

제빵 굽기 공정의 신경회로망 모형화

김승찬 · 조성인 · 전재근*

서울대학교 농공학과 농업기계전공, *서울대학교 식품공학과

Neural Network Modeling for Bread Baking Process

Seungchan Kim, Seong In Cho and Jae Geun Chun

Department of Agricultural Engineering

*Department of Food Science, Seoul National University

Abstract

Three quality factors of bread during baking process were measured to develop neural network models for bread baking process. Firstly, volume and browning changes during bread baking process were measured using image processing technique and temperature changes inside the bread during process were measured by K-type thermocouples. Relationships among them showed nonlinearity. Secondly, multilayer perceptron structure with error back propagation learning was used to construct neural network models. Three neural network models for volume, browning, and bread temperature were developed respectively. Developed models showed good performance with predictive error of 4.62% for volume and browning changes after 30 seconds, 7.38% for volume and browning changes after 2 minutes, and 1.09% for temperature change inside the bread respectively.

Key words: bread baking process, modeling, neural network

서 론

식품 산업에서 생산성 향상과 제품의 고급화를 위한 식품 제조 공정의 자동화, 지능화를 위한 연구가 활발히 진행되고 있다. 이러한 연구 분야를 들면, 제품 생산 중 공정 진행 상황의 파악, 품질의 실시간 계측, 공정의 제어, 그리고 새로운 제품의 생산을 위한 공정의 개발 등으로 나누어 질 수 있다. 식품 제조 공정 자동화의 경우, 공정 제어 신호에 의한 공정 상태의 변화가 시간 지연을 수반하기 때문에 공정의 진행 상황을 예측하여 공정을 제어하는 예측 제어 등의 기법이 도입되고 있다. 즉 공정 진행 중의 제품의 상태, 공정의 진행 정도 및 품질 변화를 정확히 계측할 수 있어야 할 뿐 아니라, 공정 중의 제품의 품질 또는 상태 변화를 정확하게 예측할 수 있는 방법이 요구되고 있다.

신경회로망 모형은 학습 능력이 있고, 왜란에 강하고, 비선형적인 관계를 잘 표현하고 있어 여러 분야에서 예측 모형에 응용되고 있다. 제빵 공정 중의 빵의 부피, 색, 온도 등의 품질 인자간의 관계는 비선형성을 나타내므로¹⁾, 이들 간의 상호 관계를 예측, 모형화하기 위해 신경회로망 기법을 이용하였다.

한편 식품 분야의 경우, 컴퓨터를 이용한 영상처리 기

법이 활발히 이용되고 있는데, Monnin²⁾은 제빵 공정의 굽기 공정 중의 제품의 형상과 부피를 계측하기 위하여 Machine vision을 이용하였고, Ling³⁾ 등은 색깔의 변화를 계측하기 위하여 Color machine vision을 이용하였다. 또한 Kexiang⁴⁾은 신경회로망과 MIZ classifier를 이용하여 영상 처리장치를 통한 데이터를 바탕으로 식품의 형상을 인식, 분류한 바 있다.

따라서 본 연구에서는 제빵 공정에서 빵의 품질을 최종적으로 결정하는 굽기 공정에 사용되는 오븐의 예측 제어를 목적으로, 공정 진행 중의 빵의 품질을 예측하기 위한 모형을 개발하였다. 즉 제빵 굽기 공정 중의 빵의 상태를 표현하는 빵의 부피 및 색 변화(browning)를 계측하기 위한 장치 및 알고리즘을 개발하고, 계측된 데이터를 바탕으로 신경회로망 기법을 이용하여 부피, 색 및 온도 등의 빵의 상태 변화를 예측하기 위한 모형을 개발하였다.

재료 및 방법

제빵 시료 및 방법

밀가루(중력분)를 주원료로 한 식빵을 혼합, 1차 발효, 분할, 둥글리기, 중간 발효, 성형, 2차 발효, 굽기의 단위 공정으로 이루어진 직접법에 의하여 제빵하였다. Table 1의 재료를 혼합하여, 반죽기를 사용하여 표피가 형성될 때까지 반죽을 하였고, 만들어진 생지를 약 600g씩 등

Corresponding author: Seungchan Kim, Department of Agricultural Engineering, Seoul National University

Table 1. Composition of bread dough

Material	Composition (g)
Wheat flour	100
Water	60
Yeast	5
Salt	4
Sugar	5
Margarine	10
Milk powder	4




Fig. 1. Notations for calculation of bread height
 x, y, z, w - screen coordinates in "pixel"
 L, l, H, h₁, h₂, h' - real value in "cm"

분하여 사용하였다. 분할된 생지는 27°C, 75%RH 조건에서 90분간 1차 발효시킨 후, 제빵틀(Fig. 1 참조)에 옮겨 40°C, 85%RH에서 50분간 2차 발효하였다. 오븐은 내부 온도를 190°C 정도로 미리 가열한 후에 시료를 넣어 공정을 진행시켰다. 본 연구의 분석 대상은 제빵의 마지막 공정인 굽기 공정을 연구 대상으로 하였다.

제빵 공정 실험 장치

제빵을 위해 반죽기(Daeyoung co.), 발효기(Daeyoung co.), 케비넷형 제빵 오븐(Daeyoung co., 전열식)을 이용하였고, 상세한 규격은 Table 2와 같다.

오븐 내의 온도 변화와, 빵의 온도(푼온, 표면 온도) 변화를 계속하기 위하여 K-type 열전쌍(Samhwa co.), AD 595AQ(Analog Device co.)를 이용한 온도 계측 장치를 구성하였다⁽⁵⁾.

굽기 공정 중의 빵의 부피, 색 변화를 계속하기 위해 영상 처리 장치를 구성하였고, 빵의 부피 결정을 위해 sobel 연산자 등을 이용한 윤곽선 결정 기법⁽⁶⁾, 빵의 색 변화를 나타내기 위해 히스토그램 분석 등의 영상 처리 기법을 이용하였다. 영상 처리 장치의 규격은 Table 3과 같고, 구성된 데이터 수집 장치는 Fig. 2와 같다.

영상 처리 기법

제빵 용기의 전면의 일부를 절단하여 빵의 영상을 획득한 후, 윤곽선 결정 기법을 통하여 Fig. 1(a), 1(b)와 같이 빵의 상단을 검출하여 식 (1), (2)를 이용하여 빵의 높이 (h)를 구하고, 이로부터 빵의 부피를 세측하였다. 또한 빵의 색 변화를 계속하기 위해서 검출된 윤곽선 안쪽의 grey-value(8bit, black~white=0~255)의 평균

Table 2. Specification of baking oven

Maker	Daeyoung co.
Oven type	Double oven, cabinet
Oven volume	0.82 m×0.72 m×0.22 m
Heater	6 kW×2 (upper & lower)

Table 3. Specification of image processing equipment

Camera	CCD camera (high resolution) /MC-750A (Kukjae co.)
Image board	SeeEye-512
Input signal	RS-170 mono video
Output signal	RS-170 composite video RGB pseudo color output
Input resolution & color	512×512×8 bit grey×1 Page
Memory map	D000:0 segment 64 kbyte




Fig. 2. Measurement system for bread baking process

값을 이용하였다⁽⁷⁾.

$$h' = \left(\frac{y-z}{y-x} \right) \times h_1 + h_2;$$

$$H = \left(\frac{y-w}{y-x} \right) \times h_1 + h_2; \text{ where } w=256 \tag{1}$$

$$\frac{l}{L} = \frac{h'-h}{H-h}$$

$$\therefore h = \frac{Lh' - lH}{L-1} \text{ for } h' < H \tag{2}$$

신경회로망 이론

빵의 부피, 색, 온도 등의 품질 인자간의 비선형적인 상호 관계를 모형화하기 위해 신경회로망 기법을 이용하였다. 신경회로망이란 생명체의 신경조직인 신경세포(neuron)에서 착안한 정보처리 시스템으로 단순한 소자들의 병렬, 분산 연결 구조를 가지고 있으며, 외부로부터 받아들이는 입력에 대하여 동적 반응을 일으킴으로써 필요한 출력을 생성시키도록 구성되어 있다. 신경회로망 모형은 일반적으로 학습 능력이 있고, 왜란에 강하고,




Fig. 3. Simple neuron model

w_1, w_2, w_n - weight values




Fig. 4. Multilayer perceptron with error back-propagation learning

비선형적인 관계를 잘 표현하는 것을 그 특징으로 한다. 현재는 단순인식자(single-layer perceptron or simple perceptron), 다층인식자(multi-layer perceptron; MLP)를 비롯하여 Hopfield network, Kohonen feature map 등이 많이 이용되고 있다^(8,9). 이러한 신경회로망은 외국의 경우 Bullock⁽¹⁰⁾, Eerikainen⁽¹¹⁾ 등에 의해서 식품 공정의 모형화에 이용되고 있다.

단순인식자는 거의 모든 신경회로망 구조의 가장 기본이 되는 것으로, 1957년에 Rosenblatt가 패턴 분류를 위해 제안한 것으로 두뇌의 신경세포 1개에 해당한다고 할 수 있다. 단순인식자 구조는 Fig. 3과 같은 구조를 가지고, 수학적 모형은 식 (3)과 같이 표현될 수 있다. 현재 가장 널리 쓰이는 신경회로망의 구조는 Fig. 4와 같은 다층인식자 구조로, 이는 단순인식자의 몇 가지 문제점을 해결하기 위해 1986년 Rumelhart에 의해 제안된 계층형 구조의 네트워크(MLP)이다. 학습 방법으로는 오류역전파 알고리즘(BP; Error Back-Propagation algorithm)을 사용하였다^(8,9).

$$\begin{aligned} \text{Activation, } net_{pk} &= \sum_{i=1}^n w_i \cdot x_i \\ \text{Output, } o_{pk} &= f(net_{pk}) \\ &= \frac{1}{1 + \exp(-\beta net_{pk})} \end{aligned} \quad (3)$$

: sigmoid function

w_i : weight value
 x_i : input value to node
 β : stiffness (~ 1.0)

BP학습 방법은 입력층(input layer)으로 입력된 신호가 순방향으로 은닉층(hidden layer), 출력층(output layer)으로 전달되고, 출력 오차는 전달된 신호(o_{pk})와 원하는 신호(y_{pk})의 비교에 의해서 최종 출력층에서 식 (4)와 같이 결정된다. 은닉층과 출력층, 입력층과 은닉층 사이의 가중치들의 값을 변경하기 위해서 출력층과 은닉층에서의 오차항(error term)이 계산되어야 하는데, 출력층에서는 식 (5)와 같이 계산되고, 은닉층에서는 식 (6)을 이용하여 출력층의 오차항을 은닉층으로 역방향으로 전달(error

back propagation)하여 계산한다. 이렇게 계산된 오차항과 일반화된 델타법(GDR: Generalized Delta Rule)을 이용하여 식 (7)과 같이 각 층의 가중치들을 갱신한다^(8,9).

$$E_p = \frac{1}{2} \sum_k (y_{pk} - o_{pk})^2 \quad (4)$$

y_{pk} : desired output,
 o_{pk} : network's output

$$\begin{aligned} \delta_{pk}^o &= \delta_{pk} \cdot f'(net_{pk}^o); \text{ for output layer} \\ \delta_{pk} &= (y_{pk} - o_{pk}) \end{aligned} \quad (5)$$

δ_{pk}^o : error term of k-th output node
 net_{pk}^o : activation of k-th output node

$$\delta_{pj}^h = \left(\sum_k \delta_{pk}^o \cdot w_{kj}^o \right) \cdot f'(net_{pj}^h); \text{ for hidden layer} \quad (6)$$

δ_{pj}^h : error term of j-th hidden node

$\sum_k \delta_{pk}^o \cdot w_{kj}^o$: back-propagated error-term
 from output layer

$$\begin{aligned} w_{kj}^o(t+1) &= w_{kj}^o(t) + \eta \delta_{pk}^o i_{pj}; \text{ for output layer} \\ w_{ji}^h(t+1) &= w_{ji}^h(t) + \eta \delta_{pj}^h x_i; \text{ for hidden layer} \end{aligned} \quad (7)$$

η : learning rate > 0

w_{kj}^o : weight value from k-th hidden node
 to j-th output node

w_{ji}^h : weight value from j-th input node
 to i-th hidden node

δ_{pk}^o : error term at k-th output node

δ_{pj}^h : error term at j-th hidden node

i_{pj} : output from j-th hidden node

x_i : i-th input value

결과 및 고찰

굽기 공정 중 물리적 변화

생기 내부 온도는 전도, 증발-응축에 의한 열교환으로




Fig. 5. Bread temperature changes during baking process




Fig. 8. Relationships between bread temperature inside and bread volume




Fig. 6. Bread volume changes during baking process




Fig. 9. Relationships between bread temperature surface and bread browning




Fig. 7. Bread browning changes during baking process

온도가 상승하고, 생지는 굽기 공정 중에 증숙, 부피 팽창, 색 변화(browning)의 3가지의 상태 변화를 거치는 것으로 알려져 있다⁽¹⁾. 공정 중의 빵 내부 온도(BTI; Bread Temperature Inside) 및 표면 온도(BTS; Bread Temperature Surface)를 측정한 결과는 Fig. 5와 같다. 오븐 온도가 200°C인 경우, 표면 온도는 초기에 급격히 상승하여, 약 7분 경과 후 110°C에 이르고, 이후는 완만히 상승하였다. 내부 온도는 초기에는 변화가 거의 없고, 약 5분 경부터 급격히 상승하여 15분 경에 90°C에 이르고, 25분 경에 100°C에 도달하였다.

공정의 진행 정도 및 빵의 품질을 판단하는 기준이

되는 빵의 부피 변화를 측정한 결과는 Fig. 6과 같다. 그 결과 부피는 초기에 급격히 증가하고 20분 경부터는 증가가 거의 없었다. 공정 시작 단계의 부피에 비해, 약 3배의 부피 증가가 관찰되었고, 오븐 온도가 200°C인 경우에 190°C보다 부피 증가의 속도가 조금 더 컸다.

빵의 색깔 변화를 grey-value의 평균값으로 측정한 결과는 Fig. 7과 같다. 11분(200°C) 또는 17분(190°C)까지는 빵의 색 변화가 없었고, 육안으로 관찰한 결과, 빵의 색깔 변화는 부피 증가가 끝나면서 색 변화가 발생하기 시작하였다. 생지의 경우에는 grey-value가 160, 잘 구워진 빵의 경우는 grey-value가 135 정도였다.

이 결과를 바탕으로 굽기 공정 중 빵의 상태 변화 모형을 개발하기 위해 각 인자(부피, 색깔, 품온, 표면 온도 등)의 관계를 도출하여 보면 각각 Fig. 8, 9와 같다. Fig. 8, 9에서 알 수 있듯이 부피, 색깔, 품온, 표면 온도의 상호 관계는 비선형적이어서, 이를 수학적 모형화 하는 것은 어렵다. 따라서 이들 사이의 관계를 정확히 정의할 수 있는 모형은 다른 방법으로 접근되어야 한다는 것을 알 수 있다. 또한 식품 제조 공정 중의 제품의 품질을 측정하는 것은 필연적으로 계속 오차를 수반하게 되는데, 이렇게 오차가 포함된 계속 정보를 바탕으로 공정의 진행 상황을 예측할 수 있는 모형을 개발하기 위해서는 개발된 모형이 측정된 정보에 어느 정도의 오차가 존재하여도

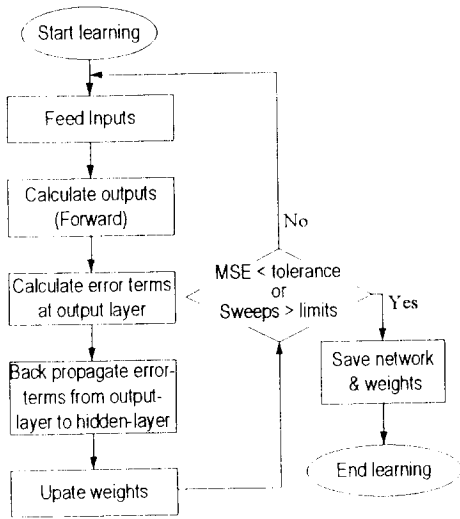


Fig. 10. Flow diagram for development of neural network model

공정의 상황을 적절히 예측할 수 있는, 즉 잡음에 강한 모형이어야 할 것이다. 신경회로망 모형은 입력 인자들을 병렬, 분산 처리함으로써 인자들간의 비선형성을 잘 모사할 뿐만 아니라 잡음에도 강한 것으로 밝혀져 있어, 식품 공정의 모형화에 적합한 것으로 보고된 바 있다.^(8,9,10,11)

굽기 공정의 신경회로망 모형 개발

굽기 공정 중의 부피, 색깔 및 내부 온도의 변화를 예측할 수 있는 신경회로망 모형을 구축하기 위해, 신경회로망 구조는 bias 항이 있는 MLP를, 학습 방법은 식 (8)과 같이 momentum항이 추가된 수정된 BP를 이용하였다^(8,9). BP학습을 이용하는 MLP 구조의 모형을 구축하고 학습 오차의 변화, 학습된 가중치와 신경회로망 구조를 저장할 수 있도록 C언어로 프로그램을 개발하였다⁽⁷⁾. 이러한 과정을 흐름도로 표시하면 Fig. 10과 같다.

$$w_{kj}(t+1) = w_{kj}(t) + \eta \delta_{pk} i_{pj} + \alpha \Delta w_{kj}(t)$$

$$\Delta w_{kj}(t) = w_{kj}(t) - w_{kj}(t-1) \tag{8}$$

α : momentum parameter < 1.0 (~0.9)

굽기 공정 중의 빵의 상태 변화 예측을 위한 신경회로망 모형 구축에 사용된 입력 인자와 출력 인자들의 결정은 문헌에 보고된 자료⁽¹¹⁾, 본 연구의 실험을 통해 얻어진 데이터의 분석 및 시행 착오를 통하여 결정되었다⁽⁷⁾.

MLP의 은닉층의 개수와 각 층의 node수는 시행착오를 거쳐 선택되었다. 우선 은닉층을 1개를 두고, 작은 개수의 node로 학습을 시키고, node수를 증가시키면서 학습 오차의 변화를 기록하여, 학습 오차가 가장 작은




Fig. 11. Neural network structure of model I to predict volume and browning after 30 seconds

Table 4. Error analysis for neural network model I to predict volume and browning of bread after 30 seconds during baking process

Input variables: $VOLUME_{t-1}$, $BROWN_{t-1}$, $VOLUME_t$, $BROWN_t$, $OVNTPT_t$; output variables: $VOLUME_{t+1}$, $BROWN_{t+1}$

Model I (5-8-6-2): after 30 seconds		Error (%)
Trained	Total error	2.08
	Volume error	1.04
	Browning error	1.93
Untrained (prediction)	Total error	4.62
	Vvolume error	3.19
	Browning error	2.34

모형을 선택하였다. 선택된 모형에서 은닉층의 개수를 늘린 후, 2번째 은닉층의 node수를 결정하였다. 각 학습된 모형 중에서, 가장 적은 학습 오차를 나타내는 모형이 최종적인 모형으로 선택되었다. 선택된 모형은 추가적인 학습을 통해 모형의 예측 성능을 향상시켰다. 1차 학습에서는 20,000회, 2차 학습에서는 60,000회의 학습이 수행되었다.

부피 및 색 변화 예측 모형(Model I)

공정 중, 30초 이후의 부피 및 색 변화를 예측하기 위해서, 30초 이전의 빵의 부피 및 표면의 색($VOLUME_{t-1}$, $BROWN_{t-1}$), 현재의 빵의 부피 및 표면의 색($VOLUME_t$, $BROWN_t$), 현재의 오븐 온도(OVNTPT)를 입력으로, 30초 이후의 빵의 부피 및 표면의 색($VOLUME_{t+1}$, $BROWN_{t+1}$)을 출력으로 하여 학습, 구축된 모형의 구조는 5-8-6-

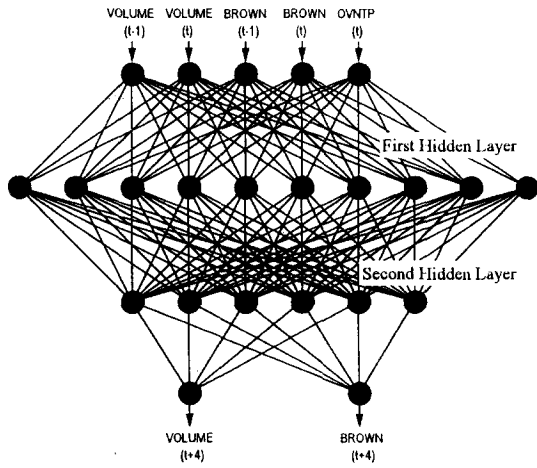


Fig. 12. Neural network structure of model II to predict volume and browning after 2 minutes




Fig. 13. Neural network structure of model III to predict bread temperature

Table 5. Error analysis for neural network model II to predict volume and browning of bread after 2 minutes during baking process

Input variables: $VOLUME_{t-1}$, $BROWN_{t-1}$, $VOLUME_t$, $BROWN_t$, $OVNTP_t$; output variables: $VOLUME_{t+4}$, $BROWN_{t+4}$

Model II (5-10-6-2): after 2 minutes		Error (%)
Trained	Total error	1.77
	Volume error	1.06
	Browning error	1.52
Untrained (prediction)	Total error	7.38
	Volume error	5.90
	Browning error	4.87

2로 Fig. 11과 같다. 신경회로망 모형의 성능은 학습 오차와 예측 오차로 나타내는 데, 학습 오차는 모형 구축에 사용된 데이터들에 대한 오차로 SEC(Standard Error of Calibration)에 해당하고, 예측 오차는 학습에 사용되지 않은 데이터들에 대한 오차로 SEP(Standard Error of Prediction)에 해당한다. 개발된 모형의 학습 및 예측 오차는 Table 4와 같고, 부피와 색에 대하여 예측 오차가 각각 $Err_{VOLUME}=0.49$ cm, $Err_{BROWN}=1.50$ grey 이었다.

부피 및 색 변화 예측 모형(Model II)

굽기 공정에 사용되는 오븐의 온도 제어는 2분의 시간 지연이 있어, 2분 후의 빵의 상태 변화($VOLUME_{t+4}$, $BROWN_{t+4}$)를 예측하기 위한 모형을 개발하였다. 입력은 Model I과 같고, 개발된 모형은 Fig. 12와 같은 5-10-6-2의 구조이다. 학습 및 예측 오차는 Table 5와 같고, 부피와 색의 예측 오차는 각각 $Err_{VOLUME}=0.91$ cm, $Err_{BROWN}=3.13$ grey 이었다.

Table 6. Error analysis for neural network model III to predict bread temperature during baking process

Input variables: $VOLUME_{t-2}$, $BROWN_{t-2}$, $VOLUME_{t-1}$, $BROWN_{t-1}$, $VOLUME_t$, $BROWN_t$, $OVNTP_t$; output variables: BTI_t , BTS_t

Model III (7-6-4-2): immediate temperature		Error (%)
Trained	Total error	0.79
	Bread temperature (body) error	0.66
	Bread temperature (surface) error	0.42
Untrained (prediction)	Total error	1.09
	Bread temperature (body) error	0.95
	Bread temperature (surface) error	0.43

품온 예측 모형(Model III)

빵의 품온은 굽기 공정 중에 발생하는 식품 화학적 반응에 중요한 영향을 주고, 표면 온도는 색 변화, 질감 등의 제품의 시각적 특성을 결정하는 주요 인자이므로⁽¹¹⁾, 이를 정확히 예측하는 것은 제품의 품질 및 상품성의 향상을 위해 필수적이다. 제빵 생산 현장에서는 공정이 진행되는 동안 빵의 품온 및 표면 온도는 공정 중에 예측할 수 없으므로, 예측 가능한 부피, 색깔 및 오븐의 온도 등을 이용하여 품온 및 표면 온도를 예측할 수 있는 모형이 필요하다. 따라서 이를 위한 신경회로망 모형은 현재, 30초 전, 1분 전의 빵의 부피 및 표면의 색과 현재 오븐의 온도를 입력으로, 품온(BTI), 표면 온도(BTS)를 출력하도록 하였다. 개발된 신경회로망 모형은 Fig. 13과

같은 7-6-4-2의 구조와, Table 6과 같은 학습 및 예측 오차를 나타내었다. 품온 및 표면 온도에 대한 예측 오차는 각각 $Err_{BTI} = 2.27^{\circ}C$, $Err_{BTS} = 1.03^{\circ}C$ 이었다.

제빵 공정 중의 부피, 색, 품온 등의 인자들은 상호 간의 관계가 비선형성을 나타내게 되므로, 이들 간의 관계를 모사하고 예측하기 위하여 신경회로망 기법을 이용하였다. 본 연구에서는 3개의 신경회로망 모형이 개발되었고, 빵의 부피, 색, 품온 간의 상호관계를 유의성있게 모사할 수 있었다.

요 약

제빵 공정 중의 굽기 공정을 대상으로 공정에 이용되는 오븐의 예측 제어를 위해 빵의 부피, 색깔, 빵의 온도 변화를 예측할 수 있는 모형을 개발하였다.

첫째, 모형 개발을 위해 필요한 데이터 획득을 위해 영상 처리 장치, K-type 열전쌍 온도 센서 등을 이용하여, 굽기 공정 중의 물리적 변화를 측정하였다. 빵의 상태 변화는 부피가 먼저 증가하고, 부피 증가가 멈춘 후에 색깔의 변화가 수반되었다. 표면 온도는 초기에 급격히 상승한 후에 완만한 상승으로 전환되었고, 내부 온도는 초기에 어느 정도 일정한 온도를 유지하다가, 중반에 급격한 상승을 나타내고, 이후에 다시 일정하게 유지되었다. 부피, 색과, 품온 간의 상호관계는 비선형적인 관계를 가진 것으로 판명되었다.

둘째, 빵의 부피, 색 변화를 예측하기 위해 MLP구조와 BP학습을 이용하여, 30초, 2분 이후의 부피 및 색 변화를 예측할 수 있는 모형과 부피, 색, 오븐 온도를 입력으로 품온 및 표면 온도를 예측할 수 있는 모형을 개발하였다. 개발된 모형의 예측 오차가 각각 4.62%, 7.38%, 1.09%로, 굽기 공정 중의 빵의 상태를 유의성 있게 예측할 수

있었다.

문 헌

1. Eliasson, A. and Larsson, K.: *Cereals in Breadmaking-A Molecular Colloidal Approach*. Marcel Dekker, Inc. (1993)
2. Monnin, M.: Machine Vision Gauging in a Bakery. In *Food Processing Automation III*, p.62 (1994)
3. Ling, P.P. and Ruzhitzky, V.N.: Color Sensing of Food Materials Using Machine Vision. In *Food Processing Automation III*, p.71 (1994)
4. Kexiang, D. and Sundaram, G.: Food Shape Inspection with Computer Vision. In *Food Processing Automation III*, p.81. (1994)
5. 김응목 : 센서활용의 전자회로. 기문사. (1994)
6. Jain, A.K.: *Fundamentals of Digital Image Processing*. Prentice Hall. (1989)
7. 김승찬 : 제빵 굽기 공정의 모형화 및 퍼지제어 시뮬레이션. 서울대학교 석사학위논문. (1995)
8. Freeman, J.A. and Skapura, D.M.: *Neural Networks-Algorithm, Applications, and Programming Technique*. Addison Wesley. (1991)
9. Hertz, J.A., Krough, A. and Palmer, R.G.: *Introduction to the Theory of Neural Computation*. Addison Wesley. (1991)
10. Bullock, D.C., Whittaker, A.D., Choi, Y. and Huang, Y.: Continuous Prediction of a Food Process with a Stationary Neural Model. *Presented at 1993 ASAE International Winter Meeting*. Paper No. 933508. ASAE, 2950 Niles Rd., St. Joseph, MI 49085-9659 USA. (1993)
11. Eerikäinen, T., Linko, P., Linko, S., Siimes, T. and Zhu, Y-H.: Fuzzy Logic and Neural Networks Applications in Food Science and Technology. *Trends in Food Science & Technology*, 4, p.237 (1993)

(1995년 3월 9일 접수)