

초음파 B-모드 영상에서 FCN(fully convolutional network) 모델을 이용한 간 섬유화 단계 분류 알고리즘

강성호^{1†} · 유선경^{2‡} · 이정은^{2*} · 안치영^{1*}

¹국가수리과학연구소 의료수학연구부, ²충남대학교 의과대학 영상의학과

A Fully Convolutional Network Model for Classifying Liver Fibrosis Stages from Ultrasound B-mode Images

Sung Ho Kang^{1†}, Sun Kyoung You^{2‡}, Jeong Eun Lee^{2*} and Chi Young Ahn^{1*}

¹National Institute for Mathematical Sciences, Daejeon 34047, Republic of Korea

²Department of Radiology, Chungnam National University College of Medicine, Daejeon 35015, Republic of Korea

(Manuscript received 28 November 2019 ; revised 14 January 2020 ; accepted 18 February 2020)

Abstract: In this paper, we deal with a liver fibrosis classification problem using ultrasound B-mode images. Commonly representative methods for classifying the stages of liver fibrosis include liver biopsy and diagnosis based on ultrasound images. The overall liver shape and the smoothness and roughness of speckle pattern represented in ultrasound images are used for determining the fibrosis stages. Although the ultrasound image based classification is used frequently as an alternative or complementary method of the invasive biopsy, it also has the limitations that liver fibrosis stage decision depends on the image quality and the doctor's experience. With the rapid development of deep learning algorithms, several studies using deep learning methods have been carried out for automated liver fibrosis classification and showed superior performance of high accuracy. The performance of those deep learning methods depends closely on the amount of datasets. We propose an enhanced U-net architecture to maximize the classification accuracy with limited small amount of image datasets. U-net is well known as a neural network for fast and precise segmentation of medical images. We design it newly for the purpose of classifying liver fibrosis stages. In order to assess the performance of the proposed architecture, numerical experiments are conducted on a total of 118 ultrasound B-mode images acquired from 78 patients with liver fibrosis symptoms of F0~F4 stages. The experimental results support that the performance of the proposed architecture is much better compared to the transfer learning using the pre-trained model of VGGNet.

Key words: Liver fibrosis, Classification, Deep learning, Transfer learning, Fully convolutional network model

1. 서 론

바이러스 감염이나 알코올 등에 의해 간이 손상을 받게 되면 간 섬유화가 진행된다[1]. 이러한 간 섬유화는 적절한 시기에 진단 및 치료되지 않으면 간경변으로 진행되고 정상 간으로 회복이 어려워진다[2,3]. 또한 간경변이 심해지면 간암, 정맥류 출혈을 포함한 다양한 합병증을 유발할 수도 있다. 따라서 간 섬유화의 정도를 정확히 진단하는 것은 만성 간질환 환자의 치료 계획에 매우 중요하다[2]. 대표적인 진단 방법으로 MRI, CT 혹은 초음파를 이용한 영상검사와 혈액검사가 있으며, 이와 같은 검사를 통해 정확한 진단이 어려울 경우에 생

Corresponding Author : Chi Young Ahn
70, Yuseong-daero 1689 beon-gil, Yuseong-gu, Daejeon 34047, Republic of Korea
Tel: +82-42-717-5710
E-mail: chiyoung@nims.re.kr
Corresponding Author : Jeong Eun Lee
282 Munhwa-ro, Jung-gu, Daejeon, 35015, Republic of Korea
Tel: +82-42-280-8061
E-mail: leeje290@gmail.com

[†]Contributed equally to this work.

본 연구는 정부의 재원으로 국가수리과학연구소(NIMS)와 한국연구재단(NRF)의 지원을 받아 수행하였음(NIMS-B20900000, NRF-2017R1E1A1A03070382, NRF-2017-2341-03).

검을 통한 조직검사까지 수행하여 진단하게 된다. 하지만 생검은 침습적 시술이며 환자에게 통증과 불편함을 주기 때문에 생검을 시행하지 않고 정확하게 진단하는 방법이 지속적으로 요구되고 있다.

생검률 감소의 필요를 충족시키면서 일반적인 영상검사를 통해 진단이 어려운 한계를 극복하기 위한 영상기법으로 탄성영상 기술이 개발되었으며[4-7] 최근 도시바의 초음파 기술인 횡파탄성영상이 건강보험심사평가원으로부터 간 섬유증 진단 및 유방 병변 진단의 안전성과 유효성 평가에 대한 심의를 통과하여 신의료기술로 등재되었다[8]. 횡파탄성영상은 조직별 탄성도에 따라 횡파의 진행 속도가 다르게 변화한다는 사실을 이용하여 탄성도를 정량화하는 영상기법으로, 초음파 프로브를 이용하여 인체 내에 푸시 펄스(push pulse)를 인가하고, 유도된 음향 방사력(acoustic radiation force)에 의한 횡파가 인체 내 조직 병변을 지날 때의 속도 변화를 측정하여 탄성 계수를 나타낸다[6,7]. 횡파의 진행 속도(c)와 횡파의 탄성계수(μ)는 식 (1)과 같은 관계를 갖는다.

$$c = \sqrt{\frac{\mu}{\rho}} \quad (\text{여기서 } \rho \text{는 연조직의 밀도}) \quad (1)$$

푸시 펄스에 의해 유도된 음향 방사력을 f , 음향 방사력에 의해 매질의 움직인 변위를 w 라고 하면, 횡파의 탄성계수 μ 는 식 (2)를 만족하게 되고, 식 (3)에 의해 음향방사력의 생성 지점 이외의 매질에서 횡파의 속도를 계산할 수 있다.

$$\rho \frac{\partial w}{\partial t} = \mu \nabla^2 w + f \quad (2)$$

$$\frac{\mu}{\rho} = \frac{\partial w}{\nabla^2 w} \quad (3)$$

한편, 계산 능력의 향상과 함께 인공지능에 대한 관심이 높아지면서 진단 보조 방법으로서의 딥 러닝 응용 연구가 급증하고 있다. 최근 딥 러닝을 이용한 간 섬유증 진단 방법에 대한 연구가 소개되었는데, 탄성영상이 아닌 초음파 B-모드에 딥 러닝을 적용한 분류 방법을 제안하였다[9]. 이 연구에서는 영상 분류 CNN 모델로 잘 알려진 VGGNet의 사전 학습된 모델을 재사용하기 위해 전이학습(TL, transfer learning)을 이용하였고, 분류 성능을 향상시키기 위해 VGGNet의 마지막 분류 단계에서 FC(fully connected) 레이어를 추가하였다. 279장의 초음파 B-모드 영상에서 섬유화 단계에 따라 다르게 표현되는 간 조직의 특성을 세계의 카테고리(F0, F1~F3, F4)로 분류하였고, 데이터 보강(data augmentation)에 의해 생성된 1674장의 70%를 간 섬유화 단계 분류를 위해 학습시켰다. 또한 간 섬유화 분류와 유사한 연구로서 CT영상에서 간암 병변 분류를 위한 딥 러닝

연구결과가 발표되었는데[10], VGGNet와 AlexNet의 사전 학습된 모델을 재사용하는 전이학습 방법을 이용하였고, 간에 양성종양과 악성종양이 포함된 3,024장의 CT영상 중 대략 67%의 영상을 학습시킨 후 양성종양과 악성종양을 분류하도록 하였다.

일반적으로 딥 러닝 기반의 분류 방법의 성능은 많은 양의 영상 데이터를 이용하여 학습을 하여야 높은 정확도의 우수한 성능을 갖게 된다. 본 연구에서는 초음파 B-모드 영상을 사용하여 간 섬유화 단계를 분류하기 위한 딥 러닝 방법을 제안하되, 제한된 양의 비교적 적은 영상 데이터를 가지고 학습하여도 분류 정확도를 최대화하는 신경망 모델을 제안하였다. 제안된 신경망 모델은 U-net 구조를 기반으로 하며, 초음파 B-모드 영상에서 간의 전체적인 모양과 스펙클 패턴을 반영하는 정확한 분할을 통해 분류 성능을 향상 시키도록 설계되었다. 제안된 모델의 성능을 평가하기 위해, 비교적 적은 수의 영상 데이터 셋을 이용하여 VGGNet의 사전 학습된 모델을 재사용하는 전이학습 방법에 의해 얻어진 결과와 비교 및 분석하고자 하였다.

II. 연구 방법

1. 분류 신경망 모델

U-net은 의료영상에서 특정 객체를 빠르고 정확하게 분할(segmentation)하기 위한 신경망으로 잘 알려져 있다[11]. 제안된 분류 신경망 모델은 간 섬유증 단계를 분류하기 위해 U-net을 기반으로 설계하였고, 기존 U-net과 비교하여 외형적으로 보기에는 매우 유사해보이나 다음 세 부분에서 차이점을 갖는다.

i) 축소 과정(contracting path)의 마지막 단계에서 전체 연결 층(fully connected layer)을 추가하여 간 섬유증 단계의 분류 결과가 출력되도록 하였다. 이 모델은 분할 성능이 분류 결과에 영향을 주는 신경망 모델로 동작하는데, 분할 결과가 정확할 수록 분류 결과 역시 정확한 결과를 얻을 수 있다는 특징이 있다. 또한 Gradient-weighted Class Activation Mapping(Grad-CAM)[12]을 사용하지 않고도 분할 결과로 분류 정확도를 식별할 수 있는 장점이 있다.

ii) 훈련 오류와 훈련 시간을 줄이기 위해 가중 손실 함수가 식 (4)와 같이 분할된 최종 출력에서뿐만 아니라 식 (5), (6), (7)과 같이 이전 두 단계의 출력과 훈련 과정 중 분류 출력 단계에서 추가되었다.

$$l_{512} = -\sum_{x \in \Omega} (y_{512}(x) \log P_{512}(x) + (1 - y_{512}(x)) \log(1 - P_{512}(x))) \quad (4)$$

$$l_{256} = -\sum_{x \in \Omega} (y_{256}(x) \log P_{256}(x) + (1 - y_{256}(x)) \log(1 - P_{256}(x))) \quad (5)$$

$$l_{128} = -\sum_{x \in \Omega} (y_{128}(x) \log P_{128}(x) + (1 - y_{128}(x)) \log(1 - P_{128}(x))) \quad (6)$$

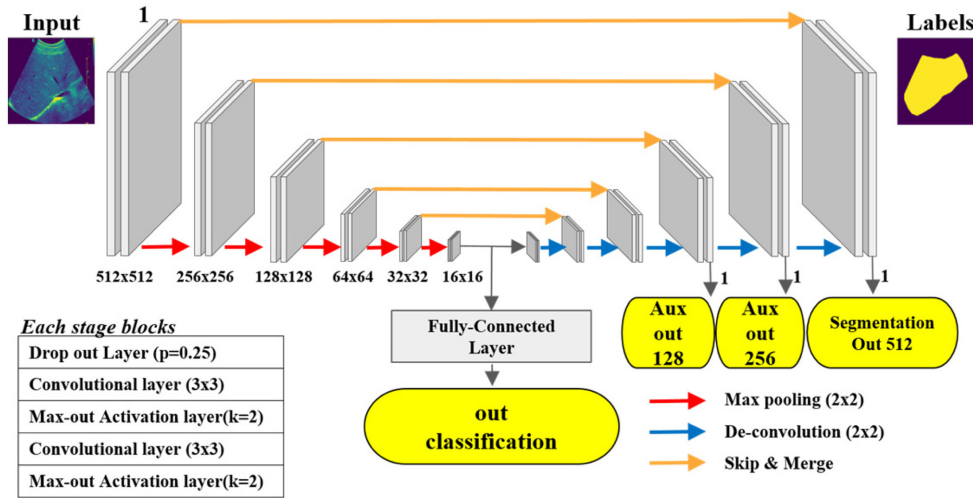


그림 1. 제안된 신경망 모델의 구조
Fig. 1. The architecture of the proposed neural network model

여기서, Ω 는 영상 전체 영역을 의미하고, l_{512} 은 최종출력 단계의 손실함수, y_{512} 는 $x \in \Omega$ 에서의 간 영역 분할 라벨값, P_{512} 는 $x \in \Omega$ 에서의 간 영역 분할 확률값을 나타낸다. 마찬가지로, l_{256} 과 l_{128} 은 최종출력 이전 두 단계의 손실함수이고, y_{256} 과 y_{128} 은 각 단계에서의 간 영역 분할 라벨값을 각각 나타내며, P_{256} 과 P_{128} 은 간 영역 분할 확률값을 나타낸다.

$$l_c = -\sum_{c \in \{C_1, C_2, C_3\}} (y_c(c) \log P_c(c) + (1 - y_c(c)) \log(1 - P_c(c))) \quad (7)$$

여기서, C_1, C_2, C_3 는 각각 분류하고자 하는 클래스들의 집합을 의미하며, l_c 는 분류 단계에서의 손실함수이고, y_c 는 간 섬유화 단계 분류 라벨값, P_c 는 간 섬유화 단계 예측 확률값을 나타낸다.

iii) 드롭 아웃(dropout) 및 최대(maxout) 층이 각 스테이지 블록에 추가되었다(그림 1). 드롭 아웃은 대략적인 모델 평균화를 위한 것이고, 최대 활성화는 드롭 아웃을 통한 최적화를 촉진하고 드롭 아웃의 빠른 근사한 모델 평균화 기법의 정확도를 향상시키기 위해 사용되었다.

2. 제안된 모델의 학습

제안된 모델의 성능을 검증하기 위해 사전에 훈련된 VGGNet 모델을 사용한 전이학습의 성능과 비교하였다. 특히 VGGNet 모델은 16개와 19개의 층으로 구성된 두가지의 모델이 있는데 이들 모두를 비교하기 위해 사용하였다. 각 모델들의 학습을 위한 데이터 셋으로는, 충남대학교병원에서 간 섬유증 증상이 있는 78명의 환자로부터 획득된 총 118장의 B-모드 초음파 영상을 이용하여 수치 실험을 수행하였다. F0부터 F4단계의 간 섬유증 증상이 있는 경우에 대해서는 생검을 통해 확인되었으며, F0, F1, F2, F3 및 F4

단계의 영상의 수는 각각 20, 20, 21, 34 및 23장이다. 이 연구에서 사용된 실험데이터는 임상시험(IRB)에 대한 사전 승인(No. CNUH 2019-10-107)을 받았으며 관련 규정을 준수하였다.

전처리 과정을 통해 간 초음파 영상에서 환자 정보를 제외한 초음파 영상 영역만을 잘라내고 512x512 픽셀의 해상도로 크기를 조정된 제안된 모델의 입력으로 사용되었다. 또한, 두 명의 임상 전문가들이 영상 라벨링 소프트웨어(Korea Copyright Commission No. C-2019-012160)를 이용하여 분류한 간 영역 라벨 영상이 제안된 모델의 학습을 위해 분류된 간 섬유증 영상과 함께 사용되었다. 이 연구에서는 제안된 모델의 분류 결과로서 3개의 클래스: Class 0 (F0/F1), Class 1 (F2/F3), Class 2 (F4)를 고려하였다. 제안된 모델은 간 섬유증 단계를 나타내는 class 값과 분할된 간 영역을 함께 출력하도록 하였다.

영상 데이터는 훈련과 테스트를 위해 90:10의 비율로 무작위로 나누었고 10-fold로 분할하여 교차 검증(cross-validation)을 수행하였다. 훈련된 이미지의 이동(shifting), 회전(rotating) 및 스케일링(scaling)과 같은 일반적인 데이터 보강이 제안된 모델을 훈련시키는데 사용되었다. 앞에서 설명한 것처럼, 손실 함수로서 이진 교차 엔트로피(binary cross entropy)가 사용되었고, 손실 함수를 최소화하기 위해 ADADELTA Optimizer[13]가 적용되었으며, 총 250 에폭(epoch)이 실행되었다.

이 연구에서 수행한 모든 수치 실험은 Intel® Core(TM) i9-7900x CPU, 128GB의 메모리 및 NVIDIA Titan Xp GPU (12GB)로 구성된 컴퓨터에서 TensorFlow(ver. 2.1.6) 기반 위에서 실행되는 Keras(ver. 1.8.0)를 이용하여 구현되었다.

III. 연구 결과

우선 VGGNet을 사용한 전이학습은 영상 데이터의 양이 매우 적기 때문에, 16개 층과 19개 층으로 이루어진 VGGNet 모델 두 경우 모두에서 40% 미만의 정확도를 보였다. 이러한 이유로, 데이터의 양을 늘리기 위해 간 전체 영상으로부터 추출된 패치 영상을 전이학습에 사용하였고, 10-fold 교차 검증을 전이학습에 적용한 결과와 제안된 신경망 모델에 의해 얻어진 결과를 표 1에 나타내었다. 전반적으로 전이학습은 평균 65% 미만의 정확도를 보인 반면, 제안된 모델은 대략 80% 이상의 정확도를 보였다.

위와 같은 정확도를 보인 것에 대해서 의미 있게 분류가 잘 된 것인지 확인하기 위해 분할 결과와 함께 비교해보았다. 분할된 간 영역과 함께 간 섬유증 단계에 대한 클래스의 예측 결과가 그림 2~4에 묘사되었다. 각 그림의 첫번째 영상은 테스트에 사용된 초음파 B-모드 영상이고, 두번째 칸의 위쪽 영상은 임상 전문가에 의해 표시된 라벨링 영상이며, 세번째 칸의 위쪽은 간 섬유화 단계를 나타내는 클래스이다. 두번째 칸과 세번째 칸의 아래쪽 영상들은 각각 제안된 분류 모델에 의해 얻어진 분할된 결과와 분류된 클래스의 확률 추정치를 나타낸다. 세 경우 모두 간 영역이 잘 분할되었고, 제안된 분류 모델에 의해 분할된 영역에서의 특

표 1. 제안된 신경망 모델에 10-fold 교차 검증을 적용한 결과

Table 1. Accuracy of the proposed neural network model with 10-fold cross-validation

k-fold (k=10)	Transfer Learning		Proposed model
	VGG16	VGG19	
	Overall Acc. (%)	Overall Acc. (%)	Overall Acc. (%)
1 fold	65	65	83
2 fold	65	60	83
3 fold	68	68	67
4 fold	55	55	75
5 fold	65	64	75
6 fold	61	59	92
7 fold	46	45	75
8 fold	52	60	92
9 fold	75	64	75
10 fold	86	85	92
Average	64	63	81

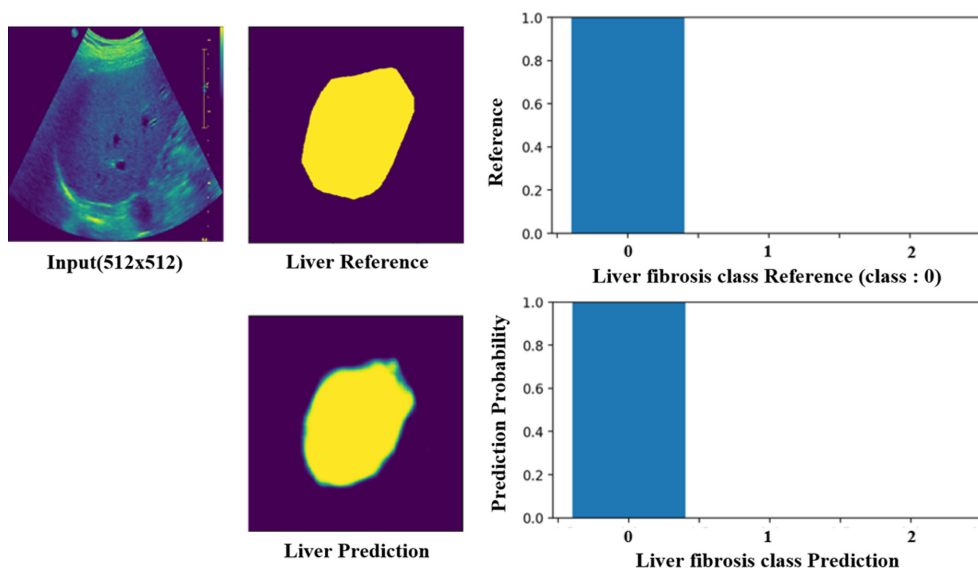


그림 2. 제안된 신경망 모델에 의해 분류된 Class 0 (F0/F1) 에 대한 결과

Fig. 2. The result classified by the proposed neural network model for Class 0 (F0/F1)

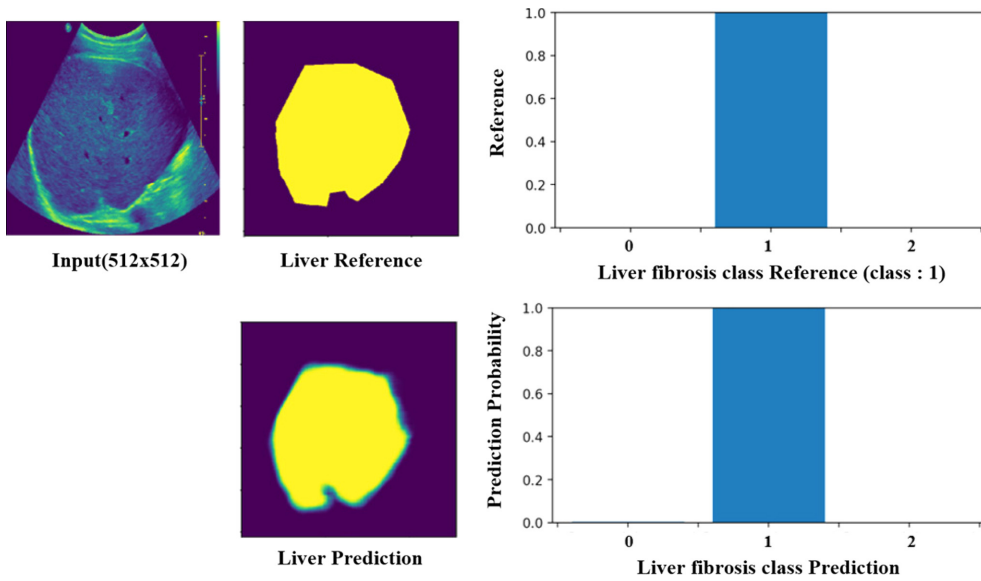


그림 3. 제안된 신경망 모델에 의해 분류된 Class 1 (F2/F3) 에 대한 결과
 Fig. 3. The result classified by the proposed neural network model for Class 1 (F2/F3)

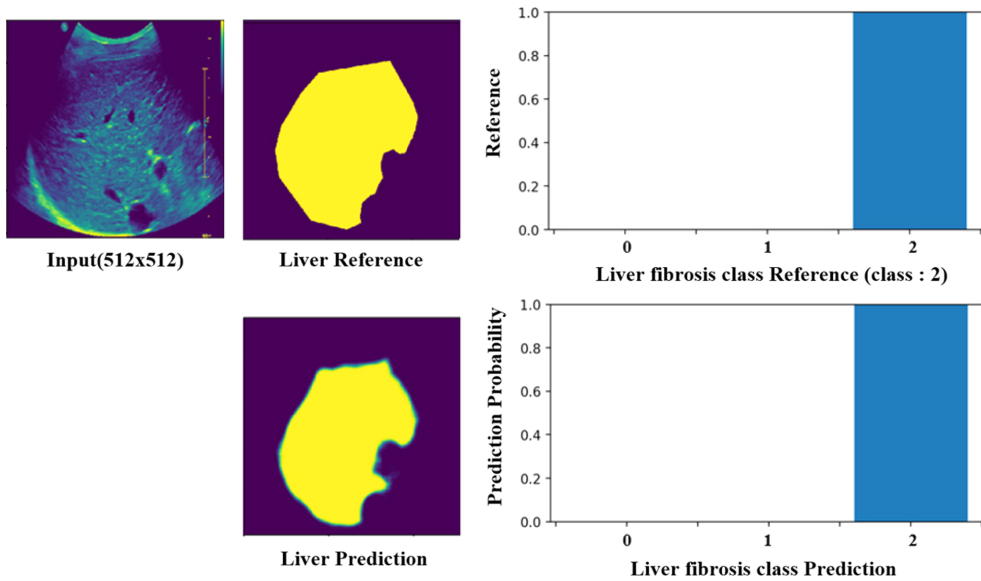


그림 4. 제안된 신경망 모델에 의해 분류된 Class 2 (F4) 에 대한 결과
 Fig. 4. The result classified by the proposed neural network model for Class 2 (F4)

성이 반영되어 해당 클래스 값이 정확하게 예측되어 분류되었음을 확인할 수 있다.

반면 제안된 U-net 모델에 의한 일부 분할 결과는 그림 5에 서처럼 간의 영역이 명확하게 분할되지 않았다. 이러한 경우에 본래 클래스 이외의 다른 클래스에 대한 확률 추정치가 작지 않은 값을 보여주고 있어 분류 결과에 영향을 끼쳤음을 추정해 볼 수 있으며 최종적으로 가장 높은 확률 추정치에 의해 분류 결과가 결정됨을 확인할 수 있었다. 그림 5의 경우는 Class 2에 대한 확률 추정치보다 Class 1에 대한 확률추정치가 조금 더 높은 값을 보여 분류 결과가 일치했음을 알 수 있다.

IV. 고찰 및 결론

딥 러닝 방법은 그 성능이 데이터의 양에 밀접하게 의존한다. 일반적으로 데이터의 양이 많을수록 알고리즘 성능이 높아진다. 이 연구에서는 데이터 양이 매우 적은 경우 제한된 조건을 극복하기 위한 분류 방법에 초점을 맞추었다. 분할을 위한 딥 러닝 구조로 잘 알려진 U-net 구조를 분할이 아닌 분류를 위한 목적으로 활용하고자 신경망을 재정의하였으며, 적은 양의 데이터에 대해 높은 정확도를 갖는 우수한 성능의 U-net 구조를 제안하였다. 특히 제안된 모델을 통해 Gradient-weighted Class Activation Mapping (Grad-

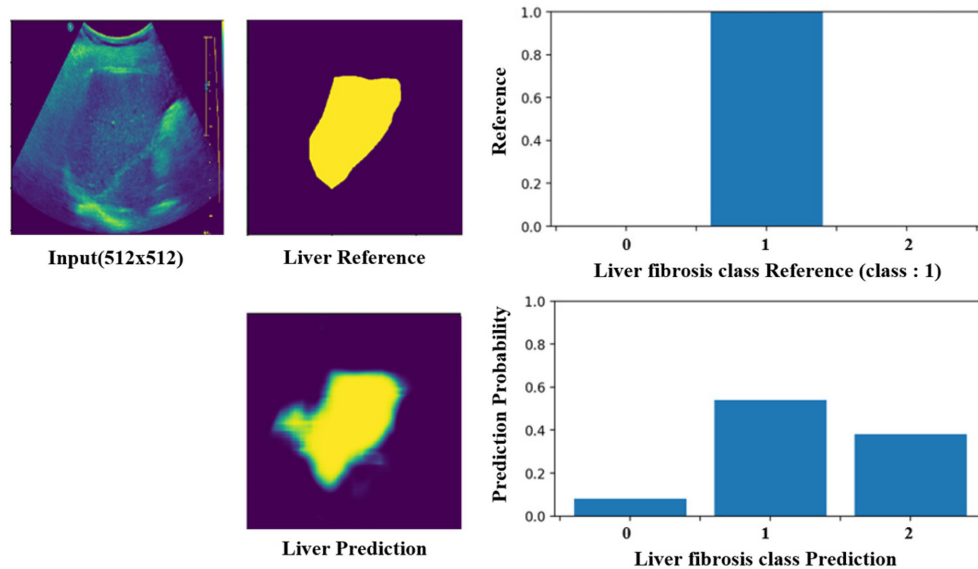


그림 5. 제안된 신경망 모델에 의해 분류된 Class 1 (F2/F3) 에 대한 결과 (2)

Fig. 5. The result classified by the proposed neural network model for Class 1 (F2/F3)

CAM)을 사용하지 않고도 분할된 결과를 통해 분류가 제대로 되었는지 정확도에 대한 식별이 어느 정도 가능함을 확인할 수 있었다.

이 논문에서는 제안된 신경망 모델의 성능을 확인하기 위해 사전 훈련된 VGGNet 모델을 사용한 전이학습 방법과 비교하였다. 16개의 층으로 구성된 VGGNet 모델과 19개의 층으로 구성된 VGGNet 모델 각각에 대해 전이학습 방법을 적용하여 간 섬유화 단계 분류 성능을 확인하였는데, 두 경우에는 초음파 B-모드 영상의 수가 부족하여 높은 정확도의 분류 결과를 얻을 수 없었고 40% 미만의 정확도를 보였다. 이러한 이유로, 데이터의 양을 늘리기 위해 간 전체 영상으로부터 추출된 패치 영상을 사용하였고, 패치 영상을 이용하여 VGGNet의 사전 훈련된 모델을 사용한 전이학습 방법의 경우 간 섬유화 단계 분류의 평균 정확도가 65% 미만으로 나타났다.

반면, 제안된 모델은 동일한 데이터 셋으로 실험한 결과 대략 80%의 정확도를 보였다. 딥 러닝 방법에 필수적 조건이라고 할 수 있는 방대한 양의 데이터 셋을 이용하여 학습을 수행하지 않았지만, 적은 양의 데이터 셋의 제한된 조건에서도 주목할만한 성능을 보여주었다. 제안된 신경망 모델의 학습을 위한 데이터가 추가로 확보가 된다면 확실히 더욱 높은 정확도의 간 섬유화 단계 분류가 가능할 것이라고 판단되며, 이 논문에서는 클래스를 3단계로 나누었지만 향후에는 4단계 혹은 5단계로 더욱 세분화하여 분류 성능에 대한 실험을 수행하고자 한다.

우리가 알기에 U-net은 처음 제안될 때부터 분할을 위한 알고리즘으로 제안이 되어 활용되었고, 분류를 위한 목적으

로는 사용된 사례가 없었으며, 분류를 위한 목적으로 U-net 구조를 사용한 것은 이번이 처음 시도이다. 또한 U-net 구조에 의한 분할 결과가 분류 결과의 성능과 관련되어 있음을 확인한 이번 연구는 U-net 구조의 활용 가능성을 확장시키는데 의미가 있다고 판단된다. 향후 연구에서는 그 관련성을 보다 엄밀하게 분석할 필요가 있다고 판단되며, 이와 더불어 제안된 방법에 대해 임상 적용 가능성 평가를 추가로 수행하고자 한다.

References

- [1] Kennedy P, Wagner M, Castera L, Hong CW, Johnson CL, Sirlin CB, Taouli B. Quantitative Elastography Methods in Liver Disease: Current Evidence and Future Directions. *Radiology*. 2018;286(3):738-63.
- [2] Lee JE, Shin KS, Cho JS, You SK, Min JH, Kim KH, Song IS, Cheon KS. Non-invasive Assessment of Liver Fibrosis with ElastPQ: Comparison with Transient Elastography and Serologic Fibrosis Marker Tests, and Correlation with Liver Pathology Results. *Ultrasound Med Biol*. 2017;43(11):2515-21.
- [3] Zhuang Y, Ding H, Zhang Y, Sun H, Xu C, Wang W. Two-dimensional Shear-Wave Elastography Performance in the Noninvasive Evaluation of Liver Fibrosis in Patients with Chronic Hepatitis B: Comparison with Serum Fibrosis Indexes. *Radiology*. 2017; 283(3):873-82.
- [4] Sandrin L, Fourquet B, Hasquenoph JM, Yon S, Fournier C, Mal F, Christidis C, Ziol M, Poulet B, Kazemi F, Beaugrand M, Palau R. Transient elastography: a new noninvasive method for assessment of hepatic fibrosis. *Ultrasound Med Biol*. 2003;29(12):1705-13.
- [5] Castéra L, Vergniol J, Foucher J, Le Bail B, Chanteloup E, Haaser M, Darriet M, Couzigou P, De Lédinghen V. Prospec-

- tive comparison of transient elastography, Fibrotest, APRI and liver biopsy for the assessment of fibrosis in chronic hepatitis C. *Gastroenterology*. 2005;128(2):343-50.
- [6] Nightingale K, McAleavey S, Trahey G. Shear-wave generation using acoustic radiation force: in vivo and ex vivo results. *Ultrasound in Medicine & Biology*. 2003;29(12):1715-23.
- [7] Bercoff J, Tanter M, Fink M. Supersonic shear imaging: a new technique for soft tissue elasticity mapping. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*. 2004;51(4):396-409.
- [8] Mo JA. Shear wave elastography: a systematic review and meta-analysis. *Journal of the Korean Medical Association*. 2016;59(7):529-35.
- [9] Meng D, Zhang L, Cao G, Cao W, Zhang G, Hu B. Liver Fibrosis Classification Based on Transfer Learning FCNet for Ultrasound Images. *IEEE Access*. 2017;5:5804-10.
- [10] Choi BH, Kim YJ, Choi SJ, Kim KG. Malignant and Benign Classification of Liver Tumor in CT according to Data pre-processing and Deep running model. *J Biomed Eng Res*. 2018; 39(6):229-36.
- [11] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. Springer. 2015;9351:234-41.
- [12] Selvaraju RR, Cogswell M, Das A, Vedantam R, Parikh D, Batra D. Grad-CAM: visual explanations from deep networks via gradient-based localization. *International Conference on Computer Vision (ICCV)*. 2017;618-26.
- [13] Zeiler MD. ADADELTA: An adaptive learning rate method. *arXiv preprint 2012*; arXiv:1212.5701.