



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

2023년 2월  
박사학위논문

서류 가공식품의  
품질 예측과 최적화를  
위한 근적외선 분광법  
및 다변수 분석

조선대학교 대학원

화학공학과

김 다 송

서류 가공식품의  
품질 예측과 최적화를  
위한 근적외선 분광법  
및 다변수 분석

**Near Infrared Spectroscopy and Multi-variable  
Analysis for Quality Prediction and Optimization  
of processed Potatoes and Sweet Potatoes**

2023년 2월 24일

조선대학교 대학원

화학공학과

김 다 송

서류 가공식품의  
품질 예측과 최적화를  
위한 근적외선 분광법  
및 다변수 분석

지도교수 신 현 재

이 논문을 공학 박사학위신청 논문으로 제출함

2 0 2 2 년 1 0 월

조선대학교 대학원

화학공학과

김 다 송

## 김다송의 박사학위논문을 인준함

위원장 조선대학교 교수 이중현 (인)

위원 조선대학교 교수 이재욱 (인)

위원 조선대학교 교수 최동유 (인)

위원 충남대학교 교수 조병관 (인)

위원 조선대학교 교수 신현재 (인)

2 0 2 3 년 1 월

조선대학교 대학원

## Contents

List of Tables .....	V
List of Figures .....	VI
ABSTRACT .....	XII
제1장 서론 .....	1
제1절 연구의 배경 .....	1
1. 서류에 대한 일반 고찰 .....	4
2. 비파괴 분광기술 및 품질 예측 .....	7
3. 알고리즘 및 인공지능을 활용한 품질 예측 .....	15
4. 다변수 분석 .....	22
5. 최적화 .....	28
6. 장내 미생물 .....	30
제2절 연구의 목적 .....	33

제2장 고구마 내부 품질 예측을 위한 근적외선 분광 법 및 다변수 분석 .....	35
제1절 서론 .....	35
제2절 재료 및 방법 .....	37
1. 고구마 .....	37
2. 저장기간동안 품질 특성 변화 측정 .....	37
3. 비파괴 기술을 이용한 품질 특성 측정 .....	39
제3절 실험결과 및 토의 .....	44
1. 저장기간동안 품질 특성 변화 측정 .....	44
2. 비파괴 기술을 이용한 품질 특성 측정 .....	48
제4절 요약 .....	64
제3장 <b>Response Surface Methodology</b> 및 <b>Artificial     Neural Network Model</b> 을 이용한 <b>pilot-scale</b> 의 감압후라이드 고구마칩 제조 공정 최적화 ..	65
제1절 서론 .....	65
제2절 재료 및 방법 .....	67
1. 재료 .....	67
2. 감압후라이드 고구마칩 제조 공정 .....	67
3. 제조 공정 최적화 .....	72

4. <b>Microstructure analysis</b> .....	75
5. 통계 .....	75
제3절 실험결과 및 토의 .....	76
1. 감압후라이드 고구마칩 제조 공정 .....	76
2. 제조 공정 최적화 .....	79
3. <b>Microstructure analysis</b> .....	94
제4절 요약 .....	98
제4장 <b>Metagenome 분석 및 mouse 모델을 이용한 감</b> <b>자튀김 식단이 장내 미생물에 미치는 영향</b>	<b>99</b>
제1절 서론 .....	99
제2절 재료 및 방법 .....	102
1. 재료 .....	102
2. <b>Frying 및 toxic compounds 분석</b> .....	102
3. 동물실험 .....	105
4. 통계 .....	110
제3절 실험결과 및 토의 .....	111
1. <b>Frying 및 toxic compounds 분석</b> .....	111
2. 동물실험 .....	117
제4절 요약 .....	128



**제5장 결론** ..... **129**

**References** ..... **132**

## List of Tables

Table 1. Nutritional composition of sweet potato and potato .....	6
Table 2. Characteristics of the infrared spectroscopy .....	13
Table 3. The specifications of the NIR spectrometer used for non-destructive measurement of sweet potato .....	40
Table 4. Changes in internal quality in terms of moisture, starch, and $\alpha$ -amylase content of sweet potatoes during storage .....	46
Table 5. Calibration, cross-validation, and prediction results of PLS model for assessing internal quality of sweet potatoes .....	55
Table 6. Central composite design and responses of dependent variables for the vacuum-fried sweet potato chip manufacturing process to independent variables .....	69
Table 7. Previous studies on sweet potato and potato chips manufactured using vacuum-frying technology .....	78
Table 8. Analysis of variance (ANOVA) for quadratic regression model of response surface methodology for vacuum fried sweet potato chip manufacturing process .....	81
Table 9. Statistical evaluation performances of the RSM and ANN models .....	91
Table 10. Optimized quality of vacuum-fried sweet potato chips using RSM and ANN-GA methods .....	93
Table 11. Analyzed fatty acid composition (% total fatty acids) in CD, CV, PD, and PV .....	112
Table 12. Analyzed polycyclic aromatic hydrocarbons (PAH) in CD, CV, PD, and PV	116

## List of Figures

Figure 1. Classification of sugar content in agricultural products using NIR; (A) Watermelon, (B) Melon, (C) Apple, (D) Korean melon. ....	9
Figure 2. Scheme of dielectric loss factor ( $\epsilon''$ ) for wavelength and frequency. ....	10
Figure 3. The NIR spectrometer using (A) at-line (Diode Array 7250, PerkinElmer), on-line or in-line ((B) Hansung engineering, (C) NIR-Online X-sENTIAL, B uchi). ....	14
Figure 4. (A) Classification of artificial intelligence and (B) prediction model development process using machine learning. ....	16
Figure 5. Traditional data analysis and artificial intelligence data analysis. ....	18
Figure 6. Characteristics of big data. ....	19
Figure 7. Convergence and application of artificial intelligence and big data technology. ....	20
Figure 8. Classification of artificial intelligences' Application for algorithm level and data level. ....	21
Figure 9. Classification of multivariable and multivariate methods. ....	23
Figure 10. Setting of (A) laboratory experimental device and (B) industrial device for measuring NIR spectra of sweet potato. 1, NIR light source; 2, sweet potato (sample); 3, sample holder; 4, detector; and 5, conveyor belt. ....	41
Figure 11. Schematic of NIR spectrum analysis applied to develop the prediction model using classification and regression of the internal quality of sweet potatoes. ....	43
Figure 12. Changes in internal quality in terms of (A) moisture, (B) starch, and (C)	

$\alpha$ -amylase content of sweet potatoes during storage (Letters indicate significant differences,  $p < 0.05$ ). ..... 45

Figure 13. (A) Cross-section of baked sweet potato completely decomposed by amylase, and (B) cross-section of baked sweet potato with starch, owing to incomplete starch degradation. .... 47

Figure 14. (A) NIR raw spectrum. Preprocessed spectrum captured through (B) S-G, (C) SNV, and (D) MSC for the sweet potatoes. .... 49

Figure 15. NIR raw spectrum of sweet potatoes with low moisture content (Legend shows moisture content of sweet potatoes). .... 50

Figure 16. Linear discriminant analysis results for internal quality of sweet potatoes based on moisture ((A) analysis by raw spectrum and (B) S-G preprocessed spectrum) and starch content ((C) analysis based on raw spectrum and (D) SNV preprocessed spectrum). .... 52

Figure 17. (A) Regression plot and (B) regression coefficient plot of partial least squares (PLS) modeling about calibration and prediction set for raw spectrum and moisture content of sweet potatoes. .... 56

Figure 18. Regression plot and (B) regression coefficient plot of PLS modeling about calibration and prediction set for raw spectrum and starch content of sweet potatoes. .... 57

Figure 19. (A) Regression plot and (B) regression coefficient plot of PLS modeling about calibration and prediction set for Savitzky-Golay (S-G) preprocessed spectrum and moisture content of sweet potatoes. .... 58

Figure 20. (A) Regression plot and (B) regression coefficient plot of PLS modeling about calibration and prediction set for S-G preprocessed spectrum and starch content of sweet potatoes. .... 59

Figure 21. (A) Regression plot and (B) regression coefficient plot of PLS modeling a  
 bout calibration and prediction set for standard normal variate (SNV) prep  
 rocessed spectrum and moisture content of sweet potatoes. .... 60

Figure 22. (A) Regression plot and (B) regression coefficient plot of PLS modeling a  
 bout calibration and prediction set for SNV preprocessed spectrum and sta  
 rch content of sweet potatoes. .... 61

Figure 23. (A) Regression plot and (B) regression coefficient plot of PLS modeling a  
 bout calibration and prediction set for multiplicative scattering correction  
 (MSC) preprocessed spectrum and moisture content of sweet potatoes. .. 62

Figure 24. (A) Regression plot and (B) regression coefficient plot of PLS modeling a  
 bout calibration and prediction set for MSC preprocessed spectrum and st  
 arch content of sweet potatoes. .... 63

Figure 25. Vacuum frying machine used in the experiment. (B) An overview of predi  
 cting and optimizing the vacuum-frying process for sweet potato chip man  
 ufacturing using response surface methodology and an artificial neural net  
 work model. .... 70

Figure 26. ANN structure for vacuum-fried sweet potato chip manufacturing process.  
 $X_1$ , osmotic dehydration (OD) concentration (%);  $X_2$ , OD temperature ( $^{\circ}$   
 $C$ );  $X_3$ , vacuum frying temperature ( $^{\circ}$  $C$ ); (A)  $Y_1$ , yield (%); (B)  $Y_2$ , oil c  
 ontent (%); (C)  $Y_3$ , browning index. .... 73

Figure 27. Response surface graphs of (A, B, C) yield, (D, E, F) oil content, and  
 (G, H, I) browning index of vacuum-fried sweet potato chips as affected  
 by osmotic dehydration (OD) concentration, OD temperature, and vacuum  
 frying temperature. .... 83

Figure 28. Performance plot for mean square error (MSE) value for the ANN model  
 of (A) yield, (B) oil content, and (C) browning index. .... 85

Figure 29. Regression plots for (A) training, (B) validation, and (C) testing of the ANN model for yield. .... 86

Figure 30. Regression plots for (A) training, (B) validation, and (C) testing of the ANN model for oil content. .... 87

Figure 31. Regression plots for (A) training, (B) validation, and (C) testing of the ANN model for browning index. .... 88

Figure 32. Appearance of (A) sliced and (B) osmotically dehydrated raw sweet potato. Appearance of fried sweet potato chips after (C) deep frying, (D) deep frying with osmotic dehydration, (E) vacuum frying, and (F) vacuum frying with osmotic dehydration. .... 95

Figure 33. SEM images of (A) sliced and (B) osmotically dehydrated raw sweet potatoes. SEM images of fried sweet potato chips after (C) deep frying, (D) deep frying with osmotic dehydration, (E) vacuum frying, and (F) vacuum frying with osmotic dehydration. .... 96

Figure 34. Texture (hardness) of fried sweet potato chips after deep frying (D), deep frying with osmotic dehydration (DO), vacuum frying (V), and vacuum frying with osmotic dehydration (VO). .... 97

Figure 35. Schematic illustration of experimental design and samples. After 1 week adaptation, 32 mice were divided randomly into four groups: the normal group was fed a standard chow diet (control, n=8) and the experimental group with a high-fat and high fructose diet (HFD, n=8), deep fried potatoes using palm oil (PD, n=8) and vacuum fried potatoes using canola oil (CV, n=8). .... 106

Figure 36. Analyzed acrylamide in CD, CV, PD, and PV. The data are presented as the mean  $\pm$  SD, and compared using analysis of variance (ANOVA) followed by Tukey test. The different letters are indicated statistically different

	ces within the fried potatoes' samples (CD, CV, PD, PV). .....	114
Figure 37.	Effect of fried potatoes on (A) body weight gain, (B) liver weight and (C) epididymal fat weight in N-fed, HF-fed, PD-fed and CV-fed mice during 12 weeks (n = 8 per group). The data are presented as the mean $\pm$ SD, and compared using analysis of variance (ANOVA) followed by Tukey test. The different letters are indicated statistically differences within the diet fed groups (N, HF, PD, CV). .....	118
Figure 38.	Concentration of cholesterol at serum and liver of N-fed, HF-fed, PD-fed and CV-fed mice. The data are presented as the mean $\pm$ SD, and compared using analysis of variance (ANOVA) followed by Tukey test. The different letters are indicated statistically differences within the diet fed groups (N, HF, PD, CV). .....	120
Figure 39.	Concentration of triglyceride at serum and liver of N-fed, HF-fed, PD-fed and CV-fed mice. The data are presented as the mean $\pm$ SD, and compared using analysis of variance (ANOVA) followed by Tukey test. The different letters are indicated statistically differences within the diet fed groups (N, HF, PD, CV). .....	121
Figure 40.	Concentration of short chain fatty acid (SCFA) which are (A) total SCFA, (B) acetate, (C) propionate, and (D) butyrate at cecum of N-fed, HF-fed, PD-fed and CV-fed mice. The data are presented as the mean $\pm$ SD, and compared using analysis of variance (ANOVA) followed by Tukey test. The different letters are indicated statistically differences within the diet fed groups (N, HF, PD, CV). .....	123
Figure 41.	Fecal microbial diversity indices of the groups. Alpha diversity was estimated with (A) OTU value and (B) Shannon index to indicate bacterial richness and diversity. Beta diversity was estimated with principal coordinates	

analysis (PCoA) plot of UniFrac distance values for (A) species level and (B) genus level. All groups of  $\alpha$  diversity indices (OTU and Shannon) data are presented as the mean  $\pm$  SD, and compared using analysis of variance (ANOVA) followed by Tuckey test. The different letters are indicated statistically differences within the diet fed groups (N, HF, PD, CV). ... 126

Figure 42. Relative abundance (%) of mice fecal microbiota at the (A) phylum, (B) class, (C) family, and (D) genus level in all groups. The level of class, family, and genus with a proportion less than 1% are indicated by other. ... 127



## ABSTRACT

# Near Infrared Spectroscopy and Multi-variable Analysis for Quality Prediction and Optimization of processed Potatoes and Sweet Potatoes

Kim, Da-Song

Advisor: Prof. Hyun-Jae Shin, Ph.D.

Department of Chemical Engineering

Graduate School of Chosun University

Recently, the interest in health increases, and consumption of well-being food is increasing. For this reason, agricultural products and processed agricultural products are in the spotlight. Even if agricultural products are of the same species, internal quality differences occur depending on the environment of cultivation and storage. Therefore, it is necessary to predict the quality of raw materials and optimize the processing process when manufacturing processed foods for agricultural products. In this study, the following three subjects were studied for quality prediction and optimization of potatoes and sweet potatoes and their processed foods.

Firstly, a non-destructive NIR measurement technology for measuring the internal quality of raw sweet potatoes was developed. In this study, the changes in the moisture, starch, and  $\alpha$ -amylase contents were measured for eight weeks after harvest. Using nondestructive near-infrared analyses and chemometric models, the moisture and starch contents were predicted. The partial least squares (PLS) method was used for prediction, while linear discriminant analysis (LDA) was used for discrimination. To increase the accuracy of the model, the near-infrared spectrum was preprocessed using the

Savitzky-Golay derivative (S-G), standard normal variate (SNV), and multiplicative scattering correction (MSC) methods. When applying PLS to the moisture content, the best calibration model accuracy was obtained using the S-G preprocessed spectrum. Furthermore, the best calibration model accuracy for starch content was obtained using the SNV-preprocessed spectrum. The moisture and starch contents were categorized into five classes for LDA, with results indicating that the internal quality of sweet potatoes can be predicted and classified using chemometric models through nondestructive detection.

Secondly, food manufacturing processes are affected by various variables; this is why multi-variable statistical methods are used to predict and optimize food quality. In this study, product yield and quality optimization of a sweet potato chip manufacturing process was performed in a pilot-scale industrial fryer using vacuum frying (VF) technology. Model performance was compared using response surface methodology (RSM) and artificial neural network (ANN) models. Three independent variables, osmotic dehydration (OD) concentration, OD temperature, and vacuum frying temperature, were designed to predict the model product yield (%), oil content (%), and browning index (BI). The experiment was designed using a central composite design (CCD), and both RSM and ANN models were found to be statistically reliable as the basis of modeling the experimental values. However, the ANN model had a higher predictive performance than the RSM. Although there are many unpredictable variables in the process, the quality could be predicted and optimized using RSM and ANN models.

Thirdly, fried foods contain nutrients, antioxidants, and lipids that could be quickly processed in the body. By eating fried foods, human could maintain health, but toxic compounds could be generated depending on the frying oil, conditions, and raw materials. In this study, the contents of toxic compounds in fried potatoes according to frying oil (canola, palm) and frying method (atmospheric (deep) pressure, vacuum pressure) were compared. The changes in biochemical parameters and gut microbiota were studied during fried potatoes' diet using metagenomic analysis and mouse model. Using canola oil, the frying samples of deep and vacuum pressure were called CD and CV. Using palm oil, the frying samples of deep and vacuum pressure were called PD and

PV. By comparing the content of toxic compounds which are trans fatty acid, acrylamide, and polycyclic aromatic hydrocarbon (PAH) in the four samples, the effects on mice was confirmed by selecting PD and CV. As a result of the fried potatoes' diet in mice, the weight increased. Cholesterol and triglyceride contents of serum and liver were not significantly different from those of the N group during the PD and CV diets. The total short chain fatty acid (SCFA) content of cecal was statistically similar to that of the N group in the PD and CV groups. In the microbial diversity indices and microbiota compositions of fecal, N and PD were classified into similar groups, and CV was similar to that of the HF group. The *Firmicutes* (F)/*Bacteroidetes* (B) ratio, which is known to have a positive correlation with obesity, increased CV and decreased PD compared to N. The abundance of *Erysipelotrichi*, which was positively correlated with the induction of fatty liver, was very high in the CV intake group. Therefore, in this study, the fried potatoes' diet had an effect on the gut microbiota. The negative health effects of the PD and CV diets were lower than those of HF, and the negative effects of CV on health were higher than those of PD. In addition, the toxic compounds generation and the effect on the gut microbiota were different depending on the frying oil and frying method.

Recently, because of the development of various analysis methods, the limit of detection for toxic compounds is lowered, or the development of sensitive analysis conditions is required. It is required to develop new approaches such as rapid quality assessment technology and predictive technology using various application fields such as chemistry, biology, spectroscopy, and data science. In this study, quality prediction and optimization of potatoes and sweet potatoes and their processed foods were performed by convergence of various fields such as near-infrared spectroscopy, non-destructive technology, multivariate analysis, chemometrics, design of experiments, RSM, ANN, and metagenomics.

# 제1장 서론

## 제1절 연구의 배경

인간은 식품 섭취를 통하여 영양소를 얻고, 에너지를 생산한다. 생명 및 신체활동을 위해서 식품 섭취는 필수적이므로 식품산업은 잠재된 경제적 가치를 가지고 있으며, 꾸준히 성장하고 있다. 한국농수산식품유통공사에 따르면 2022년 기준 세계 식품시장 규모는 약 8,428십억달러였다 [1].

영양학적으로 적절하고 안전한 식품에 대한 접근은 세계영양선언문 (World Declaration on Nutrition)에 의해 각 개인의 권리로 인정되었다 [2]. 식품산업은 단순한 섭취를 위한 소비의 개념보다 인류의 존망 및 국가 안보 등 중요한 개념을 내포하고 있다. 또한, 식품산업은 국민생활 및 건강에 직접적으로 영향을 미치는 산업으로서 원료, 품질, 안정성에 대한 정부의 규제를 받고 있다. 식품생산기술은 발전하고 있으며, 인구 증가, 환경 오염, 식품 원료 수급 등의 문제로 인하여 식량의 안정적인 수급이 각 나라의 매우 중요한 정책이 되었다.

식품 안전 및 식품 품질은 제품과 가공업자의 평판을 설명하는 중요한 요소이다 [3]. 식품 안전과 품질은 밀접하게 관련되어 있으며, 식품 매개 질병이 발생할 수 있으므로 품질 관리가 필요하다. 따라서 많은 국가의 정부는 식품 인증에 대한 관련 법률을 제정하고 있다 [4]. 또한, 식품의 안전과 품질은 한 국가의 경제 발전과 국민 생활 조건의 주요 척도이다. 많은 전문가들은 식품 안전은 식품 품질의 가장 중요한 요소라고 주장한다 [5-7]. Codex 국제식품규격위원회는 식품 안전을 식품의 의도된 용도에 따라 준비 또는 섭취할 때 소비자에게 해를 끼치지 않는다는 보증으로 정의한다 [8].

최근 웰빙 및 건강에 대한 관심이 증가하면서 식품을 ‘건강한 식품 (healthy food)’과 ‘건강하지 않은 식품 (unhealthy food)’으로 분류한다 [9]. 건강한 식품은 가공되지 않은 식품을 의미하고, 비타민, 미네랄, 항산화 성분이 풍부하게 함유되어 있다. 일반적으로 설탕과 나트륨 함량이 낮아 칼로리가 높지 않고, 영양소를 포함하고 있는 균형잡힌 식단 (balanced diet)이다. 반대로 불균형 식단 (Unbalanced diet)은 설탕, 나트륨, 지방 함량이 높지만 영양소 함량은 낮고, 인공 향료 및 유해한 화학 물질이 함유된 것을 의미한다. 건강하지 않은 식품은 junk food라고도 부르며,

가공된 식품으로서 포화지방 함량이 높다.

식품을 평가하는 분류 기준은 에너지 (energy), 맛 (taste), 기름 종류 (type of oil), 영양 가치 (nutrient value) 등이 있다 [10]. 첫 번째 분류 기준은 ‘에너지’이다. 건강한 식품은 유익한 영양소와 불포화 지방이 풍부하다. 따라서 하루 종일 포만감과 활력을 느낄 수 있도록 도와준다. 반대로, 건강하지 않은 식품은 나트륨, 설탕 및 포화 지방이 함량이 높다. 또한, 건강하지 않은 식품을 과도하게 섭취하면 위장, 두통, 심장 문제를 유발할 수 있다. 두 번째 분류 기준은 ‘맛’이며, 식품 평가 시 매우 중요한 요소이다. 일반적으로 건강한 식품은 맛있는 맛을 가지고 있다. 건강하지 않은 식품은 풍미 증강제와 같은 식품 첨가제의 사용으로 맛이 매우 좋다. 세 번째 분류 기준은 ‘기름 종류’이다. 건강한 식품에는 불포화 지방 함량 높다. 건강하지 않은 식품은 포화 지방 함량이 높고, 트랜스 지방이 포함되어 있다. 포화 지방과 트랜스 지방이 풍부한 음식을 과식하면 심혈관 질환과 같은 건강 문제가 발생할 수 있다. 네 번째 분류 기준은 ‘영양 가치’이다. 탄수화물, 단백질, 지방, 비타민, 미네랄은 필수 영양소이고, 건강한 식품은 필수 영양소를 다량 함유하고 있다. 건강하지 않은 식품은 필수 영양소 함량이 낮다.

가공식품은 농산물과 같은 원물에 식품첨가물을 첨가하여 원물을 변형하거나, 이를 혼합하여 제조·가공·포장한 식품을 의미한다 [11].

최근 건강한 식품에 대한 수요가 증가하여, 농산물 및 농산물 가공식품에 대한 관심이 증가하고 있다 [12]. 농산물은 재배환경, 수확시기 등 다양한 요인에 따라 모양, 성분 등과 같은 품질이 상이하여 품질관리가 어렵다. 농산물은 크기, 색, 상처유무 등과 같은 외형적 품질로 등급이 분류된다. 당도, 수분 함량 등과 같은 내형적 품질에 대한 등급 분류 기준은 없다. 그러나 과일의 경우 비파괴 분석을 이용하여 기준 당도 이상의 과일만 판매되기도 한다. 농산물 가공식품 품질은 원물의 내형적 품질에 영향을 많이 받는다. 따라서 원물에 대한 내형적 품질 평가가 필수적이다. 최근 화학, 컴퓨터 등의 다양한 과학기술의 발전으로 식품 품질 예측에 대한 연구가 활발하게 진행 중이다 [13].

농산물 가공식품 품질 측정 시 다음과 같은 요인이 고려되어야 한다. 첫 번째로 농산물은 재배환경, 수확시기 등 다양한 요인에 따라 모양, 성분 등과 같은 품질이 달라진다. 두 번째로 유통과정 중 변질될 수 있으므로, 보존성을 고려해야 한다. 세

번째로 식품의 영양정보 및 함량 표시가 필요하다.

식품 품질은 소비자가 수용할 수 있는 식품의 품질 특성이다. 외관 (크기, 모양, 색상, 광택, 일관성 등), 질감 및 풍미와 같은 외부 요인과 내부 (화학적, 물리적, 미생물) 요인으로 식품 품질을 분류할 수 있다. 그러나 식품 품질은 매우 일반적이고, 소비자마다 품질 기준이 다를 수 있다. 따라서 식품 품질은 객관적 특성과 주관적 특성을 가진다. 객관적 특성은 객관적으로 기술되고 측정될 수 있는 품질 특성이다. 반면에 소비자의 의견과 감상에 따라 주관적으로 정의하는 경우도 있다.

식품 산업은 전 세계적으로 큰 규모의 산업으로서, 식품 품질과 안전이 더욱더 중요해지고 있다. 식품 품질 및 안전에 대한 평가 방법을 확립하는 것은 식품산업의 제조업체, 유통업체, 소매업체, 소비자 및 국가의 이익에도 중요하다. 따라서 식품 성분 및 유해 성분 측정을 위한 효율적이고 정확한 분석 기술 개발 및 적용에 대한 요구가 크게 증가하고 있다. 하지만 기존 식품 분석은 일반적으로 비용과 노동력이 많이 소요되고, 파괴적 기술을 사용하고, 분석기기가 필요하여 실험실에서만 분석이 가능하다 [14]. 또한, 일반적으로 복잡한 과정의 시료 전처리가 필요하여 식품 제조 공정에서 실시간 및 온라인 모니터링이 어렵다.

최근 식품 분석 분야는 비파괴 기술을 사용하여, 식품 제조 공정에서 식품 품질을 실시간 및 온라인 모니터링이 가능한 방법을 개발하고 있다. 분광법, 음향법 등과 같은 기술을 적용하여 비파괴 기술을 개발하고 있다 [15].

## 1. 서류에 대한 일반 고찰

서류 (薯類, root and tuber crops)는 지하의 뿌리나 줄기에 다량의 전분과 기타 다당류를 저장하고, 식용 목적으로 재배되는 식물을 의미한다. 대표적인 서류는 고구마, 감자, 마 등이 있다 [16]. 고구마와 감자는 전분 함량이 높아, 탄수화물 대체재로서 섭취할 수 있다. 또한, 척박한 환경에서도 재배가 용이하고, 단위당 생산량이 높다. 고구마와 감자는 다른 식물 분류 체계를 가지고 있다. 고구마는 메꽃과 뿌리 채소이고, 감자는 가지과 덩이줄기이다. Table 1과 같이, 고구마 (점질, 호박고구마)와 감자 (수미)는 영양성분 함량이 다르다 [17].

고구마의 원산지는 중미의 유카탄반도와 남미 베네수엘라 오리노코강 지역이고, 우리나라에는 1973년에 경작이 시작되었다. 모든 부위 (뿌리, 줄기, 잎)가 식용 가능하고, 알칼리성 식품으로 항암, 항산화작용, 혈중 cholesterol 강화 작용 등 약리적 효능을 인정받고 있다 [18]. 고구마는 탄수화물 함량이 높고, 단백질, 지방, 식이섬유, 미네랄, 비타민 등이 골고루 들어있어 주식 대용이 가능하다. 외국에서는 고구마를 가공한 식품이 판매되고 있다. 대표적으로 일본의 고구마 소주 및 케이크가 있다.

감자의 원산지는 안데스 고지대 지역이고, 우리나라에는 1824년에 경작이 시작되었다 [19]. 감자는 뿌리만 식용 가능하고, 뛰어난 생산성과 영양학적 이점으로 식사와 간식용 식재료로 이용된다. 감자는 튀김용 냉동감자 등으로 가공된다.

2020년 기준 세계 고구마와 감자 생산량은 89,487,835 ton, 359,071,403 ton이었다. 고구마 생산량은 중국, 말라위, 탄자니아, 나이지리아 순서로 높았으며, 총 생산량의 약 55%, 8%, 5%, 4%를 차지하였다 [20]. 감자 생산량은 중국, 인도, 우크라이나, 러시아, 미국, 독일 순서로 높았으며, 총 생산량의 약 22%, 14%, 6%, 5%, 5%, 3%를 차지하였다. 대한민국의 고구마와 감자 생산량은 329,927 ton, 553,194 ton으로서, 총 생산량의 0.37%, 0.15%를 차지하였다.

캐나다, 영국, 네덜란드, 프랑스, 일본 등과 같은 선진국의 고구마 수입량이 높으며, 전 세계적으로 고구마에 대한 수요가 있다. 감자의 가공식품 수요는 지속적으로 증가하고 있다. 감자 가공식품 소비량은 미국과 유럽이 매우 높으며, 아시아는 낮은 수준이다 [21]. 소득 증가와 식단 변화에 따라 감자 가공식품 수요는 증가할 것으로 예측된다.

고구마와 감자는 영양학적으로 균형잡혀 있어 주식으로 섭취가 가능하다. 또한, 척박한 환경에서도 재배가 가능하고, 수출·입이 활발하게 이루어져 원물에 대한 접근성이 매우 높다. 식량 및 가공식품 소재로 활용이 가능하지만, 가공식품에 대한 연구 및 개발이 활발하게 이루어지지 않았다. 따라서 고구마와 감자를 활용하여 가공식품 개발 연구가 필요하다.



**Table 1. Nutritional composition of sweet potato and potato [17]**

Nutrient	(100 g)			
	Raw Sweet Potatoes	Steamed sweet potatoes	Raw Potatoes	Steamed potatoes
Energy (kcal)	141	157	70	75
Moisture (g)	63.9	59.9	81.1	79.8
Protein (g)	1.17	1.1	1.93	1.94
Fat (g)	0.2	0.15	0.03	0.05
Ash (g)	0.96	0.94	0.87	0.93
Carbohydrate (g)	33.81	37.91	16.07	17.28
Sugar (g)	9.83	14.48	0	0
Maltose (g)	9.83	11.8	0	0
Galactose (g)	0	0	0	0
Soluble dietary fiber (g)	0.8	0.9	0.5	0.3
Insoluble dietary fiber (g)	1.2	2.5	1.2	1.1
Total amino acid (mg)	1092	1021	1610	1634
Total essential amion acid (mg)	493	456	616	598
Total fatty acid (g)	0.19	0.15	0.03	0.04
Total essential fatty acid (g)	0.11	0.09	0.01	0.02
Total saturated fatty acid (g)	0.06	0.05	0.02	0.02
Ca (mg)	21	23	6	6
Fe (mg)	0.52	0.46	0.4	0.42
Mg (mg)	27	26	20	20
P (mg)	55	57	62	58
K (mg)	379	394	335	318
Na (mg)	8	5	1	0
Zn (mg)	0.2	0.21	0.38	0.41
Cu (mg)	0.111	0.108	0.134	0.143
Mn (mg)	0.469	0.433	0.142	0.159
Se (μg)	3.49	1.67	4.41	4.62
Mo (μg)	1.71	1.89	4.1	4.23
I (μg)	2.24	0.13	0	0
β-Carotene (μg)	896	553	0	0
Niacin (mg)	0.756	0.48	0.447	0.327
Vitamin C (mg)	14.49	30.62	4.47	5.8
Vitamin E (mg)	0.22	0.53	0.01	0.01
α-Tocopherol (mg)	0.22	0.53	0.01	0.01

## 2. 비파괴 분광기술 및 품질 예측

비파괴 측정은 시료의 형태나 특성을 변화시키지 않고, 품질을 측정하는 기술이다. 비파괴 측정 장치의 구성은 빛 (에너지)을 생성하여 물체에 전달하는 generator, 물체를 통과한 에너지를 수집하는 receiver, 수집한 에너지를 데이터화하는 signal processing software (computer)로 구성된다. 분석 샘플의 특성 (수분 함량, 밀도 등)에 따라서 generator의 출력량, 측정 거리 등 조건 변화가 필요하다. 최근 다양한 과학 기술이 비파괴 측정 시 적용되고 있다. 대표적으로 IR·Raman spectroscopy, X-ray, NMR, machine vision, hyperspectral imaging 등의 기술을 적용한 사례가 있다 [22].

농산물의 품질 예측 시 화학성분에 대한 정량분석이 가능한 ‘비파괴 분광기술’이 많이 활용된다. 농산물의 당도 예측 시 분광기술인 NIR (near-infrared)을 이용하여 spectrum을 얻은 후 다변수 분석법을 이용하여 당도를 예측한다. (주)한성엔지니어링은 과일 당도 선별기를 제작하여 판매 중이며, 1시간에 1,400개의 과일을 선별할 수 있으며 1개당 2.57초 이내에 당도 선별이 가능한 장비이다. 이러한 장비로 과일의 당도를 선별하여, 일정 당도 이상의 과일만 판매되고 있다 (Figure 1) [23].

분광법은 빛 (전자기파)과 물질의 상호작용을 다루는 분야이다 [24]. 물질은 물리 화학적 특성이 다르기 때문에 빛에 대한 흡수, 방출 패턴으로 물질에 대한 정보를 얻을 수 있다. 전자기파는 주기적으로 세기가 변화하는 전기장과 자기장의 한 쌍이 파동을 이루며 공간 속으로 전파되는 것을 의미한다. 빛은 파동성과 입자성을 가지고 있는 전자기 복사선 (electromagnetic radiation) 중 visible 영역이다. 전자기 복사선은 빠른 속도로 전파되는 에너지로서 파장, 진폭, 진동수, 속도로 영역을 분류할 수 있다. 전자기파는 파장에 따라 radio, microwave, IR, VIS, UV, X-ray로 분류된다. Microwave는 분자의 회전, NIR은 분자의 overtone 및 combination, MIR (mid-infrared)은 분자의 진동, UV/VIS는 전자의 전이, X-ray는 원자의 핵심 전자 전이로 인하여 빛을 흡수한다. 이러한 결과로 스펙트럼을 얻을 수 있으며, 분자 내 작용기 존재, 분자 결정 구조, 정성 및 정량 분석이 가능하다.

Figure 2는 주파수에 대한 dielectric loss factor ( $\epsilon''$ )를 나타낸 그래프이다 [15]. Dielectric loss factor는 샘플에 흡수된 전자기파가 열로 변환되는 형태를 나타낸다. Radio를 분자가 흡수하면 counterion effect, maxwell wagner effect가 발생하며, ionic loss가 발생한다. Microwave를 분자가 흡수하면 bound water, free water에서 dipolar

loss가 발생하고, rotation된다. IR을 분자가 흡수하면 atomic loss가 발생하고, vibration된다.

**A**



**B**



**C**



**D**



**Figure 1. Classification of sugar content in agricultural products using NIR;**  
**(A) Watermelon, (B) Melon, (C) Apple, (D) Korean melon [23].**

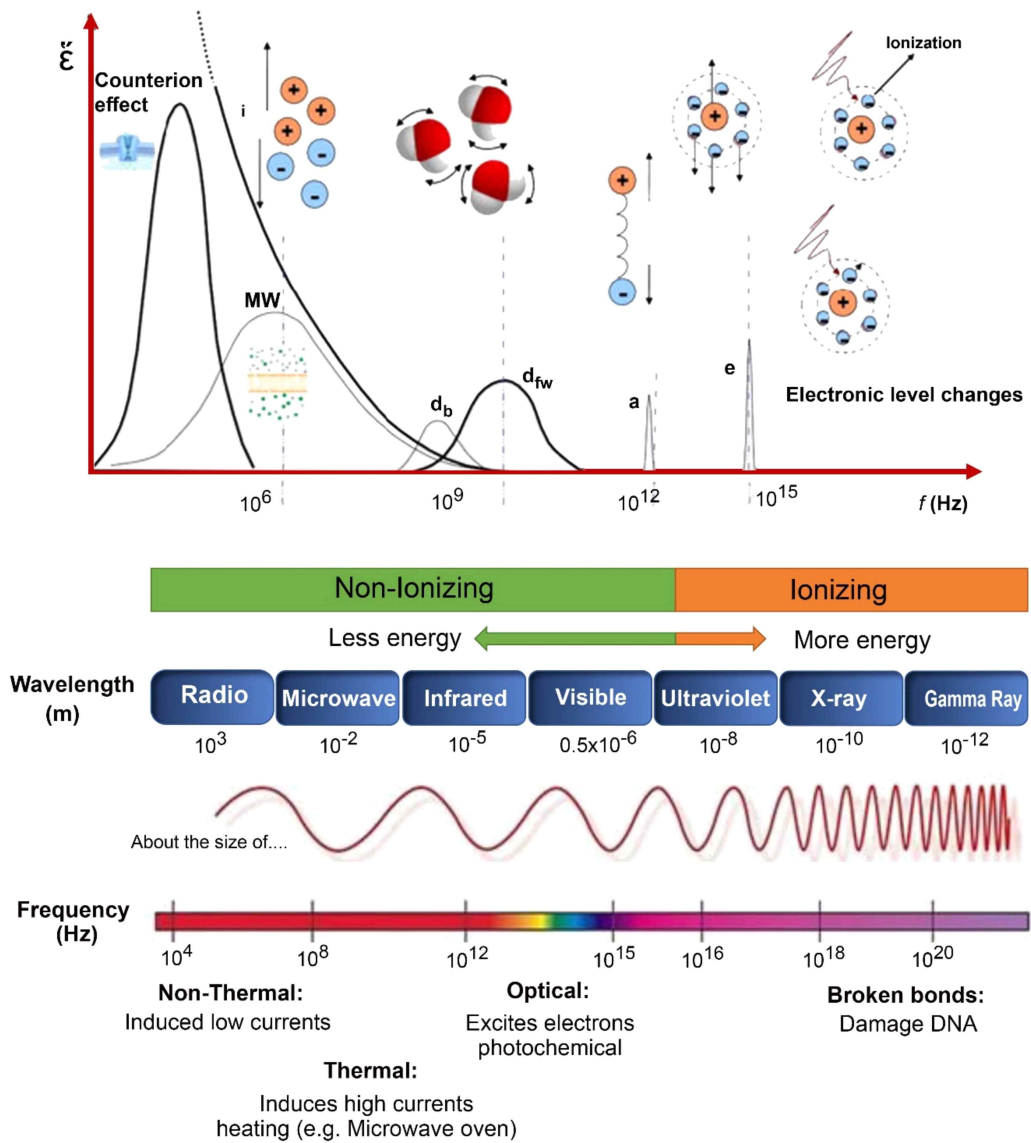


Figure 2. Scheme of dielectric loss factor ( $\epsilon''$ ) for wavelength and frequency [15].

최근 농산물 및 가공식품의 품질 분석 소요 시간을 1분 이내로 최소화하고, 환경 오염을 최소화할 수 있는 지속가능한 분석 방법을 개발하기 위하여 비파괴 측정 기술 및 분광법을 이용한 품질 예측 기술이 연구되어지고 있다.

다양한 분광법 중 IR과 같은 진동 분광법 (vibrational spectroscopy)은 빠른 분석, 저비용, 환경 친화 및 조작 용이성으로 다양한 산업 공정에서 활용된다 [25, 26]. IR을 분석 시료에 조사하면 특정 분자는 특정 파장에 관련된 빛을 흡수하여 해당 파장의 intensity가 감소한다. 이러한 intensity 변화는 시료의 특정 분자 농도와 관련이 있으며, detector를 이용하여 연속된 파장에 대한 intensity를 수치화하여 spectrum으로 표현할 수 있고, 이를 이용하여 성분에 대한 정성 및 정량분석이 가능하다. 진동 분광법을 이용하면 농산물 및 가공식품 품질 분류 공정의 in-line에 적용하여, 품질 평가가 가능하다.

IR은 측정영역에 따라 NIR과 MIR로 분류할 수 있으며, 각 특징은 Table 2와 같다. NIR spectrum의 측정 영역은  $4,000 - 12,500 \text{ cm}^{-1}$ 이고, 분자 vibrational mode의 combination과 overtone에 의해서 spectrum이 수집된다 [27]. MIR spectrum의 측정 영역은  $4,00-4,000 \text{ cm}^{-1}$ 이고, 작용기 (functional group)의 vibrational mode에 의해서 spectrum이 수집된다. NIR은 MIR보다 측정 시간 빠르고, 설치 비용이 저렴한 특징을 가지고 있어, 상업적으로 많이 활용된다. 또한, 다양한 샘플 형태에 사용할 수 있고, 투과 및 반사 방법으로 빛을 수집하여 spectrum을 얻는다.

Organic compound는 NIR 영역에서 특정 흡수 패턴을 가지며, 작용기는 NIR spectrum에 지배적인 영향을 미친다. NIR은 샘플의 화학 성분에 대한 absorption spectrum을 얻을 수 있기 때문에 chemometrics와 접목하여 화학 정보 추출 시 매우 유용하다. 그러나 NIR spectrum에는 neighbor group effects, hydrogen bonding, crystallinity, phase separation, thermal noise, mechanical noise와 같은 다양한 defect가 포함되어 있다 [28]. 이러한 defect를 제거하기 위하여 spectrum의 전처리가 필수적이다.

Figure 3은 식품 품질 예측 시 NIR spectrometer가 적용된 예시이다. 제조 공정에서 분석 시료 채취 및 분석 방법에 따라 off-line, at-line, on-line, in-line으로 분류할 수 있다. Off-line은 제조 공정의 분석 시료를 수동으로 채취하여, 분석실로 이동 후 분석자에 의하여 분석된다. At-line은 제조 공정의 분석 시료를 수동으로 채취하여, 제조 공정 현장에서 현장작업자에 의하여 분석된다. On-line은 제조 공정의 분석 시

료를 자동으로 채취하여, 제조 공정에서 분석 장비에 의하여 자동으로 분석된다. In-line 분석은 on-line 분석과 유사하며, 샘플 분석 위치에 따라 상이하다. On-line 및 in-line 분석 시 샘플에 영향을 미치지 않는 비파괴 기술 적용이 필수적이다. Figure 3A는 at-line에서 적용될 수 있는 NIR spectrometer 장비이다. Figure 3B, C는 on-line, in-line에서 적용될 수 있는 NIR spectrometer가 적용된 공정이다. NIR은 다양한 공정에서 활용 가능하고, 1가지 이상의 품질을 예측할 수 있다. 이러한 장점으로 인하여 농업, 식품, 제약, 환경, 석유화학 등 다양한 분야에서 활용되고 있다.

본 연구에서는 고구마의 내부 품질로 수분 및 전분 함량을 예측하였다. NIR을 비파괴 분광기술로 사용하였고, NIR을 선정한 이유는 다음과 같다. 첫 번째, NIR은 수소 원자를 포함하는 결합 (O-H, C-H, N-H)과 C-O, C=O에서 우선적으로 흡수 band 발생하여, 수분 및 전분 함량에 sensitive한 spectrum을 얻을 수 있다. 두 번째, NIR은 투과성이 높아 투과 spectrum을 얻을 수 있다. 비파괴 분광기술로 품질 예측 시 투과 및 반사 spectrum을 얻을 수 있는데, 투과 spectrum의 정확도가 높다고 알려져 있다 [29].

**Table 2. Characteristics of the infrared spectroscopy**

Features	NIR	MIR
Analyte	Starch, dietary fiber, moisture, sugar, mineral	Polyphenol, organic acid, microorganism
Measureable wavenumbers	12,500 – 4,000 $\text{cm}^{-1}$	4,000 – 400 $\text{cm}^{-1}$
Best vibration	Combination/overtone	Asymmetric
Process monitoring	Possible	Possible
Non-destructive analysis	Possible	Possible
Suitable fiber optics	Possible	Possible
Analysis of solids/powders	Possible	Possible
Analysis of liquids	Possible	Possible



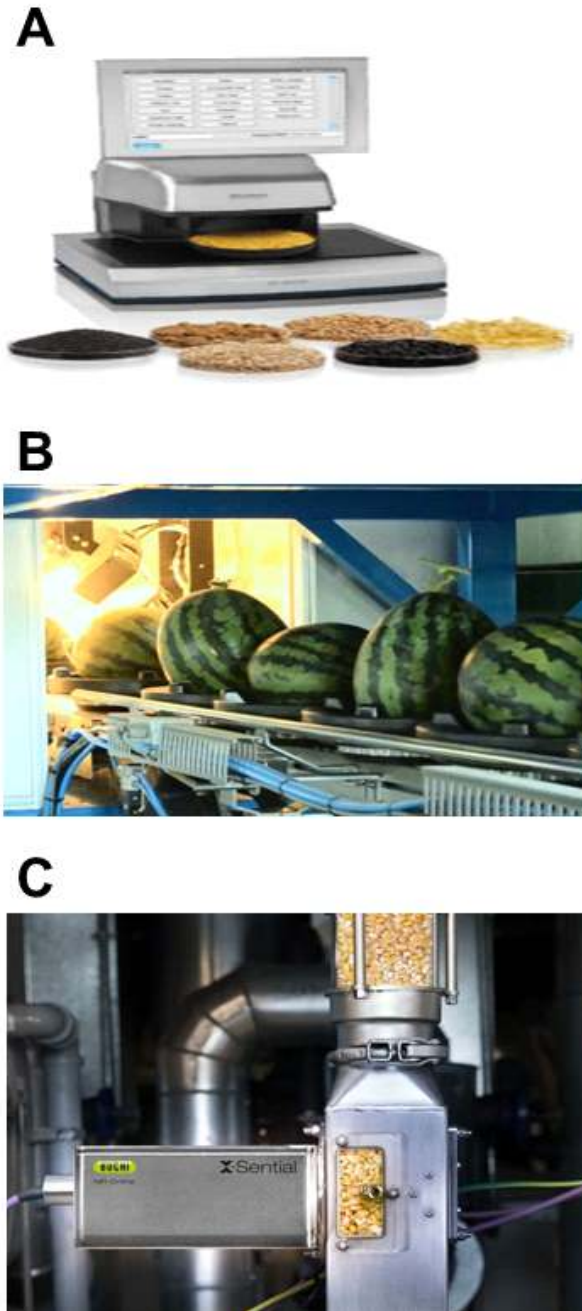


Figure 3. The NIR spectrometer using (A) at-line (Diode Array 7250, PerkinElmer), on-line or in-line ((B) Hansung engineering, (C) NIR-Online X-sENTIAL, Buchi).

### 3. 알고리즘 및 인공지능을 활용한 품질 예측

알고리즘은 일련의 명령어로서, 문제해결을 위한 절차를 명령어를 이용하여 순서대로 표현한다 [30]. 일반적으로 알고리즘을 사용하는 목적은 정확하고 효율적으로 결과 값을 얻기 위함이다. 예를 들면 컴퓨터에서 프로그램 작동을 위하여 어떠한 코딩이 효율적인지에 대한 문제를 해결하는 절차의 집합이다.

알고리즘은 입출력 (input, output), 명확성 (definiteness), 유한성 (finiteness), 효율성 (effectiveness)의 조건을 갖추어야 한다 [31]. 입출력은 0개 이상의 외부 데이터 입력과 1개 이상의 데이터 출력이 있어야 하는 것을 의미한다. 명확성은 각 명령은 단순 명확해야 하는 것을 의미한다. 유한성은 유한 번의 명령을 수행한 후 유한 시간 내에 종료해야 하는 것을 의미한다. 효율성은 모든 명령은 컴퓨터에서 수행되어야 하는 것을 의미한다. 이 중 가장 중요한 조건은 명확성과 효율성이다. 명확성은 알고리즘의 출력값이 항상 명확한 단계를 거치는 것에 대한 특성이고, 효율성은 알고리즘의 각 단계들이 효율적인가에 대한 특성이다. 알고리즘 생성 시에는 설계, 표현, 정확성 검증, 효율성 분석 단계를 거친다.

인공지능도 문제를 해결하기 위하여 컴퓨터에 적용하여 명령을 수행하므로 알고리즘이라고 할 수 있다 (Figure 4) [32–34]. 하지만 최근 머신러닝의 발달로 일반적인 알고리즘과 차이를 나타낸다. 머신러닝은 명확한 규칙을 기반으로 문제를 해결하지 않고, 입력 데이터와 출력 데이터의 관계에 대한 학습을 한다. 1980년대 인공지능 개발 시에는 규칙을 기반으로 문제를 해결하여 일반적인 알고리즘과 유사한 특성을 가졌다. 2000년대 인공지능은 컴퓨터가 학습을 진행하는 머신러닝이 적용되어 일반적인 알고리즘과는 차이가 있다. 따라서 인공지능과 알고리즘의 가장 큰 차이점은 명확한 규칙을 기반으로 문제를 해결하는 것이 아닌, 학습을 기반으로 문제를 해결하는 것이다. 인공지능의 장점은 높은 정확도와 확장 가능성이다.

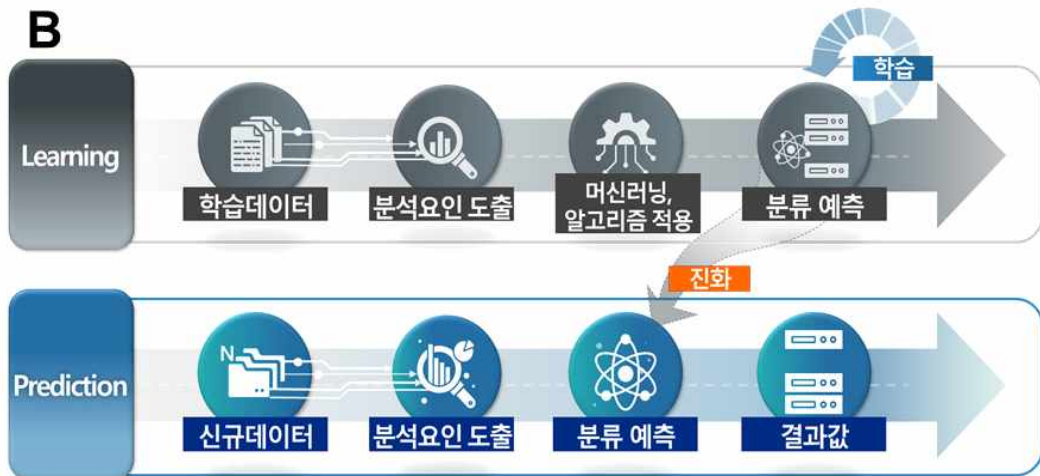
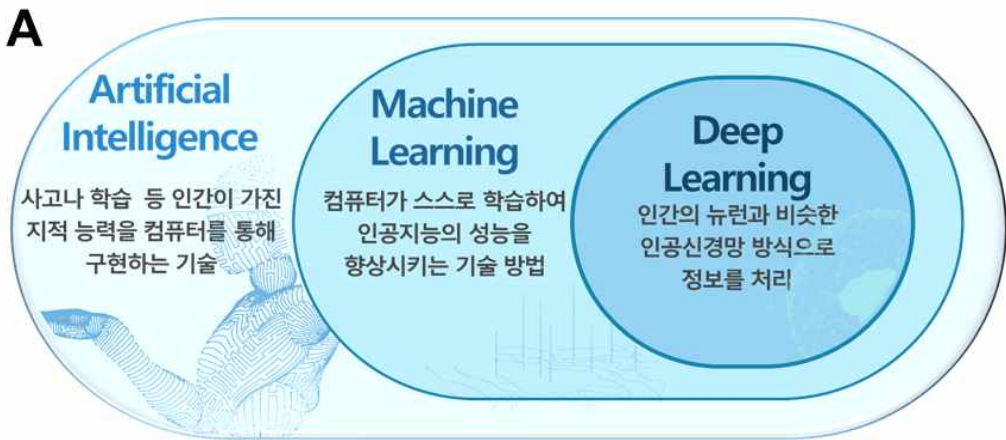


Figure 4. (A) Classification of artificial intelligence and (B) prediction model development process using machine learning [33, 34].

데이터의 패턴을 추출하고, 결과 값 예측을 수행하는 전통적 데이터 분석기법으로서 통계분석, 데이터마이닝이 사용되었다 (Figure 5) [34]. 전통적 데이터 분석기법은 회귀분석, 지도·비지도 학습, 딥러닝의 형태로 인공지능의 데이터 분석기법으로 발전하게 되었다.

인공지능은 빅데이터 기술과 융합되어 예측, 판단, 자율주행 등과 같은 다양한 응용분야에 적용된다 [35]. 빅데이터는 새로운 데이터 소스에서 발생하는 대량의 모든 데이터를 의미한다. 이러한 대량의 데이터에서 가치를 추출하고 결과를 예측 및 분석한다. 빅데이터 플랫폼은 대규모의 데이터를 저장·관리·분석할 수 있는 하드웨어 및 소프트웨어, 애플리케이션, 데이터를 유통·활용할 수 있는 모든 과정으로 구성되며, 각 요소들의 유기적 순환에 의하여 데이터 가치를 창출한다. 빅데이터는 규모 (volume), 다양성 (variety), 속도 (velocity), 정확성 (veracity), 가치(value)와 같은 특징을 가지고 있다 (Figure 6) [36].

빅데이터는 인공지능을 통하여 분석방법의 고도화가 가능하다. 또한, 인공지능은 빅데이터의 규모, 다양성, 속도적인 특성으로 정확도를 향상할 수 있다 (Figure 7) [37].

알고리즘, 인공지능의 수준과 데이터 수준의 low, high에 따라서 application을 분류할 수 있다 (Figure 8) [38]. 알고리즘, 인공지능의 수준은 accuracy, efficiency, reliability, unbiasedness에 따라서 수준을 분류한다. 데이터 수준은 quality, volume, variety, relevance에 따라서 수준을 분류한다. 알고리즘, 인공지능의 수준과 데이터 수준이 모두 high일 때 이상적인 application 적용이 가능하다.

기존의 식품품질 평가는 화학 및 미생물학적 분석을 기반으로 진행되었다. 이는 분석을 위하여 전처리 과정이 필요하고, 파괴적인 분석법이다. 또한, 전체 샘플 중 몇 개의 샘플만 선택적으로 분석하는 방법이다. 최근 알고리즘과 인공지능을 적용하여 전체 샘플을 단시간에 품질 분석할 수 있는 기술이 개발되고 있다 [39, 40]. 알고리즘은 machine vision 기술과 융합하여 이물질이 함유된 식품 분류 시 사용된다. 최근에는 인공지능을 spectroscopy 기술과 융합하여 식품의 유효성분 함량 분석과 같은 품질 평가에 사용된다.



Figure 5. Traditional data analysis and artificial intelligence data analysis [34].



Figure 6. Characteristics of big data [36].

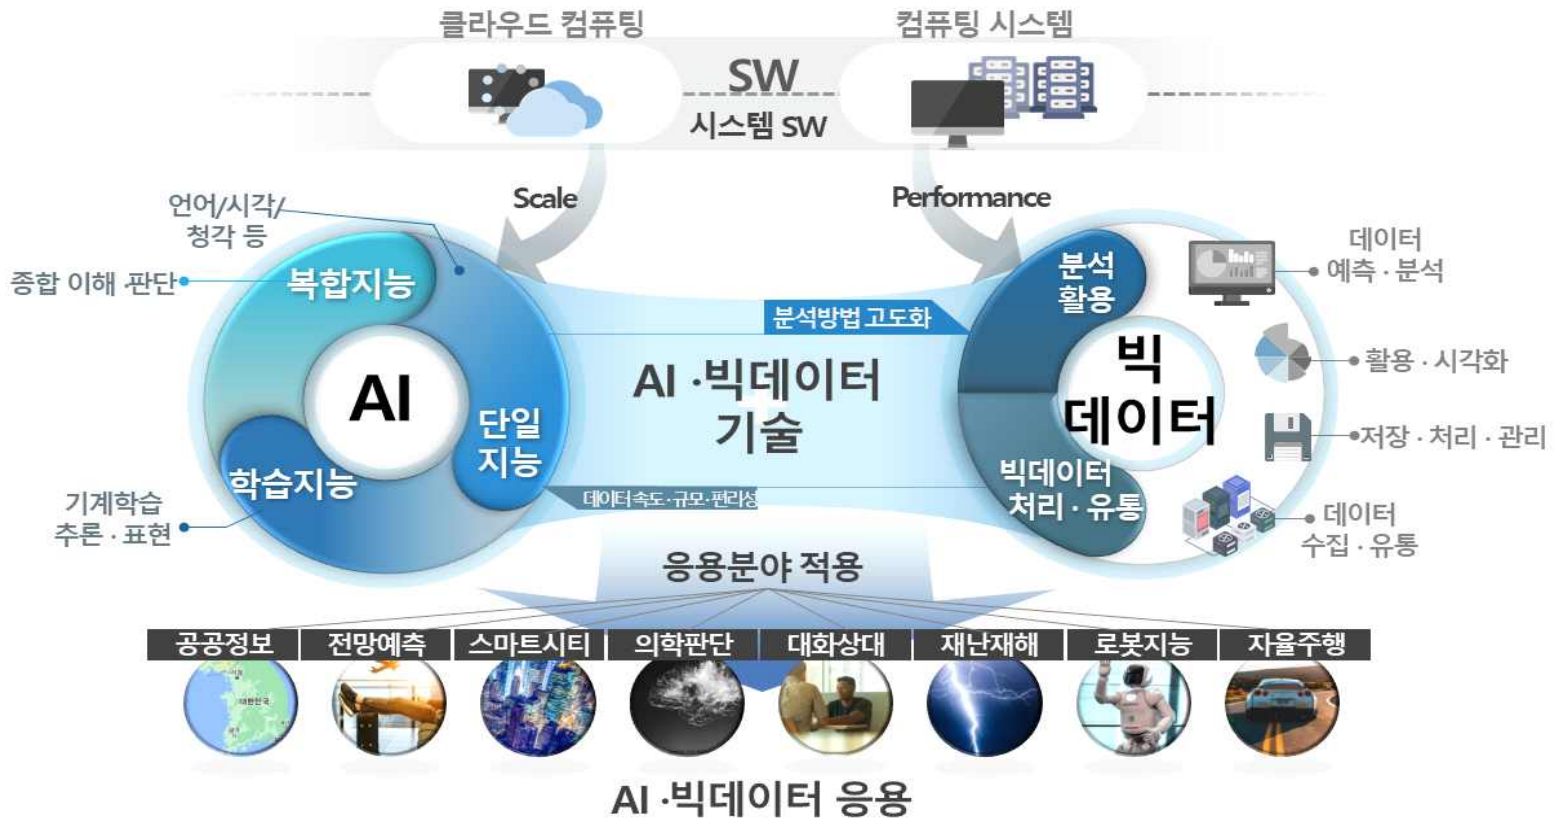


Figure 7. Convergence and application of artificial intelligence and big data technology [37].

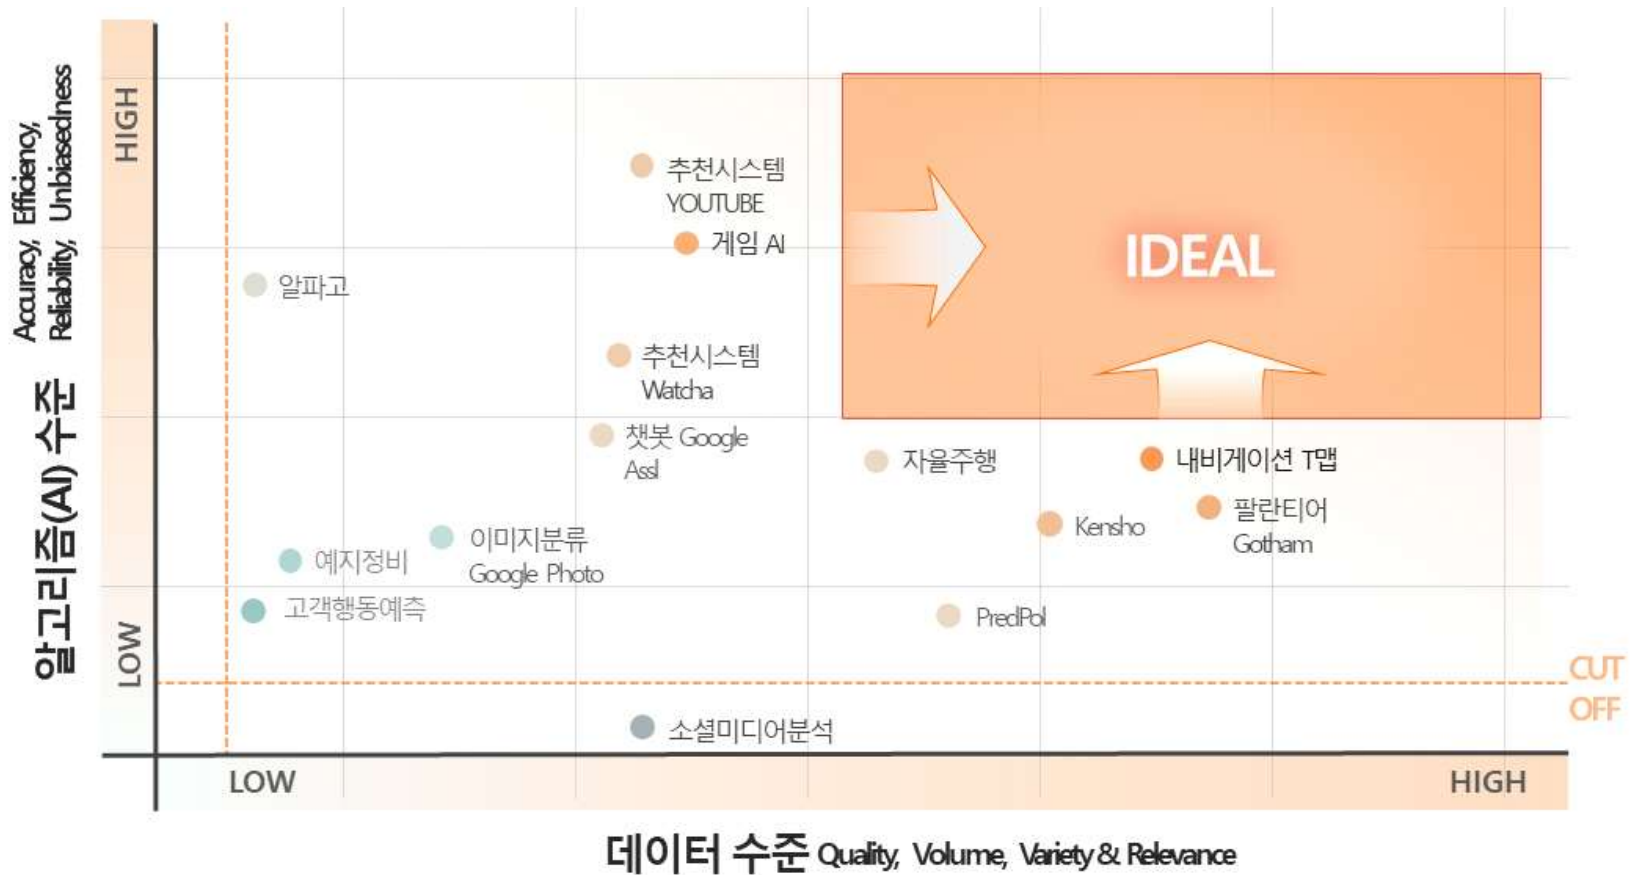


Figure 8. Classification of artificial intelligences' Application for algorithm level and data level [38].



## 4. 다변수 분석

1개의 독립변수와 종속변수의 관계를 분석하는 것을 단변수 분석 (univariable analysis)이라고 한다. 2개 이상의 독립변수와 종속변수의 관계를 분석하는 것을 다변수 분석 (multivariable analysis)이라고 한다. 다변수 분석은 classification model과 regression model로 분류할 수 있다 (Figure 9) [41]. 대표적인 classification model은 linear discriminant analysis (LDA), principal component analysis (PCA) 등이 있으며, 대표적인 regression model은 partial least squares (PLS), multiple linear regression (MLR) 등이 있다.

다변수 분석은 복잡한 화학데이터에서 정보를 추출할 때 많이 사용되며, 이를 chemometrics라고 부른다 [42]. Spectrum, chromatography 등은 다양하고 복잡한 화학 정보를 포함하는 데이터이다. Chemometrics는 화학, 수학, 컴퓨터과학 등 다양한 학문을 융합한 기술이며, 최근 식품 품질 예측 시 많이 사용된다.

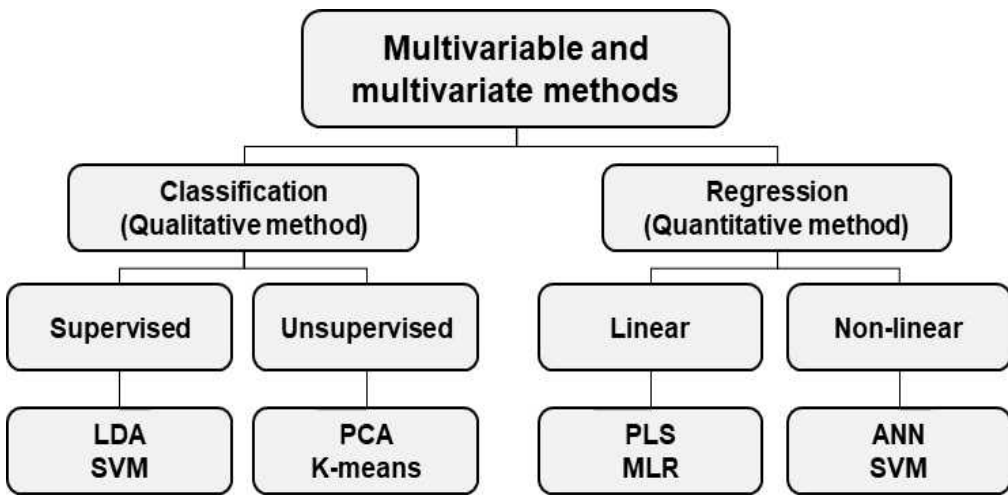


Figure 9. Classification of multivariable and multivariate methods [41].

LDA는 classification model로 많이 사용되고, 데이터 분포를 기반으로 decision boundary를 생성하여 데이터를 classification한다 [43]. LDA는 데이터를 클래스 간 분산의 비율을 최대화하고, 클래스 내 분산의 비율을 최소화하여 클래스 간의 최적 경계를 찾아 분류를 수행한다. Input vector ( $x$ )를 vector ( $w$ )에 projection 후 생성되는 1차원의 scalar를  $y$ 라고 정의한다.  $N_1$  개와  $N_2$ 개의 관측치를 갖는  $C_1$ 과  $C_2$  두 범주의 mean vector를  $m_1, m_2$ 로 정의한다.

$$y = w^T x$$

$$m_1 = \frac{1}{N_1} \sum_{n \in C_1} x_n$$

$$m_2 = \frac{1}{N_2} \sum_{n \in C_2} x_n$$

클래스 간 분산을 최대화하는 vector  $w$ 를 아래와 같은 식으로 정의한다.

$$m_2 - m_1 = W^T(m_2 - m_1)$$

$$m_k = W^T m_k$$

Projection 후 분산은 아래와 같은 식으로 정의한다.

$$S_k^2 = \sum_{n \in C_k} (y_n - m_k)^2$$

클래스 간 분산 최대화, 클래스 내 분산 최소화를 동시에 계산하기 위한 목적함수  $J(w)$ 는 아래와 식과 같다.

$$J(w) = \frac{(m_2 - m_1)^2}{S_1^2 + S_2^2} = \frac{w^T S_B w}{w^T S_W w}$$

$$S_B = (m_2 - m_1)(m_2 - m_1)^T$$

$$S_W = \sum_{n \in C_1} (x_n - m_1)(x_n - m_1)^T + \sum_{n \in C_2} (x_n - m_2)(x_n - m_2)^T$$

목적함수  $J(w)$ 는  $w$ 에 대하여 미분 시 0일 때 최댓값을 가지므로, 미분 후 식을 정리하면 아래 식과 같다.

$$(w^T S_B w) S_W w = (w^T S_W w) S_B w$$

$$S_B w - \lambda S_W w = 0$$

$$S_w^{-1} S_B w = \lambda w$$

따라서 vector  $w$ 는  $S_w^{-1} S_B$ 의 eigenvector이므로 차원 축소가 가능하다.

PLS는 regression model로 많이 이용된다 [44]. PLS는 종속변수 (Y)와 공분산이 높은 k개의 독립변수 (X)에 대한 선형조합을 추출하여, PLS 변수로 regression model을 생성한다. 이 때 생성된 PLS 변수로 설명되지 못하는 부분만을 다시 최소제곱법으로 regression model을 생성한다. 이러한 과정은 k번 반복하며, 오차 (mean square error)가 가장 낮은 k번째의 regression model을 사용한다.

PLS 분석 시에는 데이터 정규화가 필요하다. 입력변수를 X, 출력변수를 Y, X의 선형결합을 t, 선형결합의 가중치를 w로 명명한다. X의 선형 결합으로 인하여 t는 다음과 같은 식을 만족한다.

$$t = Xw$$

공분산이 최대가 되도록 하는 선형결합의 가중치가 필요하며, 계산 방법은 아래 식과 같다.

$$Cov(t, Y) = \frac{Corr(t, Y)}{\sqrt{Var(t)} \sqrt{Var(Y)}} \sqrt{Var(t)} \sqrt{Var(Y)}$$

$$Cov(t, Y) = Corr(t, Y) \sqrt{Var(t)} \sqrt{Var(Y)}$$

$$E[(X_w - E(X_w))(Y - E(Y))] = E[X_w Y]$$

$$\frac{1}{n} \sum_{i=1}^n (X_w)_i Y_i = \frac{1}{n} (X_w)^T Y = \frac{1}{n} w^T (X^T Y)$$

$x=0$ 일 때  $X^T Y$  값이 최대가 되고, 아래와 같은 식으로 정리할 수 있다.

$$w^T (X^T Y) = \|w\| \|X^T Y\| \cos\theta$$

$$w = X^T Y$$

가중치  $w$ 를 이용하여  $t$ 를 계산할 수 있다. 초기값인  $X_1, Y_1, t_1, w_1$  값으로 다음과 같은 회귀식으로  $t_1$ 의 회귀계수인  $\beta_1$ 을 계산할 수 있다.

$$t_1 = X_1 w_1$$

$$Y_1 = \beta_1 t_1 + F_1$$

$\beta_1$ 은 회귀식에서 예측해야 하는 회귀계수이며,  $F_1$ 은  $Y_1$ 의 설명할 수 없는 부분이다.  $F_1$ 은  $Y_2$ 로 정의할 수 있다. 따라서  $Y_1$ 의을 최소제곱법으로 설명하지 못하였던 부분인  $F_1$ 을  $Y_2$ 로 설정하여,  $Y_2$ 를 회귀식으로 예측하는 것이다.

$$Y_2 = F_1 = Y_1 - \beta_1 t_1$$

X 값은 다음과 같이 정의할 수 있다.

$$X_1 = \alpha_1 t_1 + E_1$$

$$X_2 = E_1 = X_1 - \alpha_1 t_1$$

입력변수 개수인  $p$ 개까지 위의 과정을 반복하여 PLS 분석을 진행하고, 예측값은 다음 식으로 계산할 수 있다.

$$\hat{Y} = \sum_{i=1}^k t_i \beta_i = t_1 \beta_1 + t_2 \beta_2 + t_3 \beta_3 + \dots + t_k \beta_k$$

## 5. 최적화

최적화의 목적은 공정에서 최고의 출력을 갖는 조건을 탐색하는 것이다 [45]. 과거 식품 품질 최적화는 1개의 매개변수에 대해서만 최적화하여 최고의 출력값을 탐색하였다. 그러나 여러 가지 변수가 품질에 영향을 미치는 식품 공정에서는 변수 간의 상호작용 효과가 고려되지 않고, 요인에 대한 설명이 부족하다는 단점이 있다 [46]. 특히, 농산물 기반 가공식품 제조 시 원물의 구성성분이 상이하기 때문에 제어 불가능한 오차가 항상 수반된다 [47]. 이러한 complexity를 해결하고, 식품 공정의 최적화를 위하여 multivariate statistic method인 반응표면분석법 (response surface methodology, RSM), 인공신경망 (artificial neural network, ANN) 적용이 연구되어 지고 있다.

반응표면분석법은 실험계획법 중 최적화를 위해 사용한다 [48]. 실험계획법이란 실험에 대한 계획 방법 (design)과 분석 방법 (analysis)을 의미하는 것으로, 해결하고자 하는 문제에 대하여 실험을 어떻게 수행하고, 어떤 방법으로 데이터를 얻으며, 어떠한 통계적인 방법으로 데이터를 분석하면 최소의 실험 횟수에서 최대의 정보를 얻을 수 있는가를 계획하는 것이다. 실험계획법은 반응변수에 영향을 미치는 유의한 요인들을 탐색하고, 고려된 계량인자들의 관심영역에서 최적조건을 구하는 것이다. 독립요인과 종속요인 간의 통계적 모델링을 기반으로 하고, 실험값을 2차 다항식에 fitting한다.

반응표면분석 시 2수준 일부실시법을 통하여 반응변수에 영향을 미치는 핵심인자를 선별한다. 선별된 핵심인자에 대한 실험설계 및 분석을 통하여 최적조건 근처의 영역을 확인한다. 최적조건 근처에서 이차모형을 가정하고, 적합한 실험 설계 기법을 이용하여 최적조건을 찾고 최적화를 진행한다.

반응표면분석 시 사용되는 실험 설계기법은 중심합성계획법 (central composite design, CCD), 박스-벤킨계획법 (Box-Behnken design)이 있다 [49]. 중심합성계획법은 가상의 정육면체를 형성하여 꼭지점 (factorial points), 중심점 (center points), 축점 (axial points)의 세 부분으로 구성된다. 중심합성계획법은 순차적으로 실험하는 경우 사용하고, 요인수가 같은 경우 박스-벤킨계획법보다 실험횟수가 많으며, 신뢰도가 높다.

박스-벤킨계획법은 이차 모형을 효율적인 3수준 실험설계로 3수준 요인배치법의

일부 실험 조건에서 실험한다. 중심합성설계법과 가장 큰 차이점은 실험점이 2개의 꼭지점 ( $\pm 1, \pm 1$ ) 수준에서 실험한다. 나머지 변수는 수준의 중앙값인 0으로 고정한다. 이 방법은 모형의 꼭지점에 해당하는 실험을 제외하여 구성하므로 실험 조건이 극단적인 경우, 이를 제외할 수 있다는 장점이 있다. 박스-벤킨계획법은 순차적으로 실험하지 않는 경우 사용한다. 또한, 꼭지점에서 실험을 수행하지 않으므로, 꼭지점에서 실험이 불가능할 경우 사용할 수 있다. 요인수가 같은 경우 중심합성계획법보다 실험횟수가 적다.

인공 신경망은 신경 세포 또는 뉴런으로 구성된 생물학적 신경계의 단순화된 model이고, input layer, hidden layer, output layer로 구성된다 [50]. Input layer에 input data, output layer에 output data를 입력하면, hidden layer에서 weight 및 bias 값을 조절하여 오차가 가장 낮은 model을 생성한다. ANN은 식품 품질 분석, 식품 이미지 분석, 식품 가공 작업 모델링과 같은 다양한 응용 분야에 활용되어지고 있다. ANN은 비선형 방식의 모델이기 때문에, 불완전한 정보로도 모델을 생성하여, 반응값 (response)을 예측할 수 있다.

ANN은 RSM에 비하여 복잡한 데이터를 유연하고 정확하게 모델링한다. 최근 식품 가공 분야에서 반응값 예측을 위한 RSM과 ANN의 모델 적용 연구가 활발하게 진행 중이다. Yang 등 (2019)은 kidney bean의 phenolic compound 추출 최적 조건을 RSM과 ANN을 이용하여 모델링하여 성능을 비교하였다 [51]. Tang 등 (2017)은 호박의 osmotical dehydration 공정 조건에 대한 품질 예측 모델을 RSM, ANN으로 모델링하였다 [52]. Onu 등 (2020)은 potato slice 건조 공정 조건에 대한 품질 예측 모델을 RSM, ANN으로 모델링하였다 [53].



## 6. 장내 미생물

인간의 몸에는 약 100조개의 미생물이 공생하고 있으며, 무게는 약 1.3 - 2.3 kg 으로 예상된다 [54]. 이러한 미생물은 소화기, 호흡기, 비뇨생식기 등 다양한 부위에 분포한다. 또한, 대사과정 중 발생하는 대사산물이 인간의 건강에 영향을 미쳐 제 2의 인간 유전체라고도 불린다 [55, 56].

인간의 위장관 (gastrointestinal tract) 위치에 따라서 미생물 군집 (microbiota)이 존재한다. 미생물 군집은 식단과 같은 환경에 따라서 구성이 매우 상이하다 [57]. 체내 미생물 중 장 (gut)에 존재하는 미생물의 비율이 가장 높다. 장내 미생물은 소화 효소로 분해되지 않은 양양 성분을 발효시켜 영양소를 생성한다.

미생물 군집의 중요한 기능은 미생물과 인간 모두에게 영향을 미치는 대사산물의 생성이다. 대사산물로서 short chain fatty acid (SCFA), long chain fatty acid, vitamin, amino acid 등을 생산하여 면역 세포 및 신경 세포에 영향을 미칠 수 있다 [58]. 건강한 미생물 군집의 정의는 통상적으로 높은 생물다양성과 특정 미생물의 abundance이다. 특정 미생물 군집 구성은 만성 질환 발병과 높은 연관성을 가지고 있다 [59]. 미생물 군집 분류 및 대사산물 분석을 통하여 질병을 예측할 수 있다. 최근 장내 미생물 composition 분석을 통하여 질병을 예측하는 연구가 활발히 진행되고 있다.

기존 미생물의 염기서열 분석 방법은 분변시료에서 미생물을 배양하여 분리 및 동정하였다. 이는 장내 미생물 군집에 대한 정보를 확인하기 어렵고, 시간과 비용이 많이 소모되는 단점이 있다 [60]. 대표적으로 사용되는 sanger sequencing은 DNA 복제 시 ddNTP가 DNA 중합효소에 의하여 제한적으로 삽입되는 기술이다. 단일 나선 DNA 주형, DNA primer, DNA 중합효소, dNTP, ddNTP를 이용하여 sequencing하며, 전기 영동을 이용해 크기별로 분리한다 [61]. 상대적인 위치에 따라서 DNA 염기서열을 분석한다. Sanger sequencing은 기술적 신뢰도가 높지만 샘플의 부분적인 DNA sequencing이 가능하고, 전체 DNA sequencing을 얻으려면 많은 분석 횟수가 필요하다.

최근 미생물 군집의 전체 미생물 염기서열을 고속으로 분석하는 기술로서 16S rRNA를 이용하는 Next Generation Sequencing (NGS)이 사용된다 [62]. NGS 분석법은 기존의 sanger 방법에서 cloning 단계를 거치지 않고 빠르게 분석이 가능하다.

16S rRNA는 conserved region과 hypervariable region이 존재하여 염기서열분석을 통해 미생물의 종 (species)을 확인할 수 있다. NGS 분석 시 DNA를 일정한 조각 (fragment)으로 분절화하여, 특정 염기서열을 가진 올리고뉴클레오티드 (oligonucleotide)를 붙여 라이브러리 (library)를 제작한다. 제작된 라이브러리를 장비에서 reading하여, 데이터 가공을 통해 염기서열 분석이 이루어진다. 특정 환경 내의 시료에서 유전체를 분석하여 시료의 전체 미생물 종을 분석하는 것을 metagenome이라고 하며, NGS 분석법 개발을 통하여 metagenome 연구가 활발하게 진행되고 있다. 따라서 NGS를 이용하여 metagenome 분석 시 장내 미생물 군집 분석 및 특성 확인이 가능하다.

NGS 분석 결과는 각 sequencing 리드 (read)의 염기서열과 염기의 품질 점수를 같이 표시한 데이터로 얻어지고, 이를 FASTQ 파일이라고 한다. FASTQ 파일을 metagenome 분석 플랫폼 (EZBioCloud, QIIME, Base Space 등)에 업로드하여 미생물 군집의 diversity와 relative abundance를 확인할 수 있다.

미생물 군집의 diversity 분석은  $\alpha$ -diversity와  $\beta$ -diversity로 분류된다 [63].  $\alpha$ -Diversity는 미생물 종 다양성을 수학적 지표로 나타내어, 샘플 내 미생물 종의 richness와 evenness를 확인할 때 사용된다. 대표적인 지표로 observed OTUs, Chao 1, Shannon index, Simpson index 등이 사용된다.  $\beta$ -Diversity는 샘플 간 다양성 군집의 유사성 및 차이점을 확인할 때 사용된다. 대표적인 지표로서 Unifrac, UPGMA, Jaccard index 등이 있다. Relative abundance는 미생물 유전자의 상대적 풍부함을 추론하여 정량화할 수 있다. 이를 통하여 장내 미생물을 composition을 확인할 수 있다.

장내 미생물의 종 구성은 host가 섭취하는 식이에 따라 변화한다. 미생물 대사산물은 탄수화물, 단백질, 지방과 같은 영양소의 영향을 크게 받는다. 식이에 따른 장내 미생물 구성 변화 mechanism은 다음과 같다 [64]. 첫 번째, 미생물 종은 그들의 유전자에 따라서 활용하는 영양소가 상이하다. 따라서 특정 영양소가 풍부할 때 특정 미생물 종은 relative abundance가 증가할 수 있다. 두 번째, 식이에 따라 pH, 염 농도 변화와 같은 장내 환경 변화가 발생하여 미생물 군집 변화가 발생할 수 있다.

주 영양소인 탄수화물, 단백질, 지방의 섭취 형태에 따른 microbiota의 변화는 다음과 같다. 탄수화물은 digestible과 non-digestible로 분류할 수 있다. Digestible 탄수

화물은 소화효소에 의하여 sugar, glucose, fructose, sucrose, lactose와 같은 성분으로 분해된다. 높은 함량의 glucose, fructose, sucrose 식품을 섭취하게 되면 *Bifidobacteria*는 증가하고, *Bacteroides*는 감소한다 [65]. Whole grain 및 wheat bran에 함유된 non-digestible carbohydrate 섭취 시 *Bifidobacteria*, *Lactobacilli*가 증가한다. Resistant starch와 같은 non-digestible carbohydrate 섭취 시 *Ruminococcus*, *Roseburia*가 증가한다 [66–68].

단백질은 식물성과 동물성으로 분류할 수 있다. 식물성 단백질 섭취 시 *Bifidobacteria*, *Lactobacillus*는 증가하고, *Bacteroides*, *Clostridium perfringens*은 감소한다 [69–71]. 이러한 microbiota의 변화는 SCFA 생성을 증가하고, 염증성 장 질환 발병을 감소할 수 있다. 동물성 단백질 섭취 시 *Bacteroides*, *Allistipes*, *Ruminococcus*는 증가하고, *Bifidobacteria*은 감소한다 [72–75]. 이러한 microbiota의 변화는 SCFA 생성을 감소하고, 염증성 장 질환을 유발할 수 있다. 또한, trimethylamine-N-oxide 생성을 증가하여 심혈관 질환을 유발할 수 있다.

지방은 불포화 및 포화로 분류할 수 있다. 불포화 지방 섭취 시 *Bifidobacteria*, *Streptococcus*, *Lactobacillus*, *Akkermansia muciniphila*가 증가한다 [76, 77]. 이러한 microbiota의 변화는 TLR activation 및 white adipose tissue inflammation을 저해할 수 있다. 포화 지방 섭취 시 *Bacteroides*, *Bilophila*, *Faecalibacterium prausnitzii*가 증가한다 [78–80]. 이러한 microbiota의 변화는 TLR activation 및 white adipose tissue inflammation 증가를 유발할 수 있다.

## 제2절 연구의 목적

최근 식품 소비자들의 건강에 대한 관심이 증가하면서 웰빙 식품에 대한 소비가 증가하고 있는 추세이며, 농산물 및 농산물 가공식품이 각광받고 있다. 농산물은 같은 품종이여도, 재배 환경 및 저장 환경에 따라 내부 품질 차이가 발생한다. 따라서 농산물 가공식품 제조 시 다음과 같은 요인이 고려되어야 한다.

첫째, 농산물 품질 예측 및 평가를 통한 품질 관리가 필요하다.

둘째, 가공공정 중 농산물 품질에 따른 최종 제품의 품질 예측 및 최적화가 필요하다.

본 연구에서는 서류 (고구마, 감자)와 서류 가공식품에 대한 품질 예측 및 최적화를 진행하였다. 농산물 중 서류를 선정한 이유는 다음과 같다. 첫째, 서류는 구황작물로서 다른 농산물에 비하여 기후에 영향을 작게 받는다. 지구온난화와 같은 기후 변화에도 지속적으로 재배가 가능하다. 둘째, 저장성이 좋아 수확 후 1년 동안 보관하여 섭취할 수 있다. 셋째, 주성분은 전분이고, 다량의 무기질을 함유하고 있어, 영양학적 장점을 가지고 있다. 그러나 고구마 가공식품으로서 연구가 거의 진행되지 않았다. 또한, 전 세계적으로 수요가 높은 감자튀김의 유해성 논란이 많지만, 건강에 미치는 기전이 명확히 밝혀지지 않았다. 따라서 본 연구에서는 고구마와 감자를 선정하여, 고구마의 내부 품질 예측, 고구마칩 제조 공정 최적화, 감자튀김 식이가 장내 microbiota에 미치는 영향을 확인하였다.

첫 번째 연구로서, 근적외선 및 다변수 분석을 활용해 비파괴 기술로 고구마 원물의 내부 품질을 예측하였다. 내부 품질로서 수분 및 전분 함량을 측정하였다. 품질 예측 시 in-line 상에 품질 측정 장비 도입 가능성을 확인하였고, 원물 1개당 3초 이내의 분석 시간이 소요되는 것을 확인하였다.

두 번째 연구로서, 감압후라이닝 기술을 이용하여 고구마칩 제조 시 RSM 및 ANN을 이용하여 가공공정을 최적화하였다. 가공 시 슬라이스한 생고구마를 당칩 처리하였다. 최적화 시 변수로 당칩 용액 농도, 당칩 온도, 감압후라이닝 온도를 설정하였다. 반응값인 최종 품질은 수율, 오일 함량, 갈변지수로 설정하여, 품질 최적화 연구를 하였다.

세 번째 연구로서, 감자튀김 식이가 장내미생물에 미치는 영향에 대하여 연구하

였다. 감자튀김 제조 시 튀김 오일 (카놀라유, 팜유)과 튀김 방법 (상압, 감압)에 따른 toxic compounds (acrylamide, trans fatty acid, PAH) 함량을 비교하였다. 또한, mouse에게 감자튀김을 12주동안 식이하여 무게 변화, cholesterol 및 triglyceride 함량 변화, 맹장 내용물의 SCFA 변화, 분변의 microbiota 함량 변화를 분석하였다.

식품 품질 및 안전을 위한 평가는 세계 정책의 핵심이다. 최근 다양한 분석 방법의 발전으로 유해 물질에 대한 허용 한도가 낮아지거나, sensitive한 분석 조건 개발이 요구된다. 화학, 생물학, 분광학, 데이터과학 등 다양한 응용 분야를 이용하여 신속한 품질 평가 기술 및 예측 기술과 같은 새로운 접근 방식 개발도 요구된다. 본 연구에서는 근적외선 분광법, 비파괴 기술, 다변수 분석, chemometrics, 실험계획법, RSM, ANN, metagenome 등 다양한 분야를 융합하여 서류와 서류 가공식품에 대한 품질 예측 및 최적화하였다.

## 제2장 고구마 내부 품질 예측을 위한 근적외선 분광 법 및 다변수 분석

### 제1절 서론

고구마는 중·남아메리카가 원산지이며, 전 세계적으로 연간 약 105,000,000 ton이 재배된다. 이 중 약 82%는 아시아 국가에서 재배된다 [81]. 고구마의 주성분은 탄수화물이며, 식이섬유, vitamin C, 알라핀 (yalapin), 세라핀 (seraffin) 등의 미량성분도 함유하고 있다 [82, 83]. 베니하루카 (*Beni Haruka*)는 아시아 국가에서 가장 인기 있는 고구마 품종으로서 다양한 방법으로 가공하여 섭취한다 [84]. 최근 고구마 소비는 영양학적 장점으로 증가하는 추세이며, 페이스트, 푸레, 말랭이, 칩 등의 가공식품 형태로 전 세계적으로 판매되고 있다 [85, 86]. 페이스트는 운송 및 사용이 간편하여 가장 많이 소비되는 고구마 가공식품이며, 고구마를 삶거나 구운 후 껍질을 제거하여 분쇄하여 제조된다 [87]. 페이스트의 90% 이상은 고구마로 구성되며, 최종 품질은 제조 시 사용한 생고구마의 수분 및 전분 함량에 의해서 결정된다. 본 연구에서는 *B. haruka* 품종의 고구마를 이용하여 품질 예측 모델을 개발하였다. *B. haruka*는 2019년 기준 국내 고구마 재배면적의 43%를 차지하였다 [88]. *B. haruka*는 높은 당도를 가지고 있어 소비자 선호도가 매우 높고, 병해충에 강하여 재배 농가의 선호도도 높다. 고구마 말랭이, 냉동 군고구마 등 가공식품 제조 시 사용하는 고구마 품종도 대부분 *B. haruka*이다. 따라서 재배면적이 높고, 가공식품 제조 시 많이 사용되는 *B. haruka* 품종으로 고구마의 내부품질 예측 모델을 연구하였다.

고구마는 재배 후 curing 과정을 거친 후 일정한 온도와 습도가 유지되는 창고에서 저장된다 [89]. 고구마 외부요소 및 내부요소는 재배 후 저장 환경에 영향을 받으며, 수분 및 전분 함량은 고구마의 내부 품질 요소에 영향을 미치는 중요한 요인이다 [90]. 고구마의 저장과 가공 공정 중 전분은  $\alpha$ -amylase,  $\beta$ -amylase, starch phosphorylase와 같은 endogenous amylolytic enzyme에 의하여 maltose와 glucose와 같은 단당으로 분해되어 당도가 증가한다. 고구마는 재배 시 껍질 부분부터 중심 부분까지 전분으로 이루어져 있으며, 재배 후 약 8주까지 껍질 부분에서  $\alpha$ -amylase가 분비되어 껍질 부분에서 중심 부분으로 전분 분해가 발생한다. 하지만 성장 및 저장 조건이 적합하지 않으면  $\alpha$ -amylase의 분비 및 활성이 억제되어 전분이 분해되지 않고

고구마 내부에 남아있게 된다. 이러한 현상을 증백 현상이라고 하며, 전분과 단당 부분의 색 차이로 인하여 가공 후 육안으로 확인이 가능하다. 또한, 증백 현상 고구마로 가공식품 제조 시 점도 및 당도가 감소하여, 최종 품질 저하를 발생시킨다. 고구마는 외부요소를 기반으로 품질 평가가 이루어진다 [91, 92]. 그러나 수분 및 전분 함량은 가공식품 제조 시 최종 품질을 결정하는 중요한 요소이다 [93]. 따라서 생고구마의 내부 품질 규격화는 필수적이며, 수분 및 전분 함량에 대한 신속하고 정확한 평가가 필요하다.

비파괴 측정 (nondestructive detection)은 물체의 모양이나 특성을 변형하거나 파괴하지 않고 물체의 품질 및 특성을 확인하는 기술이다. 비파괴 측정은 품질 평가 시 필요한 시간과 노동력을 줄일 수 있다 [94]. 다양한 분광 기술 중 근적외선 분광법 (NIR)은 짧은 측정 시간, 저렴한 비용, 간단한 조작, 높은 효율성과 같은 장점을 가지고 있어 농산물 품질 평가 시 가장 많이 사용된다 [95, 96]. 농산물 중 낮은 조직 밀도를 가지고 있는 사과, 수박, 메론은 비파괴 기술인 NIR을 적용하여 품질 평가한 연구가 있다 [97]. 그러나 고구마는 높은 조직 밀도를 가지고 있어 비파괴 기술인 NIR을 적용한 품질 평가가 어렵다. Katayama 등 (1996)은 고구마를 5 mm 두께로 절단한 후 NIR 스펙트럼을 측정하여 multiple regression 분석을 통해 수분, 전분, 당 함량을 예측하였다 [98]. Iwase 등 (2015)은 음파를 이용하여 토양 속에 있는 고구마 탐지 방법을 제안했다 [99]. 고구마와 유사한 외관을 가진 서류 작물인 감자는 내부 품질인 수분 및 당 함량, 내부 결함을 비파괴적 NIR 분광법으로 측정한 몇 가지 연구 결과가 보고되었다 [100–104]. 감자와 고구마는 구성 성분 및 특성이 완전히 상이하며, 고구마의 내부 품질을 비파괴적 NIR 분광법으로 측정한 연구는 없다. 따라서 본 연구에서는 측정 시간이 짧고, 효율이 높은 NIR 분광법을 비파괴적 측정을 위하여 사용하였다. NIR 분광법의 정확성을 증진시키기 위하여 chemometrics를 이용하여 결과를 분석하였다. Chemometrics는 spectrum과 같은 복잡한 화학분석 데이터에서 정보를 추출할 때 사용하는 분석화학의 한 분야이다. 데이터 분석 시 다변수 분석을 많이 사용하며, classification model과 regression model로 분류할 수 있다.

본 연구에서는 고구마를 수확한 후 8주동안 저장하며, 수분, 전분,  $\alpha$ -amylase 함량 변화를 측정하였다. 내부 품질은 비파괴적 NIR 분광법을 사용하여 측정한 후 수분 및 전분 함량을 예측하기 위하여 chemometrics model을 사용하여 분석하였다.

## 제2절 재료 및 방법

### 1. 고구마

본 연구에서 사용한 고구마 품종은 베니하루카 (*B. Haruka*)이며, 대한민국 전라북도 김제시 (35° 53' 27.6" N 126° 54'45.7" E)에서 수확하였다. 고구마는 재배 후 공덕농협농산물가공사업소에 저장하였으며, 3일동안 큐어링 (34℃, 상대습도 100%)하여 창고 (12℃, 상대습도 85%)에서 저장하였다. 144개 고구마를 8주동안 보관하였고, 매 주 (1 - 8주) 18개의 고구마를 실험실로 2시간이내로 운송하여 실험하였다.

### 2. 저장기간동안 품질 특성 변화 측정

#### 가. 수분 함량

고구마의 비파괴적 NIR spectrum 측정 후 내부 품질 측정을 위하여 적도 부분을 절단하여 1 mm 두께로 슬라이스하였다. 수분 함량은 수정된 AOAC 방법으로 측정하였다 [105]. 도가니를 105 °C 오븐에서 항량에 도달할 때 까지 방치한 후 데시케이터에서 30분간 냉각하였다. 도가니에 고구마 샘플을 넣고 뚜껑을 덮고 무게 (W1)를 측정하였다. 105 °C 오븐에 도가니를 넣은 후 뚜껑을 열고 3시간동안 방치한 후 데시케이터에서 30분간 냉각하여 질량을 측정하였다. 약 1~2시간동안 다시 건조시킨 후 위와 같은 실험방법으로 일정한 질량 (W2)이 될 때까지 건조를 반복하였다. 수분 함량은 아래와 같은 식으로 계산하였다.

$$Moisture (\%) = \left[ \frac{(W1 - W2)}{W1} \right] \times 100$$

#### 나. 전분 함량

고구마의 비파괴적 NIR spectrum 측정 후 수분 함량 및  $\alpha$ -amylase 활성 측정 샘플 채취 후 남은 고구마 부분을 전분 함량 측정을 위하여 180 °C 오븐에서 90분동안 구웠다. 구운고구마를 중앙 부분에서 절단하여 단면의 이미지를 촬영하였다. 촬영은 30 cm × 30 cm × 30 cm 크기의 흰색 플라스틱 박스에서 하였으며, 구운고구



마에서 약 30 cm 위에 위치한 카메라를 사용하여 촬영하였다. 이미지는 ImageJ software (NIH, Bethesda, MD, USA)를 사용하여 처리하였다. 배경을 제외하고 구운 고구마 단면만 선택하여 256-level grayscale 이미지로 변환하였다. 전분 함량은 grayscale image에서 level 값으로 분류하였다. 전분이 남아있는 부분은 흰색과 유사한 색으로 표현되었으며, level 값이 100 이상인 면적을 A1 값으로 명명하였다. 전분 가수분해 후 당화된 부분은 회색과 유사한 색으로 표현되었으며, level 값이 100 미만인 면적을 A2 값으로 명명하였다. 전분 함량은 아래와 같은 식으로 계산하였다.

$$Starch (\%) = \left[ \frac{A1}{(A1 + A2)} \right] \times 100$$

### 다. $\alpha$ -Amylase 활성

고구마의 비파괴적 NIR spectrum 측정 후 내부 품질 측정을 위하여 적도 부분을 절단하여 1 mm 두께로 슬라이스하였다. 슬라이스한 고구마 샘플 질량의 10배 부피의 Macllvaine buffer (pH 7.0) 용액을 첨가한 후 균질화하여  $\alpha$ -amylase를 추출하였다. Substrate solution으로 1% (w/v) soluble starch 용액을 사용하였다.  $\alpha$ -Amylase 활성 측정을 위하여 37°C로 preincubation된 substrate solution 5 mL, Macllvaine buffer (pH 7.0) 4 mL, 0.1% CaCl<sub>2</sub> 1 mL를  $\alpha$ -amylase 추출물 10 mL와 혼합하여 37°C에서 20분동안 반응하였다. 반응 후 4°C 이하로 냉각하여 반응을 종료하였다. 반응 용액을 4°C에서 10,000 rpm으로 10분동안 원심분리하여 상층액을 수집하였다. 상층액 0.2 mL와 dinitrosalicylic acid (DNS) 용액 0.6 mL를 혼합하여 100°C에서 5분동안 반응 후 상온으로 냉각시켜 540 nm에서 흡광값을 측정하였다. DNS 용액은 1% dinitrosalicylic acid, 1% sodium hydroxide, 0.2% phenol, 0.05% sodium sulfite로 제조하였다 [106].

### 3. 비파괴 기술을 이용한 품질 특성 측정

#### 가. NIR spectrum 측정

NIR spectrum은 halogen tungsten lamps (JCR12V-100WBAU, USHIO, Tokyo, Japan)와 detector (Ava Spec-UV/VIS/NIR, AVANTES, Apeldoorn, Netherlands)를 사용하여 측정하였고, Hansung engineering (Chungcheongnamdo, South Korea)에서 개발한 software로 control하였다 (Table 3). 500-2,500 nm 범위에서 1.0 nm의 sampling interval로 16번 scan하여 절단하거나 파괴하지 않은 고구마의 NIR spectrum을 측정하였다. Transmission mode를 사용하였고, transmittance (%T)는 다음과 같은 식을 이용하여 흡광값으로 변환하였다.

$$Absorbance = 2 - \log(\%T)$$

NIR spectrum 분석은 760 - 1,420 nm 범위를 이용하였다. 측정 장비는 Figure 10A와 같다. 본 장비를 컨베이어 벨트가 포함된 산업용 장비에 적용하였을 때도 NIR spectrum 측정이 가능한 것을 확인하였으며, Figure 10B와 같다.

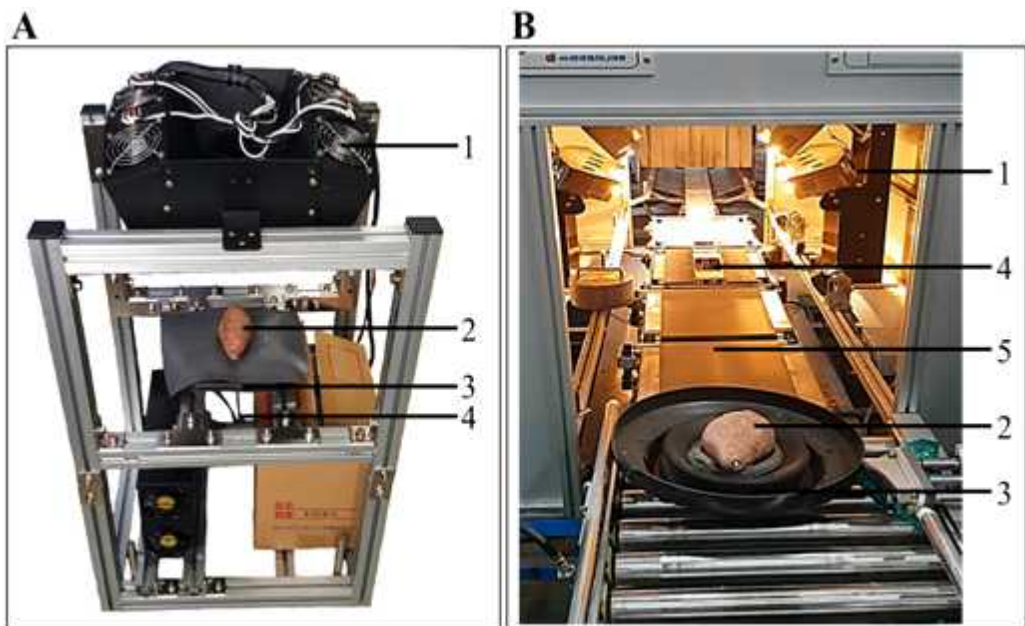
#### 나. Chemometrics

##### A. NIR spectrum 전처리

Model의 정확도를 향상시키기 위하여 NIR spectrum을 전처리하였다. 전처리 방법으로는 Savitzky-Golay derivative (S-G), standard normal variate (SNV), multiplicative scattering correction (MSC)를 이용하였고, Unscrambler (Camo Analytics, Oslo, Norway) 프로그램을 사용하였다 [107]. S-G 방법을 사용할 때 polynomial derivative를 이용하였고, first-order derivation (second order polynomial, 11 smoothing points)을 적용하였다. 스펙트럼에 S-G 방법을 적용하기 전 signal-to-noise ratio 감소를 위하여 smoothing 처리하였다 [108]. SNV와 MSC 방법을 적용하기 전 noise 및 scatter effect 감소를 위하여 Savitzky-Golay smoothing 처리하였다 [109].

**Table 3. The specifications of the NIR spectrometer used for non-destructive measurement of sweet potato**

Item	Specification
Light source	Halogen tungsten lamps (JCR12V-100WBAU, USHIO, Tokyo, Japan)
Detector	InGaAs (Ava Spec-UV/VIS/NIR, AVANTES, Apeldoorn, Netherlands)
Wavelength	500–2,500 nm
Resolution	1 nm
Scan	16



**Figure 10.** Setting of (A) laboratory experimental device and (B) industrial device for measuring NIR spectrum of sweet potato. 1, NIR light source; 2, sweet potato (sample); 3, sample holder; 4, detector; and 5, conveyor belt.

## B. NIR을 이용한 고구마 재배 후 내부 품질 예측

고구마의 내부 품질 예측을 위하여 PLS model을 이용하여 calibration model을 생성하였다 (Figure 11). 높은 Q residual과 Hotelling's  $T^2$  value를 가진 12개의 sample은 outlier로 판단하여 제외하고 모델링하였다. PLS model의 validating을 위하여 총 132개 sample은 calibration set (100개 sample)과 prediction set (32개 sample)으로 무작위로 분류하였다. PLS는 일반적으로 종속변수 예측을 위한 linear regression model이며, 독립변수와 종속변수의 높은 상관관계를 갖는 latent variable (LV)을 사용한다. Spectrum의 calibration model 생성 시 많이 사용하는 방법이다. 생성된 calibration model의 error를 계산하기 위하여 cross-validation set를 생성하였다 [110]. PLS model의 prediction ability 및 accuracy를 평가하기 위하여, calibration model, prediction model, cross-validation model에 대한 fitting correlation coefficients ( $R_c^2$ ,  $R_p^2$ ,  $R_{CV}^2$ )와 root-mean-square errors (RMSEC, RMSECV, RMSEP)를 확인하였다. PLS model의 robustness를 평가하기 위하여 RMSEP/RMSECV와 RPD 값 (standard deviation에 대한 prediction model의 standard error)을 확인하였다. PLS model의 RMSEP/RMSECV 값이 1.2 미만이면 model의 performance가 robust하고 accurate하다고 가정하였다 [111, 112]. RPD 값이 2 이상이면 높은 prediction capability, 1.5~2 사이는 중간 prediction capability, 1.5 미만은 낮은 prediction capability를 갖는다 [113].

## C. NIR을 이용한 고구마 재배 후 품질 분류

LDA는 PLS model의 calibration set의 NIR spectrum으로 분석하였다. 수분 및 전분 함량은 5개의 class로 분류하였고, MATLAB (2019a, MathWorks, MA, USA)을 이용하여 분석하였다. LDA는 dimension을 감소하고, class 간 ratio를 최대화하여 spectrum을 분류한다 [114].

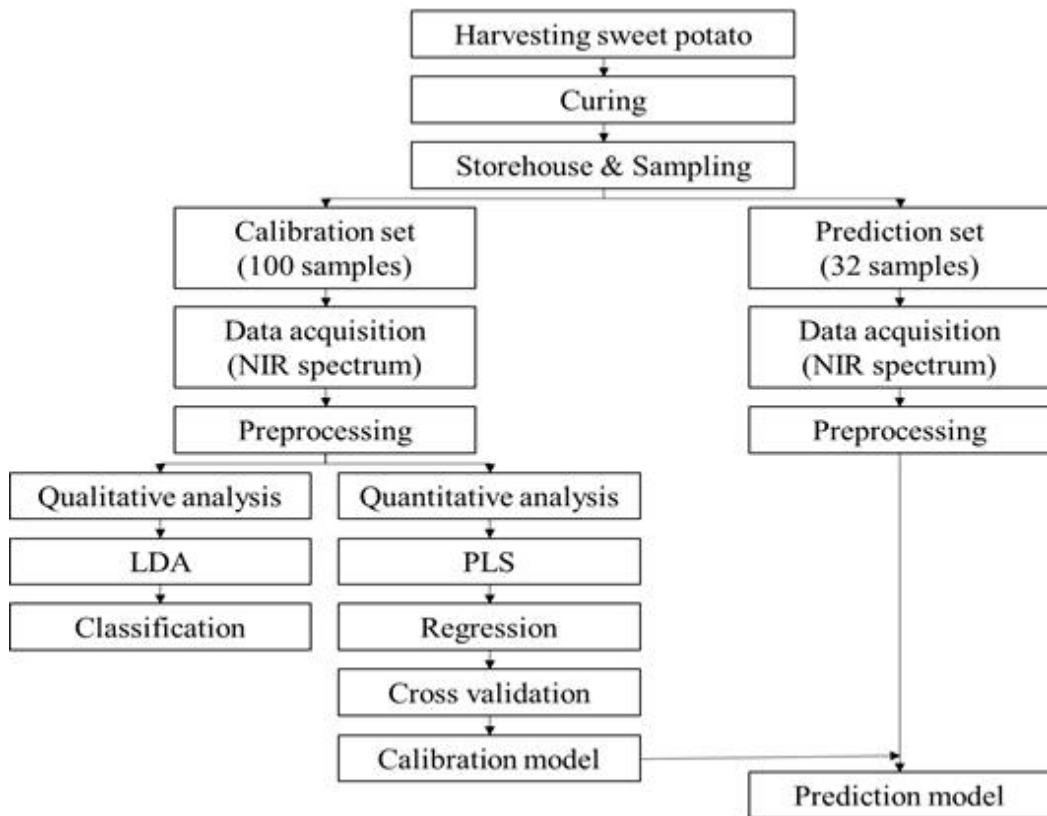
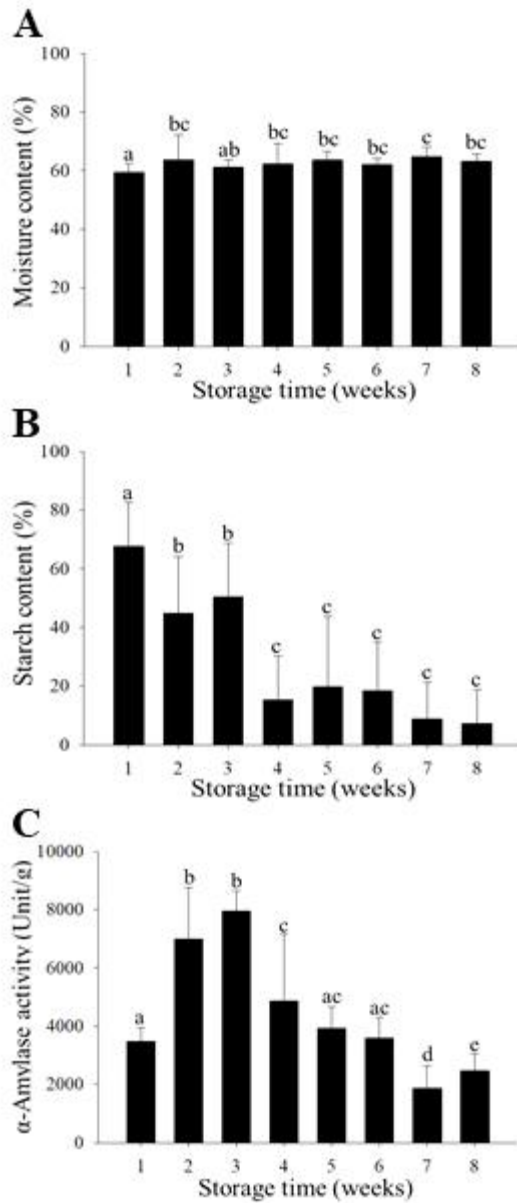


Figure 11. Schematic of NIR spectrum analysis applied to develop the prediction model using classification and regression of the internal quality of sweet potatoes.

## 제3절 실험결과 및 토의

### 1. 저장기간동안 품질 특성 변화 측정

Figure 12와 Table 4는 고구마 재배 후 8주의 저장기간동안 내부 품질인 수분, 전분,  $\alpha$ -amylase 함량 변화 측정 결과이다. 수분 함량은 59.44 - 64.83 wt%였으며, 이는 저장창고 내 습도 조절을 통하여 일정하게 유지된 것으로 판단된다 (Figure 12A). 전분 함량은 저장기간이 증가할수록 감소하였다 (Figure 12B). Figure 13은 구운고구마 단면이며, amylase와 같은 전분 분해효소에 의한 전분이 완전히 분해된 고구마 단면과 전분이 완전히 분해되지 않은 고구마 단면으로서 육안으로도 확인이 가능하다. Figure 12C와 같이 보관기간동안  $\alpha$ -amylase 활성은 3주까지 증가한 이후 감소하였고, 보관 3주째  $\alpha$ -amylase 활성은 7839 units/g으로 가장 높았다.  $\alpha$ -Amylase 활성이 증가했던 보관 3주째 이후 전분 함량이 감소하였다. 이는 고구마의 일반적인 전분 가수분해 현상이다. Agnes 등 (2012)은 우간다에서 재배된 5가지 고구마 품종의  $\alpha$ -amylase 활성 변화를 재배 후 8주동안 측정하였다 [115].  $\alpha$ -Amylase 활성은 고구마 과육 색 (cream, white, orange, pale orange)에 따라 다른 것을 확인하였고, 모든 품종이 보관 3주째 가장 높은  $\alpha$ -amylase 활성을 나타내었으며, 이는 본 연구와 동일한 결과이다. Hagenimana 등 (1992)은 고구마에 함유된  $\alpha$ -amylase를 immunological detection과 활성 측정을 통해 확인하였다 [116]. Immunological detection 결과 고구마의 laticifer, cambium, parenchyma tissues와 같은 껍질과 가까운 바깥 부분에서  $\alpha$ -amylase를 확인하였고, 중심 부분에서는  $\alpha$ -amylase를 확인하지 못하였다.  $\alpha$ -Amylase 활성은 고구마를 바깥 부분과 중심 부분으로 분리하여 측정하였으며, 측정 결과 바깥 부분이 중심 부분보다 활성이 더 높았다. 따라서  $\alpha$ -amylase는 고구마 수확 후 바깥 부분에서 분비되는 것을 확인하였다. Sarikaya 등 (2000)은 *Bacillus amyloliquefaciens*와 *B. cereus*가 생성한  $\alpha$ -amylase 및  $\beta$ -amylase의 전분 분해능을 측정하였다 [117]. 두 종류의  $\alpha$ -amylase는 다른 분해 패턴을 보였고,  $\alpha$ -amylase의 분해능은  $\beta$ -amylase보다 더 높았다. Nabubuya 등 (2017)은 8주의 저장기간동안 고구마의 포도당과 전분 함량 변화를 측정하였다 [93]. 실험결과 저장 기간이 증가할수록 포도당 함량은 증가하고, 전분 함량은 감소하는 것을 확인하였다. 또한, 전분 함량 감소는 고구마 분말의 점도 감소에 영향을 주는 것을 확인하였다.




**Figure 12.** Changes in internal quality in terms of (A) moisture, (B) starch, and (C)  $\alpha$ -amylase content of sweet potatoes during storage (Letters indicate significant differences,  $p < 0.05$ ).



**Table 4. Changes in internal quality in terms of moisture, starch, and  $\alpha$ -amylase content of sweet potatoes during storage**

Quality parameters	Week	Mean	SD	Range
Moisture	1	59.44	3.18	45.36–62.77
	2	63.66	8.42	58.32–76.91
	3	61.14	2.52	57.12–66.41
	4	62.22	7.07	26.79–68.38
	5	63.60	3.09	58.41–71.03
	6	62.21	1.93	58.81–65.54
	7	64.83	3.26	59.97–74.83
	8	63.32	2.40	59.42–68.48
Starch	1	67.71	14.89	32.67–85.66
	2	44.98	19.08	5.89–76.98
	3	50.44	17.38	3.48–74.60
	4	15.28	15.09	0.39–50.79
	5	19.87	23.52	0.17–66.43
	6	18.53	16.29	0.039–61.11
	7	8.92	12.54	0.056–39.57
	8	7.24	11.42	0.069–49.79
$\alpha$ -Amylase	1	3486.08	461.15	2641.81–4520.33
	2	7002.27	1755.64	2143.18–9825.00
	3	7956.66	685.36	6508.31–9066.51
	4	4867.27	2278.49	841.67–9332.58
	5	3938.13	728.16	2915.91–6340.15
	6	3592.93	709.74	2226.52–5294.70
	7	1875.86	768.40	76.52–2984.09
	8	2467.42	583.72	946.21–3681.06



**Figure 13. (A) Cross-section of baked sweet potato completely decomposed by amylase, and (B) cross-section of baked sweet potato with starch, owing to incomplete starch degradation.**

## 2. 비파괴 기술을 이용한 품질 특성 측정

### 가. NIR spectrum 특성

Figure 14A는 고구마의 NIR raw spectrum이며, 약 970 nm 및 1270 nm에서 main peak를 나타낸다. Figure 14 B-D는 raw spectrum을 S-G, SNV, MSC 전처리한 spectrum이다. NIR spectrum은 수분에 영향을 많이 받아 측정 시 유의해야 한다. Luck 등 (1974)은 NIR spectrum에서 970 nm, 1190 nm, 1450 nm, 1940 nm에서 -OH stretching 및 bending peak를 확인하였다 [118]. 물 (water)은 다양한 유기화합물과 결합을 형성하여 NIR 흡수 파장의 이동을 유발할 수 있다 [119]. 또한, NIR spectrum은 overlapping absorption에 의한 broad한 peak 형태를 가지며, 이는 C-H, N-H, O-H 결합의 진동에 대한 combination과 overtone의 흡수에 대한 결과이다 [120]. 본 연구에서 NIR spectrum은 수분 함량의 영향을 받는 것으로 확인되었다. 상온, 상습에서 보관하여 약 30% 수분 함량을 갖는 고구마의 NIR spectrum을 측정하였고, 측정 결과 970 nm의 peak는 약해지고 1270 nm의 peak는 상대적으로 강하게 유지되는 것을 확인하였다 (Figure 15). 970 nm 및 1270 nm peak는 각각 O-H, C-H 결합의 stretching에 대한 2번째 overtone이며, 수분 함량 감소에 의한 수소 결합 변화에 의하여 peak의 강도가 변화한 것을 확인하였다.

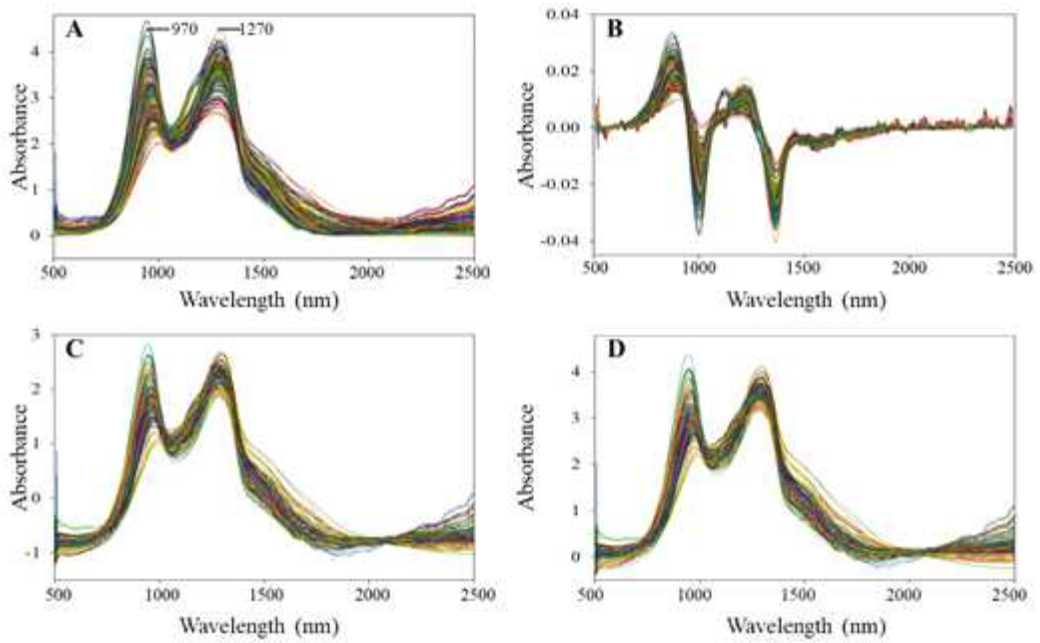



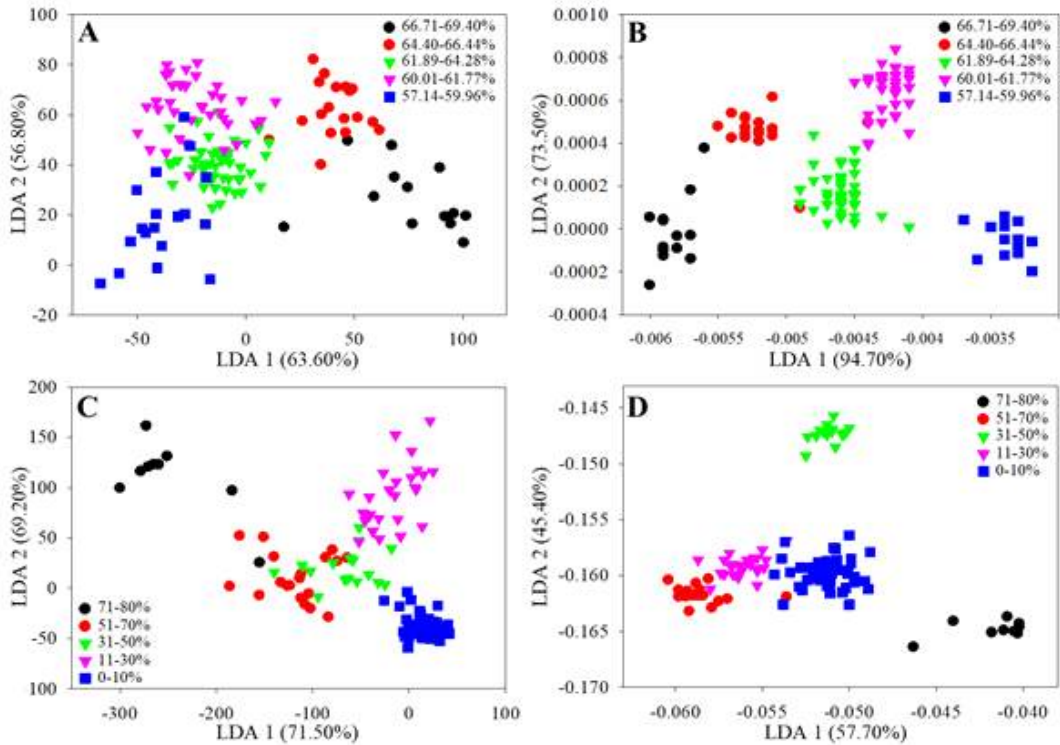
Figure 14. (A) NIR raw spectrum. Preprocessed spectrum captured through (B) S-G, (C) SNV, and (D) MSC for the sweet potatoes.



**Figure 15. NIR raw spectrum of sweet potatoes with low moisture content (Legend shows moisture content of sweet potatoes).**

## 나. NIR을 이용한 고구마 재배 후 품질 분류

LDA는 고구마의 수분 및 전분 함량의 정성적 discriminant model로 분류하기 위하여 분석하였다 (Figure 16). LDA 분석 시 PLS의 수분 함량 prediction set 중 performance가 높았던 S-G 전처리 spectrum, 전분 함량 prediction set 중 performance가 높았던 SNV 전처리 spectrum을 사용하였다. 수분 함량에 대한 raw spectrum의 LDA 분석 결과 class 간 경계가 애매하였지만, S-G 전처리 spectrum의 LDA 분석 결과 class 간 경계가 확실한 것을 확인하였다. 전분 함량에 대한 raw spectrum의 LDA 분석 결과 class 간 경계가 애매하였지만, 0% - 10% 및 71% - 80%의 class 간은 경계가 확실하게 분류되었다. 전분 함량에 대한 SNV 전처리 spectrum의 LDA 분석 결과 0% - 10%, 11% - 30%, 51% - 70%의 class 간 경계는 가까웠지만 class 간 경계는 명확하게 분류되었다. Ding 등 (2015)은 자색고구마 건조 분말과 흰색고구마 건조 분말을 일정한 비율로 혼합하여, NIR spectrum을 측정하여 LDA 분석을 통해 혼합비로 분류하였다 [121]. De Carvalho 등 (2016)은 사탕수수의 재배 지역을 분류하기 위하여 NIR raw spectrum과 S-G 및 MSC 전처리 spectrum을 이용하여 LDA 분석하였다 [122]. LDA의 분류 정확도는 S-G 및 MSC 전처리 spectrum이 raw spectrum보다 더 높았다.



**Figure 16. Linear discriminant analysis results for internal quality of sweet potatoes based on moisture ((A) analysis by raw spectrum and (B) S-G preprocessed spectrum) and starch content ((C) analysis based on raw spectrum and (D) SNV preprocessed spectrum).**

## 다. NIR을 이용한 고구마 재배 후 내부 품질 예측

Table 5는 NIR로 수집한 고구마의 raw spectrum 및 S-G, SNV, MSC 전처리 spectrum으로 수분 및 전분 함량 예측을 위한 PLS model의 calibration, cross-validation, prediction 결과이다. Figure 17-24는 각 spectrum 및 내부 품질에 대한 regression plot과 regression coefficient plot이다. 수분 함량에 대한 PLS model performance는 S-G 전처리 spectrum이 calibration set에서  $R_c^2$  값은 0.7878, RMSEC 값은 1.1147으로 가장 높았고, prediction set에서는 MSC 전처리 spectrum이  $R_p^2$  값은 0.8065, RMSEP 값은 1.2480으로 가장 높았다. 전분 함량에 대한 PLS model performance는 SNV 전처리 spectrum이 calibration set에서  $R_c^2$  값은 0.8320, RMSEC 값은 10.5383으로 가장 높았고, prediction set에서는 MSC 전처리 spectrum이  $R_p^2$  값은 0.7811, RMSEP 값은 11.4115으로 가장 높았다. 수분 함량 prediction set의 PLS model performance는 raw spectrum보다 S-G, SNV, MSC 전처리 spectrum의 정확도가 높았다. 모든 PLS model의 RMSEP/RMSECV 값은 0.771-1.0424 사이로서 1.2보다 낮아 model의 performance가 robust하고 accurate하다고 판단된다. 또한, RPD 값은 1.0211-2.1749 사이로서 중간 또는 높은 prediction capability를 갖는 것으로 판단된다.  $\alpha$ -Amylase 활성 예측에 대한 PLS 모델링을 하였지만, calibration set과 prediction set의  $R^2$  값이 모두 0.2 이하로서 실험 결과에 포함하지 않았다. Farhadi 등 (2020)은 감자의 품질 특성인 전분, 당, 수분 함량을 VIS/NIR spectroscopy와 PLS model로 예측하였다 [123]. Rady 및 Guyer (2015)은 NIR reflectance spectroscopy을 이용하여 파괴되지 않은 감자와 슬라이스된 감자의 glucose 및 sucrose 함량을 예측 및 분류하였다 [103]. Lu 등 (2006)은 NIR reflectance spectroscopy와 PLS model을 이용하여 고구마 전분의 물리화학적 특성 (아밀로오스 함량, 전분 함량, 단백질 함량, 용해도, 페이스트 점도 등)을 예측하였다 [124]. Prediction set의  $R_p^2$  값은 0.614 - 0.917 범위였으며, NIR spectrum과 고구마 전분의 물리화학적 특성은 높은 상관관계가 있었다. 따라서 고구마 전분은 NIR spectrum에 영향을 미치며, PLS model을 이용하여 전분 함량 예측이 가능할 것으로 판단된다.

고구마 내부품질인 수분 및 전분 함량을 예측하기 위하여 regression model인 PLS, classification model인 LDA를 사용하였다. Regression model을 이용하면 정량 수치를 얻을 수 있으며, 정량 수치를 기반으로 classification이 가능하다. 그러나 전분 함량에 대한 PLS model의 RMSEC 값의 범위는 10.54 - 16.61%로서 비교적 높

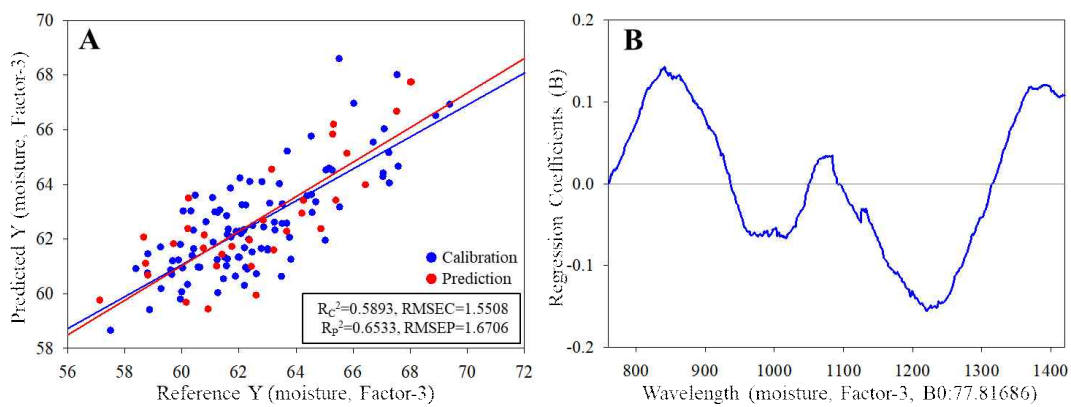


은 오차값을 나타내었다. 이는 전분 함량의 측정값 범위가 0.039 - 85.66%로서 매우 넓은 범위를 가지고 있어 RMSEC 값이 높게 측정된 것으로 판단된다. PLS model을 이용한 전분 함량 측정 시 rough prediction 및 classification이 가능하다. 본 연구에서는 넓은 측정값의 범위에 영향을 받지 않고, 독립변수로만 분석이 가능한 classification model을 개발하기 위하여 LDA 분석도 진행하였다. 그러나 LDA 분석은 데이터 분포를 기반으로 model의 정확도를 나타낼 수 있고, model의 performance를 측정할 수 있는 parameter 분석이 불가능한 단점을 가지고 있다. 이러한 단점을 보완하기 위하여 classification model인 PLS-DA model을 사용하기도 한다 [125]. 그러나 PLS-DA는 독립변수와 종속변수의 연관성을 기반으로 classification model을 생성하기 때문에 본 연구에서는 LDA 분석을 이용하였다.

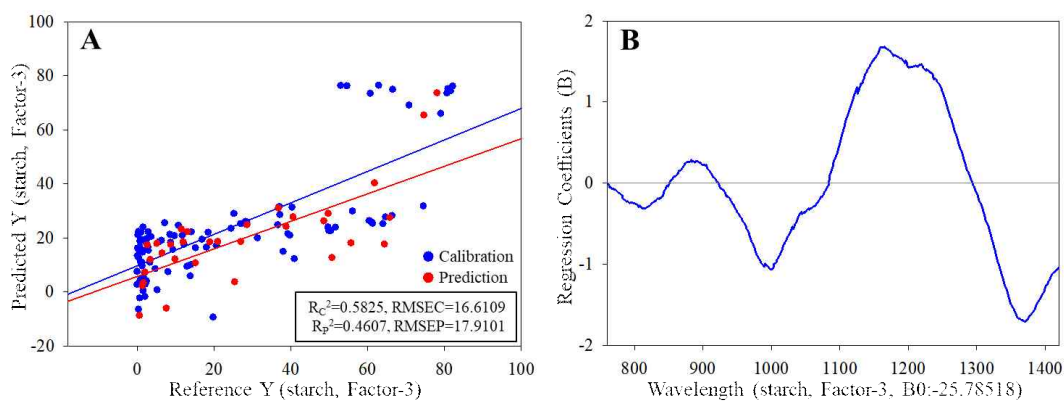
**Table 5. Calibration, cross-validation, and prediction results of PLS model for assessing internal quality of sweet potatoes**

Quality parameters	LVs	Calibration		Cross-validation		Prediction		RMSEP/ RMSECV	RPD
		$R_c^2$	RMSEC	$R_{cv}^2$	RMSECV	$R_p^2$	RMSEP		
<b>Raw spectrum</b>									
Moisture	3	0.5893	1.5508	0.5698	1.6027	0.6533	1.6706	1.0424	1.3258
Starch	3	0.5825	16.6109	0.5538	17.3473	0.4607	17.9101	1.0324	1.0211
<b>Savitzky-Golay derivative</b>									
Moisture	7	0.7878	1.1147	0.6920	1.3520	0.8031	1.2590	0.9312	2.1655
Starch	4	0.7303	13.3509	0.6896	14.4122	0.6462	14.5069	1.0066	1.6605
<b>SNV</b>									
Moisture	8	0.7715	1.1568	0.6919	1.3551	0.8047	1.2539	0.9253	2.0036
Starch	9	0.8320	10.5383	0.7688	12.5890	0.7722	11.6418	0.9248	2.1288
<b>MSC</b>									
Moisture	7	0.7531	1.2024	0.7175	1.4021	0.8065	1.2480	0.8901	2.0136
Starch	8	0.7734	12.2385	0.6784	14.8012	0.7811	11.4115	0.7710	2.1749

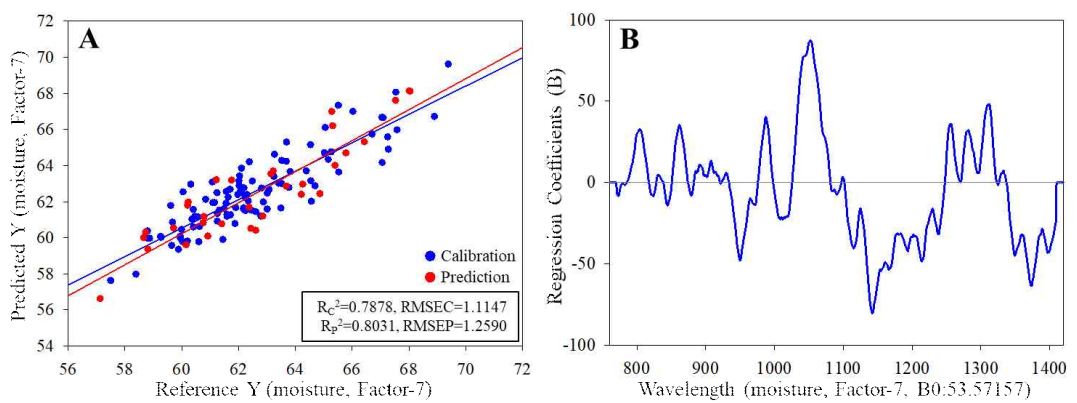
LV\_Latent variable,  $R_c^2$ \_Correlation coefficient of calibration, RMSEC\_Root-mean-square errors of calibration,  $R_{cv}^2$ \_Correlation coefficient of cross-validation, RMSECV\_Root-mean-square error of cross-validation,  $R_p^2$ \_Correlation coefficient of prediction, RMSEP\_Root-mean-square errors of prediction, RPD\_Relative percent difference.



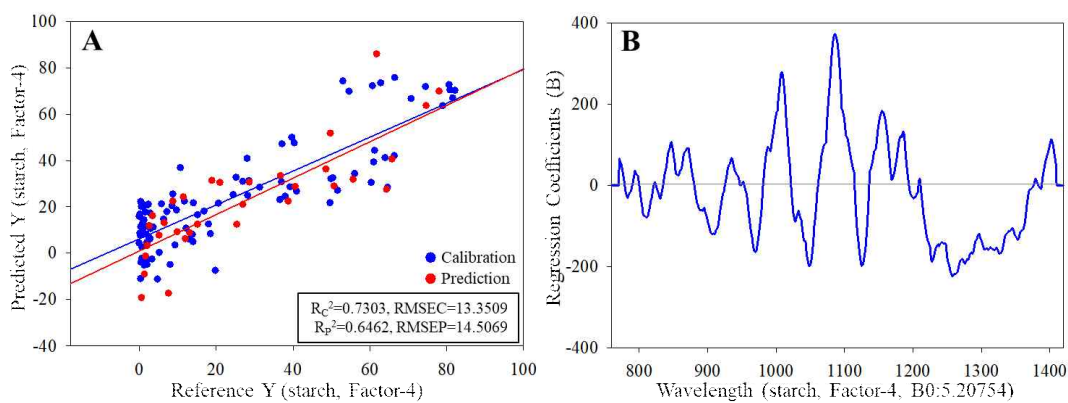
**Figure 17. (A) Regression plot and (B) regression coefficient plot of partial least squares (PLS) modeling about calibration and prediction set for raw spectrum and moisture content of sweet potatoes.**



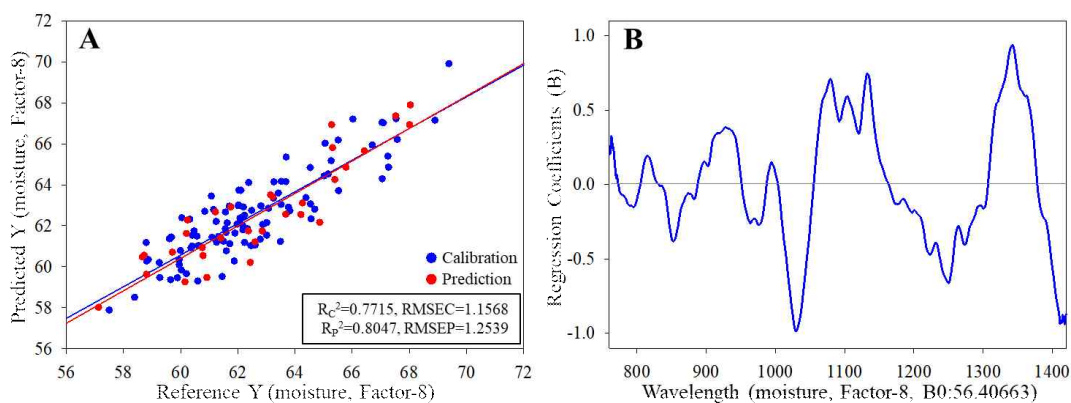
**Figure 18. Regression plot and (B) regression coefficient plot of PLS modeling about calibration and prediction set for raw spectrum and starch content of sweet potatoes.**



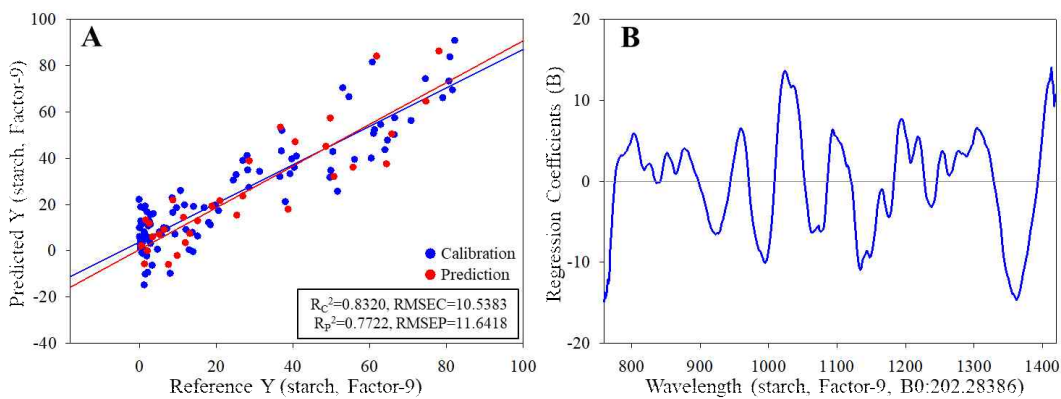
**Figure 19. (A) Regression plot and (B) regression coefficient plot of PLS modeling about calibration and prediction set for Savitzky-Golay (S-G) preprocessed spectrum and moisture content of sweet potatoes.**



**Figure 20. (A) Regression plot and (B) regression coefficient plot of PLS modeling about calibration and prediction set for S-G preprocessed spectrum and starch content of sweet potatoes.**

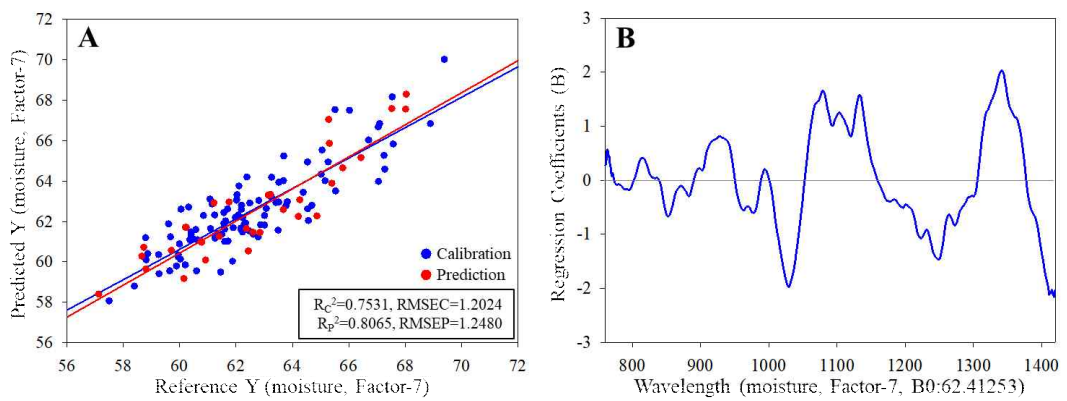


**Figure 21. (A) Regression plot and (B) regression coefficient plot of PLS modeling about calibration and prediction set for standard normal variate (SNV) preprocessed spectrum and moisture content of sweet potatoes.**

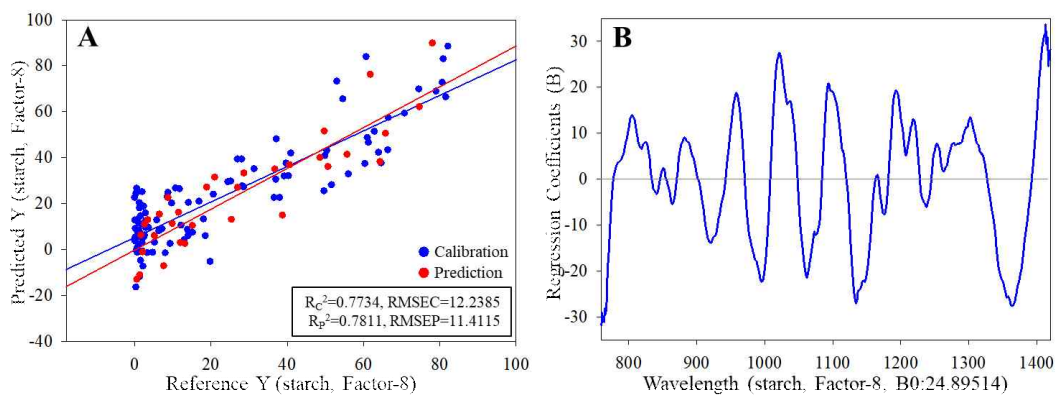


**Figure 22. (A) Regression plot and (B) regression coefficient plot of PLS modeling about calibration and prediction set for SNV preprocessed spectrum and starch content of sweet potatoes.**





**Figure 23. (A) Regression plot and (B) regression coefficient plot of PLS modeling about calibration and prediction set for multiplicative scattering correction (MSC) preprocessed spectrum and moisture content of sweet potatoes.**



**Figure 24. (A) Regression plot and (B) regression coefficient plot of PLS modeling about calibration and prediction set for MSC preprocessed spectrum and starch content of sweet potatoes.**

## 제4절 요약

고구마의 산업적 대량 가공에 적합한 원물 내부 품질 측정을 위한 비파괴적 NIR 측정 기술을 개발하였다. 수분 및 전분 함량,  $\alpha$ -amylase 활성을 포함한 고구마의 내부 품질을 재배 후 저장기간동안 측정하였다. PLS 모델링 결과  $\alpha$ -amylase 활성을 제외한 수분 및 전분 함량은 NIR spectrum을 이용하여 예측이 가능하였다. 또한, NIR spectrum을 LDA 분석을 통하여 수분 및 전분 함량에 대한 5개의 class로 분류가 가능한 것을 확인하였다. 본 연구에서는 고구마를 고정시킨 후 NIR spectrum을 측정하였다. 이전 연구에서는 로드셀에 고구마를 올린 후 컨베이어벨트 상에서 NIR spectrum 측정 가능성을 확인하였다. 컨베이어벨트 상에서 NIR spectroscopy 기술과 PLS 또는 LDA model 적용을 통한 고구마 내부 품질 예측 및 분류 기술은 빠른 시일 내에 대량 가공 공정에서 적용할 수 있다고 판단된다.

## 제3장 Response Surface Methodology 및 Artificial Neural Network Model을 이용한 pilot-scale의 감압후라이드 고구마칩 제조 공정 최적화

### 제1절 서론

식품제조 공정에서 최적화의 목적은 공정 내 최고의 출력을 갖는 조건을 탐색하는 것이다 [126]. 과거 식품 공정 최적화는 1개의 매개변수에 대해서만 최적화하여 최고의 출력값을 탐색하였다. 그러나 여러 가지 변수가 품질에 영향을 미치는 식품 공정에서는 변수 간의 상호작용 효과가 고려되지 않고, 요인이 품질에 미치는 영향을 설명하기 부족한 단점이 있었다 [127]. 특히, 농산물 기반 가공식품 제조 시 원물의 구성성분이 상이하기 때문에 제어 불가능한 오차가 항상 수반된다 [128]. 이러한 complexity를 해결하고, 식품 공정의 최적화를 위하여 multivariate statistic method인 RSM, ANN을 적용하는 연구가 진행 중이다. [129–131].

RSM은 독립요인과 종속요인 간의 통계적 모델링을 기반으로 하고, 실험값을 2차 다항식에 fitting한다. RSM은 식품 제조 공정 및 전처리 공정에서 조건 최적화를 통한 생산 및 품질을 극대화하는데 사용한다. 한편 ANN은 신경 세포 또는 뉴런으로 구성된 생물학적 신경계의 단순화된 모델이고, input layer, hidden layer, output layer로 구성된다. ANN은 식품 품질 분석, 식품 이미지 분석, 식품 가공과 같은 다양한 응용 분야에 활용되어지고 있다 [132]. ANN은 비선형 방식의 모델이기 때문에, 불완전한 정보로도 모델을 생성하여 반응값 (response)을 예측할 수 있다. ANN은 RSM에 비하여 복잡한 data를 유연하고 정확하게 모델링할 수 있다. 최근 식품 가공 분야에서 반응값 예측을 위한 RSM과 ANN의 모델 연구가 활발하게 진행 중이다. Yang 등 (2019)은 kidney bean의 phenolic compound 추출 최적 조건을 RSM과 ANN을 이용하여 모델링하였고, 성능을 비교하였다 [131]. Tang 등 (2017)은 호박의 osmotical dehydration 공정 조건에 대한 품질 예측 모델을 RSM, ANN으로 모델링하였다 [133]. Onu 등 (2020)은 potato slice 건조 공정 조건에 대한 품질 예측 모델을 RSM, ANN으로 모델링하였다 [53].

본 연구에서는 감압후라이드 기술을 이용하여 고구마칩 제조 공정에 대한 식품 품질 최적화를 위한 사례를 분석하였다. 최근 건강에 대한 관심이 증가하면서 식품

트렌드는 프리미엄 및 웰빙화되었다. 감자칩과 같이 간식으로 섭취되는 스낵은 유탄처리제품으로서 상압에서 140℃ 이상의 고온에서 튀겨지며, 이를 deep frying이라고 한다. 그러나 튀김 시 기름의 가열 및 산화 반응이 발생하여 트랜스 지방, 극성 화합물 등과 같은 유해한 성분이 생성된다 [134]. 이와 같은 상압후라이잉을 단점을 보완하기 위하여 감압후라이잉 (vacuum frying) 기술이 개발되었으며, 감압후라이잉은 기름을 열매체로 하여 감압 하에서 원료의 수분을 기화시키는 방법이다 [135, 136]. 상압후라이잉보다 낮은 유온 (80–140℃)을 사용하고, 낮은 산소 농도로 인하여 기름의 가열 및 산화 반응이 상압후라이잉에 비하여 현저히 감소한다. 따라서 감압후라이드 제품은 유해 성분 함량이 낮으며, 비교적 건강한 스낵 제품을 섭취할 수 있다.

기존의 연구는 RSM을 이용하여 감압후라이드 고구마칩의 제조 공정 최적화에 대한 연구는 있었지만, 전처리 공정에 대한 조건은 포함되지 않았다 [137–139]. 또한, RSM과 ANN을 이용하여 감압후라이드 고구마칩의 품질 예측 모델을 모델링하거나, 비교한 연구는 없었다. 본 연구에서는 감압후라이드 고구마칩 제조 시 전처리 및 vacuum frying 공정 조건을 포함하는 변수에 대한 품질 예측 모델 개발을 위하여 RSM과 ANN 모델링하였고, 2가지 모델의 성능을 비교하였다. 전처리 공정 조건을 최적화한 결과 고구마칩의 기호도가 향상되었다. 추후 향미 성분 분석 및 관능평가를 통하여 고구마칩의 제조 공정 최적화와 기호도 향상에 대한 연관성을 연구할 예정이다.

## 제2절 재료 및 방법

### 1. 재료

본 실험에서는 베니하루카 (*B. Haruka*) 품종의 꿀고구마를 사용하였으며, 공덕농협농산물가공사업소 (전라북도 김제시)에서 구입하였다. 고구마를 세척 후 1.5 mm 두께로 슬라이스하여 전처리하였다. 감압후라이딩 시 오일은 팜유 (Tradekey, CONTINENTAL RESOURCES SDN BHD, Selangor, Malaysia)를 사용하였다.

### 2. 감압후라이드 고구마칩 제조 공정

#### 가. 전처리

감압후라이드 고구마칩 제조 공정 최적화를 위하여 전처리 조건인 osmotic dehydration (OD)의 concentration 및 temperature를 최종 핵심인자로 선별하여 감압후라이드 제조 공정의 독립변수로 설정하였다. 기존의 과일 및 야채의 OD 연구를 참고하여, 방법을 변형하여 실험하였다 [140]. OD 전처리 시 정제포도당 (ES Ingredients, Gyeonggi-do, South Korea)을 이용하였으며, 농도 별로 정제포도당 용액을 제조하였다. 슬라이스한 고구마를 central composite design (CCD) design 조건에 따라서 concentration 및 temperature를 맞춘 정제포도당 용액에 3시간동안 침지시켰다 (Table 6). 침지 후 정수물로 1회 세척 후 3일동안 냉동 후 감압후라이딩하였다.

#### 나. 감압후라이딩

감압후라이드 고구마칩 제조 공정 최적화를 위하여 VF의 temperature를 최종 핵심인자로 선별하여, 독립변수로 설정하였다. CCD design의 조건에 따라서 vacuum frying 온도를 설정하였고 (Table 6), 시간은 20분으로 설정하였다. 감압후라이딩 시 키요모토코리아의 vacuum frying 장비 및 팜 오일을 사용하였다 (Figure 25A) [141]. Cylinder는 고구마 원물이 담겨있는 basket을 상하 이동 및 탈유하는 장치이다. Water condenser는 감압후라이딩 시 발생하는 수분 응축 및 배출하는 장치이다. Frying chamber는 오일로 채워진다. Frying basket inlet은 basket 투입구이다. Air compressor는 cylinder를 작동하는 장치이다. Controller는 감압후라이딩 장비 전체를

조작 및 제어한다. Chiller unit은 냉각수 저장 및 온도 유지 기능을 한다. Vacuum pump는 감압후라인 장비 내 감압 환경을 유지시켜준다. 감압후라인 시 약 장비 내부의 압력은 약 2 kPa로 유지된다. 감압후라인 완료 후 3분동안 de oil하였다.

**Table 6. Central composite design and responses of dependent variables for the vacuum-fried sweet potato chip manufacturing process to independent variables**

Run	Independent variables			Response		
	X <sub>1</sub> <sup>a</sup> (%)	X <sub>2</sub> (°C)	X <sub>3</sub> (°C)	Y <sub>1</sub> (%)	Y <sub>2</sub> (%)	Y <sub>3</sub>
1	70 (1)	60 (1)	80 (-1)	49.40	11.90	69.87
2	45 (0)	40 (0)	95 (0)	47.80	9.90	75.09
3	45 (0)	40 (0)	95 (0)	50.40	10.00	70.75
4	2.96 (-1.68)	40 (0)	95 (0)	40.80	23.70	81.79
5	70 (1)	20 (-1)	110 (1)	47.00	12.70	78.97
6	45 (0)	40 (0)	120.23 (1.68)	52.00	15.20	92.82
7	45 (0)	40 (0)	95 (0)	53.40	14.40	64.28
8	45 (0)	40 (0)	95 (0)	52.00	12.00	64.11
9	20 (-1)	60 (1)	110 (1)	41.60	19.70	89.15
10	45 (0)	73.64 (1.68)	95 (0)	40.60	20.50	61.72
11	45 (0)	6.36 (-1.68)	95 (0)	51.50	23.60	70.25
12	45 (0)	40 (0)	69.77 (-1.68)	51.80	16.20	67.76
13	45 (0)	40 (0)	95 (0)	52.90	14.70	58.26
14	70 (1)	60 (1)	110 (1)	49.50	13.50	80.16
15	20 (-1)	20 (-1)	110 (1)	45.00	25.40	83.36
16	70 (1)	20 (-1)	80 (-1)	48.00	14.10	78.67
17	20 (-1)	20 (-1)	80 (-1)	42.70	25.10	80.23
18	45 (0)	40 (0)	95 (0)	55.40	8.40	62.61
19	87.04 (1.68)	40 (0)	95 (0)	45.00	19.60	68.35
20	20 (-1)	60 (1)	80 (-1)	42.70	22.00	73.35

<sup>a</sup> X<sub>1</sub>, osmotic dehydration (OD) concentration (%); X<sub>2</sub>, OD temperature (°C); X<sub>3</sub>, vacuum frying temperature (°C); Y<sub>1</sub>, yield; Y<sub>2</sub>, oil content; Y<sub>3</sub>, browning index.

<sup>b</sup> Uncoded level (coded level) for independent variables.



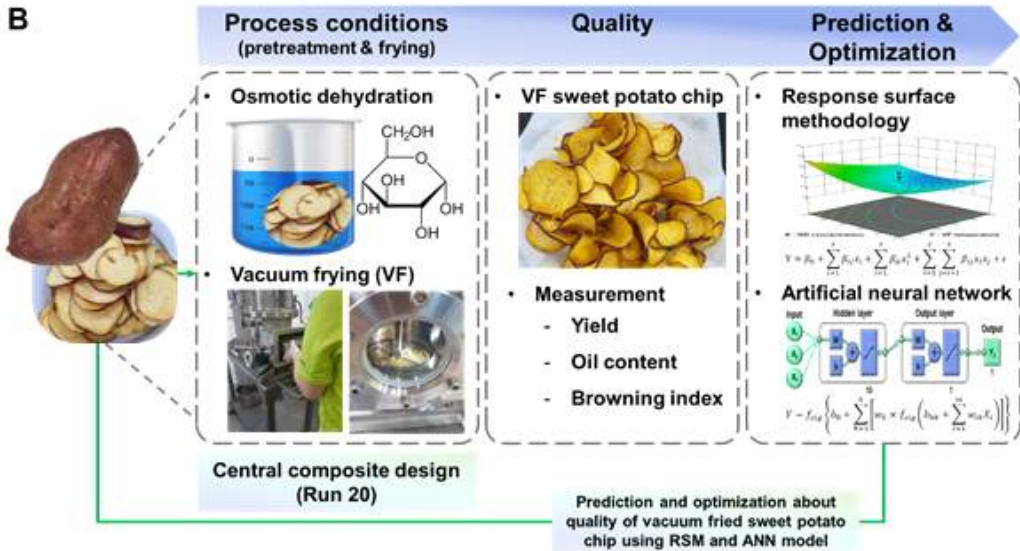



Figure 25. Vacuum frying machine used in the experiment [141]. (B) An overview of predicting and optimizing the vacuum-frying process for sweet potato chip manufacturing using response surface methodology and an artificial neural network model.

## 다. 품질 측정

### A. 수율 (yield)

감압후라이징 진행 시 1회 batch에 사용되는 고구마 원물의 무게 ( $W_0$ )를 측정하였고, 감압후라이징 후 de-oil까지 완료한 고구마 원물의 무게 ( $W_1$ )를 측정하여 다음과 같은 식으로 수율을 계산하였다.

$$Yield(\%) = \frac{W_1}{W_0} \times 100$$

### B. 오일 함량 (oil content)

Soxhlet 방법으로 시료의 오일 함량을 측정하였다. Ethyl ether를 용매로 사용하여 6시간동안 50℃에서 10 g의 감압후라이징 고구마칩을 추출하였다. 추출물은 감압 농축하여 오일 함량을 계산하였고, 시료 당 3회 반복 측정하였다.

### C. 갈변지수 (browning index, BI)

시료를 분쇄하여 20 mesh sieve로 일정한 크기의 powder를 petri dish에 모아 색차계 (ColorMeter Pro, CHN Spec, Zhejiang Province, China)로 색도를 측정하였다. 색도는 L (lightness), a (redness) 및 b (yellowness) 값으로 나타내었고, 시료 당 10회 반복 측정하여 평균값을 이용해 다음과 같은 식으로 갈변지수를 계산하였다 [142].

$$x = \frac{a + 1.75L}{5.645L + a - 3.012b}$$

$$BI = \frac{100(x - 0.31)}{0.17}$$

### 3. 제조 공정 최적화

#### 가. RSM 모델

감압후라이드 고구마칩 제조 공정 최적화를 위하여 OD concentration (% ,  $X_1$ ), OD temperature ( $^{\circ}\text{C}$ ,  $X_2$ ), VF temperature ( $^{\circ}\text{C}$ ,  $X_3$ )를 독립변수로 사용하였고, 수율, 오일 함량, 갈변지수를 종속변수로 사용하였다. 데이터의 통계 분석, 반응표면모델 검증, 조건 최적화는 Design-Expert (version 13, StatEase, MN, USA)를 이용하였다. 중심합성계획법을 이용하여 실험을 설계하였으며, 예비실험을 거친 후 실험영역은 Table 6과 같이 5수준 (-1.68, -1, 0, 1, 1.68)로 코드화하여, 총 20회 실험을 수행하였다. 다중회귀분석 (multiple regression analysis)은 다음과 같은 second order polynomial quadratic equation에 의하여 수행되었다.  $y$ 는 predicted response,  $\beta_0$ 는 constant,  $\beta_i$ 는  $i^{\text{th}}$  linear coefficient,  $\beta_{ii}$ 는  $i^{\text{th}}$  quadratic coefficient,  $\beta_{ij}$ 는  $i^{\text{th}}$  interaction coefficient,  $x_i$ 는 independent variable,  $\varepsilon$ 는 error를 나타낸다.

$$y = \beta_0 + \sum_{i=1}^3 \beta_{ij}x_i + \sum_{i=1}^3 \beta_{ii}x_i^2 + \sum_{i=1}^2 \sum_{j=i+1}^3 \beta_{ij}x_ix_j + \varepsilon$$

#### 나. ANN 모델

RSM design을 기반으로 ANN 모델링을 하였으며, MATLAB (R2019a, Mathworks, Inc. MA, USA)의 neural network toolbox를 이용하였다 (Figure 26). Neural network는 데이터 수집, 네트워크 생성, 네트워크 구성, 가중치 및 편향 초기화, 네트워크 훈련, 네트워크 검증 및 네트워크 사용으로 구성된다. Multilayer perceptron network는 input layer, hidden layer, output layer로 구성된다. 총 20개의 샘플을 training sets (70%, 14개 샘플), validation sets (15%, 3개 샘플), testing sets (15%, 3개 샘플)로 나누어 모델링하였다. ANN 모델링 훈련 단계에서 실험값과 예측값의 mean square error (MSE)를 최소화하기 위하여 Levenberg-Marquardt back-propagation algorithm을 사용하였다.




Figure 26. ANN structure for vacuum-fried sweet potato chip manufacturing process.  $X_1$ , osmotic dehydration (OD) concentration (%);  $X_2$ , OD temperature ( $^{\circ}\text{C}$ );  $X_3$ , vacuum frying temperature ( $^{\circ}\text{C}$ ); (A)  $Y_1$ , yield (%); (B)  $Y_2$ , oil content (%); (C)  $Y_3$ , browning index.

## 다. RSM 및 ANN 모델 performance

RSM 및 ANN 모델의 성능은 correlation coefficient (R), coefficient of determination ( $R^2$ ), MSE, root mean square error (RMSE), mean absolute error (MAE), standard error of prediction (SEP), mean relative percent deviation (MRPD)에 의하여 통계적으로 확인하였다 [143]. 이러한 parameter는 다음과 같은 식에 의하여 계산되었다. n은 number of experiments,  $y_{p,i}$ 는 predicted outputs,  $y_{a,i}$ 는 experimental results,  $y_{a,ave}$ 는 average experimental results,  $y_{p,ave}$ 는 average predicted output, k는 sum of input factors를 나타낸다.

$$R = \frac{\sum_{i=1}^n (y_{p,i} - y_{p,ave})(y_{a,i} - y_{a,ave})}{\sqrt{[\sum_{i=1}^n (y_{p,i} - y_{p,ave})^2][\sum_{i=1}^n (y_{a,i} - y_{a,ave})^2]}}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{a,i} - y_{p,i})^2}{\sum_{i=1}^n (y_{p,i} - y_{a,ave})^2}$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{p,i} - y_{a,i})^2$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{p,i} - y_{a,i})^2}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{p,i} - y_{a,i}|$$

$$SEP (\%) = \frac{RMSE}{y_{a,ave}} \times 100$$

$$MRPD (\%) = \frac{1}{n} \sum_{i=1}^n (y_{p,i} - y_{a,i})^2 \times 100$$

## 라. RSM 및 ANN 모델 최적화

RSM 모델의 최적화는 Design-Expert 13 software를 사용하였다. ANN 모델의 최적화는 MATLAB의 optimization toolbox의 genetic algorithm (GA)으로 최적화하였다. GA는 다양한 neural network 모델을 최적화하는데 많이 이용되며, 생물의 진화를 모방하여 최적화하는 방법이다. 예측값에 대한 evaluation, selection, crossover, mutation을 통하여 오차가 가장 낮은 값을 선별하여 최적화한다.

## 4. Microstructure analysis

고구마칩의 튀김 방법 별 microstructure 분석을 위하여 주사전자현미경 (S-4800, Hitachi, Tokyo, Japan)를 이용하였다. SEM 분석 시 시료를 동결건조하여 수분을 제거하였다. 튀긴 고구마칩은 오일을 제거하기 위하여 hexane 용액에 1시간동안 침지한 후 건조하여 분석하였다. 수분 및 오일을 제거한 시료를 0.50 cm × 0.50 cm × 0.15 cm 크기로 제조 후 코팅하여, 15 kV의 accelerating voltage와 150 배율을 이용하여 분석하였다.

## 5. 통계

반복 실험 결과는 평균과 표준편차로 나타내었다. SPSS (version 26.0, IBM, NY, USA) 프로그램을 이용하여 분산분석 (ANOVA)을 실시하여 그룹 간의 유의성 ( $p < 0.05$ )을 확인하였다.

## 제3절 실험결과 및 토의

### 1. 감압후라이드 고구마칩 제조 공정

#### 가. 전처리

식품 조리 전 원물의 물리화학적 변화를 주는 것을 전처리라고 한다. 감압후라이딩 시 발생하는 단점 (낮은 갈변도 및 관능적 기호도)을 전처리를 통하여 개선할 수 있다. 식품 공정에서 많이 사용되는 전처리 방법은 slicing, blanching, predrying, osmotic dehydration, ultrasound, freezing, antibrowning agent, hydrocolloid coating 등이 있다 [144–147]. 전처리 과정 중 원물의 탈수 (수분 함량 감소), polyphenol oxidase 활성 저해, microstructure 변화가 발생하여 조리 후 제품 품질에 영향을 미친다 [148, 149]. 또한, 전처리 과정은 최종 제품의 수율, 오일 함량, 색도, texture와 같은 물리적 특성에 영향을 미친다. 수율은 제품의 무게와 직접 관련이 있어 매출에 직접적으로 영향을 미치므로 매우 중요한 요인이다. 오일 함량은 칩과 같은 유당 처리 제품에서 고려해야하는 중요한 요인이다. 색도는 제품의 호감도 및 소비에 많은 영향을 미친다. 본 연구에서는 감압후라이드 고구마칩 제조 시 전처리 방법으로 OD를 사용하였다.

OD는 pre-dehydration 방법으로 간단한 공정과 낮은 비용 및 에너지를 소요하여 foodstuff pretreatment 시 많이 사용되는 방법이다 [150, 151]. 이는 osmotic pressure 원리를 기반으로 하며, 고구마에 함유된 수분이 용액으로 outflow되고, 용액의 용질이 고구마로 inflow되는 동시 확산 현상 (simultaneous diffusion phenomenon)이 발생한다. OD 용액 제조 시 주로 사용하는 물질은 glucose, sucrose, oligosaccharide, maltodextrin, NaCl 등 이다 [152, 153]. 튀김 공정 중 OD 처리 시 오일 함량이 감소하고, color, flavor 등이 좋아진 연구가 있다 [154–160].

본 연구팀의 이전 연구에서는 OD, predrying, blanching, antibrowning agent, hydrocolloid coating의 전처리 방법을 이용하여, 감압후라이드 고구마칩의 오일 함량, 수율, 색도, 경도를 측정하였다 [141]. OD 전처리 샘플과 무처리군 (control) 샘플을 비교하였을 때 오일 함량은 감소하고, 수율은 증가하였으며, OD가 최적의 전처리 방법이었다. 따라서 본 연구에서 OD 전처리를 이용하여 감압후라이드 고구마칩 생산 조건을 예측 및 최적화하였다.

## 나. 감압후라이닝

감압후라이드 고구마칩의 제조 공정을 최적화하기 위해 VF 온도를 핵심 요인으로 선택하고, 독립 변수로 설정하였다. VF 온도는 CCD 설계 조건에 따라 설정하였으며, VF 시간은 20분으로 설정하였다 (Table 6).

튀김 공정을 거친 식품은 바삭한 식감과 고소한 맛을 가진다. 고온의 기름으로 인해 식품 표면의 온도가 급격히 상승하여, 식품이 함유하고 있는 수분이 기화된다. 수분이 존재하던 공간에 오일이 흡수되거나 pore가 형성되어 바삭한 식감을 가진다. Table 7과 같이 상압후라이닝 기술을 대체할 수 있는 감압후라이닝 기술에 대한 일부 연구가 진행되고 있으며, 현재까지 pilot-scale로 감압후라이드 고구마칩 생산 및 최적화에 대한 연구는 없다. Pilot-scale은 제품 양산 전 단계이며 생산성과 경제성을 위해 낮은 유용량과 높은 배치 용량을 갖는 것이 매우 중요하다. 본 연구에 사용된 pilot-scale의 VF 장비 규모 (9 L, 500 g batch capacity)는 이전 연구에서 사용된 lab-scale의 장비 (50 g batch capacity)보다 약 10배 더 높은 batch capacity를 가지고 있다.



**Table 7. Previous studies on sweet potato and potato chips manufactured using vacuum-frying technology**

Scale	Oil capacity (L)	Batch capacity (g)	Sliced thickness (mm)	Measured qualities	Sample	Ref.
Pilot	9	500	1.5	Yield, oil, color (BI)	Sweet potato	Present study
Lab	7	50	4.0	Oil, moisture, color, texture, water activity	Potato	[161]
Lab	7.5	50	1.5	Oil, moisture, color, texture	Sweet potato	[162]
Lab	5	50	2.0	Oil, moisture, color, texture	Sweet potato	[163]
Lab	5	50	4.0	Color, water activity	Sweet potato	[164]

## 2. 제조 공정 최적화

### 가. RSM 모델 fitting

CCD에 따른 반응값의 실험결과는 Table 6과 같으며, 수율은 40.6–55.4%, 오일 함량은 11.9–30.4%, 갈변지수는 57.46–92.82 범위로 측정되었다. 수율, 오일 함량, 갈변지수의 quadratic regression equation은 Equation 1–3과 같다. ANOVA 결과는 Table 8과 같으며, quadratic regression model에 적합하게 fitting된 것으로 확인되었다.

수율의 quadratic regression model은 F value는 4.22,  $p$  value는 0.0173으로서 통계적 유의성 (statistical significance)을 가졌다. 또한, lack of fit의  $p$  value가 1.41로서 0.05보다 크며,  $R^2$  값은 0.7917로서 각 요인과 반응값의 수학적 관계를 model에 잘 반영하여 fitting되었다. 수율의 RSM model에서  $X_1$ ,  $X_1^2$ ,  $X_2^2$  항의 영향은 통계적으로 유의하다 ( $p < 0.05$ ).

오일 함량의 quadratic regression model은 F value는 3.98,  $p$  value는 0.0211로서 통계적 유의성을 가졌다. 또한, lack of fit의  $p$  value가 0.7956으로서 0.05보다 크며,  $R^2$  값은 0.7818로서 각 요인과 반응값의 수학적 관계를 model에 잘 반영하여 fitting 했다고 판단된다. 오일 함량 model에서  $X_1$ ,  $X_3^2$  항의 영향은 통계적으로 유의하다 ( $p < 0.05$ ).

갈변지수의 quadratic regression model은 F value는 3.73,  $p$  value는 0.0262로서 quadratic regression model에 대하여 통계적 유의성을 가지고 있다. 또한, lack of fit의  $p$  value가 0.3321으로서 0.05보다 크며,  $R^2$  값은 0.7703으로서 각 요인과 반응값의 수학적 관계를 model에 잘 반영하여 fitting 했다고 판단된다. 갈변지수 model에서  $X_1$ ,  $X_3^2$  항의 영향은 통계적으로 유의하다 ( $p < 0.05$ ).

3개의 품질 예측식 모두에서  $X_1$  항의 영향은 통계적으로 유의하기 때문에 감압 후라이드 고구마칩 제조 시 OD concentration이 가장 중요한 독립변수라고 생각한다.

$$Y_1 (\%) = 52.01 + 2.12X_1 - 1.31X_2 + 0.0466X_3 + 0.9125X_1X_2 - 0.2625X_1X_3 - 0.2875X_2X_3 - 3.4X_1^2 - 2.29X_2^2 - 0.2209X_3^2 \quad (1)$$

$$Y_2 (\%) = 22.65 - 4.43X_1 - 1.28X_2 - 0.4673X_3 + 1.09X_1X_2 - 0.5375X_1X_3 - 0.2875X_2X_3 - 0.3055X_1^2 - 0.7375X_2^2 - 2.98X_3^2 \quad (2)$$

$$Y_3 = 65.71 - 5.77X_1 - 3.12X_2 + 3.82X_3 - 3.25X_1X_2 - 3.48X_1X_3 + 0.3983X_2X_3 + 2.27X_1^2 + 0.986X_2^2 + 6.04X_3^2 \quad (3)$$

**Table 8. Analysis of variance (ANOVA) for quadratic regression model of response surface methodology for vacuum fried sweet potato chip manufacturing process**

Response	Source	DF	Sum of Squares	Mean square	F-value	<i>p-value</i>
Yield	Model	9	316.17	35.13	4.22	0.017
	X <sub>1</sub>	1	61.43	61.43	7.38	0.022
	X <sub>2</sub>	1	23.28	23.28	2.80	0.13
	X <sub>3</sub>	1	0.030	0.030	0.00	0.95
	X <sub>1</sub> <sup>2</sup>	1	166.88	166.88	20.06	0.0010
	X <sub>2</sub> <sup>2</sup>	1	75.52	75.52	9.08	0.013
	X <sub>3</sub> <sup>2</sup>	1	0.70	0.70	0.08	0.78
	X <sub>1</sub> X <sub>2</sub>	1	6.66	6.66	0.80	0.39
	X <sub>1</sub> X <sub>3</sub>	1	0.55	0.55	0.07	0.80
	X <sub>2</sub> X <sub>3</sub>	1	0.66	0.66	0.08	0.78
	Residual	10	83.19	8.32		
	Lack of Fit	5	48.66	9.73	1.41	0.36
	Pure Error	5	34.53	6.91		
Total	19	399.36				
Oil content	Model	9	451.46	50.16	4.96	0.010
	X <sub>1</sub>	1	161.03	161.03	15.92	0.0030
	X <sub>2</sub>	1	17.40	17.40	1.72	0.22
	X <sub>3</sub>	1	0.89	0.89	0.09	0.77
	X <sub>1</sub> <sup>2</sup>	1	137.63	137.63	13.60	0.0040
	X <sub>2</sub> <sup>2</sup>	1	150.51	150.51	14.88	0.0030
	X <sub>3</sub> <sup>2</sup>	1	14.03	14.03	1.39	0.27
	X <sub>1</sub> X <sub>2</sub>	1	6.85	6.85	0.68	0.43
	X <sub>1</sub> X <sub>3</sub>	1	0.61	0.61	0.06	0.81
	X <sub>2</sub> X <sub>3</sub>	1	0.020	0.020	0.00	0.97
	Residual	10	101.179	10.118		
	Lack of Fit	5	67.885	13.577	2.04	0.23
	Pure Error	5	33.293	6.659		
Total	19	552.642				
BI	Model	9	1360.75	151.20	4.64	0.012
	X <sub>1</sub>	1	123.23	123.23	3.78	0.080
	X <sub>2</sub>	1	38.89	38.89	1.19	0.30
	X <sub>3</sub>	1	376.07	376.07	11.55	0.0070
	X <sub>1</sub> <sup>2</sup>	1	267.19	267.19	8.20	0.017
	X <sub>2</sub> <sup>2</sup>	1	17.24	17.24	0.53	0.48
	X <sub>3</sub> <sup>2</sup>	1	545.32	545.32	16.74	0.0020
	X <sub>1</sub> X <sub>2</sub>	1	5.31	5.31	0.16	0.70
	X <sub>1</sub> X <sub>3</sub>	1	8.69	8.69	0.27	0.62
	X <sub>2</sub> X <sub>3</sub>	1	64.18	64.18	1.97	0.19
	Residual	10	325.68	32.57		
	Lack of Fit	5	142.69	28.54	0.78	0.60
	Pure Error	5	182.99	36.60		
Total	19	1686.43				

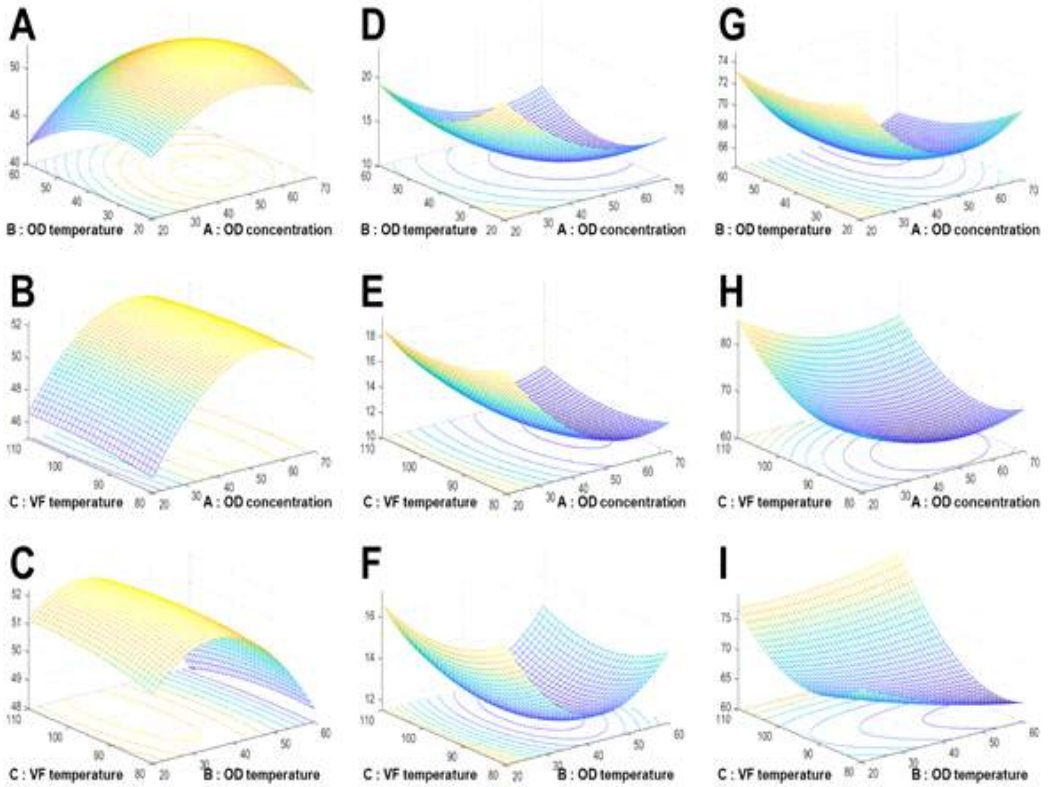
## 나. 반응 표면 분석

Quadratic regression model을 이용하여 response surface graph를 확인하였다 (Figure 27). 수율은 OD concentration이 45%일 때까지 증가하며, 45% 이상의 농도로 처리 시 감소하는 것을 확인하였다. 오일 함량은 OD concentration 및 OD temperature가 낮을수록 증가하였고, VF frying 온도가 중간범위인 95℃ 근처에서 증가하였다. 갈변지수는 OD concentration 및 OD temperature가 감소할수록 증가하였고, VF temperature가 높아질수록 증가하였다.

Selvakumar (2018)은 설탕 시럽으로 OD 전처리 용액을 제조하여 3~4 mm로 슬라이스된 당근을 OD 전처리 후 건조시켜 수율을 측정하였다 [165]. OD 전처리 용액은 40, 50, 60, 70 °Brix 농도로 제조하였으며, 20시간동안 침지하였다. 측정결과 60 °Brix까지 수율이 증가하였고, 70 °Brix는 60 °Brix에 비하여 수율이 감소한 것을 확인하였다. 이는 본 연구결과와 유사하며, 원물에 따라서 수율을 최대화할 수 있는 OD 농도가 상이한 것을 확인하였다.

Karizaki 등 (2013)은 감자의 상압후라이 시 50% (w/w) sugar+15% (w/w) NaCl 용액에서 45℃ 온도로 OD 전처리하여 상압후라이 후 품질에 미치는 영향을 확인하였다 [155]. 실험 결과 전처리를 하지 않은 control에 비하여 OD 전처리를 한 샘플의 오일 함량이 더 낮은 것을 확인하였다. 본 연구에서도 OD concentration이 높아질수록 오일 함량이 감소하는 것을 확인하였으며, 이는 기존의 연구와 유사한 결과이다.

Krokida 등 (2000)은 사과와 바나나를 설탕으로 OD 전처리 후 건조과정 중 색도 변화를 측정하였다 [166]. 실험 결과 OD 용액으로 설탕을 첨가하면 샘플의 수분 활성도가 낮아져 비효소적 갈변현상이 감소하는 것을 확인하였다. 이는 본 연구와 유사한 실험 결과로서 OD concentration이 높아질수록 갈변지수가 감소하는 것을 확인하였다.



**Figure 27.** Response surface graphs of (A, B, C) yield, (D, E, F) oil content, and (G, H, I) browning index of vacuum-fried sweet potato chips as affected by osmotic dehydration (OD) concentration, OD temperature, and vacuum frying temperature.

## 다. ANN 모델

OD concentration, OD temperature, VF temperature를 ANN model의 input layer neuron으로 설정하였다. Hidden layer의 neuron은 10개로 설정하였다. 수율, 오일 함량, 갈변지수는 output layer의 neuron으로 설정하였다. Figure 28은 ANN model의 performance plot을 MSE value로 나타낸 그래프이다. 수율, 오일 함량, 갈변지수에 대한 모든 ANN model이 underfitting 및 overfitting 없이 모델링된 것을 확인하였다.

Figure 29-31은 감압후라이드 고구마칩 품질의 실험값과 예측값의 regression plot이다. Training set, validation set, testing set에 대한 R이 계산되어있다.

Serpen & Gokmen (2007)은 ANN 모델을 이용하여 상압후라이드 감자칩의 browning ratio를 예측하였다 [167]. Input layer의 neuron으로 asparagine 농도, glucose 농도, frying temperature, frying time을 설정하였다. ANN 모델링 결과 R 값이 0.997로서 실험값과 예측값이 매우 높은 상관관계가 있는 것을 확인하였다. 특히, frying temperature는 튀김의 browning에 영향을 미치는 요인으로 판단된다.

ANN은 여러 개의 input layer neuron 및 output layer neuron으로 구성할 수 있어, 산업공정, 금융 등 복잡한 변수에 대한 예측값의 classification, prediction, pattern recognition 등이 가능하다 [168]. 특히 식품 산업, 식품 가공, 식품 공학, 식품 속성, 품질 관리 분야에서 효율적으로 사용할 수 있다.

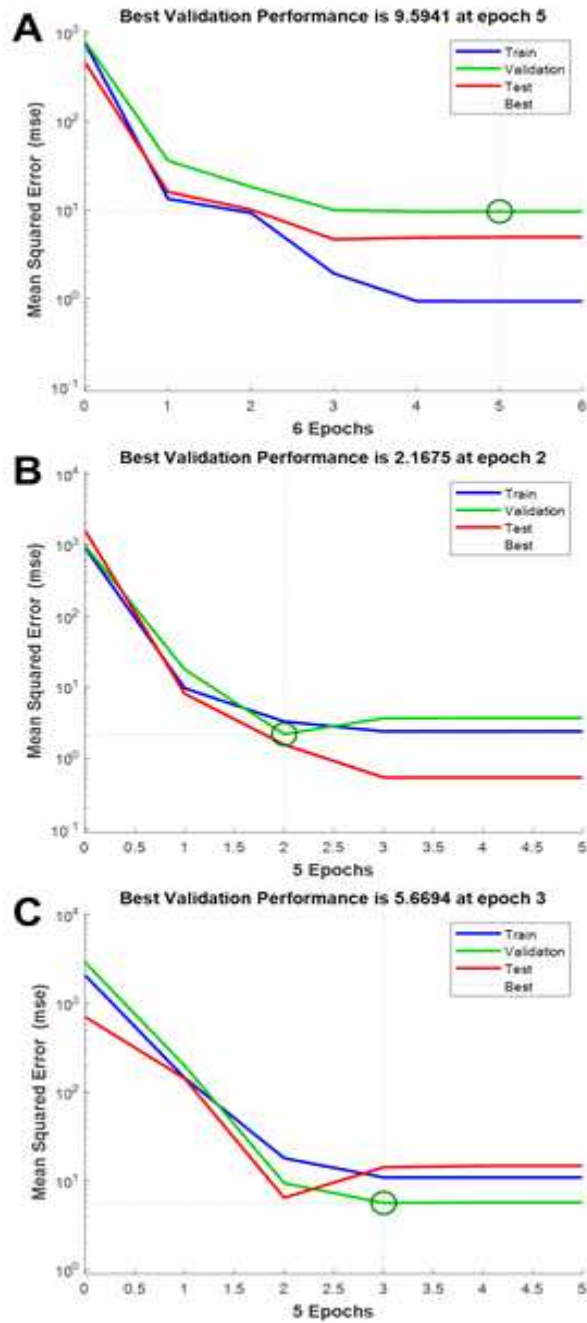


Figure 28. Performance plot for mean square error (MSE) value for the ANN model of (A) yield, (B) oil content, and (C) browning index.



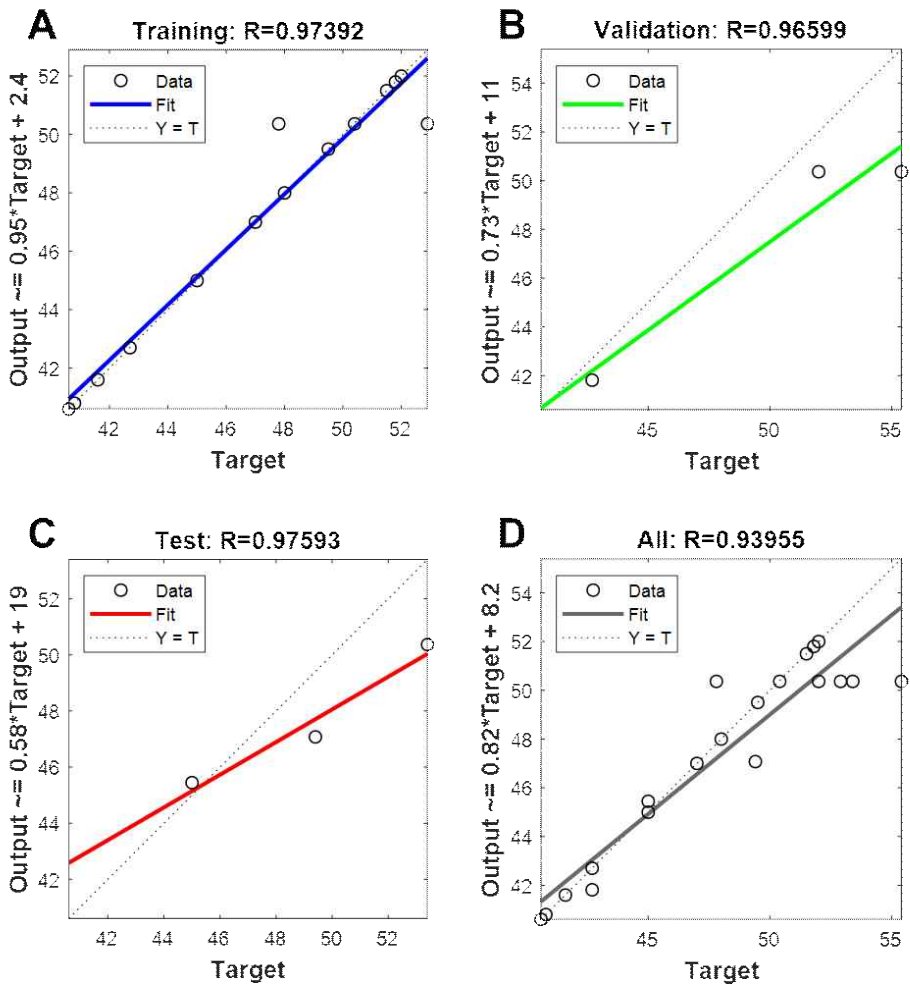


Figure 29. Regression plots for (A) training, (B) validation, and (C) testing of the ANN model for yield.

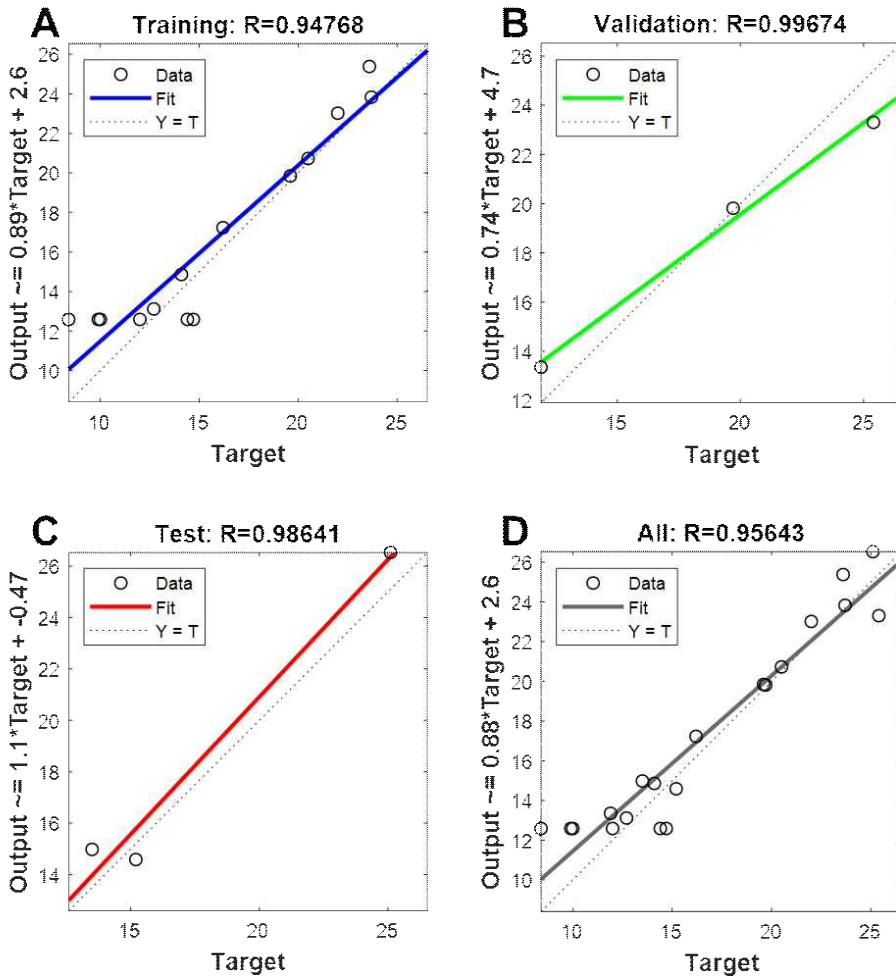


Figure 30. Regression plots for (A) training, (B) validation, and (C) testing of the ANN model for oil content.

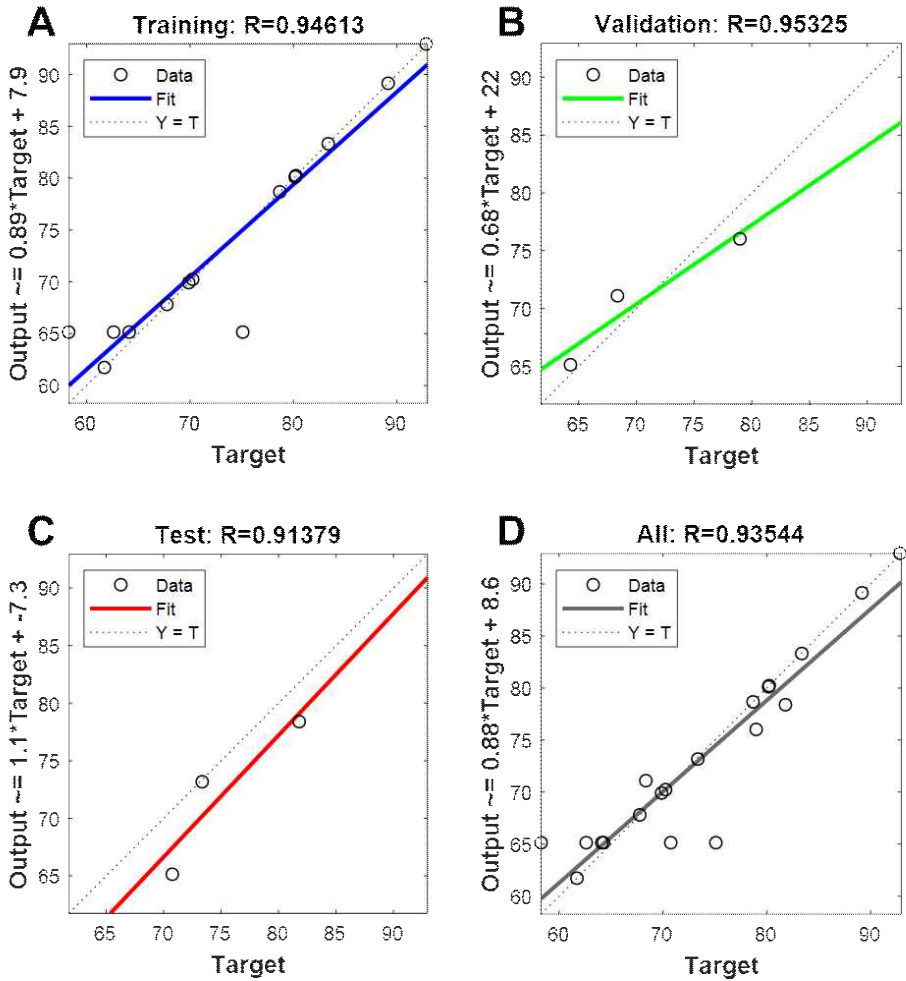


Figure 31. Regression plots for (A) training, (B) validation, and (C) testing of the ANN model for browning index.

## 라. RSM 및 ANN 모델 performance

RSM 및 ANN 모델의 성능을 비교하였으며, 성능지표인 R,  $R^2$ , MSE, RMSE, MAE, SEP, MRPD의 값은 Table 9와 같다.

실험값과 예측값으로 수율에 대한 R 및  $R^2$  값을 계산하였다. RSM 모델에 대한 R 및  $R^2$  값은 0.8898, 0.7917이었고, ANN 모델에 대한 R 및  $R^2$  값은 0.8913, 0.7943였다. ANN 모델이 RSM 모델보다 우수한 성능을 가졌다. 그러나 실험값과 예측값의 오차를 나타내는 지표인 MSE, RMSE, MAE, SEP, MRPD 값은 모두 RSM 모델이 ANN 모델보다 낮게 확인되었으며, 이는 RSM 모델이 ANN 모델보다 정확성이 높은 것으로 판단된다. RSM 모델에 비하여 ANN 모델의 R 및  $R^2$  값의 증가율은 R 값의 증가율이 0.17%,  $R^2$  값의 증가율이 0.33%였다. 증가율이 매우 낮기 때문에, 정확성이 감소한 것으로 예측된다.

실험값과 예측값으로 오일 함량에 대한 R 및  $R^2$  값을 계산하였다. RSM 모델에 대한 R 및  $R^2$  값은 0.8842, 0.7818이었고, ANN 모델에 대한 R 및  $R^2$  값은 0.8947, 0.8005였다. ANN 모델이 RSM 모델보다 우수한 성능을 갖는 것으로 판단되었다. MSE, RMSE, SEP, 값은 모두 RSM 모델이 ANN 모델보다 낮게 확인되었고, MAE, MRPD 값은 모두 ANN 모델이 RSM 모델보다 낮게 확인되었다. RSM 모델에 비하여 ANN 모델의 R 및  $R^2$  값의 증가율은 R 값의 증가율이 0.19%,  $R^2$  값의 증가율이 2.39%였다. 이는 비교적 낮은 증가율을 나타내어, 모델 성능을 나타내는 지표가 감소 또는 증가한 것으로 판단된다.

실험값과 예측값으로 갈변지수에 대한 R 및  $R^2$  값을 계산하였다. RSM 모델에 대한 R 및  $R^2$  값은 0.8776, 0.7702이었고, ANN 모델에 대한 R 및  $R^2$  값은 0.9458, 0.8944였다. ANN 모델이 RSM 모델보다 우수한 성능을 갖는 것으로 판단되었다. MSE, RMSE, MAE, SEP, MRPD 값은 모두 ANN 모델이 RSM 모델보다 낮게 확인되었으며, 이는 ANN 모델이 RSM 모델보다 정확성이 높은 것으로 판단된다. RSM 모델에 비하여 ANN 모델의 R 및  $R^2$  값의 증가율은 R 값의 증가율이 7.77%,  $R^2$  값의 증가율이 16.13%로서, 매우 높은 증가율을 나타내어 정확성이 증가한 것으로 판단된다.

대부분은 예측 모델 비교 연구에서는 R 및  $R^2$  값을 비교하거나, 모델 성능을 나타내는 지표 (MSE, RMSE, MAE, SEP, MRPD 등) 중 1-2개 정도를 사용한다. 그러

나 R 및 R<sup>2</sup> 값의 증가율에 따라 모델의 성능이 상이하므로, 다양한 오차를 나타내는 지표로 모델의 정확성 확인이 필요하다.

ANN은 정해진 수식에 데이터를 fitting하지 않고 모델링하기 때문에 RSM에 보다 더 높은 정확도를 갖는 것을 확인하였다. ANN 모델의 prediction capability는 식품 제조 공정에서 발생할 수 있는 예측 불가능한 변수를 최소화하여 식품 품질을 최적화할 수 있는 이점을 제공한다. ANN 모델이 RSM에 비하여 더 좋은 fitting 효과와 정확성을 갖는다는 기존의 연구가 존재한다 [169].

통상적으로 예측 모델의 R<sup>2</sup> 값이 1에 가까울수록 정확도가 높다고 알려져 있다. Zikmund (2000)는 R<sup>2</sup> 값의 범위를 나누어 상관관계를 주장하였다 [170]. R<sup>2</sup> 값이 0.3 미만이면 매우 약한 (very weak) 상관관계를 갖고, R<sup>2</sup> 값이 0.3-0.5이면 약한 (weak) 상관관계를 갖고, R<sup>2</sup> 값이 0.5-0.7이면 보통의 (moderate) 상관관계를 갖고, R<sup>2</sup> 값이 0.7 이상이면 강한 상관관계를 갖는다.

Henseler 등 (2009)은 모델 크기, 변수의 개수 등 각 연구 환경이 매우 상이하므로, R<sup>2</sup> 값의 범위를 규정하여 예측 모델의 정확성을 명명하는 것을 옳지 않다고 주장하였다 [171]. 경험적으로 R<sup>2</sup> 값이 0.75일 때는 상당한 상관관계를 가졌고, R<sup>2</sup> 값이 0.5일 때는 보통의 상관관계를 가졌고, R<sup>2</sup> 값이 0.25일 때는 약한 상관관계를 가졌다.

본 연구의 수율, 오일 함량, 갈변지수의 예측 모델의 R<sup>2</sup> 값은 0.7702-0.8944의 범위를 갖는다. 1에 가깝지 않아 강한 상관관계를 갖지 않지만, 상당한 상관관계를 갖는다. 그러나 R<sup>2</sup> 값은 연구 목적과 모델에 따라서 유의미한 수치 범위가 달라질 수도 있다. 본 연구에서는 높은 정확성을 갖는 모델 생성의 목적이 아니었으며, RSM과 ANN 모델의 정확성을 비교하고자 하였다. 또한, 고구마와 같은 농산물 가공 시 원물 상태와 같은 예측할 수 없는 변수가 매우 많아 다른 연구자의 결과도 R<sup>2</sup> 값이 0.9 이하인 것을 확인하였다 [172].

**Table 9. Statistical evaluation performances of the RSM and ANN models**

Responses	Y <sub>1</sub> (%) <sup>a</sup>	Y <sub>2</sub> (%)	Y <sub>3</sub>
<b>R value<sup>b</sup></b>			
RSM	0.8898	0.9038	0.8983
ANN	0.9395	0.9564	0.9354
<b>R<sup>2</sup> value</b>			
RSM	0.7917	0.8169	0.8069
ANN	0.8828	0.9148	0.8750
<b>MSE value</b>			
RSM	4.1594	5.0589	16.2838
ANN	2.8293	2.8433	10.6872
<b>RMSE value</b>			
RSM	2.0395	2.2492	4.0353
ANN	1.6821	1.6862	3.2691
<b>MAE value</b>			
RSM	1.6638	1.9078	3.2413
ANN	0.9244	1.3394	1.8249
<b>SEP value (%)</b>			
RSM	4.2511	13.5250	5.4844
ANN	3.5061	10.1396	4.4431
<b>MRPD value (%)</b>			
RSM	3.5091	13.4567	4.6667
ANN	1.7950	10.3349	2.6296

<sup>a</sup> Y<sub>1</sub>, yield; Y<sub>2</sub>, oil content; Y<sub>3</sub>, browning index.

<sup>b</sup> R: correlation coefficient; R<sup>2</sup>: coefficient of determination; MSE: mean square error; RMSE: root mean square error; MAE: mean absolute error; SEP: standard error of prediction; MRPD: mean relative percent deviation.

## 마. RSM 및 ANN 모델 최적화

RSM 및 ANN 모델의 최적화 값은 Table 10과 같다. 수율의 최적화 값은 RSM 모델이 52.46%, ANN 모델이 53.52%였다. 오일 함량의 최적화 값은 RSM 모델이 10.65%, ANN 모델이 11.58%였다. 갈변지수의 최적화 값은 RSM 모델이 61.14, ANN 모델이 60.40였다. 두 모델의 최적화 값은 약간의 차이가 있었다.

RSM 최적화는 실험 조건 내에서 독립변수의 최적점 (optimum point)을 찾는다. 최적점은 response surface에서 육안 검사 (visual inspection)을 이용할 수도 있고, quadratic regression equation을 각 변수에 대해 편미분한 함수를 0과 동일 시 한 후 연립방정식을 풀어 얻을 수 있다. Quadratic regression model의 최적점은 최대 (maximum), 최소 (minimum), 안장 (saddle)으로 분류된다.

ANN 최적화 시에는 GA를 사용하였다. GA는 실험 조건 외 또는 최적화가 어려운 상황에서 사용하는 최적화 방법이다 [173]. 최적화 시 모집단을 기반으로 하여 selection, crossover, mutation하여 각 개체의 fitness를 평가하여, 최적의 fitness를 갖는 해가 나올 때 까지 반복한다. 따라서 실험 조건 내에서 최적화 시 RSM이 더 적합하고, 실험 조건 외 또는 예측 불가능한 변수가 많은 실에는 ANN이 더 적합할 것으로 판단된다.

최근 ANN보다 학습 성능이 우수한 deep neural network (DNN), recurrent neural network (RNN), convolution neural network (CNN)가 다양한 분야에서 최적화 시 연구된다 [174–176]. 예측 불가능한 변수가 많은 경우에도 DNN, RNN, CNN은 데이터의 특성을 분석하고, 값들의 보정을 용이하게 하여 학습 성능을 향상시킨다. 추후 DNN, RNN, CNN을 이용하여 학습 성능이 향상된 식품공정 최적화 연구를 진행할 예정이다.

**Table 10. Optimized quality of vacuum-fried sweet potato chips using RSM and ANN-GA methods**

Variables		RSM				ANN	
Input	Osmotic dehydration concentration (%)	52.22	58.17	55.62	58.06	55.06	47.82
	Osmotic dehydration temperature (°C)	35.58	41.70	73.64	36.75	39.64	73.26
	Vacuum frying temperature (°C)	96.27	95.76	83.53	97.33	95.16	88.04
Output	Yield (%)	52.46	-	-	53.52	-	-
	Oil content (%)	-	10.65	-	-	11.58	-
	BI	-	-	61.14	-	-	60.40




### 3. Microstructure analysis


Figure 32는 생고구마, 당침, 튀김 공정 후 고구마를 나타내었다. Figure 32A는 슬라이스한 생고구마 (R)이고, Figure 32B는 20% refined dextrose 용액을 20°C (RO)에서 OD 전처리한 생고구마 슬라이스이다. Figure 32C는 대기압 하에서 110°C에서 20분간 튀긴 고구마 (D)이고, Figure 32D는 20% OD 용액에서 20°C로 전처리한 고구마를 대기압에서 튀긴 것이다 (DO). Figure 32E는 슬라이스한 고구마를 110°C에서 20분간 진공 상태에서 튀긴 것 (V)이고, Figure 32F는 20% OD 용액에서 20°C로 전처리한 후 진공 상태에서 튀긴 것이다 (VO). 상압후라이드 고구마칩은 낮은 튀김 온도 때문에 수분 증발이 적절히 이루어지지 않아 오일 함량이 높았다. 감압후라이드 고구마칩은 낮은 튀김 온도에도 불구하고, 감압 조건에서 수분 증발이 적절히 이루어졌다.

Figure 33은 R, RO, D, DO, V 및 VO 샘플의 SEM 분석 결과이다. 샘플 R에서는 둥근 모양의 전분과립이 확인되었다. 생고구마의 OD 전처리 시료인 샘플 RO에서는 전분 과립이 관찰되지 않았고, cell structure 손상이 확인되었다. 이는 생 감자와 고구마, OD 전처리 감자와 고구마의 SEM 분석 결과와 일치한다 [155, 177]. 샘플 D와 샘플 DO는 샘플 V와 샘플 VO보다 표면에서 더 큰 pore를 갖는 것으로 확인되었다. 표면의 pore로 인해 튀김 후 기름 흡수가 발생한다. 또한 pore 크기가 클수록 오일 함량이 높아진다는 기존 연구 결과가 있다 [178].

Figure 34는 상압 및 감압후라이드 고구마칩의 식감 (hardness) 측정 결과이다. 샘플 D는  $9.19 \pm 1.59$  N, 샘플 DO는  $11.78 \pm 0.98$  N, 샘플 V는  $12.80 \pm 2.22$  N, 샘플 VO는  $23.09 \pm 2.99$  N이었다. 감압후라이딩 시 상압후라이딩보다 hardness가 크게 증가했다. OD 전처리된 샘플 (DO, VO)의 hardness는 전처리되지 않은 샘플 (D, V)보다 유의적으로 높았다. 세포벽에 다량의 펙틴을 함유한 과일 및 채소의 경우 OD 전처리 동안 펙틴이 용해되어 경도가 감소한다 [179]. 그러나 감자와 고구마의 hardness는 수분 손실로 인해 증가하고 OD 전처리 중에 고형물이 증가한다 [180].



**Figure 32.** Appearance of (A) sliced and (B) osmotically dehydrated raw sweet potato. Appearance of fried sweet potato chips after (C) deep frying, (D) deep frying with osmotic dehydration, (E) vacuum frying, and (F) vacuum frying with osmotic dehydration.



**Figure 33. SEM images of (A) sliced and (B) osmotically dehydrated raw sweet potatoes. SEM images of fried sweet potato chips after (C) deep frying, (D) deep frying with osmotic dehydration, (E) vacuum frying, and (F) vacuum frying with osmotic dehydration.**

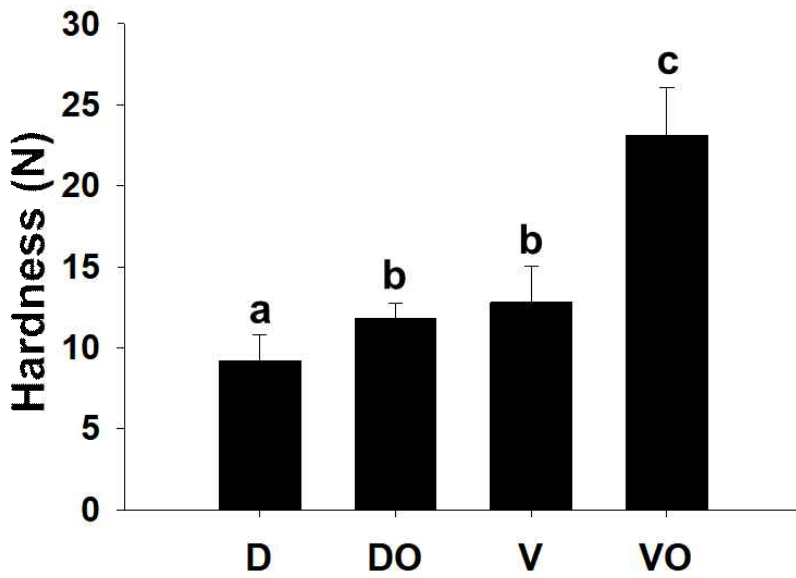


Figure 34. Texture (hardness) of fried sweet potato chips after deep frying (D), deep frying with osmotic dehydration (DO), vacuum frying (V), and vacuum frying with osmotic dehydration (VO).

## 제4절 요약

본 연구는 감압후라이드 고구마칩 제조 시 전처리 및 튀김 조건 (OD concentration, OD temperature, VF temperature)에 대한 최종 품질 (수율, 오일 함량, 갈변지수)의 예측 모델을 개발하였다. 예측 모델은 RSM과 ANN 방법을 이용하여 모델링하였다. RSM은 quadratic regression model에 통계적으로 유의하게 fitting된 것을 확인하였고, response surface graph를 이용하여 각 독립변수가 종속변수에 미치는 영향을 평가하였다. ANN 모델은 MAE 값에 대한 performance plot을 확인하여 최소의 MSE 값을 갖는 모델이 생성된 것을 확인하였다. 수학 및 통계적 분석을 이용하여 각 모델의 성능을 비교하였다. 최종 품질 요인인 수율, 오일 함량, 갈변지수 모두 R 및  $R^2$  값이 ANN 모델이 RSM보다 높았다.

그러나 모델의 성능을 나타내는 지표 (MSE, RMSE, MAE, SEP, MRPD) 값 차이는 R 및  $R^2$  값 증가율에 따라서 상이한 것을 확인하였다. RSM과 ANN 모델의 최적화 결과 두 모델의 최적화 값은 약간의 차이가 있었다. RSM과 ANN 모두 감압후라이드 고구마칩 제조 공정에 대한 수율, 오일 함량, 갈변 지수를 예측할 수 있었으며, ANN 모델이 RSM에 비하여 정확도 및 적응성이 높은 것을 확인하였다. 농산물 가공공정은 농산물의 품질에 따라서 예측 불가능한 변수가 매우 많지만, RSM과 ANN 모델을 이용하여 품질 예측 및 최적화가 가능한 것을 확인하였다. 감압후라이딩 공정을 통해 고구마칩의 품질 최적화에 대한 연구는 처음으로 연구되었다. 이는 다양한 변수가 존재하는 식품산업 공정에서 활용될 수 있다.

## 제4장 Metagenome 분석 및 mouse 모델을 이용한

### 감자튀김 식단이 장내 미생물에 미치는 영향

#### 제1절 서론

감자튀김은 고혈당의 탄수화물과 오일을 함유한 패스트푸드로서 몸에 해로운 음식으로 대중들에게 알려져있다 [181]. 감자튀김의 유해성에 대한 찬반 의견이 존재한다. 감자튀김은 다량의 탄수화물 및 지질을 함유하고 있으며, 암, 당뇨를 발생할 수 있어 유해하다고 주장한다. 반대로 섭취량 조절과 식단의 균형을 맞출 수 있으면 건강에 미치는 영향이 거의 없다고 주장한다. 감자튀김의 유해성과 관련된 몇몇 연구가 보고되어 있다. Halton 등 (2006)은 여성의 감자튀김 섭취가 제 2형 당뇨병 위험과 양의 상관관계가 있는 것을 확인하였다 [182]. 감자튀김에 함유되어 있는 발암 성분인 acrylamide 함량 분석, acrylamide 함량 저감 기술 등과 같은 연구가 진행되었다 [183–185]. 본 연구에서는 감자튀김의 유해성 검증을 위하여 후라이нг 방법 및 튀김 오일에 따른 유해성분 분석, 감자튀김 식이 시 mouse의 weight 변화, biochemical parameter 변화, cecal SCFA 함량 변화, fecal microbiota 구성성분 변화에 미치는 영향을 확인하였다.

Deep frying은 식품 조리 시 사용하는 일반적인 방법이다. 140–210℃의 기름을 이용하여 식품에 함유된 수분을 기화시켜 바삭한 식감과 고소한 풍미를 부여한다 [186]. Deep frying 시 식품 표면에서 중심으로 기름이 흡수되고, 수분이 존재했던 공간에 기름이 흡수되거나 pore가 형성된다. Deep frying은 대기압 및 높은 온도를 사용하기 때문에, 기름에 함유된 지방산의 hydrolysis, oxidation, polymerization이 발생한다. 이러한 화학반응은 다양한 polar compound 및 non-polar compound를 생성한다. 생성되는 성분 중 trans fatty acids, acrylamide, polycyclic aromatic hydrocarbons (PAH)은 발암, 동맥 경화 등을 유발하며, deep frying 중 생성되는 toxic compounds로 분류할 수 있다 [187]. Trans fatty acid는 불포화 지방산에 trans형으로 수소가 결합되어 있는 구조이며, 주로 식물성 기름의 경화과정 (hydrogenation)에서 많이 생성된다. 또한, cis fatty acid를 고온에서 재사용 시 발생하기도 한다. Trans fatty acid 섭취 시 low-density lipoprotein cholesterol (LDL)의 혈중 농도가 증가하여 관상동맥 질환을 유발한다. 최근 Matta 등 (2021)의 연구에서 trans fatty acid인 elaidic acid 함

량이 증가할수록 유방암 위험이 증가하는 것을 확인하였다 [188]. Acrylamide는 150℃ 이상에서 가열 시 아미노산과 환원당의 반응으로 생성된다. 암 유발 정도를 측정하는 기관인 International Agency for Research on Cancer (IARC)에서 acrylamide는 발암가능물질인 group 2A로 분류되었다. 온도, 시간, 사용 기름 등 다양한 튀김 공정 조건이 acrylamide 생성에 영향을 미친다. PAH는 고온에서 가열 처리 시 탄수화물, 지방, 단백질의 열분해 및 불완전 연소에 의해서 생성된다. IARC는 60종류의 PAH의 인체 암 유발 정도를 측정하였으며, 발암물질인 group 1은 1종, 발암가능물질인 group 2A는 3종, 발암우려물질인 group 2B는 11종, 발암물질로 분류되지 않는 물질인 group 3은 45종으로 분류되었다 [189]. PAH 중 대중들에게 비교적 익숙한 benzo pyrene은 group 1으로 분류된다.

최근 deep frying 시 toxic compounds 발생 감소를 위하여 vacuum frying 기술이 적용되고 있다. Vacuum frying은 감압 하에서 원료의 수분을 기화하는 기술이다 [190, 191]. 감압후라이징 시 낮은 산소 농도, 비교적 낮은 유온 (80–140℃)을 사용하여 상압후라이징에 비하여 튀김 오일의 산화 반응이 감소한다. 튀김의 acrylamide 함유 저감 기술로 감압후라이징 기술을 많이 사용한다 [192, 193]. 본 연구에서는 2가지 튀김 오일 (canola, palm)과 2가지 튀김 방법 (상압, 감압)을 이용하여 감자튀김을 제조하였으며, 각 방법에 대한 toxic compounds 함량과 섭취 시 체내에 미치는 영향에 대하여 확인하였다.

인간은 다양한 종류의 체내 미생물을 가지고 있으며, 이러한 미생물 군집이 인간과 상호작용하여 건강과 질병에 영향을 미친다 [194]. Microbe는 intestinal tract, skin, oral cavity 등 외부 환경에 노출되는 인체 부위에 서식한다. 특히 장내 microbiota는 host의 영양소 흡수, 대사과정 (metabolism), 면역 체계, 에너지 소비 등과 같은 다양한 생리적 과정 (physiological processes)에 영향을 미치는 것으로 밝혀졌다. 장내 microbiota는 비타민과 필수 아미노산을 생합성하고, 소화되지 않은 탄수화물 성분을 SCFA로 분해하여 host의 건강에 도움을 준다 [195, 196]. 또한, amyloid와 lipopolysaccharide를 생성할 수 있어 alzheimer를 발병할 수 있다. 장내 microbiota는 host 및 외부 환경에 대하여 균형을 유지하는데, 이러한 균형이 무너지면 비만, 당뇨, 간 질환, 염증성 장 질환, 심혈관 질환, 암 등과 같은 질병이 발생할 수 있다 [197–200]. 이러한 현상을 dysbiosis라고 한다. 식단은 microbiota composition 균형에 영향을 미치는 중요한 요인이며, 잘 못된 식단은 dysbiosis를 유발할 수

있다 [201].

최근 장내 microbiota 분석을 위하여 metagenomics를 많이 사용한다. Metagenomics는 어떠한 환경에 존재하는 미생물 전체의 genome을 분석하는 것을 의미한다. Metagenomics는 2000년대 이후 NGS (next generation sequencing)가 보편화되면서 연구가 활발하게 진행되었다 [202]. 16S rRNA 유전자 분석에 기반한 NGS 분석을 통해 미생물을 배양 및 분리하지 않고, DNA를 추출하여 표적 증폭 시퀀싱에 대한 대안적 접근 방식을 가지고 있다. 추출한 DNA에는 모든 미생물의 DNA가 혼합되어 있다. 이러한 DNA를 fragmentation하여, oligonucleotide를 붙인 후 library를 제작하여, 에러 필터링 (filtering), 정렬 (alignment), 분류 (taxonomic assignment)를 처리한 후에 염기서열의 동정 작업과 군집다양성 계산 (diversity calculation)을 수행한다 [203]. Metagenomics 분석 시 많이 사용하는 프로그램은 EzBioCloud, QIIME, MOTHUR, RDP 등이 있다.

본 연구에서는 후라이프 방법 및 튀김 오일 종류에 따른 감자튀김에 함유된 유해 성분 (arylamide, trans fatty acid, PAH)을 분석하였다. 또한, 감자튀김 섭취 시 mouse의 weight 변화, biochemical parameter 변화, cecal SCFA 함량 변화를 측정하였다. 본 연구에서는 최초로 감자튀김 식이가 gut microbiota에 미치는 영향을 분석하였다.



## 제2절 재료 및 방법

### 1. 재료

시중에서 판매하는 shoestring 형태의 냉동 감자튀김 (Lamb Weston, ID, USA)을 구매하여 튀김에 사용하였다. 기름은 카놀라유 (Kirkland Signature, WA, USA)와 팜유 (Tradekey, CONTINENTAL RESOURCES SDN BHD, Selangor, Malaysia)를 사용하였다.

### 2. Frying 및 toxic compounds 분석

#### 가. Frying

상압후라이닝 시 튀김기 (Wiswell, Seoul, Korea)를 사용하였고, 180 °C에서 3분동안 조리하였다. 감압후라이닝 시 키요모토코리아의 vacuum frying 장비를 사용하였고, 110 °C에서 10분동안 조리하였다.

카놀라유를 사용하여 상압후라이닝한 시료는 CD, 감압후라이닝한 시료는 CV로 명명하였다. 팜유를 사용하여 상압후라이닝한 시료는 PD, 감압후라이닝한 시료는 PV로 명명하였다.

#### 나. Fatty acid 분석

튀김 공정이 완료된 감자튀김 1 g 에 2 mL의 50 mg/mL pyrogallol을 첨가한 후 2 mL 내부표준용액 (5 mg/mL triundecanoic acid)을 첨가하여 혼합하였다. 10 mL의 8.3 M HCl을 첨가한 후 70–80°C의 water bath에서 40분동안 분해한다. 상온으로 냉각 후 2 mL EtOH을 첨가하였다. 25 mL ether를 첨가한 후 5분동안 shaking하였다. 1 시간동안 방치 후 15 mL ether 층을 수거한 후 질소를 사용하여 ether를 증발시켰다. 농축된 시료를 15 mL 수거하여 2 mL chloroform, 3 mL ether를 순서대로 넣어 잔존하는 지방을 제거하였다. 질소를 사용하여 시료를 농축한 후 2 mL의 7% trifluoroborane, 1 mL toluene을 첨가하여 vortexing하였다. 100 °C의 heating block에서 45분동안 방치 후 상온으로 냉각하였다. 5 mL 증류수, 1 mL iso-octane, 1 g sodium

sulfate, anhydrous를 첨가한 후 2000 rpm에서 5분동안 원심분리하였다. 상층액을 수거하여 분석시료로 사용하였다. Standard 물질로는 F.A.M.E Mix (CRM18918, Sigma, MA, USA)를 사용하였다.

지방산 분석 시 gas chromatography (GC, Agilent 7890A, Agilent, CA, USA)를 사용하였다. 검출기는 FID, column은 SP-2560 (100 m \* 0.25 mm \* 0.2 m), 가스는 헬륨, flow rate는 0.75 mL/min, split ratio는 100:1을 사용하였다. 주입부 온도는 225℃, 검출기 온도는 285℃로 설정하였고, column 온도는 100℃에서 4분간 유지한 후 3℃/min의 비율로 240℃까지 온도를 상승시키고 이후 15분으로 유지하였다.

## 다. Acrylamide 분석

튀김 공정이 완료된 감자튀김 1 g을 정밀히 취하여 50 mL 폴리프로필렌 튜브에 넣고 내부표준용액 1 mL (1 mg/mL acrylamide)와 물 9 mL를 가하여 20분간 진탕한 후 원심분리기를 이용하여 9,000 rpm로 30분간 원심분리하였다. 물층 5 mL를 수거한 후 7,000 rpm으로 10분동안 원심분리하여 상층액을 수거하여 시험용액 A로 하였다.

메탄올 3.5 mL와 물 3.5 mL로 활성화시킨 Oasis HLB 6cc Extraction Cartridge (Waters, MA, USA)에 A액 1.5 mL를 넣어 통과시킨 후 물 0.5 mL는 흘려버리고 물 1.5 mL를 용출시켜 모아 시험용액 B액을 얻었다. 메탄올 2.5 mL와 물 2.5 mL로 활성화시킨 Bond Elut-Accucat 카트리지 (Agilent, CA, USA)에 B액 1.5 mL를 넣어 처음 유출되는 0.5 mL를 흘려버리고 이후 얻어진 1 mL를 액체크로마토그래프의 시험용액으로 하였다.

분석은 LC-MS/MS (API4000, AB SCIEX, MA, USA)를 사용하였으며, column은 C18 (2.1 × 150 mm, 1.8 μm), column 온도는 40℃, 이동상은 0.1% formic acid 용액 (A)과 methanol (B)을 사용하였다. Gradient program을 사용하여 solvent A를 0-3분 99.5%, 3-7분 99.5-90%, 7-8분 90%, 8-9분 90-99.5%, 9-15분 99.5%로 설정하였다. 유속은 0.2 mL/min, 시료는 5 μL를 주입하였다. 이온화 방식으로 ESI (positive)를 사용하였으며, capillary temperature가 350℃, capillary voltage는 2.0 kV를 사용하였다.

## 라. Polycyclic aromatic hydrocarbon (PAH) 분석


튀김 공정이 완료된 감자튀김 10 g을 분쇄하여 100 mL의 1 M KOH·EtOH 용액을 첨가하여 80 °C에서 3시간동안 soxhlet 추출하였다. 추출물을 감압 농축하여 2mL hexane으로 용해하였다. 정제를 위하여 Sep-Pak Vac 6cc Florisil Cartridge (Waters, MA, USA)를 사용하였다. 10 mL dichloromethane, 20 mL hexane으로 카트리지를 활성화하였다. 샘플을 카트리지에 로딩한 후 5 mL hexane, 15 mL의 hexane:dichloromethane (3:1, v/v)로 각각 용출시켰다. 용출액은 농축시켜 모든 용매를 증발시켰으며, 잔류물을 200 µL dichloromethane으로 용해시켜 0.45 µm membrane filter로 여과하여 시험용액으로 사용하였다.

GC-MS (QP-2010 Ultra, Shimadzu, Kyoto, Japan)로 PAH를 분석하였다. Column은 Elite-5MS (30 m×0.25 mm I.D, 0.25 µm film thickness), 가스는 헬륨, flow rate는 1.5 mL/min, split ratio는 5:1을 사용하였다. 주입부 온도는 300 °C로 설정하였다. Column 온도는 40 °C에서 2분간 유지하고 12 °C/분의 비율로 100 °C까지 온도를 상승시키고, 7 °C/분의 비율로 300 °C까지 온도를 상승시켰다. 이온화 방법은 EI mode, 이온화 voltage는 70 eV, ion source 및 interface 온도는 각각 200 °C, 300 °C로 설정하였다. 표준물질은 QTM PAH Mix (CRM47930, Merck, NJ, USA)을 사용하였다.

### 3. 동물실험

#### 가. 동물

실험동물은 5주령의 수컷 C57BL/6J 마우스를 (주)지바이오에서 구입하였고, 1주일 동안 적응기간을 거친 후 본 실험에 사용하였다. 사육실 환경은 온도 ( $22 \pm 1$  °C), 습도 ( $50 \pm 10\%$ ) 및 광주기 (명암 12시간 간격)가 조절되며, 모든 실험동물은 사료와 물을 자유 급식하였다. 적응기 후 무작위로 그룹 당 8마리씩 총 4그룹으로 구분하여 사육하였다 (Figure 35). 정상 식이 섭취 그룹 (n=8) (Normal Diet, N)은 일반 사료 (Teklad Global 18% Protein Rodent Diet, EVIGO, IN, USA)를 급여하였다. 고지방 및 고과당 식이 섭취 그룹 (n=8) (High Fat and high fructose Diet, HF)은 고지방 사료 (TD.06414, EVIGO, IN, USA)와 fructose를 각각 60%, 40% 비율로 혼합한 사료를 급여하였다. 상압후라이нг 감자튀김 섭취 그룹 (n=8) (Deep fried potatoes Diet, DF)은 일반 사료와 팜유로 상압후라이нг한 감자튀김을 각각 70%, 30% 비율로 혼합한 사료를 급여하였다. 감압후라이нг 감자튀김 섭취 그룹 (n=8) (Vacuum fried potatoes Diet, VF)은 일반 사료와 카놀라유로 감압후라이нг한 감자튀김을 각각 70%, 30% 비율로 혼합한 사료를 급여하였다. 총 12주간 급여하였으며, 사육 기간동안 식이 및 물은 제한 없이 자율 공급하였다. 체중 및 식이 섭취량은 실험기간동안 주 1회 측정하였다. 12주 후 실험동물을 sacrifice하였다. 간 (liver), 부고환지방 (epididymal fat)을 채취하여 무게를 측정하였다. Serum, cecum, fecal을 채취하여 cholesterol, triglyceride, SCFA, gut microbiota를 분석하였다. 본 실험은 조선대학교 실험동물윤리위원회의 사전심의를 받아 진행하였다 (CIACUC2021-A0029).



**Figure 35.** Schematic illustration of experimental design and samples. After 1 week adaption, 32 mice were divided randomly into four groups: the normal group was fed a standard chow diet (control, n=8) and the experimental group with a high-fat and high fructose diet (HFD, n=8), deep fried potatoes using palm oil (PD, n=8) and vacuum fried potatoes using canola oil (CV, n=8).

## 나. Biochemical parameter 분석

Biochemical parameter로 serum과 liver의 cholesterol 및 triglyceride 함량을 측정하였다. Cholesterol 함량 측정은 K603-100 키트 (Biovision, CA, USA)를 이용하였다. Standard curve는 cholesterol을 96 well 각 well 당 1  $\mu\text{g}$ , 2  $\mu\text{g}$ , 3  $\mu\text{g}$ , 4  $\mu\text{g}$ , 5  $\mu\text{g}$  농도를 갖게 제조하여 실험하였다. Serum은 cholesterol assay buffer로 50배 희석하여 사용하였다. Liver의 cholesterol 함량 측정 시 10 mg의 liver를 200  $\mu\text{L}$  chloroform:isopropanol:NP-40 (7:11:0.1, v/v)을 첨가하여 homogenize하였다. 15,000 g에서 10분동안 원심분리 후 상등액을 수거하였다. 50  $^{\circ}\text{C}$ 에서 chloroform을 제거한 후 진공상태에서 30분동안 방치하여 모든 유기용매를 제거한 후 200  $\mu\text{L}$  cholesterol assay buffer로 용해하여 실험하였다.

Standard 용액의 cholesterol 함량 측정 시 50  $\mu\text{L}$  standard 용액에 50  $\mu\text{L}$  reaction mix (44  $\mu\text{L}$  cholesterol assay buffer, 2  $\mu\text{L}$  cholesterol probe, 2  $\mu\text{L}$  cholesterol enzyme mix, 2  $\mu\text{L}$  cholesterol esterase)를 혼합하였다. Serum 및 liver의 cholesterol 함량 측정 시 50  $\mu\text{L}$  serum 및 liver 용액에 50  $\mu\text{L}$  reaction mix를 혼합하였다. 암막조건 및 37  $^{\circ}\text{C}$ 에서 60분동안 반응 후 570 nm에서 흡광값을 측정하여 cholesterol 함량을 계산하였다.

Triglyceride 함량 측정은 K622-100 키트 (Biovision, CA, USA)를 이용하였다. Standard curve는 2 nmol, 4 nmol, 6 nmol, 8 nmol, 10 nmol 농도의 triglyceride 용액을 사용하였다. Serum은 triglyceride assay buffer로 2배 희석하여 사용하였다. Liver의 triglyceride 함량 측정 시 100 mg의 liver를 1 mL의 5% NP-40을 첨가하여 homogenize하였다. 5분동안 100  $^{\circ}\text{C}$ 의 water bath에서 가열한 후 상온으로 냉각하였다. 가열 및 냉각 과정을 1회 더 반복하였다. 15,000 g에서 2분동안 원심분리 후 상등액을 수거하여 증류수로 20배 희석하여 실험하였다.

Standard 용액의 cholesterol 함량 측정 시 50  $\mu\text{L}$  standard 용액에 50  $\mu\text{L}$  reaction mix (46  $\mu\text{L}$  triglyceride assay buffer, 2  $\mu\text{L}$  triglyceride probe, 2  $\mu\text{L}$  triglyceride enzyme mix)를 혼합하였다. Serum 및 liver의 triglyceride 함량 측정 시 50  $\mu\text{L}$  serum 및 liver 용액에 50  $\mu\text{L}$  reaction mix를 혼합하였다. 암막조건 및 25  $^{\circ}\text{C}$ 에서 60분동안 반응 후 570 nm에서 흡광값을 측정하여 triglyceride 함량을 계산하였다.

## 다. SCFA 분석

Furuhashi 등 (2018)의 방법을 변형하여 분석하였다. Standard 물질은 0.01  $\mu\text{mol}$ , 0.05  $\mu\text{mol}$ , 0.1  $\mu\text{mol}$ , 0.5  $\mu\text{mol}$ , 1.0  $\mu\text{mol}$  농도로 제조하여 분석하였다 [204]. 총 650  $\mu\text{L}$ 의 부피로 제조하였으며, 125  $\mu\text{L}$ 의 20 mM NaOH와 100  $\mu\text{L}$ 의 pyridine, 70  $\mu\text{L}$ 의 isobutanol을 첨가한 후 standard 물질과 water를 첨가하였다. 1개의 boiling stone을 넣은 후 유도체화를 위하여 50  $\mu\text{L}$ 의 isobutyl chloroformate를 첨가하여 1분동안 gas 제거를 위하여 뚜껑을 열어놓았다. Vortex 후 250  $\mu\text{L}$ 의 hexane을 첨가하여 21,000 g에서 2분동안 원심분리하였다. 200  $\mu\text{L}$ 의 상등액을 수거하여 GC vial에 옮겼다.

Cecum의 적도 부분을 절단하여 100 mg의 cecal slurry를 수거하여 1 mL의 10% isobutanol과 혼합하여 30초간격으로 20초동안 6,000 rpm에서 기계적으로 균질화하였다. 21,000 g에서 5분동안 원심분리하여 675  $\mu\text{L}$ 의 상층액을 수거하였다. 125  $\mu\text{L}$ 의 20 mM NaOH와 400  $\mu\text{L}$ 의 chloroform을 첨가하여 vortex 후 21,000 g에서 2분동안 원심분리하였다. 400  $\mu\text{L}$ 의 상층액을 수거하여 100  $\mu\text{L}$ 의 pyridine, 70  $\mu\text{L}$ 의 isobutanol을 첨가한 후 water를 이용하여 최종 부피를 650  $\mu\text{L}$ 로 맞추었다. 1개의 boiling stone을 넣은 후 유도체화를 위하여 50  $\mu\text{L}$ 의 isobutyl chloroformate를 첨가하여 1분동안 gas 제거를 위하여 뚜껑을 열어놓았다. Vortex 후 250  $\mu\text{L}$ 의 hexane을 첨가하여 21,000 g에서 2분동안 원심분리하였다. 200  $\mu\text{L}$ 의 상등액을 수거하여 GC vial에 옮겼다.

GC-MS 분석은 QP-2010 Ultra (Shimadzu, Kyoto, Japan) 기기를 사용하였다. Column은 Elite-5MS (30 m  $\times$  0.25 mm I.D, 0.25  $\mu\text{m}$  film thickness, Perkinelmer, Massachusetts, USA)을 사용하였다. 시료 주입량은 1  $\mu\text{L}$ , injection mode는 split ratio(10:1), injection temperature는 250  $^{\circ}\text{C}$ 로 설정하였다. GC Column temperature는 50  $^{\circ}\text{C}$ 로 설정하였다. Carrier gas는 He을 사용하였고, 유속은 1.3 mL/min으로 설정하였다. Oven 온도는 50  $^{\circ}\text{C}$ 에서 5분동안 유지하고 5  $^{\circ}\text{C}/\text{min}$ 으로 150  $^{\circ}\text{C}$ 까지 승온하였고, 40  $^{\circ}\text{C}/\text{min}$ 으로 310  $^{\circ}\text{C}$ 까지 승온한 후 1분동안 유지하여 분석하였다. MS의 Ion source temperature는 250  $^{\circ}\text{C}$ , interface temperature는 0  $^{\circ}\text{C}$ 로 설정하였다. Ionization method는 EI, Ionization voltage는 70 eV로 설정하였다. Retention time과 질량스펙트럼을 확인하여 SIM (selected ion monitoring)모드로 정량분석 하였다.

## 라. 분변 microbiota composition 분석

실험동물의 분변을 채취하여  $-80\text{ }^{\circ}\text{C}$ 에서 보관하였다. 분변의 genomic DNA을 분리 및 정제하기 위해 QIAamp DNA Stool Mini Kit (Qiagen, MD, USA)를 사용하였다. 분변에 ASL 버퍼 1.4 mL를 첨가하고 1분간 vortexing 후  $70\text{ }^{\circ}\text{C}$ 에서 5분동안 반응시켰다. 15초동안 vortexing하고 1분동안 원심분리한 후 2 mL 상등액을 수거하여 InhibitEX Tablet을 넣어 1분동안 반응시켰다. 3분동안 원심분리 후 1.5 mL 상등액을 수거하여, 다시 3분동안 원심분리하였다. 15  $\mu\text{L}$ 의 proteinase K 및 200  $\mu\text{L}$  AL buffer를 넣고 15초 동안 vortexing한 후  $70\text{ }^{\circ}\text{C}$ 에서 5분동안 반응한 뒤 QIAamp spin column에 옮기고 1분동안 원심분리 한 후 AW1 buffer 500  $\mu\text{L}$ 를 넣고 1분동안 원심분리하여 상등액을 수거하였다. AW2 buffer 500  $\mu\text{L}$ 를 넣고 3분동안 원심분리를 하였다. 12,000 rpm에서 1-2분간 원심분리 하면서 멤브레인을 건조한 후, collection tube를 버리고 recovery tube를 장착하여 AE buffer 100  $\mu\text{L}$ 를 중앙에 분주하여 실온에서 1분 동안 incubate하였다. 12,000 rpm에서 1분 동안 원심분리하여 DNA를 추출하고 total DNA의 농도를 정량하였다.

추출된 DNA는 NGS분석의 template DNA로 활용하였다. NGS 분석을 위하여 라이브러리는 Illumina의 16S metagenomic library prep guide sequencing을 변형하여 제작하였다. V4 region 증폭을 위하여 프라이머 (forward:5'-TCGTCGGCAGCGTCAGATGTGTATAAGAGACAGGTGYCAGCMGCCGCGGTAA-3', reverse:5'-GTCTCGTGGGCTCGGAGATGTGTATAAGAGACAGGGACTACNVGGGTWTCTAAT)를 제작하여 사용하였다. PCR 조건으로 pre-denaturation은  $94\text{ }^{\circ}\text{C}$ 에서 3분, denaturation은  $55\text{ }^{\circ}\text{C}$ 에서 30초, annealing은  $72\text{ }^{\circ}\text{C}$ 에서 30초를 사용하였으며, 25회 반복 후 extension은  $72\text{ }^{\circ}\text{C}$ 에서 5분으로 사용하였다.

증폭산물의 clean-up 과정은 Agencourt AMPure XP beads (BeckmanCoulter, CA, USA)를 이용하였으며, 인덱스를 붙이는 2차 PCR을 이용하여 라이브러리를 제작하였다. 라이브러리는 Qubit4.0 (Thermo Fisher Scientific, MA, USA)을 사용하여 정량하였다. 사이즈는 Qsep1 (Bioptic, New Taipei City, Taiwan)을 이용하여 측정하였다. 라이브러리 농도를 20 pmol로 설정하고, pooling을 통해 mixture를 제조하여 카트리지에 20  $\mu\text{L}$ 의 분석 샘플을 로딩하였다. Iseq100 (Illumina, CA, USA) 장비를 이용하여 분석하였다. 분석 결과는 FASTQ 파일로 생성되었으며, EZBioCloud (ChunLab, Seoul, South Korea) 플랫폼과 BaseSpace (Illumina, CA, USA) 플랫폼을 통해 meta-



genome을 분석하였다. Shannon diversity index, Simpson index를 통해 시료 내 미생물군집의 다양성과 균등도인  $\alpha$ -diversity를 분석하고,  $\beta$ -diversity를 통해 시료 간의 상관관계를 확인하였다.

#### 4. 통계

반복 실험 결과는 평균과 표준편차로 나타내었다. SPSS (version 26.0, IBM, NY, USA) 프로그램을 이용하여 분산분석 (ANOVA)을 실시하여 그룹 간의 유의성 ( $p < 0.05$ )을 확인하였다. Tuckey test로 사후검정하여 통계적으로 유의한 차이가 있는 그룹을 영어 소문자로 표시하였다.

### 제3절 실험결과 및 토의

#### 1. Frying 및 toxic compounds 분석

##### 가. Fatty acid 분석

후라이нг 방법 및 오일 종류에 따른 감자튀김에 함유된 fatty acid 함량은 Table 11과 같다. 오일을 추출하는 식물의 종류에 따라서 saturated fatty acids (SFA), mono-unsaturated fatty acids (MUFA), polyunsaturated fatty acids (PUFA)의 비율이 상이하다. 카놀라유 (CD, CV) 및 팜유 (PD, PV)를 이용하여 후라이한 샘플을 구성하고 있는 fatty acid 종류는 각각 MUFA>PUFA>SFA 및 MUFA>SFA>PUFA의 순서였다. CD, CV의 주성분은 oleic acid (C18:1, cis)와 linoleic acid (C18:2, cis)였고, PD, PV의 주성분은 oleic acid (C18:1, cis), palmitic acid (C16:0), linoleic acid (C18:2, cis)였다.

튀김은 높은 온도의 열을 사용하기 때문에, 가열 산화, 불포화 지방산의 감소, 가수분해, 중합체 형성이 일어나면서 품질이 저하되는 산패 현상이 발생한다. 산소가 존재하는 조건인 상압후라이에서는 유지의 산화가 발생할 수 있다. 유지의 산화 시 불포화 지방산이 산소와 반응하여 산화 생성물을 형성한다. 카놀라유는 다른 식물성 오일에 비하여 SFA 함량이 낮고, 발연점이 높아 튀김 시 사용하면 좋다. 팜유는 SFA 함량이 높아 산화가 비교적 느리게 발생하여 튀김 공정에서 많이 사용된다.

Oleic acid (C18:1, trans) 함량은 deep frying (CD, PD)이 vacuum frying (CV, PV)보다 유의적으로 높을 것을 확인하였다. 이는 진공 상태에서 frying이 되는 vacuum frying인 경우 산소에 의한 유지의 산화가 저해된 것으로 판단된다. Linoleic acid (C18:2, trans) 함량은 PD에서 유의적으로 증가하였다.

유지에 포함된 SFA 및 트랜스지방은 혈중 LDL-cholesterol 농도는 증가시키고, HDL-cholesterol 농도는 감소시켜 관상동맥 및 동맥경화 질병을 유발시킨다. 트랜스지방은 섭취 시 체내에 축적되며, 축적량과 유방암 및 대장암 유발 가능성은 상관관계가 있다. 세계보건기구에서는 트랜스지방을 전체 에너지 섭취량의 1% 미만 (하루 2,000 kcal를 섭취할 경우 트랜스지방은 약 2.2 g 미만)으로 섭취하도록 권고하고 있다.

**Table 11. Analyzed fatty acid composition (% total fatty acids) in CD, CV, PD, and PV**

		(unit : %)			
Fatty acid		CD	CV	PD	PV
<b>Saturated</b>					
C8:0	Caprylic acid	n.d.	n.d.	n.d.	0.024 ± 0.00095
C10:0	Capric acid	n.d.	n.d.	n.d.	0.030 ± 0.00018
C11:0	Undecanoic acid	n.d.	n.d.	n.d.	0 ± 0
C12:0	Lauric acid	0.03 ± 0.0049	n.d.	0.18 ± 0.017	0.33 ± 0.023
C13:0	Tridecanoic acid	n.d.	n.d.	n.d.	n.d.
C14:0	Myristic acid	0.12 ± 0.0078 <sup>a</sup>	0.073 ± 0.0057 <sup>b</sup>	0.97 ± 0.010 <sup>c</sup>	1.03 ± 0.015 <sup>d</sup>
C15:0	Pentadecanoic acid	0.025 ± 0.00076 <sup>a</sup>	0.020 ± 0.0021 <sup>a</sup>	0.039 ± 0.0018 <sup>b</sup>	0.042 ± 0.00060 <sup>b</sup>
C16:0	Palmitic acid	7.53 ± 0.25 <sup>a</sup>	5.25 ± 0.061 <sup>b</sup>	34.20 ± 0.26 <sup>c</sup>	35.20 ± 0.079 <sup>d</sup>
C17:0	Margaric acid	0.050 ± 0.0015 <sup>a</sup>	0.045 ± 0.0025 <sup>a</sup>	0.081 ± 0.0029 <sup>b</sup>	0.077 ± 0.0039 <sup>b</sup>
C18:0	Stearic acid	2.08 ± 0.19 <sup>a</sup>	1.97 ± 0.063 <sup>a</sup>	3.51 ± 0.026 <sup>b</sup>	3.62 ± 0.031 <sup>b</sup>
C20:0	Arachidic acid	0.59 ± 0.037 <sup>a</sup>	0.59 ± 0.0099 <sup>a</sup>	0.38 ± 0.0059 <sup>b</sup>	0.36 ± 0.0024 <sup>b</sup>
C21:0	Heneicosanoic acid	0.049 ± 0.00081	0.046 ± 0.00031	0.023 ± 0.00017	n.d.
C22:0	Behenic acid	0.26 ± 0.016 <sup>a</sup>	0.28 ± 0.0053 <sup>a</sup>	0.093 ± 0.0081 <sup>b</sup>	0.071 ± 0.0039 <sup>c</sup>
C23:0	Tricosanoic acid	0.031 ± 0.00095	0.031 ± 0.00021	0.023 ± 0.00017	0.018 ± 0.00011
C24:0	Lignoceric acid	0.15 ± 0.0076 <sup>a</sup>	0.16 ± 0.0088 <sup>a</sup>	0.083 ± 0.0081 <sup>b</sup>	0.083 ± 0.0065 <sup>b</sup>
<b>Monounsaturated</b>					
C16:1	Palmitoleic acid	0.22 ± 0.0069	0.22 ± 0.0054	0.22 ± 0.0077	0.23 ± 0.0079
C17:1	Heptadecenoic acid	n.d.	n.d.	n.d.	n.d.
C18:1, trans	Oleic acid	0.083 ± 0.0087 <sup>a</sup>	0.046 ± 0.00031 <sup>b</sup>	0.081 ± 0.0029 <sup>a</sup>	0.061 ± 0.00037 <sup>c</sup>
C18:1, Cis	Oleic acid	61.21 ± 1.27 <sup>a</sup>	64.23 ± 0.23 <sup>b</sup>	46.19 ± 0.23 <sup>c</sup>	44.56 ± 0.13 <sup>d</sup>
C20:1	Gadoleic acid	1.34 ± 0.058 <sup>a</sup>	1.39 ± 0.017 <sup>a</sup>	0.28 ± 0.0022 <sup>b</sup>	0.25 ± 0.0026 <sup>b</sup>
C24:1	Nervonic acid	0.13 ± 0.0040	0.12 ± 0.00080	n.d.	n.d.
<b>Polyunsaturated</b>					
C18:2, trans	Linoleic acid	0.15 ± 0.0013 <sup>a</sup>	0.16 ± 0.0040 <sup>a</sup>	0.36 ± 0.00059 <sup>b</sup>	0.14 ± 0.035 <sup>a</sup>
C18:2, Cis	Linoleic acid	18.04 ± 0.64 <sup>a</sup>	17.97 ± 0.086 <sup>a</sup>	12.15 ± 0.12 <sup>b</sup>	13.03 ± 0.23 <sup>c</sup>
C18:3n-3	Linolenic acid	7.59 ± 0.27 <sup>a</sup>	7.29 ± 0.045 <sup>b</sup>	1.08 ± 0.0082 <sup>c</sup>	0.81 ± 0.0032 <sup>d</sup>
C20:2	Eicosadienoic acid	0.096 ± 0.0038 <sup>a</sup>	0.090 ± 0.0036 <sup>b</sup>	0.040 ± 0.00031 <sup>c</sup>	0.030 ± 0.00018 <sup>d</sup>
C22:n-9	Erucic acid	0.091 ± 0.0011	0.020 ± 0.00014	0.0057 ± 0.00	0.0061 ± 0.00
C20:3n-3	Eicosatrienoic acid	0.0062 ± 0.00019	0.0051 ± 0.00	n.d.	n.d.
Total saturated		11.02 ± 0.69 <sup>a</sup>	8.47 ± 0.16 <sup>b</sup>	39.58 ± 0.35 <sup>c</sup>	40.88 ± 0.17 <sup>d</sup>
Total monounsaturated		63.00 ± 1.35 <sup>a</sup>	66.00 ± 0.26 <sup>b</sup>	46.78 ± 0.24 <sup>c</sup>	45.10 ± 0.14 <sup>d</sup>
Total polyunsaturated		25.98 ± 0.92 <sup>a</sup>	25.54 ± 0.14 <sup>a</sup>	13.64 ± 0.13 <sup>b</sup>	14.03 ± 0.27 <sup>b</sup>
Total fatty acid		0.24 ± 0.0058 <sup>a</sup>	0.21 ± 0.0058 <sup>ab</sup>	0.44 ± 0.058 <sup>c</sup>	0.20 ± 0.035 <sup>b</sup>

The data are presented as the mean ± SD, and compared using analysis of variance (ANOVA) followed by Tuckey test. The different letters are indicated statistically differences within the fried potatoes' samples (CD, CV, PD, PV).


## 나. Acrylamide 분석

Acrylamide 분석 결과는 Figure 36과 같다. CD, CV의 acrylamide 함량은  $0.256 \pm 0.0066$  mg/kg,  $0.033 \pm 0.002$  mg/kg였으며, vacuum frying 시 acrylamide 함량이 유의적으로 감소하였다. PD, PV의 acrylamide 함량은  $0.16 \pm 0.0085$  mg/kg,  $0.29 \pm 0.0017$  mg/kg였으며, vacuum frying 시 acrylamide 함량이 유의적으로 증가하였다.

일반적으로 vacuum frying 시 deep frying 보다 비교적 낮은 온도를 사용하여, acrylamide 함량이 낮아진다고 알려져있다. 그러나 낮은 온도에서 vacuum frying을 하여도, 오일 종류 및 기타 조건에 따라서 acrylamide 함량이 증가하는 것을 확인하였다. 따라서 deep frying 시에는 카놀라유 사용 시 acrylamide 발생량이 팜유에 비하여 유의적으로 높기 때문에, 카놀라유 사용을 자제하여야 한다. 대조적으로 vacuum frying 시에는 팜유 사용 시 acrylamide 발생량이 카놀라유에 비하여 유의적으로 높기 때문에, 팜유 사용을 자제하여야 한다.

Mariotti-Celis 등 (2017)은 슬라이스한 감자를 sunflower oil에 튀긴 후 acrylamide 함량을 비교하였다. 실험결과 vacuum frying이 deep frying보다 유의적으로 낮은 acrylamide 함량을 나타내었으며, driving force (°C)가 증가할수록 vacuum frying sample의 acrylamide 함량이 증가하였다 [193].

Shyu 등 (2021)은 fried bread인 Youtiao을 potassium aluminum sulfite 처리한 후 frying하여 acrylamide 함량을 비교하였다 [205]. 실험 결과 vacuum frying sample이 deep frying sample보다 acrylamide 함량이 더 높았다.



**Figure 36.** Analyzed acrylamide in CD, CV, PD, and PV. The data are presented as the mean  $\pm$  SD, and compared using analysis of variance (ANOVA) followed by Tuckey test. The different letters are indicated statistically differences within the fried potatoes' samples (CD, CV, PD, PV).

## 다. Polycyclic aromatic hydrocarbon (PAH) 분석

PAH 분석결과는 Table 12와 같다. Deep frying 샘플 (CD, PD)에서는 PAH가 검출되지 않았고, vacuum frying 샘플 (CV, PV)에서는 PAH가 검출되었다. CV 샘플의 총 PAH 함량은  $27.64 \pm 0.048 \mu\text{g}/\text{kg}$ 이었고, phenanthrene, fluoranthene, pyrene이 검출되었다. PV 샘플의 총 PAH 함량은  $46.17 \pm 0.182 \mu\text{g}/\text{kg}$ 이었고, phenanthrene, fluoranthene, pyrene, benz[a]anthracene, chrysene, benzo[a]pyrene, benzo[ghi]perylene이 검출되었다. PV 샘플의 benzo[a]pyrene 함량은  $5.09 \pm 0.060 \mu\text{g}/\text{kg}$ 였다. Benzo[a]pyrene은 인체 발암물질로 규정되어 있으며, 식약처에서 식용유지의 Benzo[a]pyrene 함량을  $2.0 \mu\text{g}/\text{kg}$  이하로 규제하고 있다.

Vacuum frying 샘플에서만 PAH가 검출된 이유는 vacuum condition으로 인한 불완전 연소, 비교적 긴 튀김 시간이라고 판단된다. Shin (2012)은 온도 및 시간 별로 deep frying한 감자튀김의 PAH 함량을 측정하였으며, 온도 및 시간이 증가할수록 PAH 함량이 증가한 것을 확인하였다 [206].

Purcaro 등 (2006)은 peanut oil과 hydrogenated vegetable oil로 deep frying한 potato chip의 PAH 함량을 측정하였다 [207]. 다양한 종류의 PAH 검출되었으며, 11개 sample의 benzo[a]pyrene 함량은 0-1.2 ppb였고, PAH 총 함량은 2.1-16.1 ppb였다.

따라서 vacuum frying 시 deep frying보다 총 PAH 함량이 더 높을 수 있고, benzo[a]pyrene 함량이 기준치를 초과할 수 있다.

**Table 12. Analyzed polycyclic aromatic hydrocarbons (PAH) in CD, CV, PD, and PV**

(unit :  $\mu\text{g}/\text{kg}$ )

	CD	CV	PD	PV
Phenanthrene	n.d.	$6.02 \pm 0.029^*$	n.d.	$2.46 \pm 0.051^*$
Fluoranthene	n.d.	$11.90 \pm 0.070^*$	n.d.	$10.43 \pm 0.040^*$
Pyrene	n.d.	$9.72 \pm 0.031^*$	n.d.	$7.20 \pm 0.079^*$
Benz[a]anthracene	n.d.	n.d.	n.d.	$3.82 \pm 0.045$
Chrysene	n.d.	n.d.	n.d.	$3.91 \pm 0.070$
Benzo[a]pyrene	n.d.	n.d.	n.d.	$5.09 \pm 0.060$
Benzo[ghi]perylene	n.d.	n.d.	n.d.	$13.27 \pm 0.073$
Total	-	$27.64 \pm 0.048^*$	-	$46.17 \pm 0.182^*$

## 2. 동물실험

### 가. 동물

Mouse 식이 실험 시 PD 그룹은 팜유를 이용하여 상압후라이한 감자튀김을 섭취하였고, CV 그룹은 카놀라유를 이용하여 감압후라이한 감자튀김을 섭취하였다. PD는 비교적 높은 trans fatty acid 및 acrylamide 함량을 가졌고, PAH는 함유하고 있지 않았다. CV는 비교적 낮은 trans fatty acid 및 acrylamide 함량을 가졌고, PAH는 함유하였다. 대조적인 유해성분을 함유하는 감자튀김 샘플이 microbiota에 미치는 영향을 확인하였다.

12주동안 식이 후 그룹 간 body weight 측정하였으며, 실험결과 N 그룹에 비하여 HF, PD, CV 그룹의 body weight가 유의적으로 증가하였다 (Figure 37). N 그룹은  $30.09 \pm 1.18$  g, HF 그룹은  $38.42 \pm 2.20$  g, PD 그룹은  $36.10 \pm 3.77$  g, CV 그룹은  $38.19 \pm 2.19$  g이었다. Liver weight 측정 결과 N 그룹은  $1.22 \pm 0.10$  g, HF 그룹은  $1.35 \pm 0.12$  g, PD 그룹은  $1.32 \pm 0.11$  g, CV 그룹은  $1.38 \pm 0.15$  g이었다. N 그룹에 비하여 HF, PD, CV 그룹의 liver weight가 증가하였지만, 그룹 간 통계적 유의성은 없었다. Epididymal fat weight 측정 결과 N 그룹은  $0.96 \pm 0.16$  g, HF 그룹은  $2.33 \pm 0.29$  g, PD 그룹은  $1.86 \pm 0.46$  g, CV 그룹은  $2.05 \pm 0.25$  g이었다. N 그룹에 비하여 HF, PD, CV 그룹의 epididymal fat weight가 유의적으로 증가하였다.



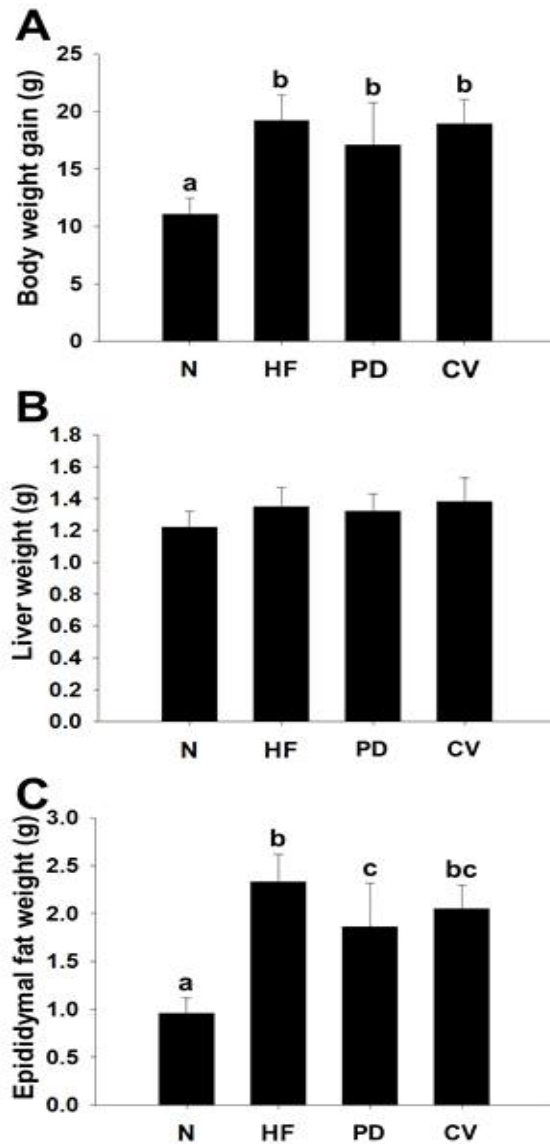


Figure 37. Effect of fried potatoes on (A) body weight gain, (B) liver weight and (C) epididymal fat weight in N-fed, HF-fed, PD-fed and CV-fed mice during 12 weeks (n = 8 per group). The data are presented as the mean  $\pm$  SD, and compared using analysis of variance (ANOVA) followed by Tuckey test. The different letters are indicated statistically differences within the diet fed groups (N, HF, PD, CV).


## 나. Biochemical parameter 분석

Cholesterol 함량 분석 결과는 Figure 38과 같다. Serum의 total cholesterol을 mouse 식이 그룹 간 비교하였다. N 그룹에 비하여 HF 그룹의 total cholesterol은 유의적으로 증가하였다. PD, CV 그룹의 total cholesterol은 N 그룹에 비하여 높았고, HF 그룹에 비하여 낮았다. Liver의 total cholesterol은 HF, PD, CV 그룹이 N 그룹보다 높았지만 통계적 유의성은 없었다.


Triglyceride 함량 분석 결과는 Figure 39와 같다. Serum의 triglyceride를 mouse 식이 그룹 간 비교하였다. N 그룹에 비하여 HF, PD, CV 그룹의 triglyceride은 증가하였지만, 통계적 유의성은 없었다. Liver의 triglyceride는 HF 그룹이 N, PD, CV 그룹보다 유의적으로 높았다. PD, CV 그룹은 N 그룹보다 triglyceride 함량이 높았지만, 통계적 유의성은 없었다.

PD, CV 식이 시 serum과 liver의 biochemical parameter는 N 그룹과 유의적인 차이가 없었다. 이는 PD, CV 식이 시 과체중, 비만은 발생했지만 metabolism disorder는 발생하지 않은 것을 확인하였다.

Liang 등 (2021)은 C57BL/6 mouse에게 12주동안 고지방 (HFD, ; 60% of energy from fat, 20% from protein, and 20% from carbohydrates) 및 고콜레스테롤 (HFHCD, 40% of energy from fat, 20% from protein, and 40% from carbohydrates)을 식이하여 포도당 및 지질 metabolism이 biochemical parameter (triglyceride, cholesterol)에 미치는 영향을 확인하였다 [208]. 측정결과 탄수화물 함량이 높은 HFHCD 그룹은 normal 그룹에 비하여 유의적인 biochemical parameter 차이가 있었지만, HFD 그룹은 normal 그룹에 비하여 유의적인 biochemical parameter 차이가 없었다. 이는 본 연구와 유사한 실험결과이며, 본 연구의 HF 그룹은 fructose 함량이 높아 고콜레스테롤 식이로 간주할 수 있으며, PD, CV는 감자튀김이 함유되어 있어 고지방 식이로 간주할 수 있다.



**Figure 38.** Concentration of cholesterol at serum and liver of N-fed, HF-fed, PD-fed and CV-fed mice. The data are presented as the mean  $\pm$  SD, and compared using analysis of variance (ANOVA) followed by Tuckey test. The different letters are indicated statistically differences within the diet fed groups (N, HF, PD, CV).

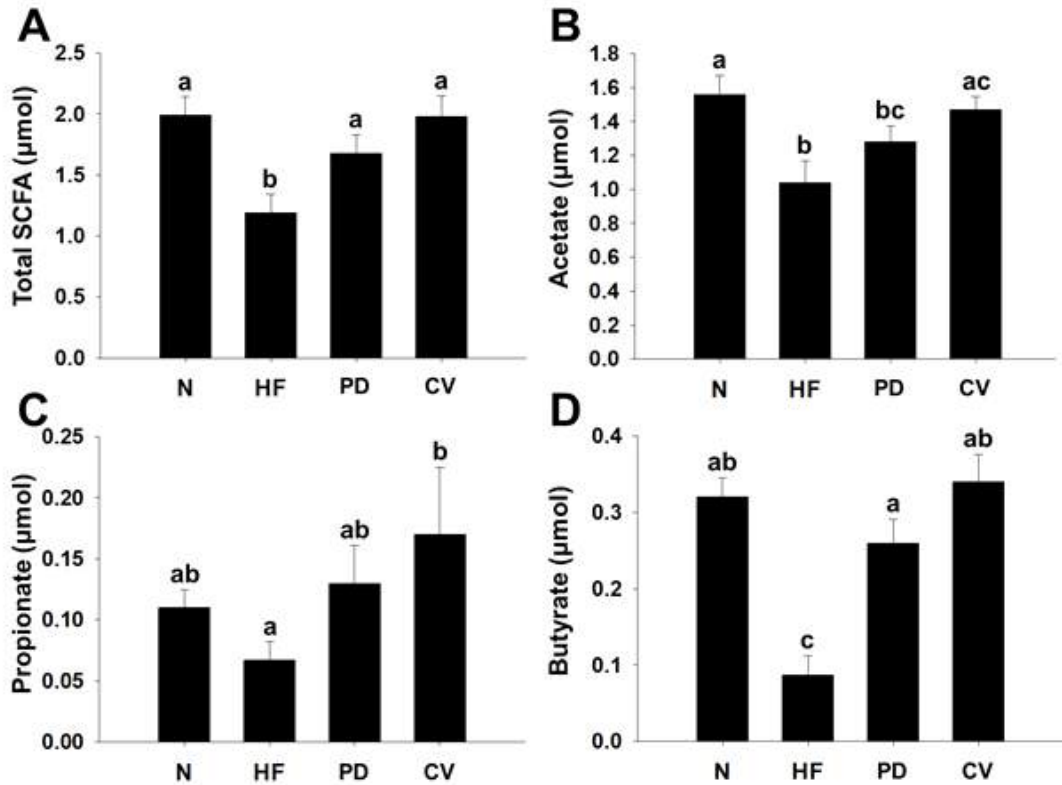


**Figure 39.** Concentration of triglyceride at serum and liver of N-fed, HF-fed, PD-fed and CV-fed mice. The data are presented as the mean  $\pm$  SD, and compared using analysis of variance (ANOVA) followed by Tuckey test. The different letters are indicated statistically differences within the diet fed groups (N, HF, PD, CV).

## 다. SCFA 분석

Non-digestible carbohydrate는 맹장에서 장내 microbiota에 의하여 발효되어 SCFA를 생성한다. 본 연구에서는 acetate, propionate, butyrate 함량을 분석하였고, total SCFA 함량은 acetate, propionate, butyrate 함량의 합으로 계산하였다 (Figure 40). Total SCFA 함량은 N 그룹이  $1.99 \pm 0.15 \mu\text{mol}$ , HF 그룹이  $1.19 \pm 0.15 \mu\text{mol}$ , PD 그룹이  $1.68 \pm 0.15 \mu\text{mol}$ , CV 그룹이  $1.98 \pm 0.17 \mu\text{mol}$ 로 측정되었다. HF 그룹만 N, PD, CV 그룹에 비하여 유의적으로 낮았고, PD, CV 그룹은 N 그룹과 통계적으로 동일하였다.

Propionate는 cholesterol 합성을 억제하고, 비만을 예방할 수 있다는 연구가 있다 [209]. HF 그룹은 N 그룹에 비해 propionate 함량이 낮았다. PD, CV 그룹은 N 그룹에 비해 propionate 함량이 높았으며, 이는 감자튀김에 함유된 non-digestible carbohydrate 섭취에 의한 것으로 예측된다 [210, 211]. Bang 등 (2019)은 전분 섭취 시 장내 microbiota에 미치는 영향을 조사하기 위하여 옥수수, 밀, 쌀, 감자 전분을 16주 동안 mouse에게 식이하였다 [212]. 맹장의 SCFA 함량을 측정하였고, 실험결과 감자 전분 식이 그룹의 propionate 함량이 다른 그룹들보다 유의적으로 높았다.



**Figure 40.** Concentration of short chain fatty acid (SCFA) which are (A) total SCFA, (B) acetate, (C) propionate, and (D) butyrate at cecum of N-fed, HF-fed, PD-fed and CV-fed mice. The data are presented as the mean  $\pm$  SD, and compared using analysis of variance (ANOVA) followed by Tuckey test. The different letters are indicated statistically differences within the diet fed groups (N, HF, PD, CV).

## 라. 분변 microbiota composition 분석

$\alpha$ -Diversity는 OTU (Operational Taxonomic Unit), Shannon 지수를 이용하여 분석하였다 (Figure 41A, B). OTU는 HF 식이 시 N 그룹에 비하여 유의적으로 감소하였으며, PD 및 CV 그룹은 N 그룹과 통계적으로 유의하였다. Shannon은 HF, PD, CV 식이 시 N 그룹에 비하여 유의적으로 감소하였다.

$\beta$ -Diversity는 UniFrac을 이용하여, species와 genus에 대하여 분석하였다 (Figure 41C, D). Species 및 genus 모두 그룹 간 경계가 뚜렷하여, 분류가 가능하였다. Species 분석 결과 1st PC 값을 기준으로 N, PD는 같은 그룹으로 분류할 수 있고, HF 및 CV는 다른 그룹으로 분류할 수 있다. Genus 분석 결과 그룹 간 경계가 애매한 sample이 있지만, 1st PC 값을 기준으로 N, PD와 HF, CV는 각각 같은 그룹으로 분류할 수 있다. 따라서 PD 섭취 시 microbiota 변화가 normal 그룹과 거의 동일하다고 볼 수 있지만, CV 섭취 시에는 HF 그룹의 microbiota와 유사하게 변화하는 것을 확인하였다.

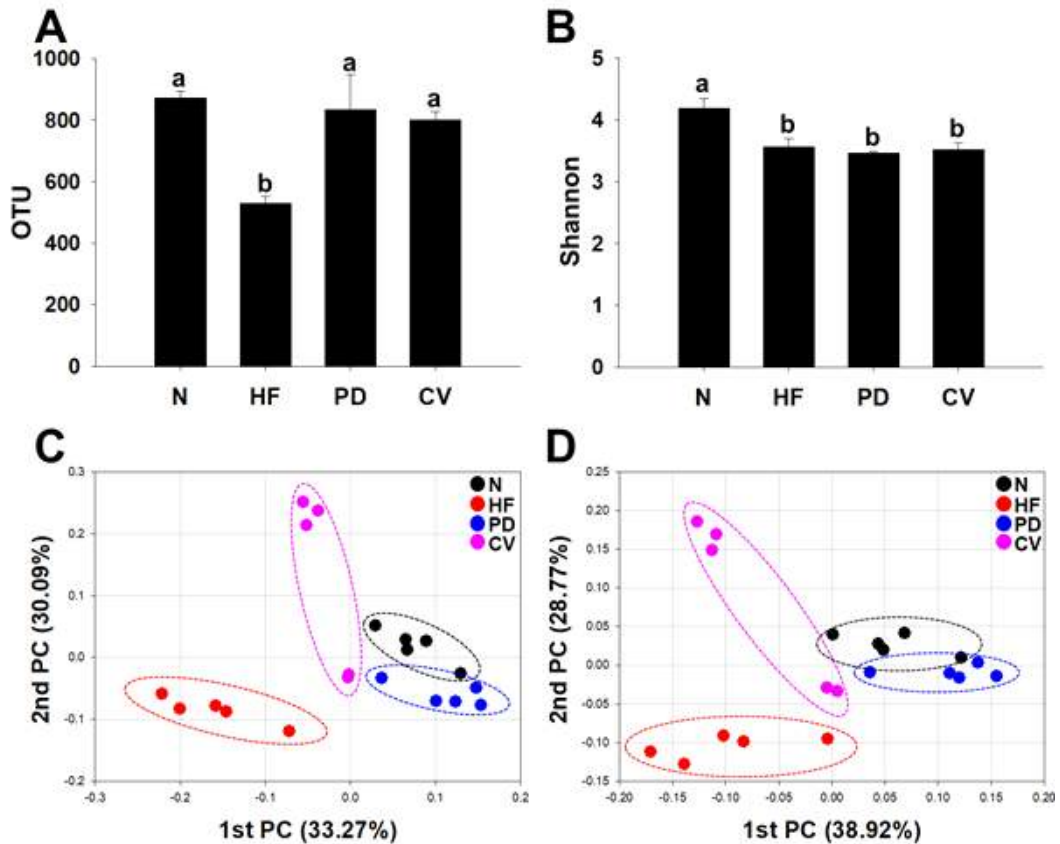
Phylum level에서 N, HF, PD, CV 그룹의 relative abundance 측정 결과, *Firmicutes*가 가장 높은 abundance를 나타내었고, *Bacteroidetes*가 2번째로 높은 abundance를 나타내었다 (Figure 42A). *Firmicutes* (F)/*Bacteroidetes* (B) ratio 증가는 obesity와 양의 상관관계를 가진다고 알려져 있다 [213]. HFD 식이 시 C57BL/6J 마우스의 비만과 염증이 발생하고, F/B ratio가 증가한 연구 결과가 있다 [214]. N 그룹에 비하여 HF, CV 그룹의 F/B ratio가 증가하였고, PD 그룹의 F/B ratio가 감소하였다.

*Proteobacteria*의 abundance 증가는 gut microbiota의 dysbiosis를 유발한다. N, HF, PD, CV 그룹의 *Proteobacteria* abundance (%)는 각각  $0.038 \pm 0.015\%$ ,  $0.12 \pm 0.13\%$ ,  $0.046 \pm 0.051\%$ ,  $0.22 \pm 0.22\%$ 로서 N 그룹에 비하여 HF, CV 그룹의 수치가 증가하였으나 유의적인 차이는 없었다.

Class 및 family level의 relative abundance 측정 결과, CV 그룹의 *Erysipelotrichi* 및 *Erysipelotrichaceae*의 abundance가 다른 그룹에 비하여 매우 높은 것을 확인할 수 있다 (Figure 42B, C). Melanie *et al.* (2011)의 연구는 *Erysipelotrichi*의 abundance는 지방간 및 지방간 환자 예측과 양의 상관관계가 있는 것을 human trial을 통하여 밝혔다 [215]. Kaakoush (2015)의 연구에 따르면 *Erysipelotrichaceae*은 host (human)의 lipid metabolism과 연관이 있고, 특정 species는 염증을 유발할 수 있다 [216].

이와 같은 fecal microbiota composition 결과를 통하여 CV가 PD 섭취에 비하여 obesity, dysbiosis, 지방간 유발 확률이 높은 것을 확인하였다.





**Figure 41.** Fecal microbial diversity indices of the groups. Alpha diversity was estimated with (A) OTU value and (B) Shannon index to indicate bacterial richness and diversity. Beta diversity was estimated with principal coordinates analysis (PCoA) plot of UniFrac distance values for (A) species level and (B) genus level. All groups of  $\alpha$  diversity indices (OTU and Shannon) data are presented as the mean  $\pm$  SD, and compared using analysis of variance (ANOVA) followed by Tuckey test. The different letters are indicated statistically differences within the diet fed groups (N, HF, PD, CV).

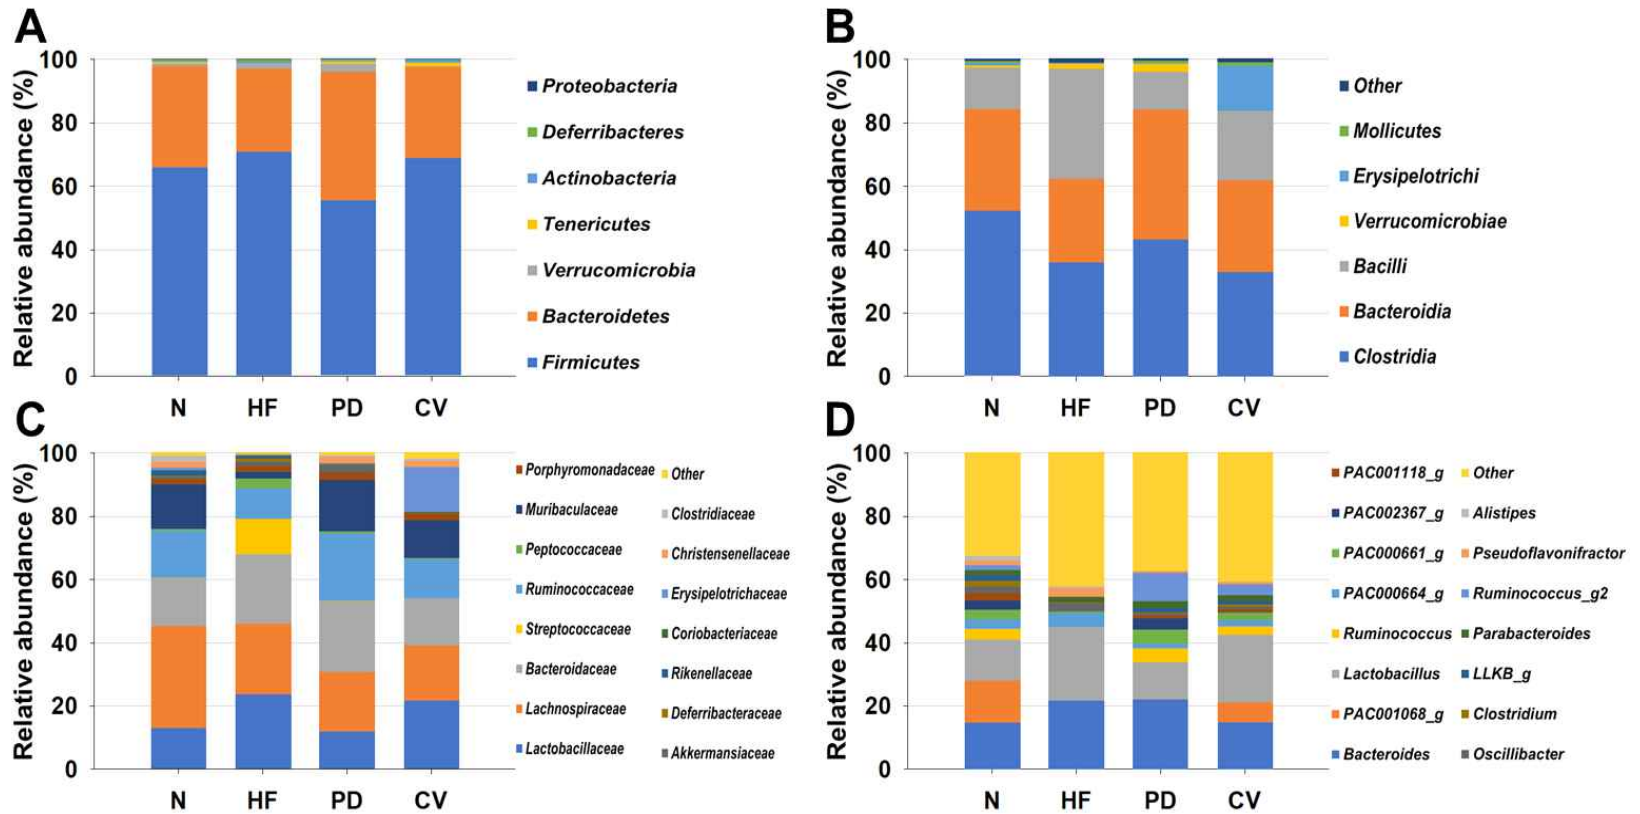


Figure 42. Relative abundance (%) of mice fecal microbiota at the (A) phylum, (B) class, (C) family, and (D) genus level in all groups. The level of class, family, and genus with a proportion less than 1% are indicated by other.

## 제4절 요약

본 연구에서는 감자튀김 섭취가 건강에 유해한 지를 확인하였다. 튀김 오일 및 방법에 대한 감자튀김의 toxic compounds 함량을 분석하였고, mouse model과 meta-genome analysis를 이용하여 감자튀김 식이가 체내와 gut microbiota에 미치는 영향을 확인하였다. 본 연구의 신규한 finding은 다음과 같다: 1) 감압후라이 기술은 상압후라이 기술보다 toxic compounds 발생이 낮다고 알려져 있지만, PAH의 경우 감압후라이 시 함량이 더 높았다; 2) 감자튀김 식이 시 몸무게는 증가하지만, 체내 cholesterol 및 triglyceride 함량은 HF 그룹과 유사한 수준은 아니었다; 3) Gut microbiota 분석 결과 CV가 PD보다 더 많은 부정적인 변화가 발생하였다. 따라서 감자튀김 섭취는 건강에 유해한 영향을 미칠 수도 있으며, 이는 튀김 오일과 방법으로 조절할 수 있다. 추가적으로 다양한 오일을 이용하여 gut microbiota에 미치는 영향을 추가 연구가 필요하다.

## 제5장 결론

최근 건강에 대한 관심이 높아지면서 웰빙식품의 소비가 증가하고 있다. 이 때문에 농산물과 가공농산물이 각광을 받고 있다. 같은 품종의 농산물이라도 재배 및 저장 환경에 따라 내부 품질의 차이가 발생한다. 따라서 농산물 가공식품을 제조할 때 원료의 품질을 예측하고 가공공정을 최적화하는 것이 필요하다. 본 연구에서는 감자, 고구마 및 그 가공식품의 품질 예측 및 최적화를 위해 3가지 topic을 연구하였다.

첫 번째 topic은 고구마 내부 품질 예측을 위한 근적외선 분광법 및 다변수 분석 연구이다. 고구마의 산업적 대량 가공에 적합한 원물 내부 품질 측정을 위한 비파괴적 NIR 측정 기술을 개발하였다. 수분 및 전분 함량,  $\alpha$ -amylase 활성을 포함한 고구마의 내부 품질을 재배 후 저장기간동안 측정하였다. PLS 모델링 결과  $\alpha$ -amylase 활성을 제외한 수분 및 전분 함량은 NIR spectrum을 이용하여 예측이 가능하였다. 또한, NIR spectrum을 LDA 분석을 통하여 수분 및 전분 함량에 대한 5개의 class로 분류가 가능한 것을 확인하였다. 본 연구에서는 고구마를 고정시킨 후 NIR spectrum을 측정하였다. 이전 연구에서는 로드셀에 고구마를 올린 후 컨베이어 벨트 상에서 NIR spectrum 측정 가능성을 확인하였다. 컨베이어벨트 상에서 NIR spectroscopy 기술과 PLS 또는 LDA model 적용을 통한 고구마 내부 품질 예측 및 분류 기술은 빠른 시일 내에 대량 가공 공정에서 적용할 수 있다고 판단된다.

두 번째 topic은 RSM 및 ANN을 사용한 고구마 칩 제조를 위한 pilot-scale 진공 튀김 공정 최적화 연구이다. 본 연구는 감압후라이드 고구마칩 제조 시 전처리 및 튀김 조건 (OD concentration, OD temperature, VF temperature)에 대한 최종 품질 (수율, 오일 함량, 갈변지수)의 예측 모델을 개발하였다. 예측 모델은 RSM과 ANN 방법을 이용하여 모델링하였다. RSM은 quadratic regression model에 통계적으로 유의하게 fitting된 것을 확인하였고, response surface graph를 이용하여 각 독립변수가 종속변수에 미치는 영향을 평가하였다. ANN 모델은 MSE 값에 대한 performance plot을 확인하여 최소의 MSE 값을 갖는 모델이 생성된 것을 확인하였다. 수확 및 통계적 분석을 이용하여 각 모델의 성능을 비교하였다. 최종 품질 요인인 수율, 오일 함량, 갈변지수 모두 R 및  $R^2$  값이 ANN 모델이 RSM 보다 높았다. 그러나 모델의 성능을 나타내는 지표 (MSE, RMSE, MAE, SEP, MRPD) 값 차이는 R 및  $R^2$

값 증가율에 따라서 상이한 것을 확인하였다. RSM과 ANN 모델의 최적화 결과 두 모델의 최적화 값은 약간의 차이가 있었다. RSM과 ANN 모두 감압후라이드 고구마칩 제조 공정에 대한 수율, 오일 함량, 갈변 지수를 예측할 수 있었으며, ANN 모델이 RSM에 비하여 정확도 및 적응성이 높은 것을 확인하였다. 농산물 가공공정은 농산물의 품질에 따라서 예측 불가능한 변수가 매우 많지만, RSM과 ANN 모델을 이용하여 품질 예측 및 최적화가 가능한 것을 확인하였다. 감압후라이드 공정을 통해 고구마칩의 품질 최적화에 대한 연구는 처음으로 연구되었다. 이는 다양한 변수가 존재하는 식품산업 공정에서 활용될 수 있다.

세 번째 topic은 감자튀김 식이가 장내미생물에 미치는 영향 연구이다. 본 연구는 튀김 시 사용한 오일과 튀김 방법에 대한 toxic compounds 함량을 분석하였다. 또한 *in vivo* 실험을 통한 감자튀김 식이 시 mouse의 biochemical parameter와 microbiota에 미치는 영향을 연구하였다. Trans fat인 oleic acid (C18:1) 함량은 deep frying (CD, PD)이 vacuum frying (CV, PV)보다 유의적으로 높았고, CD와 PD의 유의적인 차이는 없었다. Acrylamide 함량은 PV, CD, PD, CV 순서로 높았다. PAH는 vacuum frying 샘플에서만 검출되었고, deep frying 샘플에서는 검출되지 않았다. PV가 CV보다 PAH 함량이 유의적으로 높았다. C57BL/6J 마우스를 4개의 그룹으로 분류하여, normal diet (N), high fat과 high fructose diet (HF), PD diet (PD), CV diet (CV), 12주동안 식이한 후 무게, cholesterol, triglyceride, SCFA, microbiota 변화를 확인하였다. Body weight gain과 epididymal fat weight는 PD, CV 섭취 시 N에 비하여 유의적으로 증가하였다. Serum의 cholesterol 및 liver의 triglyceride 함량은 PD, CV 섭취 시 N에 비하여 증가하였지만, 유의적인 차이는 없었다. Cecal total SCFA 분석 결과 N 그룹에 비하여 PD 섭취 시 감소하였고, CV 섭취 시 유사한 함량을 가졌으나 유의적인 차이는 없었다. Microbiota 분석 결과 F/B ratio는 N 그룹에 비하여 PD 섭취 시 감소하였고, CV 섭취 시 증가하였으나 유의적인 차이는 없었다. CV 그룹의 *Erysipelotrichi*, *Erysipelotrichaceae*의 abundance가 다른 그룹에 비하여 매우 높은 것을 확인할 수 있다. 결론적으로 감자튀김 섭취 시 weight가 증가하였다. PD 섭취 시에는 N 그룹과 microbiota 군집이 유사하지만, CV 섭취 시 microbiota 군집이 HF 그룹과 유사하였다. 또한 CV 섭취 그룹은 lipid metabolism과 연관이 있고 지방간 발병과 양의 상관관계가 있는 *Erysipelotrichi*, *Erysipelotrichaceae*의 abundance가 다른 그룹에 비하여 매우 증가하는 것을 확인하였다. 실험결과 팜유 사용 시 카놀라

유에 비하여 toxic compounds 발생이 증가하였다. 감압후라이нг 감자튀김 섭취 시 microbiota 군집 변화가 발생하고, 지방간 발병 확률이 증가하는 것을 확인하였다. 감압후라이нг 기술이 건강한 튀김 제조 기술이라고 알려져 있지만 튀김 오일 및 조건, 원재료에 따라서 상압후라이нг 기술보다 toxic compounds를 더 많이 생성하여, 건강에 안 좋을 수 있다. 따라서 감압후라이нг 기술 적용 시 toxic compounds에 대한 분석이 필수적이고, 정부의 규제가 필요하다.

연구 결과 서류 및 서류 가공식품의 품질 예측 및 최적화가 근적외선 분광법, 다변수 분석, RSM, ANN을 이용하여 가능한 것을 확인하였다. 또한, 서류 가공식품의 toxic compounds를 분석하고, 식이 시 host의 gut microbiota에 미치는 영향을 확인하였다.

## References

1. aTFIS식품산업통계정보. (2022). 산업통계-주요통계. <https://www.atfis.or.kr/home/food/stats/main.do>
2. World Health Organization. (1992). World Declaration and Plan of Action for Nutrition (ICN/92/2. Unpublished). Nutrition Unit & Food and Agriculture Organization of the United Nations. <https://apps.who.int/iris/handle/10665/61051>
3. Morales-de la Peña, M., Welti-Chanes, J., & Martín-Belloso, O. (2019). Novel technologies to improve food safety and quality. *Current opinion in food science*, 30, 1-7.
4. Lähteenmäki-Uutela, A., Marimuthu, S. B., & Meijer, N. (2021). Regulations on insects as food and feed: a global comparison. *Journal of Insects as Food and Feed*, 7(5), 849-856.
5. Emond, B., & Taylor, J. Z. (2018). The importance of measuring food safety and quality culture: results from a global training survey. *Worldwide Hospitality and Tourism Themes*, 10(3), 369-375.
6. Kotsanopoulos, K. V., & Arvanitoyannis, I. S. (2017). The role of auditing, food safety, and food quality standards in the food industry: A review. *Comprehensive Reviews in Food Science and Food Safety*, 16(5), 760-775.
7. Møretør, T., & Langsrud, S. (2017). Residential bacteria on surfaces in the food industry and their implications for food safety and quality. *Comprehensive Reviews in Food Science and Food Safety*, 16(5), 1022-1041.

8. Codex Alimentarius Commission (2014). General standard for contaminants and toxins in food and feed (CODEX STAN 193-1995). Food and Agriculture Organization of the United Nations & World Health Organization. [https://knowledge4policy.ec.europa.eu/publication/general-standard-contaminants-toxins-food-feed-codex-stan-193-1995\\_en](https://knowledge4policy.ec.europa.eu/publication/general-standard-contaminants-toxins-food-feed-codex-stan-193-1995_en)
9. Block, L. G., Grier, S. A., Childers, T. L., Davis, B., Ebert, J. E., Kumanyika, S., ... & Bieshaar, M. N. G. (2011). From nutrients to nurturance: A conceptual introduction to food well-being. *Journal of Public Policy & Marketing*, 30(1), 5-13.
10. Stewart, J. E., Feinle-Bisset, C., Golding, M., Delahunty, C., Clifton, P. M., & Keast, R. S. (2010). Oral sensitivity to fatty acids, food consumption and BMI in human subjects. *British journal of nutrition*, 104(1), 145-152.
11. 식품의약품안전처. (2022). 식품의 기준 및 규격 (식약처 고시 제2022-76호). [https://www.mfds.go.kr/brd/m\\_211/view.do?seq=14728&srchFr=&srchTo=&srchWord=&srchTp=&itm\\_seq\\_1=0&itm\\_seq\\_2=0&multi\\_itm\\_seq=0&company\\_cd=&company\\_nm=&page=1](https://www.mfds.go.kr/brd/m_211/view.do?seq=14728&srchFr=&srchTo=&srchWord=&srchTp=&itm_seq_1=0&itm_seq_2=0&multi_itm_seq=0&company_cd=&company_nm=&page=1)
12. Moreno-Luzon, M. D., Gil-Marques, M., & Chams-Anturi, O. (2018). Quality and Innovation in the organic agro-food sector: Threats and opportunities of social and managerial innovation. In *Strategies and best practices in social innovation*.
13. Cortés, V., Blasco, J., Aleixos, N., Cubero, S., & Talens, P. (2019). Monitoring strategies for quality control of agricultural products using visible and near-infrared spectroscopy: A review. *Trends in Food Science & Technology*, 85, 138-148.
14. Zhang, X., Yang, J., Lin, T., & Ying, Y. (2021). Food and agro-product quality ev



- aluation based on spectroscopy and deep learning: A review. Trends in Food Science & Technology, 112, 431-441.
15. El-Mesery, H. S., Mao, H., & Abomohra, A. E. F. (2019). Applications of non-destructive technologies for agricultural and food products quality inspection. Sensors, 19(4), 846.
  16. Duque, L. O., & Villordon, A. (2019). Root branching and nutrient efficiency: status and way forward in root and tuber crops. Frontiers in plant science, 10, 237.
  17. 농식품올바로. (2022). 국가표준식품성분표-국가표준식품성분표 검색. <http://koreanfood.rda.go.kr/kfi/fct/fctFoodSrch/list#>
  18. Cartabiano-Leite, C. E., Porcu, O. M., & de Casas, A. F. (2020). Sweet potato (*Ipomoea batatas* L. Lam) nutritional potential and social relevance: A review. history, 11, 23-40.
  19. Ugent, D. (1970). The Potato: What is the botanical origin of this important crop plant, and how did it first become domesticated?. Science, 170(3963), 1161-1166.
  20. KOSIS. (2022). 농업생산량 (감자, 고구마). [https://kosis.kr/statHtml/statHtml.do?orgId=101&tblId=DT\\_2KAA406&conn\\_path=I2](https://kosis.kr/statHtml/statHtml.do?orgId=101&tblId=DT_2KAA406&conn_path=I2)
  21. 한국농촌경제연구원. (2019). 세계 감자산업 동향. <http://www.krei.re.kr/wldagr/researchReportView.do?key=158&pageType=003&biblioId=520431&pageUnit=10&searchCnd=all&searchKrwd=&pageIndex=3>

22. Zou, X., & Zhao, J. (2015). *Nondestructive measurement in food and agro-products*. Springer.
  
23. Emart mall. (2022). 파머스픽 당도선별 수박 & 달콤한 곡성농협메론 & 파머스픽 당도선별사과 & 파머스픽 당도선별 참외. <https://emart.ssg.com>
  
24. Pavia, D. L., Lampman, G. M., Kriz, G. S., & Vyvyan, J. A. (2014). *Introduction to spectroscopy*. Cengage learning.
  
25. Wang, N., Zhang, N., & Wang, M. (2006). Wireless sensors in agriculture and food industry? Recent development and future perspective. *Computers and electronics in agriculture*, 50(1), 1-14.
  
26. Schalk, R., Geörg, D., Staubach, J., Raedle, M., Methner, F. J., & Beuermann, T. (2017). Evaluation of a newly developed mid-infrared sensor for real-time monitoring of yeast fermentations. *Journal of bioscience and bioengineering*, 123(5), 651-657.
  
27. Okere, E. E., Arendse, E., Nieuwoudt, H., Perold, W. J., & Opara, U. L. (2022). Non-destructive evaluation of the quality characteristics of pomegranate kernel oil by fourier transform near-infrared and mid-infrared spectroscopy. *Frontiers in Plant Science*, 13, 867555.
  
28. Xiaobo, Z., Jiewen, Z., Hanpin, M., Jiyong, S., Xiaopin, Y., & Yanxiao, L. (2010). Genetic algorithm interval partial least squares regression combined successive projections algorithm for variable selection in near-infrared quantitative analysis of pigment in cucumber leaves. *Applied spectroscopy*, 64(7), 786-794.

29. Gardner, C. M. (2018). Transmission versus reflectance spectroscopy for quantitative. *Journal of Biomedical Optics*, 23(1), 018001.
  
30. Moschovakis, Y. N. (2001). What is an algorithm?. In Engquist, B., & Schmid, W. (Ed.) *Mathematics unlimited—2001 and beyond* (pp. 919-936). Springer.
  
31. Rana, M. S., Hossin, M. A., Mahmud, S. H., Jahan, H., Satter, A. Z., & Bhuiyan, T. (2019). MinFinder: A new approach in sorting algorithm. *Procedia Computer Science*, 154, 130-136.
  
32. Das, S., Dey, A., Pal, A., & Roy, N. (2015). Applications of artificial intelligence in machine learning: review and prospect. *International Journal of Computer Applications*, 115(9), 31-41.
  
33. 대한이비인후과학회. (2020). 인공지능? 머신러닝? 빅데이터? 알쏭달쏭한 개념 쉽게 다가가기. <https://www.korl.or.kr/webzine/100/sub2.html>
  
34. 4차산업혁명지식서비스. (2018). 기술창업지식-인공지능의 머신러닝과 기존 데이터 분석기법의 차이. <https://4ir.kisti.re.kr/ick/cmmn/viewPost/20180226000059>
  
35. Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., & Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal of big data*, 2(1), 1-21.
  
36. 한국알테어. (2021. 6. 15.). 빅데이터(Big Data)란?. ALTAIR 블로그. <https://blog.altair.co.kr/68974>

37. 지능정보산업협회. (2018). ICT RnD 기술로드맵 2023\_인공지능·빅데이터 분야 보고서. [https://www.k-ai.or.kr/kr/participate/reference.php?bbs\\_data=aWR4PTU4NiZzdGFydFBhZ2U9MCZsaXN0Tm89MTgmdGFibGU9Y3NfYmJzX2RhdGEmY29kZT10YWl1X2MyJnNIYXJjaF9pdGVtPSZzZWVhZjY2hfb3JkZXI9%7C%7C&bgu=view](https://www.k-ai.or.kr/kr/participate/reference.php?bbs_data=aWR4PTU4NiZzdGFydFBhZ2U9MCZsaXN0Tm89MTgmdGFibGU9Y3NfYmJzX2RhdGEmY29kZT10YWl1X2MyJnNIYXJjaF9pdGVtPSZzZWVhZjY2hfb3JkZXI9%7C%7C&bgu=view)
38. 리비전컬설팅. (2018. 10. 23.). 인공지능과 빅데이터의 시너지 - 현재와 미래. Revisioncrm 티스토리. <https://revisioncrm.tistory.com/426>
39. Mavani, N. R., Ali, J. M., Othman, S., Hussain, M. A., Hashim, H., & Rahman, N. A. (2022). Application of artificial intelligence in food industry—A guideline. *Food Engineering Reviews*, 14(1), 134-175.
40. Misra, N. N., Dixit, Y., Al-Mallahi, A., Bhullar, M. S., Upadhyay, R., & Martynenko, A. (2020). IoT, big data and artificial intelligence in agriculture and food industry. *IEEE Internet of Things Journal*. 9(9), 6305-6324.
41. Elmasry, G., Kamruzzaman, M., Sun, D. W., & Allen, P. (2012). Principles and applications of hyperspectral imaging in quality evaluation of agro-food products: a review. *Critical reviews in food science and nutrition*, 52(11), 999-1023.
42. Varmuza, K., & Filzmoser, P. (2016). *Introduction to multivariate statistical analysis in chemometrics*. CRC press.
43. Balakrishnama, S., & Ganapathiraju, A. (1998). Linear discriminant analysis-a brief tutorial. *Institute for Signal and information Processing*, 18(1998), 1-8.
44. Vinzi, V. E., Chin, W. W., Henseler, J., & Wang, H. (2010). *Handbook of partial l*

east squares. Springer.

45. Rodrigues, M. I., & Iemma, A. F. (2014). *Experimental design and process optimization*. Crc Press.
46. Bezerra, M. A., Santelli, R. E., Oliveira, E. P., Villar, L. S., & Escaleira, L. A. (2008). Response surface methodology (RSM) as a tool for optimization in analytical chemistry. *Talanta*, 76(5), 965-97.
47. Kim, D. S., Choi, M. H., & Shin, H. J. (2021). Estimation of starch hydrolysis in sweet potato (Beni Haruka) based on storage period using nondestructive near-infrared spectrometry. *Agriculture*, 11(2), 135.
48. Yolmeh, M., & Jafari, S. M. (2017). Applications of response surface methodology in the food industry processes. *Food and Bioprocess Technology*, 10(3), 413-433.
49. Anderson, M. J., & Whitcomb, P. J. (2016). *RSM simplified: optimizing processes using response surface methods for design of experiments*. Productivity press.
50. Bhagya Raj, G. V. S., & Dash, K. K. (2022). Comprehensive study on applications of artificial neural network in food process modeling. *Critical Reviews in Food Science and Nutrition*, 62(10), 2756-2783.
51. Yang, Q. Q., Gan, R. Y., Zhang, D., Ge, Y. Y., Cheng, L. Z., & Corke, H. (2019). Optimization of kidney bean antioxidants using RSM & ANN and characterization of antioxidant profile by UPLC-QTOF-MS. *LWT*, 114, 108321.

52. Tang, S. Y., Lee, J. S., Loh, S. P., & Tham, H. J. (2017, June). Application of artificial neural network to predict colour change, shrinkage and texture of osmotically dehydrated pumpkin [Paper presentation]. In IOP Conference Series: Materials Science and Engineering. <https://iopscience.iop.org/article/10.1088/1757-899X/206/1/012036>
  
53. Onu, C. E., Igbokwe, P. K., Nwabanne, J. T., Nwajinka, C. O., & Ohale, P. E. (2020). Evaluation of optimization techniques in predicting optimum moisture content reduction in drying potato slices. *Artificial Intelligence in Agriculture*, 4, 39-47.
  
54. Sender, R., Fuchs, S., & Milo, R. (2016). Revised estimates for the number of human and bacteria cells in the body. *PLoS biology*, 14(8), e1002533.
  
55. Selma, M. V., Espin, J. C., & Tomas-Barberan, F. A. (2009). Interaction between phenolics and gut microbiota: role in human health. *Journal of agricultural and food chemistry*, 57(15), 6485-6501.
  
56. Lee, W. J., & Hase, K. (2014). Gut microbiota-generated metabolites in animal health and disease. *Nature chemical biology*, 10(6), 416-424.
  
57. Zoetendal, E. G., Rajilić-Stojanović, M., & de Vos, W. M. (2008). High-throughput diversity and functionality analysis of the gastrointestinal tract microbiota. *Gut*, 57(11), 1605-1615.
  
58. Shapiro, H., Thaïss, C. A., Levy, M., & Elinav, E. (2014). The cross talk between microbiota and the immune system: metabolites take center stage. *Current opinion in immunology*, 30, 54-62.

59. Jae Sung Ko. (2013). The Intestinal Microbiota and Human Disease. Korean Journal of Gastroenterol, 62(2), 85-91.
  
60. Zhang, H., DiBaise, J. K., Zuccolo, A., Kudrna, D., Braidotti, M., Yu, Y., ... & Kr ajmalnik-Brown, R. (2009). Human gut microbiota in obesity and after gastric bypas s. Proceedings of the National Academy of Sciences, 106(7), 2365-2370.
  
61. Innis, M. A., Myambo, K. B., Gelfand, D. H., & Brow, M. A. (1988). DNA sequenc ing with Thermus aquaticus DNA polymerase and direct sequencing of polymeras e chain reaction-amplified DNA. Proceedings of the National Academy of Sciences, 85(24), 9436-9440.
  
62. BRIC. (2022. 07). NGS를 활용한 새로운 분석 방법 및 활용 사례 (BRIC View 2 022-T11)
  
63. Mosca, A., Leclerc, M., & Hugot, J. P. (2016). Gut microbiota diversity and huma n diseases: should we reintroduce key predators in our ecosystem?. Frontiers in mic robiology, 7, 455.
  
64. Flint, H. J., Duncan, S. H., Scott, K. P., & Louis, P. (2015). Links between diet, g ut microbiota composition and gut metabolism. Proceedings of the Nutrition Society, 74(1), 13-22.
  
65. Eid, N., Enani, S., Walton, G., Corona, G., Costabile, A., Gibson, G., ... & Spence r, J. P. (2014). The impact of date palm fruits and their component polyphenols, o n gut microbial ecology, bacterial metabolites and colon cancer cell proliferation. Jo urnal of nutritional science, 3, e46.

66. Tomova, A., Bukovsky, I., Rembert, E., Yonas, W., Alwarith, J., Barnard, N. D., & Kahleova, H. (2019). The effects of vegetarian and vegan diets on gut microbiota. *Frontiers in nutrition*, 6, 47.
  
67. Singh, R. K., Chang, H. W., Yan, D. I., Lee, K. M., Ucmak, D., Wong, K., ... & Liao, W. (2017). Influence of diet on the gut microbiome and implications for human health. *Journal of translational medicine*, 15(1), 1-17.
  
68. Keim, N. L., & Martin, R. J. (2014). Dietary whole grain-microbiota interactions: insights into mechanisms for human health. *Advances in Nutrition*, 5(5), 556-557.
  
69. Ayala-Campos, O. R., Sanchez, A., Rebollar, E. A., & Valdez-Vazquez, I. (2022). Plant-associated microbial communities converge in fermentative hydrogen production and form a core microbiome. *International Journal of Hydrogen Energy*. 47(46), 20049-20063.
  
70. Romond, M. B., Ais, A., Guillemot, F., Bounouader, R., Cortot, A., & Romond, C. (1998). Cell-free whey from milk fermented with *Bifidobacterium breve* C50 used to modify the colonic microflora of healthy subjects. *Journal of dairy science*, 81(5), 1229-1235.
  
71. Meddah, A. T. T., Yazourh, A., Desmet, I., Risbourg, B., Verstraete, W., & Romond, M. B. (2001). The regulatory effects of whey retentate from bifidobacteria fermented milk on the microbiota of the simulator of the human intestinal microbial ecosystem (SHIME). *Journal of applied microbiology*, 91(6), 1110-1117.
  
72. Tomova, A., Bukovsky, I., Rembert, E., Yonas, W., Alwarith, J., Barnard, N. D.,



- & Kahleova, H. (2019). The effects of vegetarian and vegan diets on gut microbiota. *Frontiers in nutrition*, 6, 47.
73. Wu, G. D., Bushman, F. D., & Lewis, J. D. (2013). Diet, the human gut microbiota, and IBD. *Anaerobe*, 24, 117-120.
74. Cotillard, A., Kennedy, S. P., Kong, L. C., Prifti, E., Pons, N., Le Chatelier, E., ... & Ehrlich, S. D. (2013). Dietary intervention impact on gut microbial gene richness. *Nature*, 500(7464), 585-588.
75. Jantchou, P., Morois, S., Clavel-Chapelon, F., Boutron-Ruault, M. C., & Carbonnel, F. (2010). Animal protein intake and risk of inflammatory bowel disease: The E3N prospective study. *Official journal of the American College of Gastroenterology*, 105(10), 2195-2201.
76. Gleissman, H., Johnsen, J. I., & Kogner, P. (2010). Omega-3 fatty acids in cancer, the protectors of good and the killers of evil?. *Experimental cell research*, 316(8), 1365-1373.
77. Zhang, Y., Zhang, B., Dong, L., & Chang, P. (2019). Potential of omega-3 polyunsaturated fatty acids in managing chemotherapy-or radiotherapy-related intestinal microbial dysbiosis. *Advances in Nutrition*, 10(1), 133-147.
78. Wu, G. D., Chen, J., Hoffmann, C., Bittinger, K., Chen, Y. Y., Keilbaugh, S. A., ... & Lewis, J. D. (2011). Linking long-term dietary patterns with gut microbial enterotypes. *Science*, 334(6052), 105-108.

79. Verhoog, S., Taneri, P. E., Roa Diaz, Z. M., Marques-Vidal, P., Troup, J. P., Ball y, L., ... & Muka, T. (2019). Dietary factors and modulation of bacteria strains of *Akkermansia muciniphila* and *Faecalibacterium prausnitzii*: a systematic review. *Nutrients*, 11(7), 1565.
  
80. Sanchez-Tapia, M., Miller, A. W., Granados-Portillo, O., Tovar, A. R., & Torres, N. (2020). The development of metabolic endotoxemia is dependent on the type of sweetener and the presence of saturated fat in the diet. *Gut microbes*, 12(1), 18013 01.
  
81. Mohanraj, R., & Sivasankar, S. (2014). Sweet Potato (*Ipomoea batatas* [L.] Lam)-A valuable medicinal food: A review. *Journal of medicinal food*, 17(7), 733-741.
  
82. Antia, B. S., Akpan, E. J., Okon, P. A., & Umoren, I. U. (2006). Nutritive and anti-nutritive evaluation of sweet potatoes (*Ipomoea batatas*) leaves. *Pakistan Journal of Nutrition*, 5, 166-168.
  
83. Cartier, A., Woods, J., Sismour, E., Allen, J., Ford, E., Githinji, L., & Xu, Y. (2017). Physiochemical, nutritional and antioxidant properties of fourteen Virginia-grown sweet potato varieties. *Journal of Food Measurement and Characterization*, 11(3), 1333-1341.
  
84. Truong, V.D., Avula, R.Y., Pecota, K.V., & Yencho, G.C. Sweetpotato production, processing, and nutritional quality. In iddiq, M., & Uebersax, M.A. (2nd ed.) *Handbook of vegetables and vegetable processing* (pp. 811-838). Wiley.
  
85. Bovell-Benjamin, A. C. (2007). Sweet potato: a review of its past, present, and future.

- re role in human nutrition. *Advances in food and nutrition research*, 52, 1-59.
86. Zhang, H., Patel, J., Bhunia, K., Al-Ghamdi, S., Sonar, C. R., Ross, C. F., ... & S abhani, S. S. (2019). Color, vitamin C,  $\beta$ -carotene and sensory quality retention in microwave-assisted thermally sterilized sweet potato puree: Effects of polymeric package gas barrier during storage. *Food Packaging and Shelf Life*, 21, 100324.
  87. Nath, P., Kale, S. J., Chauhan, O. P., & Gupta, R. K. (2016). High pressure processing induced changes in bioactive compounds, antioxidant activity, microbial safety and color attributes of coriander paste. *Agricultural research*, 5(2), 182-192.
  88. 김기홍. (2019.05.01.). 일본 고구마 밀수 성행...특수 금지해충 유입 '빨간불'. 농민신문. <https://m.nongmin.com/311046>
  89. Walter Jr, W. M. (1987). Effect of curing on sensory properties and carbohydrate composition of baked sweet potatoes. *Journal of food science*, 52(4), 1026-1029.
  90. Kushman, L. J., & Wright, F. S. (1969) Sweetpotato storage (No. 358). Agricultural Research Service, US Department of Agriculture. [https://books.google.co.kr/books?hl=ko&lr=&id=f\\_nAdRWCDn4C&oi=fnd&pg=PP4&dq=Kushman,+L.+J.,+%26+Wright,+F.+S.+\(1969\)+Sweetpotato+storage.+Agriculture+handbook&ots=YO\\_FWGBgI-&sig=00-Ad8-z9cbUv9k\\_jnIroyOnsWk#v=onepage&q=Kushman%2C%20L.%20J.%2C%20%26%20Wright%2C%20F.%20S.%20\(1969\)%20Sweetpotato%20storage.%20Agriculture%20handbook&f=false](https://books.google.co.kr/books?hl=ko&lr=&id=f_nAdRWCDn4C&oi=fnd&pg=PP4&dq=Kushman,+L.+J.,+%26+Wright,+F.+S.+(1969)+Sweetpotato+storage.+Agriculture+handbook&ots=YO_FWGBgI-&sig=00-Ad8-z9cbUv9k_jnIroyOnsWk#v=onepage&q=Kushman%2C%20L.%20J.%2C%20%26%20Wright%2C%20F.%20S.%20(1969)%20Sweetpotato%20storage.%20Agriculture%20handbook&f=false)
  91. Jeong, B. C., Ahn, Y. S., Chung, M. N., Lee, J. S., & Oh, Y. H. (2002). Current status and prospect of quality evaluation in sweetpotato. *Korean Journal of Crop Sci*

ence, 47, 124-134.

92. Tomlins, K. I., Ndunguru, G. T., Rwiza, E., & Westby, J. (2002). Influence of pre-harvest curing and mechanical injury on the quality and shelf-life of sweet potato (*Ipomea batatas* (L.) Lam) in East Africa. *The Journal of Horticultural Science and Biotechnology*, 77(4), 399-403.
  
93. Nabubuya, A., Namutebi, A., Byaruhanga, Y., Narvhus, J., & Wicklund, T. (2017). Influence of development, postharvest handling, and storage conditions on the carbohydrate components of sweetpotato (*Ipomea batatas* Lam.) roots. *Food science & nutrition*, 5(6), 1088-1097.
  
94. Aranguren, M., Castellón, A., & Aizpurua, A. (2020). Crop sensor based non-destructive estimation of nitrogen nutritional status, yield, and grain protein content in wheat. *Agriculture*, 10(5), 148.
  
95. Nicolai, B. M., Beullens, K., Bobelyn, E., Peirs, A., Saeys, W., Theron, K. I., & Lammertyn, J. (2007). Nondestructive measurement of fruit and vegetable quality by means of NIR spectroscopy: A review. *Postharvest biology and technology*, 46(2), 99-118.
  
96. Cozzolino, D., Porker, K., & Laws, M. (2015). An overview on the use of infrared sensors for in field, proximal and at harvest monitoring of cereal crops. *Agriculture*, 5(3), 713-722.
  
97. Xie, L., Wang, A., Xu, H., Fu, X., & Ying, Y. (2016). Applications of near-infrared systems for quality evaluation of fruits: A review. *Transactions of the ASABE*, 59

- (2), 399-419.
98. Katayama, K., Komaki, K., & Tamiya, S. (1996). Prediction of starch, moisture, and sugar in sweetpotato by near infrared transmittance. *HortScience*, 31(6), 1003-1006.
  99. Iwase, J., Sato, Y., Comparini, D., Masi, E., Mancuso, S., & Kawano, T. (2015). Non-invasive acoustic sensing of tuberous roots of sweet potato (*Ipomoea batatas*) growing belowground. *Advances in Horticultural Science*, 29(4), 176-180.
  100. Chen, J. Y., Zhang, H., Miao, Y., & Asakura, M. (2010). Nondestructive determination of sugar content in potato tubers using visible and near infrared spectroscopy. *Japan Journal of Food Engineering*, 11(1), 59-64.
  101. Camps, C., & Camps, Z. N. (2019). Optimized prediction of reducing sugars and dry matter of potato frying by FT-NIR spectroscopy on peeled tubers. *Molecules*, 24(5), 967.
  102. Han, Y. F., Lv, C. X., Yuan, Y. W., Yang, B. N., Zhao, Q. L., & Cao, Y. F. (2020, June). Non-destructive detection of blackheart potatoes based on energy spectrum of VIS/NIR transmittance [Paper presentation]. In *IOP Conference Series: Earth and Environmental Science*. <https://iopscience.iop.org/article/10.1088/1755-1315/512/1/012060/meta>
  103. Rady, A. M., & Guyer, D. E. (2015). Rapid and/or nondestructive quality evaluation methods for potatoes: A review. *Computers and electronics in agriculture*, 117, 31-48.

104. Rady, A. M., & Guyer, D. E. (2015). Evaluation of sugar content in potatoes using NIR reflectance and wavelength selection techniques. *Postharvest Biology and Technology*, 103, 17-26.
  
105. Ai, J., Witt, T., Cowin, G., Dhital, S., Turner, M. S., Stokes, J. R., & Gidley, M. J. (2018). Anti-staling of high-moisture starchy food: Effect of hydrocolloids, emulsifiers and enzymes on mechanics of steamed-rice cakes. *Food Hydrocolloids*, 83, 454-464.
  
106. Miller, G. L. (1959). Use of dinitrosalicylic acid reagent for determination of reducing sugar. *Analytical chemistry*, 31(3), 426-428.
  
107. Rinnan, Å., Van Den Berg, F., & Engelsen, S. B. (2009). Review of the most common pre-processing techniques for near-infrared spectra. *TrAC Trends in Analytical Chemistry*, 28(10), 1201-1222.
  
108. Zimmermann, B., & Kohler, A. (2013). Optimizing Savitzky-Golay parameters for improving spectral resolution and quantification in infrared spectroscopy. *Applied spectroscopy*, 67(8), 892-902.
  
109. Chen, L. J., Xing, L., & Han, L. J. (2010). Influence of data preprocessing on the quantitative determination of nutrient content in poultry manure by near infrared spectroscopy. *Journal of environmental quality*, 39(5), 1841-1847.
  
110. da Costa, N. L., da Costa, M. S., & Barbosa, R. (2021). A review on the application of chemometrics and machine learning algorithms to evaluate beer authentication. *Food Analytical Methods*, 14(1), 136-155.

111. Coûteaux, M. M., Sarmiento, L., Hervé, D., & Acevedo, D. (2005). Determination of water-soluble and total extractable polyphenolics in biomass, necromass and decomposing plant material using near-infrared reflectance spectroscopy (NIRS). *Soil Biology and Biochemistry*, 37(4), 795-799.
  
112. Alves, A., Santos, A., Rozenberg, P., Pâques, L. E., Charpentier, J. P., Schwanninger, M., & Rodrigues, J. (2012). A common near infrared—based partial least squares regression model for the prediction of wood density of *Pinus pinaster* and *Larix eurolepis*. *Wood Science and Technology*, 46(1), 157-175.
  
113. D'acqui, L. P., Pucci, A., & Janik, L. J. (2010). Soil properties prediction of western Mediterranean islands with similar climatic environments by means of mid-infrared diffuse reflectance spectroscopy. *European journal of soil science*, 61(6), 865-876.
  
114. Gad, H. A., El-Ahmady, S. H., Abou-Shoer, M. I., & Al-Azizi, M. M. (2013). Application of chemometrics in authentication of herbal medicines: a review. *Phytochemical Analysis*, 24(1), 1-24.
  
115. Agnes, N., Agnes, N., Yusuf, B., Judith, N., Yngve, S., & Trude, W. (2012). Amyolytic activity in selected sweetpotato (*Ipomoea batatas* Lam) varieties during development and in storage. *Food and Nutrition Sciences*, 3, 660-668.
  
116. Hagenimana, V., Vezina, L. P., & Simard, R. E. (1992). Distribution of amylases within sweet potato (*Ipomoea batatas* L.) root tissue. *Journal of Agricultural and Food Chemistry*, 40(10), 1777-1783.

117. Sarikaya, E., Higasa, T., Adachi, M., & Mikami, B. (2000). Comparison of degradation abilities of  $\alpha$ - and  $\beta$ -amylases on raw starch granules. *Process Biochemistry*, 35(7), 711-715.
  
118. Luck, W. A. P. (1974) Infrared overtone region. In Luck, W. A. P. (Ed.) *Structure of water and aqueous solution* (pp. 248-284). Weinheim Verlag Chemie.
  
119. Büning-Pfaue, H. (2003). Analysis of water in food by near infrared spectroscopy. *Food Chemistry*, 82(1), 107-115.
  
120. Osborne, B. G. (2006) Near-infrared spectroscopy in food analysis. In Meyers, R. A. (Ed.) *Encyclopedia of analytical chemistry: applications, theory and instrumentation* (pp 1-14). Wiley.
  
121. Ding, X., Ni, Y., & Kokot, S. (2015). NIR spectroscopy and chemometrics for the discrimination of pure, powdered, purple sweet potatoes and their samples adulterated with the white sweet potato flour. *Chemometrics and Intelligent Laboratory Systems*, 144, 17-23.
  
122. De Carvalho, L. C., De Moraes, C. D. L. M., De Lima, K. M. G., Júnior, L. C. C., Nascimento, P. A. M., De Faria, J. B., & de Almeida Teixeira, G. H. (2016). Determination of the geographical origin and ethanol content of Brazilian sugarcane spirit using near-infrared spectroscopy coupled with discriminant analysis. *Analytical Methods*, 8(28), 5658-5666.
  
123. Farhadi, R., Afkari-Sayyah, A. H., Jamshidi, B., & Gorji, A. M. (2020). Prediction of internal compositions change in potato during storage using visible/near-infrared



- (Vis/NIR) spectroscopy. *International Journal of Food Engineering*, 16(4), 20190110.
124. Lu, G., Huang, H., & Zhang, D. (2006). Prediction of sweetpotato starch physiochemical quality and pasting properties using near-infrared reflectance spectroscopy. *Food chemistry*, 94(4), 632-639.
  125. Robotti, E., & Marengo, E. (2016). Chemometric multivariate tools for candidate biomarker identification: LDA, PLS-DA, SIMCA, Ranking-PCA. Humana Press.
  126. Yolmeh, M., & Jafari, S. M. (2017). Applications of response surface methodology in the food industry processes. *Food and Bioprocess Technology*, 10, 413-433.
  127. Bezerra, M. A., Santelli, R. E., Oliveira, E. P., Villar, L. S., & Escaleira, L. A. (2008). Response surface methodology (RSM) as a tool for optimization in analytical chemistry. *Talanta*, 76, 965-977.
  128. Kim, D. S., Choi, M. H., & Shin, H. J. (2021). Estimation of starch hydrolysis in sweet potato (*Beni Haruka*) based on storage period using nondestructive near-infrared spectrometry. *Agriculture*, 11, 135.
  129. Das, M., Rajan, N., Biswas, P., & Banerjee, R. (2022). A novel approach for resistant starch production from green banana flour using amylopullulanase. *LWT*, 153, 112391.
  130. Okonkwo, C. E., Moses, O. I., Nwonuma, C., Abiola, T., Benjamin, B. O., Foluru nsho, J. O., ... & Pan, Z. (2022). Infrared and Microwave as a dry blanching tool for Irish potato: Product quality, cell integrity, and artificial neural networks (ANN

- s) modeling of enzyme inactivation kinetic. *Innovative Food Science & Emerging Technologies*, 78, 103010.
131. Yang, Q. Q., Gan, R. Y., Zhang, D., Ge, Y. Y., Cheng, L. Z., & Corke, H. (2019). Optimization of kidney bean antioxidants using RSM & ANN and characterization of antioxidant profile by UPLC-QTOF-MS. *LWT*, 114, 108321.
  132. Bhagya Raj, G. V. S., & Dash, K. K. (2022). Comprehensive study on applications of artificial neural network in food process modeling. *Critical Reviews in Food Science and Nutrition*, 62, 2756-2783.
  133. Tang, S. Y., Lee, J. S., Loh, S. P., & Tham, H. J. (2017). Application of artificial neural network to predict colour change, shrinkage and texture of osmotically dehydrated pumpkin. In *IOP Conference Series: Materials Science and Engineering*, 206, 012036.
  134. Zhang, Q., Saleh, A. S., Chen, J., & Shen, Q. (2012). Chemical alterations taken place during deep-fat frying based on certain reaction products: A review. *Chemistry and physics of lipids*, 165(6), 662-681.
  135. Moreira, R. G. (2014). Vacuum frying versus conventional frying-An overview. *European Journal of Lipid Science and Technology*, 116(6), 723-734.
  136. Mariscal, M., & Bouchon, P. (2008). Comparison between atmospheric and vacuum frying of apple slices. *Food chemistry*, 107(4), 1561-1569.
  137. Akinpelu, O. R., Idowu, M. A., Sobukola, O. P., Henshaw, F., Sanni, S. A., Bodu

- nde, G., ... & Munoz, L. (2014). Optimization of processing conditions for vacuum frying of high quality fried plantain chips using response surface methodology (RSM). *Food Science and Biotechnology*, 23(4), 1121-1128.
138. Esan, T. A., Sobukola, O. P., Sanni, L. O., Bakare, H. A., & Munoz, L. (2015). Process optimization by response surface methodology and quality attributes of vacuum fried yellow fleshed sweetpotato (*Ipomoea batatas* L.) chips. *Food and Bioprocess Processing*, 95, 27-37.
139. Giri, N. A., Pradeepika, C., & Sajeev, M. S. (2019). Process optimization by response surface methodology and quality attributes of orange fleshed sweet potato (*Ipomoea batatas* L.) vacuum fried chips. *Journal of Food Measurement and Characterization*, 13, 2367-2376.
140. Ahmed, I., Qazi, I. M., & Jamal, S. (2016). Developments in osmotic dehydration technique for the preservation of fruits and vegetables. *Innovative Food Science & Emerging Technologies*, 34, 29-43.
141. Kim, D. S., & Shin, H. J. (2021). Effect of pretreatment method on the physical properties of vacuum-fried sweet potato chips. *Journal of Advanced Engineering and Technology*, 14, 107-113.
142. Dibanda, R. F., Akdowa, E. P., & Tongwa, Q. M. (2020). Effect of microwave blanching on antioxidant activity, phenolic compounds and browning behaviour of some fruit peelings. *Food Chemistry*, 302, 125308.
143. Thoai, D. N., Tongurai, C., Prasertsit, K., & Kumar, A. (2018). Predictive capabilities

- ty evaluation of RSM and ANN in modeling and optimization of biodiesel production from palm (*Elaeisguineensis*) oil. International Journal of Applied Engineering Research, 13(10), 7529-7540.
144. Ayustaningwarno, F., Dekker, M., Fogliano, V., & Verkerk, R. (2018). Effect of vacuum frying on quality attributes of fruits. Food Engineering Reviews, 10, 154-164.
  145. Deng, L. Z., Mujumdar, A. S., Zhang, Q., Yang, X. H., Wang, J., Zheng, Z. A., ... & Xiao, H. W. (2019). Chemical and physical pretreatments of fruits and vegetables: Effects on drying characteristics and quality attributes-a comprehensive review. Critical reviews in food science and nutrition, 59(9), 1408-1432.
  146. Dziki, D. (2020). Recent trends in pretreatment of food before freeze-drying. Processes, 8, 1661.
  147. Ren, A., Pan, S., Li, W., Chen, G., & Duan, X. (2018). Effect of various pretreatments on quality attributes of vacuum-fried shiitake mushroom chips. Journal of Food Quality, 2018, 4510126.
  148. Del Valle, J. M., Aranguiz, V., & Leon, H. (1998). Effects of blanching and calcium infiltration on PPO activity, texture, microstructure and kinetics of osmotic dehydration of apple tissue. Food Research International, 31, 557-569.
  149. Rodríguez, Ó., Llabrés, P. J., Simal, S., Femenia, A., & Rosselló, C. (2015). Intensification of predrying treatments by means of ultrasonic assistance: effects on water mobility, PPO activity, microstructure, and drying kinetics of apple. Food and B

- ioprocess Technology, 8, 503-515.
150. Feng, Y., Yu, X., Yagoub, A. E. A., Xu, B., Wu, B., Zhang, L., & Zhou, C. (2019). Vacuum pretreatment coupled to ultrasound assisted osmotic dehydration as a novel method for garlic slices dehydration. *Ultrasonics sonochemistry*, 50, 363-372.
  151. Oladejo, A. O., Ma, H., Qu, W., Zhou, C., Wu, B., Uzoejinwa, B. B., ... & Yang, X. (2018). Application of pretreatment methods on agricultural products prior to frying: a review. *Journal of the Science of Food and Agriculture*, 98(2), 456-466.
  152. Cichowska, J., Żubernik, J., Czyżewski, J., Kowalska, H., & Witrowa-Rajchert, D. (2018). Efficiency of osmotic dehydration of apples in polyols solutions. *Molecules*, 23, 446.
  153. Rahaman, A., Zeng, X. A., Kumari, A., Rafiq, M., Siddeeg, A., Manzoor, M. F., ... & Ahmed, Z. (2019). Influence of ultrasound-assisted osmotic dehydration on texture, bioactive compounds and metabolites analysis of plum. *Ultrasonics sonochemistry*, 58, 104643.
  154. Dehghannya, J., & Abedpour, L. (2018). Influence of a three stage hybrid ultrasound-osmotic-frying process on production of low fat fried potato strips. *Journal of the Science of Food and Agriculture*, 98, 1485-1491.
  155. Karizaki, V. M., Sahin, S., Sumnu, G., Mosavian, M. T. H., & Luca, A. (2013). Effect of ultrasound-assisted osmotic dehydration as a pretreatment on deep fat frying of potatoes. *Food and bioprocess technology*, 6, 3554-3563.

156. Krokida, M. K., Oreopoulou, V., Maroulis, Z. B., & Marinos-Kouris, D. (2001). Effect of osmotic dedhydration pretreatment on quality of french fries. *Journal of Food Engineering*, 49, 339-345.
  
157. Nunes, Y., & Moreira, R. G. (2009). Effect of osmotic dehydration and vacuum-frying parameters to produce high-quality mango chips. *Journal of food science*, 74, 355-362.
  
158. Oladejo, A. O., Ma, H., Qu, W., Zhou, C., Wu, B., Yang, X., & Onwude, D. I. (2017). Effects of ultrasound pretreatments on the kinetics of moisture loss and oil uptake during deep fat frying of sweet potato (*Ipomea batatas*). *Innovative food science & emerging technologies*, 43, 7-17.
  
159. Su, Y., Zhang, M., Chitrakar, B., & Zhang, W. (2021). Reduction of oil uptake with osmotic dehydration and coating pre-treatment in microwave-assisted vacuum fried potato chips. *Food Bioscience*, 39, 100825.
  
160. Tran, T. M., Chen, X. D., & Southern, C. (2007). Reducing oil content of fried potato crisps considerably using a 'sweet' pre-treatment technique. *Journal of food engineering*, 80, 719-726.
  
161. Su, Y., Zhang, M., Chitrakar, B., & Zhang, W. (2020). Effects of low-frequency ultrasonic pre-treatment in water/oil medium simulated system on the improved processing efficiency and quality of microwave-assisted vacuum fried potato chips. *Ultrasonics Sonochemistry*, 63, 104958.
  
162. Da Silva, P. F., & Moreira, R. G. (2008). Vacuum frying of high-quality fruit and

- vegetable-based snacks. LWT, 41, 1758-1767.
163. Qiu, L., Zhang, M., Wang, Y., & Bhandari, B. (2018). Effects of ultrasound pretreatments on the quality of fried sweet potato (*Ipomea batatas*) chips during micro wave-assisted vacuum frying. *Journal of Food Process Engineering*, 41(8), e12879.
  164. Su, Y., Zhang, M., Bhandari, B., & Zhang, W. (2018). Enhancement of water removing and the quality of fried purple-fleshed sweet potato in the vacuum frying by combined power ultrasound and microwave technology. *Ultrasonics Sonochemistry*, 44, 368-379.
  165. Selvakumar, R., & Tiwari, R. B. (2018). Effect of osmotic treatments on weight reduction, water loss, solid gain, moisture, total solids, yield and drying ratio of carrot (*Daucus carota* L.) slices. *Chemical Science Review and Letters*, 2018, 7, 959-965.
  166. Krokida, M. K., Karathanos, V. T., & Maroulis, Z. B. (2000). Effect of osmotic dehydration on color and sorption characteristics of apple and banana. *Drying Technology*, 18, 937-950.
  167. Serpen, A., & Gokmen, V. (2007). Modeling of acrylamide formation and browning ratio in potato chips by artificial neural network. *Molecular nutrition & food research*, 51, 383-389.
  168. Guiné, R. (2019). The use of artificial neural networks (ANN) in food process engineering. *International Journal of Food Engineering*, 5, 15-21.

169. Said, F. M., Gan, J. Y., & Sulaiman, J. (2020). Correlation between response surface methodology and artificial neural network in the prediction of bioactive compounds of unripe *Musa acuminata* peel. *Engineering Science and Technology, an International Journal*, 23, 781-787.
170. Zikmund, W. G. (2000). *Business research methods*. Dryden Press.
171. Henseler, J., Ringle, C. M. & Sinkovics, R. R. (2009). The use of partial least squares path modeling in international marketing. In Sinkovics, R. R., & Ghauri, P. N. (Ed.) *New Challenges to International Marketing* (pp 277-319). Emerald Group Publishing.
172. Bai, X. L., Yue, T. L., Yuan, Y. H., & Zhang, H. W. (2010). Optimization of microwave-assisted extraction of polyphenols from apple pomace using response surface methodology and HPLC analysis. *Journal of separation science*, 33, 3751-3758.
173. Kramer, O. (2017). *Genetic algorithms*. Springer.
174. Zou, Y., & Lv, J. (2020). Using recurrent neural network to optimize electronic nose system with dimensionality reduction. *Electronics*, 9(12), 2205.
175. Ghimire, S., Deo, R. C., Casillas-Perez, D., Salcedo-Sanz, S., Sharma, E., & Ali, M. (2022). Deep learning CNN-LSTM-MLP hybrid fusion model for feature optimizations and daily solar radiation prediction. *Measurement*, 202, 111759.
176. Khare, N., Devan, P., Chowdhary, C. L., Bhattacharya, S., Singh, G., Singh, S., & Yoon, B. (2020). Smo-dnn: Spider monkey optimization and deep neural network



- hybrid classifier model for intrusion detection. *Electronics*, 9(4), 692.
177. Oladejo, A. O., Ma, H., Qu, W., Zhou, C., & Wu, B. (2017). Effects of ultrasound on mass transfer kinetics, structure, carotenoid and vitamin C content of osmodehydrated sweet potato (*Ipomea batatas*). *Food and Bioprocess Technology*, 10, 1162-1172.
  178. Sobukola, O. P., Dueik, V., Munoz, L., & Bouchon, P. (2013). Comparison of vacuum and atmospheric deep-fat frying of wheat starch and gluten based snacks. *Food Science and Biotechnology*, 22, 177-182.
  179. Pandiselvam, R., Tak, Y., Olum, E., Sujayasree, O. J., Tekgül, Y., Çalışkan Koç, G., ... & Kumar, M. (2021). Advanced osmotic dehydration techniques combined with emerging drying methods for sustainable food production: impact on bioactive components, texture, color, and sensory properties of food. *Journal of Texture Studies*. 2021, 1-26.
  180. Wang, R., Zhang, M., & Mujumdar, A. S. (2010). Effect of osmotic dehydration on microwave freeze-drying characteristics and quality of potato chips. *Drying Technology*, 28, 798-806.
  181. Carels, R. A., Harper, J., & Konrad, K. (2006). Qualitative perceptions and caloric estimations of healthy and unhealthy foods by behavioral weight loss participants. *Appetite*, 46(2), 199-206.
  182. Halton, T. L., Willett, W. C., Liu, S., Manson, J. E., Stampfer, M. J., & Hu, F. B. (2006). Potato and french fry consumption and risk of type 2 diabetes in wom

- en. The American journal of clinical nutrition, 83(2), 284-290.
183. Chen, M. J., Hsu, H. T., Lin, C. L., & Ju, W. Y. (2012). A statistical regression model for the estimation of acrylamide concentrations in French fries for excess lifetime cancer risk assessment. *Food and Chemical Toxicology*, 50(10), 3867-3876.
  184. Mesias, M., Delgado-Andrade, C., Holgado, F., & Morales, F. J. (2019). Acrylamide content in French fries prepared in food service establishments. *LWT*, 100, 83-91.
  185. Muttucumar, N., Powers, S. J., Elmore, J. S., Briddon, A., Mottram, D. S., & Halford, N. G. (2014). Evidence for the complex relationship between free amino acid and sugar concentrations and acrylamide-forming potential in potato. *Annals of applied biology*, 164(2), 286-300.
  186. Asokapandian, S., Swamy, G. J., & Hajjul, H. (2020). Deep fat frying of foods: A critical review on process and product parameters. *Critical Reviews in Food Science and Nutrition*, 60(20), 3400-3413.
  187. Morrison, J. A., Glueck, C. J., & Wang, P. (2008). Dietary trans fatty acid intake is associated with increased fetal loss. *Fertility and sterility*, 90(2), 385-390.
  188. Matta, M., Huybrechts, I., Biessy, C., Casagrande, C., Yammine, S., Fournier, A., ... & Murphy, N. (2021). Dietary intake of trans fatty acids and breast cancer risk in 9 European countries. *BMC medicine*, 19(1), 1-11.
  189. Jameson, C. W. (2019). Tumour site concordance and mechanisms of carcinogenesis

- s. IARC Scientific Publications.
190. Moreira, R. G. (2014). Vacuum frying versus conventional frying—An overview. *European Journal of Lipid Science and Technology*, 116(6), 723-734.
  191. Mariscal, M., & Bouchon, P. (2008). Comparison between atmospheric and vacuum frying of apple slices. *Food chemistry*, 107(4), 1561-1569.
  192. Granda, C., Moreira, R. G., & Tichy, S. E. (2004). Reduction of acrylamide formation in potato chips by low-temperature vacuum frying. *Journal of food science*, 69(8), 405-411.
  193. Mariotti-Celis, M. S., Cortés, P., Dueik, V., Bouchon, P., & Pedreschi, F. (2017). Application of vacuum frying as a furan and acrylamide mitigation technology in potato chips. *Food and Bioprocess Technology*, 10(11), 2092-2099.
  194. Yin, C., Noratto, G. D., Fan, X., Chen, Z., Yao, F., Shi, D., & Gao, H. (2020). The impact of mushroom polysaccharides on gut microbiota and its beneficial effects to host: a review. *Carbohydrate polymers*, 250, 116942.
  195. Backhed, F., Ley, R. E., Sonnenburg, J. L., Peterson, D. A., & Gordon, J. I. (2005). Host-bacterial mutualism in the human intestine. *science*, 307(5717), 1915-1920.
  196. Topping, D. L., & Clifton, P. M. (2001). Short-chain fatty acids and human colonic function: roles of resistant starch and nonstarch polysaccharides. *Physiological reviews*, 81, 1031-1064.

197. Canfora, E. E., Meex, R. C., Venema, K., & Blaak, E. E. (2019). Gut microbial metabolites in obesity, NAFLD and T2DM. *Nature Reviews Endocrinology*, 15(5), 261-273.
198. Dao, M. C., & Clément, K. (2018). Gut microbiota and obesity: Concepts relevant to clinical care. *European journal of internal medicine*, 48, 18-24.
199. Lavelle, A., & Sokol, H. (2020). Gut microbiota-derived metabolites as key actors in inflammatory bowel disease. *Nature reviews Gastroenterology & hepatology*, 17(4), 223-237.
200. Wu, J., Qiu, M., Zhang, C., Zhang, C., Wang, N., Zhao, F., ... & Wang, X. (2021). Type 3 resistant starch from *Canna edulis* modulates obesity and obesity-related low-grade systemic inflammation in mice by regulating gut microbiota composition and metabolism. *Food & Function*, 12(23), 12098-12114.
201. Requena, T., Martínez-Cuesta, M. C., & Peláez, C. (2018). Diet and microbiota linked in health and disease. *Food & function*, 9(2), 688-704.
202. Ji, B., & Nielsen, J. (2015). From next-generation sequencing to systematic modeling of the gut microbiome. *Frontiers in genetics*, 6, 219.
203. Shokralla, S., Spall, J. L., Gibson, J. F., & Hajibabaei, M. (2012). Next-generation sequencing technologies for environmental DNA research. *Molecular ecology*, 21(8), 1794-1805.
204. Furuhashi, T., Sugitane, K., Nakai, T., Jikumaru, Y., & Ishihara, G. (2018). Rapid

- profiling method for mammalian feces short chain fatty acids by GC-MS. *Analytical biochemistry*, 543, 51-54.
205. Shyu, Y. S., Hwang, J. Y., Shen, S. T., & Sung, W. C. (2021). The Effect of Different Frying Methods and the Addition of Potassium Aluminum Sulfate on Sensory Properties, Acrylamide, and Oil Content of Fried Bread (Youtiao). *Applied sciences*, 11(2), 549.
206. 신한승. (2013). 유당식품 중 다환방향족탄화수소 평가 및 공정요인 분석 (2013년 기초연구과제총서). 울촌재단. <http://www.youlchon.org/scho/rese/reseView.do?id x=1026&pageNo=8>
207. Purcaro, G., Navas, J. A., Guardiola, F., Conte, L. S., & Moret, S. (2006). Polycyclic aromatic hydrocarbons in frying oils and snacks. *Journal of food protection*, 69 (1), 199-204.
208. Liang, H., Jiang, F., Cheng, R., Luo, Y., Wang, J., Luo, Z., ... & He, F. (2021). A high-fat diet and high-fat and high-cholesterol diet may affect glucose and lipid metabolism differentially through gut microbiota in mice. *Experimental Animals*, 70 (1), 73-83.
209. Sa'ad, H., Peppelenbosch, M. P., Roelofsen, H., Vonk, R. J., & Venema, K. (2010). Biological effects of propionic acid in humans; metabolism, potential applications and underlying mechanisms. *Biochimica et Biophysica Acta (BBA)-Molecular and Cell Biology of Lipids*, 1801(11), 1175-1183.
210. Liu, H., Zhang, M., Ma, Q., Tian, B., Nie, C., Chen, Z., & Li, J. (2020). Health

- beneficial effects of resistant starch on diabetes and obesity via regulation of gut microbiota: a review. *Food & function*, 11(7), 5749-5767.
211. Wang, B., Yu, H., He, Y., Wen, L., Gu, J., Wang, X., ... & Wang, H. (2021). Effect of soybean insoluble dietary fiber on prevention of obesity in high-fat diet fed mice via regulation of the gut microbiota. *Food & Function*, 12(17), 7923-7937.
  212. Bang, S. J., Lee, E. S., Song, E. J., Nam, Y. D., Seo, M. J., Kim, H. J., ... & Seo, D. H. (2019). Effect of raw potato starch on the gut microbiome and metabolome in mice. *International journal of biological macromolecules*, 133, 37-43.
  213. Guo, B., Yang, B., Pang, X., Chen, T., Chen, F., & Cheng, K. W. (2019). Fucoxanthin modulates cecal and fecal microbiota differently based on diet. *Food & function*, 10(9), 5644-5655.
  214. Kim, K. A., Gu, W., Lee, I. A., Joh, E. H., & Kim, D. H. (2012). High fat diet-induced gut microbiota exacerbates inflammation and obesity in mice via the TLR 4 signaling pathway. *PLoS One*, 7, 47713.
  215. Spencer, M. D., Hamp, T. J., Reid, R. W., Fischer, L. M., Zeisel, S. H., & Fodor, A. A. (2011). Association between composition of the human gastrointestinal microbiome and development of fatty liver with choline deficiency. *Gastroenterology*, 140(3), 976-986.
  216. Kaakoush, N. O. (2015). Insights into the role of *Erysipelotrichaceae* in the human host. *Frontiers in cellular and infection microbiology*, 5, 84.