

일반논문 (Regular Paper)

방송공학회논문지 제25권 제3호, 2020년 5월 (JBE Vol. 25, No. 3, May 2020)

<https://doi.org/10.5909/JBE.2020.25.3.418>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

고기 신선도 측정 데이터의 딥러닝 기반 분석

장 애 라^{a)}, 김 혜 진^{a)}, 김 만 배^{b)†}

Deep Learning-based Analysis of Meat Freshness Measurement

Aera Jang^{a)}, Hey-Jin Kim^{a)}, and Manbae Kim^{b)†}

요 약

축산 판매장에서 판매하는 고기들의 신선도 측정은 소비자의 건강을 위해 필요한 기술이다. 신선도 측정을 목적으로 다양한 센서가 연구 개발되고 있다. 센서는 다양한 고기의 신선도 상태 때문에 측정 오류가 발생한다. 따라서 강인성을 가지는 센서를 검증한 후에, 사용하는 과정이 필요하다. 본 논문에서는 10개의 고기 신선도 측정 센서로 얻은 데이터의 분석을 통해서, 각 측정 센서의 성능을 심층신경망을 이용하여 조사한다. 고기 종류로는 소고기, 돼지고기, 닭고기를 대상으로 검증한다. 또한 토리미터보다 성능이 우수한 다중 센서를 찾기 위해서 PCA를 이용하여 3개의 센서를 찾는다. 실험에서는 심층신경망으로 3개의 센서가 토리미터보다 우수함을 증명하였다.

Abstract

The measurement of meat freshness at meat markets is important for the health of consumers. Currently a variety of sensors have been studied for the measurement of the meat freshness. Therefore, the analysis of sensor data is needed for the reduction of measurement errors. In this paper, we analyze the freshness measurement data of ten sensors based on deep learning. The measured data are composed of beef, pork and chicken, whose reliability and noise-robustness are examined by a deep neural network. Further, to search for multiple sensors better than a torritymeter, PCA (principle component analysis) is carried. Then, we validated that the performance of the three sensors outperforms the torritymeter in the experiment.

Keyword : meat freshness; deep learning; multi-sensor; robustness

a) 강원대학교 동물생명과학대학 동물응용학과(Kangwon National University, College of Animal Life Science, Dept. of Applied Animal Science)

b) 강원대학교 컴퓨터정보통신공학과(Kangwon National University, Dept. of Computer & Communications Engineering)

† Corresponding Author : 김만배(Manbae Kim)

E-mail: manbae@kangwon.ac.kr

Tel: +82-33-250-6395

ORCID: <http://orcid.org/0000-0002-4702-8276>

※ This research was supported by the MSIT (Ministry of Science and ICT), Korea, under the ITRC (Information Technology Research Center) support program (IITP-2020-2018-0-01433) supervised by the IITP(Institute for Information & communications Technology Promotion)

· Manuscript received February 14, 2020; Revised April 1, 2020; Accepted April 1, 2020.

I. 서론

최근 축산물의 신선도를 판정하기 위한 센서가 생산 판매되고 있다. 주로 부패에 의해 발생하는 암모니아와 같은 휘발성 물질의 농도를 색으로 변환하는 원리를 활용하고 있다. 축산분야에서는 소고기(beef), 돼지고기(pork), 닭고기(chicken)의 신선도(freshness) 또는 부패(spoilage)를 정확히 측정하는 것이 중요하다. 이를 위해서 다양한 센서를 이용해, 도축 후 며칠이 경과되었는지의 저장기간을 측정한다. 그러나 센서의 측정값은 편차가 존재하므로, 실제 저장기간이 10일이 경과되었는데, 15일로 판단하는 오판단이 종종 발생한다.

고기의 신선도를 측정하기 위해서 다양한 방법들이 소개되어 왔다. Xiao 등은 고기의 신선도를 측정하기 위해서 near infrared spectroscopy, pH, CO₂, VOC(volatile organic compound)를 조사하여, 신선도와 상관성을 조사하였다^[1]. Mrroljub 등은 spectrophotometer로부터 획득한 데이터에서 PCA를 이용하여 3개의 spectral 데이터를 찾은 후에, 신경망의 입력으로 사용한다^[2]. 출력은 storage day를 category로 사용하였다. Peiyuan 등은 VBN 센서의 고기 신선도의 정확도를 증명하기 위해서 입력으로 HSI 컬러와 H2S 및 HN3을 입력으로 한 신경망을 소개하였다^[3]. 멀티센서를 처리하는 방법으로 Timson 등은 hydrogen 등의 8개의 센서 데이터를 입력으로 하고, 출력으로 1, 2, 3, 8일의 닭고기의 storage day를 클래스로 한 신경망을 사용한다^[4]. 고기가 부패할 때 VOC가 발생한다. Bakhoun 등은 이 VOC를 측정하기 위해 pH, 값을 측정한 후, 패턴인식을 이용하여 VOC를 예측한다^[5].

상기 관련 연구에서 보듯이 매우 다양한 측정 기술들이 사용되고 있다. 본 연구에서는 고기 신선도를 측정하기 위하여 총 10개의 센서를 이용한다. 고기 신선도 측정에는 다음의 10종류의 측정 센서가 연구 및 활용되고 있다; 1) pH, 2) 휘발성염기질소(Volatile basic nitrogen: VBN), 3) 지방산패도(Thiobarbituric acid reactive substances: TBARS), 4) 일반 세균(Total aerobic bacteria: TAB), 5) 대장균(E.Coli), 6) 육색(meat color: MC) - L*, 7) 육색 - a*, 8) 육색 - b*, 9) 전단력(Shear force: SF), 및 10) 토리미터(Torrymeter).

한 개의 센서를 사용하여 측정하는 것은 오류가 발생하기 때문에, 멀티센서(multi-sensor)로 측정할 수 있으면 오류를 줄일 수 있는 장점이 있다. 본 논문에서는 10개의 센서로 측정된 값들로부터 경과일을 예측하기 위하여 딥러닝 기반 기법을 제안한다. 딥러닝을 이용하여 센서 데이터로부터 자동으로 저장일(storage day) Day X를 판별한다. 본 논문에서 연구하는 내용은 다음과 같다.

주요 고기로 소고기, 돼지고기, 닭고기를 대상으로 센서 데이터의 신뢰성을 검증한다. 특히 데이터의 노이즈가 존재할때에 센서의 데이터 신뢰성에 대해 조사한다.

현재 상용화가 되어 있는 토리미터보다 우수한 성능을 얻을 수 있는 센서데이터를 PCA를 이용하여 분석한다. 여기에서는 고기 종류에 따른 최적의 센서들을 선정한다.

센서값이 주어지면 이값으로 경과된 정확한 저장 기간을 판단하는 작업에 딥러닝 기술을 활용한다.

본 논문의 구성은 다음과 같다. 다음 장에서는 실험에서 사용하는 고기 신선도 측정 데이터를 분석한다. III장에서는 분석 도구인 딥 신경망 모델을 설명한다. 실험 결과는 IV장에서 소개하고, 마지막으로 V장에서는 결론 및 향후 연구를 정리한다.

II. 고기 측정 데이터 분석

고기가 도축된 이후 경과한 일수는 고기의 부패 및 신선도와 직접적인 관계가 있다. 현재는 pH, 토리미터 등의 센서를 이용하여 측정값을 보고, 도축후 경과된 저장기간을 판단한다. 그림 1은 저장기간 동안의 소고기 표면의 변화를 보여준다. 경과일은 1, 3, 6, 9, 12, 15, 18로 3일간의 간격이고, 이 경과일마다 각 센서로 부패 진행을 측정한다.

표 1~3의 실험데이터는 세 종류의 고기인 소고기, 돼지고기, 닭고기에서 측정한 10개의 센서 측정 데이터이다. 측정은 식품생체대사조절학실험실에서 수행되었다. 측정센서는 pH, 휘발성염기질소(Volatile basic nitrogen: VBN), 지방산패도(Thiobarbituric acid reactive substances; TBARS), 일반세균(Total aerobic bacteria: TAB), 대장균(E.Coli), 육색(meat color: MC) - L*(명도), 육색 - a*(적색도), 육색 - b*(황색도), 전단력(Shear force: SF), 토리미터(Torrymeter)이다.



그림 1. 저장 기간 동안의 소고기의 표면 변화

Fig. 1. Surface variation of beef during storage period

표 1. 소고기 측정 데이터. (·)은 표준편차 σ 임

Table 1. Beef measurement data. (·) is standard deviation σ

Day	pH	VBN	TBARS	TAB	E.Coli	MC-L*	MC-a*	MC-b*	SF	Torry meter
1	5.75 (0.005)	3.81 (0.079)	0.083 (0.026)	2.30 (0.054)	0.000 (0.000)	42.61 (0.441)	23.32 (0.224)	13.18 (0.060)	3.410 (0.169)	18.43 (0.050)
3	5.76 (0.074)	4.03 (0.215)	0.219 (0.012)	2.37 (0.064)	0.000 (0.000)	42.42 (2.053)	21.40 (0.793)	12.72 (0.543)	3.24 (0.137)	17.30 (0.082)
6	5.68 (0.005)	6.02 (0.426)	0.234 (0.011)	3.77 (0.092)	0.000 (0.000)	41.81 (0.398)	20.38 (0.178)	12.46 (0.066)	2.94 (0.212)	16.60 (0.490)
9	5.74 (0.008)	9.45 (0.121)	0.304 (0.040)	4.76 (0.106)	1.150 (0.174)	42.34 (0.437)	20.59 (0.625)	12.69 (0.047)	1.80 (0.384)	15.50 (0.115)
12	5.93 (0.193)	16.87 (0.807)	0.565 (0.084)	6.87 (0.147)	3.68 (0.108)	42.04 (0.610)	17.43 (0.812)	11.48 (0.398)	1.60 (0.180)	13.03 (0.189)
15	6.53 (0.122)	29.31 (2.011)	0.612 (0.039)	8.61 (0.104)	4.68 (0.099)	41.99 (1.747)	16.17 (0.761)	11.82 (0.332)	1.76 (0.171)	8.55 (0.370)
18	6.46 (0.056)	33.16 (1.229)	0.862 (0.061)	8.64 (0.091)	5.54 (0.201)	41.25 (0.256)	14.28 (0.397)	10.77 (0.210)	1.32 (0.392)	6.60 (0.216)

표 2. 돼지고기 측정 데이터 (·)은 표준편차값임

Table 2. Pork measurement data. (·) is standard deviation

Day	pH	VBN	TBARS	TAB	E.Coli	MC-L*	MC-a*	MC-b*	SF	Torry meter
1	5.69 (0.005)	5.64 (0.245)	0.036 (0.000)	3.41 (0.082)	0.00 (0.00)	50.95 (0.649)	15.69 (0.698)	7.05 (0.124)	2.44 (0.163)	14.15 (0.420)
3	5.74 (0.005)	5.86 (0.081)	0.053 (0.002)	3.44 (0.138)	1.51 (0.062)	51.19 (0.798)	14.69 (0.155)	8.72 (1.985)	2.38 (0.162)	13.65 (0.300)
6	5.81 (0.015)	6.3 (0.000)	0.083 (0.003)	3.66 (0.106)	1.56 (0.217)	52.07 (0.618)	14.48 (0.710)	9.73 (0.560)	2.33 (0.339)	13.33 (0.359)
9	5.74 (0.005)	6.14 (0.107)	0.105 (0.004)	4.58 (0.195)	1.52 (0.172)	52.56 (1.443)	13.86 (0.791)	9.87 (0.502)	2.25 (0.228)	12.53 (0.826)
12	5.96 (0.008)	15.97 (1.358)	0.140 (0.003)	7.25 (0.075)	3.02 (0.174)	52.55 (0.868)	13.75 (0.899)	9.87 (0.389)	2.21 (0.222)	11.35 (0.785)
15	6.04 (0.010)	17.41 (0.202)	0.434 (0.014)	8.09 (0.168)	4.11 (0.061)	53.03 (0.278)	13.80 (1.468)	10.14 (1.226)	2.17 (0.089)	4.530 (0.171)
18	6.47 (0.168)	19.69 (0.588)	0.716 (0.184)	8.42 (0.238)	4.52 (0.172)	53.41 (1.605)	13.51 (0.551)	10.41 (0.564)	1.84 (0.090)	4.130 (0.050)

표 3. 닭고기 측정 데이터 (·)은 표준편차값임
Table 3. Chicken measurement data. (·) is standard deviation

Day	pH	VBN	TBARS	TAB	E.Coli	MC - L*	MC - a*	MC - b*	SF	Torry meter
1	6.10 (0.017)	9.88 (0.428)	0.012 (0.001)	4.43 (0.080)	2.15 (0.130)	59.06 (2.085)	0.98 (0.078)	3.66 (0.893)	4.80 (0.613)	12.80 (0.082)
3	6.09 (0.118)	11.33 (0.040)	0.016 (0.000)	4.48 (0.097)	2.13 (0.130)	59.17 (1.723)	0.99 (0.227)	4.55 (0.368)	3.51 (0.793)	10.85 (0.058)
6	6.11 (0.006)	12.25 (0.390)	0.040 (0.005)	4.72 (0.028)	2.19 (0.236)	58.3 (1.149)	0.91 (0.328)	5.73 (1.016)	3.08 (0.286)	9.10 (0.271)
9	6.13 (0.021)	12.22 (0.121)	0.057 (0.005)	4.99 (0.138)	2.44 (0.363)	58.85 (1.399)	0.91 (0.312)	5.04 (1.010)	2.94 (0.313)	8.13 (0.126)
12	6.15 (0.025)	12.37 (0.225)	0.056 (0.004)	6.09 (0.044)	3.13 (0.124)	58.55 (3.393)	0.94 (0.577)	5.24 (1.139)	2.54 (0.203)	6.80 (0.115)
15	6.15 (0.017)	13.65 (0.242)	0.093 (0.003)	6.12 (0.239)	3.66 (0.052)	58.75 (2.367)	1.00 (0.885)	5.02 (0.505)	2.23 (0.259)	6.35 (0.173)
18	6.20 (0.012)	18.04 (0.525)	0.105 (0.006)	7.83 (0.116)	4.24 (0.127)	58.81 (2.346)	0.92 (0.503)	5.89 (0.991)	2.00 (0.469)	4.53 (0.050)

해당 값들은 고기가 도축된 이후 3일 간격으로 측정하였다. 최대 8회까지 측정하여 평균과 표준편차의 두 가지 값을 얻었다. 고기의 종류는 소고기 (표 1), 돼지고기 (표 2), 닭고기 (표 3)이며, 공통적으로 섭씨 4°C에서 호기 포장하여 저장하였다.

Day는 저장기간으로 총 7개의 날짜가 있다. pH 평균값은 5.75~6.46에서 분포하고, 표준편차 σ 는 0.005~0.193 분포를 가진다. σ 는 Day와 관계가 없는 것으로 판단된다. σ 는 실험에서 신경망 학습데이터를 생성하는데 사용한다. pH에서 pH=5.75이면 Day 1, 5.76이면 Day 3, 마지막으로 6.46이면 Day 18로 예측한다. 편차 때문에 오류가 발생하게 된다.

표 1의 pH는 Day가 증가하면 평균값도 증가해야 하는데, Day=1, 2, 3에서 각각 5.75, 5.76, 5.68로 증가, 감소가 발생한다. 이 현상은 측정 성능의 저하의 원인이 된다. 전체적으로 모든 센서 데이터에서 발생하는데, 만족스러운 성능을 얻기 위해서는 멀티센서의 데이터가 필요하다는 것을 보여준다.

Ⅲ. 시뮬레이션 설계: 심층신경망 모델

육고기 신선도를 측정할 수 있는 방법으로 SVM(support vector machine), 선형회기(linear regression) 등의 기계학습 기법들이 있는데, 최근에 딥러닝의 학습 및 분류 능력의 우수하기 때문에^[7-9] 본 연구에서는 심층신경망 모델을 기

반으로 신선도 측정을 수행한다. 센서로부터 얻은 고기 데이터의 정량적 저장기간 측정값을 특징으로 입력한 후에, 저장기간을 예측하는 분류 신경망을 구현한다. 센서의 개수가 N이면, N차원의 특징벡터(feature vector)가 입력되므로 입력노드의 개수는 N이다. 따라서 7개의 Day가 있으므로, 출력 노드는 7개이다. 센서데이터에는 고기의 다양한 종류 및 보관의 차이로 편차가 존재한다. 편차는 노이즈를 의미하므로, 노이즈가 존재할 때에 예측 능력의 성능을 신경망으로 검증한다.

그림 2는 데이터 분석을 위해 사용한 신경망 구조를 보여준다. 입력은 10차원의 고기데이터 특징벡터이므로 입력층




그림 2. 3개의 은닉층이 있는 신경망 모델 (H3-DNN)의 구조
Fig. 2. Neural network model with 3 hidden layers (H3-DNN)

엔 이와 동일하게 10개의 노드가 있다. 은닉층의 수는 1~3 개로 구성하였으며, 한 층일 경우 노드의 수는 64개, 두 층일 경우 각 64-32개, 세 층일 경우 64-32-16개로 구성하였다. 각각의 신경망은 편의상 은닉층의 수에 따라 H1-DNN, H2-DNN, H3-DNN이라 부른다. 출력층에서는 신경망이 분류할 저장 기간의 개수와 같이 7개의 노드를 갖는다. 즉, Day=1, 3, ..., 18은 각각 클래스=1, 2, ..., 7에 대응한다. 표 4는 실험에서 사용한 신경망의 파라메타값을 보여준다. 최적화는 Adam을 사용하였다. ρ_1 과 ρ_2 는 각각 0.9, 0.999이다. 그리고 δ 은 10^{-8} 이다. 학습률은 0.001, 미니배치 크기는 100이다. 활성화 함수는 모든 은닉층에서 relu를 사용하고, 출력층에는 softmax이다.

표 4. 신경망 모델 파라메터

Table 4. Parameters of neural network

Layer	Number of nodes	Activation function
Input layer	10	
H1-DNN	64	relu
H2-DNN	64-32	relu
H3-DNN	64-32-16	relu
Output layer	7	softmax

IV. 실험 결과 및 분석

1. 데이터 전처리

표 1~3의 데이터는 평균과 표준편차를 가지므로, 정규분

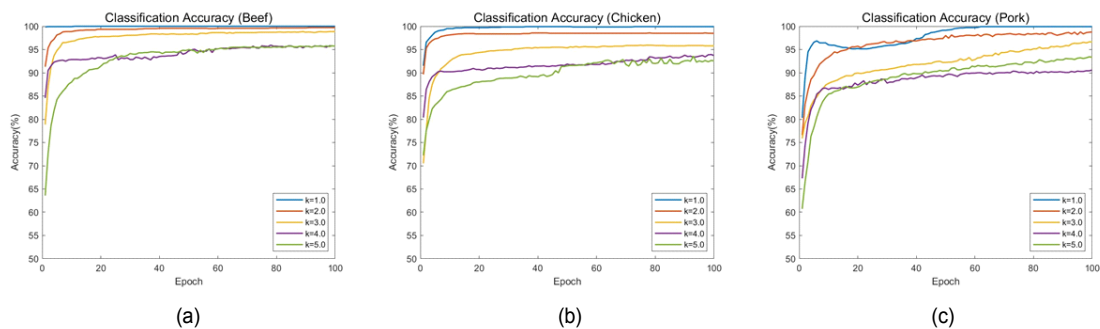
포 $N(x; \mu, k\sigma^2)$ 를 통해 랜덤하게 샘플 데이터를 생성하여 신경망의 학습데이터로 사용한다. Day별로 고정된 σ 에서 k 가 증가하면 평균에서 좌우로 멀리 퍼진 데이터가 생성된다. 실험에서는 노이즈에 대한 신뢰성도 검증한다. k 는 [1,5]의 범위에서 설정하였으며, 각 Day 별로 1,000개씩 샘플 데이터를 생성해서 총 7,000개의 학습데이터가 있다. 피쳐값들은 각각 [0,1]로 정규화(normalization)한다.

$$f_i = (f_i - \max f_i) / (\max f_i - \min f_i) \quad i \in [1, 10] \quad (1)$$

여기서 f_i 는 i 번째 피쳐이고, $\max f_i$, $\min f_i$ 는 피쳐 i 의 최대, 최소값이다.

2. 전체 센서의 분류 검증

우선 10개의 특징을 가진 데이터가 Day를 잘 분류할 수 있는지 확인하기 위한 실험을 진행하였다. 입력데이터는 10개의 특징을 가진 원본 데이터에서 k 를 1~5로 변경하면서 생성한 각 1,000개씩의 데이터이다. 신경망은 H1-DNN을 사용하였다. 그림 3의 그래프는 실험 결과를 보여준다. 수평축은 에폭(epoch), 수직축은 분류 정확도(classification accuracy)이다. 세 종류의 고기 데이터 모두에 대해 $k=1$ 인 경우 분류정확도는 100%에 접근하여 완벽하게 Day를 분류하였다. 그러나 k 가 증가함에 따라 정확도가 감소하는 것을 확인할 수 있다. 그림 3(a)의 소고기를 보면, $k=1$ 에서 분류 정확도는 100%으로 수렴하지만, k 가 증가하면 정확도는 감소함을 관찰할 수 있다. 정확도 $\geq 95\%$ 을 얻으려면

그림 3. k 에 따른 H1-DNN의 분류 정확도의 비교 (a) 소고기, (b) 닭고기 및 (c) 돼지고기Fig. 3. Comparison of classification accuracy in H1-DNN with respect to the variation of k . (a) beef, (b) chicken, and (c) pork

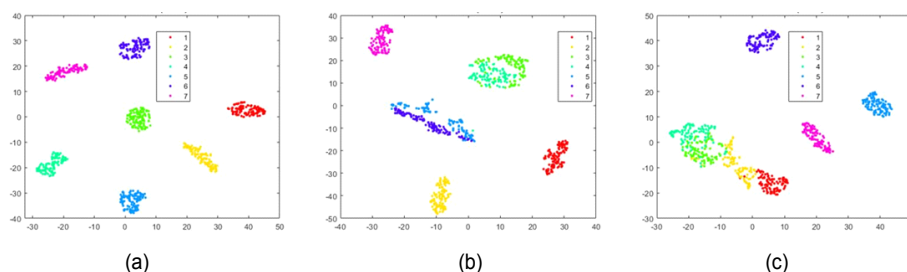


그림 4. 7개의 클래스를 가지는 샘플데이터의 t-SNE 기반 데이터 시각화 (a) 소고기, (b) 닭고기 및 (c) 돼지고기
Fig. 4. Data visualization of sample data with seven classes by t-SNE (a) beef, (b) chicken, and (c) pork

센서값의 편차는 $k \leq 2$ 이어야 한다. 또한 그림 3(b)의 닭고기는 $k \leq 3$, 그림 3(c)의 돼지고기는 $k \leq 3$ 을 만족해야 한다. 상대적으로 소고기의 오류가 가장 낮고, 돼지고기가 오류가 가장 높다. 즉, 돼지고기에서 센서데이터는 분류 정확도가 낮다고 할 수 있다.

그림 4는 t-SNE(t-distributed stochastic neighbor embedding)를 사용한 데이터 시각화를 보여준다^[10]. t-SNE는 피처의 차원을 2차원 또는 3차원으로 축소하는 기술인데, 최근접점을 2~3차원으로 매핑해 차원을 축소한다. 총 10,000개의 샘플 데이터와 해당 레이블을 입력하여 얻은 결과이다. 그래프의 한 점은 한 개의 입력 피처를 의미한다. 7개의 분류 클래스로 만족스럽게 분류되는 것을 알 수 있다. 소고기는 완벽하게 레이블을 분류한다. 닭고기는 레이블 5, 6이 약간 혼합되어 있고, 레이블 3, 4도 혼합되어 있다. 돼지고기는 레이블 4, 5가 혼합되어 있다. 즉, 소고기는 분류 성능이 상대적으로 우수함을 전달해준다.

3. 중요 피처 선택

현재 고기 신선도 측정에 많이 사용하고 있는 토리미터^[11]를 대체할 수 있는 센서가 있는지를 알아보기 위해서, 3개의 센서를 선택하여 성능을 비교 검증한다. 이를 위해 고기 데이터의 신선도 측정값 중 기여도가 높은 센서를 선택한다. 어떤 데이터가 큰 기여도를 갖는지 분석하기 위해 통계적 패키지인 R의 PCA(Principal Component Analysis)를 이용하였다^[12].

우선 토리미터를 제외한 9가지 센서값 특징들을 분석하여 Day를 분류하는데 기여도가 가장 큰 세 가지 특징을 선정한다. 그리고 선정된 특징들과 토리미터 두 가지로 데이

터셋을 만든 후에, 이 두 종류의 데이터셋을 앞에서 제안한 신경망의 학습데이터로 사용한다. 실험에서는 선정한 세 가지의 특징이 토리미터보다 Day 분류에 더 나은 성능을 가지는지를 조사한다.

표 5는 각 고기 데이터에 대한 PCA 분석결과를 보여준다. 소고기에서는 pH, VBN, 대장균(E.coli)은 가중치가 각각 0.91, 0.77, 0.69로 가장 높은 기여도를 갖는 세 개의 특징들이다. 돼지고기에 대한 분석결과에서는 pH, TBARS, 전단력(SF)이 0.83, 0.84, 0.80으로 높은 가중치를 보여주고 있다. 닭고기에서는 pH, 일반 세균(TAB), 대장균이 0.96, 0.97, 0.98로 가장 높은 가중치를 가진다.

표 5. 고기 신선도 측정에 영향을 중요한 영향을 주는 세 개의 피처
Table 5. Three features with largest weights for meat freshness measurement

Meat	3 Features	Weight
Beef	pH, VBN, E.Coli	0.91, 0.77, 0.69
Pork	pH, TBARS, SF	0.83, 0.84, 0.80
Chicken	pH, TAB, E.Coli	0.96, 0.97, 0.98

다음으로 PCA 분석결과를 바탕으로 특징 차원을 세 개로 축소한 데이터를 사용해 실험을 진행하였다. 그림 5는 소고기, 돼지고기, 닭고기의 실험결과를 보여준다. 그림 5(a)는 H1-, H2-, H3-DNN에서의 3-Feature와 토리미터의 소고기의 분류정확도를 보여준다. 전체적으로 3-Feature가 성능이 좋을 수 있다. 그림 5(b)의 돼지고기는 3-Feature가 모든 k 값에 대해서 토리미터보다 우수한 분류 성능을 보여준다. 그림 5(c)의 닭고기에서는 노이즈가 적은 $k=1$ 에서 토리미터가 3-Feature보다 좋은 성능을 보이지만, $k=2, 3$ 에서는 3-Feature의 분류성능이 우수하다.

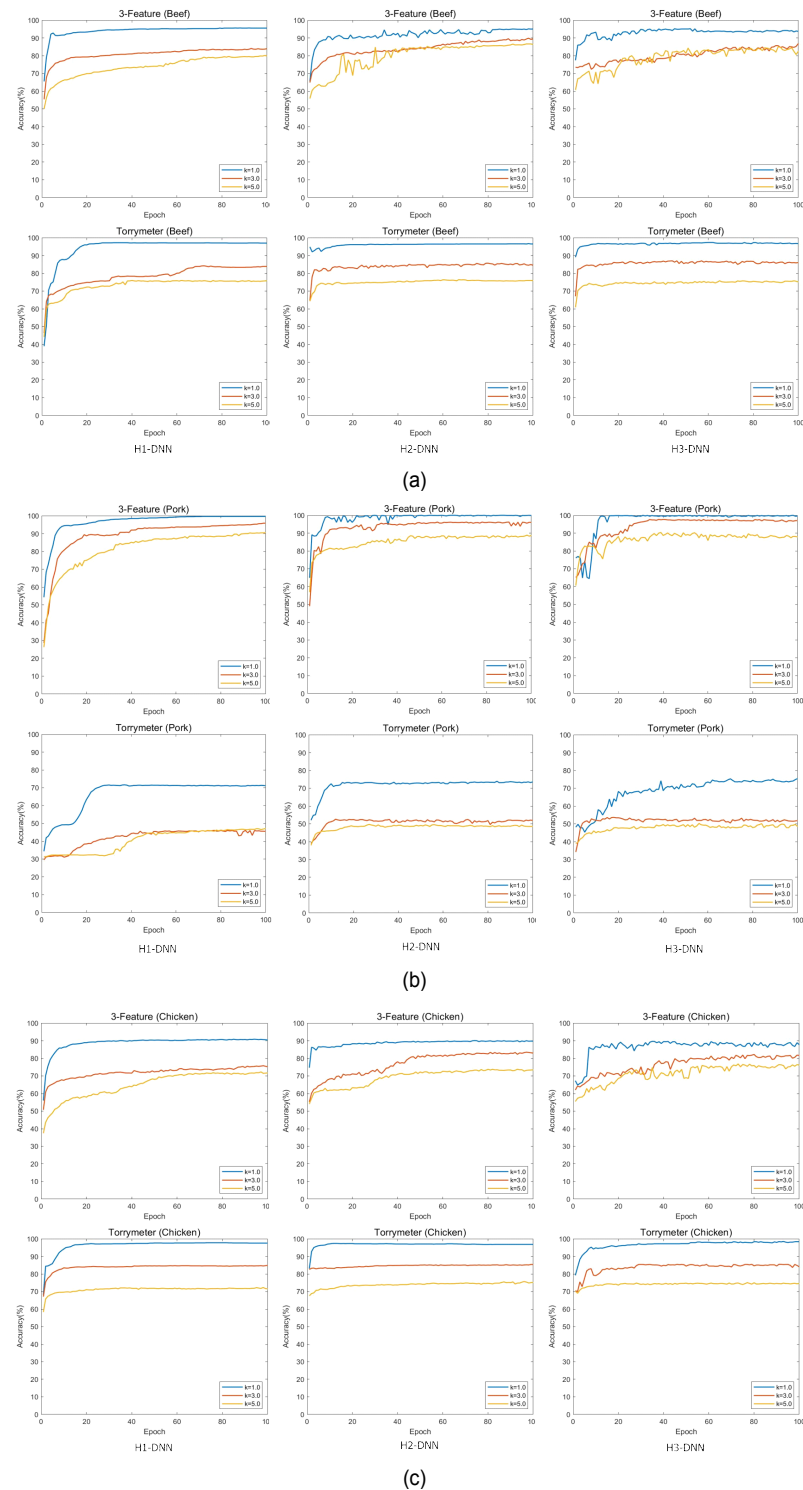


그림 5. 세개의 피쳐(3F)와 토리미터의 분류 정확도 비교. $k=[1,3,5]$. (a) 소고기, (b) 돼지고기 및 (c) 닭고기

Fig. 5. Comparison of classification accuracy of 3-Feature and Torrymeter. $k=[1,3,5]$. (a) beef, (b) pork, and (c) chicken

표 6. 3-Feature(3F)와 토리미터와의 분류 정확도. Δ =3F-Torrymeter로 증기분임. 적색 숫자는 감소, 청색 숫자는 증가임

Table 6. Classification performance of 3-Feature(3F) and Torrymeter. Δ =3F-Torrymeter is difference. Red numbers indicate decrement and blue numbers indidate increment

Meat	k	H1-DNN			H2-DNN			H3-DNN		
		Torry meter	3F	Δ	Torry meter	3F	Δ	Torry meter	3F	Δ
Beef	1	97.00	95.57	-1.430	96.50	95.64	-0.860	96.64	93.71	-2.930
	2	83.65	84.00	+0.350	84.50	89.50	+5.000	86.07	86.92	+0.850
	3	75.85	79.85	+4.000	75.92	86.35	+10.43	75.14	82.64	+7.50
Pork	1	71.14	99.64	+28.50	73.57	99.92	+26.35	75.42	99.57	+24.15
	2	45.57	95.85	+50.28	52.00	96.07	+44.07	51.85	97.07	+46.22
	3	47.14	90.57	+43.43	48.57	88.71	+40.14	48.50	87.85	+39.35
Chicken	1	97.57	90.42	-7.650	96.85	89.78	-7.070	95.35	87.71	-7.640
	2	84.92	75.14	-9.780	85.35	82.92	-2.430	84.07	81.64	-2.430
	3	71.50	71.71	+0.210	75.21	73.42	-1.790	74.64	76.14	+4.500

그림 5의 그래프의 최종 성능값은 표 6에서 보여진다. 표 6에서 소고기의 3-Feature는 (pH, VBN, E.Coli), 돼지고기는 [pH, TBARS, SF], 닭고기는 [pH, TAB, E.Coli]이다.

Beef에서는 노이즈가 낮은 $k=1$ 에서는 Hx-DNN에 관계 없이, 성능이 좋은 것으로 보여진다. H1-DNN에서는 1.43, H2-DNN에서는 -0.86, H3-DNN은 -2.93으로 토리미터가 더 좋은 성능을 보여준다. 그러나, $k=2$ 이면 3F가 토리미터 보다 좋은 성능을 보이고, 이 현상은 $k=3$ 에서도 유효하다. 3F가 데이터 노이즈에 보다 강건하다고 판단된다.

돼지고기는 k 에 관계없이 3F가 토리미터를 상당한 차이로, $k=1$ 에서 (+28.50, +26.35, +24.15)의 성능향상이 있고, $k=2$ 에서는 (+50.28, +44.07, +46.22)의 정확도가 향상된다. $k=3$ 에서는 (+43.43, +40.14, +39.35)의 향상을 얻을 수 있다. 돼지고기의 신선도 측정에는 토리미터가 적합하지 않고, 3개의 센서를 사용하는 것이 좋다고 할 수 있다.

닭고기는 전체적으로 토리미터가 우수하다는 실험결과가 나온다. $k=3$, H1-DNN과 $k=3$, H3-DNN에서만 3F가 토리미터보다 분류능력이 우수하지만, 다른 k , DNN모델에서는 모두 토리미터가 우수하다. 닭고기에는 토리미터 센서가 적합하다는 실험결과이다.

서론에서 언급한것과 같이, 신선도 측정 센서는 오류를 가지고 있고, 유한한 측정 데이터의 개수로 얻은 측정 데이터는 평균과 편차를 가지게 된다. 이 분포를 정규분포로 가정하면, 측정값이 신뢰구간(confidence interval) 외부에서 발생하는 경우도 종종 있다. 이 데이터는 일종의 이상치(outlier)이지만, 측정값의 오류가 될 가능성이 높다. 따라서

이러한 노이즈에 강건한 센서들을 사용하는 것이 권장된다.

V. 결 론

측산데이터에서 고기의 신선도 측정은 소비자의 건강을 위한 중요한 기능이다. 이를 위해서 다양한 측정센서가 연구개발되고 있는데, 고기의 종류, 보관환경 등으로 판단 오류가 발생할 수 있다. 본 논문에서는 딥러닝 기반으로 센서 데이터의 신뢰성을 조사하였다. 실험에서는 노이즈를 포함하여 강건성도 검증하였다. 기존 토리미터보다 우수한 센서들을 연구하였다. 고기의 신선도는 소비자의 건강에 직결되는 문제이며, 따라서 이를 측정하는 기술이 필요하다. 현재 다양한 측정 센서가 연구 개발되고 있는데, 고기의 종류나 보관환경 등으로 측정 오류가 발생할 수 있다. 이러한 측정 오류는 불가피하며, 멀티 센서를 사용하여 측정 오차에 의한 오판단을 줄이는 것이 필요하다.

본 논문에서는 딥러닝을 기반으로 하여 소고기, 닭고기, 돼지고기에 대한 멀티 센서 측정의 노이즈 강건성을 조사하였다. 실험 결과는 가장 큰 노이즈에서도 90%이상의 분류 정확도를 보여주었으며, 멀티 센서를 사용하는 것이 큰 노이즈에도 강건하다는 것을 증명하였다. 또한 상용화된 센서인 토리미터보다 우수한 성능을 보일 수 있는 센서에 대해 연구하였다. PCA 분석을 통해 소고기는 [pH, VBN, E.Coli], 닭고기는 [pH, TAB, E.Coli], 돼지고기는 [pH, TBARS, SF]으로 가장 기여도가 높은 세 종류의 센서를 선

정하였다. 실험 결과 닭고기에서는 전체적으로 토리미터가 더 나은 성능을 보였다. 소고기에서는 큰 노이즈를 가질수록 선정된 센서가 더 나은 성능을 보여주었다. 돼지고기에서는 모든 경우에서 선정된 센서가 토리미터보다 월등히 나은 성능을 보여주었다. 본 논문의 실험 결과는 닭고기에서 좋은 성능을 보여주는 토리미터와 소고기, 돼지고기에서 좋은 성능을 보여주는 세 종류의 센서를 혼합하면, 더욱 범용성 있는 센서 개발이 가능하다.

적은 샘플데이터로 분석한 결과이어서, 증강된 데이터를 공급이 되면 보다 정확한 분석이 가능하다. 또한 향후에는 증강 데이터를 기반으로 소고기 등 외에도 다른 고기종류에서 제안 방법을 적용할 계획이다.

참 고 문 헌 (References)

- [1] W. Xiao, W. Bao Y. Jin, L. Lu, G. Luo, and Y. Wu, "Investigation of food freshness sensing technology for consumer use", *Progress In Electromagnetic Research Symposium (PIERS)*, Shanghai, China, 8 - 11 Aug. 2016.
- [2] M. Mladenov, M. Dejanov, S. Penchev, "Evaluation of the freshness of food products by predictive models and neural networks - a comparative analysis", *IEEE 8th International Conference on Intelligent Systems*, 2016.
- [3] G. Peiyuan, B. Man, Qu Shiha and C. Tianhua, "Detection of meat fresh degree based on neural network", *Proc. of IEEE Int' Conf. on Mechatronics and Automation*, Harbin, China, 2007
- [4] K. Timsorn, C. Wongchoosuk, P. Wattuya, S. Promdaen and S. Sittichat, "Discrimination of chicken freshness using electronic nose combined with PCA and ANN", *11th Int' Conf. on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, 2014.
- [5] E. Bakhoun, H. Marvin, M. Cheng, and R. Kyle, "Low-cost, high-accuracy method and apparatus for detecting meat Spoilage", *IEEE Tran. On Inst. and Measure.*, Vol. 65, No. 7, pp. 1707-1715, July 2016
- [6] M. Baby and L. Philip, "Low-cost embedded system for detection of E.Coli bacteria in meat", *Int' Conf. on Next Generation Intelligent Systems*, 2016.
- [7] S. Lee, C. Choi, and M. Kim, "CNN-based people recognition for vision occupancy sensors", *Journal of Broadcast Engineering*, Vol. 23, No. 2, March 2018, pp. 274-282.
- [8] E. Kim and W. Kim, "Face anti-spoofing based on combination of luminance and chrominance with convolutional neural networks", *Journal of Broadcast Engineering*, Vol. 24, No. 6, pp. 1113-1121, Nov. 2018.
- [9] J. Yuna, H. Nagaharab, and I. Park, "Classification and restoration of compositely degraded Images using deep learning", *Journal of Broadcast Engineering*, Vol. 24, No. 3, May 2019.
- [10] L. Maaten and G. Hinton, "Visualizing Data using t-SNE", *Journal of Machine Learning Research*, Vol. 9, pp. 2579-2605, 2008.
- [11] J. Sujiwo, H. J. Kim, S. Song and A. Jang, "Relationship between quality and freshness traits and torrymeter values of beef loin during cold storage", *Meat Science*, 149, pp. 120-125, 2019
- [12] <https://www.r-project.org/>, accessed on Dec. 2019

저 자 소 개



장 애 라

- 1997년 : 강원대학교 동물자원과학과 농학사
- 2001년 : 서울대학교 농생명공학부 농학석사
- 2004년 : 서울대학교 농생명공학부 농학박사
- 2007년 ~ 2012년 : 농촌진흥청 국립축산과학원 연구사
- 2012년 ~ 현재 : 강원대학교 동물생명과학대학 동물응용과학과 교수
- ORCID : <https://orcid.org/0000-0003-1789-8956>
- 주관심분야 : 동물성식품의 품질 및 영양생리기능, 신선식품, ICT기술기반 동물성식품 품질제어



김 혜 진

- 2015년 : 강원대학교 동물식품응용과학과 학사
- 2017년 : 강원대학교 동물생명과학과 농학석사
- 2017년 ~ 현재 : 강원대학교 동물생명과학과 박사과정
- ORCID : <https://orcid.org/0000-0002-9384>
- 주관심분야 : 식품안전성, 기능성식품, 면역, ICT

저 자 소 개



김 만 배

- 1983년 : 한양대학교 전자공학과 학사
- 1986년 : University of Washington, Seattle 전기공학과 공학석사
- 1992년 : University of Washington, Seattle 전기공학과 공학박사
- 1992년 ~ 1998년 : 삼성종합기술원 수석연구원
- 1998년 ~ 현재 : 강원대학교 컴퓨터정보통신공학과 교수
- 2016년 ~ 2018년 : 강원대학교 정보통신연구소 소장
- ORCID : <http://orcid.org/0000-0002-4702-8276>
- 주관심분야 : 컴퓨터비전, 데이터분석, 영상처리