

송아지 질병 결정 지원 모델

최동운¹ · 강윤정^{2*}

A Calf Disease Decision Support Model

Dong-Oun Choi¹ · Yun-Jeong Kang^{2*}

¹Professor, Department of Computer Engineering, Wonkwang University, Iksan, 54538 Korea

^{2*}Assistant Professor, Division of Liberal Arts, Wonkwang University, Iksan, 54538 Korea

요약

송아지 질병 진단을 위해 사용되는 여러 데이터 중에서 분변은 질병 진단의 중요한 역할을 한다. 송아지 분변 이미지에서 형태, 색상, 질감으로 건강 상태를 알 수 있다. 건강 상태를 파악할 수 있는 분변 이미지는 분변 상태에 따라 정상 송아지 207개와 설사증 송아지 158개의 데이터를 전처리하여 사용하였다. 본 논문에서는 수집된 송아지 데이터 중에서 분변 변수의 이미지를 탐지하고 합성곱 네트워크 기술을 활용하여 질병 증상을 포함하고 있는 데이터 세트에 대해 CNN과 GLCM의 속성을 결합한 GLCM-CNN을 적용하여 이미지를 학습시켰다. CNN의 89.9% 정확도와 GLCM-CNN은 91.7%의 정확도를 보이는 GLCM-CNN은 1.8%의 높은 정확도를 나타내는 유의미한 차이가 있었다.

ABSTRACT

Among the data used for the diagnosis of calf disease, feces play an important role in disease diagnosis. In the image of calf feces, the health status can be known by the shape, color, and texture. For the fecal image that can identify the health status, data of 207 normal calves and 158 calves with diarrhea were pre-processed according to fecal status and used. In this paper, images of fecal variables are detected among the collected calf data and images are trained by applying GLCM-CNN, which combines the properties of CNN and GLCM, on a dataset containing disease symptoms using convolutional network technology. There was a significant difference between CNN's 89.9% accuracy and GLCM-CNN, which showed 91.7% accuracy, and GLCM-CNN showed a high accuracy of 1.8%.

키워드: 송아지 질병 결정 지원, 기계학습, 합성곱 신경망, 그레이 레벨 동시 발생 매트릭스

Keywords: Calf disease determination support, Machine Learning, Convolutional neural network, Gray Level co-occurrence Matrix

Received 20 August 2022, Revised 29 August 2022, Accepted 13 September 2022

* Corresponding Author Yun-Jeong Kang(E-mail:yjkang66@wku.ac.kr, Tel:+82-63-850-6290)

Assistant professor, Division of Liberal Arts, Wonkwang University, Iksan, 54538 Korea

Open Access <http://doi.org/10.6109/jkiice.2022.26.10.1462>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

쾌적한 사육환경을 제공하고 스트레스와 불필요한 고통을 최소화하여 동물의 복지 수준을 향상해서 강한 동물이 생산되는 축산물의 안전한 환경을 위한 것이 동물복지이다. 우리나라에서는 동물복지 축산농장에서 사육되고 운송·도축을 거쳐 생산된 축산물에 ‘동물복지 축산물’ 표시를 하는 등 사육·운송·도축 전 과정에서 체계적인 관리로 종합적인 농장 동물 복지체계를 추진하고 있다[1]. 또한 축사의 개체 관리는 사물인터넷 기술 발달로 가축의 움직임 등의 신체활동에 대한 모니터링과 영상, 이미지 데이터의 추적이 가능하다[2].

송아지가 사는 축사에서는 모든 가축이 같은 환경과 먹이를 먹고 무리 지어 살고 있어서 한 송아지에서 발생한 질병 증상이 다른 송아지도 발생하는 경향이 생길 수 있다. 한 송아지의 질병 증상과 다른 송아지의 질병증상에서 발생하는 지지도와 신뢰도에 따라 향상도가 예측될 수 있다. 또한 송아지 폐사의 중요한 증상은 현재까지 설사를 주요증상으로 하는 장염과 호흡기감염과 관련된 폐렴으로 보고되고 있다[3].

송아지의 건강 상태를 확인하는 방법은 육안 관찰, 분변 내 병원체 검사, 혈액 검사가 있다. 육안 관찰은 온도와 맥박을 기록하고 기침, 콧물, 눈곱, 귀, 분변 상태를 확인한다. 기침은 정상, 간헐적인 기침, 반복적인 기침, 잦은 기침으로 분류하며, 콧물은 정상, 적은 양의 탁한 콧물, 양쪽 콧구멍에서 탁한 콧물, 심한 화농성 콧물로 분류하여 확인한다. 눈곱은 정상, 적은 양의 눈곱, 양쪽 눈 모두에 눈곱, 많은 양의 눈곱으로 분류하고, 귀는 정상, 귀를 자주 움직이거나 머리를 흔들, 한쪽으로 늘어뜨린 귀, 머리를 한쪽으로 기울이거나 양쪽 귀를 모두 늘어뜨림으로 분류한다[4-5]. 분변은 표 1과 같이 점수로 수치화하며 형태와 색깔로 분류한다. 분변의 색은 황색, 갈색, 혈변 등과 분변 상태는 고형, 반고형, 묽은 수양성에 대한 정보로 건강 상태를 알 수 있다[6-8].

Table. 1 Fecal scores 0 to 3 in a 1 increment scale









Fecal Score	0	1	2	3
base				
appearance				

표 2는 육안검사를 건강점수로 변환하여 점수가 0에 가까우면 건강한 것이고, 3에 가까울수록 심한 질병 상태에 있다고 판단한다. 목장주는 항목별로 건강점수 1 점 정도의 질병 상태에서 응급처치를 시행하고, 치료반응이 좋지 않을 경우 수의사를 통해 진단과 치료를 받는다[9]. 송아지 질병 탐지나 질병 진단은 24시간을 주기로 체온 37.9~39℃, 심박 수 80~158 bpm. 습도 2~98%의 정상 상태의 기침, 콧물, 눈곱, 귀, 분변 상태일 때 정상으로 판단을 결정할 수 있다. 온도와 심박 수는 수치 데이터, 소 상태나 분변 이미지 데이터로 건강 상태를 탐지할 수 있다.

Table. 2 The clinical sign scoring criteria

Sign	Description	Score
Temperature	38.0-39.5℃	0
	39.5-40.0℃	1
	40.0-40.5℃	2
	40.51-41.0℃	3
	41.0℃>	4
Respiratory rate	<50	0
	50-60	1
	60-70	2
	70-80	3
	80>	4
Degree of nasal discharge	Absent	0
	Mild	1
	Moderate	2
	Severe	3
Cough frequency degree	Absent	0
	Mild	1
	Moderate	2

젖소에 공급되는 사료와 대변 점수와의 연관성, 젖소의 생체 데이터와 축사의 환경 데이터를 기반으로 생식 능력에 미치는 환경 요인을 분석, 축산 관리 시스템 운영을 위한 소의 품종 분류, 열 감지 장치를 장착하여 열 감지기의 색상 변화를 모니터링, 송아지 질병 예측을 위한 생체정보 수집하여 원격 진료를 위한 지식 베이스 구축하는 연구가 있다[10-14]. 돼지우리 급수량 예측과 질병 개체 파악하는 연구와 가축 행동 영상 AI 데이터 구축과 gaggles에서 “Zoo Animal Classification” 데이터 등

에서 동물 개체 데이터를 활용하기 기계학습 기술을 활용한 다양한 연구도 시도되고 있다[15-18].

본 논문에서는 송아지의 배변 이미지를 탐지하여 질병 유무를 결정을 지원한다. 어떤 질병이 포함되었는지를 찾을 수 있는 분류 기능으로 문제를 해결하기 위해 합성곱 신경망 기술을 활용하였다.

II. 송아지 질병 지원 모델과 데이터셋

이미지와 비디오 데이터는 텍스트 기반(Text-Based)과 내용 기반(Content-Based)으로 분류하게 되는데 된다. 텍스트 기반 분류는 텍스트의 주제, 내용, 파일 이름 등을 텍스트로 정의하고, 내용 기반은 이미지와 비디오에서 나타내는 형태, 질감[19-21], 색상[22] 등의 통계적인 특징이나 기하학적인 특징을 추출하여 분류를 수행한다.

송아지의 분변은 호랑이, 사자, 표범의 동물 객체를 표피에 무늬가 있는 것도 아니고 의류의 모양이나 패턴, 색처럼 특징을 추출하기는 쉽지 않다. 하늘, 산, 바다의 이미지에서 어떤 위치의 하늘인지, 어느 산인지, 바다인지를 찾는 것은 이미지 자체의 특징만으로 정확한 분류를 하려면 메타데이터까지 활용해야 한다. 따라서 본 논문에서는 분변의 색과 상태에 대한 이미지 데이터로 사람의 신경망을 모방한 심층 신경망 구조를 활용하여 정상과 비정상을 분류하였다.

2.1. 연구방법

Tensor flow 기반의 Python 라이브러리 Keras와 Numpy를 사용하여 CNN과 이미지처리를 결합한 GLCM (Gray Level Co-occurrence Matrix)-CNN을 적용하였다. 적용한 시스템 구조는 그림 1과 같다.

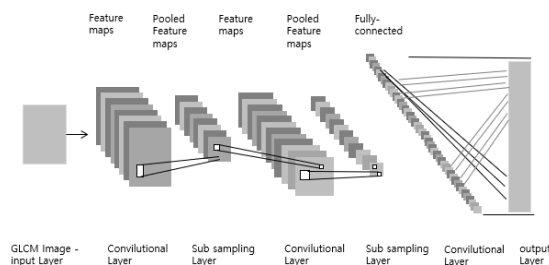


Fig. 1 structure of GLCM-CNN

심층 신경망의 CNN(Dep Neural Network)은 하나 또는 여러 개의 컨볼루션(Convolution), 활성화 함수, 서브 샘플링(sub sampling), 완전 연결(fully-connected) 계층으로 구성되었다.

컨볼루션 계층은 입력 이미지의 필터와 가중 합으로 다음 계층에 전달하고 필터는 어떤 특징이 데이터에 있는지 없는지를 판단하는 함수로 사용한다. 결괏값은 특징이 있을 때는 큰 값, 특징이 있는지 알 수 없을 때는 0에 가까운 값이 나온다. 원본 데이터의 크기에 따라 출력 크기는 입력 이미지보다 작아지는데 이를 보완하기 위해 원본 이미지 주의를 0으로 둘러싸아 결괏값이 작아져서 특징이 유실되는 것을 막고, 입력 데이터에 0 값을 넣어서 본래의 특징이 희석돼 과적합 현상을 방지하기 위해 제로 패딩을 적용한다.

필터를 통해 특징맵이 추출되면 활성화 함수를 적용하여 찾는 특징이 ‘있음’과 ‘없음’이라는 비선형 값으로 바꾸는 과정을 활성화 함수로부터 찾는다. CNN 활성화 함수로 식 1로 정의한 ReLU 함수를 사용한다.

$$f_j(z_j(n)) = \max(0, z_j(n)) \quad (1)$$

서브 샘플링 계층은 추출된 모든 특징에 의존하여 판단하면 용량 손실이 발생하고 오히려 특징을 잡아내기 어렵게 돼 일종의 풀링(pooling) 과정으로 최댓값 풀링(max pooling)을 많이 사용한다. 최댓값 풀링은 필터 내에서 가장 큰 값만 전달하고 나머지는 무시하여 샘플링을 수행한다. 최댓값 풀링을 사용하면 출력 이미지의 각 픽셀값은 식 2로 정의한다.

$$h_{ijk} = \max(a_{ppk}, (p, q) \in ohm(i, j)), \quad (2)$$

$$i = 1, \dots, W_i, j = 1, \dots, H_i, k = 1, \dots, D_a$$

완전연결 계층은 추출된 특징값을 기존의 신경 네트워크에 넣어서 학습 진행하는데 일반적인 신경망의 은닉계층과 같은 구조로 되어 있으며, 컨볼루션 과정을 통해 추출한 특징을 식별하는 역할을 한다.

그림 1에서 추출된 특징은 일정한 형태나 형태, 색상, 질감을 나타내는 학습 데이터셋을 보여주는데 이미지의 특징 자체를 컨볼루션 뉴럴 네트워크에서 학습하도록 한다. 이미지 특징 히트맵에서 붉은색 부분이 더 중요한 특징을 나타내고 하늘색 부분이 덜 중요한 특징을 의미하고 있다. 이미지의 배경과 분변 객체의 모양보다는 색상과 질감이 송아지 질병을 분류하는 특징이 될 수

도 있다. 질병이 있는 경우 객체 내의 파란색의 수용성을 포함하고 있고 중요한 특징에 수용성을 포함하지 않기도 한다. 특징 추출된 범위에서 수용성이나 질감과 색상에 대한 학습이 없다면 정확도가 떨어질 수 있다.




Fig. 1 Heatmap of feature extracted image

이러한 문제를 줄이기 위해 질감의 특징을 추출할 수 있는 서브 샘플링을 위한 GLCM-CNN을 적용하여 특징 추출을 위한 분할 과정을 전 단계에서 질감을 식별할 수 있도록 한다. 질감은 이미지 내에 관심 영역이나 객체를 식별하기 위해 사용되는 중요한 특징 중에 하나로 표면의 구조적인 배열에 관한 정보를 가지고 있다. GLCM의 생성에서 설정되는 거리와 방향은 세세한 질감을 가지는 이미지에 큰 거릿값을 조정하거나 한 쌍의 화소 사이의 방향으로 하나의 화소를 중심으로 이웃 화소는 모두 8개의 방향을 가진다.

이미지 전체에서 어느 한 픽셀과 이웃 픽셀 간의 명암 대비 측정값을 반환하는 속성 contrast는 식 3으로 정의한다. contrast는 화소 간의 명암도 차이를 구분하는데 표현하는 것으로 GLCM의 대각선상에서 상대적으로 멀리 떨어져 있는 화소의 경우 큰 값을 가진다.

$$\sum_{i,j} |i - j|^2 p(i,j) \tag{3}$$

어느 한 픽셀이 이웃 픽셀과 얼마나 상관관계가 있는지 측정하는 값을 반환하는 속성 correlation은 식 4로 정의한다. correlation은 화소 사이의 명암도의 선형적인 의존성에 대한 척도로 이미지를 부드러운 정도를 알 수 있다.

$$\sum_{i,j} \frac{(i - ui)(j - uj)p(i,j)}{\sigma_i \sigma_j} \tag{4}$$

GLCM 요소들의 제곱의 합을 반환하는 속성 energy은 식 5로 정의한다. energy은 ASM(Angular Second Moment)이라고도 하며 이미지 내 화소의 명암도가 질서정연하게 변하는가를 측정하는 척도이다. 명암도의 균일 정도를 측정하는 계산으로 균일한 이미지의 경우

energy 값은 1이다.

$$\sum_{i,j} p(i,j)^2 \tag{5}$$

GLCM 요소가 GLCM 대각선에 얼마나 근접하게 분포해 있는지 측정하는 값을 반환하는 homogeneity 속성은 식 6으로 정의한다. homogeneity는 균일성을 나타내는 것으로 대각선에서 멀어질수록 그 값은 기하급수적으로 증가하며 대각 GLCM의 경우 동질성이 1이다.

$$\sum_{i,j} \frac{p(i,j)}{1 + |i - j|vert} \tag{6}$$

GLCM 차원은 화소의 최대 그레이 레벨에 의해 결정되며 그레이 레벨의 수는 GLCM 계산에 중요한 요소이다. 그레이 레벨의 수가 많을 때 계산 부하는 증가할 수 있지만 보다 정확한 질감의 특성 분석을 할 수 있다.

표 3은 CNN과 GLCM-CNN으로 학습된 입력 데이터는 건강한 분변과 질병이 있는 분변 4개에 예시로 나타낸 것이다. GLCM-CNN의 경우 그레이 이미지 대상으로 질감 특징을 추출하여 적용한다.

Table. 3 Example of cnn and glcm-cnn images in input layer

		CNN	GLCM-CNN
abnormal	normal		
	pasty		
	loose		
	watery		

2.2. 데이터 세트

실험을 위한 데이터 세트 구축을 위해 신체 건강 데이터와 분변 상태에 따라 정상 송아지 207개와 설사증 송

아지 158개의 데이터를 전처리하여 사용하였다[23].

수집된 데이터는 11개의 속성을 포함하고 있지만 본 논문에서는 표 4에서 나타낸 Feces 속성의 이미지를 전처리하여 송아지 질병 결정 지원 모델을 학습에 적용하였다.

Table. 4 Data collection for calf parameters.

parameters.	data type	classification	
feces	Image	fecal	normal
			pasty
			loose
			watery
health	category	normal / abnormal	

III. 결과 분석

본 논문에서 제안된 송아지 질병 결정 지원 모델의 다양한 분류 문제에서 성능을 평가하기 위해 보편적으로 사용하는 성능 평가 척도인 정확도, 정밀도, 민감도, F1 measure를 사용한다.

Learning rate 학습률은 매우 낮은 학습률로 시작해서 점진적으로 매우 높은 학습률까지 수백 번 반복하여 모델을 훈련하는 것이다. 학습률이 높을수록 학습속도는 빠르지만, 최솟값을 차지 못하거나 오류가 발생한다, 반대로 학습률이 낮아지면, 학습 성능이 떨어지고 국소값에 머무를 수 있다.

Epoch는 학습 횟수 즉 전체 학습 데이터셋이 모델에 적용되어 통화했다는 의미로 epoch=10이면 학습 데이터셋을 10회 학습시켰음을 나타낸다.

Batch size는 1회의 epoch 안에 들어가는 데이터 세트의 크기를 의미하며 m개(m≥1)의 block batch가 들어갈 수 있다.

iterations는 전체 데이터를 모델에 한 번 학습시키는 데 필요한 배치의 개수를 의미하며, 300개의 데이터를 100개씩 3개의 미니배치로 나누었을 때, 1 epoch를 위해서는 3번의 iteration이 필요하며 3번의 파라미터 업데이트가 진행된다.

전체 데이터 세트 중 학습 데이터 세트는 70%, 테스트 세트는 30%로 설정하고 학습 횟수(epoch)는 10, 1회 epoch 당 batch size는 1로 설정하였다. iteration는 50,

100, 200을 설정하였다.

실험을 통해 알 수 있는 것은 먼저 GLCM의 3가지 속성 중에서 contrast와 energy는 CNN을 향상할 수 있는 정확도가 더 높지만, homogeneity 속성은 반비례해서 homogeneity 평균 정확도는 다른 속성인 contrast 및 energy보다 낮았다.

CNN의 정확도는 89.9%, GLCM-CNN는 91.7%의 정확도로 1.8%의 높은 정확도를 보이는 유의미한 차이가 있었다.

Table. 5 Classification accuracy of glcm-cnn

iteration	CNN	GLCM-CNN		
		C	E	H
50	0.834	0.891	0.827	0.762
100	0.878	0.826	0.896	0.796
200	0.899	0.839	0.917	0.823

Description of C: Contrast, E: Energy, H: Homogeneity

표 5는 GLCM-CNN의 contrast 속성의 정확도는 반복이 적었을 때 정확도가 향상한다. 50번의 iteration 후 CNN은 83.4%의 정확도를 보인 반면 contrast 이미지를 사용하는 GLCM-CNN은 89.1%의 정확도를 보였으며 100, 200번의 반복에서는 CNN이 더 높은 정확도를 보였다. GLCM-CNN의 energy 속성의 정확도는 반복이 높아질수록 정확도가 향상되었다. 200번의 iteration 후 CNN은 89.9%의 정확도를 보였고 energy 이미지를 사용하는 GLCM-CNN은 91.7%의 정확도를 보였다. GLCM-CNN의 homogeneity 속성은 반복 수가 높아질수록 정확도는 상승했으나 CNN보다 높은 정확도는 보이지 못했다.

CNN-GLCM의 contrast, energy, homogeneity의 속성을 사용한 GLCM-CNN에서 contrast와 energy 속성은 정확도가 향상되었고 homogeneity 속성에서는 정확도가 향상되지 않았다. 그러나 CNN과 GLCM-CNN가장 높은 성능은 표 6과 같으며 GLCM-CNN은 CNN보다 조금 더 개선된 성능을 포함하고 있다. CNN의 정확도는 89.9%, GLCM-CNN는 91.7%의 정확도로 1.8%의 높은 정확도를 보이는 유의미한 차이가 있었다. 정확도, 정밀도, 민감도, F1의 종합적인 지표에서 1.8~3.2%의 성능을 보였다.

Table. 6 Classification CA, PPV, sensitivity, F1 of glcm-cnn

	CA	PPV	sensitivity	F1
CNN	0.899	0.866	0.88	0.863
GLCM-CNN	0.917	0.898	0.891	0.894

IV. 결 론

GLCM 속성을 이용하여 기존 CNN을 결합하는 내용을 제시하였다. GLCM 이미지로 입력 레이어를 수정하여 원본 CNN과 비교하여 질감으로 배변이미지를 식별하여 질병을 분류하였다. GLCM의 속성을 통해 질병 분류의 정확도가 미세하게 상승했다. 따라서 GLCM-CNN의 정확도와 성능 향상을 위해 GLCM 속성 확장을 통해 정확도를 향상될 것으로 기대한다.

또한, 사람이나 동물의 질병은 육안으로 알 수 있지만 대서롭지 않게 놓치고 갈 수 있는 부분들에 대해 사람의 일생에서 SNS 기록하는 것처럼 송아지의 일상을 대표하는 배변이미지를 추가 등록하여 데이터를 추가 하여 학습 데이터를 쌓아가면 더 많은 정보를 통해 질병을 진단의 정확도를 높일 수 있을 것이다.

본 연구는 송아지 질병 결정을 위해 분변 이미지 데이터를 수집하였고 이를 활용하였다. 다른 동물의 분변 이미지 데이터 탐지를 통해 축사 밖의 실시간 동물 질병 감시 시스템[24], 동물 서식지 분포 파악 및 예측 등의 연구로 확장할 수 있을 것이다.

ACKNOWLEDGEMENT

This paper was supported by Wonkwang University in 2021.

REFERENCES

- [1] Animal protection management system [Internet]. Available: <https://www.animal.go.kr/front/community/show.do?boardId=contents&seq=144&menuNo=3000000017>.
- [2] I. Shabani, T. Biba, and B. Cico, "Design of a Cattle-Health-Monitoring System Using Microservices and IoT Devices," *Computers*, vol. 11, no. 5, p. 79, May. 2022.
- [3] U. -H. Kim, Y. -H. Jung, C. Choe, S. -J. Kang, S. S. Chang, S. -R. Cho, B. -C. Yang, and T. -Y. Hur, "Korean native calf mortality: the causes of calf death in a large breeding farm over a 10-year period," *Korean Journal of Veterinary Research*, vol. 55, no. 2, pp. 75-80, Jun. 2015.
- [4] Calf Health Scorer, Food Animal Production Medicine [Internet]. Available: <https://www.vetmed.wisc.edu/fapm/svm-dairy-apps/calf-health-scorer-chs/>.
- [5] J. Bohlen and E. Rollin, "Calf Health Basics," *UGA Cooperative Extension Bulletin 1500*, Jul. 2018.
- [6] Rural Development Administration Nongsaro Portal [Internet]. <https://www.nongsaro.go.kr/portal/ps/psb/psbx/cropEbookLst.ps?menuId=PS65290&sText=&pageIndex=1&pageSize=10&sKeyword=&sNameOrderAt=Y&group2Cnt=&cropEbookGubunChk=&sStdPrdLstCode=&sStdTchnlgyCode=&stdPrdLstCode=&sRdaStdPrdLstCode=&sRdaStdTchnlgyCode=&kidofcomdtyNo=0&sOldDtShowAt=N&sSearchText=&cNo=66&stdItemCd=LP085808&cropsEbookNm=%EC%86%8C#>.
- [7] P. Melendez and E. Roy, "The Association between Total Mixed Ration Particle Size and Fecal Scores in Holstein Lactating Dairy Cows from Florida, USA," *American Journal of Animal and Veterinary Sciences*, vol. 11, no. 1, pp. 33-40, Nov. 2016.
- [8] SeoBong BioBestech Co., Ltd, Food and Rural Affairs (MAFRA), "Efficacy of SoltoB against respiratory and intestinal disease in calves," Ministry of Agriculture, Food and Rural Affairs(MAFRA), Technical Report 11-1541000-000864-01, 2011.
- [9] H. U. Lee, "Cow Health Care and Treatment," *Monthly Dairy Beef*, vol. 30, no. 1, pp. 104-110, Jan. 2010. Available: <http://koreascience.or.kr/article/JAKO201049655293148.page?&lang=ko>.
- [10] P. Melendez and E. Roy, "The Association between Total Mixed Ration Particle Size and Fecal Scores in Holstein Lactating Dairy Cows from Florida, USA," *American Journal of Animal and Veterinary Sciences*, vol. 11, no. 1, pp. 33-40, Jan. 2016.
- [11] S. Shahinfar, D. Page, J. Guenther, V. Cabrera, P. Fricke, and K. Weigel, "Prediction of insemination outcomes in Holstein dairy cattle using alternative machine learning algorithms," *Journal of dairy sciences*, vol. 97, no. 2, pp. 731-742, Feb. 2014.
- [12] M. M. Santoni, D. I. Sensuse, A. M. Arymurthy, and M. I. Fanany, "Cattle Race Classification Using Gray Level Co-occurrence Matrix Convolutional Neural Networks," *Procedia Computer Sciences*, vol. 59, pp. 493-502, Aug.

- 2015.
- [13] S. Chowdhury, B. Verma, J. Roberts, N. Corbet, and D. Swain, "Deep Learning Based Computer Vision Technique for Automatic Heat Detection in Cows," in *Proceedings of Development International Conference on Digital Image Computing*, Gold Coast: QLD, Australia, pp. 1-6, 2016.
- [14] Y. J. Kang, "Prediction of Calf Diseases using Ontology and Bayesian Network," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 21, no. 10, pp. 1898-1908, Oct. 2017.
- [15] W. Lee, J. Ryu, T. -W. Ban, S. H. Kim, and H. Choi, "Prediction of Water Usage in Pig Farm based on Machine Learning," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 21, no. 8, pp. 1560 - 1566, Aug. 2017.
- [16] W. Lee, S. H. Kim, J. Ryu, and T. W. Ban, "Fast Detection of Disease in Livestock based on Deep Learning," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 21, no. 5, pp. 1009-1015, May 2017.
- [17] AI Hub [Internet]. Available: <https://aihub.or.kr/>.
- [18] Kaggle "Zoo Animal Classification" [Internet]. Available: <https://www.kaggle.com/datasets/uciml/zoo-animal-classification>.
- [19] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, no. 6, pp. 610-621, Nov. 1973.
- [20] Y. H. Cho, "A Performance Improvement of GLCM Based on Nonuniform Quantization Method," *Journal of Korean Institute of Intelligent Systems*, vol. 25, no. 2, pp. 133-138, Apr. 2015.
- [21] V. S. Thakare and N. N. Patil, "Classification of Texture Using Gray Level Co-Occurance Matrix and Self-Organizing Map," in *Proceedings of International Conference on Electronic Systems, Signal Processing and Computing Technologies*, Nagpur, India, pp. 350-355, 2014.
- [22] T. X. Luong, B. -K. Kim, and S. -Y. Lee, "Color image processing based on Nonnegative Matrix Factorization with Convolutional Neural Network," in *Conference Proceedings 2014 International Joint Conference on Neural Networks IEEE*, Beijing, China, pp. 2130-2135, 2014.
- [23] National Institute of Animal Science, "Developing of early management method using the Smart ICT in diarrhea calves," Rural Development Administration, Technical Report, 2019.
- [24] J. U. Jeong, H. J. Yoon, and U. K. Moon, "Introduction of 'Disease BioPortal' program, a real-time animal disease monitoring system," *Journal of the Korean Veterinary Medical Association*, vol. 48, no. 12, pp. 725-729, Dec. 2012.



최동운(Doug-Oun Choi)

1984년 2월 전북대학교 전산통계학과 전자계산학(박사)
1986년 2월 전북대학교 전산통계학과 전산통계학(석사)
1997년 2월 전북대학교 전산통계학과 (학사)
2006년~ 현재 원광대학교 컴퓨터소프트웨어공학과 교수
※ 관심분야 : 데이터베이스, 소프트웨어공학, 인공지능



강윤정(Yun-Jeong Kang)

2006년 8월 전북대학교 전산통계학과 이학박사
2022년 현재 원광대학교 교양교육원 조교수
※ 관심분야 : 지식표현, 상황인식, 인공지능