

웨이블릿 변환과 LMBP를 이용한 대뇌출혈성 병변 인식 시스템

정유정^o, 정채영
조선대학교 전산통계학과
narimono@orgio.net, cyjung@chosun.ac.kr

Intracranial Hemorrhagic Lesion Feature Extraction System Of Using Wavelet Transform and LMBP

Yu-Jeong Jeong^o, Chai-Yeoung Jung
Dept. Computer Science & Statistics, Chosun University

요 약

본 논문에서는 의료영상 인식 기술 중 인식이 뛰어나고 신뢰성 있는 대뇌출혈성 병변인식 시스템을 구현하기 위하여 신호처리 분야에서 주로 사용되는 wavelet 변환과 신경망 기법을 이용하고자 한다. 그러나 신경망 기법에서 주로 사용되는 비선형 최적화기법인 Gradient descent BP는 최적화 문제점을 해결하기에는 수렴속도가 느리기 때문에 적합하지 않다. 따라서 본 논문에서는 기존 Gradient descent BP를 보완한 Levenberg-Marquardt Back-Propagation을 대뇌출혈성 병변인식에 적용하여 구현함으로써 총 50개의 패턴 중 45개의 영상이 인식에 성공하였고 전체 평균 인식률은 각각 90%와 87%의 인식률을 보였다.

1. 서 론

최근 컴퓨터 처리속도의 고속화 추세에 맞추어 영상처리 및 컴퓨터 그래픽을 이용하여 각종 의료기관에서 생성되는 화상을 디지털화 하여 관리 및 처리하려는 노력들이 활발히 진행되고 있다. 특히 디지털 화상처리 기술 중에서 화상개선은 일반적으로 인간의 시각정보를 쉽게 이해하기 위한 수단으로 연구되어지고 있다.

의료 화상의 경우 환자의 질병 진단이나 치료를 위해 초기에는 X선이 주로 이루어졌으며 점진적인 컴퓨터의 발달로 CT 화상, MRI, 핵의학인 방사선 처리 등이 주로 이용되고 있다[1][2]. 현재 영상인식에서는 기존의 화상처리에 대한 분석검출 방법을 적용하고있으며 이 방법은 불필요한 정보까지 포함하여 특징을 추출하는데 많은 시간이 소요된다. 이러한 연구의 기반이 되는 Back-propagation은 다층 퍼셉트론에 관련된 가중치 및 임계값에 대한 해를 반복해서 구하는 일반적인 방법을 사용하며, 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 복잡한 알고리즘을 적용하고 있는데, 이들 대부분은 뉴턴 방법을 근거로 하고 있지만, 실제 적용에 있어서는 뉴턴 방법과 최소 강하법의 절충안을 사용하고 있으며 Gradient descent BP를 주로 이용한다. 하지만 비선형 최적화기법인 Gradient descent BP는 최적화 문제점을 해결하기에 수렴속도가 느려 적

합하지 않다. 따라서 본 논문에서 구현한 Levenberg-Marquardt Back-Propagation을 적용한 대뇌출혈성 병변 인식 시스템은 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 본 시스템의 구현 및 실험 결과, 4장에서는 결론 및 향후 연구과제에 대해서 기술하고자 한다.

2. Levenberg-Marquardt method

비선형 문제를 해결하는 반복적 최소자승 기법의 하나로 행렬의 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 반복시 변수변화 벡터는 (식1)과 같다.

$$\delta = (Z^T Z + \beta I)^{-1} Z^T g \quad (\text{식1})$$

여기서 β 는 라그랑지 곱수, I 는 단위행렬이다.

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 Gradient descent BP 방법을 많이 사용하고 있다. 하지만 비선형 최적화기법인 Gradient descent BP로는 최적화 문제점을 해결하기에는 수렴속도가 느리기 때문에 적합하지 않았다. 따라서 본 논문에서는 이차 근사 방법인 Levenberg-Marquardt Back-Propagation을 적용한 대뇌 출혈성 병변 시스템은 해의 수렴정도, 변수 벡터의 변화정도에 따라 적절히 크기를 변화시킴으로써 효율성과 안정성을 동시에 얻을 수 있다.

다음은 Levenberg-Marquardt function 알고리즘이다[3][4].

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

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 $E(a(k)) - E(a(k+1)) < 10^{-3}$ ($4 \times$ consecutively) then stop;
8. $\lambda \leftarrow 0.1 \times \lambda$
9. $a(k) \leftarrow a(k+1)$; goto 2;


3. 구현 및 실험 결과

3.1 이산 웨이블릿 변환 기반 특징벡터 추출


웨이블릿 변환을 이용한 특징 파라미터 추출 과정은 먼저 해상도가 256×256인 두 개의 입력 영상 신호를 극좌표계와 예지 분포를 이용하여 특징영역으로 분리한 다음 웨이블릿 변환을 수행하고 계수 행렬을 구한다. 본 논문에서는 영상의 데이터 양으로 인한 시간 지연을 고려해 3-레벨 웨이블릿 변환계수를 사용하였다.

본 논문에서 사용한 대뇌출혈성 병변영상의 특징영역에 대해 3-레벨 웨이블릿 변환을 수행하면 계수행렬 cA3, cH3, cV3 그리고 cD3을 구할 수 있다. 여기서 cA3은 3-레벨 저주파 계수 행렬, cH3은 수평 고주파 계수행렬, cV3은 수직고주파 계수 행렬 그리고 cD3은 대각 고주파 계수 행렬인데 이들의 분포특성을 분석한 후 특징벡터를 추출한다. 다음으로 3개의 계수 행렬에 대해 절대값을 구하고 cA3, cH3, cV3, cD3에 대해 각각 특징벡터를 추출하여 +1과 -1 사이로 정규화한다. 특징추출은 원 영상에 대해 10개의 학습 샘플을 선정한 후 이를 3-레벨 웨이블릿

변환하여 cA3, cH3, cV3, cD3 등을 각각 구했다. 다음으로 이들 계수행렬의 데이터 분포를 분석한 후 특징벡터를 추출하였고 이를 정규화하여 신경망의 입력 벡터로 사용한다. (그림1)는 본 논문의 실험자료로 사용된 원 영상 샘플중의 하나이며 (그림2)는 3-레벨 웨이블릿 변환 후의 계수행렬 cA3, wH3, wV3, wD3의 영상을 나타낸 것으로 이들 3개의 계수 행렬에 원 영상의 정보가 집중되어있는 결과를 보여주고 있다.



<그림1>본 논문에서 사용된 원 영상




<그림2>3-레벨 웨이블릿 변환 후의 병변 영상


3.2 신경망 학습

본 논문의 실험에서는 해상도가 256×256인 대뇌출혈성 병변영상을 3-레벨 웨이블릿 변환을 이용해 구한 계수값 9개를 신경망의 입력 패턴으로 사용하였으며 실험에 사용된 영상은 총 10명에 대하여 각각 10개의 영상을 사용한다. 획득된 영상 중 5개의 영상은 신경망 학습을 위한 학습데이터로 사용하고, 나머지 5개의 영상은 학습된 신경망의 인식률을 측정하기 위한 실험 데이터로 사용하였다. 본 대뇌출혈성 병변영상 인식에서는 9개의 입력노드와 5개의 출력노드, 그리고 2배수 정도인 20개의 노드를 사용하였으며 2개의 은닉층을 지닌 9×20×20×5의 신경망을 사용한다. 설계된 신경망을 이용한 학습방법은 일반적인 신경망 학습 알고리즘인 Gradient descent BP 학습 알고리즘과 본 논문에서 적용한 Levenberg-Marquardt BP 알고리즘을 사용하였다. 학습패턴은 3-레벨 웨이블릿 변환을 통하여 얻어낸 계수 특징벡터로 총 10명에 대한 5개의 대뇌출혈성 병변영상을 사용하여 전체 학습패턴의 개수는 50개이다. GD BP 학습방법과 LM 학습 방법은 모두 학습률 0.4, 모멘텀 0.7 학습오차 0.01을 사용하여 학습의 시간, 인식률을 실험하였다. 반복학습 회수는 500회를 지정하여 학습 오차 값이 지정된 학습오차 0.01 이하로 감소하는 경우 학습이 완료된 것으로 간주하여 학습을 종료한다. 안정화 학습 후 완료된 신경망은 대뇌출혈성 병변인식에 대한 신경망으로 사용된다. 신경망 학습의 특성상 항상 동일한 학습범위 내에서 학습이 완료되지 않으며 최악의 경우 학습이 이루어지지 않는 상황이 발생 할 수도 있다. 본 논문에서는 총 10회의 LM, GD BP 학습을 통하여 두 학습방법의 평균적인 학습 수렴속도를 나타내었다. 총 10회의 학습을 수행했을 때 LM학습 방법은 8회의 학습이 성공하였고 학습이 이루어지지 않는 경우를 제외한 학습 횟수는 평균 37.24회에서 오차범위 이내에서 수렴되어 학습이 종료되었으며, GD BP 학습의 경우 학습 성공 횟수가 5회였고 평균 524.72회의 반복 학

습 후에 학습오차가 오차범위 이내에서 수렴되어 학습이 종료되었다. 따라서 학습 성공을 대상으로 한 평균 반복 학습의 회수를 비교하였을 때 LM 학습 알고리즘이 본 실험에서 수행한 대뇌출혈성 병변 학습패턴에 적합한 학습 방법이라고 볼 수 있다. <그림3>과 <그림4>는 두 신경망 학습을 수행 한 후의 평균 수렴 속도 결과를 비교한 것이다.



<그림3>GD BP 학습 알고리즘 수렴 결과



<그림4>본 논문에서 제안한 LM 학습 알고리즘 수렴 결과

테스트 패턴에 대한 대뇌출혈성 병변 인식률은 학습이 완료된 신경망에 대하여 학습에 참여한 패턴을 제외한 나머지 10명의 50개의 대뇌출혈성 병변 영상에 대하여 인식 여부를 수행하였다. 테스트 패턴의 경우 LM신경망으로 인식을 수행한 경우 총 50개의 패턴 중 45개의 영상이 인식에 성공하였고, GD BP신경망의 경우 40개의 영상을 정확히 인식하였다. 전체 평균 인식률은 각각 90%와 87%의 인식률을 보였다. LM과 GD BP신경망 결과를 MSE, NMSE(normalized mean squared error), MAE(mean absolute error)로 비교해보았다. 결과는 <표1>과 같다.

<표 1>LMBP와 GDBP비교

MSE	0.03692	0.03777
NMSE	0.15167	0.15410
MAE	0.08893	0.09072
인식률	0.9012(90%)	0.8701(87%)

4. 결론

본 논문에서 적용한 Levenberg-Marquardt Back-Propagatio

n을 이용하여 대뇌출혈성 병변인식의 수렴속도를 빠르게 하는 신경망을 사용하였다. 학습회수를 측정한 결과 LMBP 알고리즘이 대뇌출혈성 병변인식 학습 패턴에 더 적합한 것을 알았고 빠른 수렴속도와 학습패턴은 91%의 인식률을 나타내었고 테스트 패턴도 90%의 인식률을 보였다. 인식되지 못한 영상은 대뇌 반구의 기저부에 육안으로 판별하기 어려운 부분의 출혈 영상부분이 인식률이 떨어지는 것을 확인했다. 향후 연구과제로는 장소에 따라 용기되어 육안으로 판별하기 어려운 부분의 출혈영상 부분에서도 인식할 수 있는 특징을 분석하여 고유한 대뇌출혈성 병변 코드를 만들어 직접 사용할 수 있는 특징을 찾아내어 신뢰도를 높이기 위한 연구가 수행되어야 할 것으로 사료된다.

교신저자

이름 : 정 채영

mail : cyjung@chosun.ac.kr

전화 : 062-230-6625

주소 : 광주시 동구 서석동 375번지 조선대학교 자연과학대학 수학.전산통계학부

참고문헌

- [1] 김민용, "영상분석을 위한 순환형 에지 연산자에 관한 연구", 석사학위 논문, 청주대학교, 1989.
- [2] Bernd, Jahne, : *Digital Image Processing*, 1991.
- [3] <http://falcon.postech.ac.kr/ipawb/demo/kiss98cs4/html/sld008.html>
- [4] 이현엽,문경일, "MatLAB을 이용한 퍼지-뉴로", 1999.12.