

논문 2021-16-08

# 이동형 디바이스를 이용한 딥러닝 기반의 돼지 무게 추정 알고리즘

## (Deep Learning-Based Pig Weight Estimation Algorithm Using Mobile Devices)

정재진, 심승보, 원형필, 구교권\*

(Jae Jin Jeong, Seungbo Shim, Won Hyoung Pil, Gyogwon Koo)

Abstract : This paper proposes a deep learning algorithm for estimating pig weight. The proposed algorithm estimates the weight of a pig using the point cloud obtained through a mobile device. The proposed model is based on the PointNet which is widely used in the point cloud data. Through the optimization of the PointNet, the proposed method not only improves the accuracy, but also reduces the computational complexity. The accuracy (82.4 %) of the proposed method was about 3 % higher than that of the conventional method (79.4 %). Also, the numbers of the trainable parameters for the PointNet and the proposed method were 3,114,771 and 150,554, respectively. That is, the proposed method used only 5 % of trainable parameters compared to the PointNet. The developed model makes it easier and faster to measure the weight of a pig than the conventional method.

Keywords : 3D classification, PointNet, 3D point cloud

### 1. 서론

우리나라 2018년 농업생산액은 50조 5백억 원으로 연평균 9.6 % 증가하고 있다. 그중에서 첫 번째는 재배업 생산액으로 금액은 30조 3천억 원, 비율로는 약 60.5 %를 차지하고 있다. 다음은 축산업 생산액으로 금액은 19조 7천억 원, 비율은 약 39.4 %를 차지하고 있다. 이 중 돼지가 차지하는 비율은 약 44.6 %이다 [1]. 따라서 국내 양돈산업은 축산업의 대표적인 산업이며 우리나라 농업에서 중요한 역할을 차지하고 있다.

1997년 돈육의 수입 자유화가 된 후 돈육의 수입량은 가파른 상승세를 보이고 있으며, 자급 비율은 감소하고 있다. 또한 축산농가 경영주의 고령화율이 2005년 25.5 %에서 2019년 43.6 %로 18.4 %가 증가하였다 [1]. 이 결과로부터 고령화율이 계속 증가할 것을 예상할 수 있다. 이러한 국내 양돈 농가의 어려움을 극복하기 위해서는 자동화 시스템 구축을 통한 양돈 농가의 생산성 향상이 필요하다. 양돈 농가

의 생산성과 관련되는 대표적인 지표는 돼지의 무게이다. 돼지의 무게를 통해 체중 및 성장상태를 관리할 수 있기 때문이다. 이를 통해 최적의 사료 양을 결정할 수 있으며, 품질 관리를 위한 규격돈의 출하시기를 선정할 수 있다. 즉, 사육 일수 및 사육비용의 최적화를 통해 비용의 절감 및 생산성 향상을 기대할 수 있다.

대표적으로 양돈의 무게 측정 방법은 흉위 측위법 [2]과 돈형기에 의한 방법이다. 흉위 측위법은 돼지의 흉위를 줄자로 측정하여 산출식에 의해 무게를 측정하는 방법으로 측정 오차가 매우 커 실제 양돈 농가에서는 많이 사용되지 않는다. 다음으로 돈형기는 저울을 이용하여 돼지의 무게를 직접 측정하는 방법으로 정확한 무게를 측정할 수 있다는 장점이 있지만 돈형기 위로 돼지를 올려놓기 위해 많은 인력과 시간이 소모된다는 단점이 있다.

이러한 기존의 양돈 무게 측정 방식의 문제점을 해결하고자 카메라 영상을 이용하여 무게를 측정하는 새로운 방법이 고안되었다 [3-6]. 이 방법들은 돈사 천장에 Top-view 카메라를 설치하고 이를 통해 획득한 2D 또는 3D 영상정보를 이용하여, 돼지의 윤곽이나 등뼈 라인 등을 추출하여 타원 피팅 알고리즘 통하여 양돈의 무게를 추정하는 방법이다. 이 방법들은 돼지의 픽셀 수 또는 영상처리 기술 등을 이용한다. 그리고 최근, [7]에 소개된 방법은 딥러닝 Faster-RCNN을 이용한 방법으로 돼지를 인식하고, 회귀 네트워크를 이용하여 돼지의 무게를 추정한다. 앞에서 언급한 방법들은 돈사의 환경에 많은 영향을 받게 된다. 예를 들면, 돈사의 높이가 모두 일정하지 않다는 것이다. 이 방법을 활용하기 위해

\*Corresponding Author (gkoo@dgist.ac.kr)

Received: Feb. 9, 2021, Revised: Mar. 8, 2021, Accepted: Apr. 1, 2021.

J.J. Jeong: Daegu Catholic University (Assist. Prof.)

S. Shim: Korea Institute of Civil Engineering and Building Technology. (Research specialist)

W.H. Pil: Illumination (CEO)

G. Koo: DGIST (Senior Researcher)

※ 본 연구는 2020년도 정부(과학기술정보통신부)의 재원으로 과학기술인 자리진흥원의 지원을 받아 수행되었습니다. (1711121241) 또한, 본 연구는 과학기술정보통신부에서 지원하는 DGIST 기관고유사업에 의해 수행되었습니다 (21-IT-10-03).



그림 1. 돼지 무게 추정 시스템  
Fig. 1. System of pig weight estimation



그림 2. 점 구름 돼지 영상  
Fig. 2. Point cloud of pig

서는 돈사의 높이에 따른 카메라 및 알고리즘의 보정 등이 해결해야 할 문제점으로 남아있다.

본 연구에서는 이러한 문제점을 해결하고자 이동식 디바이스를 이용하여 돼지의 무게를 측정하는 방법을 개발한다. 제안된 알고리즘은 이동식 디바이스를 통해 획득된 돼지 깊이 영상으로부터 돼지 무게를 추정하는 딥러닝 기반 알고리즘이다. 이러한 깊이 영상을 획득하기 위해 깊이 카메라 (depth camera)를 사용하였으며, 점 구름 (point cloud) 데이터에서 널리 활용되는 포인트넷 (PointNet)의 구조 [8]를 참조하여 새로운 구조의 모델을 제안하고, 실험 결과를 통해 제안된 모델의 성능을 검증한다.

본 논문의 구성은 다음과 같다. 2장에서는 카메라 시스템 및 깊이 카메라를 이용한 돼지 영상에 대해 소개하고, 3장에서는 포인트넷의 구조와 제안하는 구조에 대해 설명한다. 제안된 알고리즘의 평가를 위한 실험 결과를 4장에서 기술하고, 마지막으로 결론을 제시한다.

## II. 돼지 무게 추정을 위한 데이터

일반적인 카메라가 부착된 이동식 디바이스를 이용하여 돼지의 영상을 획득하는 경우 돼지와 디바이스 사이의 거리가 고정되지 않고 환경에 따라 차이가 발생하는 특징이 존재한다. 즉, 획득된 영상에서 거리 정보가 존재하지 않기 때문에 돼지의 무게를 추정하기가 매우 어렵다. 그 이유는 영상에서 보이는 돼지의 크기 정보가 돼지의 실제 크기로 인

한 것인지 아니며 디바이스와 돼지 사이의 거리에 의한 것인지에 대한 명확한 구분이 어렵기 때문이다. 따라서, 돼지의 크기를 이용하여 무게 추정을 위해서는 디바이스와 돼지 사이의 거리 정보를 활용하는 것은 매우 중요하다. 거리 정보를 포함한 영상을 얻기 위해 그림 1과 같은 시스템을 이용한다. 그림 1은 카메라 시스템을 이용하여 실제 돼지의 영상을 획득하는 모습이다. 카메라 시스템은 안드로이드 기반 태블릿과 깊이 카메라 (structure sensor의 depth camera)로 구성된다.

깊이 카메라를 통해 얻어진 돼지의 영상은 그림 2와 같은 점 구름 형태이다. 영상 획득 환경에 따라 돼지의 머리 위치가 달라질 수 있으며, 디바이스와 돼지 사이의 거리에 따라 크기가 달라질 수 있음을 이 영상을 통해 확인할 수 있다. 이 3차원 점 구름은 X, Y, Z 축의 좌표를 통해 돼지의 표면을 나타낸다. 데이터는 행렬 형태로 저장되며  $N$ (포인트의 수) \* 3(X, Y, Z 축의 좌표)의 크기를 가진다. 점 구름 데이터를 딥러닝의 입력으로 이용하여 돼지의 무게를 추정하고자 한다. 실측값을 얻기 위해 사용된 저울의 분해능은 1 kg이며 돼지의 무게가 이산적인 값으로 측정된다. 그리고 출하돈 등의 선정을 위해서는 g 단위의 정확한 무게보다는 대략적인 무게가 중요하므로 분류를 이용하여 문제를 해결한다.

## III. 딥러닝 기반 돼지 무게 추정 알고리즘

산업 현장에 적용하여 돼지의 무게 추정을 위해서는 성능이 중요한 요소이지만, 실제적인 구현을 위해서는 계산량, 계산 시간 등의 조건도 반드시 고려해야 하는 중요한 요소이다. 그러므로 적절한 규모의 네트워크를 사용하는 것은 중요하다. 본 연구에서는 점 구름 데이터를 입력으로 사용하여 우수한 성능을 나타내고 있는 포인트넷의 구조를 기반으로 하여 알고리즘을 개발한다. 포인트넷 구조는 합성곱 계층 (convolution layer), 풀링 (pooling)과 완전 연결 계층 (fully connected layer) 등으로 이루어져 있으며, 깊은 구조를 가진다. 우수한 성능을 나타내는 모델을 구하기 위해서는 충분한 데이터가 필요하게 된다 [7]. 하지만 실제 현장에서 돼지의 무게 추정을 위한 충분한 데이터의 확보가 어려우므로 이러한 문제를 해결하기 위해 포인트넷을 변형한 새로운 구조를 제안한다.

먼저, 포인트넷에 대해 소개하면 다음과 같다. 포인트넷은 그림 3과 같이 크게 4개의 모듈로 구성된다. 그림 3의 하단 (·)은 각각 출력의 크기를 의미하며,  $MLP(A, B)$ 는 연속된 출력 크기가 A인 완전 연결 계층과 출력 크기가 B인 완전 연결 계층을 의미한다. 또한 입력 변환 네트워크 (input transform network)와 특징 변환 네트워크 (feature transform network)의  $I_{xy}, F_{xy}$ 는 각각 계층의 출력 크기를 의미하며,  $x$ 는 계층의 종류를 의미 (즉,  $c$ 는 1D 합성곱 계층,  $d$ 는 완전 연결 계층)하고  $y$ 는 순서를 나타낸다. 첫 번째 모듈은 입력 변환 네트워크로 T-Net으로 명명된 변환 행렬을 포함하고 있다. 이 네트워크는 변환 행렬과 입력의 곱을

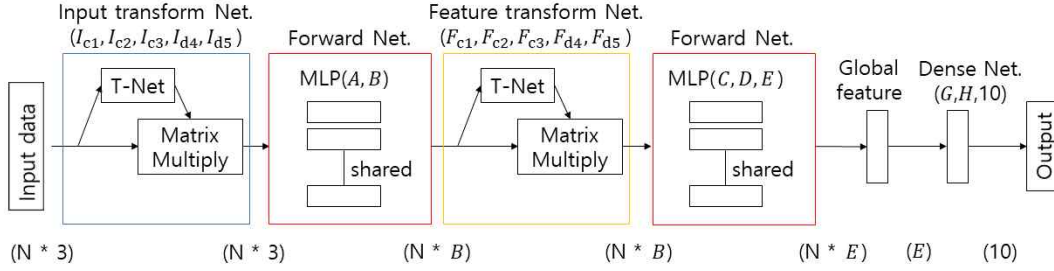


그림 3. 포인트넷 구조  
Fig. 3. Structure of PointNet




그림 4. 데이터 증가의 예  
(a) 원본 (b) 좌우 반전

Fig. 4. Example of data augmentation  
(a) original data (b) flipped data

통해 입력 데이터의 순서에 상관없이 같은 결과를 얻을 수 있게 만드는 네트워크이다. 점 구름 데이터는 같은 데이터에 대해서도 어떠한 순서로 저장하느냐에 따라 다양한 행렬이 존재할 수 있다. 이것은 점 구름 데이터의 순서에 따라 성능이 변화할 수 있다는 것을 의미하며, 이를 보완해주기 위한 입력 변환 네트워크는 저장된 점들의 순서에 상관없이 비슷한 성능을 나타나게 해주는 부분이다. 두 번째 모듈은 입력된 데이터에서 특징점을 추출하는 순방향 네트워크(forward network)이다. 세 번째 모듈, 특징 변환 네트워크는 추출된 특징점의 움직임과 회전 등에 강인한 특성을 가지게 해주는 네트워크이다. 즉, 이 네트워크는 T-Net을 통해 특징점이 일반화 되도록 회전하게 하는 동작을 수행한다. 마지막 모듈은 밀집 네트워크(dense network)이다. 이 네트

워크는 완전 연결 계층으로만 구성되어 있으며, 앞 모듈에서 추출된 특징점들로부터 클래스를 분류해주는 역할을 한다.

위에서 설명한 포인트넷을 기반으로 돼지의 무게 추정을 위한 제안된 모델은 다음과 같다. 본 논문에서 사용된 시스템은 깊이 영상을 저장하는 과정에서 일정한 순서로 정렬하여 데이터를 저장하는 방법을 사용하였다. 따라서 포인트넷 첫 번째 모듈인 입력 변환 네트워크의 필요성이 줄어들게 된다. 이것은 네트워크의 크기를 증가시키며, 과적합(overfitting)을 초래할 수 있으므로 제안된 모델에서는 입력 변환 네트워크를 제거하였다. 데이터에서 특징점을 추출, 특징점의 변환, 특징점과 무게 사이의 상관성 연결은 필수적이다. 따라서 제안하는 네트워크는 순방향 네트워크-특징 변환 네트워크-풀링-밀집 네트워크로 구성된다. 또한, 이동식 디바이스에 적합하고 모델의 과적합을 피하기 위해 각 층의 뉴런의 수는 실험을 통해 최적화 하였다.

#### IV. 실험결과

본 논문의 실험을 위해 실제 양돈 농가에서 90 ~ 99 kg의 돼지를 대상으로 825 장의 깊이 영상을 획득하였다. 그중 660 장과 165 장을 각각 학습 데이터와 검증 데이터로 분류하였다. 그림 2와 같이 돼지 머리의 위치가 고정되어 있지 않기 때문에 이를 반영하고자 좌우 반전을 통한 데이터 증가(data augmentation)를 수행하였다. 그림 4는 데이터 증가의 결과를 나타내고 있다. 또한 본 연구는 알고리즘을 검증하는 단계로써, 실험은 연구실 환경에서 수행되었으며, RTX 2080 Ti와 Keras 환경에서 개발되었다.

알고리즘의 성능을 평가하기 위한 추정 정확도 F는 다음과 같이 정의된다.

$$F = \frac{1}{N} \sum_{i=1}^N \mathbf{1}_{|y_i^* - \hat{y}_i| \leq 2} (y_i^*) \quad (1)$$

여기서  $N$ 은 전체 데이터 수이고,  $y_i^* = \arg \max_i p_i^*$ 와  $\hat{y}_i = \arg \max_i \hat{p}_i$ 는 각각 돼지의 실제 무게와 추정 무게를 의미하고,  $p_i^*$ 와  $\hat{p}_i$ 는 각각 실제와 추정 무게의 one-hot encoding 벡터로써 90~99 kg의 값을 의미하며, 각각은 10 개

표 1. 모델의 구조

Table 1. Structure of models

	model A	model A'	model B	model B'
Ic1	32	32	-	-
Ic2	64	64	-	-
Ic3	512	256	-	-
Id4	512	128	-	-
Id5	256	-	-	-
A	64	16	16	16
B	64	16	16	16
Fc1	64	32	32	32
Fc2	128	64	64	64
Fc3	1024	512	512	512
Fd4	512	128	128	128
Fd5	256	-	-	-
C	64	16	16	16
D	128	64	16	16
E	1024	512	128	128
G	512	64	64	64 (L2)
H	265	-	-	-

의 클래스로 구분된다. 그리고  $\mathbf{1}_A(a)$ 는 지시 함수로써, 다음과 같다.

$$\mathbf{1}_A(a) := \begin{cases} 1 & a \in A \\ 0 & a \notin A \end{cases}. \quad (2)$$




그림 5. 포인트넷의 결과

Fig. 5. Confusion matrix of PointNet




그림 7. 모델 B의 결과

Fig. 7. Confusion matrix of model B




그림 6. 모델 A'의 결과

Fig. 6. Confusion matrix of model A'

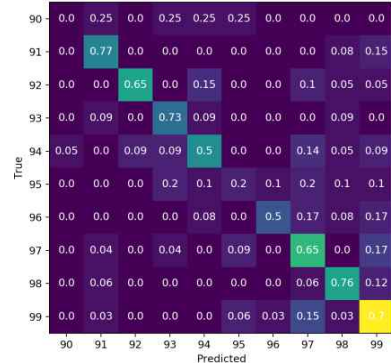


그림 8. 모델 B'의 결과

Fig. 8. Confusion matrix of model B'

본 실험의 학습을 위해 사용된 최적화 기법은 네스테로프 Adam (Nadam) optimizer를 활용하였고 손실함수 L 는 다음과 같다.

$$L = -\frac{1}{N} \sum_{i=1}^N p_i^* \log \hat{p}_i. \quad (3)$$

이 실험에서 사용된 모델의 구조는 표 1에 정리되어 있다. 기존의 포인트넷을 이용하면 학습가능한 파라미터는 약 3,114,771 개를 가지며, 이 경우는 최대 검증 정확도는 약 79.4 %를 가진다. 이 결과를 혼동행렬 (confusion matrix)로 나타내면 그림 5와 같다. 혼동행렬의 밝은색은 높은 확률을 의미하며, 확률이 낮은 경우 어두운색으로 표현된다. 그리고 x축은 추정 무게, y축은 실측 무게를 나타낸다.

모델의 과적합 방지와 이동형 디바이스에 적용을 위해 파라미터의 수를 줄인 포인트넷을 적용한 결과이다. 이 모델의 학습 가능한 파라미터의 수는 약 263,635 개이며, 최대 검증 정확도는 약 81.2 %를 가진다. 이 모델의 혼동행렬은 그림 6과 같으며 포인트넷을 그대로 적용한 것보다 파라미터의 수는 1/10 이상 줄어들었지만, 오히려 성능은 향상하는 것을 볼 수 있다. 모델 A'는 모델 A와 비교하여 네트워크에 사용되는 뉴런의 수를 최적화한 결과로써 모델의 크기를 적

표 2. 실험 결과

Table 2. Experimental results

	modelA	modelA'	modelB	modelB'
Input Transform Net.	○	○		
Forward Net.	○	○	○	○
Feature Transform Net.	○	○	○	○
Forward Net.	○	○	○	○
Dense Net.	○	○	○	○
Accuracy (%)	79.4	81.2	81.8	82.4

절하게 감소시킬 경우 성능을 증가시킬 수 있다는 것을 보여 준다. 다음은 앞에서 언급한 것과 같이 입력 변환 네트워크를 제거한 모델 B에 대해서 실험한 결과이다. 이 모델은 약 150,554 개의 학습 가능한 파라미터, 약 81.8 %의 최대 검증 정확도를 나타낸다. 이 때 혼동행렬의 결과는 그림 7과 같다. 모델 B와 모델 A'의 실험을 통해 입력 변환 네트워크가 돼지 무게 추정의 성능 향상에 큰 영향을 미치지 않는다는 것을 알 수 있으며, 모델의 파라미터를 증가시킨다는 것을 보여준다. 다음은 모델 B의 과적합을 방지하기 위해 가중치 규제 등의 방법을 사용하여 얻어진 모델 B'이다. 그림 8은 제안하는 모델의 혼동행렬 결과를 나타낸다. 이것은 밀집 네트워크 가중치의 L2 규제를 적용한 모델이다. 이는 약 82.4 %의 최대 검증 정확도를 나타내었다. 이 실험을 통해 모델의 규제를 통해 성능을 향상시킬 수 있다는 것을 알 수 있다. 표 2은 딥러닝 기반의 돼지 무게 추정 알고리즘의 결과를 정리한 것이다. 이 결과를 통해서 모델 B'가 제일 좋은 추정 정확도를 나타낸다는 것을 볼 수 있다.

모든 실험에서 90 kg과 95 kg에서 실제 값과 추정 값의 사이에 큰 차이가 발생하는데 그 이유는 데이터의 수가 다른 무게에 비해 현저히 부족하기 때문이다. 즉, 90 kg의 경우 전체영상에서 20 장, 95 kg은 49 장의 영상이 존재한다. 즉, 데이터 불균형으로 인해 모든 모델에서 분류 성능의 저하가 발생하였다. 만약 부족한 무게에 대한 영상을 추가한다면 더 좋은 성능의 모델을 개발할 수 있을 것으로 생각된다.

### V. 결론

본 논문에서는 돼지의 무게를 추정하기 위한 딥러닝 기반 알고리즘을 개발하였다. 개발된 알고리즘은 이동식 디바이스를 통해 얻어진 영상을 이용하여 돼지의 무게를 추정하는

것이다. 이때의 영상은 깊이 카메라로 획득한 영상을 이용하였으며, 이동식 디바이스에 적합한 계산량을 가지는 딥러닝 알고리즘을 제안하였다. 제안된 알고리즘의 정확도는 82.4 %였으며, 이는 기존 포인트넷 (79.4 %)보다 약 3 % 높았다. 또한 제안된 알고리즘의 학습 가능한 파라미터의 수는 150,554 개였다. 이는 기존 포인트넷의 파라미터 수 대비 약 5 % 수준이다. 이를 통해 기존의 방법보다 돼지의 무게를 쉽고 빠르게 측정할 수 있게 되었으며, 향후 더 넓은 범위의 돼지의 무게 추정과 정확도 향상을 위한 연구 및 이동형 디바이스에 적용을 위한 연구를 진행하고자 한다.

### References

- [1] [https://www.kostat.go.kr/portal/korea/kor\\_nw/1/1/index.board?bmode=read&aSeq=386478](https://www.kostat.go.kr/portal/korea/kor_nw/1/1/index.board?bmode=read&aSeq=386478)
- [2] C. N. Groesbeck, K. R. Lawrence, M. G. Young, Robert D. Goodband, Joel M. DeRouchey, Michael D. Tokach, Jim L. Nelssen, Steven S. Dritz "Using Heart Girth to Determine Weight in Finishing Pigs," Kansas Agricultural Experiment Station Research Reports, pp. 166-168, 2002.
- [3] M. Kashiha, C. Bahr, S. Ott, C. Moons, T. Niewold, F. Odberg, D. Berckmans, "Weight Estimation of Pigs Using Top-view Image Processing," in Proceeding International Conference Image Analysis and Recognition, pp. 496-503, 2014.
- [4] M. Kashiha, C. Bahr, S. Ott, C. Moons, T. Niewold, F. Odberg, D. Berckmans, "Automatic Weight Estimation of Individual Pigs Using Image Analysis," Computers and Electronics in Agriculture, Vol. 107, pp. 38-44, 2014.
- [5] M. Lu, T. Norton, A. Youssef, N. Radojkovic, A. Fernandez, D. Berckmans, "Extracting Body Surface Dimensions from Top-view Images of Pigs," International Journal of Agricultural and Biological Engineering, Vol. 11, No. 5, pp. 182-191, 2018.
- [6] A. Pezzuolo, M. Guarinob, L. Sartoria, L. Gonzalez, F. Marinello, "On-barn Pig Weight Estimation Based on Body Measurements by a Kinect v1 Depth Camera," Computers and Electronics in Agriculture, Vol. 148, pp. 29-36, 2018.
- [7] Y. Cang, H. He, Y. Qiao, "An Intelligent Pig Weights Estimate Method Based on Deep Learning in Sow Stall Environments." IEEE Access, 7, pp. 164867-164875, 2019.
- [8] C. R. Qi, H. Su, K. Mo, and L. J. Guibas, "Pointnet: Deep Learning on Point sets for 3d Classification and Segmentation," Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 652-680, 2017.



**Jae Jin Jeong (정재진)**

2008 Electrical and Electronic Engineering from Kyungpook National University (B.S.)

2011 Electrical and Electronic Engineering from POSTECH (M.S.)

2016 Electrical and Electronic Engineering from POSTECH (Ph.D.)

2009~School of Electronic and Electrical Engineering at Daegu Catholic University (Professor)

Career:

2016~2019 Senior Researcher, Defense Agency for Technology and Quality

Field of Interests: Signal Processing, Machine Learning

Email: jjeong@cu.ac.kr

**Won Hyoung Pil (원형필)**

2005 Computer information engineering from University of VISION College of Jeonju

2020 Computer engineering from University of National Institute For Lifelong Education

Career:

2007~ Representative of Leewon Systems

2015~ Chairman of Jeonbuk 3D Printing Cooperative Association

2018~ CEO of Illumination

Field of Interests: Machine Learning, Computer Vision, On-Device AI,

Email: hpwon@illumination.kr

**Seungbo Shim (심승보)**

2009 Electrical Engineering from Pusan National University (B.S.)

2011 Electronic and electrical engineering from POSTECH (M.S.)

2020 Ph. D candidate Civil & environmental engineering from KAIST

2017~Research specialist, Korea Institute of Civil Engineering and Building Technology (KICT)

Career:

2010~2017: Research Engineer, Samsung Heavy Industries (SHI)

Field of Interests: Machine vision, Deep learning, Automatic measurement system, Sensor network, Infrastructure maintenance

Email: seungboshim@kict.re.kr

**Gyogwon Koo (구교원)**

2013 Electrical Engineering from Kyungpook National University (B.S.)

2015 Electrical Engineering from POSTECH (M.S.)

2020 Electrical Engineering from POSTECH (Ph.D.)

2020~ DGIST (Senior Researcher)

Field of Interests: Deep Learning, Computer Vision, Signal Processing, Optimization, Factory Automation

Email: gkoo@dgist.ac.kr