

다해상도 주파수 분할과 Back-Propagation을 이용한 홍채인식

박경우[†]

Iris Recognition System using Multi-Resolution Frequency Analysis and Back-Propagation

Kyung-Woo Park[†]

Abstract

본 논문에서는 기존의 개인 식별 방법의 한계를 해결하는 대안으로 떠오르고 있는 생체인식 기술 중 인식률이 뛰어나고 신뢰성 있는 홍채인식 시스템을 구현하고자 한다. 구현을 위하여 신호처리 분야에서 주로 사용되는 wavelet변환으로 계수 특징 값 추출을 하였으며, 인식률을 알아보기 위하여 신경망 기법을 이용하고자 한다. 그러나 신경망 기법에서 주로 사용되는 비선형 최적화기법인 Scale Conjugate Gradient는 최적화 문제점을 해결하기에는 수렴속도가 느리기 때문에 적합하지 않다. 따라서 본 논문에서는 기존 Scale Conjugate Gradient를 보완한 Levenberg-Marquardt Back-Propagation을 홍채인식에 적용하여 구현함으로써 인식율을 높이고자 한다. 적용한 알고리즘 구현으로 해의 수렴정도, 변수 벡터의 변화정도에 따라 크기를 적절히 변화시킴으로써 수렴속도를 개선하고, 효율성과 안정성을 동시에 얻을 수 있었다.

Key words : Levenberg-Marquardt Back-Propagation, Multi-Resolution Frequency Analysis, Conjugate Gradient

1. 서 론

인터넷의 발달로 생체인식 시스템은 그 기능이 다양화되고 높은 인식률을 갖는 시스템의 발달로 위조가 불가능하고 신뢰성이 높아, 현금 지급기, 과학 수사 등에 활용되고 있다. 이러한 높은 신뢰성을 요구하는 분야에 최근들어 생물학적 데이터를 이용하는 생체 감지 분야가 매우 활성화되고 있다. 지금까지는 대부분의 경우 패스워드를 이용한 사용자 인증방법 등을 이용하고 있으나, 타인에게 노출되기 쉬운 정보를

보호하기 위한 혹은 개인을 안전하게 인증하기 위한 좋은 수단이 될 수 없다. 이러한 단점을 극복하기 위해 개인의 신체적 또는 형태학적 특징에 따라 사람의 신원을 확인하는 생체인식(Biometrics)이 활발하게 연구되고 있다.

이에 따라 신원 확인 및 인증을 위한 많은 기술들이 소개되고 있으나, 각각 그 취약점을 가지고 있는 것이 현실이다. 따라서, 인간의 생체 자체를 인식하는 기술

이 강력한 보안 및 인증 분야의 해결책으로 제시되고 있다. 생체인식은 개인의 신체적·생물학적·행동적 기반으로 개인을 인식하거나 검증하기 위한 자동화된 방법으로 신뢰도가 높고 정확성을 지닌 개인식별 방법이라 할 수 있다^[1-3].

생체인식에 의한 개인 식별방법이 지금의 패스워드나 ID 카드에 비하여 갖는 장점은 매우 많지만, 생체인식은 실존에 의한 인증이라는 점이다. 즉, 패스워드나 ID 카드의 경우는 분실이나 대여 등에 의한 도용의 우려가 있으나 생체인식의 경우 해당자가 실제로 있어야 본인 여부가 확인된다. 생체인식을 통한 개인 식별은 새로이 등장한 개념이 아니라 오래 전부터 사용되어왔다. 이러한 개인 식별 시스템은 보다 낮은 비용과 높은 신뢰도를 갖게 하려는 시도가 계속되고 있다. 특히 이러한 연구의 기반이 되는 Back-propagation은 다층 퍼셉트론에 관련된 가중치 및 임계값에 대한 해를 반복해서 구하는 일반적인 방법을 사용한다. 작은 학습률이 사용되는 경우에 아주 안정적인 최소 강하법에 속하지만, 수렴이 느린 단점을 가지고 있다. Back-propagation의 성능을 높이기 위한 방법으로 moment 항의 추가, 가변적인 학습률의 적용 등이 고려될 수 있다. 가중치 및 임계값의 해를 얻기 위한 다른 방법은 매우 복

광주보건대학 병원전산과(Dept. of Hospital Information Management, Gwangju Health College)

[†]Corresponding author: kwpark@ghc.ac.kr

(Received : August 12, 2008, Accepted : December 6, 2008)

잡한 알고리즘을 적용하고 있는데, 이들 대부분은 뉴턴 방법을 근거로 하고 있지만, 실제 적용에 있어서는 뉴턴 방법과 최소 강하법의 절충안을 사용하고 있으며 Scale Conjugate Gradient(SCG)를 많이 주로 이용한다. 하지만 비선형 최적화기법인 Conjugate Gradient는 최적화 문제점을 해결하기에 수렴속도가 느려 적합하지 않다. 따라서 본 논문에서 Levenberg-Marquardt Back-Propagation을 적용한 홍채인식 시스템에서는 해의 수렴정도, 변수 벡터의 변화정도에 따라 적절히 크기를 변화시킴으로써 학습 수렴속도가 빨라지며 효율성과 안정성을 동시에 얻을 수 있다.

본 논문의 구성은 다음과 같다. 2장에서는 기존의 관련연구, 3장에서는 제안된 홍채인식 시스템의 구현 기법과 성능분석, 4장에서는 본 시스템의 구현 및 실험 결과, 5장에서는 결론 및 향후 연구과제에 대해서 기술하고자 한다.

2. 홍채영상 인식 적용방법

2.1. 홍채인식 시스템

홍채인식 시스템은 홍채영상을 획득하기 위한 영상 획득부와 획득된 영상을 이용해 식별하는 인식부분으로 나눌 수 있다. 홍채영상 획득부는 홍채영역을 분리하는 홍채영역 추출, 홍채영역에 나타나는 무늬패턴의 특징을 추출하는 홍채특징 추출, 홍채특징을 부호화 하는 홍채코드 생성, 두 홍채코드의 유사도를 비교하기 위한 등록 및 인식 등의 기능을 수행한다. 일반적인 홍채인식 시스템의 작동원리는 시스템 중앙렌즈에서 5-30 cm 정도 떨어져 사용자의 눈을 카메라에 갖다 대면 자동으로 홍채를 흑백 디지털 이미지로 저장하고, 사용자 홍채의 고유한 패턴이 디지털 신호화되어 홍채 코드가 형성되고, 형성된 홍채코드는 데이터베이스에 등록되며 이후 2-3초 내에 이 코드로 신원을 확인하게 된다^[4-6].

2.2. wavelet 변환

Wavelet 변환은 다해상도 시스템으로 입력된 신호의 샘플 주파수를 다른 형태의 샘플 주파수로 변환시켜 다양한 주파수 대역에서 신호를 처리할 수 있는 장점을 가지고 있다. 입력 신호의 샘플링 주파수를 2down-sampling으로 분할할 수 있으며, Wavelet 함수와 스케일링 함수를 입력신호와 곱하여 고주파와 저주파로 주파수 대역을 나누어 신호를 분석하는데 매우 유용하다. Wavelet 함수의 주파수 분할특성은 모 wavelet (mother wavelet)의 종류에 따라 달라진다.

Wavelet 변환을 위한 공간 $L^2(R)$ 은 임의의 함수에 대하여

$$\int_{-\infty}^{+\infty} |f(x)|^2 dx < \infty \tag{1}$$

식(1)을 만족한다. 푸리에 변환을 기저 함수 집합인 $\{e^{imx}\}$ 의 선형조합으로 표현한다면, Wavelet 변환은 다음 두 가지 조건을 만족하는 기저 함수(wavelet 함수)의 선형조합이라고 할 수 있다.

$$\int_{-\infty}^{+\infty} \psi(x) dx = 0 \tag{2}$$

$$\lim_{x \rightarrow \infty} |\psi(x)| = 0 \tag{3}$$

Wavelet 변환은 Wavelet 함수 $\psi(x)$ 로부터 스케일링 (scaling)요소 'a'와 천이 (translation)요소 'd'로 구분하여 표현할 수 있다.

$$\psi(x)_{a,d} = \frac{1}{\sqrt{a}} \psi\left(\frac{x-d}{a}\right) \tag{4}$$

Wavelet과 같은 다해상도 신호해석 기법은 $L^2(R)$ 공간을 서로 다른 해상도를 갖는 여러 개의 부공간(sub-space)인 $V_j; j \in Z$ 로 분해한다. 이 때 Z 는 정수이며, 이러한 V_j 를 생성하는 함수 $\Phi \in L^2$ 를 스케일링 함수라 하고, Wavelet 변환의 기저함수인 ψ_{ad} 가 형성되는 공간 W_j 를 V_{j-1} 에서 V_j 의 차공간(complement space)이라 한다.

이산 Wavelet 변환은 스케일링 요소 'a'와, 천이 요소 'd'를 이산화 함으로써 얻어진다.

$$\Psi(n) = \sum_k h(k)\Phi(2n-k) \tag{5}$$

$$\Phi(n) = \sum_k g(k)\Phi(2n-k) \tag{6}$$

(ψ : wavelet 함수, Φ : 스케일링 함수)

식 (5), (6)에서 $h(k)$ 는 Wavelet 함수의 계수로서 고역통과 필터의 역할을 하며, $g(k)$ 는 스케일링 함수의 계수로서 저역통과 필터의 계수 역할을 한다. 이산신호 $x(n)$ 은 레벨 $j=1$ 일 때 고주파 성분의 신호인 과으로 구분되어 표현된다. 즉, 입력 신호 $x(n)$ 은

$$x(n) = D_2^1[x(n)] + A_2^1[x(n)] \tag{7}$$

식(7)로 나타낼 수 있으며, 이것을 일반화된 식으로 표현하면 식 (8), (9)와 같다.

$$D_{2^j}[x(n)] = \sum_{k=0}^{2^j-1} d_{2^j}(k)\psi_{2^j}(n-2^j k) \tag{8}$$

$$A_{2^j}[x(n)] = \sum_{k=0}^{2^j-1} a_{2^j}(k)\Phi_{2^j}(n-2^j k) \tag{9}$$

이때 는 레벨 2^j 가 감소함에 따라 샘플수가 2 down-

sampling 됨을 나타낸다. 식 (8)은 detail 신호로써 식 (5)의 Wavelet 함수와 친이 요소인 'd'에 의해서 입력 신호의 고주파 성분을 레벨 j에 따라 분할하며 식 (9)는 approximate 신호로써 식 (6)의 스케일 함수와 스케일 요소인 'a'에 의해서 입력 신호의 저주파 성분을 레벨 j에 따라 분할한다. 또한 식 (8), (9)를 이용하여 Wavelet 변환을 할 때 레벨의 감소(j=-1, -2, ..., k)에 따라 신호의 주파수 스펙트럼이 <그림 1>에서처럼 2 단계 저주파와 고주파로 분할웨이브렛 변환 구조를 갖는다.^[7-10]

2.3. BPN (back propagation neural network)

다층 퍼셉트론의 학습방법인 오류 역전파 학습 알고리즘은 교사신호에 의한 학습 방법이다. 학습은 실제 출력을 얻는 순방향 부분과 실제 출력과 교사신호의 오차를 구하여 역전파시켜 델타규칙으로 가중치를 수정하는 역전파 부분으로 이루어진다. 델타규칙의 기본은 현재의 가중치로 계산된 실제 출력과 원하는 출력간의 오차를 감소시키는 방향으로 가중치를 조정하는 것이다. 그러나 신경회로망이 다층으로 구성되었을 때, 출력 뉴런과 직접 연결되지 않은 가중치는 어떻게 조정할 것인가 하는 문제가 발생하게 된다. 오류 역전파 학습 알고리즘은 이러한 문제를 해결하기 위하여 신경회로망 내에 존재하는 모든 뉴런과 가중치에 책임을 분담시키는 방법을 택하고 있다. 실제 출력과 원하는




그림 1. 2-레벨 웨이브렛 변환




그림 2. Back-Propagation Algorithm

출력간의 오차에 대한 책임은 출력 뉴런의 오차를 그에 연결된 전위 뉴런으로 역전파시킴으로써 책임을 분담시키며, 이러한 역전파 과정을 입력 뉴런에 이를 때까지 반복 수행한다^[12,13].

(그림 2)는 back propagation neural network 알고리즘을 나타낸 것이다.

역전파 신경망 알고리즘에 사용되는 오류함수는 식 (10)과 같다.

$$E = \frac{1}{P \cdot N} \sum_{m=1}^P \sum_{i=1}^{N_m} [d_{s,i} - y_{s,i}^M]^2 \quad \text{식(10)}$$

$d_{s,i}$, $y_{s,i}^M$ 는 각각 s번째 학습 데이터에 대한 i번째 뉴런의 원하는 출력 값과 실제 출력 값이며, N_m 은 출력 뉴런의 개수이다. <그림 3>은 백프로퍼게이션 학습 알고리즘의 학습과정 흐름도를 나타내고 있다. 그리고, 식(10)의 오류 함수 값을 한계값 이하로 만들기 위한 학습 알고리즘은 다음과 같다^[14].

STEP 1 네트워크의 상태를 결정하는 연결강도 $\{W_{ji}\}$, $\{V_{kj}\}$ 와 offset $\{\theta_j\}$, $\{\gamma_k\}$ 를 각각 임의의 랜덤 값으로 초기화한다.

STEP 2 최초의 패턴을 학습 패턴으로 한다.




그림 3. Back-Propagation 학습 알고리즘의 학습과정 흐름도

STEP 3 학습 패턴의 값을 입력 노드의 (I_i)출력 에 넣고, 입력 층에서 은닉 층에의 연결강도 $\{W_{ji}\}$ 와 은닉층 노드 j 의 offset θ_j 를 이용해서 은닉층 j 노드의 입력 U_j 를 구하고 입력 U_j 와 시그모이드 함수에 의해 은닉층 노드 j 의 출력 H_j 를 구한다.

$$U_j = \sum_i W_{ji} \cdot I_i + \theta_j$$

$$H_j = f(U_j)$$

STEP 4 은닉층 노드의 $\{H_j\}$ 출력과, 은닉 층에서 출력 층으로의 $\{V_{kj}\}$ 연결강도와 출력층 노드 k 로의 입력를 구하고 입력 S_k 와 시그모이드 함수에 의해 출력층 노드 k 의 O_k 를 구한다.

$$S_k = \sum_j V_{kj} \cdot H_j$$

$$O_k = f(S_k)$$

STEP 5 학습패턴의 교사신호 T_k 와 출력층의 출력 O_k 와의 차로부터 출력층 노드 k 에 연결되는 연결강도와 은닉층 노드 k 의 offset에 대한 오차 δ_k 를 구한다.

$$\delta_k = (O_k - T_k) \cdot O_k \cdot (1 - O_k)$$

STEP 6 오차 δ_k 와 은닉층에서 출력층으로의 연결강도 $\{V_{kj}\}$ 와 은닉층의 출력 H_j 로부터, 은닉층 노드 j 에 연결되는 연결강도와 은닉층 노드 offset에 대한 오차 σ_j 를 구한다.

$$\sigma_j = \sum_k \delta_k \cdot V_{kj} \cdot H_j \cdot (1 - H_j)$$

STEP 7 5단계에서 구한 출력층 노드 k 에서의 오차 δ_k 와 은닉층 노드 j 의 출력 H_j 와 정수 α 와의 곱을 가산하는 것으로 은닉층 노드 j 에서 출력층 노드 k 에 연결되는 노드 k 의 옵세트 γ_k 를 수정한다.

$$V_{kj} = V_{kj} + \alpha \cdot \delta_k \cdot H_j$$

$$\gamma_k = \gamma_k + \beta \cdot \delta_k$$

STEP 8 은닉층 노드 j 에서의 오차 σ_j 와, 입력층 노드 i 의 출력 I_i 와 정수 α 와의 곱을 가산하는 것으로 입력층 노드 i 에서 은닉층 노드 j 에 연결되는 연결강도 W_{ji} 를 수정한다. 또 오차 σ_j 와 정수 β 와의 곱을 가산하는 것으로 은닉층 유닛 j 의 옵세트 θ_j 를 수정한다.

$$W_{ji} = W_{ji} + \alpha \cdot \sigma_j \cdot I_i$$

$$\theta_j = \theta_j + \beta \cdot \sigma_j$$

STEP 9 다음의 패턴을 학습 패턴으로 한다.

STEP 10 학습 패턴이 종료할 때까지 STEP 3으로 되돌아간다.

STEP 11 학습의 반복 횟수를 갱신한다.

STEP 12 학습이 반복 횟수가 제한 횟수 이하이면 STEP 2로 되돌아간다.

STEP 13 학습을 종료한다.

2.4. Levenberg-Marquardt method

비선형 문제를 해결하는 반복적 최소자승 기법의 하나로써 행렬의 주 대각성분에 라그랑지 곱수를 더해줌으로써, 해의 발산을 막고 안정된 해를 구할 수 있다. 모델변수에 대한 모델반응의 Jacobian 행렬을 Z , 측정값과 모델반응의 차이벡터를 g 라 할 때, Marquardt에서의 매 반복 시 변수변화 벡터는 식(11)로 주어진다.

$$\delta = (Z^T Z + \beta I)^{-1} Z^T g \quad \text{식(11)}$$

여기서 β 는 라그랑지 곱수, I 는 단위행렬이다. 만약 β 가 0이면 이는 뉴턴랩슨법(Newton-Raphson method)과 동일해지며, 해의 계산속도는 매우 빠르나 해의 발산 등 불안정성의 문제를 안고 있다. 반면 무한대일 경우 최대경사법과 동일해지며, 수렴성은 좋으나 수렴 속도가 매우 느려진다. 따라서 Levenberg-Marquardt에서는 해의 수렴정도, 즉 변수 벡터의 변화정도에 따라 적절히 크기를 변화시킴으로써 효율성과 안정성을 동시에 얻을 수 있다^[15].

Back-propagation은 다층 퍼셉트론에 관련된 가중치 및 임계값에 관한 해를 반복적으로 구하는 일반적인 방법을 나타낸다. 작은 학습률이 사용되는 경우에 아주 안정적인 최소 강하법에 속하지만, 수렴이 느린 단점을 가지고 있다. Back-propagation의 성능을 높이기 위한 방법으로 moment 항의 추가, 가변적인 학습률의 적용 등이 고려될 수 있다. 가중치 및 임계값의 해를 얻기 위한 다른 방법은 아주 복잡한 알고리즘을 포함하고 있다. 이들 방법의 대부분은 뉴턴 방법을 근거로 하고 있지만, 실제 적용에 있어서는 뉴턴 방법과 최속 강하법의 절충안인 Scale Conjugate Gradient (SCG) 방법을 많이 사용하고 있다^[16]. 하지만 비선형 최적화기법인 Conjugate Gradient으로는 최적화 문제점을 해결하기에는 수렴속도가 느리기 때문에 적합하지 않았다. 따라서 본 논문에서는 이차 근사 방법인 Levenberg-Marquardt Back-Propagation을 홍채인식 시스템에 적용하여 해의 수렴정도, 변수 벡터의 변화정도에 따라 적절

히 크기를 변화시킴으로써 효율성과 안정성을 동시에 얻을 수 있다.

3. 제안한 홍채인식 구현 기법과 성능분석

3.1. 특징벡터 생성

홍채인식을 위한 영상인식의 전처리를 크게 두가지의 단계로 제안한다. 먼저 전처리에 앞서 직각 좌표계의 영상을 극좌표계로 변환한다. 이러한 좌표계의 변환은 홍채영상이 내부로부터 증가되는 반지름에 따른 원주상에 빗살모양, 일록집, 또는 동공주위를 둘러싼 코로나 모양의 특징이 극좌표계상의 반지름과 중심각의 크기로 표현이 더욱 용이하기 때문이다.

이러한 좌표계의 변환이후에 첫 번째 전처리로 눈 영상에서 눈동자를 가리는 속눈썹의 제거와 조명으로 인해 생기는 반사 영상을 제거하고, 둘째로 에지검출 방법을 이용한 눈 영상에서의 동공 부위와 홍채의 분리 수행을 하게 된다. 극 좌표계로의 변환을 행한 후 눈동자를 가리는 속눈썹의 제거와 눈꺼풀이 눈동자를 덮은 정도에 대한 정보를 추출, 현 영상으로의 인식이 무리가 없는가를 점검한다. 현재 영상으로 인식이 불가능한가에 대한 점검 및 잡영을 없앤 후에는 동공을 추출한다. 이때 홍채의 동공에 대한 지식을 사용하는데 예외 상황이 발생하면 홍채에 이상이 있는 경우로 간주한다. 위의 전처리를 행하고 난 후 Haar 웨이블릿 변환 기반 특징벡터 추출을 다시 한번 행한다.

3.2. Haar 웨이블릿 변환 기반 특징벡터 추출

웨이블릿 변환을 이용한 특징 파라미터 추출 과정은 먼저 해상도가 256×256인 두 개의 입력 영상 신호를 극좌표계와 에지분포를 이용하여 특징영역으로 분리한 다음 웨이블릿 변환을 수행하고 계수 행렬을 구한다. 본 논문에서는 영상의 데이터 양으로 인한 시간 지연을 고려해 4-레벨 웨이블릿 변환계수를 사용하였다.

본 논문에서 사용한 홍채영상의 특징영역에 대해 4-레벨 웨이블릿 변환을 수행하면 계수행렬 $wA8, wH8, wV8$ 그리고 $wD8$ 을 구할 수 있다. 여기서 $wA8$ 은 4-레벨 저주파 계수 행렬, $wH8$ 은 수평 고주파 계수행렬, $wV8$ 은 수직고주파 계수 행렬 그리고 $wD8$ 은 대각 고주파 계수 행렬인데 이들의 분포특성을 분석한 후 특징벡터를 추출한다. 다음으로 4개의 계수 행렬에 대해 절대값을 구하고 $wA8, wH8, wV8, wD8$ 에 대해 각각 특징벡터를 추출한다. <그림 4>는 본 논문의 실험자료로 사용된 원 영상 샘플중의 하나이며 <그림 5>는 4-레벨 웨이블릿 변환 후의 계수행렬 $wA8, wH8, wV8, wD8$ 의 영상을




그림 4. 본 논문에서 사용된 원 영상




그림 5. 4-레벨 웨이블릿 변환 후의 홍채영상

나타낸 것으로 이들 4개의 계수 행렬에 원 영상의 정보가 집중되어있는 결과를 보여주고 있다. 특징추출은 원 영상에 대해 10개의 학습 샘플을 선정 한 후 이를 4-레벨 웨이블릿 변환하여 $wA8, wH8, wV8, wD8$ 등을 각각 구했다. 다음으로 이들 계수행렬의 데이터 분포를 분석한 후 특징벡터를 추출하였고 이를 정규화하여 신경망의 입력 벡터로 사용한다. <그림 6,7,8,9>는 원 영상에 대한 샘플영상의 특징분포를 나타낸 것이다.

3.3. 제안된 Levenberg-Marquardt Function Back-Propagation

기존에 연구된 Back-propagation은 다층 퍼셉트론에 관련된 가중치 및 임계값에 관한 해를 반복적으로 구하는 일반적인 방법을 사용하였다. 이 방법은 작은 학

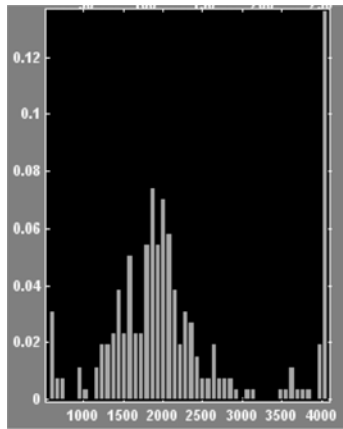


그림 6. wA8의 분포 특성

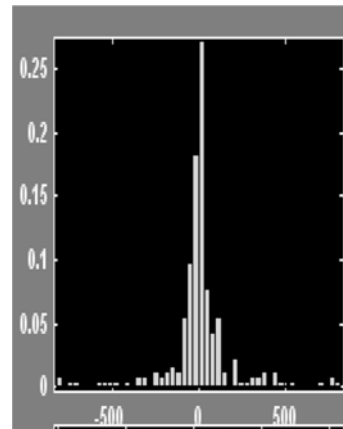


그림 8. wV8의 분포 특성




그림 7. wH8의 분포 특성




그림 9. wD8의 분포 특성

습률이 사용되는 경우에는 안정적인 최소 강하법에 속 하지만, 수렴이 느린 단점을 가지고 있으며, 특히 비선형 최적화 기법인 Scale Conjugate Gradient 방법으로는 최적화 문제점을 해결하기에 수렴속도가 느려 적합하지 않았다. 따라서 본 논문에서는 Levenberg-Marquardt을 적용한 흥채인식 식별 시스템에서는 해의 수렴정도, 변수 벡터의 변화정도에 따라 적절히 크기를 변화시킴으로써 학습 수렴속도가 빨라지며 효율성과 안정성을 동시에 얻을 수 있다.

다음은 Levenberg-Marquardt function 알고리즘이다.

$$obj\ ft\ E(a) = \sum_{i=1}^n f_i^2(a)$$

Algorithm

1. $\lambda \leftarrow 10^{-3}$; $a(0) = a_0$
2. Compute $E(a(k))$;
3. Compute Jacobian J_k ;

4. $a(k+1) \leftarrow a(k) - \lambda^k (J_k^T J_k + \lambda I)^{-1} J_k^T f(a(k))$;
5. Compute $E(a(k+1))$;
6. if $E(a(k+1)) > E(a(k))$ then $\lambda \leftarrow 10 \times \lambda$ and goto 4;
7. if $E(a(k+1)) > E(a(k)) < 10^{-4}$ then stop
if $E(a(k)) - E(a(k+1)) < 10^{-3}$ (4×consecutively) then stop;
8. $\lambda \leftarrow 0.1 \times \lambda$
9. $a(k) \leftarrow a(k+1)$; goto 2;

3.4. 흥채인식을 위한 신경망

정규화된 특징벡터를 이용한 신경망 학습을 위하여 학습에 사용될 신경망을 설계해야한다. 신경망 설계시 입력층 노드와 출력층 노드의 수는 학습할 패턴의 형태에 따라 미리 정해지지만 은닉층 개수와 노드 수는 학습 정도에 따라 임의로 설정할 수 있다. 본 논문에서 제안한 흥채인식 시스템에서는 웨이블릿을 통해서 구한 계수 값 16개를 신경망의 입력노드로 한다. 8개의

출력노드, 30개의 은닉노드를 사용하였으며, 2개의 은닉층을 지닌 16×30×30×8의 신경망을 사용한다. 입력노드와 은닉노드, 은닉노드와 출력노드 사이의 활성화 함수는 양극성 시그모이드(Sigmoid) 함수를 사용하였고, 각 층간의 노드는 완전 연결시켰다. <그림 10>은 실험에 사용된 16×30×30×8 신경망 구조이다. 신경망을 이용한 인식단계에서는 인식률을 측정하기 위하여 학습 반복횟수를 500회로 제한하였고, 학습 오차 값이 0.01 이하인 경우 학습을 종료하게 하였다.

4. 구현 및 실험 결과

4.1. 신경망 학습

본 논문의 실험에서는 해상도가 256×256인 홍채영상을 4-레벨 웨이블릿 변환을 이용해 구한 계수값 16개를 신경망의 입력 패턴으로 사용하였으며 실험에 사용된 영상은 총 10명에 대하여 각각 20개의 영상을 사용한다.

획득된 영상 중 10개의 영상은 신경망 학습을 위한 학습데이터로 사용하고, 나머지 10개의 영상은 학습된 신경망의 인식률을 측정하기 위한 실험 데이터로 사용하였다. 본 홍채영상 인식에서는 16개의 입력노드와 8개의 출력노드, 그리고 2배수 정도인 30개의 노드를 사용하였으며 2개의 은닉층을 지닌 16×30×30×8의 신경망을 사용한다. 설계된 신경망을 이용하여 학습방법은 일반적인 신경망 학습 알고리즘인 Scale Conjugate Gradient 학습 알고리즘과 본 논문에서 적용하여 제안한 Levenberg-Marquardt BP 알고리즘을 사용하였다. 학습패턴은 4-레벨 웨이블릿 변환을 통하여 얻어낸 계수 특징벡터로 총 10명에 대한 10개의 홍채영상을 사용하여 전체 학습패턴의 개수는 100개이다. SCG 학습방법과 LM 학습 방법은 모두 학습률 0.4, 모멘텀 0.7 학습오차 0.01을 사용하여 학습의 시간, 인식률을 실험




그림 10. 본 논문에서 사용된 신경망 구조

하였다. 반복 학습 회수는 500회를 지정하여 학습 오차 값이 지정된 학습오차 0.01 이하로 감소하는 경우 학습이 완료된 것으로 간주하여 학습을 종료한다. 안정화 학습 후 완료된 신경망은 홍채인식에 대한 신경망으로 사용된다. 신경망 학습의 특성상 항상 동일한 학습범위 내에서 학습이 완료되지 않으며 최악의 경우 학습이 이루어지지 않은 상황이 발생 할 수도 있다. 본 논문에서는 총 10회의 LM, SCG 학습을 통하여 두 학습방법의 평균적인 학습 수렴속도를 나타내었다. 총 10회의 학습을 수행했을 때 LM 학습 방법은 9회의 학습이 성공하였고 학습이 이루어지지 않는 경우를 제외한 학습 횟수는 평균 37.24회에서 오차범위 이내에서 수렴되어 학습이 종료되었으며, SCG 학습의 경우 학습 성공 횟수가 7회였고 평균 524.72회의 반복 학습 후에 학습오차가 오차범위 이내에서 수렴되어 학습이 종료되었다. 따라서 학습 성공을 대상으로 한 평균 반복 학습의 회수를 비교하였을 때 LM 학습 알고리즘이 본 실험에서 수행한 홍채 학습패턴에 적합한 학습 방법이라고 볼 수 있다. <그림 11>과 <그림 12>는 두 신경망 학습을 수행 한 후의 평균 수렴 속도 결과를 비교한 것이다.

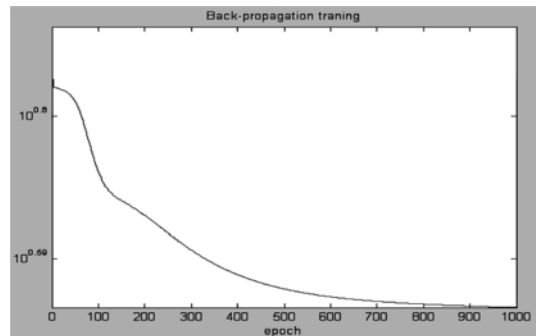


그림 11. SCG 학습 알고리즘 수렴 결과

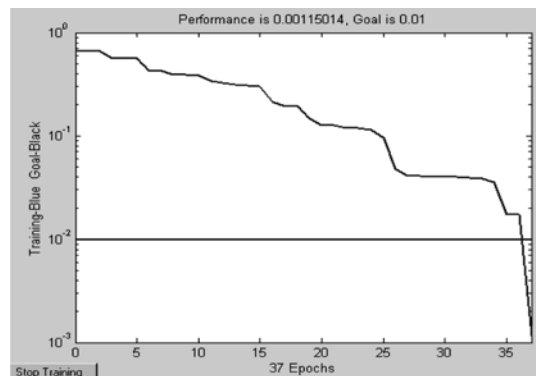


그림 12. 본 논문에서 제안한 LM 학습 알고리즘 수렴 결과




그림 13. 평균 MSE 테스트 수렴 결과

표 1. LMBP와 SCGBP 비교

Performance	LMBP	SCGBP
MSE	0.03792	0.03877
NMSE	0.15267	0.15610
MAE	0.08893	0.09072
인식률	0.9212(92%)	0.8910(89%)

테스트 패턴에 대한 홍채인식률은 학습이 완료된 신경망에 대하여 학습에 참여한 패턴을 제외한 나머지 10명의 100개의 홍채영상에 대하여 인식 여부를 수행하였다. 테스트 패턴의 경우 LM신경망으로 인식을 수행한 경우 총 100개의 패턴 중 92개의 영상이 인식에 성공하였고, SCG신경망의 경우 89개의 영상을 정확히 인식하였다. 전체 평균 인식률은 각각 91%와 89%의 인식률을 보였다. <그림 13>은 10명의 테스트 수렴결과를 평균 MSE로 나타내보았다. LM과 SCG신경망 결과를 MSE, NMSE (normalized mean squared error), MAE (mean absolute error)로 비교해보았다. 결과는 <표 1>과 같다.

<표 1>의 결과와 같이 본 논문에서 적용한 LM 신경망이 테스트 패턴에 대해 적합한 학습이라고 볼 수 있다. 하지만 인식이 되지 않은 영상에 대해서는 조명에 있는 영상, 눈꺼풀이 천천리에서 완전히 제거되지 않은 영상이나 홍채에 병변이 있는 경우에는 정확한 홍채영상에서 오 인식을 나타내었다.

5. 결 론

본 논문에서 적용한 Levenberg-Marquardt Back-Propagation을 이용하여 홍채인식의 수렴속도를 빠르게 하는 신경망을 사용하였다. 설계된 신경망 알고리즘은 LMBP 알고리즘과 SCGBP 알고리즘을 통해 학습시켰다. 10명에 대한 10개의 학습 패턴 수는 100개이고

학습률 0.4, 모멘텀 0.7 학습오차 0.01을 사용하였다. 학습 반복횟수 500회를 지정하여 지정된 학습 오차값이 0.01이하로 감소하는 경우 학습이 완료된 것으로 간주하였다. 학습회수를 측정할 결과 LMBP 알고리즘이 홍채인식 학습 패턴에 더 적합한 것을 알았고 빠른 수행속도와 학습패턴은 90%의 인식률을 나타내었고 테스트 패턴도 92%의 인식률을 보였다. 인식되지 못한 영상은 홍채에 병변이 발견된 경우, 조명이 제거되지 않은 영상, 눈꺼풀이 내려와 있는 영상에서는 인식률이 떨어지는 것을 확인했다. 향후 연구과제로는 황달 등의 신체적 질병에도 이상을 가져올 수 있는 요소를 제거 고있기 때문에 이러한 가공된 특징을 분석하여 고유한 홍채코드를 만들어 직접 사용할 수 있는 특징을 찾아내어 신뢰도를 높이기 위한 연구가 수행되어져야 할 것으로 사료된다.

참고문헌

- [1] A. K. Jain, Ruud Bolle and Sharath Pankanti, "Biometrics Personal Identification in Networked Society", Kluwer Academic Publishers, 1999.
- [2] Despina Polemi, "Biometric Techniques: Review and Evaluation of Biometric Techniques for Identification and Authentication, Including an Appraisal of the Ares where They Are Most Application", Institute of Communication and Computer Systems National Technical University of Athens, 1999.
- [3] Gray Roethenbaugh, "The Biometrics Industry", ICOSA, Inc., 1999.
- [4] Richard P. Wildes, "Iris Recognition: An Emerging Biometric Technology", Proceeding of the IEEE, Vol.85, No.9, pp.1348-1363, Sep.1997.
- [5] R. P. Wildes et al., "A System for Automated Iris Recognition", IEEE pp.121-128, 1994.
- [6] N. Chacko, C. Myssen, and R. Singhal, "A Study in Iris Recognition", pp.18-551 Final Project, 1999.
- [7] N. J. Fliege, *Multirate Digital Signal processing*, John Wiley & Sons, INC., 1994
- [8] Ail N. Akansu and Richard A. Haddad, "Multiresolution Signal Decomposition," ACADEMIC PRESS, INC., 1992
- [9] I. Daubechies. *The wavelet transform, time frequency localization and signal analysis*. IEEE Trans. Inform, September 1990.
- [10] M. Vetterli and C. Herley. *Wavelets and filterbanks: Theory and design*. IEEE Tran. Signal Proc., September 1992.
- [11] D. E. Rumelhart, G. E. Hilton, R. J. Williams, "Learning Internal Representation by Error Back-

- propagation”, in *Parallel Distributed Processing*, Vol.1, pp.318-362, 1986.
- [12] D. E. Rumelhart, R. Durbin, R. Golden, and Y. Chauvin, “Backpropagation: The Basic theory”, in *Backpropagation-theory, Architectures, and Application*, Y. Chauvin and D. E. Rumelhart (Eds.), pp.1-34, Lawrence Erlbaum Associates, Publishers, 1995.
- [13] P. D. Wasserman, *Neural Computing: Theory and Price*, New York, Van Nostrand Reinhold, 1989.
- [14] D. E. Rumelhart, G. E. Hilton, R. J. Williams, “Learning Representation by Back-Propagation Errors”, *Nature*, Vol. 3239, pp.533-536, Oct. 1986.
- [15] <http://falcon.postech.ac.kr/ipawb/demo/kiss98cs4/html/sld008.html>
- [16] 이현엽, 문경일, “MatLAB을 이용한 퍼지-뉴로”, 1999.12.