

Real-time Artificial Neural Network for High-dimensional Medical Image

Kwontaeg Choi*

Division of Computer Media Engineering, Kangnam University

Received: December 07, 2016. Revised: December 20, 2016. Accepted: December 31, 2016

ABSTRACT

Due to the popularity of artificial intelligent, medical image processing using artificial neural network is increasingly attracting the attention of academic and industry researches. Deep learning with a convolutional neural network has been proved to very effective representation of images. However, the training process requires high performance H/W platform. Thus, the realtime learning of a large number of high dimensional samples within low-power devices is a challenging problem. In this paper, we attempt to establish this possibility by presenting a realtime neural network method on Raspberry pi using online sequential extreme learning machine. Our experiments on high-dimensional dataset show that the proposed method records an almost real-time execution.

Keywords: Medical Imaging, Classification, Artificial Neural Network, ELM, Online Learning

I. INTRODUCTION

인공지능이 4차 산업 혁명의 견인차 역할을 할 것으로 기대되면서 최근 많은 영역에서 관련 연구가 활발히 진행되고 있다. 의료영상에서도 인공지능을 활용한 진단 시스템에 대한 연구가 영상의학 및 방사선의학과를 중심으로 활발히 이루어지고 있다.

이러한 진단 시스템에서는 1차 취득한 영상으로부터 특징을 추출하고, 자동분류를 위해 기계학습 알고리즘이 사용되는데 주로 인공신경망과 SVM(Support Vector Machine)같은 분류기를 활용한 연구가 주로 이루어졌다. 최근에는 주로 딥러닝(deep learning)이라는 효율적인 인공신경망 알고리즘을 사용해 뇌 자기공명 영상에서 다양체 학습, 조직병리 영상에서 기저세포암 인지, 뇌 자기공명 영상에서 해마 분할 같은 다양한 연구가 진행되고 있다.^[1]

이러한 인공신경망 알고리즘은 최적 솔루션을 찾지 못하고 국소 최적화에 빠져 학습데이터에 지나치게 의존적인 모델로 학습되는 문제를 해결할 수 있는 기술적인 진보와 많은 양의 데이터를 처리할 수 있는 고성

능 컴퓨팅 플랫폼의 등장으로 최근 다시 주목받게 되어 다양한 연구가 의료 영상 분야에서 이루어지고 있다.

그러나 딥러닝을 사용한 보조 진단시스템 구현은 고 사양의 서버 학습이 필요하다. 더구나 영상 데이터는 계속 축적되고 추가 성능 개선이 이루어져야 하는데 기존 학습 알고리즘은 처음부터 다시 학습이 필요하다.

최근 인공 신경망을 이용한 연구 중, ELM(Extreme Learning Machine)을^[2] 사용한 다양한 의료영상 분석에 대한 연구가 진행되고 있다.^[3] ELM은 상대적으로 정확도가 높고, 구현의 단순성 때문에 심부정맥 분류^[4], 암진단^[5], 유방암 진단^[6], 간질^[7], 간 종양 검출^[8], 저혈당증 예측^[9] 같은 분야에서 주로 연구되었다.

본 논문에서는 의료 영상 분석에 사용되는 ELM의 계산 복잡도를 분석한다. 특히 적용 분야의 확대를 위해 PC나 스마트폰 같은 고성능 H/W 플랫폼이 아닌 라즈베리파이 같은 저사양 플랫폼에서 ELM 알고리즘의 실시간 학습에 대한 효율성을 분석하고자 한다.

*Corresponding Author: Kwon Taeg Choi

E-mail: kwontaeg.choi@kangnam.ac.kr

Tel: +82-31-280-3660

II. BACKGROUND

ELM 알고리즘은 아래 Eq. (1)처럼 표현된다.

$$\hat{y} = \alpha \psi(Wx) \quad (1)$$

여기서 W 은 가우시안 랜덤노이즈로 이루어진 은닉 계층의 가중치 행렬이고, ψ 는 비선형 처리를 위한 활성화 함수이고, α 는 출력층의 가중치 벡터이다.

학습샘플 X 와 출력 Y 가 주어지면 α 는 최소자승법 (Least Square Method) 알고리즘으로 아래 Eq. (2)처럼 추정할 수 있다.

$$\alpha = (\psi(WX)^T \psi(WX))^{-1} \psi(WX)^T Y \quad (2)$$

일반적인 인공신경망에서는 α 와 W 가 모두 추정되어야 하기 때문에 학습이 용이하지 않지만, ELM에서는 W 는 별도 학습 없이 랜덤하게 결정되고 α 만 반복적인 수렴학습 알고리즘이 아닌 최소자승법을 사용해 빠르게 출력층의 학습 가중치를 결정할 수 있다.

고차원 영상 데이터에 대한 ELM과 SVM의 성능 비교는 여러 논문에서^[10-11] 분석되었다. 이들 논문에서 ELM 기반 알고리즘이 SVM 기반 알고리즘에 비해 4% 정도 향상된 인식 성능을 보여주었다. 따라서 본 논문에서는 분류기의 정확도가 아닌 학습에 대한 계산 복잡도를 분석하고자 한다. 특히 PC나 스마트폰 같은 고성능 플랫폼이 아닌 라즈베리파이 같은 저사양 플랫폼에서 인공신경망의 실시간 학습에 대한 가능성을 검토하고자 한다.

III. ANALYSIS

본 논문에서는 ELM 알고리즘의 학습 시간에 영향을 미치는 부분을 3개 영역으로 분할하고 이를 종합적으로 분석하고자 한다. 정확한 복잡도 분석을 위해 Table 1에 계산에 영향을 끼치는 요소에 대해 정리하였다.

Table 1. Notation definition for computation analysis

Specification	
d	feature dimension
h	number of hidden nodes
n1	number of training samples
c	number of classes
n2	number of additional training samples

1. 은닉 계층 출력

Eq. (1)에서 $\psi(Wx)$ 함수에 의해 은닉 계층의 출력이 계산된다. W 에 대한 가우시안 노이즈 생성, 행렬연산 WX , 활성화 함수 ψ 에 대한 계산이 필요하다. 이를 각각 C1, C2, C3로 표기하고, 각각에 대한 연산 비용은 Table 2와 같다.

Table 2. Computation of hidden layer outputs

	Specification	Computation
C1	W initialization	$(h+1) \times d \rightarrow hd$
C2	matrix multiplication	$(h \times d) \times (d \times h) \rightarrow h^2d$
C3	function evaluation	$(h \times n) \rightarrow hn$

실제 학습 환경을 가정하면 n 이 가장 크겠지만 전체 연산에서 d 와 h 연산이 더 빈번히 발생한다. 또한 대개 h 의 개수는 d 와 유사한 크기로 결정되기 때문에 은닉층의 출력은 주로 d 에 의존하게 된다. 이럴 경우 C2에 대한 계산 복잡도는 d^3 이 된다.

활성화 함수 ψ 는 선형, sigmoid, RBF, sin 함수 등이 사용될 수 있지만 응용 분야 및 방법에 따라 성능상 차이가 크지 않기 때문에 본 논문에서는 아래와 같은 sigmoid 함수를 사용하였다.

$$\psi(Wx) = 1.0 / (1 + \exp(-Wx)) \quad (3)$$

2. 출력 계층의 가중치 학습

ELM에서 출력층의 가중치는 Eq. (2)에 의해 계산된다. 활성화 함수의 행렬연산, 역행렬, 역행렬과의 행렬곱 연산이 필요하고 이를 각각 C4, C5로 표기하고, 각각에 대한 연산 비용을 Table 3에 표기하였다.

Table 3. Computation of hidden layer training

	Specification	Computation
C4	$\psi(WX)^T \psi(WX)$	$(h \times n) \times (n \times h) \rightarrow nh^2$
C5	$(\cdot)^{-1}$ $\psi(WX)^T Y$	$(h \times h)$ inversion $\rightarrow h^3$ $(h \times h) \times (h \times n) \times (n \times 1)$ $\rightarrow hn^2$

학습샘플의 수가 충분하지 않아 특징 차원의 수가 샘플수 보다 많은 경우가 발생한다. 이럴 경우 C5의 역행렬 계산시 low rank 문제로 인해 정확한 값이 계산될 수 없다. 이를 위해 본 논문에서는 아래 수식과 같은 정규화된 ELM^[12]을 사용하였다.

$$\alpha = (\psi(WX)^T \psi(WX) + 1/C)^{-1} \psi(WX)^T y \quad (4)$$

여기서 C는 정규화 값으로 본 논문에서는 10^6 을 사용하였다.

가장 계산 비용이 높은 부분은 C5이다. 일반적으로 h보다 n이 매우 크기 때문에 학습 샘플수가 매우 많은 경우 학습에 매우 많은 시간이 필요하게 된다. 따라서 학습 샘플수를 줄일 수 있는 방법이 필요하다.

3. 추가 학습 데이터를 이용한 온라인 학습

앞절에서 분석했듯이 학습 샘플수가 많은 경우 C5에 대한 계산 비용이 매우 커진다. 이는 본 논문에서 살펴 보려고 하는 저사양 플랫폼에서는 문제가 발생한다. 이를 위해 한 번에 전체 학습 데이터를 사용하지 않고 추가적인 데이터만으로 지속적으로 학습이 가능한 온라인 버전의 OS-ELM^[13]이 연구되었다.

OS-ELM에서 α_t 는 아래 Eq. (5) 처럼 이전 학습 결과와 새로운 샘플을 사용해 계산될 수 있다.

$$\alpha_t = \alpha_{t-1} + M_t^{-1} \psi(X_t)^T (y_t - \psi(X_t) \alpha_{t-1}) \quad (5)$$

여기서 M_t^{-1} 은 아래 수식과 같다.

$$M_t^{-1} = M_{t-1}^{-1} + M_{t-1}^{-1} \psi(WX_t)^T \cdot (I + \psi(WX_t) M_{t-1}^{-1} \psi(WX_t)^T)^{-1} \psi(WX_t) M_{t-1}^{-1} \quad (6)$$

Eq. (2)를 이용한 방법과 Eq. (5), Eq. (6)을 사용한 방법은 동일한 값을 추정한다.

M_t^{-1} 을 계산하기 위해 $(h \times h)$ 크기의 역행렬 연산과 다수의 행렬 연산이 필요하지만 n2가 h보다 작기 때문에 전체 계산 복잡도가 h에 의해 제한된다. 따라서 저사양 H/W 플랫폼에서 유용할 수 있다.

ELM의 성능 개선을 위해 다양한 방법이 제안되었지만^[14,15] 이들 방법의 성능 개선폭이 크지 않고, 개선된 알고리즘 모두가 온라인 학습을 지원하는 것은 아니기 때문에 본 논문에서는 정규화된 ELM과 OS-ELM 알고리즘을 기준으로 실험하고자 한다.

IV. RESULT

ELM과 OS-ELM 알고리즘의 학습 성능을 평가하기 위해 GMM 모델을 사용해 1024 크기의 영상을 가상으로 생성하였다. ELM 알고리즘은 행렬 계산만을 사용하기 때문에 데이터셋에 대한 분포 특성이 전체 계산 복잡도에 큰 영향을 주지 않는다. 실험에 사용한 H/W 플랫폼은 라즈베리파이3이고, ELM 알고리즘은 라즈베리파이위에 설치된 OpenCV 제공 행렬 함수를 사용하여 구현되었다.

1. 은닉 계층의 크기에 따른 학습 시간 실험

이번 실험에서는 은닉층의 노드수를 변경해가며 학습시간을 측정하였다. 일반적으로 은닉층의 노드수는 인식성과 학습 시간 모두에 영향을 끼친다. 대개 최적 노드수는 실험에 따라 튜닝된다. 따라서 이번 실험에서는 은닉층의 노드수를 특징 차원의 50%, 75%, 100%, 125%, 150%로 변경해가며 시간을 측정하였다. 샘플수 n=200, 클래스 수 c=10, 특징 차원 수 d=1024로 실험하였다. Table 4는 측정 결과이다.

Table 4. Computation time varying number of hidden nodes (milliseconds)

	C1	C2	C3	C4	C5	Total
512(50%)	26	1050	52	650	1826	3760
768(75%)	35	1469	79	1476	5838	8899
1024(100%)	44	2092	107	2515	12953	17714
1280(125%)	54	2514	131	4070	23635	23635
1536(150%)	63	3132	158	5759	39053	39053

실험 결과를 보면 노드수가 512에서 1536으로 3배 증가할 때 학습시간은 3760ms에서 39053ms으로 10배 이상 증가하였다. 따라서 은닉층의 노드수가 512일 때 4초 수준으로 즉시 학습이 가능해 보이나 노드수가 1000을 넘어가면서 학습에 40초 이상 걸린다. 따라서 다양한 저 사양 플랫폼에 적용하기 위해서는 특징 차원수를 최적화할 필요가 있다.

본 논문에는 ELM 알고리즘의 계산 복잡도를 자세히 분석하기 위해 전체 계산 영역을 C1 ~ C5 다섯개의 영역으로 나누어 개별 부분에 대한 복잡도를 분석하였다. 어떤 부분이 상대적으로 얼마나 계산을 전체적인 관점에서 살펴보기 위해 각 영역을 평균하여 Fig. 1 처럼 상대적 시간을 평가하였다.

Fig. 1에서 확실히 볼 수 있듯이 전체 계산에서 가장 많은 비용은 C5 부분이다. h^3 , n^3 의 복잡도가 필요한 부분이다. 따라서 향후 속도 개선을 위해 이 부분을 집중적으로 최적화할 필요가 있다. C1, C3부분은 연산 비용이 거의 들지 않기 때문에 최적화할 필요가 없다.




Fig. 1. Computation comparison of C1 ~ C5.

2. 학습 샘플의 크기에 따른 학습 시간 실험

두 번째 실험에서는 학습 샘플의 크기를 변경해가며 학습시간을 측정하였다. 일반적으로 학습 샘플이 많을 때 인식 성능과 학습 속도는 증가하게 된다. 따라서 이번 실험에서는 학습 샘플의 수를 200, 500, 1000, 2000, 3000개로 바꿔가면서 학습 시간을 측정하였다. 클래스 수 $c=10$, 특징 차원 수 $d=1024$, 은닉층의 노드수 $h=1024$ 로 실험하였다. Table 5는 측정 결과이다.

Table 5. Computation time varying number of training samples(millisecond)

	C1	C2	C3	C4	C5	Total
200	45	2106	107	2628	13149	18038
500	64	5586	263	6462	21871	34249
1000	95	11673	535	13039	41401	66746
2000	157	23647	1059	25933	77071	127869
3000	219	35703	1587	38888	113743	190144

실험에서 알 수 있듯, 학습 샘플 수가 1000개가 넘어가면 학습에 1분 이상 필요하고 3000개 일 때 3분 이상이 필요하다. 학습샘플수에 대략적으로 비례하는 것으로 보인다. 이번 실험을 통해 알 수 있는 것은 ELM 알고리즘이 기존 알고리즘에 비해 빠른 학습이 가능하다고는 하지만 학습 데이터가 많은 경우 매우 큰 학습 시간이 필요하다. 또한 학습 샘플수가 많아지면 단순 연산인 C2, C4에 대한 계산도 수십초 이상이 필요함을 알 수 있다.

Fig. 1은 학습 샘플수와 은닉층의 노드수를 동시에 변경해가면서 학습 시간을 3차원 형태로 표현하였다. ELM 알고리즘은 샘플수와 은닉층의 노드수 중에서 노드수에 더 영향받음을 알 수 있다.




Fig. 2. Computation time varying number of hidden nodes and training samples.

3. 클래스 수에 따른 학습 시간 실험

ELM은 이진 분류기이다. 따라서 일대다 방법을 사용해 멀티 클래스로 확장할 수 있다. Table 6은 은닉층의 노드수와 클래스 수에 따라 학습 시간을 측정된 결과이다.

Table 6. Computation time varying number of classes(millisecond)

	h=512	h=1024
c=2	3189	17921
c=4	3222	17908
c=6	3181	17922
c=8	3166	17804
c=10	3184	17810

Table 6의 실험결과는 클래스 수가 학습시간에 거의 영향을 끼치지 않음을 보여주고 있다. 이는 계산 비용이 많이 드는 부분은 클래스 정보와 무관하다. 클래스 정보는 역행렬 연산 이후에 필요하기 때문에 ELM 알고리즘은 클래스 수에 효율적으로 가중치 계산이 가능함을 알 수 있다.

4. 온라인 학습에 따른 학습 시간 실험

온라인 학습에 대한 성능 평가를 위해 은닉층의 노드수와 학습데이터 수를 변경하면서 수행 시간을 평가하였다. 은닉층 노드수 h는 512, 1024, 추가 학습 데이터 n2는 10,20,30,40,50개로 변경해가면서 학습에 걸리는 시간을 측정해 Table 7에 표사하였다.

Table 7. Computation time of online training(millisecond)

	h=512	h=1024
n2=10	1699	12793
n2=20	1799	13222
n2=30	1927	13797
n2=40	2035	14230
n2=50	2202	14819

Table 7을 통해 확인할 수 있는 사항은 크게 3가지이다. 첫 번째로 은닉층의 노드수가 크면 OSELM 알고리즘도 학습시간이 10초 이상 걸린다. 두 번째는 추가 샘플의 수가 전체 연산에 큰 영향을 끼치지 않는다는 점이다. 그 이유는 Eq. (5) 와 Eq. (6)의 계산 부분에서 h에 비해 n2 값이 현저히 작기 때문이다. 따라서 OSELM 알고리즘에서 추가 학습 데이터의 크기는 큰 영향을 끼치지 않는다. 세 번째는 2,3초 이내로 빠른 학습이 필요한 응용에서는 은닉층의 노드수를 512개 이하로 해야 된다는 점이다.

V. CONCLUSION

본 논문에서는 고차원 의료 영상 분석에 사용되는 ELM 기반의 인공지능망에 대한 계산 복잡도를 분석하고, 저사양 H/W 플랫폼에서 기계학습 가능성을 확인하였다. 실험을 통해 PC나 스마트폰 같은 고성능 플랫폼이 아닌 IoT 디바이스용으로 많이 연구되고 있는 라즈베리파이에서 ELM은 2초 이내에 실시간 기계 학습이 가능함을 살펴보았다. 의료영상을 촬영하고 디지털화하는 기기와 기술이 발전하고 있기 때문에 빠른 진단을 통해 전문가의 의사결정에 도움을 줄 수 있는 인공지능 시스템 개발에 대한 연구가 활성화될 것으로 보인다.

Acknowledgement

본 연구는 강남대학교 교내연구비의 지원에 의해 수행되었다.

Reference

- [1] Hansang Lee, Minseok Park, Junmo Kim, "Deep Learning in Medical Imaging", Journal of the Korean Society of Radiology, Vol. 20, pp. 13-18, 2014.
- [2] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: A new learning scheme of feedforward neural networks," in Proc. IJCNN, Budapest, Hungary, Jul. 25 - 29, 2004, vol. 2, pp. 985 - 990.
- [3] Jiuwen Cao and Zhiping Lin, "Extreme Learning Machine on High Dimensional and Large Data Applications : A Survey", Math. Probl. Eng. 501 (2015).
- [4] J. Kim, H. Shin, Y. Lee, and J. Lee, "Algorithm for classifying arrhythmia using extreme learning machine and principal component analysis," in Proceedings of the 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pp. 3257 - 3260, Lyon, France, August 2007.
- [5] S. Saraswathi, S. Sundaram, N. Sundararajan, M. Zimmermann, and M. Nilsen-Hamilton, "ICGA-PSO-ELM approach for accurate multiclass cancer classification resulting in reduced gene sets in which genes encoding secreted proteins are highly represented," IEEE/ACM Transactions on Computational Biology and Bioinformatics, vol. 8, no. 2, pp. 452 - 46

3, 2011..

- [6] E. Malar, A. Kandaswamy, D. Chakravarthy, and A. Giri Dharan, "A novel approach for detection and classification of mammographic microcalcifications using wavelet analysis and extreme learning machine," *Computers in Biology and Medicine*, vol. 42, no. 9, pp. 898 - 905, 2012.
- [7] Y. Song and J. Zhang, "Automatic recognition of epileptic EEG patterns via extreme learning machine and multiresolution feature extraction," *Expert Systems with Applications*, vol. 40, no. 14, pp. 5477 - 5489, 2013.
- [8] W. Huang, Y. Yang, Z. Lin, et al., "Random feature subspace ensemble based Extreme Learning Machine for liver tumor detection and segmentation," in *Proceedings of the 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC '14)*, pp. 4675 - 4678, Chicago, Ill, USA, August 2014.
- [9] X. Mo, Y. Wang, and X. Wu, "Hypoglycemia prediction using extreme learning machine (ELM) and regularized ELM," in *Proceedings of the 25th Chinese Control and Decision Conference (CCDC '13)*, pp. 4405 - 4409, Guigang, China, May 2013.
- [10] J. Xu, H. Zhou, G.B. Huang, Extreme Learning Machine based fast object recognition, in: *International Conference on Information Fusion*, 2012, pp. 1490 - 1496.
- [11] Lei Zhang , David Zhang, Fengchun Tian, "SVM and ELM: Who Wins? Object Recognition with Deep Convolutional Features from ImageNet", *Proceedings of ELM-2015 Volume 1*, pp 249-263, 2016.
- [12] W. Deng, Q. Zheng, and L. Chen, "Regularized extreme learning machine," in *Proc. IEEE Symp. CIDM*, Mar. 30 - Apr. 2, 2009, pp. 389 - 395.
- [13] N.-Y. Liang, G.-B. Huang, P. Saratchandran, and N. Sundararajan, "A Fast and Accurate On-line Sequential Learning Algorithm for Feedforward Networks", *IEEE Transactions on Neural Networks*, vol. 17, no. 6, pp. 1411-1423, 2006
- [14] G.-B. Huang, Q.-Y. Zhu and C.-K. Siew, "Extreme Learning Machine: Theory and Applications", *Neurocomputing*, vol. 70, pp. 489-501, 2006
- [15] Kwontaeg Choi , Kar-Ann Toh , Hyeran Byun, "Realtime training on mobile devices for face recognition applications", *Pattern Recognition*, v.44 n.2, p.386-400, February, 2011

고차원 의료 영상을 위한 실시간 인공 신경망

최권택

강남대학교 컴퓨터미디어정보공학부

요 약

최근 인공지능에 대중의 관심으로 인해, 인공신경망을 사용한 의료영상 처리가 학계와 산업계에서 관심이 커져가고 있다. 딥러닝을 이용한 컨볼루션 신경망은 영상을 효과적으로 표현할 수 있는 것으로 증명되었다. 그러나 학습을 위해서는 고성능 H/W 플랫폼이 요구된다. 따라서 고차원의 많은 학습 샘플을 저사양 H/W 플랫폼에서 학습하는 것은 매우 도전적인 문제이다. 본 논문에서는 온라인 인공 신경망을 사용해 라즈베리파이에서 동작할 수 있는 실시간 신경망 알고리즘을 제안하고자 한다. 다양한 실험 결과를 통해 제안된 방법은 실시간 학습이 가능함을 보여주었다.

중심단어: 의료영상, 분류, 인공신경망, ELM, 온라인 학습