

인공지능을 활용한 밀키트 포장 방법 및 재질 분류 모델 개발

김태형 · 권기현 · 김아나*

한국식품연구원 스마트제조연구단

Artificial Intelligence Based Meal-kit Packaging Method and Material Classification Model

Tae Hyong Kim, Kihyun Kwon, and Ah-Na Kim*

Smart Manufacturing Research Group, Korea Food Research Institute, Wanju 55365, Jeonbuk-do, Republic of Korea

Abstract This study proposes an artificial intelligence (AI)-based multi-output artificial neural network (ANN) classification model capable of automatically predicting optimal packaging methods and materials based on product characteristics. A total of 51 commercial meal-kit products distributed under ambient, chilled, and frozen conditions were analyzed to construct a comprehensive dataset comprising 19 packaging-related parameters such as distribution type, cooking requirement, packaging material, and sealing type. Of these, 17 parameters were used as input features, and two—packaging method and packaging material—served as output targets. The initial ANN model included an input layer of 17 nodes, two hidden layers with 128 neurons each (tanh activation), and two softmax output layers (nine and eight nodes for method and material classification, respectively). To optimize performance, Bayesian optimization was applied to five key hyperparameters: neuron count, learning rate, activation function, neuron division ratio, and optimizer type. The optimized model with four hidden layers and 1,024 neurons achieved classification accuracies of 85.8% for packaging method and 93.9% for packaging material, with corresponding F1-scores of 84.4% and 90.9%, respectively. Compared to the baseline, this represents a 22-44% improvement across metrics. The findings demonstrate the potential of AI-driven systems for intelligent, standardized, and sustainable packaging design, contributing to the advancement of smart manufacturing and eco-efficient food packaging automation.

Keywords Artificial intelligence, Neural network, Meal-kit, Packaging, Automation

서론

국내 밀키트 산업은 최근 몇 년간 빠르게 성장하며 주요 식품 소비 트렌드로 자리잡고 있다. 1인 가구와 맞벌이 가정 증가, 건강하고 간편한 식사에 대한 수요가 늘어나면서 밀키트 시장은 꾸준히 확대되고 있다¹⁾. 국내 밀키트 시장은 2020년 이후 급성장하고 있으며, 최근 한식, 양식, 아시아 음식, 프리미엄 요리까지 다양한 메뉴가 포함된 밀키트가 출시되고 있다. 밀키트는 대형마트, 편의점뿐만 아니라 온라인 유통 플랫폼을 통해 쉽게 구매가 가능하게 됨에 따

라 빠르고 간편하게 밀키트를 구매할 수 있어 소비자 접근성이 높아졌다²⁾.

신선한 재료가 포함된 밀키트의 특성상 제조 및 유통 과정에서 온도관리와 신선도 유지가 중요하다. 이를 위해 콜드체인 시스템 강화를 통한 품질 관리를 고도화하고 있다³⁾. 최근, 밀키트의 수요가 증가함에 따라 대량생산 시스템과 자동화의 도입을 통해 생산의 효율성을 높이고 있으나, 이에 따라 제품의 평균 가격이 높아지는 문제점으로 인하여 중장기적 소비자 확대를 위한 공급망 효율화와 자동화 비용 절감 등에 대한 연구가 필요하다⁴⁾. 또한, 프리미엄 밀키트 등 다양한 개별 제품이 포함된 밀키트가 출시되고 있으나, 이는 개별 제품을 각기 포장해야하는 문제점으로 인한 과도한 플라스틱 사용 등 환경적 문제가 발생하고 있으며, 이를 위한 친환경적 포장재 또는 재활용 가능한 종이 포장 등에 대한 방법에 대한 연구가 수행되고 있다⁵⁻⁶⁾.

*Corresponding Author: Ah-Na Kim
Smart Manufacturing Research Group, Korea Food Research Institute, Wanju 55365, Jeonbuk-do, Republic of Korea
Tel: +82-63-219-9494
E-mail: kimahna@kfri.re.kr

국내 밀키트 제품은 크게 상온, 냉장, 냉동 유통으로 구분되며, 각 유통 방법에 따라 포장 형태, 기법, 재질이 다양하며, 제품의 신선도 연장, 살균 여부, 가열 여부, 원재료 또는 식품 특성을 고려하여 선정된다⁷⁾. 예를 들어, 생육, 육 제품, 치즈 등과 같이 탈기 후에도 형태 유지성이 좋은 식품의 경우 진공포장을 적용하지만, 형태가 불균일하거나 분말 제품 또는 빵류와 같은 제품은 진공 포장 방법이 부적절하다. 한편, 채소, 과일 및 곡류 등의 밀키트 제품의 경우 신선도를 유지하기 위해서 산소 농도가 1~5% 정도 유지되어야 하므로 가스치환 포장 방법이 유리하다⁸⁾.

밀키트 포장 방법 외에도 포장 재질에 대한 고려도 필수적이다. 밀키트 포장 재질은 제품의 특성과 구성, 포장 기법, 유통 방법, 포장 자동화 방법 등으로 인하여 다양한 재질을 활용한다. 밀키트 구성품이 면류일 때 유통 또는 포장 과정에서 파손 방지를 위하여 트레이를 사용하며, HIPS 재질의 경우 성형성과 강도적인 측면에서 PP 재질 대비 우수하지만, 냉동 상태에서는 파손이 되기 쉬운 특성이 있어 상온 유통용 밀키트에 적용된다⁹⁾. 또한, 조리 과정 후 레트로트 살균 또는 열탕 살균에 따라 PET 또는 NY 재질의 외포장을 진행한다¹⁰⁾.

이러한 문제점들을 개선하기 위하여 밀키트 제품에 대한 포장 방식, 주요 소재, 형태 등을 고려한 포장 규격화 또는 표준화를 위한 방법론 개발이 필수적이다. 또한, 새롭게 개발하는 밀키트에 대한 포장 방법, 형태, 재질 등에 대한 정보가 부족하고, 과포장 등을 방지하기 위하여 포장 방식을 추천 할 수 있는 시스템 구축이 시급하다¹¹⁾.

최근 식품 및 포장 산업에서는 복잡한 제품 특성과 다변화된 포장 조건을 효율적으로 분류·판별하기 위하여 인공지능 기반 분석 기법의 적용이 확대되고 있다. 특히, 컴퓨터 비전과 딥러닝 기술은 식품 포장재의 외형, 재질 특성, 구조적 차이를 학습하여 자동 분류 및 선별에 활용되고 있으며, 이는 기존의 규칙 기반 또는 수작업 분류 방식의 한계를 보완할 수 있는 대안으로 보고되고 있다¹²⁾. 또한, 다층 구조를 갖는 플라스틱 포장재나 오염도가 상이한 포장재를 대상으로 한 연구에서도 인공지능 모델을 활용한 재질 판별의 가능성이 제시되고 있다¹³⁾. 최근에는 영상 정보 뿐만 아니라 센서 데이터와 결합한 인공지능 기반 분류 시스템이 제안되며, 포장 자동화 및 표준화 공정에서의 적용 가능성이 확대되고 있다¹⁴⁾. 그러나 기존 연구들은 주로 단일 포장재 또는 폐기물 분류를 중심으로 수행되어, 다양한 유통 조건과 조리 특성을 동시에 고려해야 하는 밀키트 제품에 대한 포장 방법 및 포장 재질 판별 연구는 여전히 제한적인 실정이다.

이를 위해 본 연구에서는 밀키트의 개별 제품에 대한 원물 형태, 유통 방법, 포장 방법, 조리 방법 등에 대한 제품 분석을 통하여 밀키트 및 개별 구성품에 대한 인공지능 기

반 포장 방법 및 포장 재질을 판별 시스템을 개발하였다.

재료 및 방법

1. 실험 재료

국내 판매 중인 밀키트 제품 중 냉장, 냉동 그리고 실온 유통 보관인 51종의 밀키트 제품을 구매하여, 해당 제품에 대한 최종 제품 및 내부의 개별 제품 포장 방법, 포장 재질 등에 대한 분석을 수행하였다.

2. 밀키트 제품 분석을 위한 파라미터 정의

판매 중인 최종 밀키트 제품에 대한 규격 (무게, 크기), 포장 방법, 포장 재질, 인분, 유통 기한, 유통 형태, 금액, 포장의 인쇄도, 포장 기법, 품목 개수, 제품 형태, 품질 유지 제품 여부 등 총 19가지의 파라미터를 분석한 후, 최종 밀키트 제품 내 포함되어 있는 개별 제품들에 대하여 동일한 파라미터를 분석하였다. 본 연구에서 분석한 파라미터는 Table 1에 나타나 있다.

각 분석 파라미터에는 여러 변수들이 포함되어 있는데, 예를 들어 조리 여부 파라미터의 경우, 최종 밀키트 제품이 조리가 된 상태에서 판매되는지 또는 구매자가 밀키트 제품을 직접 조리해야 하는지 여부를 분석하였다. 또한, 포장 방법 파라미터의 경우 총 9가지의 타입으로 분류되었는데, 진공 포장, 스탠딩 파우치, 필로우 포장, 셀링, 폼필셀타입, 로켓/가제트 포장, 열수축, 이지필, 트레이 그리고 슬리브 포장 방법으로 구성되어 있었다. Tabel 2에서 정리한 바와



B사 밀키트 제품



Fig. 1. Example of Meal-kit sample for packaging analysis.

Table 1. Parameters for analysis of meal-kit packaging

Parameter for analysis of meal-kit packaging		
Cooked or not (Ex: Not cooked)	Meal-kit distribution method (Ex: cold chain)	Inner or Outer packaging (EX:Inner packaging)
Final or individual product (Ex: Final meal kit)	Number of individual product (Ex: 4ea)	Weight (Ex: 300g)
Packaging method (Ex: Vacuum sealing)	Types of meal-kit (Ex: sauce)	Packaging printing (Ex: 3)
Packaging technique (Ex: Standing pouch)	Number of each products (Ex: 4ea)	Quality maintenance product (Ex: Antioxidants)
Packaging components (Ex: Vinly)	Size (Ex: 90×150mm)	Price (Ex: 9800won)
Packaging materials (Ex: OPP)	Serving size (Ex: 2)	Shelf life (Ex: 6 months)
Number of outer packaging		

Table 2. Types of meal-kit materials

Types of meal-kit packaging materials		
Oriented/Cast Polypropylene	Oriented/Cast Nylon	Low-density/High-density Polyethylene
Polyethylene terephthalate/Aluminum film	Polyethylene terephthalate film	Aluminum tray
SC Molded Pulp/Kraft paper	Polyethylene terephthalate tray	Polypropylene tray

같이 포장 재질의 경우 8가지 재질들로 나타났으며, OPP, NY, LDPE/HDPE, AL, PP, PET, SC 등으로 나타났다.

2.3. 인공지능 기반 밀키트 포장 재질 및 방법 분류 모델

2.3.1. 밀키트 분석 파라미터 이산화/카테고리화

이산화란 연속적인 것을 연속적인 변수나 데이터를 여러

개의 범주나 구간으로 나누어 표현하는 방법이다¹²⁾. 이를 위해, 분석한 19개의 파라미터들에 대하여 이산화, 카테고리화 그리고 정수 형태로 변환 과정을 수행하였다. 예를 들어, 밀키트 제품의 포장 재질은 9가지로 분석되었으며, 이를 0부터 8까지 정수로 변환하는 과정을 수행하였으며, 중량의 경우 0~10, 10~25, 25~50, 50~100, 100~250, 250~500, 500~750 그리고 750~1000g의 구간을 0에서 7까지의 정수로 변환하였다. 따라서, 본 연구에서 분석한 밀키트 제품의 19개 파라미터에 중 17개의 파라미터는 인공지능 분류 모델의 입력 변수로 활용하였으며, 2개의 파라미터 (밀키트 포장 방법 및 재질)은 인공지능 분류 모델의 출력 변수로 활용하였다 (Fig. 3).

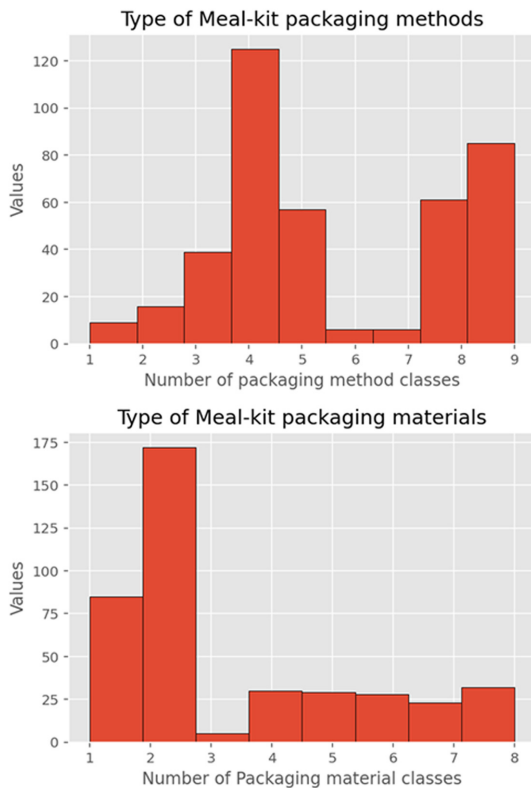


Fig. 2. Histogram of number of samples for each type of packaging materials and methods.

Input variables		Output variables
Cooked or not	Serving size	Packaging Method
Final or individual product	Inner or Outer packaging	
Packaging method	Weight	
Packaging components	Packaging printing	
Meal-kit distribution method	Quality maintenance product	Packaging Materials
Number of individual product	Price	
Types of meal-kit	Shelf life	
Number of each products	Number of outer packaging	
Size		

Fig. 3. Input and output variables for multi-output artificial neural network classification model.

2.3.2. 멀티 출력 인공신경망 분류 모델

밀키트 포장 방법 및 재질 분류를 위하여 본 연구에서는 ANN 모델을 기초 backbone으로 구성하였다. ANN 모델의 입력 layer는 17개의 input variable로 설정하였으며, 2개의 hidden layers와 2개의 output layer로 구성하였다. 2개의 hidden layers의 unit 개수는 128개로 설정하였으며, activation 함수로는 tanh로 설정하였다. 또한, 2개의 output layer의 dense 개수는 밀키트 포장 방법 타입 개수인 9와 재질 타입 개수인 8로 설정하였으며, activation 함수로는 softmax를 적용하였다. Multi-output ANN 분류 모델에 대한 학습 성능평가는 정확도와 F1-score로 설정하였으며, 학습 epochs는 100, 초기 학습률은 0.01로 설정하였다.

2.3.3. 인공신경망 분류 모델 최적화

본 연구에서는 multi-output ANN 분류 모델의 성능 향상을 위하여 베이지안 최적화 모델을 적용하였다. 일반적인 grid search 또는 random search와 같은 알고리즘의 경우 최적화 결과 도출 시간이 오래 걸리며, 정확도가 다소 낮게 나타나는 반면, 베이지안 최적화는 사전 정보를 최적값에 탐색하여 반영하는 방법론으로 보다 효율적으로 최적값을 찾아내는 장점이 있다¹⁴⁾. 일반적으로 인공신경망의 layer 또는 뉴런의 개수, 학습률 등이 영향을 미친다고 보고되어 있다. 따라서, 분류 모델의 성능 향상을 위하여 총 5가지의 hyperparameter를 설정하였으며, 설정된 hyperparameter와 최적화 design variable의 범위는 표 3에 나타나 있다. 본 연구에서 최적화의 목적 함수는 두 개의 밀키트 제품 포장 방법과 재질을 동시에 분류하여야 하는 인공신경망 모델로 구축되어 있기에 두 개의 출력 loss 값을 합산한 final loss 값을 최소화할 수 있도록 커스텀 함수를 구현하였다.

2.3.4. 다중 출력 인공신경망 분류 모델 성능 평가 방법

본 연구에서 분석한 최종 및 개별 밀키트 제품의 포장 분석 데이터는 총 404개이며, 밀키트 제품의 포장 방법과 재질을 동시에 분류하는 Multi-output ANN 모델의 분류 성능을 평가하기 위하여 학습(training), 검증(validation), 평가(test) 세트를 75%, 12.5%, 12.5%로 구분하였다. 추가적으로 학습, 검증, 평가 데이터셋에 모든 포장 방법과 재질

의 분류 class가 포함되도록 stratify기법을 적용하였다. Multi-output ANN 분류 모델과 분류 모델의 성능 향상을 위한 최적화를 위하여 Python 3.9 version, tensorflow 2.10 프로그램을 활용하였으며, Intel(R) Core(TM) i7-10700 (2.90 GHz), DDR4(128 GB) RAM, GPU인 Nvidia A4000 GPU(32 GB)를 사용하였다.

결과 및 고찰

1. 밀키트 제품 포장 방법 및 재질 분류 결과

본 연구에서는 밀키트 제품들의 포장 방법 및 포장지의 재질을 자동으로 분석하기 위한 방법으로 인공지능 모델을 적용하였다. 보다 자세하게는 포장 방법과 포장지의 재질을 동시에 분류하기 위하여 인공신경망의 architecture를 재구성하였다. 구축한 다중 출력 인공신경망으로부터 학습 및 검증을 통하여 아래 표와 같은 성능을 도출하였다. 그 결과 밀키트의 포장 방법의 분류 정확도는 약 70.3%로 나타났으며, F1-score의 경우 58.6%로 낮게 나타났다 (Table 4). 그림 4A에서의 confusion matrix에서 나타난 바와 같이 포장 방법 분류 결과의 경우 3번 class인 쉘링 포장 방법이 가장 오분류가 많이 나타났으며, 진공 포장 방법(Class 0)의 경우 검증 데이터셋에서 진공 포장 방법을 분류하지 못하였다. 이로 인하여 재현율과 정밀도가 낮게 나타났다.

추가적으로, 밀키트의 포장 재질에 대한 다중 출력 인공신경망의 분류 정확도는 약 80.2%로 포장 방법의 분류 결과보다는 높게 나타났으며, F1-score의 경우 64.1%로 나타났다 (Table 5). 그림 4B에서의 confusion matrix에서 나타난 바와 같이 포장 재질 분류 결과 NY class가 오분류율이 높게 나타났으며, LYPE/HDPE (Class 2)에 대한 분류는 0으로 나타났다. 이는 학습 및 검증 데이터 셋의 수가 부족하여 분류율이 낮게 나타난 것으로 파악된다¹⁵⁾.

2. 다중 출력 인공신경망 구조 최적화 결과

본 연구에서 다중 출력 인공신경망 분류 모델의 성능을 향상 시키기 위한 방법으로 베이지안 최적화 모델을 적용하였으며, 이를 위해 설정한 각 5가지의 design variables의 최적 값은 1024(number of neurons), 0.01(학습률), tanh(activation function), 1(neuron division rate) 그리고 sgd

Table 3. List of multi-output artificial neural network optimization design variables

Multi-output artificial neural network hyperparameters	
Number of neurons	[256, 1024, step : 128]
Learning rates	[0.01, 0.001, 0.0001]
Activation functions	['relu', 'tanh', 'sigmoid']
Neuron division	[1, 2, 4]
Optimizer	['adam', 'sgd']

Table 4. Representative classification result of meal-kit packaging method

	Before Optimization	After Optimization
Accuracy (%)	70.3 ± 0.1	85.8 ± 0.1
Recall (%)	62.1 ± 0.2	87.1 ± 0.1
Precision (%)	55.4 ± 0.1	81.9 ± 0.2
F1-score (%)	58.6 ± 0.1	84.4 ± 0.1

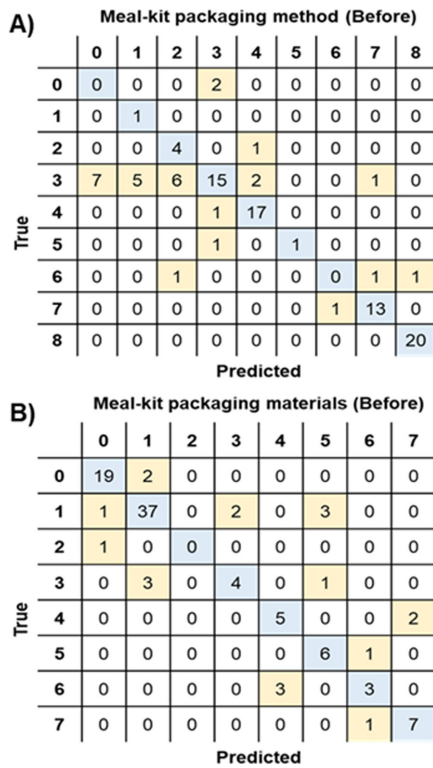


Fig. 4. Representative confusion matrix for classification result of meal-kit packaging (A) method and (B) materials before optimization

(optimizer)로 선정되었다. 도출된 최적 값을 바탕으로 인공 신경망을 재학습한 결과 최적화를 진행하기 전보다 포장 방법 분류의 정확도, 재현율, 정밀도 그리고 F1-score가 각각 22%, 40%, 48% 그리고 44% 향상되었음을 확인하였다 (Table 4). 추가적으로, 밀키트의 포장 재질의 분류 정확도, 재현율, 정밀도 그리고 F1-score가 17%, 39%, 44% 그리고 42% 향상되었다 (Table 5). 이는, 그림 5의 confusion matrix에서 나타난 바와 같이, 모든 class에 대한 오분류가 없어졌기에, 재현율, 정밀도가 크게 향상되었다. 이러한 개선은 베이지안 최적화가 단순 탐색 기반 알고리즘(grid search, random search)에 비해 탐색 공간의 효율적 축소 및 사전 확률(prior) 기반의 최적화 경로 선택이 가능하기 때문으로 분석된다¹⁷⁾. 베이지안 최적화 모델을 적용하여 다중 출력 인공신경망의 구조의 변화는 아래 그림 6에서 나

Table 5. Representative classification result of meal-kit packaging materials

	Before Optimization	After Optimization
Accuracy (%)	80.2 ± 0.1	93.9 ± 0.1
Recall (%)	65.1 ± 0.1	90.9 ± 0.2
Precision (%)	63.2 ± 0.1	90.9 ± 0.1
F1-score (%)	64.1 ± 0.1	90.9 ± 0.1

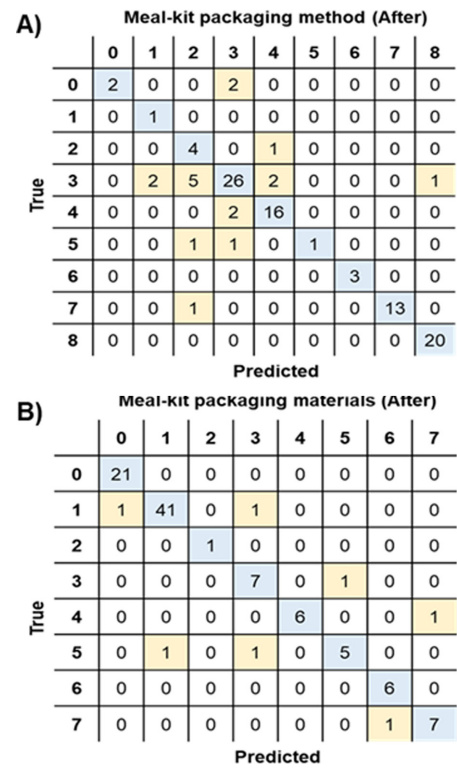


Fig. 5. Representative confusion matrix for classification result of meal-kit packaging (A) method and (B) materials after optimization

타난 바와 같이, hidden layer의 개수가 2개에서 4개로 증가하였으며, hidden layer의 neuron 개수도 256에서 1,024개로 증가하였다. 즉, 모델의 표현력(capacity)이 향상되었고, 결과적으로 클래스 간 결정 경계(decision boundary)의 명확성이 개선된 것으로 판단된다¹⁸⁾. 따라서, 인공지능 기반 포장 방법-재질 판별 모델의 성능은 데이터 수의 확충뿐 아니라, 하이퍼파라미터 최적화 접근법을 적용함으로써 효과적으로 개선될 수 있음을 확인하였다.

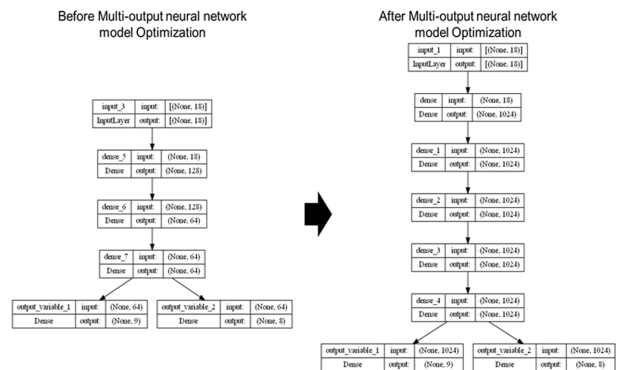


Fig. 6. Multi-output artificial neural network architecture for before and after optimization process.

요 약

국내 밀키트 산업은 1인 가구와 맞벌이 증가, 간편하면서 건강하고 맛있는 식사에 대한 수요 확대를 기반으로 2020년 이후 빠르게 성장함에 따라 대량생산 및 자동화 시스템 도입이 시급하지만, 다양한 제품화로 인한 개별 포장 증가 등으로 인한 플라스틱 사용 등 환경적 문제 등이 유발되고 있다. 밀키트 제품의 특성 상 상온, 냉장, 냉동 유통 방식으로 구분되며, 이에 따른 다양한 포장 기법 그리고 포장 재질이 활용되고 있으며, 추가적으로 제품의 형태, 조리 및 살균 방식 등에 영향을 받는다. 본 연구에서는 51종의 밀키트 제품 및 개별 제품들에 대한 제품 분석을 통하여 포장 방법, 재질 등에 대하여 파라미터화를 실시하였으나, 향후 연구에서는 다양한 상용 밀키트 제품들을 추가적으로 분석하여 데이터 수의 불균일성 등에 대한 보완 및 고도화된 인공지능 모델을 적용함으로써 포장 방법 및 재질 분류 모델의 성능을 향상시키기 위한 추가 연구가 필요할 것으로 사료된다. 향후 밀키트 산업의 지속적인 성장을 위해서는 과포장, 일관성이 없는 포장 규격, 품질에 영향을 야기하는 포장 방법 등에 대한 문제점 개선을 위하여 재사용 여부, 포장 규격화 및 표준화가 필요하며, 이에 대한 사전 연구로 인공지능을 활용한 포장 방법 및 재질 판별 시스템 개발하였고, 이를 통해 효율적이고 친환경적인 산업 생태계 구축이 가능할 것으로 기대된다.

감사의 글

본 연구는 산업통상자원부(한국산업기술기획평가원) 로봇산업기술개발(RS-2024-00508387)과 농림축산식품부(농림식품기술기획평가원) 고부가가치식품기술개발사업(RS-2024-00413186)의 지원을 받아 수행된 연구결과입니다.

참고문헌

1. Yoon, S., Gao, Z., and House, L. 2022. Do efforts to reduce packaging waste impact preferences for meal kits? *Food Qual. Prefer.*, 96: 104410.
2. Romagnoli, F., Salimbeni, A., and Neri, E. 2019. Comparison of life cycle environmental impacts from meal kits and grocery store meals. *Resour. Conserv. Recycl.*, 147: 189-200.
3. Heard, B.R., Bandekar, M., Vassar, B., and Miller, S.A. 2019. Comparison of life cycle environmental impacts from meal kits and grocery store meals. *Resour. Conserv. Recycl.*, 147: 189-200.
4. Kim, T.H., Gu, B.I., Kwon, K.H., and Kim, A.N. 2025. A framework for 3D plant simulation of meal-kit-packaging robot automation system. *Appl. Sci.*, 15(8): 4116.
5. Hussain, S., Akhter, R., and Makedar, S.S. 2024. Advancements in sustainable food packaging: from eco-friendly materials to innovative technologies. *Sustain. Food Technol.*, 2: 1297-1364.
6. Kan, M., and Miller, S.A. 2022. Environmental impacts of plastic packaging of food products. *Resour. Conserv. Recycl.*, 180: 106156.
7. Hemachandra, S., Hadjikakou, M., and Pettigrew, S. 2024. A scoping review of food packaging life cycle assessments that account for packaging-related food waste. *Int. J. Life Cycle Assess.*, 29(10): 1899-1915.
8. Robertson, G.L. 2016. *Food Packaging: Principles and Practice*. CRC Press, Boca Raton, USA.
9. Marsh, K. and Bugusu, B. 2007. Food packaging—Roles, materials, and environmental issues. *J. Food Sci.*, 72(3): R39-R55.
10. Niaounakis, M. 2015. *Biopolymers: Applications and Trends*. William Andrew/Elsevier, Oxford, UK.
11. Grunert, K.G. 2011. Sustainability in the food sector: A consumer behaviour perspective. *Int. J. Food Syst. Dyn.*, 2(3): 1-12.
12. McShane, B.B., Preacher, K.J., and Rucker, D.D. 2015. A researcher's guide to regression, discretization, and median splits of continuous variables. *J. Consum. Psychol.*, 25(4): 666-678.
13. Lu, W., and Chen, J. 2022. Computer vision for solid waste sorting: A critical review of academic research. *Waste Manag.*, 142: 29-43.
14. Pučnik, R., Dokl, M., Fan, Y.V., Varbanov, P.S., and Klemeš, J.J. 2024. A waste separation system based on sensor technology and deep learning: A simple approach applied to a case study of plastic packaging waste. *J. Clean. Prod.*, 450: 141762.
15. Mittal, G., Yagnik, K.B., Garg, M., and Krishnan, N.C. 2016. SpotGarbage: Smartphone app to detect garbage using deep learning. *Proc. ACM Int. Joint Conf. Pervasive Ubiquitous Comput.*, 2016: 940-945.
16. Bischl, B., Binder, M., Lang, M., Pielok, T., Richter, J., Coors, S., Thomas, J., Ullmann, T., Becker, M., Boulesteix, A-L., Deng, D., and Lindauer, M. 2021. Hyperparameter Optimization: Foundations, Algorithms, Best Practices and Open Challenges. *WIREs Data Mining Knowl. Discover.*, 13(2): e1484.
17. Martinez-Hernandez, U., West, G., and Assaf, T. 2024. Low-cost recognition of plastic waste using deep learning and a multi-spectral NIR sensor. *Sensors*, 24(9): 2821.
18. Snoek, J., Larochelle, H., and Adams, R.P. 2012. Practical Bayesian optimization of machine learning algorithms. *Adv. Neural Inf. Process. Syst.*, 25: 2951-2959.
19. Goodfellow, I., Bengio, Y., Courville, A., and Bengio, Y. 2016. *Deep Learning*. MIT Press, Cambridge, USA.

투고: 2025.11.10 / 심사완료: 2025.12.10 / 게재확정: 2025.12.29