08$ 밝기차 분산에 의한 Hurst 계수[7] $H_{Q=40} = -0.05$, $H_{Q=20} = -0.08$, $H_{Q=10} = -0.10$ 스케일별 표면면적의 변화 기울기[7,8] $s_1(e), s_2(e), s_3(e)$

그림 1. 거칠기의 물리적 특성을 나타내는 특징벡터들

Fig. 1. Feature vectors representing the physical characteristics of texture

변성 역학이 유사한 질환들을 분류해보면 많은 분류 오차가 발생한다. 이는 미만성 질환들은 질환의 종류나 그 진행 정도에 따라서 거칠기의 여러 가지 특성을 달리하므로 주요 분류 파라메타로 거칠기의 복잡도를 나타내는 다해상도 프랙탈 특징 벡터를 사용하기보다는 거칠기의 거친 정도나 방향성, 입자화된 정도, 균일성 등을 정량화한 거칠기 특징 벡터들을 복합적으로 사용해야 하기 때문이다.

또한 임의의 실험 영상을 Wu[13]등이 제안한 방법으로 분류해 보면 동일한 영상에 대해서도 사용한 다해상도 프랙탈 특징 벡터의 종류에 따라서 서로 다른 질환으로 분류를 하는 경우가 발생하는데 이는 실험 영상이 갖는 비정상성(non-stationarity) 임의성(randomness)에서 기인한 것으로 분류기 설계시에 이러한 성질에 대한 고려가 요구된다.

따라서 본 논문에서는 이와 같은 문제점을 극복하기 위하여 정상간과 지방간, 간경화의 분류에 최소의 분류 오차를 갖는 분류 파라메타인 다중 거칠기 벡터를 구성하는 방법과 영상의 비정상성과 임의성을 고려하여 여러 개의 다중 거칠기 벡터들에 의한 분류 결과를 종합하여 최종 분류를 내리는 통계적 분류기를 제안하고자 한다.

다중 거칠기 벡터들은 질환 사이의 분리 정도가 우수한 특징 벡터들로 구성되는데 이러한 특징 벡터들의 선택은 질환 실험 모집단의 영상들에서 기존에 발표된 특징 벡터들을 모두 구한 뒤 각 특징 벡터의 질환 분리 정도(separability)를 Bhattacharyya distance와 Hotelling Trace Criterion으로 정량화하여 분리 정도가 큰 특징 벡터들로 구성하였다.

통계적 분류기는 영상의 임의성과 비정상성을 고려하여

임의 영상에서 질환 분리 정도가 우수한 것으로 판명된 세개의 다중 거칠기 벡터를 검출한 뒤 각 다중 거칠기 벡터를 Bayes 분류기로 진단을 한다. 그런 다음 각 다중 거칠기 벡터의 진단이 정상간, 지방간, 간경화 질환에서 왔을 사후 확률(*a posteriori probability*)들을 계산하여 영상이 정상간, 지방간, 간경화일 평균 사후 확률을 구함으로서 영상의 질환을 최종 분류하는 분류기이다.

특징 벡터의 종류

초음파 영상의 주요 거칠기 특성인 밝기, 거친 정도, 균일성, 방향성, 입자화 정도, 복잡도 등을 검출하는데 사용하는 특징 벡터들은 그림 1과 같다.

그림 1과 같은 각 특징 벡터들은 초음파 간 영상의 거친 정도나 거칠기 입자의 방향성, 균일성, 입자화된 정도, 복잡도 등과 같은 물리적 특성을 정량화한 값들로서 거칠기를 이용한 초음파 간 질환의 분류에 관한 연구들은 주로 이러한 특징 벡터 값의 크기와 분포를 이용하여 간 질환을 분류한다.

벡터의 클래스 분리 정도 평가 방법

각 질환의 실험 모집단의 영상에서 구한 특징 벡터나 다중 거칠기 벡터는 정규 가우시안 분포를 나타낸다[13]. 본 논문에서는 각 특징 벡터나 다중 거칠기 벡터에 대해 다음과 같은 두 방법으로 질환사이의 분리 성능이 우수한 특징 벡터나 다중 거칠기 벡터를 선정하였다.

1. Bhattacharyya distance

두 질환 클래스 w_1, w_2 에서 확률 변수 벡터 X 의 조건 확률 밀도 함수 $p(X | w_1), p(X | w_2)$ 가 각각 정규 가우시안이고 평균 벡터가 M_i 이고 분산 행렬이 C_i 인 $N_x(M_i, C_i)$, 평균 벡터가 M_2 이고 분산 행렬이 C_2 인 $N_x(M_2, C_2)$ 라고 하면 Bayes total error bound $e_u(s)$ 는 Chernoff error bound $\mu(s)$ 로 아래와 같은 관계식을 갖는다[14].

$$e_u(s) = \int p(X | w_1)^s p(X | w_2)^{1-s} dx = e^{-\mu(s)} \quad 0 \leq s \leq 1 \quad (1)$$

여기서,

$$\begin{aligned} \mu(s) &= \frac{s(1-s)}{2} (M_2 - M_1)^T [sC_1 + (1-s)C_2]^{-1} (M_2 - M_1) \\ &+ \frac{1}{2} \ln \frac{|sC_1 + (1-s)C_2|}{|C_1|^s |C_2|^{1-s}} \end{aligned} \quad (2)$$

식 (1)에서 볼 수 있듯이 질환 클래스 w_1, w_2 사이의 $\mu(s)$ 가 클수록 Bayes total error bound는 감소하므로 $\mu(s)$ 의 값이 큰 확률 변수일수록 분리정도가 우수한 벡터라 할 수 있다.

정규 가우시안일 경우 $s = \frac{1}{2}$ 일때 $\mu(s)$ 가 최대가 되고 이를 식 (1)에 대입하면 아래와 같다[6].

$$\int \sqrt{p(X | w_1)p(X | w_2)} dx = e^{-\mu(\frac{1}{2})} \quad (3)$$

이때,

$$\begin{aligned} \mu(1/2) &= \frac{1}{8} (M_2 - M_1)^T \left[\frac{C_1 + C_2}{2} \right]^{-1} (M_2 - M_1) \\ &+ \frac{1}{2} \ln \frac{\left| \frac{C_1 + C_2}{2} \right|}{|C_1| |C_2|} \end{aligned} \quad (4)$$

$\mu(1/2)$ 를 Bhattacharyya distance(B-distance)라고 부르고 정규 가우시안인 w_1, w_2 클래스의 분리 정도를 평가하는데 유용한 척도로 사용한다. 본 논문에서는 정상간, 지방간, 간경화 질환을 분류하므로 정상간과 지방간 실험 모집단의 확률 변수 벡터 X 에 대한 B-distance, 지방간과 간경화 실험 모집단의 확률 변수 벡터 X 에 대한 B-distance 그리고 간경화와 정상간 실험 모집단의 확률 변수 벡터 X 에 대한 B-distance를 구하여 확률 변수 벡터 X 의 질환 분리 정도를 평가하였다.

2. Hotelling Trace Criterion

Hotelling Trace Criterion(HTC)은 질환 클래스들의 전체적인 분리 정도를 평가하는 방법이다. 임의 확률 변

수 벡터 X 의 각 질환 클래스의 평균 벡터와 분산 행렬이 아래와 같다면 HTC는 식(5)와 같은 스칼라 양 J 로 된다[13].

$$J = \text{trace}(S_w^{-1} S_b) \quad (5)$$

여기서

$$\begin{aligned} S_w &= \sum_{i=1}^m P(w_i) C_i, \\ S_b &= \sum_{i=1}^m P(w_i) (M_i - M_0) (M_i - M_0)^T \end{aligned} \quad (6)$$

$P(w_i)$: i번째 질환 클래스 w_i 의 a priori probability
 C_i : i번째 질환 클래스 w_i 에서의 확률 변수 벡터 X 의 분산 행렬
 M_i : i번째 질환 클래스 w_i 에서의 확률 변수 벡터 X 의 평균 벡터
 M_0 : 전체 질환 클래스에서의 확률 변수 벡터 X 의 평균 벡터, $\sum_{i=1}^m (Pw_i) M_i$

m : 전체 질환 클래스의 개수 = 3

식 (6)에서 볼 수 있듯이 S_b 는 각 질환 클래스간 평균 벡터의 차이에 의존하고 S_w 는 전체 질환 클래스의 분산 행렬에 의존하므로, 확률 변수 벡터 X 에 대한 질환 클래스 사이의 분리 정도 J 는 각 질환 클래스의 확률 변수 벡터 X 들이 평균 벡터를 중심으로 모여 있을수록 그리고 각 질환 클래스의 확률 변수 벡터 X 들의 평균 벡터와 전체 확률 변수 벡터 X 들의 평균 벡터사이의 차가 클수록 J 값은 크게된다. 따라서 J 의 값이 큰 벡터일수록 클래스 사이의 분리 정도가 양호하다고 할 수 있다.

다중 거칠기 벡터 구성

그림 1의 각 특징 벡터들은 초음파 영상의 한가지 거칠기 특성(거친 정도, 방향성, 균일성, 입자화 정도, 거칠기 입자의 형태, 복잡성)만을 정량화한 것이므로 분류에 사용한 특징 벡터가 나타내는 거칠기의 물리적 특성 차이가 큰 질환 클래스 사이의 분류에는 적합하나 사용된 특징 벡터의 질환 클래스 사이의 분리 정도가 불량한 경우에는 많은 분류 오차를 발생시킨다. 이러한 분류 오차를 감소시키기 위해서는 분류하고자하는 질환의 초음파 영상들이 일반적으로 거칠기 특성에 대한 검출이 선행되어야 하며 이렇게 검출된 주요 거칠기 특성을 보다 정확하게 정량화 하는 특징 벡터를 선택하여 분류 파라메타로 사용해야 한다.

일반적으로 정상간의 초음파 영상의 특성은 인접한 화

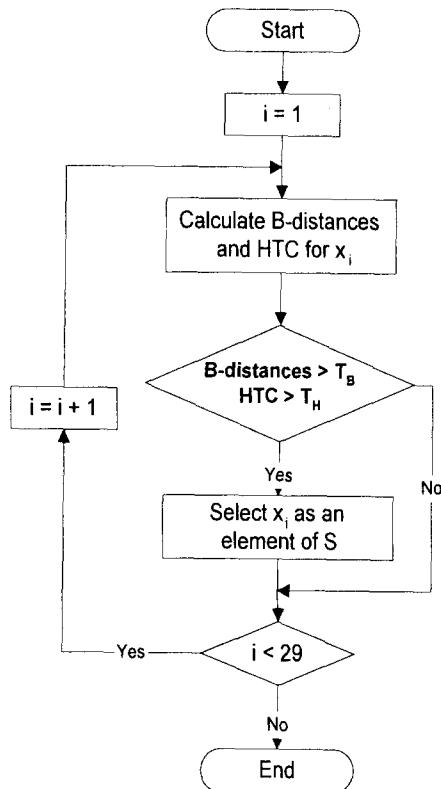
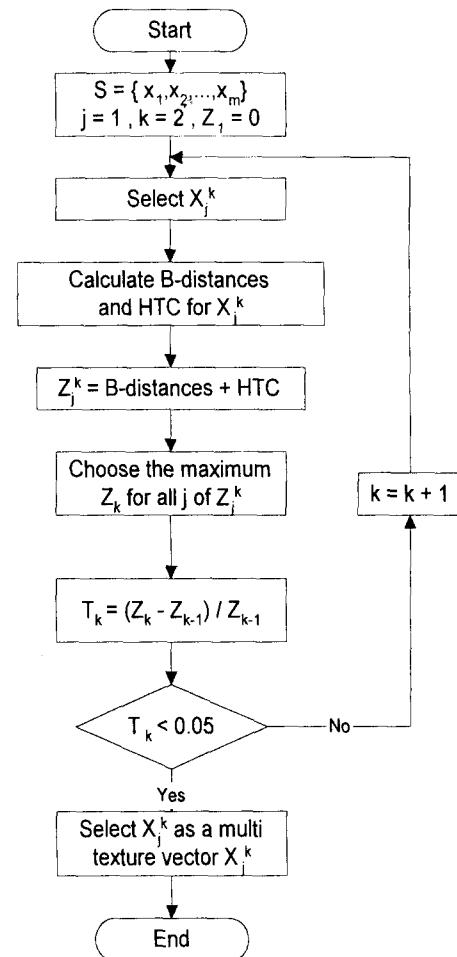


그림 2. 거칠기 벡터집합 S의 구성

Fig. 2. Construction of the texture vector set S

소간의 밝기의 차가 균일하고 영상의 거칠기가 완만하고 부드러우며 지방간과 간경화의 영상들은 실질내 지방 침윤이나 실질의 변질, 파사나 출혈 등으로 인접 화소들의 밝기의 차가 크고 불규칙하여 정상간에 비하여 거칠기가 거칠고 복잡하게 나타난다. 따라서 임의의 초음파 간 영상의 질환이 정상간인지 비정상간인지를 분류할 경우에는 거칠기의 거친 정도나 복잡도만을 정량화한 다해상도 프랙탈 특징 벡터만으로도 높은 분류 정확도를 얻을 수 있다. 그러나 이러한 거친 정도와 복잡도만을 나타내는 특징 벡터로 지방간이나 간경화와 같은 비정상 질환을 분류해 보면 낮은 분류 정확도를 나타내는데, 이는 지방간이나 간경화는 거칠기의 거친 정도와 복잡도가 유사하므로 지방간과 간경화의 분류에는 거칠기의 거친 정도나 복잡도를 나타내는 특징 벡터와 함께 거칠기의 방향성이나 입자화 정도 등을 정량화한 특징 벡터를 사용해야 하기 때문이다.

따라서 본 논문에서는 정상간과 지방간, 간경화 질환을 분류하는데 있어 분류 오차를 최소화하여 세 질환의 거칠기 특성을 모두 반영하는 다중 거칠기 벡터 X^k 를 제안하고자 한다. 다중 거칠기 벡터 X^k 의 위첨자 k는 다중 거칠기 벡터의 구성을 위해 선택된 특징 벡터의 개수이고

그림 3. 다중 거칠기 벡터 X^k 의 평가Fig. 3. Evaluation of a multi texture vector X^k

아래 첨자 j는 이러한 개수의 특징 벡터들로 구성되는 다중 거칠기 벡터의 고유 번호이다.

먼저 세 질환의 분류에 적합한 거칠기 특성을 검출하고자 그림 2와 같이 기존에 발표된 각 특징 벡터 x_i 의 질환 분리 정도를 B-distance와 HTC로 평가하였다. 그림 2에서 x_i 는 그림 1의 각 특징 벡터로서 총 29개의 특징 벡터들을 사용하였으므로 i는 1부터 29까지의 자연수이다.

정상간과 지방간, 간경화의 실험 모집단의 영상들에서 특징벡터 x_i 의 값을 모두 구한 뒤 x_i 의 질환 클래스사이 B-distance 값들과 전체 질환 클래스의 HTC 값이 일정 임계값 T_B , T_H 이상일 경우에는 질환 분리 정도가 우수한 특징 벡터로 판정하여 거칠기 벡터 집합 S의 원소로 하고 임계값 이하일 경우에는 질환 분리 정도가 불량한 특징 벡터로 판정하여 실험에서 사용하지 않는다. 이러한 과정을 특징 벡터 x_1 에서 x_{29} 까지 반복하여 질환간 분리 정도가 우수한 특징 벡터들로 구성된 거칠기 벡터 집합

S를 얻는다. 그러므로 거칠기 벡터 집합 S는 정상간, 지방간, 간경화의 분류에 비교적 적합한 거칠기의 물리적 특성을 나타내는 특징 벡터 x_i 들의 집합이다.

임의의 영상이 정상간인지 또는 지방간, 간경화인지를 알기 위해서는 거친 정도 외에 거칠기의 방향성, 입자성, 균일성 등을 함께 고려해야 하므로 분류에 사용하는 파라메타는 분리 정도가 우수한 복수개의 특징 벡터를 사용하는 것이 적합하다. 따라서 S의 부분 집합 중에서 특징 벡터의 개수가 k인 j번째 다중 거칠기 벡터를 X_j^k 를 분류 파라메타로 사용한다.

그림 3은 다중 거칠기 벡터 X_j^k 를 구하는 순서도이다. 먼저 그림 2에서 구한 S의 특징 벡터들 가운데서 개수가 k인 다중 거칠기 벡터 X_j^k 를 구성한다. 이때 j는 S에서 선택할 수 있는 총수이다. 그런 다음 X_j^k 의 HTC와 B-distance들을 구해 HTC와 B-distance들의 합인 z_j^k 를 구한다. z_j^k 는 X_j^k 의 질환 분리 정도를 나타내는 값으로서 값이 클수록 질환 분리 정도가 우수한 다중 거칠기 벡터라고 말할 수 있다.

만약 S의 특징 벡터 총 개수가 m개라면 특징 벡터들의 개수가 k인 다중 거칠기 벡터의 개수는 ${}_mC_k$ 개가 된다. 즉, X_j^k 에서의 j의 값을 ${}_mC_k$ 이고 X_j^k 의 질환 분리 정도를 나타내는 값인 z_j^k 도 ${}_mC_k$ 개가 있다. 따라서 각 X_j^k 의 질환 분리 정도 z_j^k 의 값을 구한 다음 z_j^k 의 최대값을 최대 질환 분리 정도($=Z_k$)를 구한다. 그런 다음 다중 거칠기 벡터 X_j^{k+1} 들 중에서 최대 분리 정도를 갖는 다중 거칠기 벡터의 분리 정도 값 Z_{k+1} 과 다중 거칠기 벡터 X_j^k 들 중에서 최대 분리 정도를 갖는 다중 거칠기 벡터의 분리 정도 값 Z_k 의 증가율 T_k 를 구해 최대 분리 정도의 증가율이 5% 이상이 되면 차원 $k+1$ 의 다중 거칠기 벡터 X_j^{k+1} 들에 대해 그림 3의 과정을 반복한다.

만약 다중 거칠기 벡터 X_j^{k+1} 들 중에서 분리 정도가 가장 우수한 다중 거칠기 벡터의 최대 분리 정도 값 Z_{k+1} 의 Z_k 에 대한 증가율이 5% 이하가 되면 연산 시간을 고려하여 X_j^k 들 중에서 최대 분리 정도 Z_k 를 갖는 다중 거칠기 벡터를 분류 파라메타로 선택한다.

통계적 분류기

실험 모집단의 영상들에서 분리 정도가 우수한 것으로 판명된 몇 개의 분류 파라메타들로 영상을 각각 분류해보면 사용한 분류 파라메타별로 서로 다른 진단을 내리는 경우를 관찰할 수 있는데 이는 영상의 고유 성질인 비정상성과 임의성에서 기인한 것이다.

따라서 본 논문에서는 이러한 영상의 비정상성과 임의성을 고려하여 질환 분리 정도가 우수한 세개의 다중 거칠기 벡터 X_a^k , X_b^k , X_c^k 의 분류 결과들을 종합하여 최종 진

단을 내리는 통계적 분류기를 설계하였다.

통계적 분류기는 임의의 입력 영상에서 검출된 다중 거칠기 벡터 X_a^k , X_b^k , X_c^k 의 Bayes 분류기 진단 결과 D_a , D_b , D_c 가 각 질환에서 왔을 사후 확률(*a posteriori probability*)들을 계산하고 각 사후 확률들로부터 입력 영상이 정상간, 지방간, 간경화일 평균 사후 확률을 구해 최대 평균 사후 확률 값을 갖는 질환으로 최종 진단을 내리는 분류기로서 구성은 다음과 같다.

1. Bayes 분류기

다중 거칠기 벡터 X_a^k 가 다중 가우시안 분포를 갖는다고 가정하고, 각 질환의 사전 확률 $P(w_i)$ 가 같다고 하면, X_a^k 의 w_i 질환 discriminant function $g_i(X_a^k)$ 는 식 (7)과 같이 정리된다[13].

$$g_i(X_a^k) = -\frac{1}{2}(X_a^k - M_i)^T C_i^{-1} (X_a^k - M_i) - \frac{1}{2} \log |C_i| \quad (7)$$

여기서 M_i 는 질환 w_i 의 실험 모집단 영상들에서 구한 X_a^k 의 평균 벡터이고 C_i 는 질환 w_i 의 실험 모집단 영상들에서 구한 X_a^k 의 분산 행렬이다.

Bayes 분류기는 임의의 영상에 대해 X_a^k 를 검출한 뒤 $g_1(X_a^k)$, $g_2(X_a^k)$, $g_3(X_a^k)$ 의 값을 구하여 최대값을 갖는 w_i 질환으로 진단 D_i 를 내리는 분류기이다.

$$\text{진단 } D_a = \max \{g_1(X_a^k), g_2(X_a^k), g_3(X_a^k)\}$$

다중 거칠기 벡터 X_b^k , X_c^k 에 의한 진단의 경우도 다중 거칠기 벡터 X_a^k 에 의한 진단의 경우와 마찬가지로 진단 D_b , D_c 를 내린다.

2. 각 다중 거칠기 벡터의 사후 확률의 계산

임의의 입력 영상에서 검출한 다중 거칠기 벡터 X_a^k 를 Bayes 분류기로 분류했을 때 진단이 D 라고하면 D 가 질환 w_i 에서 왔을 사후 확률 $P(w_i | D)$ 는 식 (8)과 같은 Bayes 정리를 이용하여 사전 확률(*a priori probability*) $P(w_i)$ 와 전이 확률(transition probability) $P(D | w_i)$ 로부터 구할 수 있다[14].

$$P(w_i | D) = \frac{P(w_i)P(D | w_i)}{\sum_{i=1}^3 P(w_i)P(D | w_i)} \quad (8)$$

여기서,

$P(w_i | D)$: 진단 D 가 질환 w_i 에서 왔을 사후 확률, D = 정상간, 지방간, 또는 간경화

$P(D | w_i)$: 질환 w_i 의 실험 모집단을 X_a^k 와 Bayes 분류기로 분류했을 때의 진단 D 로 분류한 확

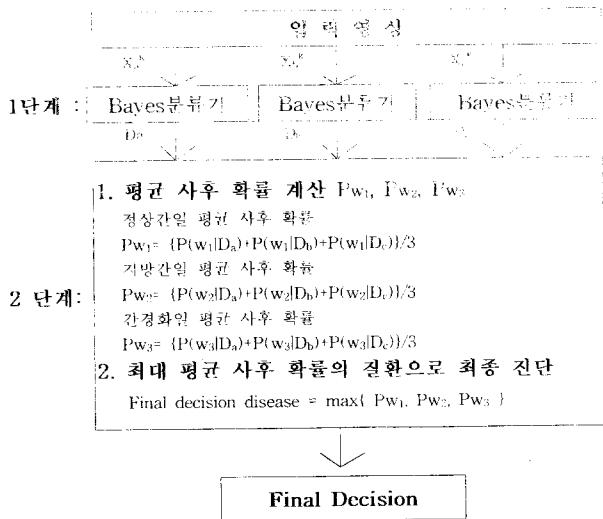


그림 4. 통계적 분류기

Fig. 4. Statistical classifier

률, 즉, 전이 확률

 $P(w_i)$: 질환 w_i 의 사전 확률 w_i : 질환 실험 모집단의 번호, w_1 = 정상간, w_2 = 지방간, w_3 = 간경화

본 논문에서는 입력 영상이 랜덤하다고 가정하여 사전 확률 $P(w_1)=P(w_2)=P(w_3)=1/3$ 으로 가정하였다. 그리고 전이 확률 $P(D|w_i)$ 는 실험 모집단 w_i 를 X_i^k 와 Bayes 분류기로 분류했을 때 D 로 분류한 영상의 개수를 백분율 (%)로 구한 값이다.

그림 4는 본 논문에서 구성한 통계적 분류기이다. 먼저 1단계에서 입력 영상으로부터 질환간의 분리 정도가 우수한 것으로 판정된 다중 거칠기 벡터 X_a^k , X_b^k , X_c^k 를 검출한 뒤 각 Bayes 분류기로 분류하여 진단 D_n , D_f , D_c 를 구한다. D_n , D_f , D_c 는 정상간, 지방간 또는 간경화 중의 한 질환이다.

그리고 2 단계에서는 식 (8)을 이용하여 입력 영상에 대한 다중 거칠기 벡터 X_a^k , X_b^k , X_c^k 의 Bayes 분류기 진단 D_n , D_f , D_c 가 정상간, 지방간, 간경화에서 왔을 사후 확률들을 구하는데 세 개의 다중 거칠기 벡터를 사용했고 분류하고자 하는 질환의 개수가 세 가지이므로 총 9개의 사후 확률들이 구해진다. 각 사후 확률 값은 각 거칠기 벡

표 1. 분류 성능이 우수한 특징 벡터들

Table 1. Feature vectors having good classification performance

S의 원소들, 질환 분리 정도가 우수한 특징 벡터

M, V, S_f, SE(i,j;645°), ENT, Template 1, Template 2, Tempate 3, SRE, LRE, S_n,GLN, s_i(e), S_{FB}, Robert 연산자, Range 연산자, H_{Q=-40}, H_{Q=-10}, H_{n=16}

터에 대한 분류 결과 D 가 세 가지 질환에서 왔을 확률 값을 나타내므로 입력 영상이 각 질환의 평균 확률 Pw_1 , Pw_2 , Pw_3 를 구해 최대 값을 갖는 질환 w_i 로 입력 영상을 최종 진단한다.

실험 및 고찰

1. 실험 데이터 획득 및 실험 집단 구성

본 논문에서 사용한 초음파 간 영상은 현재 임상의 진단 방사선과에서 운용 중인 초음파 B 모드 장비로부터 획득했다. 실험에 사용한 초음파 탐침자 주사방식은 환자에 따라 sagittal, subcostal, transverse 방식을 사용하였으며 성별이나 연령에 관계없이 질환에 따라 전문의가 육안으로 진단을 내린 질환별 영상을 동일한 기기에서 동일한 이득(2 db)으로 비디오 테이프에 녹화한 뒤 PC의 프레임 그레이버를 이용하여 디지털화된 그레이 영상을 640 × 480, 128 그레이 레벨로 획득했다. 획득된 총 영상의 수는 정상간 50장, 지방간 50장, 간경화 50장씩 총 150장이다.

이렇게 획득된 질환별 영상으로부터 진단에 근거가 될 수 있는 깊이 5-10cm의 간 실질 부위를 32 × 32 크기, 128 그레이 레벨로 샘플링 하여 실험 데이터로 사용하였는데 영상 1개당 중복되지 않게 3개의 실험 영상을 추출하였다. 이렇게 추출된 질환별 150개의 표본 영상 중에서 100개는 특징 벡터의 질환 분리 정도를 측정하고 분류에 최적인 다중 거칠기 벡터를 검출하는 실험 모집단으로 구성하였으며 나머지 50개는 실험 집단으로 구성하여 실험 모집단에서 구한 최적의 다중 거칠기 벡터와 통계적 분류기의 분류 성능을 평가하는데 사용하였다.

2. 특징 벡터의 질환 분리 정도 평가

그림 2의 알고리듬으로 각 특징 벡터 x_i 들의 B-distance와 HTC를 계산해 본 결과 B-distance와 HTC 값이 $T_B=0.3$, $T_H=0.6$ 이상으로 거칠기 벡터 S를 구성하는 특징 벡터는 표 1과 같다.

3. 다중 거칠기 벡터 구성 및 분류 결과

표 1과 같은 거칠기 벡터 집합 S에 대해 그림 3의 알고리듬을 이용하여 질환사이의 분리 정도가 가장 우수한

표 2. 질환 분리 정도가 우수한 3차원 거칠기 벡터

Table 2. 3 dimension texture vectors having a good separability

다중 거칠기 벡터	x_i	x_m	x_n	질환 분리 정도 Z_i^3	HTC	B-distance		
						정상간 ↓ 지방간	지방간 ↓ 간경화	간경화 ↓ 정상간
X_{566}^3	S_E	$H_{\alpha=-10}$	$SE(i,j;6,45^\circ)$	11.087954	3.870515	2.943864	2.298962	1.974613
X_{122}^3	Robert	$H_{n=16}$	$SE(i,j;6,45^\circ)$	8.807736	4.042292	1.154221	1.684379	1.926844
X_{325}^3	GLN	LRE	ENT	8.144211	3.250005	1.860115	1.663437	1.400654

표 3. 분리정도가 우수한 하나의 특징 벡터로 실험 모집단을 분류한 결과

Table 3. Classification results using a single feature vector for each training set(단위:%)

구 분	분류 방법	실험 모집단								
		정상간			지방간			간경화		
		N	F	C	N	F	C	N	F	C
하나의 특징 벡터를 사용한 분류	S_E + Bayes 분류기	83	17	0	18	60	22	2	18	80
	$H_{\alpha=-10}$ + Bayes 분류기	87	05	13	26	32	42	33	15	52
	$SE(i,j;6,45^\circ)$ + Bayes 분류기	85	15	0	20	68	12	3	10	87
	Robert + Bayes 분류기	82	18	0	14	67	19	6	36	58
	$H_{n=16}$ + Bayes 분류기	80	10	10	17	57	26	9	5	86
	GLN + Bayes 분류기	59	17	24	22	28	50	11	8	81
	LRE + Bayes 분류기	50	15	35	4	80	16	50	17	33
	ENT + Bayes 분류기	82	18	0	17	69	14	2	13	85

표 4. 본 논문에서 제안한 방법으로 실험 모집단을 분류한 결과

Table 4. Classification results using the proposed method for each training set(단위:%)

구 분	분류 방법	실험 모집단								
		정상간			지방간			간경화		
		N	F	C	N	F	C	N	F	C
본 논문에서 제안한 방법	X_{566}^3 + Bayes 분류기	93	6	1	7	93	0	3	6	91
	X_{122}^3 + Bayes 분류기	92	7	1	4	95	1	2	4	94
	X_{325}^3 + Bayes 분류기	91	8	1	7	91	2	3	2	95
	$X_{566}^3, X_{122}^3, X_{325}^3$ +	94	6	0	5	94	1	3	5	92
	통계적 분류기									

다중 거칠기 벡터 X_i^3 를 검출해본 결과 2차원 거칠기 벡터들에서보다 3차원 다중 거칠기 벡터들에서 큰 질환 분리 정도를 얻을 수 있었다.

실험 결과, 3차원 다중 거칠기 벡터들 중에서 최대 질환 분리 정도 Z_i^3 값은 11.087954였으나 4차원 다중 거칠기 벡터들중 최대 질환 분리 정도 Z_4 의 값은 11.612123으로 최대 분리 정도 값의 증가율을 나타내는 T_4 의 값이 4.5%가 되어 4차원 다중 거칠기 벡터들과 3차원 다중 거칠기 벡터들과의 질환 분리 정도 차이가 거의 없음을 알 수 있었다. 그러므로 분류에 소요되는 연산 시간을 고

려하여 3차원 다중 거칠기 벡터들 중에서 질환 분류 정도가 가장 우수한 $X_{566}^3, X_{122}^3, X_{325}^3$ 를 분류 파라메타로 선택하였다. 969개의 3차원 다중 거칠기 벡터 X_i^3 중에서 질환 분리 정도 Z_i^3 이 가장 큰 세개의 3차원 다중 거칠기 벡터들은 표 2와 같다.

표 2에서 특징 벡터 $H_{\alpha=-10}, H_{n=10}$ 은 영상의 복잡도를 정량화 하는 특징 벡터이고 $SE(i, j; 6, 45^\circ)$ 는 영상의 거칠기 방향성을 나타내는 특징 벡터이다. 또한 GLN은 영상의 거친 정도를 나타내는 특징 벡터이다.

표 3은 각 질환의 실험 모집단 영상들을 표 1의 분리

표 5. Wu[13]가 제안한 방법으로 실험 집단을 분류한 결과

Table 5. Classification results using the Wu[13] method for each test set(단위 : %)

구 분	분 류 방 법	실험 집단								
		정상간			지방간			간경화		
		N	F	C	N	F	C	N	F	C
Wu(13) 방법	다해상도 프랙탈 특징벡터 파워 스펙트럼 + Bayes 분류기	86	4	10	6	78	16	6	12	82

표 6. 본 논문에서 제안한 방법으로 실험 집단을 분류한 결과

Table 6. Classification results using the proposed method for the test set(단위 : %)

구 분	분 류 방 법	실험 집단								
		정상간			지방간			간경화		
		N	F	C	N	F	C	N	F	C
본 논문에 시 제안한 방법	$X_{566}^3 +$ 통계적 분류기	92	6	2	10	84	6	4	10	86
	$X_{122}^3 +$ 통계적 분류기	82	10	8	8	80	12	6	8	86
	$X_{325}^3 +$ 통계적 분류기	90	6	4	8	78	14	6	8	86
	$X_{566}^3, X_{122}^3, X_{325}^3 +$ 통계적 분류기	94	6	0	8	84	8	6	8	86

정도가 우수한 각 특징 벡터들로 분류한 결과이다.

표 3에서 볼 수 있듯이 각 특징 벡터가 나타내는 거칠기의 물리적 특성에 따라 한 종류의 질환 분류에는 80% 정도의 비교적 높은 분류 정확도를 얻을 수 있었으나 세 질환에 공통적으로 높은 분류 정확도를 나타내는 특징 벡터는 구할 수 없었다.

표 4는 그림 3과 같은 과정을 거쳐 구한 각 3차원 다중 거칠기 벡터 $X_{566}^3, X_{122}^3, X_{325}^3$ 를 Bayes 분류기로 분류한 결과이다. 질환 분류 정도가 우수한 2차원의 거칠기 벡터 $X_{23}^3, X_{32}^3, X_{11}^3$ 를 사용하여 분류한 결과보다 정상간, 지방간, 간경화 실험 모집단 모두 향상된 분류 정확도를 얻을 수 있었으며 세 질환 모두 90%를 상회하는 분류 정확도를 얻을 수 있었다.

이는 3차원 다중 거칠기 벡터의 경우 거친 정도와 거칠기 표면의 복잡도 외에 거칠기의 방향성을 정량화한 특징 벡터를 분류에 함께 사용하므로 하나의 특징 벡터만을 사용한 경우에 비하여 거칠기의 특성이 유사한 지방간과 간경화의 분류에서 보다 적은 오차를 발생시켰기 때문이다.

또한 하나의 영상에서 3차원 다중 거칠기 벡터 $X_{566}^3, X_{122}^3, X_{325}^3$ 를 검출하여 통계적 분류기로 분류한 정확도가 하나의 3차원 다중 거칠기 벡터를 Bayes 분류기로 분류한 정확도보다 높음을 알 수 있는데 이는 영상의 임의성과 비정상 성을 고려하여 동일한 영상에서 검출된 3개의 3차원 다중 거칠기 벡터들의 분류 결과를 종합하여 최종 분류를 내렸기 때문이다.

표 5는 Wu[13] 등이 제안한 분류 파라메타인 다해상도 프랙탈 특징 벡터와 퓨리에 파워 스펙트럼을 실험 집단의 영상들에서 검출하여 분류한 결과이다. 하나의 특징 벡터로 만으로 분류한 결과보다는 높은 분류 정확도를 얻을 수 있었다.

그러나 지방간 실험 모집단의 경우는 정상간이나 간경화 실험 모집단에 비하여 낮은 정확도를 나타냈는데 이는 분류 파라메타로 사용한 프랙탈 차원과 퓨리에 파워 스펙트럼 특징 벡터들은 영상의 거친 정도만을 정량화한 특징 벡터이므로 거친 정도가 유사한 간경화 질환과의 분류에 많은 오차를 발생시켰기 때문이다. 또한 분류하고자 하는 영상에서 파워 스펙트럼을 구하고 그 영상을 3가지 해상도로 샘플링하여 3개의 프랙탈 차원들을 구하여 분류에 사용하므로 3차원 다중 거칠기 벡터에 비해 분류에 많은 시간이 소요되는 단점이 있었다.

표 6은 50개씩의 각 질환 실험 집단 영상들을 본 논문에서 제안한 방법으로 분류한 분류 결과이다. 정상간의 경우 통계적 분류기를 사용한 경우 94%의 높은 분류 정확도를 얻을 수 있었다.

결 론

초음파 간 영상의 진단은 간 실질 및 표면의 변성 상태, 간의 형태 변형과 관상 구조물의 상태 등을 육안으로 관찰함으로서 이루어지는데 이중 간 실질의 변성에 따른 초음파 반향의 세기와 분포 변화는 초음파 영상의 거칠기

를 특징 지우므로 이러한 거칠기 특성은 초음파 간 영상의 질환 분류에 널리 이용되어 왔다. 이러한 초음파 간 영상의 거칠기는 외부 변수나 관찰자의 주관에 따라 크게 달라지므로 이를 객관화하기 위해 거칠기의 특성(거친 정도, 방향성, 균일성, 입자화 정도)을 정량화 하는 여러 가지 특징 벡터들이 발표되어 왔다. 그러나 이러한 특징 벡터는 그 종류에 따라 질환 분류 성능이 상이하고 동일한 영상에 대해서도 사용한 특징 벡터에 따라 서로 다른 진단을 나타내는 문제점이 있다.

본 논문에서는 정상간, 지방간, 간경화의 질환을 분류하는데 있어서 최소의 분류 오차를 갖는 분류 파라메타로 복수 개의 특징 벡터로 구성되는 다중 거칠기 벡터를 제안했다.

다중 거칠기 벡터는 질환 분리 정도가 큰 특징 벡터들로 구성되고 복수 개의 거칠기 특성을 정량화한 분류 파라메타이므로 이를 이용하여 지방간과 간경화와 같은 미만성 질환을 분류해본 결과, 하나의 특징 벡터만으로 분류했을 때보다 약 10~15% 정도의 분류 정확도 상승을 얻을 수 있었다.

또한 본 논문에서는 영상 고유의 성질인 비정상성과 임의성을 고려하고 분류에 대한 신뢰도를 향상시키기 위하여 질환 분리 정도가 우수한 세 개의 다중 거칠기 벡터들을 입력으로 하는 통계적 분류기를 제안했다. 통계적 분류기는 입력 영상에서 세개의 다중 거칠기 벡터들을 검출한 뒤 각 다중 거칠기 벡터를 Bayes 분류기로 진단한다. 그런 다음 각 진단 결과가 각 질환에서 왔을 사후 확률들을 계산하고 입력 영상이 정상간, 지방간, 간경화일 평균 사후 확률을 구해 그 크기에 따라 입력 영상을 최종 진단하는 분류기이다.

각 질환의 실험 모집단과 실험 집단의 영상들을 본 논문에서 제안한 다중 거칠기 벡터와 통계적 분류기로 분류해 본 결과, 한 종류의 특징 벡터를 사용하는 기존의 방법들에 비해 높은 분류 정확도를 얻을 수 있었으며 Wu [13] 등이 제안한 방법과 비교하여 정상간 집단은 약 8%, 지방간 집단은 약 6% 그리고 간경화 집단은 약 4%의 분류 정확도 향상을 얻을 수 있었다.

참 고 문 헌

- Francis S. Weill, "Ultrasound Diagnosis of Digestive Diseases", 3th, Springer-Verlag, 1989

- Robert A. Wilkins & Heather B. Nunnerley, "Imaging of the Liver, Pancreas and Spleen", Blackwell Scientific Publications, Oxford London, 1990
- Robert M., Haralick, "Textural Features for Image Classification", IEEE Trans. SMC , VOL smc-3 , NO. 6, NOVEMBER 1973
- Robert M., Haralick, "Statistical and Structural Approaches to Texture", Proceedings of the IEEE, VOL 67, NO. 5, MAY 1979
- 홍정우, 김선일, 이두구, "통계적 특성과 신경망을 이용한 초음파 화상진단", 대한생체공학회 1992년 추계 학술대회 논문집 제 14 권 제 2 호, pp 26-29, 1992
- 이동혁, 이용우, 송인찬, 김희찬, 민병구, "초음파 영상의 거칠기 변수를 이용한 간질환 분류", 대한생체 공학회 1994년 추계학술대회 논문집 제 16권 제 2 호, pp 52-57, 1994
- 정정원, 김동윤, "초음파 간 영상의 특징벡터 분류 및 진단 시스템 개발에 관한 연구", 대한 생체공학회 1995년 추계학술대회 논문집 제 17권 제 2 호, pp 177-182, 1995
- Shamuel Peleg, "Multi Resolution Texture Analysis and Classification", IEEE Trans. PAMI, Vol. PAMI-6, No 4, JULY 1984.
- A. K. Jain, "Fundamentals of Digital Image Processing, Englewood Cliffs", NY;Prentice-Hall. Inc, 1989.
- William K. Pratt, "Digital Image Processing", 2nd, Wiley Interscience, 1991
- Rafael C. Gonzalez, Richard E. Woods, "Digital Image Processing", Addison Wesley, 1992
- C.C. Chen, J.S. Daponte, and M.D. Fox, "Fractal feature analysis and classification in medical imaging", IEEE Trans. Med. Imaging, vol. 8, pp. 133-142, 1989.
- Chung-Ming Wu, Yung-Chang Chen, "Texture Feature for Ultrasonic Liver Images", IEEE Trans. Med. Imaging, vol. 11, NO 2, pp. 141-152, 1992.
- Keinosuke Fukunaga, "Introduction to Statistical Pattern Recognition", 2nd, Academic Press, 1990