

## 의사결정트리를 이용한 돈사 환경데이터와 일당증체 간의 연관성 분석 모델 개발

한강휘 · 이용섭\* · 성길영

### Development of a model to analyze the relationship between smart pig-farm environmental data and daily weight increase based on decision tree

KangHwi Han · Woongsup Lee\* · Kil-Young Sung

Department of Information and Communication Engineering, Gyeongsang National University, Tongyeong  
53064, Korea

#### 요 약

최근 농업분야에서 IoT(Internet of Things)기술을 통해 다양한 생체 및 환경 정보를 DB(data base)로 구축할 수 있게 되면서 빅 데이터를 이용한 기계학습 분석이 증가하고 있다. 기계학습 분석을 통해 농업의 생산량과 가축의 질병 등을 예측할 수 있게 되어 농업경영에서 효율적인 의사결정을 돕는다. 본 논문에서는 스마트 돈사의 다양한 환경데이터와 몸무게데이터를 이용하여 환경정보와 일당증체의 연관성 모델을 도출하고 그 정확도를 분석하였다. 이를 위해 기계학습의 M5P tree 기법을 적용하였다. 분석을 통해 일당증체량이 풍속에 큰 영향을 받는 것을 확인하였다.

#### ABSTRACT

In recent days, IoT (Internet of Things) technology has been widely used in the field of agriculture, which enables the collection of environmental data and biometric data into the database. The availability of big data on agriculture results in the increase of the machine learning based analysis. Through the analysis, it is possible to forecast agricultural production and the diseases of livestock, thus helping the efficient decision making in the management of smart farm. Herein, we use the environmental and biometric data of Smart Pig farm to derive the accurate relationship model between the environmental information and the daily weight increase of swine and verify the accuracy of the derived model. To this end, we applied the M5P tree algorithm of machine learning which reveals that the wind speed is the major factor which affects the daily weight increase of swine.

**키워드** : 양돈, 의사결정트리, 기계학습, M5P tree 알고리즘, 스마트 돈사

**Key word** : Swine, Decision tree, Machine learning, M5P tree algorithm, Smart pig-farm

Received 22 September 2016, Revised 29 September 2016, Accepted 03 October 2016

\* Corresponding Author Woongsup Lee (E-mail: wslee@gnu.ac.kr, Tel:+82-55-772-9271)

Department of Information and Communication Engineering, Gyeongsang National University, Tongyeong 53064, Korea

Open Access <http://doi.org/10.6109/jkice.2016.20.12.2348>

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

최근에 국내 축산업은 구제역, AI 등 전염성 가축질병으로 많은 피해를 입어 축산농가의 경제적 피해가 늘어났다. 이런 국내 축산업의 문제점을 해결하기 위해 IoT(Internet of Thing)기술적용이 점차 증가하고 있는 추세이다. IoT기술이 농업 및 축산업 분야에 활발하게 적용되면서 더 적은 수의 인력으로 돈사관리를 효율적으로 할 수 있게 되었다. 특히 미국이나 유럽 등 축산선진국에는 많은 농장에 이미 적용되어있다. IoT기술을 이용하여 데이터를 수집하면서 자동으로 많은 양의 데이터(빅 데이터)를 수집 할 수 있게 되었고, 자연스럽게 이러한 빅 데이터를 활용한 기계학습 분석으로 이어졌다.

[1]에서는 닭 무리의 움직임 데이터를 수집해서 기계학습기법의 베이지안(Bayesian), 회귀(Regression)를 통해 다양한 움직임으로 닭의 질병예측방안을 개발했다. [2,3]에서는 분석의 정확도를 높이기 위해 많은 양의 농장데이터와 젖소데이터를 확보하여 젖소의 생식능력에 영향을 미치는 요인들을 기계학습기법인 의사결정트리(Decision Tree), 랜덤 포레스트(Random Forest), 나이브 베이즈 분류(Naive Bayes Classification), 베이지안 네트워크(Bayesian Network), 배깅(bagging)을 이용해서 분석하였고 이를 통해 어떠한 환경요소가 임신에 영향이 있는지 밝혔다.

양돈을 위한 스마트 돈사에서서는 각 개체(비육돈, 육성돈, 포유돈, 자돈, 모돈등)의 생체데이터 및 환경데이터를 실시간으로 수집할 수 있다. 수집된 데이터에 기계학습을 적용하여 돈사관리를 효율적으로 하려는 많은 연구가 진행되고 있다.

최근 양돈관리 프로그램인 Pigplan에 축적된 데이터베이스를 기반으로 모돈 생산성 예측모델이 개발되었다[4]. [4]의 연구에서는 수집된 데이터를 훈련데이터 셋(Training Set), 유효성데이터 셋(Validation Set), 시험데이터 셋(Test Set)으로 각각 40%, 30%, 30% 비율로 나누고, 기계학습 알고리즘인 인공신경망(ANN), 로지스틱 회귀(Logistic Regression), KNN(K-Nearest Neighbor), 의사결정트리, 앙상블(Ensemble)을 이용하여 오차와 예측 정확도를 비교하였다. 또한 돈사에 마이크를 설치하여 모돈의 분만 단계에서 환경의 상태를 구분하고 그에 따른 발생소리를 녹음하여 주파수로 변환한 다음 이를 Weka를 이용해서 분류하는 방식이

제안되었다[5]. 그리고 [6,7]의 연구에서 돈사에 카메라를 설치하고 개체의 움직임을 모니터링 하여 데이터를 수집 한 후 기계학습에 적용하여 개체의 건강을 파악하고 복지에 대한 수치를 예측했다. [8]의 연구에서는 돼지 농가에서 다양한 데이터를 수집하고 실제 측정된 데이터를 기계학습기법인 의사결정트리(Decision Tree)의 C4.5알고리즘을 적용해서 모돈 집단을 분석했다.

많은 연구가 진행되어 왔지만 현재까지는 인력을 통한 돈사의 센서 제어와 개체 모니터링을 통한 연구까지만 하고 자동화 시스템을 위한 돈사의 환경데이터와 개체의 체중변화(일당중체)간의 연관성을 분석한 연구는 없었다. 하지만 실제 양돈농가에서는 일당중체가 돼지의 생산성을 나타내므로 일당중체의 분석이 중요하다. 따라서 본 연구에서는 기계학습기법인 의사결정트리(Decision Tree)를 이용하여 돈사 환경데이터와 일당중체간의 연관성모델을 개발하고 예측 정확도를 분석한다. 본 논문의 2장은 데이터 수집방법을 설명하고 3장에서는 적용 알고리즘을 알아보고 연구 방법을 자세히 제시하고, 4장에서는 비교 분석된 결과를 알아본다. 마지막으로 5장에서는 논문을 마무리 한다.

## II. 데이터 수집과 설정

스마트 돈사에서서는 센서 네트워크를 이용하여 많은 양의 데이터가 수집된다. 본 연구에서는 효율적인 데이터 수집을 위하여 돈사에 다양한 센서를 설치했다. 그림 1은 실제 설치된 센서장비를 보여준다. 설치 후 하루 동안 장치가 설치된 스마트 돈사의 환경과 개체의 변화를 일정한 주기로 측정하여 데이터를 수집하였다.



Fig. 1 Data collection facilities.

본 논문에서는 육성돈을 바탕으로 2015년 4월 16일부터 2015년 7월 12일까지의 날짜별 기간 동안 실험돈사 환경데이터와 3개체의 생체데이터(몸무게)를 수집하고 종합한 264샘플을 사용했다. 실험돈사에서 수집된 환경데이터와 생체데이터의 연관성을 찾기 위해 각 개체의 일당증체를 기준으로 영향을 끼치는 환경데이터와 개체데이터의 몸무게를 속성으로 설정했다. 사용된 환경데이터는 최고온도, 최소온도, 평균온도, 최고습도, 최소습도, 평균습도, 최고CO<sub>2</sub>발생량, 최소CO<sub>2</sub>발생량, 평균CO<sub>2</sub>발생량, 최대풍속, 최소풍속, 평균풍속이며 Threshold는 클래스를 나타낸다. 첫 번째 Threshold는 일당증체가 0.6kg이하는 0(저성장)으로 0.7kg이상이면 1(고성장)로 설정했다. 두 번째는 0.4kg이하면 0(저성장), 0.5kg과 0.9kg사이는 1(평균성장), 나머지는 2(고성장)로 설정했다. 이렇게 일당증체량의 범위를 일정하게 나누어 사용함으로써 예측 정확도가 높아지고 오류를 줄일 수 있다. 표 1은 속성과 클래스의 설명이다.

**Table. 1** Attribute of environmental data in the pig-farm.

Mark	Explanation	Unit
Temp.avg	Average Temperature	℃
Temp.max	Maximum Temperature	℃
Temp.min	Minimum Temperature	℃
Hum.avg	Average Humidity	%
Hum.max	Maximum Humidity	%
Hum.min	Minimum Humidity	%
CO <sub>2</sub> .Avg	Average CO <sub>2</sub>	ppm
CO <sub>2</sub> .Max	Maximum CO <sub>2</sub>	ppm
CO <sub>2</sub> .Min	Minimum CO <sub>2</sub>	ppm
Wind.Avg	Average Wind	m/s
Wind.Max	Maximum Wind	m/s
Wind.Min	Minimum Wind	m/s
Weight	Weight	kg
Threshold	Daily Weight Increase	kg
	0 <=0.6, 1 >=0.7	Double
	0 <= 0.4, 1 <= 0.9, 2 = Otherwise	Double

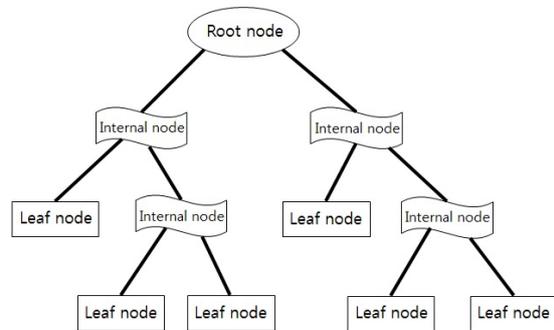
Threshold에서 Daily Weight Increase는 측정된 하루 동안 늘어난 몸무게(일당증체)이다. 본 연구에서는 똑같은 속성데이터 조건으로 일당증체와 두 가지 Threshold기반을 모두 분석하였다.

### III. 돈사환경 데이터와 일당증체간의 연관성 분석 모델

본 논문에서는 의사결정트리를 적용하여 데이터를 분석했다. 의사결정트리는 결과를 쉽게 이해할 수 있고 다양한 데이터에 적용할 수 있으며 데이터의 분류에 많이 사용된다. 클래스 값이 한정적 값이면 분류트리(Classification Tree)를 사용할 수 있고 일반적인 수치 값이면 회귀트리(Regression Tree)로 얻을 수 있다. 단계는 뿌리노드(Root Node), 잎 노드(Leaf Node), 내부 노드(Internal Node)3가지로 나뉜다. 데이터를 분류할 때 엔트로피(Entropy)공식을 사용하여 각 노드로 분류한다[9]. 엔트로피 공식은 다음과 같다.

$$Entropy(E) = - \sum_{j=1}^n (C_j) \log_2 p(C_j) \quad (1)$$

여기서 C는 클래스 이고 n은 전체 데이터 숫자이다. 즉 엔트로피는 모든 데이터 셋에서 j번째에서 클래스 값에 대한 probability에 로그를 취하고 곱하여 모두 더한다. 그림 2는 의사결정트리의 전반적인 모델을 보여 준다.



**Fig. 2** Decision tree model.

기계학습 알고리즘을 적용하기 위해서 Waikito대학에서 Java를 기반으로 하여 개발한 Weka 기계학습 툴을 사용한다. 본 논문에서는 Weka툴에 의사결정트리의 M5P tree를 적용한다. M5P tree는 데이터 샘플의 엔트로피를 사용하여 회귀트리를 구성한다. 그리고 과 적합(Over fitting)을 막기 위해 10배 교차검증(10-fold cross validation<sup>1)</sup>)을 적용한다. 다음으로는 전체 데이터에서

오차분석을 한다. 본 논문에선 Correlation Coefficient, MAE, RMSE를 이용하여 성능지표로 사용하였다.

Correlation Coefficient는 예상한 값과 실제 수치와의 연관성을 나타내는 값이다. 이 값은 다음과 같은 공식을 사용하여 계산하게 된다. 여기서 X는 실제 수치, Y는 예상한 값으로 나타내고  $X'$ 와  $Y'$ 는 각각 X와 Y의 표준편차이며  $\mu_X$ 와  $\mu_Y$ 는 평균을 의미한다.

$$\text{Correlation}(X, Y) = \frac{\text{COV}(X, Y)}{X'Y'} = \frac{E(XY) - \mu_X\mu_Y}{X'Y'} \quad (2)$$

COV(X, Y)는 공분산이고 식을 정리하면 E(XY)는 기댓값이며 X와 Y의 평균값을 곱하여 빼주면 공분산의 식이 성립한다. 값이 1에 가까우면 예상한 값이 정확하다는 것을 의미한다.

두 번째, MAE(Mean Absolute Error)는 예상 값( $PY_j$ )과 실제 값( $Y_j$ )을 빼고 절대 값으로 만들어서 평균을 구하는 계산 방식을 사용한다. 예측이 정확할수록 값이 0에 가까워진다[10].

$$MAE = \frac{1}{m} \sum_{j=1}^m |PY_j - Y_j| \quad (3)$$

세 번째, RMSE(Root Mean Square Error)는 다음과 같은 공식으로 계산하게 된다. 이 또한 작아질수록 성능이 좋다. 실제수치가 예측치보다 클 경우에 error value가 커진다[10].

$$RMSE = \frac{1}{m} \sum_{j=1}^m (PY_j - Y_j)^2 \quad (4)$$

마지막으로, MAE와 RMSE를 이용하여 각각의 값과 평균을 계산하여 예측한 수치와의 비율을 나타내는 각각의 Relative Absolute Error와 Root Relative Squared Error를 나타낸다. 값이 0에 가까울수록 좋다. 본 연구에서는 Correlation Coefficient, Mean Absolute Error, Root Mean Square Error, Relative Absolute Error, Root Relative Squared Error 그리고 사용한 샘플 개수를 비교하였다[10].

#### IV. 실험 및 분석

본 장에서는 클래스의 일당증체와 Threshold를 이용한 일당증체간의 비교 분석을 하고 마지막으로 각각 Threshold의 모든 샘플을 이용한 성능과 에러 분석을 통한 오차를 제거하여 나온 성능을 비교한다.

Table. 2 Performance analysis of using all samples.

	Daily Weight Increase	0<=0.6 1>=0.7	0<=0.4 1<=0.9 2=The rest
Correlation Coefficient	-0.067	0.2612	0.3592
MAE	1.3061	0.4512	0.6343
RMSE	5.4155	0.4804	0.7373
RAE	116%	91.5%	95.5%
RSE	101%	96.6%	93.6%
Total Number of Instances	264	264	264

표 2는 모든 샘플을 활용하여 기계학습을 적용했을 때 각 3개의 클래스에 대한 성능을 나타낸 것이다. 전체적으로 측정된 수치는 다른 두 클래스에 비해 일당증체가 가장 성능이 떨어지는 것을 볼 수 있는데 이는 세 개체의 측정된 일당증체데이터가 각각 다르고 체중 측정에서 발생된 오차 때문인 것으로 판단된다. 여기서 상대오차(RAE)가 100% 이상인 것은 과 적합(Over fitting)을 막기 위해 적용한 10-fold cross validation으로 인해 발생한다. 반면 오차를 보완하기 위해서 클래스 값의 범위를 한정할 경우에는 비교적 더 좋은 성능을 보인다.

그림 3은 전체 데이터 샘플을 이용해서 일당증체를 분석하여 나온 결과의 에러를 나타낸다. 실제로 측정된 일당증체가 기계의 오작동으로 인해 몇몇 샘플의 수치가 크게 나오는 것을 그림에서 볼 수 있다. 그렇게 예측한 일당증체와 측정된 일당증체가 오차가 크게 나오면서 커다란 오차를 표시하고 있다(X의 크기가 클수록 오차가 큼).

1) K-fold cross validation는 데이터의 양이 부족할 때 알고리즘 성능분석의 정확성과 신뢰도를 높이기 위해서 적용하는 방식으로, 데이터를 K개로 나누고 K-1개 데이터를 가지고 학습(Training set)한 다음, 얻어진 결과를 남은 데이터로 성능(Test set)을 확인한다.

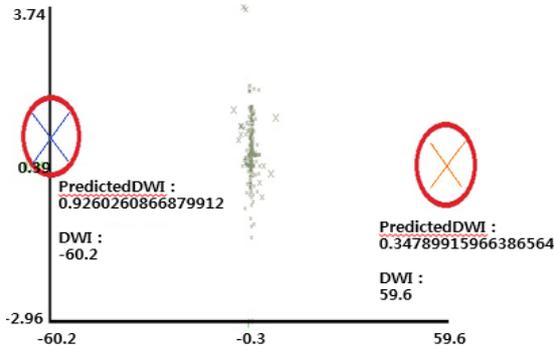


Fig. 3 Visualization of error.

표 3은 오차(-60.2kg, 59.6kg)에 의해서 생긴 커다란 오차샘플을 제거한 결과와의 비교이다. 볼 수 있듯이 성능이 전반적으로 좋아진다. 따라서 본 연구에서는 오차가 큰 샘플을 일부 제거하고 성능을 분석하였다.

Table. 3 Performance analysis by removing outlier.

Total Number of Instances	Correlation Coefficient	MAE	RMSE	RAE	RSE
264	-0.067	1.3061	5.4155	116%	101%
262	0.2317	0.6854	1.1479	102%	99%

다음으로 표 4는 조건에 따른 클래스를 0, 1로 설정하여 큰 오차를 하나씩 제거해서 나온 성능 분석결과이다. Correlation Coefficient가 1에 가깝게 표시되었고 상대오차(RAE)가 10%대로 줄어든 것을 확인할 수 있다.

Table. 4 Performance analysis by removing outlier. (0<=0.6, 1>=0.7)

Total Number of Instances	Correlation Coefficient	MAE	RMSE	RAE	RSE
264	0.2612	0.4521	0.4804	91.5%	96.6%
165	0.9768	0.087	0.1154	17.6%	23.2%

그림 4는 4개의 leaf node를 구성하는 회귀(Regression) 모델트리를 보여준다.

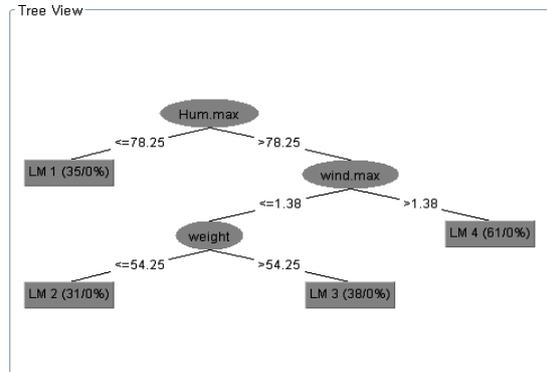


Fig. 4 Model tree with outlier removed(0<=0.6,1>=0.7).

다음은 4개의 leaf node의 회귀 식을 표현한다.

$$LM1 \text{ Threshold} = \begin{pmatrix} -0.0093 * Hum.max \\ -0.1789 * wind.max \\ +0.0118 * weight \\ +1.197 \end{pmatrix} \quad (5)$$

$$LM2 \text{ Threshold} = \begin{pmatrix} -0.0032 * Hum.max \\ -0.1694 * wind.max \\ +0.0173 * weight \\ -0.3106 \end{pmatrix} \quad (6)$$

$$LM3 \text{ Threshold} = \begin{pmatrix} -0.0032 * Hum.max \\ -0.1694 * wind.max \\ +0.0163 * weight \\ +0.2602 \end{pmatrix} \quad (7)$$

$$LM4 \text{ Threshold} = \begin{pmatrix} -0.0032 * Hum.max \\ -0.1807 * wind.max \\ +0.0103 * weight \\ -0.004 \end{pmatrix} \quad (8)$$

(5), (6), (7), (8)식을 보면 공통적으로 최대풍속이 클래스 분류에 큰 영향이 있음을 보여준다.

Table. 5 Performance analysis by removing outlier. (0<=0.4, 1>=0.9, 2=The rest)

Total Number of Instances	Correlation Coefficient	MAE	RMSE	RAE	RSE
264	0.3592	0.6343	0.7373	95.5%	93.6%
199	0.7718	0.4037	0.4554	68.3%	63.4%

표 5는 조건에 따른 0, 1, 2 클래스로 설정하여 큰 오차를 하나씩 제거해서 나온 성능 분석 수치이다. 전반적인 성능의 상승폭이 작으나 이전 결과에 비해 더 많은 샘플을 사용했다. 본 결과에서도 오차를 제거하면

성능이 좋아지는 것을 확인할 수 있고 본 논문에는 나타내지는 않았지만 클래스에 최대풍속과 평균 풍속의 영향이 크고 16개의 leaf node를 가지는 모델트리를 구성하였다.

해 연관성모델의 정확도를 향상시킬 수 있을 것이고, 또한 더 정확한 개체성장 예측 및 정밀한 돈사제어가 가능할 것이다.

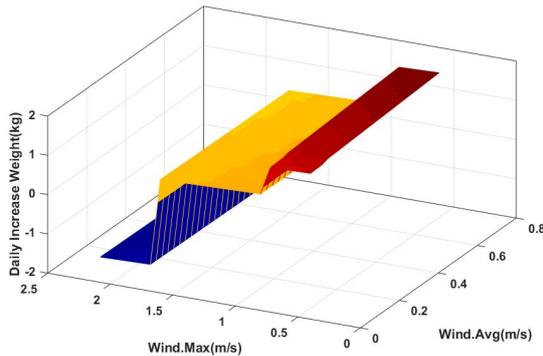


Fig. 5 Predicted daily weighting increase graph.

그림 5는 X축을 최대풍속(범위 : 최솟값, 최댓값), Y축을 평균풍속(범위 : 최솟값, 최댓값)으로 하며, Z축은 예측된 일당증체 보여주는 그래프이다. 최대풍속이 낮고 평균풍속이 올라갈수록 개체가 고성장하는 것을 확인할 수 있다.

## V. 결 론

본 연구에서는 스마트 돈사에서 수집된 환경데이터와 개체생체데이터를 이용하여 환경데이터와 일당증체의 연관성모델을 구축하고 Weka를 이용하여 개발된 연관성모델의 성능을 분석하였다. 이를 위해서 기계학습의 MSP tree 알고리즘을 적용하였다. 또한 환경데이터를 속성으로 설정하고 개체생체데이터를 클래스로 설정해서 분류했다. 성능분석을 통해 큰 오차를 보이는 샘플을 제거하여 최대 10%의 상대오차수치를 보이는 것을 확인했다. 또한 돈사의 최대풍속이 개체의 일당증체의 큰 영향을 주는 요소임을 확인하였고 이러한 정보는 스마트돈사구축에 유용하게 활용 할 수 있다. 다만 현재 분석한 데이터의 경우 데이터양이 적고 일부 측정 오차가 존재하여 예측정확도가 매우 높지는 않다. 따라서 현재 더 정확하고 더 많은 환경 및 생체데이터를 수집하여 분석하는 후속연구를 진행 중에 있다. 이를 통

## ACKNOWLEDGMENTS

This work was carried out with the support of "Cooperative Research Program for Agriculture Science & Technology Development (Project title: Development of swine management model with animal-metric for livestock welfare, Project No. PJ010541022016)" Rural Development Administration, Republic of Korea, and this work was also supported by Development Fund Foundation, Gyeongsang National University, 2015.

## REFERENCES

- [ 1 ] S. J. Roberts, R. Cain and M. S. Dawkins, "Prediction of welfare outcomes for broiler chickens using Bayesian regression on continuous optical flow data," *Journal of the Royal Society interface*, vol. 9, no. 77, pp.3436-3443, Sep. 2012.
- [ 2 ] D. Z. Caraviello, K. A. Weigel, M. Craven, D. Gianola, N. B. Cook, K. V. Nordlund and M. C. Wiltbank, "Analysis of reproductive performance of lactating cows on large dairy farms using machine learning algorithms," *Journal of dairy science*, vol. 89, no. 12, pp.4703-4722, Dec. 2006.
- [ 3 ] 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 science*, vol. 97, no. 2, pp.731-742, Feb. 2014.
- [ 4 ] M. S. Lee and Y. C. Choe, "Forecasting Sow's Productivity using the Machine Learning Models," *Journal of Agricultural Extension & Community Development*, vol. 16, no. 4, pp. 939-965, Dec. 2009.
- [ 5 ] A.F.S. Cordero, I.A. Naas, S.R.M. Oliveira, A.C.M. Almeida and D.P. Neves, "Using Decision Tree for Classifying Farrowing Piglets Stress Conditions using Vocalization," *2012 IX International Livestock Environment*

- Symposium (ILES IX)*, Valencia: Spain, pp. 3, July 8-12. 2012.
- [ 6 ] M. A. Kashiha, C. Bahr, S. Ott, C. P. Moons, T. A. Niewold, F. Tuytens and D. Berckmans, "Automatic monitoring of pig locomotion using image analysis," *Livestock Science*, vol. 159, pp.141-148, Jan. 2014.
- [ 7 ] E. Khoramshahi, J. Hietaoja, A. Valros, J. Yun and M. Pastell, "Real-time recognition of sows in video: A supervised approach," *Information Processing in Agriculture*, vol. 1, no. 1, pp. 73-81, Aug. 2014.
- [ 8 ] K. Kirchner, K. H. Tolle and J. Krieter , "The analysis of simulated sow herd datasets using decision tree technique," *Computer and Electronics in Agriculture*, vol. 42, no. 2, pp. 111-127, Feb. 2004.
- [ 9 ] N. Bhargava, G. Sharma, R. Bhargava and M. Mathuria, "Decison Tree Analysis on J48 Algorithm for Data Mining," *International Journal of Advanced Research in Computer Science and Software Engineering*, vol. 3, no.6, pp.1114-1119, June. 2013.
- [10] I. H. Witten, E. Frank. *Data Mining: Practical machine learning tools and techniques*, 3th ed. San Francisco, CA, United States, Morgan Kaufmann, 2011.



한강휘(KangHwi Han)

2015년 8월 경상대학교 정보통신공학과 학사  
2015년 9월 ~ 현재 : 경상대학교 정보통신공학과 석사과정  
※관심분야 : 빅 데이터 분석, IT융합, 차세대 이동통신 시스템(5G)



이용섭(Woongsup Lee)

2006년 한국과학기술원 전기및전자공학과 학사  
2011년 한국과학기술원 전기및전자공학과 박사  
2014년 3월 ~ 현재 : 경상대학교 정보통신공학과 조교수  
※관심분야 : 차세대 이동통신 시스템, 인지 라디오 시스템, 스마트 그리드, 빅 데이터 분석



성길영(Kil-Young Sung)

1980년 경북대학교 전자공학과 학사  
1985년 건국대학교 전자공학과 석사  
2000년 부경대학교 전자공학과 박사  
현재 : 경상대학교 정보통신공학과 교수  
※관심분야 : VLSI Array, Computer Architecture, Image Compression