

랜덤 포레스트를 이용한 X-선 혈관조영영상에서의 혈관 자동 영역화 알고리즘

정성희 · 이수찬¹ · 심학준² · 정호엽³ · 허용석⁴ · 장혁재⁵

연세대학교 의과대학 의과학과, ¹순천향대학교 공과대학 전자공학과, ²연세대학교 의과대학 심혈관연구소
³한국외국어대학교 공과대학 컴퓨터·전자시스템공학부, ⁴아주대학교 공과대학 전자공학과
⁵연세대학교 의과대학 내과학교실 심장내과

An Automatic Algorithm for Vessel Segmentation in X-Ray Angiogram using Random Forest

Sunghye Jung, Soochahn Lee¹, Hackjoon Shim², Ho Yub Jung³,
Yong Seok Heo⁴ and Hyuk-Jae Chang⁵

Brain Korea 21 Project for Medical Science, Yonsei University

¹Department of Electronic Engineering, Soonchunhyang University

²Cardiovascular Research Institute, Yonsei University College of Medicine

³Division of Computer & Electronic Systems Engineering, Hankuk University of Foreign Studies

⁴Department of Electrical and Computer Engineering, Ajou University

⁵Division of Cardiology, Department of Internal Medicine, Yonsei University College of Medicine

(Manuscript received 10 June 2015; revised 23 July 2015; accepted 24 July 2015)

79

Abstract: The purpose of this study is to develop an automatic algorithm for vessel segmentation in X-Ray angiogram using Random Forest (RF). The proposed algorithm is composed of the following steps: First, the multiscale hessian-based filtering is performed in order to enhance the vessel structure. Second, eigenvalues and eigenvectors of hessian matrix are used to learn the RF classifier as feature vectors. Finally, we can get the result through the trained RF. We evaluated the similarity between the result of proposed algorithm and the manual segmentation using 349 frames, and compared with the results of the following two methods: Frangi *et al.* [1] and Krissian *et al.* [2]. According to the experimental results, the proposed algorithm showed high similarity compared to other two methods.

Key words: Vessel segmentation, X-Ray angiogram, Random Forest

1. 서 론

경피적 관상동맥 중재술(Percutaneous coronary inter-

vention, PCI)은 시술자가 피부를 통해 도관(catheter)를 삽입하여 관상동맥에 위치시킨 후, 방사선 조영제를 주입하여 촬영된 X-선 혈관조영영상(angiogram)을 바탕으로 진행된다. 하지만 도관을 삽입하는 도중에는 조영된 혈관을 실시간으로 확인할 수 없기 때문에 전적으로 시술자의 감에 의존할 수 밖에 없다. 또한 시술과정에서 얻어지는 영상은 이차원 평면에 투영(projection)된 영상이므로 삼차원 해부학적 정보는 제공해주지 못한다. 그로 인해 시술의 정확성을 담보하기 어려우며, 스텐트(stent) 등 체내 삽입기구가 잘못 삽입되어 이탈하는 경우가 발생하기도 한다.

이러한 한계를 극복하기 위해 이차원 X-선 혈관조영영상

Corresponding Author : Soochahn Lee
Department of Electronic Engineering, Soonchunhyang University (336-745) 22, Soonchunhyang-ro, Sinchang-myeon, Asan-si, Chungcheongnam-do, Korea
TEL: +82-41-530-1448 / MOBILE: +82-10-8993-6668
E-mail: sclsch@sch.ac.kr

이 논문은 2015년도 정부(미래창조과학부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연구임(R0101-15-0171, 다중의료영상을 활용한 3차원 초정밀 시뮬레이션 기반 심·혈관 질환 진단·치료지원 통합소프트웨어 시스템 개발)

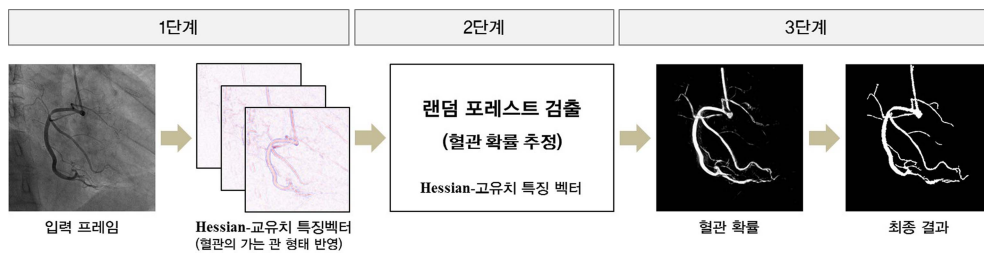


그림 1. 제안 알고리즘의 워크플로우.

Fig. 1. A workflow of the proposed algorithm.

에서의 혈관 영역화가 필수적이다. 이차원 혈관 영역화 결과와 삼차원 CT에서의 혈관 영역화 결과를 정합(registration)함으로써 도관을 올바른 방향으로 삽입할 수 있도록 유도하는 가이드 역할을 할 수 있으며, 혈관이 좁아진 협착(stenosis) 정도를 더욱 정확하게 가늠할 수 있기 때문이다.

이에 따라 이차원 X-선 혈관조영영상에서의 혈관 영역화를 위한 많은 연구가 수행되었다. 이 중 가장 대표적인 기법으로 Frangi *et al.*의 기법[1]과 Krissian *et al.*의 기법[2]을 들 수 있다. 두 기법 모두 혈관의 가늘고 긴 지역적 특성을 반영하기 위해 다중 스케일에서 헤시안(Hessian) 행렬의 고윳값(eigenvalue) 및 고유벡터(eigenvector)를 기반으로 활용한다. Frangi *et al.*의 기법에서는 두 고윳값의 벡터 크기(norm) 및 두 고윳값 간의 비율을 이용하여 특정 픽셀이 혈관일 확률, 소위 혈관도(vesselness)를 정의한다. 반면 Krissian *et al.*의 기법[2]에서는 고윳값 및 고유벡터에 다 기울기 정보(gradient information)까지 활용한 응답함수(response function)를 제안하였다. 두 기법 모두 비율, 크기 등 단순한 수치를 일률적으로 이용하기 때문에 혈관이 아닌 배경의 잡음까지 증강되어 긍정 오류(false positive)가 상당히 많이 발생한다는 한계점이 있다.

따라서 본 연구에서는 혈관 검출 확률을 높이기 위해 기존 혈관 증강 필터링 기법에서 활용된 헤시안(Hessian) 행렬의 고윳값(eigenvalue) 및 고유벡터(eigenvector)를 특징 벡터로 이용하는 랜덤 포레스트 판별기를 학습하여 이차원 혈관조영영상에서 자동으로 혈관을 영역화하는 기법을 제안한다. 헤시안 행렬을 기반으로 랜덤 포레스트 판별기를 결합한 연구로는 Fraz *et al.*의 기법[3]과 Gupta *et al.*의 기법[4]을 들 수 있다. 먼저, Fraz *et al.*은 그래디언트 방향(gradient orientation), gabor 필터 응답 등 아주 고차원 특징 벡터를 활용하였고, 여러 개의 의사결정트리가 결합된 판별기(classifier)를 활용하여 높은 정확도를 달성하는 반면 복잡도가 높아진다는 단점을 가진다. 그리고 Gupta *et al.*은 Frangi *et al.* 기법에서 제안한 혈관도 측정값 자체를 특징으로 이용하여 랜덤 포레스트 판별기를 통해 혈관을 구별하는 기법이다. 본 연구에서 제안하는 기법은 복잡도가 단순한 픽셀 단위 혈관 확률 추정 기법으로서 Frangi

*et al.*의 기법 및 Krissian *et al.*의 기법 등 유사한 유형의 기존 기법들 대비 개선된 정확도를 보인다. 구체적으로는, 다중 스케일 헤시안들의 고윳값들(eigenvalues)을 토대로 한 특징 벡터(feature vector)를 정의한 후, 랜덤 포레스트 기반 회귀분석(regression)을 통해 혈관도 값에 대응되는 혈관 확률 값을 더 정확하게 도출하고자 한다.

II. 제안하는 기법

본 연구에서 제안하는 알고리즘은 그림 1과 같이 크게 세 단계로 구분할 수 있다. 첫째, 다중 스케일에서 헤시안 행렬의 고윳값 분석을 통해 혈관을 증강(enhancement)하고 둘째, 헤시안-고윳값 특징벡터를 이용하여 랜덤 포레스트 판별기를 학습하고 셋째, 학습된 판별기를 테스트함으로써 최종 영역화 결과를 얻는다.

1. 다중 스케일 Hessian 기반 필터링을 통한 혈관 증강

이차원 혈관조영영상에서의 헤시안 행렬 기반 필터링은 각 픽셀마다 고윳값(λ_1, λ_2) 분석을 통해, 두 고윳값의 벡터 크기와 두 값 간의 비율을 이용하여 각 픽셀이 혈관일 가능성(likelihood)을 결정하는 것이라 할 수 있다. 본 연구에서 다룰 영상과 같이 혈관이 배경에 비해 어두운 경우, 혈관 중심 축이 식(1)과 같은 기준에 따르게 된다.

$$\begin{aligned} \lambda_1 &\approx 0; \\ |\lambda_1| &\ll |\lambda_2| \end{aligned} \tag{1}$$

고윳값 분석을 바탕으로 Frangi *et al.* [1]은 각 픽셀 p가 혈관일 가능성(likelihood)을 의미하는 혈관도(vesselness) 값을 계산하는 식(2)를 제안하였다. R_B 는 관 형태의 구조물(tubular structure)을 측정하기 위한 기하학적 비율 나타내고, S 는 Hessian 행렬의 norm으로써 구조물의 여부를 구분할 수 있는 구조도(structureness)를 말한다. 예를 들어, 대조도(contrast)가 낮고 구조물이 없는 배경에서는 고윳값(λ_1, λ_2)이 작아 그 수치가 낮게 나타나므로 혈관과 배경을 구분할 수 있게 된다. 이때, β 와 γ 는 각각 R_B 와 S 의

민감도에 영향을 미치는 임계값(threshold)을 의미한다. 즉, 혈관도 값은 식(2)와 같이 두 measure R_B 와 S 를 이용하여 혈관일 확률을 나타낸다고 할 수 있다.

$$v_{\text{Frangi}}(\mathbf{p}) = \begin{cases} 0 & \text{if } \lambda_2 < 0, \\ \exp\left(-\frac{R_B^2}{2\beta^2}\right) \left(1 - \exp\left(-\frac{S^2}{2\gamma^2}\right)\right) & \end{cases} \quad (2)$$

$$R_B = \frac{|\lambda_1|}{|\lambda_2|}, \quad S = \sqrt{\lambda_1^2 + \lambda_2^2}$$

식(2)에서 v 가 특정 스케일 σ 에서의 혈관도를 나타낸다고 할 때, 다중 스케일로 확장하면 식(3)과 같이 나타낼 수 있다. 픽셀마다 가장 큰 혈관도 값인 $\max_{\sigma} v$ 와 그에 상응하는 스케일을 출력함으로써, 다양한 두께의 혈관을 검출할 수 있게 된다. 스케일 σ 이 클수록 두꺼운 혈관을 검출할 수 있다.

$$V(\mathbf{p}) = \max_{\sigma_{\min} \leq \sigma \leq \sigma_{\max}} v(\mathbf{p}, \sigma) \quad (3)$$

2. 랜덤 포레스트 판별기 학습 및 테스트

X-선 혈관조영영상에서의 혈관 영역화를 위해 헤시안 고윳값 분석을 통한 혈관증강기법이 자주 이용되지만, 혈관의 형태의 지역적 일관성(local coherence)을 고려하지 않기 때문에, 혈관 형태와 유사한 모양을 갖는 도관, 횡격막, 늑골, 척추 등 잡음(noise)까지 증강되는 경우가 있다. 또한, 교차(cross)나 분기(branching) 등 혈관 내강(lumen)의 잡음으로 인해 혈관이 끊기는 경우가 발생하여 최종 영역화 단계에까지 영향을 미칠 수 있다. 따라서, 본 연구에서는 랜덤 포레스트 판별기 학습을 통해 혈관 검출의 확률을 높임으로써 영역화의 정확도를 높이고자 한다.

(1) 랜덤 포레스트(Random Forest) 리뷰

랜덤 포레스트는 여러 개의 의사결정트리(Decision tree)로 구성된 Bagging 기법[5]과 Random subspace 기법[6]을 조합한 기법으로, 2001년에 Leo Breiman[7]에 의해 고안되었다. 각 노드에서 후보를 분할 때, Bagging은 현재 노드에 주어진 모든 변수에 대해 판단을 하지만, 랜덤 포레스트는 전체가 아닌 무작위로 샘플링한 일부 변수에 대해서만 판단하여 자식노드를 생성함으로써 Bagging에 비해 수행시간이 짧다는 장점이 있다.

의사결정트리를 생성하는 과정인 학습 단계가 완료되면, 새로운 데이터에 대한 예측을 수행하는 테스트 단계를 거쳐 최종결과를 도출하게된다. 이때 하나의 의사결정트리는 과대적합(overfitting)으로 인한 큰 분산 때문에 정확도가 낮은 반면, 랜덤 포레스트는 다수의 의사결정트리를 통해 도출된 예측결과 중 과반수 투표(majority voting)를 통해 결

정하거나 평균값을 적용하여 과대적합을 방지함으로써 상대적으로 정확도가 높아진다는 장점이 있다. 또한, 랜덤 포레스트는 방대한 데이터베이스에서도 효과적이고 높은 정확도를 보인다.

랜덤 포레스트 판별기를 학습하는데 필요한 매개변수로는 트리의 최대 깊이와 최대 개수가 있다. 먼저, 트리의 최대 깊이는 얕을수록 과소적합, 깊을수록 과대적합할 가능성이 있고 트리의 최대 개수는 많을수록 정확도는 높아지지만 예측 수행시간이 선형증가하게 된다.

(2) 학습에 필요한 데이터베이스(DB) 구축

랜덤 포레스트 판별기 학습에 필요한 학습 데이터를 구성하는 positive set과 negative set을 생성하기 위하여, 혈관을 전경(foreground)으로 mask한 영상을 활용한다. 먼저 positive set은 mask 영상에서 확실하게 혈관이라 여겨지는 중심선(centerline) 위의 픽셀들 중 무작위로 추출한 픽셀에서 특징 벡터를 추출함으로써 생성한다. 반면, negative set은 중심선과 그 주변을 제외한 나머지 배경(background) 중 무작위로 선정된 픽셀에서의 특징 벡터를 추출함으로써 생성된다.

(3) 특징 벡터 추출

생성된 positive, negative set에 대해 이전 단계에서 분석한 스케일 σ_1 에서의 고윳값(λ_1, λ_2)을 조합한 특징 벡터(feature vector) $f(\mathbf{p})$ 를 추출하게 되는데, 각 픽셀 \mathbf{p} 에서의 특징 벡터는 식(4)와 같이 두 고윳값 λ_1, λ_2 , 두 값의 비율, 그리고 두 고윳값으로 구성된 2차원 벡터의 절대값 등을 이용하여 다음과 같이 정의된다:

$$f_{\sigma_1}(\mathbf{p}) = \left(\lambda_1, \lambda_2, \frac{|\lambda_1|}{|\lambda_2|}, \sqrt{\lambda_1^2 + \lambda_2^2} \right). \quad (4)$$

이때 입력 영상의 취득 환경에 따라 밝기값의 범위가 다를 수 있으므로 각 수치들은 두 고윳값의 2차원 벡터 절대값의 최대 및 최소 값을 바탕으로 정규화(normalization)하여 사용한다. 또한, 다양한 굵기의 혈관 추출을 위해 본 기법에서는 다양한 스케일의 Hessian 고윳값을 활용하여 전체 특징 벡터 $f(\mathbf{p})$ 는 다음과 같이 정의된다:

$$f(\mathbf{p}) = (f_{\sigma_1}(\mathbf{p}), f_{\sigma_2}(\mathbf{p}), \dots, f_{\sigma_n}(\mathbf{p})) \quad (5)$$

이때, n 은 사용하게 되는 스케일의 갯수를 의미한다.

(4) 랜덤 포레스트 판별기 학습 및 테스트

구축한 DB의 특징 벡터를 기반으로 랜덤 포레스트 판별기를 학습하게 된다. 포레스트를 구성하는 개별적인 트리 학

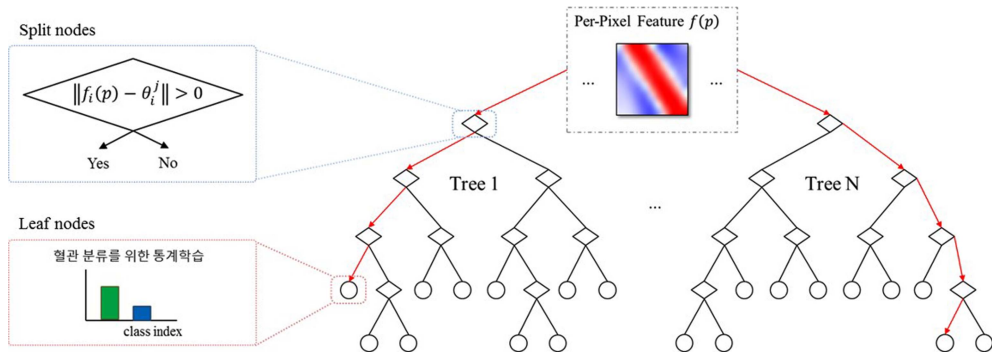


그림 2. 랜덤 포레스트 판별기를 통한 학습 (혈관 확률 추정).
 Fig. 2. A diagram of Random Forest, applied to the proposed algorithm.




그림 3. 이차원 X-선 조영영상에서의 혈관 영역화 결과: (a) 원본 영상, (b) 수동 영역화, (c) Frangi *et al.* [1], (d) Krissian *et al.* [2], (e) 제안 알고리즘.
 Fig. 3. Vessel segmentation results in X-ray angiograms: (a) original image, (b) manual segmentation, (c) Frangi *et al.* [1], (d) Krissian *et al.* [2], (e) proposed algorithm.

습에는 앞서 구축했던 전체 DB 중 무작위로 추출된 학습 데이터가 이용되며, 각 노드(non-leaf node)에서의 결정은 특징 벡터의 원소 중 하나에 대한 대소 판별(thresholding)이라는 단순한 형태로 정의된다. 본 연구에서는 식(6)과 같이 $f(p)$ 의 i 번째 원소로부터 임계값(threshold) θ_i^j 까지의 거리로 나타내었다. 즉, 각 non-leaf node에서는 대소 판별을 할 때의 임계값(threshold)을 학습한다고 할 수 있다.

$$\|f_i(p) - \theta_i^j\| > 0 \tag{6}$$

테스트 단계에서는 입력 영상의 픽셀 p 의 특징 벡터 $f(p)$ 를 추출한 다음, 이미 학습된 모든 개별적인 트리를 거치고, 최종적으로 모든 트리의 잎 노드(leaf node)는 해당 픽셀이 혈관에 속할 확률을 가지게 된다. 그림 2는 랜덤 포레스트가 본 연구에 어떻게 적용되었는가를 보여준다.

III. 실험 및 결과

본 연구에서 제안한 랜덤 포레스트를 이용한 혈관 자동 영역화 알고리즘의 성능을 평가하기 위해 기존에 혈관 영역화에 자주 이용되어왔던 Frangi *et al.* [1]과 Krissian *et al.* [2]이 제안한 자동 영역화 기법들과 비교하는 실험을 수행하였다.

각 기법을 통해 얻어진 결과는 다년간 훈련된 판독자가 수동으로 분할한 결과(manual segmentation)인 혈관 mask영상과의 민감도(sensitivity, 참값의 혈관 영역 가운데 자동 분할에서도 혈관으로 인식된 영역의 비율) 및 DSC (Dice Similarity Coefficient, 수동 또는 자동 분할된 결과에서 혈관인 영역 가운데 둘 모두에서 혈관인 영역의 비율)을 척도로 비교하였다.

성능 실험은 Intel(R) Core(TM) i7-3770K CPU, 16 GB RAM 사양의 PC에 C++로 구현된 프로그램을 이용하여 수행되었다. 랜덤 포레스트의 학습 및 적용을 위한 코드는 OpenCV 라이브러리[8]를 활용하였다. 랜덤 포레스트 판별기 학습에 이용한 원본영상과 혈관 mask 영상은 각각 1,853 장씩으로 구성되며, 모든 영상의 해상도는 512×512 이다. 전체 영상데이터 중 절반은 학습 집합(training set)으로, 나머지는 실험 집합(test set)으로 구성하였다. 학습 단계에서 positive set과 negative set은 각각 29,905개씩 생성되었다. 그리고 식(4)에서 언급한 것과 같이 교차값을 이용한 네 가지의 특징과 다섯 가지 스케일을 조합함으로써 각 픽셀은 20개의 특징 벡터를 갖게 된다. 랜덤 포레스트를 구성하는 트리의 최대 개수는 50개, 최대 깊이는 50으로 설정하여 실험을 수행하였다.

총 349 프레임에 대해 각 영역화 기법의 유사도 측정 실

표 1. 제안 알고리즘의 유사도 측정 결과.

Table 1. Similarity measurement results of the proposed algorithm.

	제안 알고리즘	Frangi <i>et al.</i> [1]	Krissian <i>et al.</i> [2]
민감도 (%)	67	29	39
DSC (%)	56	18	23

*DSC: Dice Similarity Coefficient




그림 4. ROC (receiver operating characteristic) 곡선을 이용한 제안 기법 및 타 두 기법 간의 성능 비교.

Fig. 4. ROC (receiver operating characteristic) curve for proposed method, Frangi *et al.*, and Krissian *et al.*

험 결과 표 1에서 볼 수 있듯이, 제안 알고리즘은 67%의 민감도와 56%의 DSC를 보였으며, Frangi *et al.* [1]과 Krissian *et al.* [2] 기법에 비해 민감도는 약 38%, 28% 씩 높게, 그리고 DSC는 약 38%, 33% 씩 높게 측정되었다. 또한, 그림 3은 다섯 프레임에 대한 영역화 결과를 정리한 것으로, 육안으로 보았을 때, 제안 알고리즘을 적용한 영역화 결과에서 타 두 기법에 비해 false positive가 확연히 감소한 것을 확인할 수 있다.

또한, 본 알고리즘은 다중스케일 기반이므로 스케일의 개수 변화에 따른 성능을 평가하기 위해 같은 스케일 범위 내에서 3개, 5개, 7개 스케일에 대해, 그리고 다른 스케일 범위를 가지는 5개의 스케일 세 종류에 대해 민감도와 DSC 성능평가를 수행한 결과, 5개의 스케일을 사용했을 때에 1.5% 내외의 차이로 조금 높은 유사도를 보였다. 또한, 제안한 알고리즘의 보다 객관적인 성능 평가를 위해, 그림 4와 같이 0 부터 1 까지 0.1 간격으로 10개의 임계값(threshold)에 대하여 민감도와 1-특이도를 ROC (receiver operating characteristic) 곡선으로 나타낸 결과, Frangi




그림 5. 혈관과 모양 및 대조도가 비슷한 비관심영역(노란색 화살표)이 검출된 경우: (a) 원본 영상, (b) 수동 영역화, (c) Frangi *et al.* [1], (d) Krissian *et al.* [2], (e) 제안 알고리즘.

Fig. 5. Detection of non-vessel region (indicated by yellow arrows): (a) original image, (b) manual segmentation, (c) Frangi *et al.* [1], (d) Krissian *et al.* [2], (e) proposed algorithm.

et al. [1]과 Krissian *et al.* [2] 기법에 비해 전반적으로 True positive rate(민감도)는 높고 False positive rate(1-특이도)는 낮은 결과를 보였다.

학습 단계에 소요되는 시간은 학습 집합의 규모에 따라 결정되는 데, 본 실험에서는 약 2분 30초가 소요되었으며, 실험 단계에서 혈관을 영역화 하는데에는 한 프레임 당 약 4.5초가 소요되었다.

IV. 논 의

앞서 실험을 통해 제안 알고리즘을 이용한 영역화 결과의 정확도가 기존의 헤시안 기반 필터링 기법만을 적용한 결과와 비교하여 높다는 결론을 도출했으나, 몇 가지 한계점이 존재한다. 첫 번째로 보통 X-선 혈관조영영상은 여러 장의 시퀀스로 구성되는데, 본 연구에서 제안한 알고리즘은 입력된 하나의 프레임에서 얻을 수 있는 정보만 이용하기 때문에 활용할 수 있는 특징 정보가 제한적이다. 따라서 인접한 프레임간의 연관성을 또 다른 특징 벡터로 활용함으로써 영역화 결과를 개선하는 후속 연구를 진행 중이다.

두 번째 한계점은 이차원 X-선 혈관조영영상은 혈관 뿐만 아니라 늑골, 횡격막, 척추 등 비관심영역도 포함되어 있는 경우가 많은데다, 그림 5와 같이 혈관과 그 모양과 대조도가 비슷한 경우에는 헤시안 행렬의 고윳값 분석으로 구분해 내기가 쉽지 않다. 따라서 그들을 미리 제외시킬 수 있다면 혈관 영역화의 정확도를 높일 수 있을 것이다.

V. 결론 및 기대효과

본 논문에서는 이차원 X-선 혈관조영영상에서 헤시안 행렬의 고윳값 분석과 랜덤 포레스트 판별기 학습을 통해 자동으로 혈관을 영역화하는 기법을 제안하였다. 먼저, 혈관의 가늘고 긴 특징을 추출하기 위해, 다중스케일 헤시안 기반 필터링을 통해 혈관을 증강시킨다. 그리고 고윳값과 다양한 스케일을 조합한 특징벡터를 기반으로 한 학습 데이터를 생

성한 후, 랜덤 포레스트 판별기를 학습하고, 마지막으로 학습된 판별기를 통해 최종 영역화 결과를 얻는다. 즉, 제안 기법은 다중스케일 기반 특징 벡터를 활용하며, 랜덤 포레스트 판별기를 학습할 때, 혈관과 배경을 구분하기 위해 스스로 유용한 스케일의 특징을 선택한다는 장점을 갖는다. 따라서 어느 정도 유용한 스케일 범위를 적용한다면, 스케일 개수를 변화시키더라도 성능에 크게 영향을 미치지 않는다.

총 349 테스트 프레임에 대상으로 수동 분할된 결과와의 유사도(similarity)를 측정하는 실험을 수행한 결과, 제안하는 기법은 유사한 유형의 대표적인 기법들보다 정확도가 우수함을 실험을 통해 확인하였다.

본 알고리즘을 적용하여 얻은 이차원 혈관 영역화 결과는 관상동맥 중재술 과정에서 시술자가 혈관의 협착 정도를 보다 정확하게 파악하고, 삼차원 CT 혈관 영역화 결과와의 정합을 통해 더 이상 감에 의존하지 않고 올바른 방향으로 도관을 삽입할 수 있도록 유도하여 시술의 정확성을 높이는데 활용될 수 있을 것이다.

Reference

- [1] A.F. Frangi, W.J. Niessen, K.L. Vincken, M.A. Viergever, "Multiscale vessel enhancement filtering," in Medical Image Computing and Computer-Assisted Intervention - MICCAI'98, Lecture Notes in Computer Science, vol. 1496 - Springer Verlag, Berlin, Germany, Oct. 1998, pp. 130-137.
- [2] K. Krissian, G. Malandain, N. Ayache, R. Vaillant, and Y. Troussel, "Model based detection of tubular structures in 3D images," Computer Vision and Image Understanding, vol. 80, no. 2, pp. 130-171, 2000.
- [3] Fraz, M. M., Remagnino, P., Hoppe, A., Uyyanonvara, B. "An Ensemble Classification-Based Approach Applied to Retinal Blood Vessel Segmentation." Biomedical Engineering, IEEE Transactions on vol. 59, no. 9, pp. 2538-2548, 2012.
- [4] Gupta, V., Kale, A., & Sundar, H. "A robust and accurate approach to automatic blood vessel detection and segmentation from angiography x-ray images using multistage random forests," in SPIE Medical Imaging 2012: Computer-Aided Diagnosis, vol. 8315, pp. 83152F-83152F-6

- [5] L. Breiman, "Bagging Predictors." Machine Learning, vol. 24, no. 2, pp. 123-140, 1996.
- [6] T. Ho, "The random subspace method for constructing decision forests." Pattern Analysis and Machine Intelligence, IEEE Transactions on, vol. 20, no. 8, pp. 832-844, 1998.
- [7] L. Breiman, "Random Forests," Machine Learning, vol. 45, no. 1, pp. 5-32, 2001.
- [8] Open Source Computer Vision Library, <http://opencv.org>.