

A3C 기반 안저영상 왜곡 보정 기법

천성진*, 추현승**

*성균관대학교 인공지능학과, **성균관대학교 소프트웨어대학

chunsoungjin@skku.edu*, choo@skku.edu**

A3C-based Fundus Image Distortion Correction Technique

Sungjin Chun*, Hyunseung Choo**

*Dept. of Artificial Intelligence, Sungkyunkwan University

**College of Software, Sungkyunkwan University

요약

안저 영상 촬영기술이 발달되며 진단에 사용되는 안저 영상에는 시각적으로 많은 변화가 일어났다. 새로운 촬영 기법인 초광각 안저 영상은 기존 영상에 비해 넓은 범위의 영상을 생성할 수 있다. 촬영 범위가 넓어짐에 따라 이미지에는 왜곡이 발생하고, 이로 인해 안저 영상을 통한 황반 부위 진단에 어려움을 야기하기도 한다. 본 논문에서는 이러한 왜곡을 보정하고 초광각 안저 영상을 기준 안저 영상의 영역으로 변환하는 시스템을 강화학습을 통해 구축한다. 제안하는 방법은 A3C 강화학습법을 사용하며 실험 결과는 제안 방법을 통해 안저 영상을 자동으로 변환할 수 있음을 보여준다.

1. 서론

광각 (UWF, ultrawide field) 안저 촬영술이 도입되며 기존 안저 촬영술에 비해 더 넓은 범위의 정보를 이미지에 담을 수 있게 되었다 [1]. 약 200° 범위의 정보를 한 장의 이미지에 담으며, 동일한 크기의 이미지에서 황반부 변성 정보가 소실되어 확인이 어려운 문제가 발생한다. 또한 기준에 45°로 촬영된 안저 영상과 비교하였을 때 왜곡이 발생하는 것을 확인할 수 있다.

본 논문에서는 강화학습을 이용하여 초광각 안저 촬영술로 찍힌 안저 영상을 기준 촬영 기법으로 생성된 안저 영상의 영역으로 바꾸는 기술을 제안한다. 강화학습 알고리즘은 Asynchronous Advantage Actor-Critic (A3C)을 사용한다. 제안하는 방법은 안저 영상 외의 다른 domain의 이미지를 처리할 때도 사용할 수 있을 것으로 기대한다.

2. Asynchronous Advantage Actor-Critic

A3C는 여러 Agent들이 탐색을 하며 비동기적으로 policy update를 하는 강화학습법이다 [2]. A3C는 보상에서 예측한 가치를 차감하는 Advantage 개념을 정의하고 이를 loss에 사용한다. Reward를 R, 예측한 가치를 V라 한다면 Advantage는 수식 1과 같이 표현된다.

$$\text{Advantage} = R - V \quad (1)$$

Advantage는 올바른 학습이 진행 중이거나 과소 평가가 발생한 경우 양의 값을, 과대평가가 이뤄진 경우 음의 값을 갖는다. A3C는 정의된 Advantage를 사용하여 두 가지 loss를 정의한다:

$$\text{Value loss} = \text{Advantage}^2 \quad (2)$$

Value loss는 Advantage의 제곱으로 정의한다. 이는 실제 받는 보상을 과대, 과소평가하지 않게 조절하는 역할을 한다.

Policy loss는 Softmax Cross Entropy를 이용하여 정의한다. Softmax는 어떤 입력 x 에 대해 수식 3과 같이 정의한다.

$$\text{Softmax}(x) = \exp(x) / \sum(\exp(x)) \quad (3)$$

어떤 입력 x 에 대한 분포를 $q(x)$, 목표하고자 하는 출력의 분포를 $p(x)$ 라 하면 수식 4와 같이 표현된다.

$$\text{Cross Entropy}(x) = -\sum(p(x) * \log(q(x))) \quad (4)$$

Softmax Cross Entropy는 Cross Entropy의 $q(x)$ 를 Softmax(x)로 대체한다. 즉, 어떤 입력의 분포 $q(x)$ 를 어떤 입력이 갖는 상대적 분포로 변환하여 입력으로

해석한다. Softmax Cross Entropy 를 S_CE 로 간략히 줄이면, 수식 5 와 같이 표현된다.

$$S_CE(p(x), x) = -\sum(p(x) * \log(\text{Softmax}(x))) \quad (5)$$

Policy loss 는 agent 의 action 을 label 로, Policy 의 output 을 logits 으로 사용한다. Cross Entropy 의 p(x)는 action 에, q(x)는 policy 에 대응한다. 수식 1 과 5 에 따라 Policy loss 를 수식 6 과 같이 정의한다.

$$\text{Policy loss} = S_CE(\text{action}, \text{policy}) * \text{advantage} \quad (6)$$

Policy loss 는 정책이 출력되는 확률이 확신을 갖고 학습하되, 학습에서 잘못된 경험이 발생한 것은 advantage 에 따라 역방향 학습이 이뤄질 수 있도록 구성된다. A3C 의 final loss 는 정의된 value loss (수식 2) 와 policy loss (수식 6)에 따라 수식 7 로 표현한다.

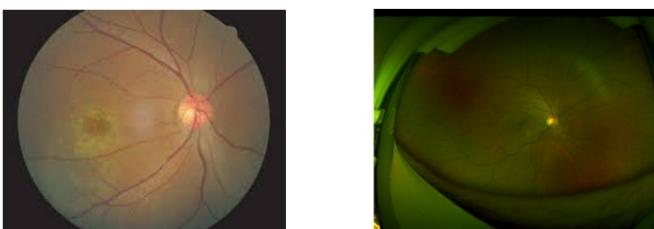
$$\text{Final loss} = \text{policy loss} + 0.5 * \text{value loss} \quad (7)$$

```
Algorithm S2 Asynchronous advantage actor-critic - pseudocode for each actor-learner thread.
// Assume global shared parameter vectors  $\theta$  and  $\theta_v$ , and global shared counter  $T = 0$ 
// Assume thread-specific parameter vectors  $\theta'$  and  $\theta'_v$ 
Initialize thread step counter  $t \leftarrow 1$ 
repeat
    Reset gradients:  $d\theta \leftarrow 0$  and  $d\theta_v \leftarrow 0$ .
    Synchronize thread-specific parameters  $\theta' = \theta$  and  $\theta'_v = \theta_v$ 
     $t_{start} \leftarrow t$ 
    Get state  $s_t$ 
    repeat
        Perform  $a_t$  according to policy  $\pi(a_t | s_t; \theta')$ 
        Receive reward  $r_t$  and new state  $s_{t+1}$ 
         $t \leftarrow t + 1$ 
         $T \leftarrow T + 1$ 
    until terminal  $s_t$  or  $t - t_{start} == t_{max}$ 
     $R = \begin{cases} 0 & \text{for terminal } s_t \\ V(s_t, \theta'_v) & \text{for non-terminal } s_t \end{cases}$  // Bootstrap from last state
    for  $i \in \{t-1, \dots, t_{start}\}$  do
         $R \leftarrow r_i + \gamma R$ 
        Accumulate gradients wrt  $\theta'$ :  $d\theta \leftarrow d\theta + \nabla_{\theta'} \log \pi(a_i | s_i; \theta') (R - V(s_i; \theta'_v))$ 
        Accumulate gradients wrt  $\theta'_v$ :  $d\theta_v \leftarrow d\theta_v + \partial (R - V(s_i; \theta'_v))^2 / \partial \theta'_v$ 
    end for
    Perform asynchronous update of  $\theta$  using  $d\theta$  and of  $\theta_v$  using  $d\theta_v$ .
until  $T > T_{max}$ 
```

(그림 1) A3C 알고리즘 의사 코드 [2]

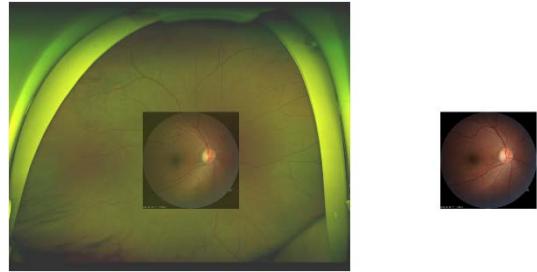
3. A3C based Fundus Image Processing System

A3C 를 사용하여 안저영상 변환을 처리하는 모델을 구축한다. 변화하고자 하는 안저 영상은 그림 2 와 같다.



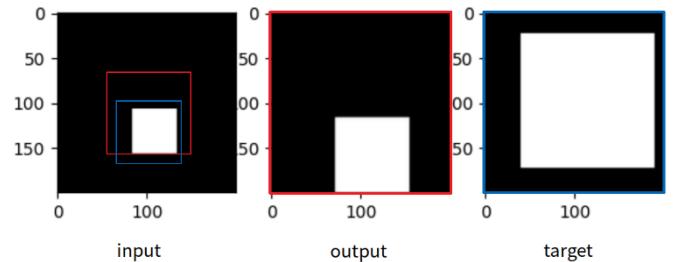
(그림 2) 기존 안저영상(좌), 초광각 안저영상(우)

초광각 안저영상을 사용한 진단은 기존의 안저영상으로 진단할 수 있는 병변을 놓칠 수 있는 가능성이 있다 [3]. 이를 해결하기 위해 촬영기법이 바뀜에 따라 소실되거나 놓칠 수 있는 정보를 초광각 안저영상에 기존의 안저영상 정보를 입힐 수 있는 시스템을 제안한다.



(그림 3) 기준 안저영상과 초광각 안저영상의 촬영 영역

그림 3 에서 볼 수 있듯이, 기준 안저영상으로부터 추가될 정보들은 초광각 안저영상의 특정 영역에 mapping 된다. 강화학습 agent 는 이러한 영역을 자동으로 탐색하고 영상에서 자동으로 cropping 하는 action 을 하도록 디자인한다. 초광각 안저사진에서 cropping 될 목표 영역과 그 외의 영역을 추상화하여 agent 의 입력으로 사용한다. 목표 영역을 흰색, 그 외의 영역을 검은색으로 추상화하고 agent 는 cropping window 의 좌표 값을 action 출력 값으로 갖는다. Agent 가 출력한 좌표 값을 따라 cropping window 를 설정하고 cropping window 를 따라 이미지를 잘랐을 때 결과 이미지가 목표 영역과 일치하는 정도에 따라 reward 를 설정한다.

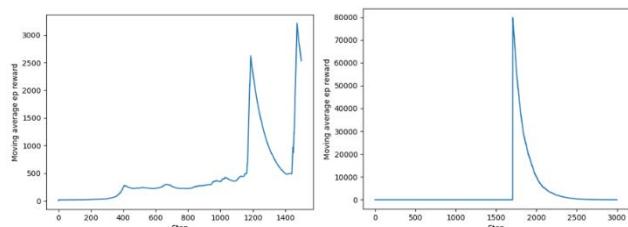


(그림 4) target area (blue), action window (red)

그림 4 의 red window 은 agent 의 action output 을 따라 설정된다. 설정된 red window 을 따라 최종 output 영상이 설정되고, 환경은 target area 와 최종 output 영상의 차를 이용하여 reward 를 계산한다. 이러한 작업은 A3C 의 각 agent 별로 반복되며 탐색하고 학습된다.

4. 실험 환경 및 결과

Reward 는 target area 좌표와 red window 좌표의 distance 를 기반으로 구성한다. 추가적으로 Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM), 그리고 RMSE (pixel by pixel) 를 사용하였다. RMSE (pixel by pixel) 는 penalty reward 로 사용한다. 실험을 진행하며 평균적인 reward 그래프를 출력하여 학습의 정도를 비교하고 분석한다. CartPole 문제를 A3C 로 해결하고 도출된 reward 그래프를 대조군 그래프로 사용한다. 제안한 방법의 학습 정도를 reward 그래프로 표현하고 두 그래프를 비교 분석한다.



(그림 5) 수렴 완료된 CartPole reward 그래프(좌),
제안하는 방법의 reward 그래프(우)

A3C는 병렬 탐색 특성과 주기적인 optimal policy 를 master agent로부터 동기화 받는 특성에 의하여 학습 진행에 따른 평균 reward 그래프가 뒤는 형태를 띤다. 그림 5의 왼쪽 그래프는 학습이 비교적 쉽게 이뤄지는 CartPole 문제를 해결하며 그려지는 A3C의 평균 reward 그래프다. 그림 5의 오른쪽 그래프는 제안하는 방법이 학습 중에 만드는 그래프이며, 그래프 양상을 비교하면 탐색 횟수, reward의 spike 정도는 다르지만 동일하게 학습이 진행됨을 확인할 수 있다.

5. 결론 및 향후 연구 계획

제안하는 방법을 통해 안저 이미지 처리 과정을 확인할 수 있다. 이러한 시스템을 기반으로 이미지 처리를 강화학습을 통해 처리하고 출력된 이미지를 기반으로 warping domain 을 맞출 수 있다. 학습된 모델은 이미지를 입력을 받아 목표하는 영역으로 자동으로 처리하는 모델이다. 진행된 연구 결과를 기반으로 3000 x 3000 초광각 안저 영상 입력을 자동으로 alignment 하는 시스템 연구를 계속할 예정이다.

Acknowledgement

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 글로벌핵심인재양성지원사업 (2019-0-01579), ICT 명품인재양성 사업(IITP-2020-0-01821), 인공지능대학원 (No.2019-0-00421)의 지원을 받아 수행된 연구임

참고문헌

- [1] Takao Hirano, et al. "Assessment of diabetic retinopathy using two ultra-wide-field fundus imaging systems, the Clarus® and Optos™ systems," *BMC ophthalmology* 18.1 (2018): 1-7.
- [2] Mnih Volodymyr, et al. "Asynchronous methods for deep reinforcement learning," International conference on machine learning, PMLR, 2016.
- [3] Lee, Dong Hyun, et al. "Identifiable peripheral retinal lesions using ultra-widefield scanning laser ophthalmoscope and its usefulness in myopic patients." *J Korean Ophthalmol Soc* 55.12 (2014): 1814-1820.