

인공신경망을 이용한 기체환경제어 저장 복숭아 감모율 예측

이승철^{1,2}, 남광우¹, 최동수², 김용훈², 김진세², 박찬원^{2*}
¹군산대학교 컴퓨터정보공학과, ²국립농업과학원 농업공학부

Prediction for Weight Loss Rate of Peach in Controlled Atmosphere Storage Using Artificial Neural Network

Seung Chul Lee^{1,2}, Kwang Woo Nam¹, Dong Soo Choi²,
Yong Hun Kim², Jin Se Kim², Chun Wan Park^{2*}

¹Department of Computer Information Engineering, Kunsan University
²Department of Agricultural Engineering, National Institute of Agricultural Sciences

요약 수확 후 CA 저장고 내의 환경데이터를 기반으로 저장고 내의 복숭아 품질예측 가능성을 확인 하고자 했다. CA 저장고에서 저장기간 중 복숭아의 감모율을 예측하기 위해 포화수증기압차 방식과 인공신경망을 이용하여 예측하고 실제 측정된 값과 비교하여 정확도를 결정계수(R^2)로 나타내었다. 포화수증기압차 방식에서 사용하는 증산계수는 기존 알려진 572가 아닌 실측값과 비교하여 계산했을 때 271이었고, 증산계수는 저장환경 등의 영향으로 다르게 산출되며 하나의 고정된 값이 없어 포화수증기압차 방식으로 예측하기 어려웠다. 인공신경망 학습을 통한 예측의 적합도를 나타내는 결정계수(R^2)는 0.93이었다. 심층신경망 모델과 포화수증기압차 방식 모두 실제 주차별 평균 감모율과 비슷하였으나, 개별 시료 예측의 결정계수(R^2)는 심층신경망 0.93, 포화수증기압차 0.77로, 심층신경망이 좋은 결과를 보였다. 저장기간이 길어질 때(21, 28일차), 예측값의 적합도가 떨어졌으며, 이는 모델의 불완전성을 나타내는 것으로 판단된다. 인공신경망을 이용한 예측의 적합도를 높이기 위해 더 많은 데이터의 확보가 필요해 보이며, 심층신경망 학습을 통한 감모율 예측은 다른 농산물에도 활용할 수 있을 것으로 사료된다.

Abstract The potential for predicting the quality of peaches within a Controlled Atmosphere (CA) storage facility was determined post-harvest using environmental data collected inside the facility. The weight loss rate of peaches during storage in the CA storage facility was predicted using the saturation vapor pressure deficit method and artificial neural network analysis. Predicted and measured values were compared, and accuracies were expressed as determination coefficients (R^2). The deep neural network model and the saturation vapor pressure deficit method predicted similar average storage weight loss rates. The determination coefficient (R^2) for individual sample predictions was 0.93 for the deep neural network and 0.77 for the saturation vapor pressure deficit method, indicating that the deep neural network yielded superior results. Prediction fitness decreased when the storage period was extended to 21 and 28 days, indicating model incompleteness. More data is required to improve the fitness of predictions made using artificial neural networks.

Keywords : Artificial Neural Network, Cold Storage, Peach, Weight-Loss

본 연구는 농촌진흥청 농업과학기술 연구개발사업(PJ01675502)의 지원에 의해 이루어진 것임.

*Corresponding Author : Chun Wan Park(Division of Postharvest Engineering, National Institute of Agricultural Sciences)
email: chunwan1@korea.kr

Received November 23, 2023

Revised December 28, 2023

Accepted January 5, 2024

Published January 31, 2024

1. 서론

복숭아는 재배면적으로 볼 때 2022년 기준으로 20,300 ha 로 사과, 감귤에 이어 세 번째에 해당하며, 생산량은 204,000톤에 달하고, 수확시기는 6월~10월로 고온 다습한 환경에서 수확된다[1,2]. 복숭아는 일반적으로 실온에서 3~5일 보관이 가능하고[3], 저온 저장고에서 2~4주 저장이 가능하다고 보고되고 있으나[4], 0°C에서 3주 이상 저장하는 것 보다 2~5°C에서 저장하는 것이 1~2주 더 빨리 냉해가 발생하므로 주의가 필요하다[5]. 복숭아를 비롯하여 과일은 수확후에도 호흡을 하며, 호흡을 통해 발생하는 수분 손실로 과실의 중량이 감소하고, 에틸렌 등의 발생으로 과실이 물러지고, 표면의 색이 변화하고, 내부에 갈변이 발생하는 등 품질에 변화가 생겨 저장 기간을 단축하게 된다[6]. 복숭아의 저장기간을 늘리고 품질 유지를 위해 복숭아 부패에 영향을 주는 미생물을 사멸시키기 위해 자외선을 조사하고[2], 복숭아의 호흡량 억제를 통한 생리작용 지연으로 품질을 유지하는 일산화질소 처리[7], 수확 1~2주 전에 복숭아 성숙에 영향을 미치는 에틸렌 생성을 억제하거나 에틸렌 작용을 억제하는 에틸렌 생성 억제제 및 에틸렌 작용 억제제를 도포하고, 수확 후 에틸렌 작용 억제제를 훈증 처리하여 품질을 유지 시키는 방법[8], 저장고 내의 온도 및 기체 조성을 조절하여 품질을 유지 시키는 기체조성(CA, Controlled Atmosphere) 저장[9] 등이 연구되고 있다.

복숭아는 기상 조건에 따라 조기 수확할 수 있고, 이 경우 저장고에서 성숙 후 출하해야 하며, 저장 중에도 저장 상황에 따라 장기저장을 할 수 있고, 단기저장 후 출하할 수도 있어, 저장기간을 유동적으로 조절할 수 있어야 한다. 이를 위해 저장기간 동안 올바른 복숭아 품질 예측이 가능해야 하며, 저장환경에 기반한 저장기간 동안 복숭아 품질 예측은 국내·외적으로 표준화된 방법은 없고, 계속해서 연구 중이며, 알려진 방법 중 미국에서 발간한 백서에 포화수증기압차(VPD, Vapor Pressure Deficit)를 이용한 방법이 있으나[10] 정확하지 못하고, 더욱 정확한 예측을 위해 인공신경망(ANN, Artificial Neural Network)을 활용한 방법을 고려해 볼 수 있다.

최근 농업에 인공신경망을 적용한 연구가 활발히 이루어지고 있으며, 복숭아에 이를 적용한 연구는 복숭아 품종별 이미지나 성숙도 이미지를 합성곱신경망(CNN, Convolution Neural Network)을 이용한 품종 분류, 성숙도 분류[11,12], 초분광 이미지를 다층 퍼셉트론(Multilayer Perceptron)에 적용한 냉해 탐지[13], 재배

지도 작성을 위한 복숭아 검출[14] 등 주로 분류나 검출을 다루는 이미지를 활용한 연구가 많다. 반면, 숫자 데이터에 기반한 연구는 회귀, 예측에 대한 문제이며, 주로 사용하는 인공신경망(ANN)은 심층신경망(DNN, Deep Neural Networks)[15]이 주로 이용되며, 농업에서 활용한 경우는 드물다.

본 연구는 수확 후 CA 저장고 내의 환경 데이터를 기반으로 저장고 내의 복숭아의 품질예측 가능성을 확인했다. 세부적으로는 인공신경망(ANN) 중에서 심층신경망(DNN)을 이용하였고, 알려진 방법인 환경분석(VPD)을 통한 감모율 예측 결과를 비교했다.

2. 재료 및 방법

2.1 학습데이터

본 연구는 선행연구에서[9] 사용한 복숭아 시료 192개에 대한 CA 저장고의 온도, 습도, 풍속 등의 환경데이터와 저장기간 중 일주일 간격(0, 7, 14, 21, 28일)으로 측정된 복숭아 중량 데이터를 사용하였다. 이때 사용한 데이터는 처리구별 18개로 품질 특성 조사에 따른 시료 수의 물리적 한계로 데이터 개수가 제한적이며, 연구 초기 단계로 데이터 개수의 한계가 존재한다. 또한 이미지를 이용한 연구는 이미지 반전, 이미지 회전, 확대, 축소 등을 통해 데이터양을 늘려 학습이 용이하지만 [16], 숫자 데이터에 기반한 연구는 데이터양을 늘리는 것이 제한적이다.

2.2 예측방법 및 데이터 전처리

2.2.1 포화수증기압차(VPD) 이용 예측

감모율(W_r)은 저장기간 동안에 농산물의 수분손실로 인한 무게 감소율을 말하며, 포화수증기압차를 이용한 계산은 농산물의 증기압을 포화증기로 고려하고 저장공간의 증기압과 차를 구해 증산량(증발량)을 산출하고 그 값에 증산계수(k-value)를 곱하여 구할 수 있으며 [10,17], Eq (1)에 나타내었다.

$$W_r(\%/1day) = k\ value \times VPD \quad (1)$$

$$VPD = VP \times \left(1 - \frac{RH}{100}\right)$$

$$VP = 611 \times \exp\left(\frac{17.27 \times T}{273.3 \times T}\right)$$

W_r : Weight loss rate per 1 day
 k value : Transpiration coefficient
 VPD : Vapor Pressure Deficit
 RH : Relative Humidity
 VP : Vapor Pressure (RH 100%)

복숭아의 증산계수(k value)는 572로 알려져 있으나 [10], 실제 측정된 주 단위 평균 감모율과는 차이가 커서 주 단위 평균 감모율과 평균제곱오차(MSE, Mean Square Error)가 가장 작은 값을 계산하여 사용하였다. 심층신경망 모델의 예측값과 비교하기 위해 Eq (2)로 변화된 중량을 계산하였다.

$$Wt = Wt_0(1 - W_r \times day) \quad (2)$$

Wt : changed Weight
 Wt_0 : initial Weight
 W_r : Weight loss rate (per day)
 day : storage Day

2.2.2 인공신경망(ANN) 이용 예측

인공신경망은 입력층, 은닉층, 출력층으로 구성되며, 여러 개의 은닉층을 가진 구조를 심층신경망(DNN, Deep Neural Network)이라고 하며[15], 본 실험에서는 심층신경망 학습을 통한 복숭아의 감모율 예측을 실시했다. Fig. 1은 출력값이 1개인 심층신경망을 나타내었다. 입력층과 은닉층은 각각의 유닛(unit)들이 서로 연결되어 있고, 유닛들 사이의 연결에는 개별 가중치(w)를 가지고 있다. Eq. (3)은 심층신경망 학습의 연산을 보여준다. 은닉층의 유닛 값은 입력층의 유닛에 연결된 가중치를 곱하고, 모두 더한 후 함수에 넣어 계산하는데, 함수의 결과가 다음 층 유닛의 값이다. 이때 사용하는 함수를 활성화함수(Activation Function)라고 하며, 본 실험에서는 활성화함수로 정류선형유닛((ReLU, Rectified Linear Unit)을 사용하였다. 손실함수(목적함수)는 학습 중에 출력값과 실제값의 차이를 구하고 각각의 가중치에 이를 반영하여 수정에 이용한다. 손실함수 값이 최소가 되는 방향으로 학습하며, 손실함수로 MSE를 사용하였다. 학습 지표의 하나로 정확도를 측정하는데, 분류 문제에서는 정확도를 사용하지만, 값을 다루는 회귀 문제는 예측값과 실제값이 정확히 일치하는 경우가 거의 없어, 정확도를 사용할 수 없다. 따라서 적합도를 나타내는 결정계수(R^2)를 사용하였다. 결정계수(R^2)는 0과 1사이의




Fig. 1. Deep Neural Network Model

값을 가지며, 1에 가까울수록 적합도가 높음을 의미하고, 예측값이 실제값과 얼마나 가까운지 나타낸다. 입력값은 온도, 습도, 풍속, 초기 중량, 저장 일수로 5개의 유닛을 사용하였고, 은닉층은 3개의 층으로 각각 32, 16, 8개의 유닛을 사용하였다. 출력층에서는 변화된 중량이 출력된다. 복숭아 시료 192개 중에서 랜덤하게 분리하여 70%는 학습용 데이터로 사용하였고 30%는 검증용 데이터로 사용하였다. 심층신경망 모델이 학습용 데이터에만 최적화되는 과대적합(Overfit)을 방지하기 위해 조기종료조건을 설정하였다. 조기종료조건은 학습 중 손실함수 값을 비교하여 개선이 없을 때 추가로 10회 더 학습하고, 추가 학습 후에도 개선이 없을 때 조기종료하는 함수를 호출하였다[18].

$$y_j = f\left(\sum_{i=1}^p w_{ij} \times x_i + b \times w_0\right) \quad (3)$$

$$f(x) = \max(0, x)$$

y_j : output

w_{ij} : weights

x_i : input

b : bias node (= 1)

w_0 : bias node weight

$f(x)$: Activation function (ReLU)

포화수증기압차(VPD) 방식 예측과 비교에는 검증용 데이터를 활용하였다.

주차별 예측의 유의성 검증을 위해 SAS(Statistical Analysis System, 9.4, SAS Institute Inc., Cary, NC, USA) 프로그램을 이용하여 일원배치 분산분석(ANOVA)

을 하였고, 유의적 차이가 있는 경우 $p < 0.001$ 수준에서 Duncan의 다중검정 방법으로 사후분석을 실시하였다.

2.2.3 데이터 전처리

효과적인 인공지능망 학습을 위해 Eq (4)을 이용하여 데이터를 표준화하였고[19], 온도, 습도, 풍속, 초기증량 등 모든 입력값과 결과값을 표준화했다.

$$x_s = \frac{x_o - x_{avg}}{x_{stdev}} \quad (4)$$

x_s : standardization data

x_o : original data

x_{avg} : x average

x_{stdev} : x standard deviation

3. 결과 및 고찰

3.1 포화증기압차(VPD) 예측

Fig. 2는 복숭아를 저장하는 동안에 측정된 온도와 습도를 이용하여 포화증기압차(VPD) 방식으로 계산한 저장기간에 따른 무게 감소율을 나타낸 그래프이다. 최종적으로 28일차 실제 감모율은 9.13%를 보였으나, 복숭아의 증산계수(k value)로 알려진 572를 적용하였을 경우 18.64%로 실측값과 9%p 넘게 차이가 났다. 포화수증기압차 계산방식은 저장환경의 온도와 습도가 정밀하게 측정된 경우 증산계수의 지배적인 영향을 받는다. 따라서, 복숭아의 적정 증산계수를 산출하기 위해 포화수증기압차 방식을 이용한 계산값과 측정값의 MSE가 가

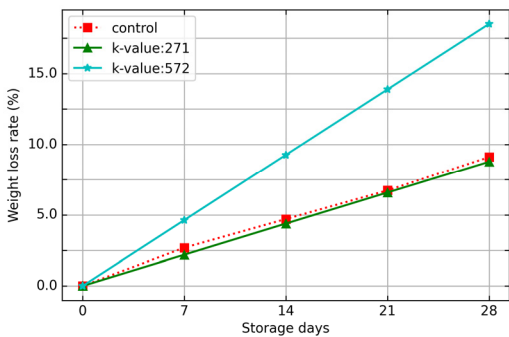


Fig. 2. Weight loss rate using VPD(Vapor Pressure Deficit) method applying different k-value

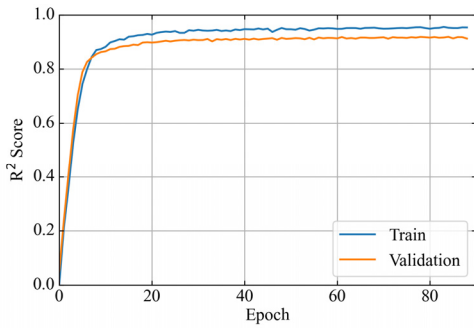
장 작은 증산계수를 산출한 결과 271로 산출되었다. 이를 이용해 무게 감소율을 계산했을 때 8.83%로 실제감모율과 0.3%p 차이가 났고, 증산계수의 차이로 인해 정확한 측정이 어려웠다. 저장기간 동안 실제감모율과의 차이는 주차별로 0.1 ~ 0.5%p로 나타났다. 이는 포화수증기압차 계산 방식의 한계로 증산계수가 작물, 품종, 작황 등에 따라 매우 예민하게 반응하기 때문으로 판단된다[16].

실험기간 중 저장고 내의 위치별로 측정된 온도, 습도를 이용하여 위치별 증산계수를 계산하였고, 증산계수의 차이가 크게는 200 넘게 차이가 났다. 이는 온도에 따라 포화수증기압과 복숭아의 호흡률이 달라지며, 조성기체에 따라 증산량의 차이가 나타나며[20,21], 결국 복숭아의 증산계수의 변화로 이어진 것으로 판단된다. 따라서 저장고 전체의 평균값으로 계산한 하나의 증산계수로는 저장고 내의 전체적인 추이는 가능할 수 있겠지만, 개별 시료에 대해 예측하기는 힘들다고 판단된다. 이는 이번 실험에서 도출한 증산계수를 다른 실험에도 동일하게 적용할 수 없음을 의미한다. 앞으로도 포화수증기압차를 이용한 감모율 예측은 증산계수 도출을 위해 별도의 실험을 하거나, 이번 실험처럼 저장기간 동안 주기적으로 복숭아 증량을 측정한 다음 증산계수를 계산하는 방식으로 값을 도출해야 할 것이다. 복숭아는 아니지만 선행연구를 보면 알려진 증산계수와 다른 값을 도출한 것으로 볼 때[16], 증산계수에 대한 추가적인 연구가 필요해 보인다.


3.2 심층신경망(DNN) 학습 및 예측

3.2.1 심층신경망(DNN) 학습

Fig. 3은 표준화 데이터로 학습한 모델의 결정계수와 손실함수 그래프이다. 학습은 200회 실시 하였으나 89회에 조기종료 되었고, 종료시 검증용 데이터의 결정계수(R^2)는 0.93이었으며, MSE는 0.079이었다. 비표준화 데이터로 학습할 때, 손실함수를 MSE로 사용하였으나 제대로 학습이 되지 않아 손실함수를 평균절대오차(MAE, Mean Absolute Error)로 교체하였다. 학습은 182회에 조기종료 하였고, 이때 검증용 데이터의 결정계수(R^2)는 0.89, MAE는 5.43이었다. 표준화 데이터로 학습한 모델(표준화 모델)과 비표준화 데이터로 학습한 모델(비표준화 모델)은 손실함수가 달라 직접적인 비교는 어렵다. 하지만 간단히 MSE를 MAE의 제곱으로 가정할 때 비표준화 모델이 표준화 모델과 비교하여 MSE가 상당히 클 것으로 예상된다. 표준화 모델은 비표준화 모델



(a) DNN Coefficient of determination



(b) DNN Loss value

Fig. 3. Learning for DNN (Deep Neural Network)

과 비교하여 학습이 빨리 종료되었고, 적합도가 높은 것으로 볼 때 소량의 데이터에도 데이터의 표준화가 학습에 효율적임을 확인하였다.

3.2.2 심층신경망 예측

심층신경망 학습을 통한 주 단위 평균 감모율 그래프를 보면, 28일차 감모율 예측이 표준화 모델은 9.1%였고, 비표준화 모델은 8.03%였다. 실제 감모율 9.13%와 비교할 때, 표준화 모델은 거의 차이가 없었고, 비표준화 모델은 1.1%p의 차이가 났다. 저장기간 동안 표준화 모델의 예측 감모율과 실제 감모율의 주 단위 평균 감모율의 차이가 0.02 ~ 0.09%p를 보였고, 비표준화 모델은 0.2 ~ 1.1%p로 저장기간이 길어질수록 차이가 커졌다 (Fig. 4). 최종 감모율 및 주 단위 평균 감모율의 차이를 볼 때, 표준화 모델이 비표준화 모델과 비교하여 모델의 적합도가 높음을 보였으며, 데이터를 표준화하는 것이 심층신경망 학습에 유리할 것으로 판단된다.

심층신경망 모델은 입력값으로 증산계수는 필요 없으나, 저장기간 동안의 환경데이터와 저장실험 데이터가 필요하다. 이번 실험에서는 현재 시료에 대해 적합도

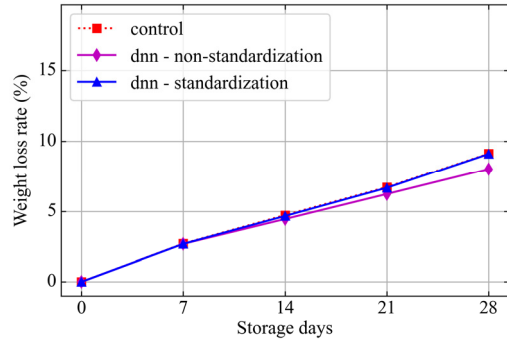



Fig. 4. Weight loss rate by DNN (Deep Neural Network)

0.93으로 예측한다고 볼 수 있다. 선행연구 결과를 볼 때, 실험 방법이나 품종이 같은 것은 아니지만 인공신경망을 활용한 예측 적합도(R^2)가 항목에 따라 0.82 ~ 0.94로 나온 것으로 볼 때 [22], 이번 실험의 적합도가 낮은 것은 아니라고 보여진다. 그러나, 더 많은 데이터의 확보로 적합도를 높일 필요가 있다. 더 많은 데이터를 확보하는 방법에는 추가 실험을 통해 데이터를 확보는 방법과 퍼지이론을 적용하여 데이터의 범위를 확장하고, 데이터의 추세를 추정하여 유사 데이터를 생성하는 방법 [23] 등이 있으며, 유사 데이터를 생성하여 적합도를 높이는 방법은 차후에 다뤄볼 예정이다.


이번에 사용한 데이터는 반복횟수가 작은 시계열 데이터로 예측의 적합도를 높이기 위해 시계열 예측에 많이 사용되는 순환신경망(RNN, Recurrent Neural Network)이나, 그 변형 모델인 Long Short Term Memory (LSTM)[24], Gated Recurrent Unit(GRU)[25] 등을 이용하는 방법이 있다. 이러한 시계열 학습데이터를 작성할 때, 7일차를 학습시키고, 나머지 기간을 예측하거나, 7, 14일을 학습시키고, 21, 28일을 예측하는 등 학습데이터 형태에 따라 몇가지 모델을 만들어야 한다. 이번 논문 내용에는 들어있지 않지만 실험적으로 7, 14, 21일차를 학습하고, 28일 감모율을 예측한 적합도(R^2)는 0.97이었다.

3.3 예측 비교

Fig. 5는 복숭아 각 시료의 저장 기간동안 실제 변화된 증량을 증산계수 값으로 271을 사용한 포화수증기압차 방식 예측 증량과 심층신경망 표준화 모델의 예측 증량을 비교할 수 있게 각각 나타내었다. 포화수증기압차 방식 예측의 결정계수(R^2)는 0.77이었으며, 심층신경망 표준화 모델 예측의 결정계수는(R^2)는 0.93으로 심층신



(a) VPD method



(b) DNN

Fig. 5. Weight(g) prediction using VPD (Vapor Pressure Deficit) method & DNN (Deep Neural Network)

경망 표준화 모델이 높은 적합도를 보였다. 포화수증기압차 방식 예측과 심층신경망 표준화 모델 모두 주차별 감모율 평균과 유사하지만 개별 시료에 대한 예측은 심층신경망 표준화 모델이 더 나은 것으로 나타났다. 두 그래프 모두 좌측하단부의 중량이 작은 부분에서 분산되는 모양을 보였는데, 심층신경망 그래프의 분산 원인을 파악하기 위해 중량이 360 g 이하인 데이터를 저장기간 별로 분류한 결과 데이터 분포가 7, 14, 21, 28일차 별로 13%, 20%, 29%, 38% 였고, 이 기간 동안 감모율의 오차가 DNN은 0.7%에서 2.3%까지 증가하였고, VPD는 0.9%에서 4.5%까지 증가하였다. 이는 초기중량이 작은 시료 예측의 적합도가 낮은 영향도 있겠지만, 저장기간이 길어질수록 중량이 줄어들고, 이에 대한 예측의 적합

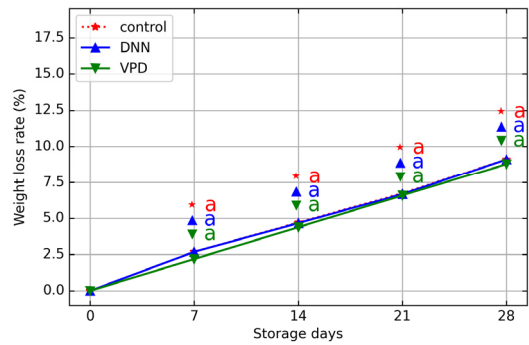


Fig. 6. Weight loss rate by prediction & Result of Duncan's multiple range test

도가 낮은 것으로 보인다. 즉 저장기간이 길어질수록(21, 28 일차) 예측 적합도가 떨어지고 있는 것이며, 이는 모델의 불완전성을 나타내는 것으로 판단된다.

저장기간이 길어지면서 21, 28 일차에 나타나는 낮은 적합도를 높이기 위해서는 추가적인 실험을 통해 더 많은 데이터를 확보하고 학습할 필요가 있어 보인다.

Fig. 6은 DNN과 VPD를 이용해 예측한 결과와 실제 측정된 데이터의 평균을 나타낸 그래프이다. DNN을 이용한 예측은 실제 측정값과 동일하게 변화하고 있으나 VPD를 이용한 예측값은 7, 14, 28일차에 각각 1%, 2%, 4%의 오차가 발생하고 있다. 이는 제상 및 냉각운전에 따른 저장환경의 급속한 변화와 온습도 측정오차에 의한 예측오차로 판단된다. 하지만 예측 결과는 $p < 0.001$ 수준에서 유의차가 없게 나타났고 무게 감소율을 예측하기 위한 모델로서 적합하다고 사료된다.

4. 결론

본 연구는 품질예측의 일환으로 저장중인 복숭아의 감모율 예측 모델을 상호비교 및 검증하였다. 그 결과는 다음과 같다.

- 1) 포화수증기압차 방식 예측에서 사용한 증산계수를 알려진 값인 572를 사용했을 때, 실제 감모율과는 차이가 컸고, 실제 감모율과 유사한 감모율을 나타낸 값은 271이었다.
- 2) 심층신경망 학습에서 데이터를 표준화한 것이 학습은 93회 빨리 끝났으며, 예측값의 적합도(R^2)가 0.04 높게 나타났다.
- 3) 심층신경망 예측의 적합도(R^2)는 0.93 이었고, 포화수증기압차 방식의 예측 적합도(R^2)는 0.77로 나

타나 심층신경망의 적합도가 높게 나타났으나, 저장기간이 길어지는 21, 28 일차에서는 두가지 방식 모두 예측 적합도가 떨어졌다.

포화수증기압차 방식 예측과 인공신경망 모델을 이용한 예측이 가능한 이유는 감모율이 저장기간에 따라 선형적으로 변하고, 감모율에 작용하는 요소가 온도, 습도 등으로 알려져 있기 때문이다. 하지만, 포화수증기압차 방식에서 증산계수는 중요한 값으로 사용되는데, 저장 환경에 따라 그 값이 달라 저장 환경에 맞는 실험을 통해 증산계수를 다시 구하지 않으면 감모율 예측이 힘들다. 또한, 심층신경망 학습을 위해 일반적으로 대량의 데이터가 필요한데 이번 실험에 사용된 데이터는 192개 시료의 데이터로 매우 작은 양으로 도출된 결과이며, 예측의 적합도를 높이기 위해 더 많은 데이터의 확보가 필요하며, 유사 데이터 생성도 고려해 볼 수 있겠다.

인공신경망 학습을 통한 저장기간 동안의 감모율 예측은 다른 농산물에도 적용할 수 있을 것으로 사료된다.

References

- [1] KREI. Agricultural Outlook 2023 Korea. Korea rural economic institute(E04-2023), Korea. pp537-582, 2023.
- [2] J.H. Jang, J.H. Park, K.E. Ban, K.H. Lee, "Changes in the Quality of Peaches (*Prunus persica* L. Batsch) Treated by UV-C Irradiation during Storage", *The Korean Journal of Food and Nutrition*. Vol.41, No.12, pp.1798-1804, 2012.
DOI: <https://dx.doi.org/10.3746/jkfn.2012.41.12.1798>
- [3] N. Gupta, S. K. Jawandha, P. S. Gill, "Effect of Calcium on Cold Storage and Post-Storage Quality of Peach", *Journal of food science and technology*, Vol.48, pp.225-229, 2011.
DOI: <https://dx.doi.org/10.1007/s13197-010-0116-z>
- [4] S. Brizzolara, M. Hertog, R. Tosetti, B. Nicolai, P. Tonutti, "Metabolic Responses to Low Temperature of three Peach Fruit Cultivars Differently Sensitive to Cold Storage", *Frontiers in Plant Science*, Vol.9, 2018.
DOI: <https://dx.doi.org/10.3389/fpls.2018.00706>
- [5] S. Lurie, C. H. Crisosto, "Chilling injury in Peach and Nectarine", *Postharvest biology and technology*, Vol.37, pp.195-208, 2005.
DOI: <https://dx.doi.org/10.1016/j.postharvbio.2005.04.012>
- [6] B. S. Kim, H. J. Lee, H. W. Park, H. S. Cha, "Effect of Respiration and Transpiration Rates on the Weight Loss of various Fruits (Peach, Apple, Pear, Persimon, Mandarin)", *Korean Journal of Food Preservation*, Vol.10, No.2, pp.142-146, 2003.
- [7] H. Eum, D. Hwang, Y. Hong, S. Lee, "Treatment of Nitric Oxide to Improve the Quality of 'Mibaekdo' Peach during Shelf Life", *Korean Journal of Horticultural Science & Technology*, Vol.27, No.4, pp.618-624, 2009.
- [8] J. Yoo, C. Park, J. G. Kwon, D. H. Lee, H. Y. Jung, Y. J. Cho, I. K. Kang, "Effects of Preharvest Aminoethoxyvinylglycine and Pre-or Postharvest 1-Methylcyclopropene Treatments on Fruit Quality Attributes during Cold Storage in 'Misshong' Peaches", *Horticultural Science and Technology*, Vol.38, No.3, pp.364-373, 2020.
DOI: <https://doi.org/10.12735/HORT.20200035>
- [9] C. W. Park, D. S. Choi, Y. H. Kim, J. S. Kim, S. H. Kim, Y. B. Kwack, & J. H. Song, "Quality Characteristics of 'Kunika' Peaches according to Storage Methods", *The Journal of the Korean Society of International Agriculture*, Vol.34, No.4, pp.344-349, 2022.
DOI: <https://doi.org/10.12719/KSIA.2022.34.4.344>
- [10] H. Deirdre, "Water Relations in Harvested Fresh Produce", PEF(The Postharvest Education Foundation), No. 15-1, pp.9, 2015.
- [11] A. Amir, G. Hosein, Z. Saman, "Classification of three varieties of Peach Fruit using Artificial Neural Network Assisted with Image Processing Techniques.", *International Journal of Agronomy and Plant Production*, Vol.4, No 9, pp.2179-2186, 2013.
<https://www.researchgate.net/publication/318878038>
- [12] M. H. Shin, K. E. Jang, S. K. Lee, J. G. Cho, S. J. Song, J. G. Kim, "Grading of Harvested 'Mihwang' Peach Maturity with Convolutional Neural Network", *Journal of Bio-Environment Control*, Vol.31, No 4, pp.270-278, 2022.
DOI: <https://doi.org/10.12791/KSBEC.2022.31.4.270>
- [13] L. Pan, Q. Zhang, W. Zhang, Y. Sun, P. Hu, K. Tu, "Detection of Cold Injury in Peaches by Hyperspectral Reflectance Imaging and Artificial Neural Network", *Food chemistry*, Vol.192, pp.134-141, 2016.
DOI: <https://dx.doi.org/10.1016/j.foodchem.2015.06.106>
- [14] F. Kurtulmus, W. S. Lee, A. Vardar, "Immature Peach Detection in Colour Images Acquired in Natural Illumination Conditions using Statistical Classifiers and Neural Network", *Precision agriculture*, Vol.15, pp.57-79, 2014
DOI: <http://dx.doi.org/10.1007/s11119-013-9323-8>
- [15] V. Sze, Y. H. Chen, T. J. Yang, J. S. Emer, "Efficient Processing of Deep Neural Networks: A Tutorial and Survey", *Proceedings of the IEEE*, Vol.105, No 12, pp.2295-2329, 2017
DOI: <http://dx.doi.org/10.1109/JPROC.2017.2761740>
- [16] C. Shorten, & T. M. Khoshgoftaar, "A Survey on Image Data Augmentation for Deep Learning". *Journal of big data*, 6(1), 1-48, 2019.
DOI: <https://doi.org/10.1186/s40537-019-0197-0>
- [17] C. W. Park, S. H. Park, J. S. Kim, D. S. Choi, Y. H. Kim, S. J. Lee, "Weight Loss Prediction by Operating Conditions of CA Storage", *Food Engineering Progress*, Vol.21, No 4, pp.312-317 2017

DOI: <https://doi.org/10.13050/foodengprog.2017.21.4.312>

- [18] I. S. Oh, J. S. Lee, "Artificial Intelligence Made with Python", p608, *Hanbit Academy Inc.*, 2021, pp224-226, p407.
DOI: <https://doi.org/10.979.115664/8284>
- [19] C. W. Dawson, R. L. Wilby, "Hydrological Modelling Using Artificial Neural Networks", *Progress in physical Geography*, Vol.25, No1, pp.80-108, 2001
DOI: <https://doi.org/10.1177/030913330102500104>
- [20] B. S. Kim, H. J. Lee, H. W. Park, H. S. Cha, "Effect of Respiration and Transpiration Rates on the Weight Loss of various Fruits(Peach, Apple, Pear, Persimon, Mandarin)", *Korean Journal of Food Preservation*, Vol.10, No.2, pp.142-146, 2003.
- [21] J. S. Kang, H. S. Chung, J. U. Choi, "Effects of Storage Gas Concentrations on the Transpiration Rate of Fuji Apple during CA Storage", *Korean Journal of Food preservation*, Vol.9, No 3, pp.261-266, 2002
- [22] M. Mohammed, M. Munir, & A. Aljabr. "Prediction of Date Fruit Quality Attributes during Cold Storage Based on their Electrical Properties using Artificial Neural Networks Models." *Foods*, Vol.11, No.11, 2022
DOI: <http://dx.doi.org/10.3390/foods11111666>
- [23] A. Lateh, A. K. Muda, Z. I. M. Yusof, N. A. Muda., & M. S. Azmi, "Handling a Small Dataset Problem in Prediction Model by employ Artificial Data generation Approach: A review." *Journal of Physics: Conference Series*, IOP Publishing, Langkawi, Malaysia, Vol. 892, No. 1, pp012~016 May, 2017.
DOI: <https://doi.org/10.1088/1742-6596/892/1/012016>
- [24] H. Sepp, J. Schmidhuber. "Long Short-Term Memory." *Neural computation* Vol.9, No.8, pp1735-1780, 1997.
DOI: <http://dx.doi.org/10.1162/neco.1997.9.8.1735>
- [25] J. Chung, C. Gulcehre, K. Cho & Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling." arXiv preprint arXiv:1412.3555, 2014.
DOI: <https://doi.org/10.48550/arXiv.1412.3555>

이 승 철(Seung-Chul Lee)

[정회원]



- 2021년 9월 : 전주대학교 농생명 융합학과 (이학석사)
- 2022년 3월 ~ 현재 : 군산대학교 컴퓨터정보공학과 박사과정
- 2014년 2월 ~ 현재 : 국립농업과학원 스마트팜개발과 연구원

<관심분야>

인공지능, 데이터마이닝

남 광 우(Kwang-Woo Nam)

[정회원]



- 1997년 2월 : 충북대학교 전자계산학과 이학석사
- 2001년 8월 : 충북대학교 전자계산학과 이학박사
- 2001년 12월 ~ 2004년 9월 : 한국전자통신연구원 텔레매틱스·USN 연구단 선임연구원
- 2004년 9월 ~ 현재 : 군산대학교 컴퓨터정보통신학부 교수

<관심분야>

공간데이터베이스, 데이터마이닝

최 동 수(Dong-Soo Choi)

[정회원]



- 1993년 2월 : 충남대학교 농업기계공학과 석사
- 2001년 2월 : 충남대학교 농업기계공학과 박사
- 1998년 2월 ~ 현재 : 국립농업과학원 수확후관리공학과 농업연구사

<관심분야>

정보경영, 정보통신

김 용 훈(Yong-Hoon Kim)

[정회원]




- 1997년 2월 : 한국외국어대학교 화학과 석사
- 2005년 3월 : The graduate university for advanced studies (일본) 박사
- 2009년 1월 ~ 현재 : 국립농업과학원 수확후관리공학과 농업연구사

<관심분야>

화학공학, 저장유통공학, ICT융복합

김 진 세(Jin-Se Kim)

[정회원]



- 2000년 2월 : 고려대학교 물리학과 (물리학석사)
- 2018년 8월 : 충남대학교 농기계공학과 (농기계공학박사)
- 2013년 10월 ~ 현재 : 국립농업과학원 수확후관리공학과 농업연구사

<관심분야>

물리학, 농업공학

박 천 완(Chun-Wan Park)

[정회원]



- 2011년 2월 : 전북대학교 기계공학과 석사
- 2016년 2월 : 전북대학교 기계공학과 박사
- 2016년 1월 ~ 2022년 12월 : 국립농업과학원 박사후연구원
- 2023년 1월 ~ 현재 : 국립농업과학원 수확후관리공학과 농업연구사

<관심분야>

냉동공학, 환경제어, 센서공학, 저장유통