

특집논문 (Special Paper)

방송공학회논문지 제24권 제4호, 2019년 7월 (JBE Vol. 24, No. 4, July 2019)

<https://doi.org/10.5909/JBE.2019.24.4.592>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

지역적 패치기반 보정기법을 활용한 2D X-ray 영상에서의 강인한 관상동맥 재연결 기법

한 경 훈^{a),b)}, 전 병 환^{a),b)*}, 김 세 근^{a),c)}, 장 영 결^{a),b)}, 정 성 희^{a),b)}, 심 학 준^{a)}, 장 혁 재^{a),d)}

Robust Coronary Artery Segmentation in 2D X-ray Images using Local Patch-based Re-connection Methods

Kyunghoon Han^{a),b)}, Byunghwan Jeon^{a),b)*}, Sekeun Kim^{a),c)}, Yeonggul Jang^{a),b)}, Sunghee Jung^{a),b)},
Hackjoon Shim^{a)}, and Hyukjae Chang^{a),d)}

요 약

관상동맥 시술을 위해 혈관 조영 X-선 영상은 시술 진단 및 보조에 유용하게 활용된다. 삼차원의 복잡한 구조를 가진 관상동맥을 이차원 X-선 영상에서 기존의 단일기법만을 사용하여 정확히 분할하는 것에 어려움이 있으며, 특히 혈관이 중간에 끊어지거나 말단부 위혈관이 유실되는 현상으로부터 오차가 크게 발생하는 경향이 있었다. 이러한 문제를 해결하기 위하여 기존 단일기법으로 초기분할 단계를 거친 후, 초기분할결과를 기반으로 정교한 보정영역을 설정하는 단계, 보정영역을 대상으로 패치기반 지역보정을 수행하는 단계가 수행된다. 본 연구를 통해 끊긴 혈관을 보완한 분할 결과를 구할 수 있을 뿐만 아니라 미세혈관까지 포함하지 못한 참 값의 한계점을 해결할 수 있다. 또한, 존재하는 기존 관상동맥 분할방법들에 융합하여 추가적인 성능개선을 얻어낼 수 있다. 본 논문에서는 Fully convolutional network 기반 깊은 신경망 네트워크인 U-net을 활용하였으며, 제안된 보정방법을 융합하여 기존 U-net 단일 모델 대비 성능이 상당히 개선된다는 것을 실제 여러 환자들의 데이터 셋을 통하여 증명하였다.

Abstract

For coronary procedures, X-ray angiogram images are useful for diagnosing and assisting procedures. It is challenging to accurately segment a coronary artery using only a single segmentation model in 2D X-ray images due to a complex structure of three-dimensional coronary artery, especially from phenomenon of vessels being broken in the middle or end of coronary artery. In order to solve these problems, the initial segmentation is performed using an existing single model, and the candidate regions for the sophisticate correction is estimated based on the initial segment, and the local patch-based correction is performed in the candidate regions. Through this research, not only the broken coronary arteries are re-connected, but also the distal part of coronary artery that is very thin is additionally correctly found. Further, the performance can be much improved by combining the proposed correction method with any existing coronary artery segmentation method. In this paper, the U-net, a fully convolutional network was chosen as a segmentation method and the proposed correction method was combined with U-net to demonstrate a significant improvement in performance through X-ray images from several patients.

Keyword : 2D X-ray, Angiogram, Coronary Artery, Segmentation, Patch-Based Correction

Copyright © 2016 Korean Institute of Broadcast and Media Engineers. All rights reserved.

“This is an Open-Access article distributed under the terms of the Creative Commons BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited and not altered.”

I. 서론

심혈관계 질환은 세계적으로 사망원인 1위로 보고 되고 있으며, 이는 콜레스테롤이나 지방 등이 혈관에 축적되어 혈관이 좁아지는 현상으로부터 발생된다. 이를 치료하기 위하여 도관을 통해 기구를 삽입하여 좁아진 혈관을 물리적으로 확장하는 경피적 관상동맥 시술이 이루어진다. 시술 중 도관의 위치와 관상동맥의 구조를 실시간으로 파악하기 위하여 시술자는 2D X-선 관상동맥 조영 영상을 참고한다^[1]. 하지만 X-선 영상을 촬영할 때 방출되는 방사선은 환자와 시술자 모두에게 부담이 되기 때문에 X-선 영상 촬영시간을 최소화하면서 관상동맥의 형상을 실시간으로 참고하기 위하여 X-선 영상기반 관상동맥 분할기술이 필수적이다. 정확한 2D X-ray 혈관분할 결과는 시술시 가이드 역할을 할 수 있을 뿐만 아니라 3D CT영상기반 혈관구조물과 정합을 통하여 조영영상에서도 잘 보이지 않는 협착혈관 부분까지 가이드 할 수 있는 보조시스템으로 사용될 수 있다^[2].

현재까지 2D X-ray 혈관 조영 영상에서 혈관분할을 위한 여러 연구가 수행되었는데, 가장 대표적인 두 기법은 Frangi et al.,^[3]의 기법과 Krissian et al.,^[4]의 기법이다. Frangi와 Krissian의 두 기법 모두 다중 스케일에서 Hessian 행렬의 고유값 및 고유벡터를 기반으로 활용하였지만, Frangi는 두 고유값의 벡터크기 및 고유값 간의 비율을 이용하여 특정 픽셀이 혈관일 확률을 정의하였고, Krissian은 고유값 및 고유벡터에 기울기 정보까지 활용한 응답함수를 소

개하였다. 하지만 두 기법 모두 단순한 수치를 변화 없이 사용하기 때문에 긍정오류 (false positive, FP)가 많이 발생한다.

이를 해결하고자 Dehkordi et al.,^[5]에서는 혈관 추출을 위해 활성 외곽선(active contour)를 소개하였고, 이를 통해서 다른 크기의 혈관을 탐지하고, 잡음과 배경의 복잡성을 처리하기 위한 지역적 특징 조절함수를 제안하였다. 하지만 활성 외곽선은 영상내의 빛의 강도가 일정하지 않을 때 대부분 실패하게 된다. 또한 활성 외곽선은 외곽선의 초기 선택에 매우 의존적이며 높은 컴퓨터 복잡성을 가지고 있다. Shoujun et al.,^[6]에서는 fuzzy추론을 이용한 추적(tracking)기반 방법을 소개하였다. 먼저 Gabor와 Hessian 필터를 적용하여 영상을 향상시킨 후 확률적 추적 연산자에 의해 파생된 후보자들의 그룹으로부터 관상동맥 혈관들을 선택하였다. 하지만 추적기반 모델은 해상도가 낮거나 복잡한 배경이 존재한다면 잘못 유도될 수 있다.

이러한 문제를 해결하기 위하여 Jung et al.,^[7]에서는 혈관 검출 확률을 높이기 위해 기존 혈관 증강 필터링 기법에 활용된 Hessian 행렬의 고유값 및 고유벡터를 특징 벡터로 활용한 랜덤포레스트 판별기를 학습하는 방법을 제시하였다. Lee et al.,^[8]에서는 내강을 증가시키는 Frangi의 기법과 외곽선을 증가시키는 Krissian의 기법의 두 장점을 모두 살려 Gaussian mixture model을 제안하였다. 이를 위하여 영상 내에 있는 각각의 픽셀에 대한 Hessian의 특성에 기반한 vesselness가 Frangi의 vesselness와 Krissian의 medialness를 결합시키기 위해 제안되었다.

관상동맥은 복잡한 구조로 인해 기존의 영상처리 기법으로는 일반화된 모델링을 하기 어렵다. 따라서 본 논문에서는 모델링하기 어려운 특징들을 학습하고 분류하는데 좋은 성능을 보여주는 인공지능 기법을 사용하여 혈관분할을 수행하고자 하였다.

II. 제안한 방법

본 논문에서는 2D X-ray 혈관 조영 영상에서의 정확한 혈관분할 결과를 얻기 위하여 그림 (1)과 같이 크게 4 단계의 실험을 진행하였다. 섹션 II.1에서는 1) 입력 영상 (512×512)에 대해서 U-net^[9]을 이용하여 확률 맵 생성을

a) 연세대학교 심장혈관 ICT 기술연구센터(Cardio-vascular ICT Research Center, Yonsei University)

b) 연세대학교 의과학과(Brain Korea 21 PLUS Project for Medical Science, Yonsei University)

c) 연세대학교 생체공학협동과정(Graduate Program of Biomedical Engineering, Yonsei University)

d) 연세대학교 의과대학 내과학교실 심장내과(Division of Cardiology, Department of Internal Medicine, Yonsei University College of Medicine)

‡ Corresponding Author : 전병환 (Byunghwan Jeon)

E-mail: byunghwanjeon@yonsei.ac.kr

Tel: +82-2-312-8067

ORCID: <https://orcid.org/0000-0002-0414-1762>

※ 이 논문의 연구결과 중 일부는 "IPIU 2019"에서 발표한 바 있음.

※ 이 논문은 2018년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연구임(No.2018-0-00861, 의료데이터 분석지능형 SW 기술개발)

· Manuscript received May 7, 2019; Revised July 15, 2019; Accepted July 15, 2019.




그림 1. 제안하는 기법의 흐름도

Fig. 1. The flow chart of the proposed method

생성하고, 섹션 II.2에서는 패치를 생성하기 위한 후보군을 추출한다. 섹션 II.3에서는 추출한 후보군들과 인접한영역에 대하여 다시 한 번 패치 영상(64×64)을 만들고 이에 대한 픽셀별 확률 맵을 생성한다. 마지막으로 섹션 II.4에서는 앞의 섹션 II.1과 섹션 II.3에서 구한 U-net의 혈관 확률 맵과 패치 영상의 혈관 확률 맵들을 동시에 고려한 최종 혈관분할 결과를 구한다.

1. 혈관 확률 및 보정 후보지역 추출


관상동맥을 분할하기 위해 입력 영상(512×512)에 대해 U-net을 활용하여 혈관 확률 맵을 추출한다. 본 연구에서 76명의 환자로부터 얻은 총 2,794장의 X-ray 혈관조영 영상 및 전문가에 의한 수동 관상동맥 분할 영역(참 값)을 사용했다. 이 중 66명의 환자로부터 해당하는 2,424장을 학습 데이터로 10명 환자에 해당하는 370장을 테스트 데이터로 구성하였다. 사용된 U-net의 구조는 수축(인코딩) 단계에서 5개의 레이어와 확장(디코딩) 단계에서 5개의 레이어로 구성되어 있다. 실험을 위한 하이퍼파라미터는 배치크기 7, 학습율(learning rate)은 0.001, 비용함수는 Cross-

Entropy로 설정하였으며 RMSPropOptimizer 최적화 함수를 사용하여 비용함수가 최소가 되도록 하였다.

본 논문에서 활용된 U-net모델들은 $M_{N_x \times N_y}$ 으로 표현되어 있으며 $N_x \times N_y$ 는 사용된 입력 영상의 차원이다. 학습된 모델 $M_{512 \times 512}$ 의 마지막 단계에 있는 소프트맥스 $\sigma(p)$ (수식 (1))를 통하여 각 픽셀 x 에 맵핑된 0-1 스케일의 혈관 확률 맵 Σ 을 구할 수 있다. 그림 2는 입력 영상과 추론된 혈관 확률 맵을 보여주고 있다.

$$\sigma(p) = \frac{e^{z_v}}{\sum_{k \in K} e^{z_k}}, K = \{v, non-v\} \quad (1)$$

여기서 v 와 $non-v$ 는 혈관인 영역과 혈관이 아닌 배경 영역의 label을 의미하며, 그림 2(b)는 $\sigma(p)$ 를 맵핑한 혈관 확률 맵 Σ 이다. Σ 을 기반으로 특정 임계값 이상을 검출된 혈관영역으로 볼 수 있으며, receiver operating characteristics (ROC) 분석을 통하여 최적의 분류성능에서의 임계값으로 τ_1 을 획득하였다. 그러나 최적의 임계값($\sigma(p) > \tau_1$)을 적용하였음에도 불구하고, 그림 5(a)와 같이 병변이나 고르

그림 2. 입력 영상과 혈관 확률 맵. (a) 2D X-ray 입력 영상, (b) $M_{512 \times 512}$ 을 통해 얻어진 혈관 확률 맵 Σ , (c) 참 값Fig. 2. An input image and its vessel probability map. (a) 2D X-ray input image, (b) vessel probability map Σ obtained by $M_{512 \times 512}$, (c) label




그림 3. 일반적인 혈관 부분과 혈관의 분기점 및 혈관의 끝 부분에서도 혈관과 배경영역이 고르게 분포되었음을 보이는 패치와 각각에 해당하는 참 값
 Fig. 3. Patches and corresponding labels showing that the vessel and the background are similarly distributed at normal vessel part and at the bifurcation point of the vessel and at the end of the vessel

지 못한 확률 값에 의하여 혈관 곳곳이 끊어져 나타나게 되는 것을 확인 하였다. 또한, 혈관의 말단 부위에서 확률이 낮아서 실제 혈관이 존재하지만 최종 혈관영역으로 선택되지 않은 경우도 있었다.

혈관이 고르게 분할되지 못한 이유는 배경영역대비 관상동맥 영역이 차지하는 비율이 매우 낮아 클래스별 픽셀 개수의 불균형으로 인해 발생하는 것으로 판단된다. 또한, 혈관이 중간에 끊어지게 되는 현상은 단일 모델만을 사용했을 때의 난점이자, 임상적용의 관점에서 존재해야 할 혈관이 없는 정보로 표시되는 것은 의사결정에 있어서 치명적일 수 있으므로 지역적으로 보정하여 끊어진 혈관 부분의 확률 값을 보정하는 추가적인 방법이 필수적이다.

이를 해결하기 위하여 참 값 영역을 기반으로 혈관 영역을 중심으로 하는 작은 패치(64×64) 데이터들을 그림 3과 같이 추출하였다. 작은 지역패치는 혈관의 영역과 혈관이 아닌 영역이 그림 2와 같이 균일하게 분포되어 있으므로 지역적인 관점에서 끊어진 혈관에서도 높은 확률 값을 갖도록 지역보정모델 $M_{64 \times 64}$ 을 학습 할 수 있다.

지역보정모델 $M_{64 \times 64}$ 을 위하여 사용한 모델 구조를 그림 4에 나타내었다. 모델의 구조는 작은 크기의 영상에 존재하는 물체를 분할하는 목적에 최적화된 U-net의 변형된 버전이며, 파란색 박스는 각 단에서의 채널의 수와 차원의 변화에 따른 모양을 의미한다. 지역보정모델 $M_{64 \times 64}$ 을 최대한 혈관의 영역에서만 수행하여 유실된 혈관영역이 보정될




그림 4. 지역보정모델 $M_{64 \times 64}$ 의 구조와 각 단계에서의 채널의 수와 차원의 변화에 따른 모양

Fig. 4. Structure of local correction model $M_{64 \times 64}$ and the number of each layer's channel and shape as dimension changes

수 있도록 하기 위하여 탐색지역을 잘 설정하는 것이 중요하다. 탐색지역을 설정하는 내용을 다음 섹션에서 소개한다.

2. 보정을 위한 후보 탐색지역 설정

지역보정모델 $M_{64 \times 64}$ 을 적용하기 위한 후보 탐색지역을 설정하기 위하여 총 3단계의 처리단계를 거친다.

먼저 1단계) 그림 5(a)와 같이 $M_{512 \times 512}$ 의 초기영역결과에 존재하는 작은 FP들을 제거하기 위하여 연결요소분석 (connected component analysis, CCA)를 수행하여 그림 5(b)와 같이 큰 덩어리의 혈관 영역만을 남기도록 한다. 2단계) 남겨진 큰 영역들의 외각 점들이 이루는 컨벡스 헐 (convex hull)을 구한다. 컨벡스 헐 내부 영역을 C 라고 할 때 C 를 그림 5(b)와 같이 자동으로 결정 할 수 있으며, C 는 관상동맥과 어느 정도의 배경영역을 함께 포함하는 영역이 된다. 3단계) C 내부에 끊어진 혈관들이 존재하므로 혈관 확률 값들 중 불확실성이 높은 영역을 설정하기 위하여 τ_0 와 τ_1 사이의 최종 후보 영역을 수식 (2)의 조건으로 설정하였다. 그림 5(c)는 보정이 필요한 최종 위치들 $\hat{S}$ 를 나타낸다.

$$\hat{S} = \{p = (x, y) \mid \tau_0 < \sigma(p) < \tau_1, v \in C\} \quad (2)$$

3. 패치 영상에서 확률 값 추출

섹션 II.2에서 구한 최종 후보영역 $\hat{S}$ 의 요소들이 중심이

되는 패치를 ϕ 라고 할 때, 패치기반 보정 모델 $M_{64 \times 64}$ 을 통과한 확률 맵을 ϕ' 라고 하자. 이 때, 모든 후보 요소들 $\phi(i)$, $i \in \hat{S}$ 에 대해 $M_{64 \times 64}$ 을 통과시킨 확률 맵들을 중첩하여 평균값으로 재보정하게 된다.

$$\phi'(p) = (1 - \frac{1}{N})\bar{\phi}'_{N-1}(p) + \frac{1}{N}\phi'_N(p), \quad p \in \hat{S} \quad (3)$$

수식 (3)은 중첩되는 영역의 확률 값을 업데이트하는 방법이며, 여기서 N 은 픽셀별로 중첩된 확률의 갯수를 의미한다. $\bar{\phi}'_{i_{N-1}}$ 는 $N-1$ 까지 중첩된 부분에 대한 평균값을 나타내며 ϕ'_{i_N} 은 N 중첩에 의해 보정된 픽셀 p 에서 확률을 의미하며, $\phi'(p)$ 가 맵핑된 최종 보정 혈관 확률 맵을 Φ 으로 표기하였다.

4. 입력과 패치 영상에서 최종 확률 값 추출

섹션 II.2와 II.3에서 얻은 두 가지 확률 맵을 동시에 고려한 최종 혈관 확률 맵을 구하기 위하여 $M_{512 \times 512}$ 기반 확률 맵 Σ 와 $M_{64 \times 64}$ 기반 패치기반 보정 확률 맵 Φ 를 수식 (4)와 같이 선형적으로 결합하여 끊어진 혈관 부분이 보정된 최종 혈관 확률 맵 P^* 를 얻을 수 있다.

$$P^* = \lambda_1 \times \Sigma + (1 - \lambda_1) \times \Phi \quad (4)$$

각 확률 맵의 가중 정도를 결정하는 λ_1 그리고 P^* 에 대




그림 5. 혈관분할 결과 및 보정이 필요한 후보 영역: (a) τ_1 을 적용한 $M_{512 \times 512}$ 기반 확률 분할 결과, (b) 연결 성분 분석 후 컨벡스 헐을 적용한 결과, (c) 입력 영상에 빨간색으로 표시한 $\hat{S}$ 및 확대

Fig. 5. Vessel segmentation results and candidate region to correct: (a) $M_{512 \times 512}$ -based segmentation result apply τ_1 , (b) result apply convex hull after CCA, (c) $\hat{S}$ marked in red in input image and magnification

한 임계값 τ_2 는 ROC를 분석하여 최적의 값들로 설정 하였고, 설정된 값들을 적용한 후 연결 성분 분석을 통하여 FP를 제거한 결과 제안된 기법에서 높은 체적일치도를 얻을 수 있었다. 실험에 대한 자세한 내용이 섹션III에서 설명되어 있다.

III. 실험 결과 및 분석

본 논문에서 제안한 기법의 성능을 10명의 환자에 대하여 370장의 2D 혈관 조영 영상에서 테스트하였다. 실험을 통하여 섹션 II에서 정의한 수식 (2)의 τ_0 과 τ_1 은 각각 0.1과 0.33으로 정의하였으며, τ_2 는 0.23, λ_1 은 0.65로 고정하였다. 실험을 위한 시스템 성능은 Intel® Core(TM) i7-3770K CPU @ 3.50GHz, 32.0 GB RAM, NVIDIA® TITAN X (memory: 12.0GB)이고, Linux(Ubuntu 14.04)기반의 Python을 통해 Tensorflow 1.9버전으로 수행하였다

무엇보다 기존에 있는 방법 대비 보정 후 개선되었음을 증명하기 위하여 U-net의 결과와 U-net +보정의 결과를 비교하였을 뿐만 아니라, 최근에 제안되었던 다른 기법들과 정량적 비교를 수행하였다. 측정방법으로는 표 (1)에서 제시된 (dice similarity coefficient, DSC)를 사용하였으며 (true positive, TP), (false positive, FP), (true negative, TN) 그리고 (false negative, FN)의 양을 기반으로 측정되었다.

표 1. 제안기법의 성능을 평가하기 위한 평가지표와 설명
Table 1. metrics and descriptions for evaluating proposed method

Metrics	Description
TP	Number of vessel pixels classified as vessel
FP	Number of background pixels classified as vessel
TN	Number of background pixels classified as background
FN	Number of vessel pixels classified as background
DSC	$2TP/(2TP + FP + FN)$

표 (2)에서는 10명의 환자, 370장의 2D X-ray영상에서 $M_{512 \times 512}$ 을 통하여 얻어진 혈관 확률 맵 σ 와 추가보정을 통하여 얻어진 확률 맵 P^* 에 각각 최적의 임계값을 적용하

여 DSC측정을 통해 정략적으로 평가된 결과를 보여주고 있다. $M_{512 \times 512}$ 을 이용한 혈관분할 결과는 DSC 74.3%였으며, $M_{512 \times 512}$ 에 추가 보정기법을 적용한 결과 P^* 는 DSC 75.5%로서 보정 후 더 높은 성능을 보여주었다. 보정 과정에 대한 처리 시간은 평균 5.08초를 필요로 하였으며, X-ray영상 하나를 처리하기 위해서는 U-net에서의 추론과정에 필요한 0.03초를 더한 5.11초의 시간이 소모되었다. 그러나 처리 시간이 추가적으로 필요하다더라도 만성폐색변인 치료를 위해서는 끊어진 혈관이 더 정확하게 분할되는 기술이 임상적으로 가치가 있다.

표 2. 대표되는 10명의 2D X-ray 데이터를 기반으로 한 단일모델($M_{512 \times 512}$)과 제안기법(P^*)의 DSC 성능 비교
Table 2. Quantitative results (DSC) with Single model($M_{512 \times 512}$)and proposed method(P^*)

Patient #	Frame (n)	$M_{512 \times 512}$	P^*
		Avg DSC(%)	Avg DSC(%)
01	53	79.5	80.9
02	36	71.4	72.9
03	37	73.8	75.7
04	45	70.1	71.4
05	25	78.6	79.7
06	38	71.5	73.0
07	36	78.4	79.6
08	30	73.2	74.2
09	35	73.7	74.6
10	35	72.2	73.0
Avg	37	74.3	75.5

픽셀별로 비교한 DSC측정 결과에서 큰 차이가 나지 않는 것으로 보이지만, 실제로 끊어진 혈관이 보정되는 점에서 임상적 가치에서 큰 차이가 있다. 그림 6에서 나타내듯이 실제로 끊어진 혈관의 부분은 매우 지역적이며 그 영역이 크지 않기 때문에 정량적 평가에서 큰 차이가 나지 않는 것으로 보이지만, 임상적 활용가치는 매우 크다고 평가할 수 있다.

또한, 객관적 성능비교를 위하여 세브란스병원에서 추가적으로 확보한 18명의 환자, 350장의 2D X-ray영상을 기반으로 다른 기법들과의 비교를 수행하였다. 혈관의 확률을 측정하는 정통적인 기법인 Frangi [3]과 Krissian [4], 그리




그림 6. 2D X-ray 혈관 조영 영상에서의 혈관분할 결과 비교: (a) 원본 입력 영상, (b) 단일모델 $M_{512 \times 512}$ 에 의한 결과로써 혈관의 중간 부위가 유실되는 경우가 많음, (c) 제안 기법으로 보정한 결과 유실부위가 다시 연결되는 것을 확인할 수 있음, (d) 전문가에 의해 수동으로 생성된 참값을 보여주고 있으며 b의 단일모델에 의한 결과보다 c의 제안된 방법에 의한 결과와 매우 일치하는 것을 확인할 수 있으며 이는 표 1에서 정량적으로 증명되었음.

Fig. 6. Vessel segmentation results in 2D X-ray angiography: (a) input image, (b) the broken coronary arteries are found in the results by using only a single model $M_{512 \times 512}$, (c) the broken coronary arteries are re-connected by the proposed correction method, (d) the ground truths manually annotated by the experts match to the results of the proposed method in c rather than the results in b, which is quantitatively demonstrated in Table 1

고 고윳값들의 조합을 특징벡터로 사용한 기계학습모델 기법 [7]을 350장의 동일한 테스트케이스를 사용하여 직접적 비교를 수행하였다. 또한, Gaussian Mixture 모델기반 기법

을 제안한 연구 [8]에서 완료된 실험결과를 참고하여 간접적인 성능비교결과를 표 (3)에 추가하였다.

표 3. Dice similarity coefficient (DSC) 측정을 통한 제안기법과 다른 기법들 [3, 4, 7] 간 정량적 비교: 18명의 환자, 350장의 2D X-ray 영상에서 측정된 DSC결과, 제안기법에서 가장 높은 성능을 보여주었다. 다만, IVGMM [8] 기법의 경우, 논문에서 892장의 비공개데이터를 기반으로 완료한 실험을 참고하였다. Table 3. The comparison between the proposed method and the other methods [3, 4, 7] with the same dataset, 18 patients, 350 2D X-ray images. The result of dice similarity coefficient (DSC) shows that the highest accuracy from the proposed method. Note that IVGMM [8] is indirectly compared since IVGMM uses other 892 private dataset, and the DSC is referred from the experiment completed in the published paper [8]

Methods	Proposed method (P^*)	Frangi [3]	Krissian [4]	Random Forest [7]	IVGMM [8]
DSC (%)	78.1	18.0	23.0	57.0	70.4

IV. 결 론

본 논문에서는 심혈관 질환 시술을 진행하기 위한 영상 모달리티인 2D X-ray 혈관 조영 영상에서의 혈관 영역을 분할하기 위해 두 혈관 확률 맵을 동시에 고려한 기법을 소개하였다. 실험결과, $M_{512 \times 512}$ 의 혈관분할 결과에서 많이 존재하던 끊어진 부분이 제안한 기법의 혈관분할 결과에서는 많이 이어진 것을 알 수 있었다. 또한, 학습 입력 영상인 참값이 미세혈관들을 정확히 포함하지 못하고 있는 한계점을 제안한 기법의 결과에서는 일부분 극복한 것을 정성적으로 알 수 있었다. 하지만 그림 5(c)를 보면 혈관 가장자리에서 확률이 낮은 곳들이 많이 있는 것을 알 수 있는데, 이 부분들이 섹션 II.3의 보완을 통해 기존의 참값 대비 혈관의 영역이 더 넓어졌기 때문에 미세혈관을 찾음으로써 증가되어야 하는 DSC가 상쇄된 것으로 판단된다. 향후 혈관의 확률이 낮은 부분들 전체가 아닌 혈관이 끊어진 부분에만 패치 기반의 보완을 수행함으로써 더욱 정확한 혈관분할 결과를 얻을 수 있을 것으로 기대된다.

또한, 제안한 기법은 학습을 통해 얻어진 $M_{512 \times 512}$ 기반의 혈관 확률 맵을 패치 영상들을 통해 재보정하는 구조이기 때문에 초기의 $M_{512 \times 512}$ 혈관 확률 맵에서 향상된 결과를 얻을 수 있도록 학습모델을 개선하거나 2D X-ray 영상에 존재하는 잡음이나 밝기의 불균형성 같은 인공지능이 학습하는 과정에서 어려움을 느낄 수 있는 항목들을 최소화시킴으로써 더욱 개선된 최종 혈관분할 결과를 얻을 수 있을 것으로 기대된다.

제안된 기법은 후속연구를 통하여 실제 의료기관에서 만성폐색병변 관상동맥 시술시 가이드를 위한 보조영상으로써의 활용가치를 평가할 예정이다.

참 고 문 헌 (References)


- [1] FAZLALI, Hamid R., et al. "Vessel region detection in coronary X-ray angiograms," *Proceeding of IEEE International Conference on Image Processing (ICIP)*, pp. 1493-1497, 2015.
- [2] NASR-ESFAHANI, Ebrahim, et al. "Segmentation of vessels in angiograms using convolutional neural networks," *Biomedical Signal Processing and Control*, Vol.40, pp.240-251, 2018.
- [3] A. F. Frangi, W. J. Niessen, K. L. Vincken, and M. A. Viergever, "Multiscale vessel enhancement filtering," *Proceeding of International Conference on Medical Image Computing and Computer-Assisted Intervention*, Springer, Berlin, Germany, pp. 130 - 137, 1998.
- [4] K. Krissian, G. Malandain, N. Ayache, R. Vaillant, and Y. Troussset, "Model based detection of tubular structures in 3D images," *Computer Vision and Image Understanding*, vol.80, no. 2, pp. 130-171, 2000.
- [5] M. T. Dehkordi, A. M. D. Hoseini, S. Sadri, & H. Soltanianzadeh, "Local feature fitting active contour for segmenting vessels in angiograms," *IET Computer Vision*, Vol.8, No.3, pp.161-170, 2013.
- [6] S. Zhou, et al. "Automatic segmentation of coronary angiograms based on fuzzy inferring and probabilistic tracking," *Biomedical engineering online* Vol.9, No.1 pp.40, 2010, <https://doi.org/10.1186/1475-925X-9-40> (accepted Aug. 20, 2010).
- [7] S. Jung, S. Lee, H. Shim, H. Y. Jung, Y. S. Heo, & H. J. Chang, "An Automatic Algorithm for Vessel Segmentation in X-Ray Angiogram using Random Forest", *Journal of Biomedical Engineering Research*, Vol.36, No.4, pp.79-85, 2015.
- [8] H. Lee, H. Shim, & H. J. Chang, "Intensity-vesselness Gaussian mixture model (IVGMM) for 2D+ t segmentation of coronary arteries for X-ray angiography image sequences", *Journal of X-ray Science and Technology*, Vol.23, No.5, pp.579-592, 2015.
- [9] R. Olaf, P. Fischer, and T. Brox. "U-net: Convolutional networks for biomedical image segmentation." *Proceeding of International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, Cham, pp. 234-241, 2015.

저 자 소 개



한 경 훈

- 2013년 3월 ~ 2019년 2월 : 한국외국어대학교 디지털정보공학과 학사
- 2019년 3월 ~ 현재 : 연세대학교 의과학과 석사과정
- ORCID : <https://orcid.org/0000-0001-9393-1565>
- 주관심분야 : 의료영상처리, 인공지능



전 병 환

- 2009년 3월 ~ 2013년 8월 : 한국외국어대학교 컴퓨터공학과 학사
- 2014년 3월 ~ 2019년 8월 : 연세대학교 의과학과 박사
- ORCID : <https://orcid.org/0000-0002-0414-1762>
- 주관심분야 : 의료영상처리, 인공지능



김 세 군

- 2010년 3월 ~ 2016년 2월 : 연세대학교 의공학부 학사
- 2016년 9월 ~ 현재 : 연세대학교 생체공학협동과정 석박통합과정
- ORCID : <https://orcid.org/0000-0003-4196-6242>
- 주관심분야 : 의료영상처리, 인공지능



장 영 길

- 2009년 3월 ~ 2013년 8월 : 한국외국어대학교 컴퓨터공학과 학사
- 2014년 9월 ~ 현재 : 연세대학교 의과학과 석박통합과정
- ORCID : <https://orcid.org/0000-0002-5805-7494>
- 주관심분야 : 의료영상처리, 인공지능



정 성 희

- 2009년 3월 - 2013년 2월 : 한국외국어대학교 컴퓨터공학과 학사
- 2013년 3월 ~ 현재 : 연세대학교 의과학과 석박통합과정
- ORCID : <https://orcid.org/0000-0003-2323-1189>
- 주관심분야 : 의료영상처리, 인공지능

저 자 소 개



심 학 준

- 1993년 : 서울대학교 전기공학부 공학사
- 1995년 : 서울대학교 전기공학부 공학석사
- 2007년 : 서울대학교 전기컴퓨터공학부 공학박사
- 2008년 ~ 2010년 : 서울대학교 전기공학부 BK21 연구교수
- 2011년 ~ 현재 : 연세대학교 세브란스 병원 연구교수
- 주관심분야 : 컴퓨터 비전, 패턴인식, 영상처리



장 혁 재

- 1994년 : 연세대학교 의학과 의학사
- 1999년 : 연세대학교 의학과 의학석사
- 2003년 : 아주대학교 의학과 의학박사
- 2013년 ~ 현재 : 연세대학교 의과대학 심장내과 정교수
- <https://orcid.org/0000-0002-6139-7545>
- 주관심분야 : 심장관막질환, 심부전, 심근질환