

# 기계시각과 인공 신경망을 이용한 계란의 외부 품질 평가

## Eggshell Evaluation Using Machine Vision and Artificial Neural Network

이수환\*  
정회원  
S. H. Lee

조한근\*  
정회원  
H. K. Cho

최완규\*  
정회원  
W. K. Choi

### 1. 서론

계란은 예나 지금이나 국민의 식생활에 없어서는 안될 주요한 식품이다. 더욱이 국민의 소득향상에 따라 식품에 대한 소비자의 기호도가 고급화 되어가고 있고, 또 건강지향형 식품에 관심이 높아지고 있기 때문에 품질이 좋고 위생적인 계란을 생산하는 것은 계란 가격의 시장 경쟁력 확보뿐만 아니라 양계농가의 소득향상에 중요한 요소이다.

계란의 품질과 관련된 중요한 인자로는 난각의 균열, 난각에 묻은 오물 및 기형란 등이다. 이 중 난각에 균열이 있는 계란은 인력에 의해서 가장 먼저 제거되며, 이것을 기계적으로 분류해 내기 위한 연구가 많은 연구자들에 의해 행해졌다(권, 1996; Patel 등, 1994, 1996; Worley 등, 1995). 그러나 지금까지의 연구는 기계시각에 의한 영상 처리만을 이용한 방법이 대부분이었다. 최근 농산물의 비파괴 품질 평가 연구에서 판별 성능을 높이고 처리 속도를 향상시키기 위한 한가지 방법으로 인공 신경망 기법을 많이 이용하고 있다.

기존에 연구된 영상처리에 의한 파란 검사 방법은 복잡한 영상처리 단계를 거친 후 정상란과 파란을 선별하기 때문에 처리 시간이 오래 걸리는 단점이 있었다. 따라서 이 연구에서는 영상처리에 의해 획득한 명암도 값만을 인공 신경망 학습에 적용하여 판별시간과 판별율을 향상시키는데 중점을 두었다.

### 2. 재료 및 방법

#### 가. 공시재료

공시 재료는 일반 소매점에서 쉽게 구할 수 있는 축협 제품의 흰색 계란을 사용하였으며, 신경망의 학습을 위해 사용된 계란의 수는 정상란 30개, 파란(破卵) 30개이며, 학습된 신경망의 성능을 평가하기 위해서 신경망 학습에 사용되지 않은 새로운 정상란 60개, 파란 60개를 이용하였다. 파란의 경우 자연적으로 생긴 파란을 포함하여 실제 양계장에서 생길 수 있는 파란과 유사한 형태의 파란을 인위적으로 만들어 사용하였다.

---

\* 충북대학교 농업기계공학과

## 나. 실험장치

본 연구에 사용된 기계 시각 시스템은 주컴퓨터, 흑백 영상 처리 보드, 영상 출력 장치, 영상 입력 장치, 조명 장치로 구성되어 있다. 주컴퓨터는 펜티엄II-Celeron 333A컴퓨터로서 기계 시각 시스템의 주 제어장치이다. 영상 처리 보드로는 DT-2855보드(Data Translation사)로서 흑백 영상 처리를 할 수 있고, 8-bit A/D 변환기는 각 화소당  $2^8$  또는 256까지의 명암 값을 나타낼 수 있다. 영상 출력 장치는 12인치 크기의 흑백 모니터이며, 영상 입력 장치는 고체 촬상(CCD)형의 흑백 카메라(Panasonic사 모델 WV-BP100), 입력 전원은 120V AC60Hz, 촬영 면적은 4.8(H)×3.6(V)mm, 카메라에 부착된 렌즈는 초점거리가 12mm인 수동 조절 렌즈이다. 조명 장치로는 광섬유 조명 장치(Fiber Optic Illuminator, Right Tek System사 모델GLS-V100D)로서 0W~100W까지 밝기가 조절되는 것을 사용하였으며, 계란을 투과한 빛에 의한 영상을 얻기 위해 광원을 시료의 아래쪽에 설치하였다. 이때 계란의 밑면과 광원 사이의 거리는 7cm이었고 카메라 렌즈와 계란의 밑면까지의 거리는 22cm이었다. 그리고 획득되는 영상에서 계란과 배경과의 명암도 대비를 좋게 하기 위하여 시료판은 두꺼운 검은색 종이를 사용하였다. 또한 외부 광원의 유입을 방지하기 위하여 검은색 종이를 차광막을 설치하였다. 그림 1은 본 연구에서 사용된 영상 처리 시스템의 개략도이다.




Fig. 1. Schematic diagram of imaging system

## 다. 실험 방법

### 1) 영상처리

인공 신경망 학습의 입력값으로 사용하기 위해 정상란 30개, 파란 30개에 대한 영상의 명암도 값을 획득하였다. 입력된 영상의 명암도를 나타내는 히스토그램은 계란의 영상 부분과 배경의 영상으로 구분되는 두개의 봉우리 모양으로 나타난다. 배경과 계란 영상을 분리하기 위한 문턱값 자동 설정 방법으로는 히스토그램 클러스터링 방법, 최대 엔트로피 방법,

모멘트 보존 방법, 단순 영상 통계 방법, 배경 윈도우 확장법 등이 있는데, 본 연구에서는 조와 송(1994)이 연구한 방법 중, 소요 시간에 있어 가장 우수한 것으로 판명된 최대 엔트로피 방법을 사용하였다.

또한, 배경이 분리된 영상에 대해 결합 부분을 부각시키기 위한 방법으로 권(1996)에 의해 연구된 난각의 결합 부분을 부각시키는데 가장 우수한 성능을 보이는 것으로 나타난 소벨 연산자를 적용하였다. 소벨 연산자를 적용한 후의 영상에는 난각의 결합 부분뿐만 아니라 외곽선 까지도 결합 부분과 비슷하게 부각이 되며 비슷한 명암도 값을 갖는다. 따라서 외곽선 값이 히스토그램에 적용되지 않게 하기 위해 외곽선의 좌표 값을 구한 후 이를 제거하였다.

## 2) 인공신경망

최소한의 영상처리에 의해 획득한 계란 영상의 명암도 값을 인공 신경망 학습의 입력값으로 사용하였다. 신경망의 학습 방법은 학습 시간을 절약해 주고, 지역 최소 문제를 극복해주는 개선된 역전파(Improved back propagation) 알고리즘을 사용하였다.

신경망 학습시 입력되는 명암도의 개수, 은닉층 노드의 수, 허용 오차의 값을 변화시켜 가며 학습에 가장 적합한 조합을 찾고자 하였다. 신경망의 학습 속도를 향상시키기 위해서 256개의 명암도로 표현되는 영상의 히스토그램에서 서로 인접한 명암도의 값을 평균하는 방법에 의해 128개와 64개일 때로 입력되는 명암도의 개수를 변화시켰고, 은닉층 노드의 수는 10~50사이에서, 그리고 허용 오차의 범위는 0.01~0.00001사이의 값으로 변화시키며 학습을 하였다. 학습을 통해 얻은 신경망의 성능을 평가하기 위하여 새로운 정상란 60개, 파란 60개의 명암도 값을 적용하여 판별율과 판별시간을 조사하였다. 이때 정상란과 파란을 구별하기 위한 경계값을 0.5로 정하여, 경계값 이상이면 정상란으로, 경계값 보다 작으면 파란으로 판별하였다.

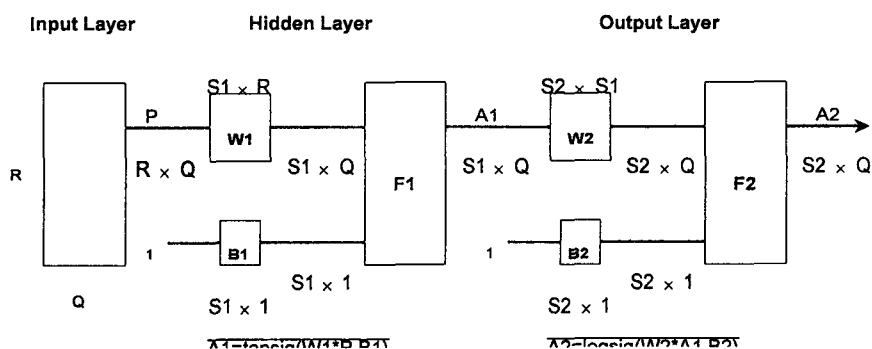


Fig. 2. Construction of 3-layer neural network

그림 2는 본 연구에서 사용된 3층 신경망 구조를 나타낸다. 그림 2에서  $Q$ 는 입력된 표본의 입력 벡터,  $R$ 은 입력에 사용된 영상의 명암도 개수,  $P$ 는 입력 벡터와 입력에 사용된 명

암도 행렬, W1과 B1은 은닉층의 연결 강도와 편차, W2와 B2는 출력층의 연결 강도와 편차, S1과 S2는 은닉층과 출력층의 노드의 수이다. 신경세포의 활성화 함수로서 은닉층의 활성화 함수 F1은 Tangent-Sigmoid 함수, 출력층의 활성화 함수 F2는 Log-Sigmoid 함수를 사용하였으며, A1은 은닉층의 출력값, A2는 출력층의 출력값이다.

### 3. 결과 및 고찰

#### 가. 영상의 이치화 및 영상의 향상

문턱값을 설정하여 계란 영상과 배경을 분리하기 전에는 배경 부분과 계란 영상 부분의 두개의 봉우리 형태로 히스토그램이 나타난다. 이때 자동으로 배경과 물체를 분리하기 위해 최대 엔트로피의 방법을 사용하여 문턱값을 설정한 후 배경을 분리하였다. 그림 3은 획득된 영상으로부터 배경을 분리해 낸 후의 영상을 나타낸다. 그림 4는 배경이 분리된 영상에 대해 소벨 연산자를 적용하여 결함 부분을 부각시킨 영상이고, 그림 5은 소벨 연산자를 적용한 후 생긴 계란의 외곽선을 제거한 영상이다.




Fig.3. Thresholding




Fig.4. Sobel mask



Fig.5. Removed contour

#### 나. 영상의 히스토그램

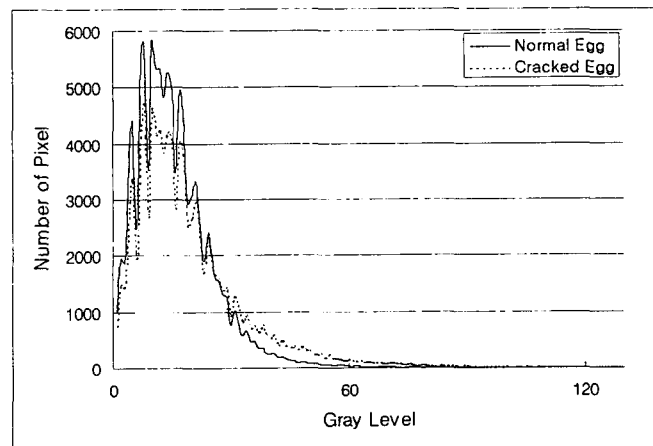


Fig. 6. Differences in histograms of normal and cracked egg

영상 이치화와 영상 향상을 거친 후 외곽선까지 제거된 그림 5의 영상을 이용하여 명암도 값에 대한 픽셀 수의 히스토그램을 생성하였다. 그림 6은 대표적인 정상란과 파란에서 얻은 영상의 히스토그램이다. 정상란과 파란을 비교했을 때 특정 영역에서 뚜렷한 차이를 보이지는 않았지만 파란의 경우 명암도 값이 높은 부분에서는 픽셀의 수가 정상란의 픽셀 수보다 대체적으로 많이 나타났고, 명암도 값이 낮은 부분에서는 픽셀의 수가 적게 나타나는 특징을 보였다.

#### 다. 인공 신경망에 의한 파란 검출

표 1은 신경망의 허용 오차 범위를  $10^{-5}$ 으로 고정한 상태에서 입력되는 명암도 값의 개수를 64개와 128개로 변화시키고, 은닉층 노드의 수를 변화시키며 학습을 한 후 판별 성능을 평가한 결과이다.

실험 결과, 입력 노드의 수가 64개 일 때는 은닉층 노드의 수가 50개일 때 판별 성공률이 87.5%로 가장 좋은 판별 성능을 보였으며, 입력 노드의 수를 128개로 했을 때는 은닉층 노드의 수가 10개일 때 판별율 87.5%로 가장 좋은 성공률을 나타냈다. 판별 결과를 볼 때, 입력 노드의 수와 은닉층 노드의 수를 변화시키는 것은 신경망의 판별 성능에 큰 영향을 미치지 않는 것으로 보여진다.

난각에는 대부분 반점이 포함되어 있는데 영상에서 이 반점들에 대한 명암도 값은 난각의 균열 부분의 명암도 값과 비슷한 값을 갖는다. 따라서 정상란 이면서 반점이 많은 계란과 파란이면서 반점이 적은 계란이 판별 성능에 많은 영향을 미치는 것으로 보인다. 따라서 이 반점에 의한 영향을 최소로 한다면 신경망의 판별 성능이 상당히 향상 될 것으로 생각된다.

Table 1. The performance of the neural network

Number of hidden node	Performance(%)	
	64 input node	128 input node
10	84.1	87.5
20	83.3	85.8
30	83.3	85.8
40	83.3	85.8
50	87.5	85

Table 2. The comparison of Elapsed processing time.

Type of Eggs	Number of Eggs tested	Elapsed Time (Average(sec))	
		previous	current
Crack	50	10.56	5.48
Normal	50	24.07	5.47
Total	100	17.32	5.475

표 2는 이전의 연구(권, 1996)와 비교하여 판별 시간의 향상 정도를 비교하기 위해 수행한 실험 결과로서 정상란과 파란 각각 50개에 대한 각각의 판별 시간을 평균치로 나타낸 것이다. CCD 카메라로부터 영상을 얻고 결과를 도출해 내기까지의 평균 시간은 파란과 정상란의 경우 각각 5.48초와 5.47초가 소요되었는데 이것은 권(1996)이 연구한 컴퓨터 시각에 영

상 처리만을 이용한 연구에서의 판별 시간인 10.56초와 24.07초 보다 향상된 것이다. 이러한 판별 소요시간은 더 나은 하드웨어 장치를 사용하거나 영상 처리 알고리즘의 최적화를 통해서 단축될 수 있을 것이다.

#### 4. 요약 및 결론

계란의 외부 품질을 평가하기 위해서 최소한의 영상 처리와 인공 신경망을 이용하였다. 연구 결과를 요약하면 다음과 같다.

가. 신경망 모델은 입력 노드의 수가 64개, 은닉층 노드가 50개 일 때, 또 입력 노드의 수가 128개, 은닉층 노드의 수가 10개 일 때 가장 좋은 성능을 보였으며 성능 시험에서 각각 87.5%의 성공률을 보였다. 그러나 신경망 내의 매개 변수를 변화시키는 것은 판별율에 큰 영향을 미치지 않았으며, 난각의 반점이 큰 영향을 미치는 것으로 판단된다.

나. 영상 처리에 신경망을 적용하여 판별한 경우, 판별 시간은 정상란과 파란이 각각 5.47초와 5.48초로 영상 처리만을 이용한 방법보다 판별 시간을 단축 할 수 있었다.

#### 5. 참고문헌

1. 권 양. 1996. 컴퓨터 시각에 의한 계란의 크랙 검출. 충북대학교 대학원 석사학위 논문
2. 조한근, 송현갑. 1994. 컴퓨터 시각에 의한 잎담배의 외형 및 색특징 추출. 한국농업기계학회지 19(4) : 380-396
3. Elster R. T. and J. W. Goodrum. 1991. Detection of cracks in eggs using machine vision. Trans. of the ASAE 34(1) : 307-312.
4. Patel V. C., R. W. McClendon and J. W. Goodrum. 1994. Crack detection in eggs using computer vision and neural networks. AI application 8(2) : 21-31.
5. Patel V. C., R. W. McClendon and J. W. Goodrum. 1996. Detection of blood spots and dirt stains in eggs using computer vision and neural networks. Trans. of the ASAE 12(2) : 253-258.
6. Worley J. W. and J. W. Goodrum. 1995. Strobe versus incandescent lighting for egg crack detection using machine vision. Trans. of the ASAE 11(4) : 549-554.