

A Comparative Study of Shallow Learning with Deep Learning Neural Networks on Fire Accident Prediction for Industrial Facilities

Woo Il Choi⁺, Dae Won Jang, Yon Soo Kim

⁺ Research & Development Center, LIG System, 442 Bongeunsa-ro, Gangnam-gu, Seoul, Korea

Abstract

The shallow learning neural network (SNN) has some limitations in the assessment of fire risk of industrial facilities due to its inherent problems such as over-fitting and gradient vanishing. However, in recent years, it has become possible to build a deep learning neural network (DNN) consisting of multiple hidden layers and to make learning algorithms more sophisticated, which allows for the use of a fire risk assessment tool in the fire insurance. In this paper, prediction performances between SNN and DNN are compared under various conditions using Google's Tensorflow. As a result, most SNN problems are solved through the drop-out method and ReLU activation function in DNN, and the learning performance of DNN with a maximum TS value of 0.76 is confirmed to be 58% higher than that of SNN. Nevertheless, in order to improve the utilization of fire insurance as a risk management tool, a systematic and large amount of learning data should be secured.

Key words: fire insurance, DNN, tensorflow, drop-out, ReLU

1. 서론

보험산업에서 기계학습은 보험가입 대상의 위험을 평가하고 요율을 산정하는 위험관리업무에서 폭넓게 활용되고 있다(Nikolopoulos & Duvendack 1994; Golibersuch, *et. al.*, 1995). 특히 화재보험에서 위험 평가는 화재를 유발하는 인자들과 화재발생 간에는 비선형적 인과관계를 가지기 때문에 기계학습 중 비선형적 통계기법인 인공신경망의 활용이 적합하다(Choi, *et. al.*, 2017). 인공신경망이란 뇌신경의 패턴을 모방하여 학습하는 모델의 전반을 가리키며, 생물학적 신경

망에서 뉴런이 학습을 통해 시냅스의 결합강도를 변경 하듯이 인공신경망은 노드의 연결가중치를 변경하여 학습된 결과값을 도출한다. 인공신경망의 학습알고리즘은 대부분 지도학습(supervised learning)으로 입력값과 출력값을 미리 알고 있는 상태에서 수행되며, 먼저 전방계산으로 초기 오류를 산정한 후 출력층에서 반대방향으로 진행하면서 오류값이 줄어들도록 하는 경사하강법(Gradient Descent)을 이용하여 연결가중치를 갱신하는데, 이를 오류 역전파 알고리즘(Error Back-Propagation Algorithm)이라고 한다(Oh, 2008). 인공신경망의 구조는 <Figure 1>과 같이 입력층(Input

⁺ Corresponding author: Woo Il Choi, Tel. +82-2-6900-6806, Fax. +82-2-6900-6860, e-mail. wooil.choi@ligcorp.com

layer), 출력층(Output layer) 그리고 입력층과 출력층 사이에 위치한 은닉층(Hidden layer)으로 구성되어 있는데, 기존의 인공신경망은 대부분 하나의 은닉층을 가지고 있기 때문에 이를 얇은 인공신경망(Shallow learning neural network, SNN)이라고 한다.

SNN을 이용한 화재위험성 평가는 대부분 산림화재의 공간적 위험성을 연구하는데 한정되어 있다(Christos, et al., 2009; Li, et al., 2009; Youssef & Abdelaziz, 2013). 산업시설의 화재예측을 위한 인공신경망 구축은 Choi, et al.(2017)에 의해서 수행된 바가 있다. 이 연구에서는 하나의 은닉층을 가지는 SNN을 구축한 후 282개의 화재이력이 있는 사업장을 포함하여 총 582개의 산업시설 사업장의 위험실사결과를 학습데이터로 활용하여 SNN의 학습성능을 검증하였다. 이 연구 결과에 따르면, 검증 데이터의 예측정중률(Hit Ratio, H)은 0.73으로 비교적 높게 나타났으나 실제 화재이력이 있는 사업장의 예측정확도를 나타내는 위험점수(Threat score, TS)는 0.47로 낮은 학습 성능을 나타냈다. 이는 기존의 SNN 학습이 과도한 학습유연성으로 인하여 위험실사를 수행한 사업장의 학습결과가 화재가 발생한 사업장을 대상으로는 일반화되지 못한다는 것을 의미한다. 그러나 화재보험에서 위험평가는 모든 산업시설에 대한 대표성보다 화재가 발생하거나 발생할 수 있는 사업장의 대표성을 파악하는 것이 더 중요하기 때문에, Choi, et al.(2017)에 의해서 수행된 SNN의 학습성능은 화재보험의 위험 평가도구로서 뚜렷한 한계를 가진

다. 산업시설의 화재를 유발하는 변수는 다양하고, 변수간의 상관관계는 매우 복잡한 비선형관계를 관계를 가진다. 따라서 화재보험의 위험 평가도구로서 인공신경망의 활용성을 높이기 위해서는 은닉층을 다층으로 구성하여 보다 복잡한 모델링이 가능하도록 하는 동시에 과도한 학습유연성을 억제하여 화재 발생 가능성이 있는 사업장의 대표성을 추출하는 것이 필수적이다. 본 논문은 먼저 산업시설의 화재발생예측에 있어서 기존의 SNN의 문제점을 검토하였고, 은닉층을 다층으로 하는 깊은 인공신경망 (Deep learning Neural Network, DNN)을 다양한 조건으로 구축하여 학습을 수행한 후 SNN과 비교하여 학습성능이 얼마나 개선되었는가를 비교하고자 하였다. DNN의 구축은 Google사에서 오픈소스로 배포한 텐서플로우를 이용하였다.

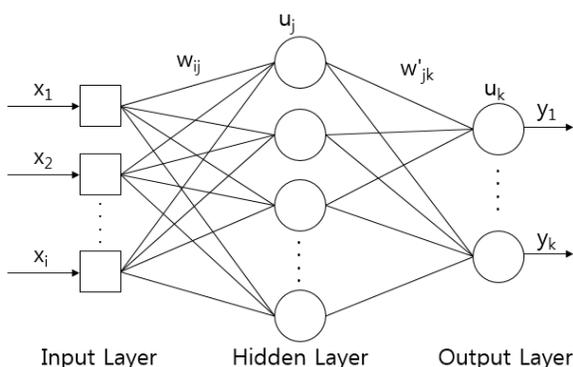
II. 기존 얇은 신경망의 한계

1. 과적합(Over-fitting)

앞서 언급한 SNN의 과도한 학습유연성은 제한된 학습데이터에서 노이즈까지 과하게 학습되어 학습데이터에서의 오차가 최소화됨에도 불구하고 검증 또는 실제 데이터에 대한 오차는 오히려 증가하는 현상에서 비롯된 것으로 이를 과적합이라고 한다. 이는 학습과정에서 최종오차가 전역최솟값(Global minima)에 도달하지 못하고 지역최솟값(Local minima)에 갇히는 현상과 밀접한 관련이 있다. 오류역전파알고리즘을 통한 학습과정은 결과값의 오차를 줄여나가기 위하여 Eq.(1)과 같이 연결가중치(w)에 따른 오차(E)를 편미분한 후 기울기가 낮은 방향으로 조금씩 이동하는 과정을 극값에 이를 때까지 반복하는 경사하강법을 이용한다(Rojas, 2013).

$$\nabla E = \left(\frac{\partial E}{\partial w_1}, \frac{\partial E}{\partial w_2}, \dots, \frac{\partial E}{\partial w_\ell} \right) \quad (1)$$

경사하강법에서 연결가중치 w는 Eq.(2)와 같이 증분을 이용하여 갱신되는데, 여기서 γ 는 각 단계에서



※ Source: Choi, et al.(2017)

Figure 1. Structure of shallow learning neural network

편미분된 가중치를 얼마만큼 반영할 것인가를 나타내는 학습률(Learning Rate)을 뜻한다.

$$\Delta w_i = -\gamma \frac{\partial E}{\partial w_i} \quad \text{for } i = 1, \dots, \ell \quad (2)$$

이 때 학습률이 큰 경우에는 오차값이 가장 작은 전역 최소값을 피하게 되며, 학습률이 작으면 지역최소값에 수렴하여 갇히게 되는데 이와 같은 현상이 SNN에서 과적합을 유발하는 주요한 원인이 된다(〈Figure 2〉).

2. Gradient Vanishing

역전파 알고리즘에서 경사하강법으로 학습을 할 경우 활성화함수를 미분하는 과정이 필요하다. 시그모이드 함수(Sigmoid Function)는 전 구간에서 미분이 가능하고 특정 입력변수가 과도하게 영향력을 행사하는 것을 미연에 예방하는 장점이 있기 때문에 기존의 SNN에서는 Eq. (3)과 같이 표현되는 시그모이드함수를 활성화함수로 채택하여 사용하여왔다.

$$\Phi(z) = \frac{1}{1 + \exp(-\sigma z)} \quad (3)$$

그러나 시그모이드의 미분함수는 Fig 3에서 보는바와 같이 최대값이 0.25이고 양끝으로 갈수록 0에 가까워지므로 은닉층을 다층으로 구성된 신경망으로 학습

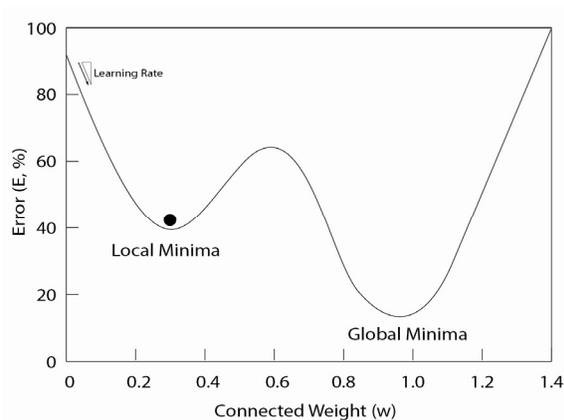


Figure 2. An example of local minima problem in gradient descent method

할 경우 연결가중치는 0에 수렴하게 되고 결국 신경망이 작동하지 않는 Gradient Vanishing 현상이 발생한다(Bengio, *et. al.*, 1994). 화재유발인자와 화재발생간의 복잡하고 다양한 인과관계를 일반화하기 위해서는 은닉층을 다층으로 구성하는 DNN의 구축이 필수적이다. 그러나 Gradient Vanishing 현상으로 인하여 기존의 인공신경망은 은닉층을 한 개의 층으로만 구축할 수밖에 없는 한계를 가지고 있기 때문에 복잡한 인과관계를 반영하지 못하고 낮은 예측정중률을 보이게 된다.

III. 깊은 인공신경망 구축

1. 텐서플로우 개요

텐서플로우(Tensorflow)는 기계학습과 DNN의 연구를 목적으로 Google사에서 개발된 오픈소스 라이브러리 시스템으로 2015년 최초로 일반에게 공개되었다. 텐서플로우에서의 연산은 노드(Node)로 구성된 Data-flow 그래프로 설명할 수 있는데, 여기서 각각의 노드(node)는 수학적 연산을 나타내고 노드를 연결하는 엣지(edge)는 다차원 배열의 텐서를 나타낸다(Abadi, *et. al.*, 2016). 깊은 인공신경망 알고리즘은 DNN(Deep Neural Network) 뿐만 아니라 음성인식, 기계번역 등 입력과 출력이 모두 시퀀스인 RNN(Recurrent Neural Network), 합성곱 계층과 풀링 계층이 추가되어 영상분석에 적합한 CNN(Convolutional Neural Network) 등 다양한 학습 알고리즘이 존재하며,

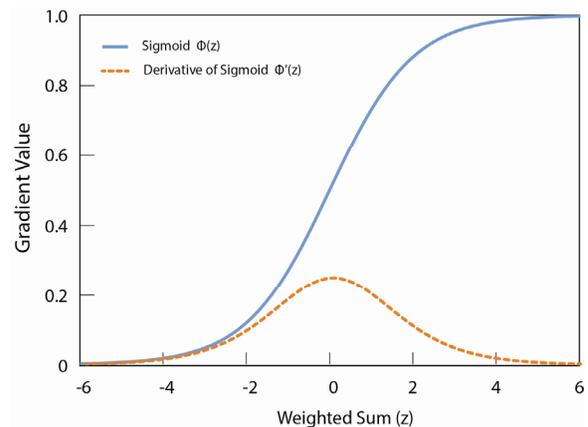


Figure 3. The relationship between the sigmoid and derivative of sigmoid

Table 1. Examples of representative algorithms provided in the tensorflow

Category	Examples of Representative algorithms
Element-wise mathematical operations	Add, Sub, Mul, Div, Exp, Log, Greater, Less, Equal, ...
Array operations	Concat, Slice, Split, Constant, Rank, Shape, Shuffle, ...
Matrix operations	MatMul, MatrixInverse, MatrixDeterminant, ...
Stateful operations	Variable, Assign, AssignAdd, ...
Neural-net building blocks	SoftMax, Sigmoid, ReLU, Convolution2D, MaxPool, ...
Checkpointing operations	Save, Restore
Queue and synchronization operations	Enqueue, Dequeue, MutexAcquire, MutexRelease, ...
Control flow operations	Merge, Switch, Enter, Leave, NextIteration

※ Source: Abadi, *et. al.*(2016)

텐서플로우는 DNN의 학습알고리즘 뿐 만 아니라 기계 학습과 관련되는 대부분의 알고리즘을 이미 구현하여 제공하고 있다. <Table 1>은 텐서플로우에서 제공하는 대표적인 알고리즘을 정리한 것이다.

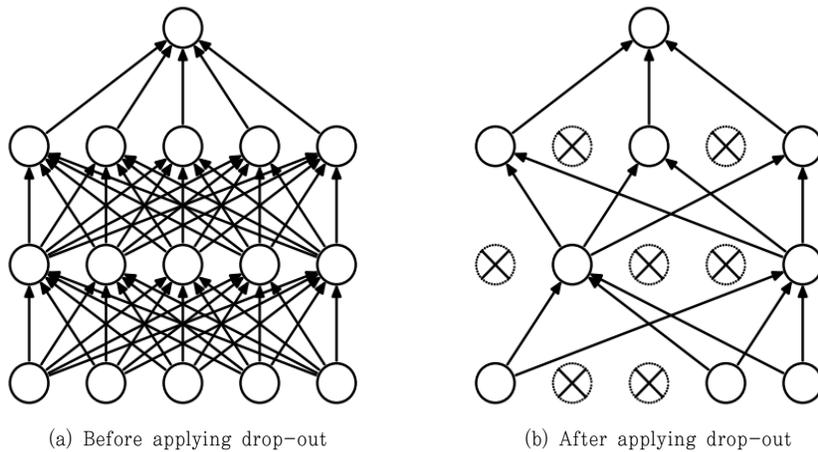
2. Drop-out 함수의 적용

최종오차가 지역최솟값으로의 수렴함으로써 발생하는 과적합의 문제는 DNN에서 Drop-out 함수의 적용을 통해 해결할 수 있다(Srivastava, *et. al.*, 2014). Drop-out 함수는 <Figure 4>와 같이 무작위로 일부 노드를 생략한 채 학습을 수행하는 것으로, 생략된 신경망의 학습이 끝나면 다시 무작위로 다른 노드를 생략하면서 반복적으로 학습을 수행하며 각각의 연결가중치들이 동일한 지역최솟값에 수렴하지 못하게 하고 중국에는 전역최솟값을 찾도록 유도하는 것이다.

Tensorflow에서는 Drop-out 함수를 이미 구현하여 제공하고 있기 때문에 DNN을 구축할 때 각층마다 활성화 함수를 호출한 후, 다음 층에 전달하기 전에 Drop-out 함수를 불러들이는 방식으로 일부 노드를 생략한 후 학습을 수행하였으며, 학습을 반복할 때 마다 노드의 생략비율을 조정하여 학습데이터의 정확도와 검증결과를 분석하여 최적의 생략비율을 도출하였다.

3. ReLU(Rectified Linear unit) 활성화함수 적용

본 연구에서는 DNN에서의 고질적인 문제점인 Gradient Vanishing 현상을 예방하기 위하여 활성화함수로 Rectified Linear unit(ReLU) 함수를 적용하였다. ReLU는 Hahnloser, *et. al.*(2000)에 의해서 처음 소개되었는데, 가중치가 곱해진 입력값이 0보다 작으면 출력값을 0으로 표출하고 입력값이 0보다 큰 경우에는



※ Source: Srivastava, *et. al.* (2014)

Figure 4. An example of a thinned neural network produced by dropout method

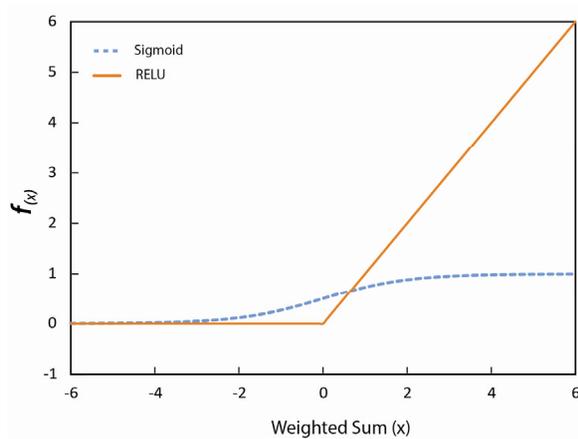


Figure 5. Comparison between ReLU and Sigmoid function

입력값을 그대로 출력값으로 표출하여 전자공학에서 활용되는 반파정류회로(half wave rectifier)의 전달곡선과 유사한 비대칭형태의 그래프로 나타낼 수 있다 (Eq. 4).

$$f(x) = \begin{cases} (x < 0), f(x) = 0 \\ (x \geq 0), f(x) = x \end{cases} \quad (4)$$

입력값이 0보다 큰 경우 ReLU 함수에서는 미분값이 항상 1이 되기 때문에 은닉층을 다층으로 구성한다고 할지라도 Gradient Vanishing 현상을 예방할 수 있으며 분석시간도 단축된다. 또한 0보다 작은 입력값에 대하여 출력값을 0으로 표출하기 때문에 학습과정에서 신경망을 임의로 초기화하더라도 은닉층의 유닛을 약 50%정도 활성화 시키는 등 기존의 활성화함수에 비해 다양한 이점이 있다(Glorot, et. al., 2011; Maas, et. al., 2013)(Figure 5)).

IV. 학습데이터의 구축

1. COPE Data의 수집

국내외의 보험사들은 산업시설의 화재보험을 인수할 때 건축특성(Construction), 업종 및 이용특성(Occupancy), 방재설비 및 위험관리현황(Protection) 및 외부노출(Exposure) 등 4가지 측면의 위험요인을 분석하여 작성된 위험실사보고서를 근거로 하여 위험성을 평가한

다(Baker, et. al., 2008). 이 때 수집되는 데이터를 COPE Data라고 하는데, 일반적으로 COPE Data는 Table 2와 같이 항목별 세분된 위험요인으로 분류될 수 있다.

위험실사보고서에 기술되어 있는 COPE Data의 세부위험요인은 NFPA 또는 ISO 등 국제기준을 근거로 위험등급이 나뉜다. 예를 들어 COPE Data 중 건축(Construction)측면은 건물의 구조(C1), 규모(C2), 면적(C3) 그리고 건물 이격거리(C4) 등으로 세분되어 평가하는데, 이 중 건축구조측면(C1)의 위험등급은 NFPA 220에서 제안하는 골조, 내외장재의 내화성능 등을 기준으로 5개의 등급으로 구분할 수 있다(NFPA, 2015). 그 밖에 업종·용도(Occupancy)측면은 사무동(O1), 공장동(O2), 창고동(O3)을 구분하여 각 시설에서 활용되는 원재료 및 기계 및 설비특성과 작업공정 중 위험물 사용 및 고온고압작업여부 등을 기준으로 위험성을 평가한다. 방재설비 및 위험관리현황(Protection)은 감지설비 및 소화설비 등 설비측면 뿐 만 아니라 화기작

Table 2. Classification of COPE data

Classification	Risk Factor	
	Code	Variables
Construction	C1	Building Structure
	C2	Construction Size
	C3	Construction Area
	C4	Building Arrangement
Occupancy	O1	Office Area
	O2	Process Area
	O3	Storage Area
	O4	Electrical Utilities
Protection	P1	Sprinkler System
	P2	Fire Detection System
	P3	Water Supply System
	P4	Other Fire Suppression System
	P5	Prevention Activities
	P6	Hazardous Materials Management
	P7	Hot Work Management
	P8	Smoke Controls
	P9	Safety Management
Exposure	E1	Local wildfire risk
	E2	Distance between nearest facility

업, 흡연관리 등 안전관리메뉴얼 및 작업자의 안전관리 교육 등을 평가하여 산정하고, 외부노출(Exposure)은 산불 및 인접한 시설에서 화재가 확산될 수 있는 위험을 평가하게 산정하게 된다. 그러나 각 보험사가 작성하는 위험실사보고서는 COPE Data의 세부위험요인 및 위험평가의 기준근거가 다소 상이하고, 업종에 따른 손해율이 보험사마다 차이가 있기 때문에 같은 시설에 대해 동일한 위험평가가 이루어지는 것은 아니다.

본 연구에서는 Choi, *et. al.*(2017)에서 수행된 SNN의 화재발생예측결과와 같은 학습조건에서 DNN의 예측정확도를 비교하기 위하여 동일한 학습데이터를 활용하였다. 수집된 위험실사자료는 총 3,448건이며, 이중 화재사고가 발생한 사업장은 282건으로 전체자료의 8%에 불과하다. 이러한 학습데이터의 불균형을 해결하기 위하여 화재사고가 발생하지 않은 시설 중 평가항목의 점수에 가중치를 주지 않을 경우 가장 높은 점수를 가지는 300건과 화재가 발생한 시설 282건의 위험실사 자료를 선택한 후 19개의 COPE Data 항목 중 산업시설의 화재발생과 상관관계가 낮은 건축면적(C3), 사무동의 위험특성(O1)과 인근지역의 산불위험(E1)과 인접시설의 이격거리(E2)를 제외한 15개의 항목을 추출하였다. 또한 입력층의 후보 독립변수가 많아서 생기는 가중치의 개수가 급격히 증가하는 문제를 사전에 예방하기 위하여 다중회기분석 및 전문가 의견을 종합하여 15개의 COPE Data 세부위험요인 중 유의수준이 높거나 중요도가 있는 9개의 위험요인을 다시 정제하여 인공신경망을 학습시켰는데, 본 논문에서도 동일한 위험요인을 DNN의 입력데이터로 적용하였다(〈Table 3〉).

확보된 데이터 중 80%는 학습데이터로 활용하였으며, 나머지 20%(무사고사업장 60개소, 화재사업장 58개소)는 DNN의 학습성능을 검증하는데 사용하였다.

2. DNN구축 및 학습

DNN 구축에 있어 모든 입력변수의 척도는 동일한 범위 내에 값을 갖도록 하는 전처리과정이 필요한데 이를 정규화(Normalization)라고 한다. 본 연구에서는 입

Table 3. Input variables of DNN

No.	Code	Input Variables
1	C2	Construction Size
2	C4	Building Arrangement
3	O2	Process Area
4	O4	Electrical Utilities
5	P2	Fire Detection System
6	P3	Water Supply System
7	P6	Hazardous Materials Management
8	P7	Hot Work Management
9	P8	Smoke Controls

력변수의 최솟값을 0으로 하고 최댓값을 1로 고정한 후 각 변수값을 0 ~ 1사이의 값으로 변환시키는 MinMaxScaler 함수를 이용하여 각 입력변수의 정규화를 수행하였다(Eq.5).

$$X_{norm} = \frac{X - X_{min}}{X_{max} + X_{min}} \quad (5)$$

은닉층은 3개층으로 구성하고 은닉층의 노드수는 기존 연구와 동일하게 $2d+1$ 개로 설정한 후 활성화함수로 ReLU함수를 적용하였다. Srivastava, *et. al.*(2014)의 연구결과에 의하면, 학습과정에서 은닉층을 무작위로 50%를 생략했을 경우 과적합이 최소화되는 것으로 나타났다으나 이는 모든 학습과정에 일반화되지는 않는다. 또한 50% 이상의 생략은 과소적합(Under-fitting)으로 인하여 예측정확도를 낮추는 문제를 야기시킨다. 이러한 점을 고려하여 본 연구에서는 각각의 은닉층마다 Drop-Out 함수를 이용하여 은닉층의 노드가 생략되지 않은 경우와 무작위로 10%, 20%, 30%, 40%, 50%를 생략시킨 경우 등 총 6가지의 경우를 구분하여 학습을 수행하였다. 출력층에서는 연결가중치를 통해 도출된 결과값은 화재발생유무에 따라서 2개의 클래스로 구분되어야 한다. 본 연구에서는 Tensorflow에서 제공하는 Softmax함수를 이용하여 화재유무를 구분하도록 하였다. Softmax함수는 Eq.(6)와 같이 각 클래스에 도출된 출력값을 지수함수에 도입한 후 정규화상수(Normalizing constant)를 나누어 가장 큰 값을 부여받은 클래스를 최

Table 4. Configurations of the DNN

Training Parameter	Value
Input Node	9
Hidden Layer	3
Hidden Node	19
Output Node	2
Learning Rate (α)	0.01
Normalization	MinMaxScaler
Drop-out Rate	0%, 10%, 20%, 30%, 40%, 50%
Activation Function	ReLU
Classifier	Softmax Function
Iterations	2,000

중 예측값으로 분류하도록 한다.

$$f(y)_i = \frac{\exp(y_i)}{\sum_{k=1}^n \exp(y_k)} \text{ for } i = 1, \dots, n \quad (6)$$

〈Table 4〉는 본 연구에서 적용된 DNN의 학습조건을 요약한 것이다.

V. 학습결과분석 및 성능평가 비교

각각의 모형에서 학습결과는 〈Table 5〉와 같이 예측결과 분할표를 작성하여 학습데이터의 결과정확도(Accuracy Rate, AR), 검증데이터의 예측정확도(H), 검증데이터 중 화재사업장의 예측적중률을 나타내는 위험점수(TS)

Table 5. 2×2 Contingency Table for Forecast Verification

Classification		Observation	
		Yes	No
Forecast	Yes	Hits (a)	False alarms (b)
	No	Misses (c)	Correct negative (d)

Table 6. Comparative verification between SNN and DNN

Classification	SNN	DNN					
		0%	10%	20%	30%	40%	50%
Drop-Out	-	0%	10%	20%	30%	40%	50%
Leaning Accuracy (AR)	0.81	0.87	0.87	0.83	0.82	0.82	0.82
Hit Rate (H)	0.73	0.75	0.85	0.83	0.75	0.77	0.70
Threat Score (TS)	0.48	0.67	0.76	0.74	0.64	0.64	0.56
Standard dev.	0.172	0.101	0.059	0.052	0.091	0.093	0.130

를 이용하여 학습조건별 과적합여부를 검토하고 학습 성능을 비교하였다.

화재가 발생한 시설의 비율은 전체 산업시설에 비해 미미한 수준이다. 따라서 위의 학습성능 평가기법 중 관측된 화재시설과 예측된 화재시설의 합에 대한 예측적중률을 나타내는 위험점수(TS)가 높을 경우 학습모형의 성능이 우수한 것으로 판단할 수 있다.

$$AR = \frac{\text{number of matched result}}{\text{total number of leaning data}} \quad (7)$$

$$H = \frac{\text{number of correct forecast}}{\text{total number of verification data}} = \frac{(a+d)}{n} \quad (8)$$

$$TS = \frac{\text{number of correct forecast}}{\text{number of firecase of verification data}} = \frac{a}{(a+b+c)} \quad (9)$$

각각의 학습조건에서 학습성능을 검증한 결과는 〈Table 6〉과 같다.

SNN에서의 TS는 0.48로 화재사업장에 대하여 절반 이하의 예측적중률을 보였으나 DNN는 Drop-out을 적용하지 않는 경우에도 TS가 0.67로 약 40% 학습성능이 향상되었고, 표준편차도 SNN보다 48% 줄어들어 것으로 나타났다. DNN 학습 시 표준편차는 최소화하는 Drop-out의 비율은 20%로 표준편차가 0.052였으며, Drop-out을 10% 적용하였을 때 TS가 0.76으로 학습성능이 가장 우수한 것으로 분석되었다. Drop-out 10% 및 20% 적용 시 학습성능 및 표준편차의 차이는 미미한 것으로 보인다. Srivastava, *et. al.*(2014) 등 기존의 선행연구에서 최적의 Drop-out 비율이었던 50%를 적용할 경우에는 표준편차가 0.13으로 20% 적용시보다 60% 증가하였고 TS도 0.56으로 학습성능이

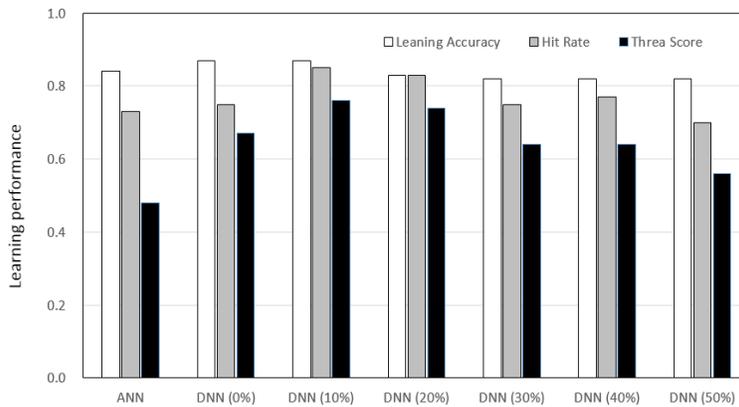


Figure 6. Learning performance between SNN and DNN

24% 저하된 것으로 나타났다. DNN은 기본적으로 블랙박스모형이기 때문에 선행연구와 Drop-out의 최적화 비율이 차이 나는 원인을 정량적으로 해석하는 것은 불가능하다. 다만 기존 선행연구가 이미지분석으로 많은 학습데이터와 복잡한 신경망구조로 설계된 것에 반하여 본 연구는 상대적으로 네트워크 구조가 단순하게 설계되었고 학습데이터가 582건으로 제한적이기 때문에 DNN 학습 시 은닉층의 노드를 20%이상 생략할 경우 과소적합(Under-fitting)현상이 발생하여 학습성능을 떨어뜨리는 것으로, 학습데이터가 증가할수록 최적의 Drop-out 비율은 점차 증가할 것으로 판단된다.

VI. 결론

본 논문에서는 화재보험에서 산업시설의 화재위험 평가도구로서 신경망의 활용성을 검토하기 위하여 다양한 조건의 DNN을 구축한 후 SNN과 학습성능을 비교하였다. 본 논문의 결론을 요약하면 다음과 같다.

(1) DNN 학습결과, 화재사업장 예측적중률을 나타내는 TS가 최대 0.74였다. 이는 SNN의 학습성능에 비해 약 58% 향상된 것으로 향후 위험평가에서 SNN보다 활용성이 높아졌다는 것을 의미한다.

(2) 기존 SNN의 과적합문제와 Gradient Vanishing 현상은 DNN에서 Drop-out의 적용과 활성화함수로 ReLU함수의 적용을 통해 해결될 수 있다.

(3) 본 연구에서 최적화된 Drop-out 비율dl 선행연

구의 50%보다 낮은 10~20%인 것으로 나타났다. 이러한 원인은 582개의 한정된 학습데이터로 인하여 Drop-out 비율을 20%이상 높일 경우 과소적합이 발생하기 때문이다.

화재보험에서 위험성평가는 단순히 화재발생가능성 뿐 만 아니라 발생빈도, 피해심도, 예방가능성 등을 종합적으로 검토하여야 한다. 또한 산업시설의 화재특성은 업종의 제조공정 프로세스와 설비의 설계기준 등이 큰 영향을 차지하는데 현재 국내의 보험사에서 수행하는 위험실사보고서는 이와 관련된 자료가 제한적으로 기재되어 있고 수집된 자료라 할지라도 대부분 비정형 데이터로 정형화된 데이터로 이루어지지 않는 경우가 많으며, 자료의 변환과정 중 발생하는 데이터 손실 등의 이유로 양질의 학습데이터를 확보하는 것이 어려운 실정이다. DNN이 기존의 화재위험성평가도구를 대체하기 위해서 향후 연구는 위험실사자료의 품질을 높이고 개별데이터에 대한 체계적인 관리방안과 병행되어야 하며 이를 기반으로 화재발생 이외에 다양한 관점에서 위험관리방안을 도출할 수 있도록 DNN의 구조를 고도화시켜야 한다.

감사의 글

본 연구는 정부(행정안전부)의 재원으로 재난안전기술 개발사업단의 지원을 받아 수행된 연구임 (MOIS-재난-2015-05).

References

- Abadi, Martín, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, Jeffrey Dean, and Matthieu Devin. 2016. *Tensorflow: Large-scale Machine Learning on Heterogeneous Distributed Systems*. ArXiv Preprint arXiv:1603.04467.
- Baker, Frank J. 2008. "COPE" & the "Rules of Engagement"-How Construction, Occupancy, Protection, Exposures and Firefighting Tactics Affect the Outcome of a Fire Emergency. *Paper Presented at ASSE Professional Development Conference and Exhibition, American Society of Safety Engineers*.
- Bengio, Yoshua, Patrice Simard, and Paolo Frasconi. 1994. Learning Long-term Dependencies with Gradient Descent Is Difficult. *IEEE Transactions on Neural Networks*. 5(2): 157-166.
- Choi, Woo Il, Yon Soo Kim, Dae Won Jang, Gil Ho Kim, and Yun Sub Jung. 2017. A Study on Development of Fire Risk Prediction Model in Manufacturing Facilities Using Artificial Neural Network. *Journal of the Korean Society of Hazard Mitigation*. 17: 161-167.
- Christos, V., K. Kostas, H. John, and M. Ioannis. 2009. Identifying Wildland Fire Ignition Factors through Sensitivity Analysis of a Neural Network. *Natural Hazards*. 50(1): 125-143.
- Glorot, Xavier, Antoine Bordes, and Yoshua Bengio. 2011. Deep Sparse Rectifier Neural Networks. *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, PMLR*. 15: 315-323.
- Golibersuch, David C., Rebecca Towne, and Cheryl A. Wiebe. 1995. GENIUSTM Automated Underwriting System: Combining Knowledge Engineering and Machine Learning. *Proceedings of Innovative Applications of Artificial Intelligence Conferences, Canada*. 7: 49-61.
- Hahnloser, Richard H., Rahul Sarpeshkar, Misha A. Mahowald, Rodney J. Douglas, and H. Sebastian Seung. 2000. Digital Selection and Analogue Amplification Coexist in a Cortex-inspired Silicon Circuit. *Nature*. 405(6789): 947-951.
- Li, Li-Ming, Wei-Guo Song, Jian Ma, and Kohyu Satoh. 2009. Artificial Neural Network Approach for Modeling the Impact of Population Density and Weather Parameters on Forest Fire Risk. *International Journal of Wildland Fire*. 18(6): 640-647.
- Maas, A. L., Awni Y. H., and Andrew Y. N. 2013. Rectifier Nonlinearities Improve Neural Network Acoustic Models. *Proceedings of International Conference on Machine Learning(ICML)*. 30(1): 3.
- NFPA. 2015. *NFPA-220: Standard on Types of Building Construction*. National Fire Protection Association, USA. 28
- Nikolopoulos, C. and S. Duvendack. 1994. A Hybrid Machine Learning System and Its Application to Insurance Underwriting. *Proceedings of the First IEEE Conference on Evolutionary Computation*. IEEE World Congress on Computational Intelligence. 2: 692-695.
- Oh, Il Seok. 2008. *Pattern Recognition*. Kyobo-book.
- Rojas, Raúl. 2013. *Neural Networks: A Systematic Introduction*. Springer Science & Business Media.
- Srivastava, Nitish, Geoffrey E. Hinton, Alex Krizhevsky, Ilya Sutskever, and Ruslan Salakhutdinov. 2014. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*. 15(1): 1929-1958.
- Youssef, Safi and Abdelaziz Bouroumi. 2013. Prediction of Forest Fires Using Artificial Neural Networks. *Applied Mathematical Sciences*. 7(6): 271-286.

Korean References Translated from the English

- 오일석. 2008. 패턴인식. 교보문고사.
- 최우일, 김연수, 장대원, 김길호, 정윤섭. 2017. 인공지능경망을 이용한 제조시설 화재위험 예측모델 개발 연구. 한국방재학회논문집. 17(1): 161-167.

Received: Nov. 27, 2017 / Revised: Feb. 6, 2018 / Accepted: Feb. 24, 2018

산업시설 화재사고예측에 대한 얇은 신경망과 깊은 신경망의 성능 비교 연구

국문초록 기존의 얇은 인공신경망은 과적합과 Gradient Vanishing 현상 등 내재적 문제점으로 인하여 산업시설의 화재 위험성 평가에 한계가 있었다. 그러나 최근 들어 은닉층을 다층으로 구성하는 깊은 신경망의 구축이 가능해지고 학습알고리즘이 고도화되면서 화재보험에서 화재위험성 평가도구로서 활용성이 높아졌다. 본 논문에서는 구글사의 텐서플로우를 이용하여 다양한 학습조건에서 깊은 신경망을 학습시켜 얇은 신경망의 예측성능과 비교하였다. 그 결과 깊은 신경망에서는 Drop-out 및 ReLU함수의 활용을 통해 기존의 SNN의 문제점을 해소할 수 있었으며 TS값이 최대 0.76으로 얇은 신경망보다 58% 높은 학습성능을 확인하였다. 그러나 화재보험에서 위험관리도구로서 활용성을 높이기 위해서는 체계적이고 많은 데이터가 확보되어야 한다.

주제어 : 화재보험, 깊은 신경망, 텐서플로우, Drop-out, ReLU

Profiles **Woo Il Choi** : He received his Ph.D from the Department of Civil Engineering at University of Seoul, Korea in 2013. He is a Senior Research Engineer of Research & Development Center at LIG System which he joined on 2005. His research concerns are disaster insurance, Insure-tech, catastrophe model and deep-learning(wooil.choi@ligcorp.com).

Dae Won Jang : He received his Ph.D from the Department of Civil Engineering from INHA University, Korea in 2010. He is a Principal Research Engineer of Risk Management Institute at LIG System Co.,Ltd. which he joined in 2015. His research concerns are Disaster management, Water Resource Engineering and Geospatial Information(daewon.jang@ligcorp.com).

Yon Soo Kim : His Ph.D was in Department of Civil Engineering from INHA University, Korea in 2016. He is a Research Engineer of Risk Management Institute at LIG System Co.,Ltd. which he joined in 2016. His research interests are in the areas of Water Resource Engineering, Climate Change and Big Data(yonsoo.km@ligcorp.com).