

논문 2018-13-36

웨이블릿 퓨전에 의한 딥러닝 색상화의 성능 향상

(High-performance of Deep learning Colorization With Wavelet fusion)

김 영 백*, 최 현, 조 중 휘
(Young-Back Kim, Hyun Choi, Joong-Hwee Cho)

Abstract : We propose a post-processing algorithm to improve the quality of the RGB image generated by deep learning based colorization from the gray-scale image of an infrared camera. Wavelet fusion is used to generate a new luminance component of the RGB image luminance component from the deep learning model and the luminance component of the infrared camera. PSNR is increased for all experimental images by applying the proposed algorithm to RGB images generated by two deep learning models of SegNet and DCGAN. For the SegNet model, the average PSNR is improved by 1.3906dB at level 1 of the Haar wavelet method. For the DCGAN model, PSNR is improved 0.0759dB on the average at level 5 of the Daubechies wavelet method. It is also confirmed that the edge components are emphasized by the post-processing and the visibility is improved.

Keywords : Infrared, Colorization, Deep learning, Post-processing, Wavelet fusion

1. 서 론

RGB, Infrared (적외선), Near Infrared (근적외선) 등 많은 종류의 카메라가 CCTV, 차량용 카메라, 휴대용 카메라, 군사용 카메라와 같이 다양한 분야에 사용되고 있다. RGB 영상의 경우에는 가시광선이 거의 없는 야간 환경에서 영상을 찍으면 정보가 거의 없어 사람이나 컴퓨터 시스템이 영상을 해석하기가 까다롭다. 따라서 야간 환경에서 의미가 있는 정보를 갖는 영상을 얻기 위해서는 적외선 파장대의 카메라를 사용하는데 적외선 카메라의 경우, 촬영을 통해 얻어지는 영상은 단일 채널의 영상이다. 사람이나 컴퓨터 시스템은 다채널 영상으로부터의 인식 성능이 높으므로 적외선 카메라를 통해 얻은 영상을 RGB 칼라 영상으로 색상화하는 연구가

필요하였다. 사용자가 seed 컬러를 지정하고 색상화하는 방법 [1]이 개발되었으나, 딥러닝 기술의 도입으로 사용자 개입 없이 적외선 영상을 자동으로 색상화가 가능하게 되었다 [2-6]. 하지만 휘도 성분이 다소 왜곡되는 문제점이 있다. 따라서, 본 논문에서는 딥러닝으로 색상화를 하는 몇 가지 모델들에 대해서 살펴보고 문제점을 파악 후, 색상화 성능 향상을 위한 후처리 방법을 제안한다. 제안한 후처리에 대한 다양한 실험을 수행하여 제안한 알고리즘의 우수성을 보인다.

II. 딥러닝에 의한 색상화 분석

딥러닝을 사용한 색상화 방법은 픽셀 단위의 세그멘테이션 모델 [5]과 이미지 생성이 가능한 DCGAN 모델 [6]로 크게 나누어지는데 본 논문에서는 두 가지 모델을 사용한 색상화 개념을 설명하고 이들의 문제점을 분석하고자 한다. 본 논문에서는 딥러닝의 학습을 위해 [EPFL-IC-IVRL]에서 제공되는 NIR-RGB dataset을 사용하였다. 이 dataset은 1024*680의 해상도를 갖는 총 477쌍의 NIR-RGB 이미지로 이루어져 있다. 이 중 학습에 332장의 이미지, 테스트를 위해 145장의 이미지를 사용하였다.

*Corresponding Author (yback7902@inu.ac.kr)

Received: Sep. 11 2018, Revised: Oct. 23 2018, Accepted: Oct. 26 2018.

Y.B. Kim, H. Choi, J.H. Cho: Incheon National University

※ 본 논문은 인천대학교 2018년도 자체 연구비 지원에 의하여 연구되었음.

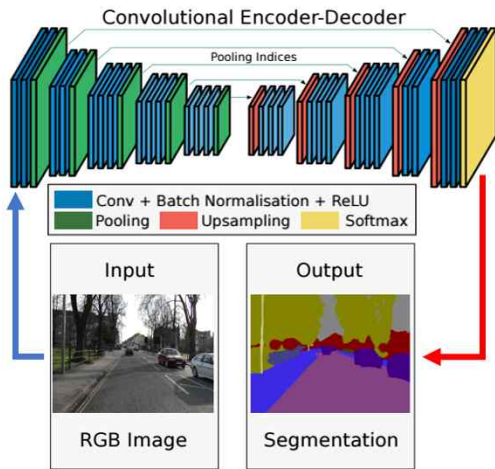


그림 1. SegNet 구조
Fig. 1 SegNet architecture




그림 3. SegNet 기반의 색상화 결과
Fig. 3 SegNet based colorization results




그림 2. SegNet 기반의 색상화 모델
Fig. 2 SegNet based colorization model

1. SegNet 기반 색상화 모델

세그멘테이션의 대표적 모델인 SegNet [7]은 그림 1과 같이 표현된다. SegNet을 기반으로 한 색상화 모델 [5]은 그림 2와 같이 SegNet 구조를 RGB이미지의 각 채널 학습을 진행하여 입력 NIR 이미지를 색상화 한다.

SegNet 기반의 색상화 모델을 이용한 NIR 이미지 색상화 결과는 그림 3의 오른쪽과 같다. 가운데의 실제 이미지와 비교하여 에지 부분이 모호하다. 이와 같은 원인 분석을 위하여 그림 4에 원본 이미지의 Y채널과 색상화 결과 이미지의 Y채널을 비교하였다. 원본 Y채널과 비교했을 때, 출력 이미지의 픽셀 값이 낮고, 에지 성분들이 모호하여 이미지의 세부적인 특징이 표현되지 못하고 영상 정보 손실이 존재하는 것을 볼 수 있다. 따라서 RGB 이미지의 색감과 에지 성분을 강화하기 위한 후처리가 필요하다.




그림 4. 원본과 출력 이미지의 휘도 성분 비교
Fig. 4. Comparison of luminance components between ground truth and output images

2. DCGAN 기반 색상화 모델

DCGAN은 이미지를 생성하는 Generator 모델과 이미지를 판별하는 Discriminator 모델로 구성되는데 DCGAN 구조 기반의 색상화 모델 [6]은 그림 5와 같은 방법으로 학습을 진행한다. DCGAN 기반 색상화 모델은 Generator 신경망의 U-Net [8]과 Discriminator 신경망의 CNN이 서로 대립하며 학습한다. 학습 과정에서는 Generator 신경망에 NIR 이미지를 입력하면 색상화 이미지가 생성되며, Discriminator가 Generator의 생성 이미지와 Ground truth를 참/거짓으로 변갈아가며 판별하면

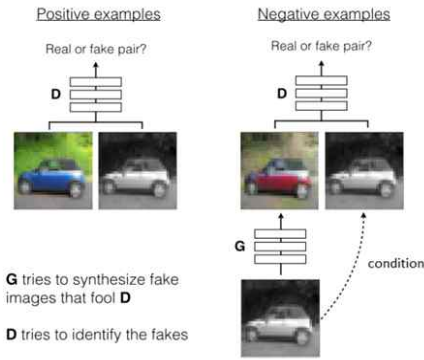


그림 5. DCGAN 기반 색상화 모델 학습 알고리즘
Fig. 5 DCGAN based colorization model training algorithm

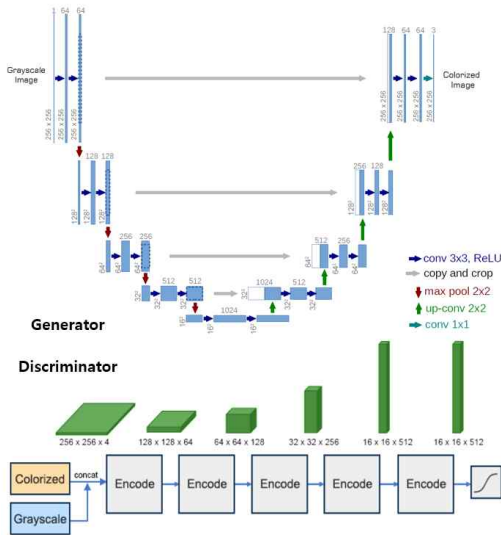


그림 6. DCGAN 기반의 색상화 모델
Fig. 6 DCGAN based colorization model

서 두 신경망 모델 파라미터가 업데이트된다. 이와 같은 동작을 반복하여 신경망을 완성하고 그림 6과 같은 구조로 이루어진 신경망 중 Generator 부분만이 최종적으로 DCGAN 기반의 색상화 신경망으로 사용된다.

[6]에서 색상화에 사용된 DCGAN 신경망 구조는 Convolutional layer, Pooling layer, ReLU activation layer 등으로 이루어진 Generator와 Convolution layer, Batch normalization, LeakyReLU, Dropout, Max pooling layer을 포함하는 Encode unit으로 이루어진 Discriminator로




그림 7. DCGAN 기반의 색상화 결과
Fig. 7 DCGAN based colorization results

구성되어 있다. 이 모델을 사용한 색상화 결과는 그림 7에 나타내었는데 색상화된 이미지를 살펴보면 SegNet 모델 기반에 비교하여 보다 자연스러운 색감을 보인다. 하지만 결과 이미지의 에지 부분이 모호하고 그림 7 (a)에서는 울타리와 같은 영상 정보가 손실되는 문제점이 있다. 따라서 SegNet과 마찬가지로 에지 성분을 강화하는 후처리 방법이 필요하다.

III. 제안하는 후처리 알고리즘

3장에서는 기존 색상화 결과 이미지의 특징을 강화하여 색상화 품질을 개선하는 후처리 방법을 서술한다. 제안 알고리즘은 색상화 결과 이미지의 휘도 성분 Y채널과 입력 NIR 이미지의 웨이블릿 퓨전으로 수행하는데 웨이블릿 융합 파라미터 선택과 웨이블릿 기법에 대한 선택을 성능 분석과 함께 진행한다.

1. 제안하는 시스템 개요

이미지 융합은 보편적으로 두 이미지의 특징을 적절하게 반영하여 보다 많은 영상 정보를 나타내기 위해 사용된다. 두 신경망 [5, 6]의 칼라화 결과




그림 8. 딥러닝과 웨이블릿 융합에 의한 색상화

Fig. 8 Colorization by deep-learning and wavelet fusion

이미지의 에지 성분이 모호하고 손실되는 영상 정보가 존재하기 때문에 색상화 품질이 떨어진다. YCbCr 색상 공간으로 변환하여 CbCr의 색감 정보는 색상화 결과를 그대로 가져가되, Y채널의 경우, 입력 NIR 이미지의 경우 휘도 정보가 원본과 동일하게 포함되어 있어 색상화 결과에 적용이 가능하다. 따라서 그림 8과 같이 이미지의 휘도 성분을 강화시켜 색상화 품질을 높이는 방법을 제안한다.

입력 NIR 이미지가 딥러닝에 의해서 색상화가 된 RGB 이미지가 출력이 되면 이를 YCbCr 색공간으로 변화시킨다. 입력 NIR 이미지와 YCbCr로 변환된 이미지의 Y채널을 웨이블릿 융합한다. 융합된 Y' 이미지는 이전의 변환된 CbCr 채널과 합치고 다시 RGB 이미지로 변환하여 최종 색상화 이미지로 출력된다.

2. 웨이블릿 융합 파라미터 선정

입력 NIR 이미지와 색상화 결과 이미지의 휘도 성분을 웨이블릿 기반의 이미지 융합을 하였다. 웨이블릿 융합은 크게 세 과정으로 나뉜다. 첫째 과정은 융합하고자 하는 이미지를 웨이블릿 분해를 진행하여 이미지를 분해한다. 그림 9는 DCGAN 결과 이미지의 Y채널과 입력 NIR 이미지를 1단계 웨이블릿 분해한 결과이다. 웨이블릿 분해를 통해 얻은 이미지에서 저주파 성분 LL는 이미지의 전체적인 근사값 성분을 나타내고 그 외 고주파 성분들은 이미지의 전체적인 세부값 성분을 나타낸다. 둘째 과정은 분해된 이미지를 사용하여 이미지를 융합한다. 이 과정에서 이미지는 고주파 성분을 통해서 에지 성분이 강화되고 저주파 성분을 통해서 이미지의 근사값으로 정보를 유지하기 때문에 저주파, 고주파 성분 별로 융합을 진행한다. 셋째 과정은 융합 이미지를 웨이블릿 역변환을 수행하여 최종 이미지를 얻는다.

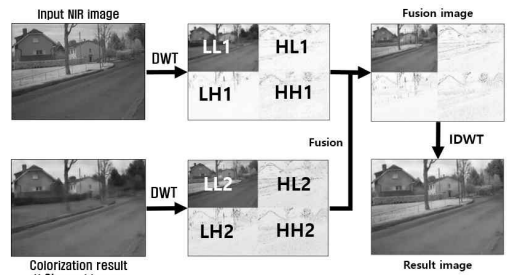


그림 9. 웨이블릿 변환 및 이미지 융합

Fig. 9 Wavelet transform and image fusion

표 1. 융합 파라미터에 따른 PSNR

Table 1. PSNR according to fusion parameters

Model	SegNet	DCGAN
Fusion parameter (approximations/details)	15.2465	19.1616
Max/Max	16.6171	19.1206
Max/Mean	16.6371	19.1446
Max/Min	16.5875	19.0925
Mean/Max	16.1020	18.4486
Mean/Mean	16.1545	18.5055
Mean/Min	16.0925	18.4358
Min/Max	14.8349	16.6689
Min/Mean	14.8480	16.6852
Min/Min	14.8286	16.6687
Wavelet method : haar / 1 level decomposition		

웨이블릿 융합에서의 첫째 과정 중 근사값 및 세부 값을 결정하는 융합 파라미터 설정을 위해 각 파라미터 선택에 따른 실험을 수행하였다. 표 1은 haar 웨이블릿 1단계 분해를 사용해서 Ground truth 이미지와의 PSNR 비교인데 DCGAN, SegNet 모델 모두 근사값은 최댓값을, 세부 값은 평균값을 사용한 융합 방법이 가장 높은 PSNR을 보인다. 같은 방법으로 Symlets4 (sym4), Daubechies2 (db2)에 대하여도 실험을 수행하여 융합 파라미터는 최댓값과 평균값으로 설정한다.

3. 웨이블릿 방법과 분해단계 선정

3.2절에서 융합 파라미터를 설정 방법을 선택하였는데 3.3절에서는 3가지 웨이블릿 기법에 따른 분해 단계별 결과를 분석하여 각 딥러닝 모델에 대한 웨이블릿 기법과 분해 단계를 선정한다. 표 2는

표 2. 웨이블릿 기법과 분해단계에 따른 PSNR
Table 2. PSNR according to wavelet method and each decomposition step

Model		SegNet	DCGAN
Wavelet method / decomposition level		15.2465	19.1616
haar	1	16.6371	19.1446
	2	16.6266	19.1774
	3	16.6119	19.1957
	4	16.5950	19.2158
	5	16.5757	19.2346
sym4	1	16.6345	19.1410
	2	16.6313	19.1729
	3	16.6180	19.1894
	4	16.6028	19.2097
	5	16.5851	19.2356
db2	1	16.6344	19.1428
	2	16.6294	19.1738
	3	16.6176	19.1931
	4	16.6012	19.2120
	5	16.5849	19.2375

사용된 dataset 중 145장의 Ground Truth 이미지와 후처리 결과 이미지의 PSNR을 평균으로 계산하여 나타낸 결과이다. SegNet 색상화 모델은 후처리 결과, 1단계 분해부터 5단계 분해까지 모든 분해 단계가 PSNR이 증가하였고, DCGAN 색상화 모델은 2단계 분해부터 PSNR이 증가하였다. 색상화에 사용된 두 가지 딥러닝 모델에 대하여 3가지 웨이블릿 기법 사이에 PSNR 차이는 작으며, 웨이블릿 분해 단계별 PSNR 결과 또한 큰 차이를 보이지는 않으나 DCGAN 모델 같은 경우, PSNR이 최대 0.0759 (dB), SegNet은 1.3906 (dB) 증가했다. PSNR이 가장 많이 증가한 웨이블릿 기법과 분해 단계에서 DCGAN은 최소 0.0458 (dB)부터 최대 0.1027 (dB)까지, SegNet은 최소 0.9523 (dB)부터 최대 1.5496 (dB)까지 모든 테스트 이미지의 PSNR이 증가했다. 따라서 SegNet 색상화 모델의 후처리는 가장 PSNR이 높은 harr 1단계 분해를 사용하고 DCGAN 색상화 모델은 db2 5단계 분해를 사용하는 것이 효율이 좋은 것으로 판단된다.

4. 최종 색상화 이미지 가시성 고찰

그림 10과 11에는 두 가지 딥러닝 모델에 대하여 입력이미지, Ground Truth 이미지, 딥러닝 색상화 이미지 및 웨이블릿 기반 이미지 융합 후처리




그림 10. SegNet 기반 색상화 이미지와 후처리에 따른 가시성 비교
Fig. 10 Comparison of visibility SegNet based colorization and post-processing




그림 11. DCGAN 기반 색상화 이미지와 후처리에 따른 가시성 비교
Fig. 11 Comparison of visibility DCGAN based colorization and post-processing

결과 이미지를 각각 보이고 있다. 제안하는 알고리즘을 적용한 후처리 이미지 결과가 부자연스러운 색감이 개선되고 손실된 예지를 표현함으로써 시각적으로도 색상화 품질이 개선됨을 확인할 수 있다.

IV. 결 론

본 논문에서는 딥러닝 기반의 색상화 모델에 대하여 성능 개선을 위한 후처리 방법을 제안하고 다양한 실험을 통하여 성능 향상을 확인하였다. 딥러닝 기반 색상화 이미지의 휘도 성분과 입력 NIR 이미지를 웨이블릿 기반의 융합을 진행하여 예지 성분과 손실된 영상 정보를 개선하였다. 웨이블릿 융합 과정에 요구되는 웨이블릿 파라미터 설정, 웨이블릿 방법 및 단계 선택을 위한 실험을 진행하였는데, 융합 파라미터에 따른 성능과 haar, sym4, db2 웨이블릿 기법에 대하여 1~5단계의 분해에 따른 성능을 비교하였다. 실험 결과 융합 파라미터는 근삿값에 대해 최댓값을 세부 값에 대하여 평균값을 취하여 융합하였을 때가 가장 성능이 높게 나타났다. 그리고 각 모델의 PSNR을 고려하였을 때, SegNet 색상화 모델의 경우는 haar 웨이블릿 1단계 분해, DCGAN 색상화 모델의 경우는 db2 웨이블릿 5단계 분해를 사용한 이미지 융합이 가장 적절한 것으로 보인다.

References

- [1] Mengchi He, Xiaojing Gu, Kingsheng Gu, "A Fast Colorization Algorithm for Infrared Video," Proceedings of International Conference on Life System Modeling and Simulation and International Conference on Intelligent Computing for Sustainable Energy and Environment, pp. 282-292, 2014.
- [2] Patricia L. Suarez, Angel D. Sappa, Boris X. Vintimilla, "Infrared Image Colorization based on a Triplet DCGAN Architecture," Proceedings of IEEE Computer Vision and Pattern Recognition Workshop, pp. 212-217, 2017.
- [3] Matthias Limmer, Hendrik P.A. Lensch, "Infrared Colorization Using Deep Convolutional Neural Networks," Proceedings of IEEE Machine Learning and Applications, pp. 61-68, 2016.
- [4] Richard Zhang, Phillip Isola, Alexei A. Efros, "Colorful Image Colorization," Proceedings of European Conference on Computer Vision, pp. 649-666, 2016.
- [5] Choi Hyun, "Colorization Based on SegNet Architecture and Post-processing Using Wavelet Fusion," M.D. Thesis, Incheon National University, 2018. (in Korean)
- [6] Kamyar Nazeri, Eric Ng, "Image Colorization with Generative Adversarial Networks," Faculty of Science, University of Ontario Institute of Technology, arXiv:1803.05400, 2018.
- [7] Vijay Badrinarayanan, Alex Kendall, Roberto Cipolla, Senior Member, "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation," Proceedings of IEEE Pattern Analysis and Machine Intelligence, Vol. 39, No. 12, pp. 2481-2495, 2017.
- [8] Olaf Ronneberger, Philipp Fischer, Thomas Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention, pp. 234-241, 2015.

Young-Back Kim (김 영 백)



He is received B.S. degree from the department of Embedded Systems Engineering Incheon National University, Korea, in 2017.

Email: yback7902@inu.ac.kr

Hyun Choi (최 현)



He is received B.S. degree from the department of Embedded Systems Engineering Incheon National University, Korea, in 2016.

Email: guswk0816@inu.ac.kr

Joong-Hwee Cho (조 중 휘)



He is an professor with the department of Embedded Systems Engineering in Incheon National University. He received B.S, M.S, and Ph.D. degrees from the department of Electronics Engineering, Hanyang University, Korea, in 1981, 1983, and 1986, respectively.
Email: joonghwee.cho@gmail.com