

논문 2021-1-10 <http://dx.doi.org/10.29056/jsav.2021.06.10>

# 다변량 데이터와 순환 신경망을 이용한 젖소의 유방염 진단예측 방법

박기철\*, 이성훈\*, 박재화\*\*†

## Method for predicting the diagnosis of mastitis in cows using multivariate data and Recurrent Neural Network

Gicheol Park\*, Seonghun Lee\*, Jaehwa Park\*\*†

### 요 약

젖소에 있어 유방염은 농가의 낙농 생산성을 저해하는 주된 요인이며 이를 해결하기 위해 지난동안 폭넓은 연구가 이루어졌다. 하지만 유방염에 대한 연구는 사후 진단에 국한되어왔으며 이마저도 단일 센서를 활용하는 것이 주류이다. 본 연구에서는 생체 데이터와 환경 데이터를 이용하여 다음 날의 유방염 발병여부를 예측하는 모델을 개발하였다. 데이터는 충청남도 농가에 설치된 착유기와 센서들로부터 수집되었으며 3주간의 데이터를 다변량 데이터로 구성하였다. 유방염 진단예측을 위해 순환 신경망 모델을 사용하였고, 그 결과 유방염을 82.9%의 정확도로 예측하였다. 데이터 수집 기간을 다양하게 하여 예측 성능을 비교하였고 여러 모델과 성능을 비교하여 모델의 우수성을 확인하였다.

### Abstract

Mastitis in cows is a major factor that hinders dairy productivity of farms, and many attempts have been made to solve it. However, research on mastitis has been limited to diagnosis rather than prediction, and even this is mostly using a single sensor. In this study, a predictive model was developed using multivariate data including biometric data and environmental data. The data used for the analysis were collected from robot milking machines and sensors installed in farmhouses in Chungcheongnam-do, South Korea. The recurrent neural network model using three weeks of data predicts whether or not mastitis is diagnosed the next day. As a result, mastitis was predicted with an accuracy of 82.9%. The superiority of the model was confirmed by comparing the performance of various data collection periods and various models.

**한글키워드 :** 유방염 예측, 다변량 데이터, 정보통신기술, 스마트팜, 딥러닝

**keywords :** Mastitis Prediction, Multivariate data, ICT, Smart Farm, Deep Learning

\* 중앙대학교 컴퓨터공학과

\*\* 중앙대학교 소프트웨어학과

† 교신저자: 박재화(email: jaehwa@cau.ac.kr)

접수일자: 2021.06.03. 심사완료: 2021.06.14.

게재확정: 2021.06.20.

## 1. 서 론

한국의 젖소 두당 원유생산량은 2019년 기준 10,769 L로, 세계 3위 수준의 원유 생산 기술을

보유하고 있다[1]. 그러나 높은 생산 기술에 비해 집약적 축산 환경에 따른 축사 오염이 만연하고 있으며, 이로 인해 환경오염과 질병이 가속화되고 있는 실정이다[2]. 이는 착유의 안정성에 부정적인 영향을 미치는 중대한 요소이다.

불안정적인 착유는 우유의 질을 떨어뜨리고, 젖소의 스트레스를 유발한다[3-4]. 이는 우유 생산과 이를 통한 가공품의 생산이 주 목적인 낙농가에 막대한 경제적인 피해를 입힌다. 따라서 젖소의 질병관리는 사전에 예방하고 적절한 조치를 취하는 것이 중요하다[5-6].

하지만 사람이 젖소의 상태를 매번 확인하는 데에는 많은 비용과 시간이 소요된다. 이에 따라 낙농업에서는 정보통신기술(Information and Communication Technology, ICT)을 결합하여 로봇착유기와 젖소에 부착된 센서를 통해 생체 데이터 및 환경 데이터를 수집하고 이를 활용하여 질병을 진단하거나 예측하고자 하였다[7].

Xudong Zhang은 열화상 사진을 바탕으로 체온 변화에 따른 유방염 진단 모델을 제안하였고[8] Colin Tobin은 자이로스코프를 활용하여 소의 질병을 진단하고자 하였다[9]. 대부분의 연구들은 이처럼 단일 데이터를 사용하여 분석을 진행하였다. 하지만 질병의 전조 및 증상은 활동량, 체온, 우유의 성분 변화 등 여러 가지로 나타나기 때문에 단일 센서 데이터를 통해 질병을 진단하는 데는 한계가 존재한다. 또한 현재까지의 연구 목표는 예측이 아닌 진단에 초점이 맞춰졌다. 이미 질병이 발견된 시점에서 치료를 위해 젖소의 착유는 중단되고, 질병으로 인한 염증과 통증은 젖소의 건강상태에 부정적인 영향을 미친다. 따라서 질병 발병 시점 이전에 미리 젖소의 상태를 파악하고 예방하는 것이 중요하다.

Bettina Miekley는 우유의 체세포 수를 사용해 젖소의 유방염과 보행장애를 진단하고자 하였으며[10], Leo Weissbart는 유방염 진단을 위한 체

세포 수를 예측하고자 한 연구에서 다층 퍼셉트론은 평균보다 낮은 에러율을 가지는 것을 확인하였다[11]. 체세포 수는 우유 속의 백혈구 수를 나타내는 것으로 세균성 질환인 유방염을 진단하는데 중요한 요소이지만, 검출에 소요되는 시간이 길기 때문에, 예측을 위한 변수로는 적합하지 않다[12].

이에 본 논문은 기존의 단일 모델 중심의 분석 모델이 아닌 다변량 데이터를 활용하여 유방염을 예측하였다. 체온, 활동량, 유단백, 유당, 유지방, 착사 내부 및 외부 온도 등 다양한 센서 데이터를 유방염 예측에 활용하였고, 각각의 데이터가 예측에 미치는 영향을 변수 중요도(Feature Importance) 분석을 통해 알아보았다.

모델의 우수성을 입증하기 위해 다른 모델과의 비교를 진행하였다. 다양한 데이터 수집기간과 랜덤 포레스트, 그래디언트 부스팅 모델(LightGBM), MLP(Multi-Layer Perceptron)와 같은 여러 예측 알고리즘을 이용한 모델과의 성능을 비교하였다. 또한 교차검증을 통해 모델의 과적합을 방지하고 모델의 안정성을 높이고자 하였다. 모델의 성능을 평가하기 위해 단순히 정확도만을 제시하지 않고 정밀도와 재현율, F1-Score 같은 추가적인 지표를 제시하였다. 모든 지표를 종합적으로 평가함으로써 신뢰성을 확보하였다.

## 2. 데이터 및 연구방법

### 2.1 데이터 수집

본 연구는 대한민국 충청남도 지역의 2개의 목장의 착유 데이터를 활용하였다. 로봇 착유기와 젖소에 부착된 센서를 통해 총 288마리의 소로부터 115,238개의 데이터를 수집하였다. 수집 데이터는 우유의 유지방, 유당, 유단백, 전기 전도도,

등의 성분 데이터와 유량과 활동량, 체온, 축사 내/외부 온도 및 습도를 포함한다. 수집된 데이터는 무선 네트워크를 통해 중앙 서버로 전달되어 데이터베이스에 저장된다.

유방염 최초 진단일로부터 6 주 전까지의 모든 데이터를 하나의 분석 데이터로써 활용하였다. 각각의 분석 데이터를 날짜를 기준으로 반으로 나눠 유방염 발생일까지의 데이터를 양성, 나머지 절반을 음성 데이터로 정의한다. 그림 1은 하나의 분석 데이터의 항목들을 일별 시계열 그래프로 나타낸 것이다. 첫 번째 그래프는 자이로 센서로부터 얻은 젖소의 활동량, 두 번째 그래프는 젖소의 4개 유방별 전기전도도, 세 번째 그래프는 유량, 네 번째는 우유의 유당, 유지방 및 유단백을 나타낸 것이다. 다섯 번째와 여섯 번째 그래프는 각각 축사 내부와 외부의 온도 및 습도를 나타낸 것이다. 음성 데이터와 양성 데이터를 구분하기 위해 빨간색 점선으로 표시하였다.

유량 및 우유 성분 데이터는 일별 총 데이터의 합을 착유 횟수로 나눈 평균으로 계산하였다. 활동량 데이터는 자이로스코프의 x, y, z축 가속도 값의 제곱의 합의 제곱근으로 정의하였다. 따라서 활동량은 다음과 같이 나타낸다.

$$Act(C_i) = \sqrt{C_{i_x}^2 + C_{i_y}^2 + C_{i_z}^2} \quad \dots\dots (1)$$

이 때, i는 개체 번호를 나타내며  $C_x, C_y, C_z$ 는 x, y, z축으로의 가속도 값을 나타낸다. 축사 내부와 외부 온도 및 습도는 10분 간격으로 수집되었고, 각각의 데이터는 일평균으로 변환하여 사용하였다.

## 2.2 데이터 전처리

수집한 데이터에는 하나 이상의 내용이 존재하지 않는 데이터, 유방염 진단 기록이 없는 데이터, 유방염 진단일이 하루밖에 되지 않아 거짓 양성 가능성이 의심되는 데이터가 포함되어 있다. 이러

한 데이터는 부정확한 예측 결과를 야기하기 때문에 본 연구에서는 수집한 데이터를 3단계에 걸쳐 정제하였다.




그림 1. 유방염 진단 데이터  
Fig. 1. Mastitis Diagnostic Data

그림 2는 데이터 전처리 과정을 나타낸 것이다. 전체 데이터를 3개의 필터링 과정을 통해 정제하였다. 첫 번째 필터는 유방염 진단일이 존재하지 않는 데이터를 제거한다. 두 번째 필터는 분석 기간의 데이터가 모두 채워지지 않은 불완전 데이터를 제거한다. 마지막으로 세 번째 필터는 유방염 진단일이 최초 진단일을 제외하고 진단 기록이 존재하지 않는 개체를 제거한다. 필터링된 개체의 데이터는 크기가 차이가 존재하기 때문에 Z-score를 사용하여 정규화하고 분석데이터로 활용하였다.

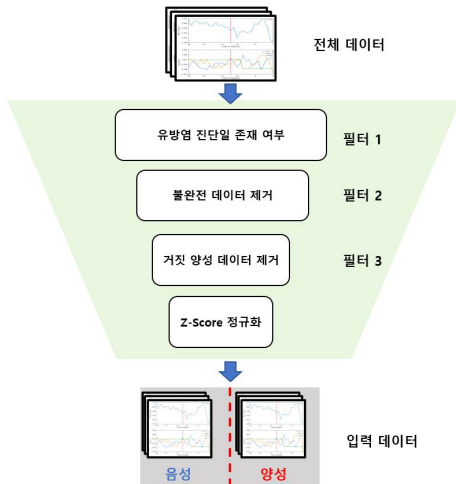


그림 2. 데이터 전처리 과정  
Fig. 2. Data Pre-processing Procedure

### 2.3 변수 중요도

머신러닝은 예측 모델을 생성하기 위해 변수를 사용한다. 높은 정확도를 얻기 위해서는 적절한 변수들의 조합을 사용하는 것이 중요하다. 변수 중요도가 낮은 불명확한 변수를 사용하면 모델이 과적합되거나 모델의 복잡도(Complexity)가 증가하는 문제가 발생한다[13]. 그렇기 때문에 예측하고자 하는 결과와 연관성이 높은 변수들을 찾아서 모델에 활용하는 것이 모델의 복잡도를 줄이고, 과적합을 막는데 유리하다. 따라서 모델

에 대해서 각각의 변수가 기여하는 정도를 측정하고, 예측에 중요한 영향을 미치는 변수들만을 가지고 예측을 진행하였다.

본 연구에서는 변수 중요도를 측정하기 위해 두 가지 방법을 사용하였다. 첫 번째로 각각의 변수들을 하나씩 제거하면서 모델의 성능의 변화를 관찰한다. 이는 가장 단순하지만 변수 조합에 따라 얼마나 모델의 성능이 떨어지는지를 실제로 볼 수 있다. 두 번째로 변수들 간의 상관계수를 분석하였다. 상관계수가 큰 변수들은 두 변수의 증감 추이가 비슷하다는 것으로, 예측 값의 편향을 유발하고 모델의 성능과 안정성에 부정적인 영향을 끼칠 수 있다. 그림 3은 수집된 데이터간의 상관계수를 Heatmap으로 나타낸 것으로 상관계수가 0.8이 넘는 변수들을 예측 데이터에서 제외하였다.

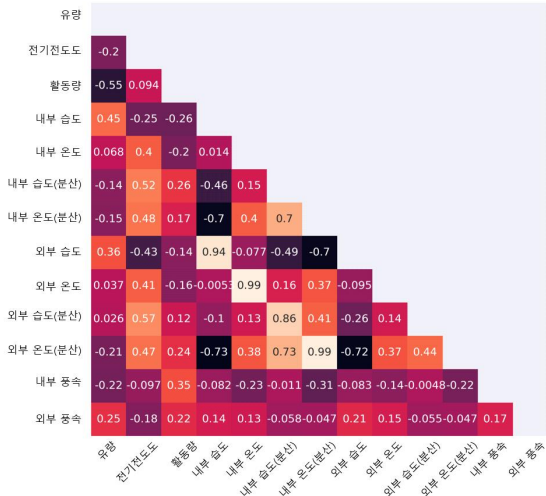


그림 3. 데이터간의 상관계수 히트맵  
Fig. 3. Correlation coefficient Heatmap between Data

### 2.4 예측 모델

각각의 예측 모델은 트리의 개수, 은닉층(Hidden Layer)의 수, 학습률 같은 초매개변수(Hyper Parameter)에 따라 성능이 달라진다. 그렇기 때문에 최적의 결과를 얻기 위한 초매개변

수 값의 조정이 필요하다. 본 연구에서는 모델의 성능을 최적화하기 위해 전체 데이터를 훈련, 검증, 테스트 세트로 구분하였다. 첫 번째로 훈련 데이터를 사용하여 여러 가지 초매개변수를 설정하고 모델을 학습시킨다. 두 번째로 검증 데이터를 사용하여 모델의 성능을 평가하였다. 설정한 여러 가지 모델의 성능을 비교하고 가장 성능이 좋은 모델의 초매개변수 값을 설정하였다. 고정된 훈련 데이터와 검증 데이터를 활용하여 모델의 성능을 평가하는 경우, 특정 데이터 세트에 대하여 초 매개변수를 조정하기 때문에 과적합이 일어나는 문제가 생길 수 있다. 이를 해결하기 위해 훈련 데이터와 검증 데이터의 교차 검증(Cross Validation)을 실시하였다. 전체 데이터를 6:2:2의 비율로 나누고 각각을 훈련 데이터, 검증 데이터, 테스트 데이터로 구분하였다. 교차 검증에는 Stratified K-Fold 교차 검증을 사용하였다. Stratified K-Fold 교차 검증은 데이터의 분포를 최대한 균일하게 유지하여 Fold를 구성하기 때문에 데이터의 편향을 막을 수 있다[14].

위와 같은 과정을 통해 과적합 문제를 최소화함으로써 특정 입력 데이터, 초매개변수 조합에 대한 의존도를 줄일 수 있으며 신뢰도 높은 모델을 개발할 수 있다.

### 3. 결과

유방염 예측을 위한 모델으로 RNN을 사용하였다. 모델의 입력 데이터로 3주 간의 모든 센서 데이터를 사용하였고, 다음날의 유방염 진단 결과를 출력 값으로 정의하였다. 다른 알고리즘을 이용한 모델과의 정확도 비교를 통해 모델의 우수성을 확인하였다.

표 1은 본 연구에서 가장 우수한 성능을 보인 RNN 모델의 성능을 나타낸 것이다. 정확도만으

로 모델의 성능을 판단할 경우, 예측 변수의 비율이 불균형할 때 모델의 신뢰도가 떨어진다는 단점이 있다.

$$\begin{aligned}
 Accuracy &= \frac{TP + TN}{TP + FN + FP + TN} \\
 Precision &= \frac{TP}{TP + FP} \\
 Recall &= \frac{TP}{TP + FN} \quad \dots(2) \\
 Specificity &= \frac{TN}{TN + FP} \\
 F1-Score &= \frac{Recall}{Precision + Recall}
 \end{aligned}$$

표 1. 유방염 예측 모델 성능  
Table. 1. Mastitis Prediction Model Performance

	정상	유방염 진단
Accuracy	0.832	0.825
Precision	0.809	0.797
Recall	0.813	0.793
Specificity	0.782	0.801
F1-Score	0.797	0.797

모델의 신뢰도를 높이기 위해 본 연구에서는 식 2와 같이 정확도와 함께 정밀도(Precision)와 재현율(Sensitivity, Recall), 특이도(Specificity), F1-Score를 제시하였다[15].

정확도는 전체 데이터 중 예측 결과와 실제 결과 값이 동일한 정도를 나타낸다. 이는 모델이 얼마나 정확하게 참 혹은 거짓을 구분하는지를 알 수 있는 지표다. 정밀도는 모델이 참이라고 예측한 데이터 중 실제 참 값의 비율이다. 정밀도가 높을수록 사용자가 원하는 데이터를 모델이 제대로 분류하였는지를 알 수 있다. 재현율은 정밀도와 반대로 실제 참 값을 모델이 참이라고 예측한 비율을 나타낸다. 이를 통해 모델이 실제로 구분하길 원하는 데이터를 얼마나 잘 예측하는지를 알 수 있다. 특이도의 경우 실제 거짓 값 중 모델이 실제로 거짓이라고 예측한 비율이다. 특

이도가 높은 모델은 유방염에 걸리지 않은 모델을 유방염에 걸렸다고 진단할 확률이 낮다. F1 Score는 정밀도와 재현율의 조화평균으로 정의되며 클수록 분류가 잘 된 것으로 판단한다.

표 2는 입력 데이터 종류를 하나씩 제외한 것을 입력 데이터로 사용한 모델의 성능을 나타낸 것이다. 모든 데이터를 사용한 모델과 비교해서 전기전도도를 제외한 모델의 성능이 크게 차이가 없는데 반해, 온도와 습도를 제외한 모델의 성능이 0.2 이상 떨어지는 것을 확인하였다.

표 2. 학습 데이터에 따른 모델 정확도  
Table. 2. Model accuracy according to training data

학습 데이터	정상	유방염 진단
모든 데이터	0.803*	0.788*
전기전도도 제외	0.791	0.757
유량 제외	0.715	0.739
활동량 제외	0.707	0.631
유당, 유단백, 유지방 제외	0.673	0.685
온도 & 습도 제외	0.426	0.437

\* 가장 좋은 성능을 나타냄

표 3은 데이터 수집 기간과 예측 모델별 유방염 예측 정확도를 나타낸 것이다. 데이터 수집 기간을 3주로 설정한 모델의 정확도가 가장 높은 것을 확인할 수 있다. 또한 그 중에서도 RNN을 사용한 모델이 82.9%의 정확도로 가장 정확하게 유방염을 예측하였음을 알 수 있었다. 시계열 데이터 처리에 강점을 가지고 있는 순환 신경망 모델의 특징을 고려했을 때, 이는 유의미한 결과로 볼 수 있다. 가장 높은 성능을 보인 순환 신경망 모델에 단변량 데이터와 다변량 데이터를 입력 데이터로 사용했을때의 성능을 비교하여 다변량 모델의 우수성을 확인하였다.

표 4는 단일 모델 대비 다변량 모델의 정확도 차이를 나타낸 것이다. 예측에는 3주간의 데이터

수집기간을 활용한 RNN 모델을 사용하였다. 유량, 활동량, 전도도를 각각 입력 데이터로 사용한 모델의 정확도는 0.5 미만의 저조한 예측률을 보여주었다. 이는 여러 변수가 함께 영향을 미치는 유방염의 특성을 나타냄과 동시에 단변량 예측 모델의 한계를 보여준다. 온도와 습도를 사용한 모델이 0.658의 비교적 높은 정확도를 나타냈지만, 모든 데이터를 활용한 다변량 모델의 0.793에는 미치지 못하는 것을 확인할 수 있다.

표 3. 데이터 수집기간과 모델별 유방염 예측 정확도  
Table. 3. Mastitis prediction accuracy by data collection period and model

기간	모델	정상	유방염 진단
2주	RF	0.691	0.733*
	LGBM	0.630	0.658
	MLP	0.704*	0.695
	RNN	0.653	0.682
3주	RF	0.782	0.721
	LGBM	0.666	0.752
	MLP	0.703	0.769
	RNN	0.832*	0.825*
4주	RF	0.668	0.666
	LGBM	0.658	0.609
	MLP	0.737	0.624
	RNN	0.777*	0.731*

RF : Random Forest, LGBM : LightGBM

MLP : Multi-layer Perceptron, RNN : Recurrent Neural Network

\* 가장 좋은 성능을 나타냄

표 4. 단일 데이터 기반 모델의 예측 정확도  
Table. 4. Accuracy of a single data-driven model

학습 데이터	정상	유방염 진단
모든 데이터	0.788*	0.798*
전기전도도	0.344	0.388
유단백	0.482	0.471
유당	0.373	0.399
유지방	0.436	0.445
활동량	0.637	0.599
유량	0.691	0.674
온도 & 습도	0.661	0.655

\* 가장 좋은 성능을 나타냄

#### 4. 결론

다변량 데이터와 순환 신경망을 이용하여 젖소의 유방염 발생을 예측하였다. 3주간의 데이터를 입력 데이터로 사용하였으며 82.9%의 정확도의 유방염 예측 성능을 보여주었다. 변수 중요도 분석을 통해 중요도가 낮은 변수들을 제거하였고, 이를 통해 기존의 단변량 데이터 기반 모델보다 뛰어난 성능을 가짐을 확인하였다.

모델의 우수성을 입증하기 위해 다양한 데이터 수집기간과 다른 알고리즘을 이용한 모델과의 성능을 비교하였으며, 타 모델 대비 10%p 이상의 높은 정확도를 가짐을 확인하였다. 또한 교차검증을 통해 모델의 안정성을 높였고, 정확도 외에 추가적인 지표를 제시함으로써 신뢰성을 확보하였다.

하지만 본 연구에서 사용한 모델은 산차, 질병 이력, 섭취 정보 등의 특성을 모델에 포함하지 않았고 소수의 농장 데이터만을 사용하였기에 표준 모델로서의 역할에는 한계가 존재한다.

따라서 향후 더 많은 농장의 데이터를 확보하고 추가적인 종류의 데이터를 모델의 입력 값으로써 활용하여 유방염 예측의 표준 모델로서의 신뢰성을 확보할 것이다.

본 결과물은 농림축산식품부의 재원으로  
첨단생산기술개발사업의 지원을 받아  
연구되었음(318005-4).

#### 참고 문헌

[1] 농림축산식품부, 농협경제지주 젖소개량사업소, “2019년도 한국 유우군 능력검정 사업보고서”, 2019.  
[2] S.Tamminga, “Nutrition Management of

Dairy Cows as a Contribution to Pollution Control”, *Journal of Dairy Science*, vol. 75, Issue 1, 345-3576, 1992.  
[3] Yuri Fujimoto, Hirotaka Ito, Hidetoshi Higuchi, Hiroshi Ohno, Kohei Makita, “A case-control study of herd-and cow-level risk factors associated with an outbreak of *Mycoplasma mastitis* in Nemuro, Japan”, *Preventive Veterinary Medicine*, vol. 177, 2020.  
[4] Sławomir Zduńczyk, Tomasz Janowski, “Bacteriophages and associated endolysins in therapy and prevention of mastitis and metritis in cow: Current knowledge”, *Animal Reproduction Science*, vol. 218, 2020.  
[5] N.Tzanidakis, C.N.Brozos, N.Voutzourakis, A.Stefanakis, E.Malama, D.Zoller, A.Zdragkas, J.Hickford, S.Sotiraki, E.Kiossis, “Effect of abiotic and biotic factors on subclinical mastitis occurrence in low-input dairy sheep production systems”, *Small Ruminant Research*, Volume 198, 106341, May 2021.  
[6] M.A. Puerto, E. Shepley, R.I Cue, D. Warner, J. Dubuc, E. Vasseur, “The hidden cost of disease: I. Impact of the first incidence of mastitis on production and economic indicators of primiparous dairy cows”, *Journal of Dairy Science*, Volume 104, 2021. DOI: 10.3168/jds.2020-19584  
[7] Shivank Vyas, Vipin Shukla, Nishant Doshi, “FMD and Mastitis Disease Detection in Cows Using Internet of Things(IOT)”, *Procedia Computer Science*, vol. 160, 728-733. 2019.  
[8] Xudong Zhang, Xi Kang, Ningning Feng, Gang Liu, “Automatic recognition of dairy cow mastitis from thermal images by a deep learning detector”, *Computers and Electronics in Agriculture*, vol. 178, 2020.  
[9] Colin Tobin, Derek W. Bailey, Mark G. Trotter, Lauren O'Connor, “Sensor based

disease detection: A Case study using accelerometers to recognize symptoms of Bovin Ephemeral Fever”, Computers and Electronics in Agriculture, vol. 175, 2020.

[10] Bettina Miekley, Imke Traulsen, Joachim Krieter, “Detection of mastitis and lameness in dairy cows using wavelet analysis”, Livestock Science, vol. 148, Issue 3, 227-236, 2012.

[11] Leo Weissbart, “Performance Analysis of Multilayer Perceptron in Profiling Side-Channel Analysis”, Cryptology ePrint Archive, Report 2019/1476, 2019.

[12] Jose Carlos de Figueiredo Pantoja, Pamela Ruegg, “Understanding and using somatic cell counts to improve milk quality”, Irish Journal of Agricultural and Food Research, vol. 52, Issue 21, 101-117, 2013.

[13] Guangfen Wei, Jie Zhao, Yanli Feng, Aixiang He, Jun Yu, “A Novel hybrid feature selection method based on dynamic feature importance”, Applied Soft Computing, vol. 93, 2020.

[14] Ron Kohavi, “A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection”, Appears in the International Joint Conference on Artificial Intelligence, vol. 2, 1137-1143, 1995.

[15] Xueliang Zhang, Xuezhi Feng, Pengfeng Xiao, Guangjun He, Liujun Zhu, “Segmentation quality evaluation using region-based precision and recall measures for remote sensing images”, ISPRS Journal of Photogrammetry and Remote Sensing, vol. 102, 73-84, 2015.

— 저 자 소 개 —



박기철(Gicheol Park)

2020.2 중앙대학교 컴퓨터공학부 졸업  
 2020.3-현재 : 중앙대학교 컴퓨터공학과 석사과정  
 <주관심분야> 패턴인식, 인공지능



이성훈(Seonghun Lee)

2017.2 중앙대학교 컴퓨터공학부 졸업  
 2019.2 중앙대학교 컴퓨터공학과 석사  
 2019.3-현재 : 중앙대학교 컴퓨터공학과 박사과정  
 <주관심분야> 시계열분석, 데이터분석



박재화(Jaehwa Park)

1989 한양대학교 전자공학과 졸업  
 1991 한양대학교 전자공학과 석사  
 2000 Univ. at Buffalo 박사  
 2000-2003 Motorola, Inc. 연구원  
 2003-현재 : 중앙대학교 교수  
 <주관심 분야> 패턴인식, 인공지능