



# Artificial Intelligence in Medicine: Beginner's Guide

## 의료인공지능: 인공지능 초심자를 위한 길라잡이

Seong Ho Park, MD\*

Department of Radiology and Research Institute of Radiology, Asan Medical Center, University of Ulsan College of Medicine, Seoul, Korea

Artificial intelligence is expected to influence clinical practice substantially in the foreseeable future. Despite all the excitement around the technology, it cannot be denied that the application of artificial intelligence in medicine is overhyped. In fact, artificial intelligence for medicine is presently in its infancy, and very few are currently in clinical use. To best leverage the potential of this technology to improve patient care, clinicians need to see beyond the hype, as the guidance and leadership of medical professionals are critical in this matter. To this end, medical professionals must understand the underlying technological basics of artificial intelligence, as well as the methodologies of its proper clinical validation. They should also have an impartial, complete view of the capabilities, pitfalls, and limitations of the technology and its use in healthcare. The present article provides succinct explanations of these matters and suggests further reading materials (peer-reviewed articles and web pages) for medical professionals who are unfamiliar with artificial intelligence.

Received April 1, 2018

Accepted April 13, 2018

\*Corresponding author: Seong Ho Park, MD  
Department of Radiology and Research Institute of Radiology, University of Ulsan College of Medicine, Asan Medical Center, 88 Olympic-ro 43-gil, Songpa-gu, Seoul 05505, Korea.  
Tel. 82-2-3010-5984 Fax. 82-2-476-4719  
E-mail: parksh.radiology@gmail.com

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

### Index terms

- Artificial Intelligence
- Machine Learning
- Medicine
- Medical Imaging
- Diagnoses

### 서론

인공지능 기술이 가까운 미래에 의료 분야에 많은 영향을 미칠 것으로 예상된다. 인공지능 기술이 처음 등장한 것은 이미 오래전의 일이나(1) 의학/의료 분야에 있어 본격적인 화두가 된 것은 최근 수 년 동안의 일이다. 특히, 다른 의학/의료 분야에 비해 영상의학 분야에 더 큰 화두가 되고 있는데, 이는 최근 화제가 되고 있는 인공지능 기술인 딥러닝(deep learning) 기술 중 현재 가장 각광을 받는 기술의 하나인 컴퓨터 비전(computer vision)으로도 알려진 컨볼루션 신경망(convolutional neural network)이 의학영상 분석에 직접 적용될 수 있기 때문이다. 컨볼루션 신경망(convolutional neural network)을 포함한 딥러닝(deep learning) 기술의 의학/의료 분야 적용이 처음 소개될 때에는, 이러한 기술이 가까운 미래에 영상학과 또는 병리과와 같이 영상분석 및 판독을 전문으로 하는 분야의 전문 의료인력

을 대체할 것이라는 많이 과장된 선부른 “예측”들이 나오기도 하였고, 이로 인해 해당 분야의 전공의 지원을 기피하는 촌극과 같은 일이 일어나기도 하였다. 하지만, 이러한 일들은 새로운 기술에 대한 이해와 지식의 부족에서 오는 일시적인 현상으로, 인공지능 기술에 대한 이해가 증가함에 따라 이후 약 1~2년 정도의 짧은 기간을 거치며 의료인공지능을 바라보는 시각에 매우 큰 변화가 나타났다. 최근 주요 의학/과학 학술지들에 나온 의료인공지능에 대한 의견을 보면(정확한 의미의 전달을 위해 원어 문장들을 Table 1에 그대로 인용하였다) 인공지능이 의학/의료 분야에 처음 소개될 때의 반응과는 사실상 정 반대에 가까운 입장을 제시하고 있다(2-5). 인공지능 기술의 임상 적용은 현재 초기 단계이고, 현재 실제로 임상 진료에 널리 사용되는 예를 별로 찾아볼 수 없는 상황이다. 이러한 현실 상황은, 부분적으로는 아직까지 인공지능 의료기술의 임상 도입에 필요한 평가 및 인허가 체계가 원활하게 갖추어지지 않았다는 것과 연

**Table 1. Opinions on Artificial Intelligence in Medicine Recently Published in Premier Medical and Scientific Journals**

Author (Reference)	Journal, Month, Year	Opinions
Obermeyer (2)	New Engl J Med, September 2017	When you look at all of the enthusiasm and hype around how machine learning will contribute to medicine, I think it's quite striking how little machine learning has contributed to medicine already.
The Lancet (3)	Lancet, December 2017	There is no doubt that AI in health care remains overhyped and at risk of commercial exploitation. Despite the excitement around these sophisticated AI technologies, very few are in clinical use. The inherent requirement for large-scale, high-quality, well structured data might ultimately limit the areas in which AI can bring benefits to health care.
Beam and Kohane (4)	JAMA, March 2018	Machine learning is not a magic device that can spin data into gold, though many news releases would imply that it can. Instead, it is a natural extension to traditional statistical approaches.
No authors listed (5)	Nature, March 2018	Many reports are best viewed as analogous to studies showing that a drug kills a pathogen in a Petri dish. They are not applying the evidence-based approaches that are established in mature fields, such as drug development. Many reports of new AI diagnostic tools, for example, go no further than preprints or claims on websites. They haven't undergone peer review, and might never do so.

관될 수도 있겠으나, 보다 근본적으로 이러한 일련의 일들은 의료인공지능과 관련하여 그간 많은 과장과 부정확한 정보들이 퍼져 있었음을 잘 보여 준다. 이와 같이 많은 과장이 발생하게 된 데에는 여러 원인이 있으며, 환자를 중심으로 한 의료의 근본보다는 의료데이터를 이용한 산업화와 기술에 치우친 시각, 진료 현장의 요구와 의료에 대한 전문 경험/지식으로부터 나오는 실제적 쓰임새(use case)에 대한 고려 부족과 이를 수집/발굴하려는 노력의 부족, 의료 분야에는 아직까지 빅데이터(big data)와 인공지능 기술을 원활하게 적용할 수 있는 기반 전산체계가 갖추어지지 않았음에 대한 간과, 즉시 활용 가능한 의료 빅데이터(big data)는 드물며 실제로는 의료 빅데이터(big data)의 구축이 매우 어렵다는 점을 간과, 의료인들 사이에 인공지능 기술에 대한 이해의 부족, 그리고 충분한 임상검증 없이 의료인공지능 기술의 성능을 과장하여 보고하는 일 등을 원인으로 생각해 볼 수 있다. 이 중, 임상검증이 충분히 되지 않은 결과를 과장하여 보고하는 것은 의료인공지능 기술의 적절한 임상검증을 위한 올바른 방법에 대한 이해의 부족이 한 가지 원인일 것이다. 의료인은 환자 진료의 최전방에서 인공지능 기술의 환자 적용과 적용 결과를 해석 활용함에 있어 최종 결정권자의 역할을 해야 하는 사람들이다. 따라서, 의료인이 의료인공지능에 대해 올바른 기본 지식과 판단을 갖추는 것은 매우 중요하다.

이러한 배경에서, 이 논문은 인공지능을 잘 모르는 의료인들에게 의료인공지능과 관련된 기본적인 개념들에 대하여 길잡이 역할을 하고자 한다. 의학/의료 분야에 적용을 고려해 볼 수 있는 인공지능 기술은 다양하며, 딥러닝(deep learning)만 생각하더라도 컨볼루션 신경망(convolutional neural network) 외에도 오토인코더(autoencoder), 순환신경망(recurrent neural network) 등 다양한 기술들이 있다(1). 주제의 방대함을 고려할 때 이러한 내용을 모두 다루는 것은 기본적 입문 성격인 이 종설의 범

위를 초과하며, 이 종설은 의학/의료 전체로 보면 인공지능을 이용한 분류(classification)에 대한 관심이 높다는 점(이에 대해서는 뒤에서 다시 설명한다)과 영상의학 분야는 의학영상 분석과 관련하여 컨볼루션 신경망(convolutional neural network)에 많은 관심이 있다는 점을 고려하여 이 두 가지 측면에 주로 중점을 두고 설명을 하고자 한다. 또, 의료인들이 참고할 만한 의료인공지능 관련 논문이나 인터넷 자료들이 이미 많이 나와 있음을 고려할 때, 이 종설에서는 의료인공지능에 대한 구체적인 지식을 직접 자세히 설명하는 것보다는 간결한 개념적 설명과 함께 대신 공부에 도움이 되는 유용한 논문들과 인터넷 자료들을 소개하고자 한다[이러한 자료들을 쉽게 찾아볼 수 있도록 Supplementary Material (in the online-only Data Supplement)에 목록으로 정리해 놓았다]. 따라서, 독자들은 이 논문을 의료인공지능에 대하여 좀 더 깊이 있게 알아보기 위한 일종의 길라잡이로 이용할 수 있을 것이다.

이 논문에 나오는 기술적 용어들에 대한 한글표현은, 현재 인공지능 관련 한글학술용어가 일관되게 정립되어 있지 않음을 고려하여, 대한전자공학회지의 국문 학술지인 전자공학회지 (ISSN: 1016-9288)에 최근 사용된 용어 표현 방식을 따랐고 이해를 돕기 위해 국문(영문) 식으로 병기하였다. 또한 통계학 관련 한글 용어는 한국통계학회의 공식용어를 사용하였다. 이들에 포함되지 않은 용어는 대한의사협회의 공식용어를 사용하였다.

### 의료인을 위한 딥러닝(Deep Learning)에 대한 종합적 설명

의학/의료 관점에서, 특히 영상의학 관점에서 영상학과 의사를 대상으로, 딥러닝(deep learning) 관련 용어, 기술적 개요 및 원리, 기술적 요구사항, 임상 적용 분야, 제약점 및 향후 방향

에 대한 종합적 설명을 제공하면서 동시에 비교적 자세하게 설명을 하는 종설이 최근 출간되었다. Supplementary Material (in the online-only Data Supplement)의 해당 자료를 확인하여 읽기를 권장한다.


## 인공신경망(Artificial Neural Network)과 컨볼루션 신경망(Convolutional Neural Network)의 기본 원리

여기서는 딥러닝(deep learning)의 방법들 중 임상적 진단/예측(특히, 영상을 이용한 진단/예측)을 하기 위한 인공지능 알고리즘을 이해하는 데 기본이 되는 다층 퍼셉트론(multilayer perceptron) 인공신경망(artificial neural network)과 컨볼루션 신경망(convolutional neural network)의 기본적인 원리를 설명하고자 한다. 이 신경망 알고리즘들은 간단히 이야기하면 매우 많은  $x$  변수들로부터 결과 값  $y$ 를 예측해 내는 매우 복잡한 수학 공식이라 생각할 수 있다. 가령, 간 전산화단층촬영 영상을 이용하여 간세포암을 진단하는 가상의 심층 신경망(deep neural network) 알고리즘을 예로 들면, 전산화단층촬영 영상 내 각각의 화소들이 개별  $x$  변수들이 되며 간세포암( $y = 1$ )과 간세포암이 아님( $y = 0$ )이  $y$  값이 된다. 이러한  $x$ 와  $y$  사이의 관계를 부여하는 인공지능 알고리즘을 만든다는(“교육” 시킨다는) 것은, 매우 복잡한 수학 공식 내 개개  $x$  변수들에 부여할 적절한 계수 다른 말로 가중치(weight)들(즉,  $\text{weight}_1 \times x_1 + \text{weight}_2 \times x_2 + \dots$ )을 찾아내는 것이다. 이러한 알고리즘을 교육시키는 과정이 마치 사람이 교육을 받는 것과 비슷한 것처럼 설명을 하는 경우를 볼 수 있는데, 사실 사람의 교육과 이러한 심층 신경망(deep neural network) 알고리즘의 교육은 다른 점이 많다. 사람을 교육하는 것은 원리와 개념에 의한 교육이 추가 된다. 가령, 전산화단층촬영을 이용한 간세포암 진단을 영상의학과 전공의에게 교육하는 경우, 전산화단층촬영의 조영증강 방법, 동맥기, 문맥기, 및 지연기 영상을 얻는 원리에 대한 설명, 간세포암이 간 동맥으로부터 혈류를 받고 간 문맥으로는 혈류를 받지 않는 병리학적 특징이 있다는 점, 그리고 간단한 간의 전산화단층촬영 해부학을 개념적으로 알려주면 심지어는 간세포암의 전산화단층촬영 영상을 직접 보여주면서 교육하지 않더라도 많은 전공의들로 하여금 전산화단층촬영 영상에서 간세포암을 잘 판독하도록 만들 수 있다. 반면, 이러한 심층 신경망(deep neural network)은 주어진 영상과 판독결과를 끝에서 끝으로 어떻게 든 연결시키기 위해 자료 내의 패턴을 찾아내는 과정이다-수학적 모형 적합(mathematical model fitting). 이와 같은 방식의 수학적 모형 적합(mathematical model fitting)을 소위

“의학적 지식을 가르치거나 제공하지 않아도 영상 판독을 스스로 배운다”는 식으로 은유적으로 묘사하기도 하나 이는 좀 과장된 기술이다. 또한, 이러한 수학적 패턴 찾기와 모형 적합(model fitting) 자체는 딥러닝(deep learning)에만 해당하는 것이 아니라 모든 수학적/통계학적 모형화(mathematical/statistical modeling)에 공통된 사항이다. 이와 같이 끝에서 끝으로 관계를 맺는 방식으로 수학적 모형 적합(mathematical model fitting)을 하기 위해서는 매우 많은 양의 자료가 필요하며, 이러한 이유로 딥러닝(deep learning)은 빅데이터(big data)를 필요로 하게 되고 이것이 두 가지 개념이 같이 붙어 다니는 이유이다. 알고리즘을 만들기 위해 매우 많은 양의 자료가 필요하다는 측면에서 딥러닝(deep learning) 방식의 모형 적합(model fitting)은 한편으로 효율적인 방법이 아니라 생각할 수도 있다. 즉, 사람은 몇 증례만 보면 배울 수 있는 것을 딥러닝(deep learning)으로 만들기 위해서는 수만 증례의 자료가 필요할 수도 있다.

### 다층 퍼셉트론(Multilayer Perceptron)

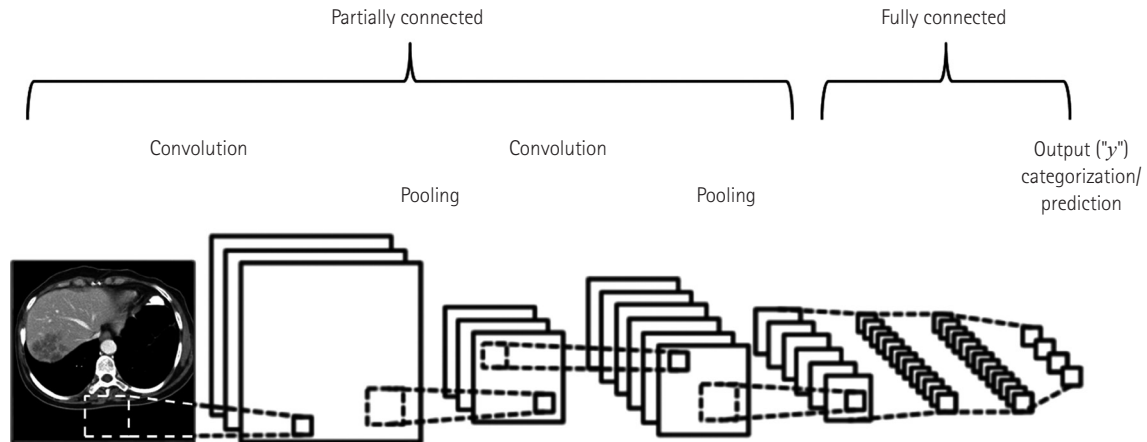
다층 퍼셉트론(multilayer perceptron) 인공신경망(artificial neural network)을 설명하기 위해 흔히 작은 원-노드(node)라고 함-들과 이 원들을 모두 서로 연결하는 화살표로 구성된 모식도를 이용한다(Fig. 1). 다층 퍼셉트론(multilayer perceptron)은 수학적으로 생각하면 입력 자료를 비선형 변환(non-linear transformation)을 통해 좀 더 고차원의 수학적 공간으로 사영(projection)하는 과정을 다층으로 쌓아 여러 번 반복하는 것으로, Fig. 1의 간단한 예에서 보면 첫 번째 층(layer)인 입력층(input layer)과 두 번째 층인 은닉층(hidden layer) 1의 연결을 위해 로지스틱 함수(logistic function)를 활성 함수(activation function)로 이용할 경우, 은닉층(hidden layer) 1의 각각의 노드(node)들과 입력층(input layer)의 4개의 노드(node)들에 해당하는 4가지  $x$  변수( $x_1 \sim x_4$ )들 간의 연결을 각각 개별적인 로지스틱 회귀 모형(logistic regression model)이라 생각할 수 있다, 즉, 빨간색, 녹색, 파란색, 검정색 연결들이 각각 하나의 로지스틱 회귀 모형(logistic regression model)을 형성한다. 로지스틱 회귀(logistic regression)를 이용한 통계분석에 익숙한 독자들은 이 부분에 대해서 의아하게 생각할 수 있다. 로지스틱 회귀(logistic regression)를 이용한 통계분석을 생각해 보면, 어떤 자료가 주어진 경우 한 세트의 자료로부터는 한 개의 로지스틱 회귀 모형(logistic regression model)을 만들게 되는데, 이와 달리 여기서는 4개의 로지스틱 회귀 모형(logistic regression model)을 ( $h_1 \sim h_4$ ) 만들고 있기 때문이다. 이는 인공신경망(artificial neural network)은 일반적인 통계학의 로지스틱 회귀(logistic regression) 분석과는 다른 방법으로 로지스틱 함수



**Fig. 1.** A diagram of artificial neural network consisting of multilayer perceptron. This simple diagram is for a conceptual explanation. When the logistic function is used as the activation function, the connection between all nodes (all  $x$  variables) in the input layer and one each node in hidden layer 1 makes a separate logistic function. Therefore, four different logistic functions ( $h_1$  to  $h_4$ ) marked by different colors (red, green, blue, and black) are created to connect the input layer to hidden layer 1 in this example. Other functions such as the tanh or the ReLU can be used as an activation function. Please see the main text for further explanations. ReLU = rectified linear unit, Tanh = hyperbolic tangent

(logistic function)를 이용하기 때문이다. 통상의 통계분석에서는 주어진 자료들을 로지스틱 함수(logistic function)로 가장 잘 설명해 낼 수 있는 가중치(weight) 값들을 구하는 분석을 해서 이를 통해 얻어진 가중치(weight)들로부터 하나의 로지스틱 회귀(logistic regression) 공식을 구하고 또  $e^{\text{weight}}$ 으로 어떤  $x$  변수에 해당하는 승산비(odds ratio)를 계산하게 된다. 반면, 인공신경망(artificial neural network)은 이러한 목적으로 로지스틱 함수(logistic function)를 이용하는 것이 아니고 단지 인공신경망(artificial neural network) 내의 이전 층(layer)의 입력 값들을 다음 층(layer)으로 변환 전달하는 수단으로서 로지스틱 함수(logistic function)를 이용한다. 이 예에서, 인공신경망(artificial neural network)이 만들어지는 실제 과정을 보면 처음에는 각 로지스틱 회귀 모형(logistic regression model)에 가중치(weight)를 무작위로 부여하여 서로 다른 4개의 로지스틱 회귀

모형(logistic regression model)들을 만든다. 이런 방법으로 “의미 없는” 임의의 계수들이 부여된 다수의 로지스틱 회귀 모형(logistic regression model)들을 여러 층으로 쌓아 전체 인공신경망(artificial neural network) 구조를 먼저 구성하고 나중에 전체 인공신경망(artificial neural network) 내의 무수히 많은 가중치(weight) 값들을 오차 역전파(back-propagation)라는 방법을 이용하여 모두 한꺼번에 차례로 맞추어 나가게 된다. 다층 퍼셉트론(multilayer perceptron)을 설명할 때 이해를 돕기 위해 로지스틱 함수(logistic function)를 활성화 함수(activation function)의 예로 들어 설명하는 경우가 많으나, 다른 함수들도 활성화함수(activation function)로 같은 방법으로 사용될 수 있다. 실제 로지스틱 함수(logistic function) 외에도 쌍곡탄젠트(hyperbolic tangent), 정류선형유닛(rectified linear unit) 함수 등이 활성화 함수(activation function)로 널리 쓰이고 있다. 은닉층



**Fig. 2.** A diagram of convolutional neural network. This simple diagram is for a conceptual explanation. A typical convolutional neural network algorithm contains a much greater number of convolution and pooling steps and layers. Adapted from a background image available on the Internet (14).

(hidden layer) 1에서 다음 층(layer)으로의 진행도 이상의 설명과 같은 방법으로 이루어지며, 입력층(input layer)에서 은닉층(hidden layer) 1로 진행하는 것과의 차이점은  $x_1 \sim x_4$  대신에 계산을 통해서 얻어진 새로운 변수들인  $h_1 \sim h_4$ 가 이용된다는 점이다. 이러한 다층의 반복적인 비선형 변환(non-linear transformation)을 통해 원래의 입력 자료 그대로는 구분해 낼 수 없는  $y$  값들도 구분해 낼 수 있게 되며, 이는 딥러닝(deep learning)이 과거의 다른 통계학적 모형화(statistical modeling) 방법들보다  $y$  값들을 더 정확하게 구분해 낼 수 있는 중요한 이유 중 하나이다. 반면, 이는 과적합(overfitting)을 일으키는 약점이 되기도 한다(이에 대해서는 뒤에서 다시 설명한다). 다층 퍼셉트론(multilayer perceptron)이 어떤 원리로 작동하는지를 직접 경험해 보기 위해서는 Google이 제공하는 “Neural Network Playground”라는 간단히 직접 실행을 해 볼 수 있는 웹 사이트(<http://playground.tensorflow.org>)가 유용하다.

### 컨볼루션 신경망(Convolutional Neural Network)

컨볼루션 신경망(convolutional neural network)은 서론에서 잠깐 기술한 바와 같이 영상분석에 사용되는 딥러닝(deep learning) 기술의 대표적 방법이다. 최근 컨볼루션 신경망(convolutional neural network)을 다양한 의학영상 분석에 적용한 임상 연구 논문들이 다수 출간되었다(6-13). 컨볼루션 신경망(convolutional neural network)은 크게 두 부분으로 구성되며(Fig. 2) 앞에서 설명한 다층 퍼셉트론(multilayer perceptron) 구조의 심층 신경망(deep neural network)이 전체의 뒷부분에 나오며 앞쪽은 컨볼루션(convolution)과 풀링(pooling)과정의 조합으로 구성되는 다른 형태의 심층 신경망(deep neural network) 구조로 구성되어 있다. 앞쪽의 컨볼루션(convolution)과 풀링

(pooling) 부분도 다층 퍼셉트론(multilayer perceptron)과 마찬가지로 원과 화살표로 구성된 모식도를 이용하여 표현할 수도 있으나 수학적 연산과정이 다층 퍼셉트론(multilayer perceptron)과는 달라 Fig. 2에 보이는 바와 같이 개념적인 그림으로 설명하는 것이 좀 더 편리하고 이해가 쉽다. 또한, 이 컨볼루션(convolution)과 풀링(pooling) 부분은 다층 퍼셉트론(multilayer perceptron) 구조와는 달리 인공신경망(artificial neural network)의 층(layer)과 층(layer)간의 연결 방식이 이전 층(layer)의 모든 노드(node)들을 다음 층(layer)의 모든 노드(node)들에 연결하는 것이 아니어서 다층 퍼셉트론(multilayer perceptron)을 “완전히 연결된(fully connected)”이라 설명하는 것과 달리 “부분적으로 연결된(partially connected)”으로 이야기한다. 컨볼루션(convolution)과 풀링(pooling) 부분이 하는 일을 개념적으로 설명하면, 컨볼루션(convolution)은 원래의 영상에 무수히 많은 영상 필터들을 씌워(예: 대조도를 강조하는 필터, 사물의 가장 자리를 강조하는 필터, 선형을 강조하는 필터 등) 변형된 새로운 영상들을 만들어 내는 것이고, 풀링(pooling)은 이렇게 만들어진 영상들을 크기를 줄이는(예:  $1000 \times 1000$  화소를  $100 \times 100$  화소로 줄임) 것이다. 이런 과정을 여러 번 반복해서 하나의 영상으로부터 그 영상의 개별 특징들을 각각 보여주는 매우 많은 수의 작은 영상들을 만들어 내게 된다. 영상이 컨볼루션 신경망(convolutional neural network)에 투입될 때 영상 내의 개별 화소들이 개별  $x$  변수로 입력이 되고 이 과정에서 개별 화소들의 영상 내 위치 정보는 포함되지 않고 단순한 선형벡터의 형태로 자료가 입력되게 되는데, 반복적인 컨볼루션(convolution)과 풀링(pooling)을 통해 얻어진 여러 개별적 영상 특징들을 보여주는 다수의 작은 영상들이 화소의 위치 정보를 대신한다고도 생각할 수 있다. 영상을 분석하는 컨볼루션 신경망

(convolutional neural network)은 한 영상 내 화소의 개수를 생각할 때 기본적으로 매우 많은 수의  $x$  변수를 포함하는 모형이고 더구나 컨볼루션(convolution) 과정에서 많은 수의 새로운 변형된 영상들이 생성되므로 일반적으로 무수히 많은  $x$  변수를 포함하리라는 것을 쉽게 예상할 수 있다. 이러한 모형을 고차원(high-dimensional) 또는 과모수화(overparameterized) 모형이라 하며 이는 과적합(overfitting)이란 문제를 야기한다(이에 대해서는 뒤에서 다시 설명한다). 컨볼루션 신경망(convolutional neural network)에 대한 좀 더 자세한 설명을 위해서는 Supplementary Material (in the online-only Data Supplement)의 참고 자료를 찾아보기를 권한다.

### 인공지능 알고리즘의 임상검증

인공지능을 임상 진료에 도입하기에 앞서 꼼꼼한 체계적 임상 검증을 하는 것이 매우 중요하다. 의학적 진단 및 예측을 위한 인공지능 알고리즘에 대한 많은 연구들이 발표되고 있음에도 불구하고 현재까지 제대로 된 임상검증의 사례는 매우 드물며, 최근 의학/과학 분야의 주요 학술지들이 의료인공지능에 대한 체계적인 임상검증이 이루어지지 않는 문제를 지적하고 있다(2, 5). 인공지능 기술은 의학/의료 분야에 다양한 방식으로 적용될 수 있으며, 의학영상 분야 내에서도 여러 가지 용도로 이용될 수 있다. 분류(classification, 예: 앞서 설명한 예와 같이 간세포포암과 간세포포암이 아님을 구분), 영상 분할(segmentation, 예: 전체 영상에서 간을 자동으로 분리하여 간의 부피 측정을 자동화할 수 있도록 함), 컴퓨터보조검출(computer-assisted detection) 방식의 병변 자동 검출, 모의(simulation) 영상(예: 저선량 전산화단층촬영 영상으로부터 인공지능을 이용하여 가상의 보통 선량 전산화단층촬영 영상과 유사한 영상을 만들어 냄) 등이 대표적인 사례이다. 의학 전체 분야를 생각해 보면 인공지능을 이용한 분류(classification)에 현재 가장 관심이 집중되고 있다. 이는 빅데이터(big data)와 인공지능을 이용한 분류(classification)가 정밀의료(precision medicine)의 근간이 되기 때문이다(예: 어떤 치료 약제에 대해 좋은 반응을 보일 암과 그렇지 못할 암을 치료 전에 구분/예측하고자 함).

의학적 진단 및 예측을 위한 분류(classification) 방식 인공지능 알고리즘의 정확도 평가는 통상 수신자 조작 특성(receiver operating characteristic) 분석을 이용한다. Receiver operating characteristic (이하 ROC) 분석법에 대한 자세한 내용은 이미 출간된 여러 좋은 논문들을 참고할 수 있으며 또한 Supplementary Material (in the online-only Data Supplement)의 해당 자료를 참고하기 바란다. 의학적 진단 및 예측을 위한 분류(classification)

방식 인공지능 알고리즘의 정확도를 올바르게 검증하기 위해서는, 과적합(overfitting, 알고리즘이 학습데이터 내에서는 정확하나 학습에 사용되지 않은 외부 데이터에서는 정확도가 떨어지는 현상), 스펙트럼 효과(spectrum effect), 유행률 효과(prevalence effect)가 인공지능 알고리즘의 성능 평가에 어떤 영향을 미치고 어떤 바이어스(bias)를 유발할 수 있는지 잘 이해할 필요가 있으며 이러한 바이어스(bias)를 피하여 정확한 성능 평가를 하는 것이 매우 중요하다(15). 과적합(overfitting)은 자료를 보다 깊이 탐색하고 기존에 인지하지 못하였던 새로운 연관성의 확인을 통해 새롭고 좀 더 정확한 인공지능 알고리즘을 개발하는 측면에서 도움을 줄 수도 있으나, 알고리즘을 성능을 임상적으로 평가하는 관점에서 보면 알고리즘의 정확도를 과장하는 문제를 일으킬 수 있다. 딥러닝(deep learning)에는 과적합(overfitting)을 줄이기 위한 방법들이 적용되고 있으나(16) 이를 통해 과적합(overfitting) 문제가 항상 충분히 해결된다고 보장할 수 없다. 또한, 딥러닝(deep learning) 알고리즘 개발에 사용되는 자료들은 보통 편의적으로 환자-대조군 방식으로 수집되는 경우가 많아 스펙트럼에 의한 바이어스(spectrum bias)에 취약하다. 과적합(overfitting)과 스펙트럼에 의한 바이어스(spectrum bias)는 모두 인공지능 알고리즘의 정확도와 일반화 가능성을 크게 과장할 수 있으므로 알고리즘의 임상검증 과정에서 반드시 꼼꼼히 검토해야 하는 부분이다. 보다 자세한 설명을 위해서는 Supplementary Material (in the online-only Data Supplement)의 관련 참고자료를 보기 바란다. 특히, 딥러닝(deep learning) 방식의 알고리즘은 알고리즘이 제시하는 결과에 대해서 왜 그러한 결과가 나왔는지 명확한 설명을 하기 어려운 “black box” 성격을 가지고 있어 임상검증에 있어 보다 엄격한 평가가 요구된다. 딥러닝(deep learning) 알고리즘이 제시하는 결과가 나온 이유를 가능한 어느 정도 직관적으로 이해할 수 있도록 도와주는 “black box” 문제를 보완하기 위한 방법들이 일부 제시되어 있다(예: attention map, saliency region). 향후 이 분야에 더 많은 발전이 있으리라 기대하며 이러한 방법들에 대한 발전과 이해가 향후 딥러닝(deep learning) 알고리즘의 임상검증에 추가로 도움을 줄 수 있을 것이다.

영상 분할(segmentation)과 컴퓨터보조검출(computer-assisted detection) 알고리즘의 정확도를 평가하기 위해서는 앞의 설명과는 다른 별도의 통계분석 방법 및 지표가 이용되며, 분할(segmentation)은 Dice coefficient와 Jaccard coefficient가, 컴퓨터보조검출(computer-assisted detection) 알고리즘은 free-response ROC 분석이 주로 이용된다. 이러한 통계학적인 방법들에 대한 구체적인 내용은 Supplementary Material (in the online-only Data Supplement)의 참고자료에서 찾아볼 수 있다.

## 의료인공지능 시대 의사의 역할과 이를 위한 대비

서론에서 이야기 한 바와 같이 인공지능이 영상학과 의사를 포함한 의료인을 대체한다는 것은 피상적인 과장에 불과하다. 이제는 이러한 피상적 과장의 시기를 지나 의료의 전문가로서 보다 객관적이고 넓은 관점에서 인공지능 기술을 바라볼 필요가 있다. 인공지능 기술의 의학/의료에의 도입은 임상 진료에 있어 실수와 변이를 줄이고 효율을 높이며, 많은 시간과 단순 반복적인 노력을 필요로 하는 일을 감소시켜 줌으로써 의료인들이 더 복잡한 진료 행위에 보다 효과적으로 집중할 수 있도록 하고, 영상데이터의 분석도 현재의 해부학적 분석 외에 다양한 정량적 분석들을 보다 쉽게 활용할 수 있도록 도와줄 것으로 기대된다. 의학 지식과 자료의 지속적인 빠른 증가와 영상기술의 발전으로 인해 과거의 진료 방식만으로는 증가하는 정보들을 충분히 효율적으로 환자 진료에 이용하는 것이 점점 더 어려운 상황이 되어가고 있다. 따라서, 가까운 미래에 의료인들이 수많은 정보를 충분히 활용하여 환자들에게 보다 양질의 진료를 제공하기 위해서는 현재까지의 임상 진료와는 달리 좀 더 발전된 “smart digital assistant”가 반드시 필요할 것으로 생각되며 의료인공지능 기술이 이러한 역할을 할 수 있을 것이라 기대해 본다. 의료인공지능 시대에 부합하는 의료전문가로서 인공지능 기술을 적절히 활용하여 의료를 발전시키고 궁극적으로 환자 진료에 보다 많은 도움을 주기 위해서는, 앞서 설명한 인공지능 기술과 관련된 여러 지식들을 습득하는 것 외에도 의료 발전에 있어 인공지능 기술의 역할과 한계에 대한 올바른 폭넓은 시각을 갖는 것이 중요하다. 아울러, 인공지능이 의학/의료에 도움을 주는 방향으로 개발, 발전, 도입되기 위해서는 의료인들의 적극적인 관심과 참여가 필요하다. 의료인은 의료인공지능 도구의 개발에서 활용의 전 과정에 걸쳐 의학적 경험/지식에 기반한 자문 및 방향 제시, 사용되는 데이터의 질 관리 및 환자 정보 보호, 엄격한 임상검증, 임상 활용 결과에 대한 관찰/감시를 해야 할 의무가 있다. 영상의학 관련 생물 정보학(bioinformatics) 분야의 대가인 University of Chicago의 Dr. Paul Chang의 말을 인용하면 “We have to be in the driver seat in this. If we are not in the driver seat, people will make mistakes and patients will get hurt (<https://www.youtube.com/watch?v=4b0t7TzjRZE>).”라는 말로 의료인공지능과 관련하여 의료인들의 적극적 관심과 참여의 중요성을 잘 요약하고 있다. 의료인공지능 시대를 대비하는 영상학과 의사로서 이 새로운 기술을 어떤 시각에서 바라보고 어떤 대비를 해야 하는가에 대하여 좀 더 풍부한 내용을 원하는 독자들은 Supplementary Material

(in the online-only Data Supplement)의 참고자료들을 보기를 권한다.

## 결론

인공지능 기술이 가까운 미래에 의료 분야에 많은 영향을 미칠 것으로 예상된다. 인공지능이 영상학과 의사를 포함한 의료인을 대체한다는 것은 피상적인 과장에 불과하다. 이제는 이러한 피상적 과장의 시기를 지나 보다 객관적이고 넓은 관점에서 인공지능 기술을 바라볼 필요가 있다. 의료인공지능 시대에 부합하는 의료전문가로서 인공지능 기술을 적절히 활용하여 의료를 발전시키고 궁극적으로 환자 진료에 보다 많은 도움을 주기 위해서는 인공지능 기술에 대한 기본 지식, 의료인공지능 기술의 올바른 임상검증을 위한 방법론, 그리고 의료 발전에 있어 인공지능 기술의 역할과 한계에 대한 폭넓은 시각을 습득할 필요가 있다. 아울러, 인공지능이 의학/의료에 도움을 주는 방향으로 개발 발전 도입되기 위해서는 의료인들의 적극적인 관심과 참여가 필요하다. 이 논문의 내용과 논문에 소개된 여러 유관 문헌 및 참고자료들이 이러한 지식의 습득 및 의료인공지능에 대한 올바른 이해와 판단을 갖추는 데 도움이 되기를 바란다.

## Acknowledgments

This work was supported by the Industrial Strategic technology development program (10072064) funded by the Ministry of Trade Industry and Energy (MOTIE, Korea).

## Supplementary Materials

The online-only Data Supplement is available with this article at <http://dx.doi.org/10.3348/jksr.2018.78.5.301>.

## REFERENCES

1. Lee JG, Jun S, Cho YW, Lee H, Kim GB, Seo JB, et al. Deep learning in medical imaging: general overview. *Korean J Radiol* 2017;18:570-584
2. Obermeyer Z. Interview with Dr. Ziad Obermeyer on how collaboration between doctors and computers will help improve medical care. Available at: [http://www.nejm.org/action/showMediaPlayer?doi=10.1056%2FNEJMp1705348&aid=NEJMp1705348\\_attach\\_1&area=](http://www.nejm.org/action/showMediaPlayer?doi=10.1056%2FNEJMp1705348&aid=NEJMp1705348_attach_1&area=). Published 2017. Accessed Apr 20, 2018
3. The Lancet. Artificial intelligence in health care: within

touching distance. *Lancet* 2017;390:2739

4. Beam AL, Kohane IS. Big data and machine learning in health care. *JAMA* 2018;319:1317-1318
5. No authors listed. AI diagnostics need attention. *Nature* 2018;555:285
6. Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA* 2016;316:2402-2410
7. Ting DSW, Cheung CY, Lim G, Tan GSW, Quang ND, Gan A, et al. Development and validation of a deep learning system for diabetic retinopathy and related eye diseases using retinal images from multiethnic populations with diabetes. *JAMA* 2017;318:2211-2223
8. Ehteshami Bejnordi B, Veta M, Johannes van Diest P, van Ginneken B, Karssemeijer N, Litjens G, et al. Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer. *JAMA* 2017; 318:2199-2210
9. Chen PJ, Lin MC, Lai MJ, Lin JC, Lu HH, Tseng VS. Accurate classification of diminutive colorectal polyps using computer-aided analysis. *Gastroenterology* 2018;154:568-575
10. Lakhani P, Sundaram B. Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks. *Radiology* 2017;284:574-582
11. Larson DB, Chen MC, Lungren MP, Halabi SS, Stence NV, Langlotz CP. Performance of a deep-learning neural network model in assessing skeletal maturity on pediatric hand radiographs. *Radiology* 2018;287:313-322
12. Yasaka K, Akai H, Abe O, Kiryu S. Deep learning with convolutional neural network for differentiation of liver masses at dynamic contrast-enhanced CT: a preliminary study. *Radiology* 2018;286:887-896
13. Yasaka K, Akai H, Kunimatsu A, Abe O, Kiryu S. Liver fibrosis: deep convolutional neural network for staging by using gadoteric acid-enhanced hepatobiliary phase MR images. *Radiology* 2018;287:146-155
14. Clarifai, Inc. Available at: <https://www.clarifai.com/technology>. Accessed Apr 18, 2018
15. Park SH, Han K. Methodologic guide for evaluating clinical performance and effect of artificial intelligence technology for medical diagnosis and prediction. *Radiology* 2018;286: 800-809
16. Chartrand G, Cheng PM, Vorontsov E, Drozdal M, Turcotte S, Pal CJ, et al. Deep learning: a primer for radiologists. *Radiographics* 2017;37:2113-2131

## 의료인공지능: 인공지능 초심자를 위한 길라잡이

박 성 호\*

인공지능 기술이 가까운 미래에 의료에 많은 영향을 미칠 것으로 예상된다. 하지만 인공지능 기술이 의학/의료 분야에 소개된 이후 많은 과장이 있었음을 부인할 수 없다. 실제로, 인공지능 기술의 임상 적용은 아직 초기 단계에 있으며 현재 임상 진료에 널리 쓰이고 있는 것은 거의 없다. 인공지능 기술을 적절히 활용하여 의료를 발전시키고 궁극적으로 환자 진료에 보다 큰 도움을 주기 위해서는, 이러한 피상적 과장을 넘어 보다 객관적이고 올바른 인공지능 기술을 바라보아야 한다. 인공지능이 의학/의료에 도움을 주는 방향으로 개발 도입되기 위해서는 의료인들의 적극적인 관심과 참여를 통한 방향 제시가 필요하다. 이를 위해, 의료인들은 인공지능 기술에 대한 기본 지식, 의료인공지능 기술의 올바른 임상검증 방법론, 그리고 의료 발전에 있어 인공지능 기술의 역할과 한계에 대한 폭넓은 시각을 습득하여야 한다. 이 논문은 인공지능을 잘 모르는 의료인들에게 이러한 내용에 대해 설명하고 공부에 도움이 되는 유용한 논문들과 인터넷 자료들을 소개하고자 한다.

울산대학교 의과대학 서울아산병원 영상의학과, 영상의학과 연구소