

RESEARCH ARTICLE

인공지능 기반 소도체 등급판정 부위 분할을 위한 연구

이정호¹, 최선², 황헌^{3*}

¹국립농업과학원 농업공학부 스마트팜개발과, ²한국폴리텍대학 성남캠퍼스, ³성균관대학교 바이오메카트로닉스학과

A study for Segmentation of Beef carcass grading part based on Artificial intelligence

Jeong-Ho Lee¹, Sun Choi², Heon Hwang^{3*}

¹Division of Agricultural Engineering, National Institute of Agricultural Sciences, RDA, Jeonju, Korea

²Korea Polytechnics SeongNam campus, SeongNam, Korea

³Department of Biomechatronics, Sungkyunkwan University, Suwon, Korea

*Corresponding author: hhwang@skku.edu

Abstract

In this paper, a study was conducted on a method of separating the grading part from the cut surface of the beef carcass using the semantic segmentation network, which is a kind of artificial intelligence network. In order to apply semantic segmentation of the grading part, the grading part annotated by an expert was used as learning data. Then, it was divided into 123 training data and 99 test data. Fully convolutional network, Deeplab V3, ResNeSt were applied in the experimental process, and Intersection over Union (IoU) was applied as a performance evaluation index to check which network is suitable for separating the grading part. By applying a labeling algorithm to the resulting image of semantic segmentation network, the part predicted by the semantic segmentation network as a grading part due to a misjudgment is removed. Through this experiment, IoU values were obtained at 0.932, 0.938, and 0.936, respectively.

Keywords: Artificial intelligence, Deep learning, Semantic segmentation, Beef carcass

Introduction

국내의 최근 10년간 소 도축 현황은 매년 증가하고 있으며 앞으로도 더 증가할 추세이다(Lee et al., 2021). 도축된 소도체의 등급판정제도는 1990년에 시안이 마련되고 1992년 7월에 서울 공판장에서 시범적으로 운영되었으며 1993년에 의무화가 되어 등급별 유통이 시작되었고 생산 체제나 유통 환경의 변화에 맞추어 등급판정 기준이 수차례에 걸쳐 개정되었다(Lee et al., 2006). 2019년 12월 1일부터 개정된 축산물 등급판정 기준에서 소도체는 근내지방도 위주의 등급체계를 개선하여 소고기의 생산성을 높이기 위해 근내지방도 이외의 타 항목 기준을 강화하는 최저등급제를 도입하여 각 항목



OPEN ACCESS

DOI: <https://doi.org/10.12972/jame.20220009>

Received: November 11, 2021

Revised: December 05, 2021

Accepted: December 05, 2021

Copyright: © 2022 Journal of Agricultural Machinery Engineering



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

중 가장 낮은 등급을 최종등급으로 산출하게 했다(Jung, 2020). 소도체 등급판정에 관한 기준은 지속적으로 상황에 맞춰 개편이 되었으나 과정은 기술의 발전 여부와 상관없이 여전히 육안 평가에 의존하고 있다.

반면에 최근 인공지능 기술이 발전함에 따라 이미지 기반 돼지의 개체 분류(Sihalath et al., 2020), 감자의 수확량을 예측하기 위한 감자의 객체 인식 및 분할(Lee et al., 2020), 산란계와 소의 녹음된 발성을 분류(Jung et al., 2021), 잎 영상 기반 커피 나무 종류 분류(Putra et al., 2022) 등 농업과 축산 분야에 활발하게 적용되어 사람의 판단에 의존하는 부분을 인공지능 기술이 대체할 수 있는 가능성을 보여주고 있다.

이러한 인공지능 기술의 한 부분인 딥러닝에서 Fully Convolutional Network (FCN) (Long et al., 2015)은 의미론적 분할 신경망의 가장 기초가 되는 신경망으로서 심층신경망의 마지막 층을 Fully connected layer에서 convolution layer로 변경하여 위치 정보가 소실되는 문제를 해결하였다. 추가적으로 Feature map에서 업 샘플링하는 과정에서 이전 층의 convolution layer를 참고하여 업 샘플링을 진행하는 skip combining 기법을 제안하였다. Deeplab V3 (Chen et al., 2017)은 출력 층의 한 화소에 영향을 미치는 입력 층의 영역을 의미하는 receptive field가 고정 값을 가지는 특징을 가진 FCN이 다양한 크기의 물체에 대응하기 어려운 단점을 극복하기 위해 convolution filter에 빈 공간을 두는 atrous convolution 방식을 도입하였다. ResNeSt (Zhang et al., 2020)은 FCN과 Deeplab V3가 backbone으로 사용하는 ResNet (He et al., 2016)의 residual block을 split-attention block으로 변경하여 크로스 채널 정보를 반영하지 못하는 점을 해결하였다.

따라서 본 연구에서는 육안 평가에 의존하고 있는 등급판정 과정 중 하나인 소도체의 절단면에서 등급판정 부위 분할하는 과정에 인공지능 기술의 한 종류인 의미론적 분할 신경망을 적용해서 육안 평가를 대체할 수 있는지를 확인하고 나아가 서로 구조를 가진 의미론적 분할 신경망 FCN, Deeplab V3 및 ResNeSt을 backbone으로 사용하는 Deeplab V3 (이하 ResNeSt)을 적용하여 각 신경망의 등급판정 부위 분할에 대한 성능을 비교하는 것을 목표로 하였다.

Materials and Methods

Materials

학습에 사용될 영상은 카메라(BU406M, Toshiba, Tokyo, Japan)를 사용해서 $2,048 \times 2,048$ 해상도로 수집되었다. 영상은 축산물품질평가원 경기지원에서 도축된 소의 절단면에서 등급판정 부위를 촬영하여 획득하였다. 실험에 사용될 의미론적 분할 신경망의 입력 영상 크기에 맞춰 수집된 영상을 480×360 해상도로 변경 후 123개의 학습데이터와 99개의 테스트 데이터로 나누어 실험이 진행되었다. Fig. 1은 학습에 사용된 영상 샘플을 보여주고 있다. Fig. 1의 오른쪽 영상은 의미론적 분할 학습에 필요한 정답 데이터를 보여주고 있다. 이러한 정답데이터는 전문가가 Fig. 1의 왼쪽에 해당하는 수집된 영상에 등급판정 부위에 해당하는 부분을 표시하고 등급판정 부위를 255(백색), 배경을 0(흑색)으로 변경하여 생성하였다.

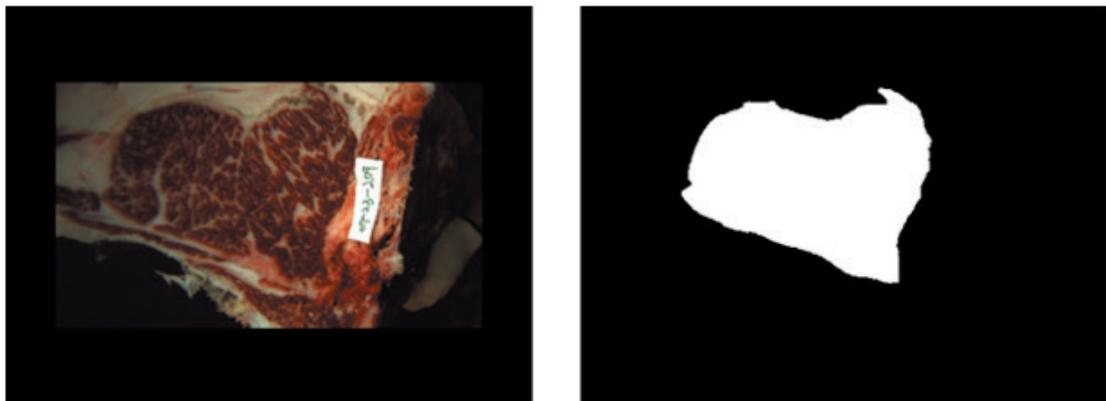


Fig. 1. Original image (left) and Ground-truth image (right).

Methods

학습은 ResNet-101을 backbone으로 사용하는 FCN과 Deeplab V3, ResNeSt-101을 backbone으로 사용하는 Deeplab V3를 적용하여 비교하였다. 3개의 신경망 모두 python 3.6과 pytorch 1.1.0으로 구축되었으며 하이퍼 파라미터는 epoch 250, batch 크기 4, 오차 함수는 Cross entropy, 초기 학습률 0.0001, 최적화 알고리즘은 Adam으로 모두 동일하게 설정하였다. 학습된 신경망을 통해서 얻어진 결과 영상의 경우 소 절단면의 비정형적인 특성상 Fig. 2의 왼쪽 영상에서 확인할 수 있듯이 등급판정 부위가 아닌 부분을 신경망이 오판하는 경우가 있다. 이러한 문제점을 해결하기 위해 Labeling 알고리즘을 적용하여 각 영역을 분리하고 적합한 부분을 제외한 나머지 영역은 배경과 같은 흑색으로 변경하여 Fig. 2의 오른쪽 영상과 같은 최종 영상을 획득하였다.

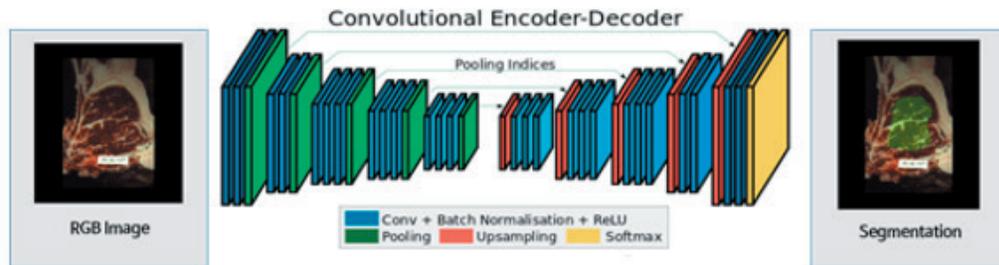


Fig. 2. Example of Semantic segmentation network model.

Evaluation

위에서 언급한 방법으로 학습된 신경망에 대한 성능을 평가하기 위해 의미론적 분할의 주요 평가지표 중 하나인 Intersection over Union (IoU)을 사용하였으며 추가적인 지표로는 Pixel accuracy, Dice coefficient, Matthews correlation coefficient를 사용하였다. 평가지표에 사용된 수식은 아래에서 확인할 수 있다.

$$IoU = \frac{|A \cap B|}{|A \cup B|}$$

$$Pixel\ accuracy = \frac{\sum_{i=0}^K p_{ii}}{\sum_{i=0}^K \sum_{j=0}^K p_{ij}}$$

$$Dice\ coefficient = \frac{2TP}{2TP + FP + FN}$$

$$Matthews\ correlation\ coefficient = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

위 식에서 A, B는 주석 처리된 영역과 신경망이 예측한 영역을 의미하고 있으며 p_{ij} 는 i 로 주석 처리한 화소를 j 로 예측한 수를 나타낸다. TP (True positive)는 양성을 양성으로 예측한 경우, FP (False positive)는 음성을 양성으로 예측한 경우, FN (False negative)는 양성을 음성으로 예측한 경우, TN (True negative)는 음성을 음성으로 예측한 경우를 나타낸다. 평가에 사용된 지표 모두 0~1 사이의 값을 가지며 1의 경우 신경망의 예측 결과와 주석 처리된 영역이 동일하다는 것을 의미한다. 따라서 평가지표의 값이 1에 근접할수록 신경망의 성능이 우수하다는 것은 나타낸다.

Results and Discussion

Table 1은 전문가가 주석 처리한 영역과 3개의 신경망이 예측한 결과의 예시를 보여주고 있다. 실험에 사용된 의미론적 분할 신경망은 의미론적 분할 신경망의 기초가 되는 FCN을 기준으로 FCN의 단점인 receptive field을 해결한 Deeplab V3, FCN과 Deeplab V3의 backbone인 ResNet의 크로스 채널 정보를 반영하지 못하는 점을 해결한 ResNeSt로 FCN, Deeplab V3, ResNeSt 순서로 이전 신경망이 가지는 문제점을 극복해서 발전된 신경망이다. 일반적으로 의미론적 분할 신경망의 성능 평가에 사용되는 데이터셋을 기준으로 이전 신경망의 한계를 극복한 발전된 신경망일수록 높은 성능을 보이기 때문에 비정형에 해당하는 소도체 등급판정 부위 분할에도 그와 같은 현상을 보일 것으로 예상하였으나 Table 2의 테스트 데이터 99개에 대한 평가지표의 평균에서 확인할 수 있듯이 Deeplab V3가 IoU: 0.938, Pixel accuracy: 0.991, Dice coefficient: 0.968, Matthews Correlation Coefficient: 0.963으로 가장 좋은 결과를 얻었다. 하지만 Table 2의 3가지 신경망에 대한 평가지표에서 확인할 수 있듯이 평가지표의 최소값은 FCN의 IoU: 0.933이며 가장 좋은 결과를 나타낸 Deeplab V3와의 최대 편차를 나타내는 지표는 FCN의 IoU이며 편차는 0.005이다. 신경망의 성능 평가에 사용된 지표는 1에 근접할수록 신경망의 성능이 우수하다는 것을 나타내기 때문에 가장 최소값을 가지는 FCN도 평가지표 수치를 통해서 충분히 사용할 수 있음을 알 수 있으며 3가지 신경망 사이에 근소한 차이를 보여 모두 소 절단면의 등급판정 부위를 분할하는데 적합하다고 판단된다. 다만 신경망 적용의 효율성을 따져봤을 경우 Deeplab V3가 가장 적합하다고 판단된다. 실험에서 사용된 연산 장치(GeForce GTX 1080Ti 11GB, NVIDIA, Santa Clara, USA)기준으로 batch 크기를 4이상 설정할 수 있었던 FCN, Deeplab V3와는 다르게 ResNeSt의 경우 연산 장치의 메모리 부족으로 인해 batch의 크기를 4를 초과하여 설정할 수 없었다. Batch의 크기가 작을 경우 노이즈가 커져 신경망의 수렴을 방해해 적용에 어려움이 발생할 수 있다. Deeplab V3에 적용된 atrous convolution는 FCN에 적용된 일반적인 convolution과 비교해서 파라미터의 수는 늘리지 않고 한 화소가 볼 수 있는 영역을 크게 가져갈 수 있게 만들어 준다. 파라미터의 수는 늘리지 않고 Table 2에서 확인할 수 있듯이 미세하지만 더욱 우수한 성능을 보여주는 Deeplab V3가 실험에 사용한 신경망 중에서는 가장 효율적이라고 판단된다. Table 3은 3개의 신경망이 예측한 결과 영상의 Green 채널의 가중치를 0.2, 원본 영상의 가중치를 0.8로 설정하고 합성한 영상을 보여주고 있다.

Table 1. Example of Semantic segmentation network results and Ground-truth

Number	Ground-truth	FCN	Deeplab V3	ResNeSt
1				
2				
3				
4				
5				

Table 2. Mean value for evaluation indicators

Metric	FCN	Deeplab V3	ResNeSt
IoU	0.933	0.938	0.936
Pixel accuracy	0.990	0.991	0.991
Dice Coefficient	0.965	0.968	0.967
Matthews Correlation Coefficient	0.959	0.963	0.961

Table 3. Result of masking the predicted image on the real image

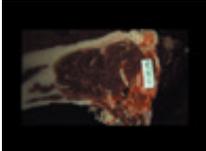
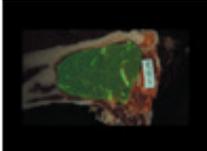
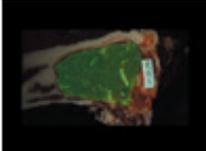
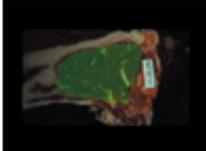
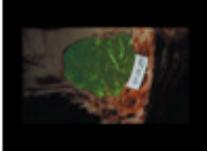
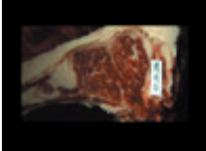
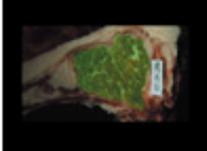
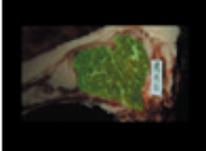
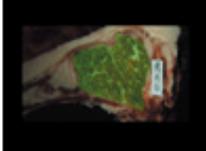
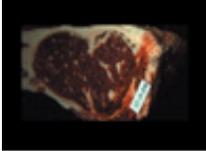
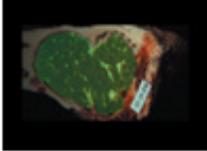
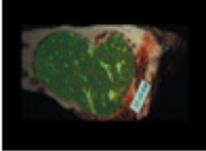
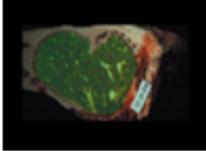
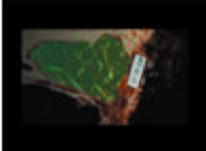
Number	Real	FCN	Deeplab V3	ResNeSt
1				
				
3				
				
5				



Fig. 3. Result of segmentation (left) and post image processing algorithm (right).

Conclusion

본 연구에서는 소 절단면의 등급판정 부위를 분할하기 위해 인공지능의 의미론적 분할 신경망을 적용하였다. 적절한 신경망을 찾기 위해 3가지의 신경망인 FCN, Deeplab V3, ResNeSt이 적용되었고 신경망이 오판한 부분을 고치기 위해 신경망 결과 영상에 Labeling 알고리즘을 적용해서 결과 영상을 수정하였다. 신경망의 성능을 비교하기 위해 평가지표로 IoU, Pixel accuracy, Dice coefficient, Matthews correlation coefficient를 사용하였으며 실험 결과 근소한 차이로 Deeplab V3가 좋은 성능을 나타냈으나 3가지 신경망 모두 충분히 높은 평가 지표 수치를 보여주어 소 절단면의 등급판정 부위를 분할하는데 적합하다고 판단되지만 신경망을 단독으로 사용하였을 경우에 소도체 절단면의 비정형에 의한 오판이 발생한다. 오판으로 인해 추가되는 Labeling 알고리즘과 같은 후속 처리는 연산 속도에 영향을 미쳐 다량의 연산이나 실시간 연산에 영향을 미칠 수도 있으므로 향후 신경망만을 활용해서 높은 성능을 보이는 의미론적 분할 신경망에 대한 연구가 필요할 것으로 보인다.

References

- Chen LC, Papandreou G, Schroff F, Adam H, 2017. Rethinking Atrous Convolution for Semantic Image Segmentation. arXiv:1706.05587v3 [cs.CV] 5 Dec 2017.
- He K, Zhang X, Ren S, Sun J, 2016. Deep Residual Learning for Image Recognition. IEEE Conference on Computer Vision and Pattern Recognition (CVPR). pp. 770-778. doi:10.1109/CVPR.2016.90.
- Jung DH, Kim NY, Moon SH, et al. 2021. Classification of Vocalization Recordings of Laying Hens and Cattle Using Convolutional Neural Network Models. Journal of Biosystems Engineering. 46:217-224. doi:10.1007/s42853-021-00101-1.[in Korean]
- Jung YB. 2020. Background and Main Contents of Revised Beef Grading System. Korean Society for Food Science of Animal Resources. Volume 9 Issue 1. pp. 81-89.[in Korean]
- Long J, Shelhamer E, Darrell T, 2015. Fully Convolutional Networks for Semantic Segmentation. IEEE Conference on Computer Vision and Pattern Recognition (CVPR). pp. 3431-3440. doi:10.109/CVPR.2015.7298965.
- Lee JO, An TY, Choi KS, Seonwoo H, 2021. Development of 3D Printing Technique for Artificial Meat. Journal of Agricultural Machinery Engineering(JAME). doi:10.12972/jame.20210005.[in Korean]
- Lee HS, Shin BS. 2020. Potato Detection and Segmentation Based on Mask R-CNN. Journal of Biosystems Engineering. 45:233-238. doi:10.1007/s42853-020-00063-w.[in Korean]
- Lee JH, Shin SM, Lee SJ, Kim JB. 2006. The Changes of Carcass Grading System for Cattle in Korea. Annals of Animal Resource Sciences. 17:54~64.[in Korean]
- Putra BTW, Amirudin R, Marhaenanto B. 2020. The Evaluation of Deep Learning Using Convolutional Neural Network (CNN) Approach for Identifying Arabica and Robusta Coffee Plants. Journal of Biosystems Engineering. 47:118-129. doi:10.1007/s42853-022-00136-y.[in Korean]
- Silhalath T, Basak JK, Bhujel A, et al. 2021. Pig Identification Using Deep Convolutional Neural Network Based on Different Age Range. Journal of Biosystems Engineering. 46:182-195. doi:10.1007/s42853-021-00098-7.[in Korean]
- Zhang H, Wu C, Zhang Z, Zhu Y, Lin H, Zhang Z, Sun Y, He T, Mueller J, Mannatha R, Li M, Smola A, 2022. ResNeSt: Split-Attention Networks. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops(CVPRW). pp. 2735-2745. doi:10.1109/CVPRW56347.2022.00309.