

공간 가변적 커널 추정 및 적응적 밀도 맵 생성 기반의 해충 카운팅 모델

김경태, 조정민, 손창환(교신저자)*

국립군산대학교 소프트웨어학과

3dlife4620@naver.com, 5281cjm@gmail.com, cson@kunsan.ac.kr*

Pest Counting Model Based on Spatially Variant Kernels and Adaptive Density Map Generation

Kyoung-Tae Kim, Jeong-Min Cho, and Chang-Hwan Son*

요약

본 논문은 해충의 조기 발견은 농작물 피해를 줄이고 생산성을 제고 할 수 있는 중요한 작업이다. 종래의 숙련된 농부가 육안으로 측정하는 방식을 탈피하여 디지털 트랩을 사용하여 포획된 해충 마릿수를 자동으로 측정하는 방제시스템이 도입되고 있다. 하지만, 포획된 해충의 폐색 문제로 인해 해충 카운팅의 정확도가 저하되고 있다. 이를 해결하고자 본 논문에서는 스택으로 쌓은 밀도 맵 기반 카운터와 커널 생성자로 구성된 해충 카운팅 모델을 제시하고자 한다.

I. 서론

무역화와 기후변화로 인해 외래 및 돌발 해충의 유입이 증가하고 있으며, 작물 재배의 다양화와 시설 재배 확대에 따라 해충 발생이 지속되고 있다. 이러한 해충은 농작물에 피해를 주어 품질 저하, 생산량 감소, 경제적 손실을 초래한다. 이에 해충 발생량을 조기에 정확히 파악하는 것이 중요하며, 이를 위해 디지털 트랩이 도입되고 있다. 디지털 트랩은 주광성과 주화성을 이용해 해충을 유인하고, 카메라로 이미지를 획득한 후 딥러닝 모델을 통해 해충 마릿수를 예측한다.

해충 카운팅 모델은 주로 객체 검출(Object Detection)과 밀도 맵 추정(Density Map Estimation) 방식으로 나눌 수 있다[1]. 객체 검출은 객체의 크기와 수가 적절할 때 효과적이지만, 해충이 작고 수백 마리일 때는 폐색 문제로 정확도가 떨어진다. 반면, 밀도 맵 추정 방식은 해충이 많은 경우에도 더 나은 성능을 보인다. 기존 해충 카운팅 모델은 해충 중심점을 도트 맵으로 표시한 후 가우시안 커널을 적용해 밀도 맵을 생성하지만, 폐색 문제로 인해 정확한 예측이 어렵다.

이를 해결하기 위해 본 연구에서는 밀도 맵 카운터와 커널 생성자를 스택 구조로 결합한 해충 카운팅 모델을 새롭게 제안한다. 기존의 고정된 가우시안 커널을 사용하는 방식 대신, 공간적으로 가변적인 커널을 생성함으로써 해충 이미지 내의 폐색 문제를 효과적으로 완화한다. 이러한 접근법을 통해 다양한 환경에서도 일관된 성능을 발휘할 수 있도록 하였으며, 실험 결과 제안한 모델이 기존 모델들에 비해 더 높은 정확도를 보였다.

II. 본론

2.1 제안한 접근 방법

기존 MCNN[2]은 히트맵 추정에 효과적이며, 이는 밀도 맵과 유사하다. 두 방식 모두 도트맵을 기반으로 가우시안 커널로 필터링을 수행하지만, 히트맵은 커널의 중심을 유지한다는 점에서 밀도 맵과 차이가 있다. 본 연구에서는 밀도 맵의 정확도를 개선하기 위해, 밀도 맵 추정을 위한 새로운 해충 카운팅 모델을 제안하며, 카운터 외에 공간 가변적으로 커널을 추정할 수 있는 생성자도 스택으로 쌓은 구조를 제안한다. 기존 KDMG[3] 모델과 유사하지만, 제안한 모델은 카운터의 위치와 마스킹 실험을 통해 공간적 어텐션을 활용하여 밀도 맵의 정확도를 개선했다는 점에서 차별화된다. 또한 군중 카운팅에만 적용되었고, 해충 카운팅에는 검증되지 않았다.

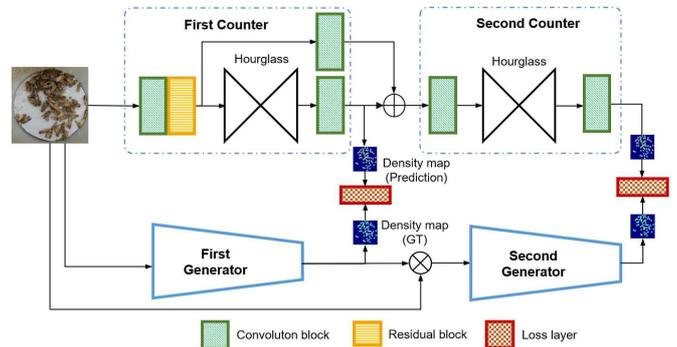


그림 1. 제안한 스택형 생성자 및 카운터 기반 해충 카운팅 모델 아키텍처

2.2 제안한 해충 카운팅 모델의 아키텍처

그림 1은 제안한 해충 카운팅 모델의 아키텍처를 보여준다. 제안된 모델은 카운터와 생성자로 구성되며, 각각 Hourglass와 잘린 VGG 모델[4]을 기반으로 스택 구조로 설계되었다. 카운터는 밀도 맵 예측을, 생성자는 공간적으로 가변적인 커널을 추정해 실측 밀도 맵을 생성하는 역할을 한다. 기존의 고정된 가우시안 커널 대신, 학습을 통해 커널을 생성해 실측 밀도 맵을 만든다. 첫 번째 생성자의 실측 밀도 맵은 마스킹을 통해 개선된 후, 두 번째 생성자로 입력된다. 모델 학습은 두 카운터와 생성자에서 발생한 오차 합을 최소화하는 방식으로 진행된다.

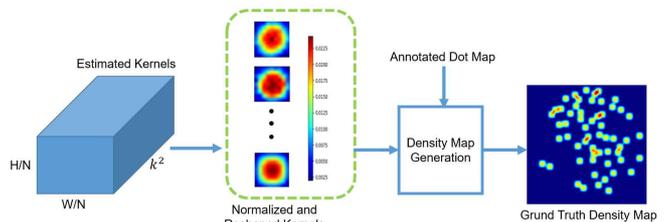


그림 2. 커널 생성자를 활용한 실측 밀도 맵 생성 과정

2.3 커널 학습을 위한 생성자 모듈

커널 생성자는 입력 해충 이미지의 공간 영역별로 가변적인 커널을 추정한다. 속도를 고려해 픽셀 단위가 아닌, 이미지를 가로·세로로 등분한 서

브 영역별로 커널을 계산한다.

$$K_f = G_f(I) \quad (1)$$

여기서 I 는 입력 해충 이미지이고 G_f 는 스택 구조에서 첫 번째 커널 생성자를 의미한다. 본 연구에서는 G_f 를 위해 잘림 VGG 모델[4]을 사용하였다. VGG 모델의 4번째 컨볼루션 블록에서 자른 후, 컨볼루션 레이어를 추가하여 출력 형상의 크기를 결정하였다. 그리고 K_f 는 추정된 커널로써, 3차원 배열이고 커널 형상은 $(W/N) \times (H/N) \times k^2$ 이다. 여기서 W 와 H 는 입력 해충 이미지의 가로 및 세로 길이에 해당한다.

$$K_f(j) = Reshape(Norm(K_f(j))) \quad (2)$$

여기서 $K_f(j)$ 는 j 번째 픽셀에서 추정된 커널을 의미하고 $1 \times 1 \times k^2$ 형상을 갖는다. $Norm$ 함수는 커널 $K_f(j)$ 의 값이 양수이며 합이 1이 되도록 만든다. 본 연구에서는 $Norm$ 함수를 위해 소프트맥스 함수를 적용하였다. $Reshape$ 함수는 $K_f(j)$ 형상을 $k \times k$ 크기의 2차원 배열로 변환한다.

그림 2는 커널 생성 과정과 밀도 맵 생성 예시를 보여준다. 예측된 커널은 기존 가우시안 커널과 다르며, 각 커널을 입력 도트 맵의 좌표에 적용해 실측 밀도 맵을 만든다.

2.4 손실함수

제안한 스택 구조에서의 최종 손실은 다음과 같다.

$$L = w_1 L_f + w_2 L_s \quad (3)$$

여기서 L_f 와 L_s 는 각각 첫 번째와 두 번째 생성자와 카운터 간의 오차를 나타낸다. 그리고 w 는 각 손실에 대한 가중치이다.

$$L_f = \| P_f - \hat{P}_f \|^2 \quad (4)$$

$$L_s = \| P_s - \hat{P}_s \|^2 \quad (5)$$

본 연구에서는 실측 밀도 맵과 예측 밀도 맵 간의 오차를 ℓ_2 -놈(norm)을 사용하였다. 참고로 테스트 단계에서 최종 예측 밀도 맵은 두 번째 카운터의 예측치를 사용하기 때문에 w_2 를 w_1 보다 높게 설정하였다. 본 연구에서는 경험적인 방법을 통해 $w_2 = 0.8$, $w_1 = 0.2$ 로 설정하였다.

2.5 밀도 맵 시각화

그림 3은 제안한 모델의 생성자와 카운터로 추정된 커널과 밀도 맵의 결과를 보여준다. 그림에서 제공된 밀도 맵은 제안한 모델의 두 번째 카운터에서 추출된 예측치에 해당한다. 이 추정된 밀도 맵을 합산하면 최종 해충 개수를 산출할 수 있다. 그림의 해충 이미지의 하단에는 육안으로 측정된 해충 개수가 있다. 그리고 예측 밀도 맵 하단에도 추정된 해충 개수가 있다. 그림에서 보듯이, 측정된 해충 개수와 예측된 해충 개수가 거의 비슷한 것을 볼 수 있다. 이는 제안한 스택 구조 형태의 실측 밀도 맵 생성 방법이 해충 카운팅의 정확도 개선에 아주 효과적임을 말해준다.

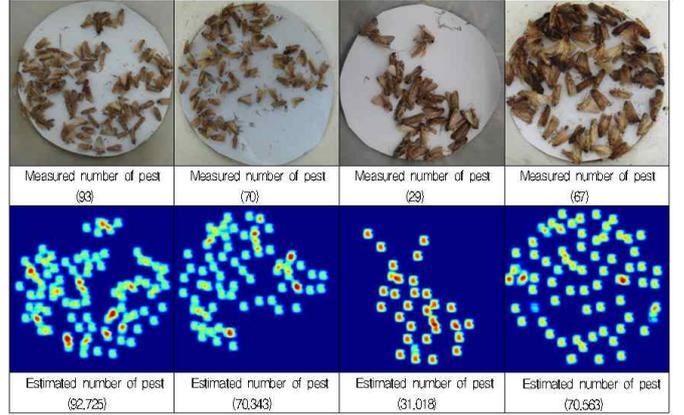


그림 3. 실험 결과; 입력 이미지(첫 번째 행), 제안한 해충 카운팅 모델이 예측된 밀도 맵(두 번째 행)

2.6 실험 및 실험 결과

표 1. 트랩 기반 해충 카운팅을 위한 정량적 평가

Method	Counting Models	MAE
Object Detection	RetinaNet[4]	4.634
	Faster RCNN[5]	3.312
	YOLOv7[6]	1.105
Density map Estimation	MCNN[2]	4.104
	ICNet[7]	9.710
	KDMG[3]	1.273
	DM-Count[8]	0.888
	MaD2a-PCM[9]	0.913
	Proposed Model	0.722

표 1은 MAE 평가 결과를 보여준다. 정량적 평가는 평균 절대 오차(MAE)를 사용했다. MAE는 예측과 실제 값의 평균 오차를 나타낸다. 제안한 모델은 기존 밀도 맵 기반 모델들보다 더 높은 정확도를 보이며, 생성자를 제거한 버전보다 실측 밀도 맵 생성이 더 효과적임을 확인할 수 있다. 또한, KDMG[3]는 커널 생성 방식을 사용하지만 스택 구조가 없어 정확도가 낮다. 실측 밀도 맵 생성이 해충 카운팅 정확도에 큰 영향을 미친다는 것을 알 수 있으며, 바운딩 박스 검출 기반 해충 카운팅보다도 성능이 우수함을 보여준다.

III. 결론

본 논문은 학습을 통해 커널을 생성하는 밀도 맵 기반 해충 카운팅 모델을 제안한다. 생성자와 카운터를 스택 구조로 결합하고, 첫 번째 생성자의 실측 밀도 맵을 공간 어텐션으로 활용해 두 번째 생성자의 성능을 개선했다. 실험 결과, 제안된 모델은 기존 밀도 맵 기반 모델뿐만 아니라 객체 인식 방식보다도 더 우수한 성능을 보였으며, 커널 생성자의 효과성을 입증했다. 또한, 카운터 위치와 마스킹 실험을 통해 공간 어텐션의 기여를 확인했다. 이 모델은 웹 애플리케이션으로 구현되어 노지 트랩 이미지에 적용되며, 농가의 생산량과 품질 향상을 기대할 수 있다.

ACKNOWLEDGMENT

이 연구는 농촌진흥청 연구사업(과제번호: PJ01630303)의 지원을 받아 수행된 연구임

참 고 문 헌

- [1] J.-H. Lee and C.-H. Son, "Trap-based pest counting : Multiscale and deformable attention CenterNet integrating internal LR and HR joint feature learning," *Remote Sensing*, vol. 15, no. 15, 3810, July 2023. <https://doi.org/10.3390/rs15153810>.
- [2] Y. Zhang, D. Zhou, S. Chen, S. Gao, and Y. Ma, "Single-image crowd counting via multi-column convolutional neural network," in *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, pp. 589 - 597, Jun. 2016. <https://doi.org/10.1109/cvpr.2016.70>.
- [3] J. Wan, Q. Wang, and A. B. Chan, "Kernel-based density map generation for dense object counting," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 3, Mar. 2022. <https://doi.org/10.1109/tpami.2020.3022878>.
- [4] T. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, "Focal loss for dense object detection" in *Proc. IEEE International Conference on Computer Vision*, pp. 2999-3007, Oct. 2017. <https://doi.org/10.1109/iccv.2017.324>.
- [5] Sh. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards real-time object detection with region proposal networks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 39, No. 6, pp. 1137-1149, Jun. 2017. <https://doi.org/10.1109/tpami.2016.2577031>.
- [6] W. Wang, A. D. O. C. A. L. W., X. Zhang, and D. Li, "YOLOv7: A High-Performance Object Detection Framework," *arXiv preprint arXiv:2207.02696*, 2022. <https://doi.org/10.1063/pt.5.028530>.
- [7] V. Ranjan, Hieu. Le, and M. Hoai, "Iterative crowd counting," in *Proc. European Conference on Computer Vision*, Munich, Germany, pp. 278-293, Oct. 2018. https://openaccess.thecvf.com/content_ECCV_2018/html/Viresh_Ranjan_Iterative_Crowd_Counting_ECCV_2018_paper.html.
- [8] B. Wang, H. Liu, D. Samaras, M. Hoai, "Distribution matching for crowd counting," in *Proc. Neural Information Processing Systems*, Vancouver, Canada, pp. 1595-1607, Dec. 2020. <https://proceedings.neurips.cc/paper/2020>.
- [9] W.-D Lee, C.-H. Son, and S.-W. Park, "Multiscale and deformable density attention model for trap-based pest counting," *Journal of Korean Institute of Information Technology*, vol. 21, no. 12, pp. 1-11, Dec. 2023. <https://doi.org/10.14801/jkiit.2023.21.12.1>.