

심층 신경망 기법을 이용한 초기설계단계의 경하중량 추정

김기용(부산대학교), 반임준(부산대학교), 박병철(부산대학교), 오상진(부산대학교), 신성철(부산대학교)

Lightweight Estimation in Initial Design Stage Using Deep Neural Network Technique

Gi-yong Kim(Pusan National University), Im-jun Ban(Pusan National University),
Byeong-cheol Park(Pusan National University), Sang-jin Oh(Pusan National University),
Sung-chul Shin(Pusan National University)

Abstract

Lightweight, one of the most important factors to be determined in the ship design process. If lightweight and center of gravity are incorrectly estimated in the initial design, may incur additional costs for the use of lightweight materials. Scantling of additional ballast and member dimensions is required to adjust the center of gravity, and weight and center of gravity are determined by the combination of many weight factors. So initial estimation is difficult. Moreover the process is complicated as the process progresses. The purpose of this study is analyze existed vessels light weight data and to predict light weight using deep running that one of artificial neural network techniques at the beginning of design. Therefore, it is simpler and easier to estimate than the conventional method, so that the initial design stage time will be shortened and accuracy will be improved. Designer can efficiently perform the design work.

Keywords : Neural network(신경망), Deep learning(딥 러닝), Lightweight(경하중량), Initial design(초기 설계)

1. 서론

1.1 연구 배경 및 필요성

선박을 설계하기 위한 분류로 설계 진행과정(Process)에 따라 견적설계, 기본설계, 상세설계, 생산설계로 나뉘게 된다. 초기 설계 방식으로는 기존에 설계된 유사선(Parent ship)을 이용하여 설계선(Design ship)의 요구조건에 만족하도록 수정을 가해 설계하는 유사설계와 유사선이 없는 경우 신속하고 개략적인 설계단계에서부터 구체적이고 정밀한 설계단계로 반복하는 설계과정(Design spiral)을 거쳐 요구조건에 맞도록 접근시키는 신규설계로 나눌 수 있다(SNAK, 2015).

선박의 견적설계 및 기본설계의 최적화, 그리고 최종적인 설계와 건조의 성공 여부는 원가 및 성능을 고려한 적정 주요 치수의 선정, 선박의 정확한 경하중량(Light weight) 및 재화중량(Deadweight)의 추정 등을 통하여 결정된다. 선박의 경하중량은 경사시험 후 최종 결정되지만 원가 산정과 기본설계 시에 정확한 추정이 필수적으로 요구 된다. 경하중량은 크게 선체강재중량(Net hull steel weight), 의장품중량(Outfitting weight), 기관부중

량(Machinery weight)으로 구성되며, 이렇게 얻어진 중량에 필요한 적정 여유치(Margin)를 추가하게 된다,

실제 조선소에서는 위 선박설계 방법을 통하여 중량추정과 중량통제 하는 것을 매우 중요하게 취급하고 있고, 선박수주를 목적으로 하는 영업과정 초기의 견적설계에서 경하중량 추정은 선가와 선박의 기본성능과 맞물려 중요한 의미를 지닌다.

1.2 연구방법

현재 조선소에서의 초기 경하중량 추정은 기업 비밀로 분류한다. 선박의 세부 경하중량 품목은 선주 측에 전달되는 자료에도 명시하지 않고 보내는 경우가 빈번하다. 그리고 조선소 별 경하중량 데이터 관리를 위한 중량분류기준이 다르기 때문에, 같은 선종의 동등한 크기의 선박을 설계하더라도 추정되는 경하중량 차이가 발생하고 보유하지 않은 선박의 중량 추정에 어려움이 따른다.

본 논문에서는 초기설계단계에서 경하중량을 추정하기 위해 Tensorflow를 이용한 심층신경망을 구현시켰다. 학습할 데이터의 선종의 컨테이너선이며, 총 110척의 데이터를 확보하였다. 학습조건을 설정하여 은닉계층의 증가에 따라 추정되는 경하중량

의 정확도와 경험식을 이용한 경하중량 추정값 실제 경하중량값에 비교해보고, 학습하지 않은 범위의 데이터를 테스트 하였을 때 나타나는 정확도를 확인해보고자 한다.

2. 심층신경망 기법

2.1 심층신경망 개요

과거 딥러닝 이전의 전통적 인공지능 방법에서는 컴퓨터에 어떤 학습을 시키려면 각각의 요소와 그 특징표현을 설명을 해주어야 했다. 이미지에서 자전거를 알아보게 하려면, 윤곽선을 추출하고 선의 모양과 연결을 파악하여 요약된 특징표현을 인간이 직접 정의하였다. 추상적인 수준의 정보를 인간의 말이나 수식으로 표현하는 것은 상당히 어려운 일이었다(Ryu, 2017).

그러나 딥러닝에서는 특징표현을 입력할 필요가 없다. 단지 자전거를 포함하는 수많은 사진 자료를 학습하기만 하면 된다. 자전거에 어떤 요소가 필요한지 그리고 그 특징표현은 어떠한지 등은 모두 컴퓨터가 스스로 발견하고 학습한다. 딥러닝에서는 컴퓨터가 스스로 특징 표현을 찾아내므로, 특징 판단에 관여하는 고도의 수학적 지식이나 프로그래밍 능력도 필요하지 않다. 또한 아이러니 하게도 사람이 손수 만드는 모델에 비해 컴퓨터 스스로 만들어내는 모델이 일반적으로 성능이 더 우수하게 나타난다. Fig. 1은 위 설명을 간단히 도식화 한 것이다.

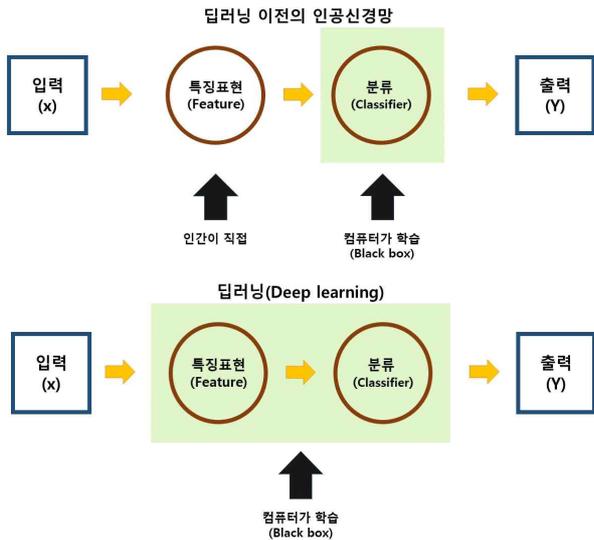


Fig. 1 Artificial Neural Network before Deep Learning & Artificial Neural Network Using Deep Learning.

인공 신경망의 형태 중 입력과 출력계층 사이에 하나의 은닉 계층으로만 이루어진 신경망을 단일 계층 신경망(Single layer neural network)이라 하며 Fig. 2와 같이 입력과 출력계층 사이에 은닉계층이 2개 이상 이루어져 있으면 다중 계층 신경망(Deep neural network)이라 한다. 심층신경망이라고도 하며 딥러

닝의 기본적인 형태로 알고리즘에 따라 형태가 바뀐다(Oh, 2017).

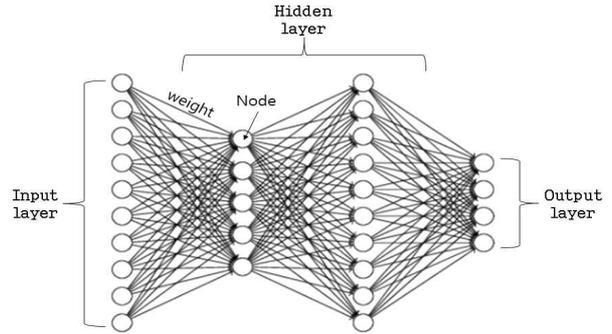


Fig. 2 Deep Neural Network

2.2 초기 경하중량 추정을 위한 알고리즘 고안

우선 심층신경망 알고리즘을 구현하기 위해 사용할 프로그래밍 언어와 종류와 컴퓨터 운영체제 등을 선택해야한다. 본 연구에서는 Python 언어를 이용해 심층신경망 구현을 하였다. Python은 대부분의 라이브러리들이 빠른속도로 업데이트 되고 특히 구글에서 오픈소스로 공개한 Tensorflow 구현이 가능하다는 장점이 있다(Kim, 2017). Tensorflow는 머신러닝 및 딥러닝 프레임 워크로 CPU와GPU 중 선택하여 사용 가능하다. 이러한 딥러닝 프레임 워크를 이용하여 다양한 알고리즘을 적용한 데이터 분석을 수행하고자 한다.

활성화 함수로는 최근 다른 여타 함수보다 학습시간이 빠르고 깊은 층으로 갈수록 생기는 vanishing Gradient Problem을 해결할 수 있는 Relu(Rectified linear unit)함수를 사용 하였으며 아래에 Relu함수를 표현한 식과 Fig. 3와 같이 도식화하여 나타내었다.

$$f = \begin{cases} x < 0, f(x) = 0 \\ x \geq 0, f(x) = x \end{cases} \quad (1)$$

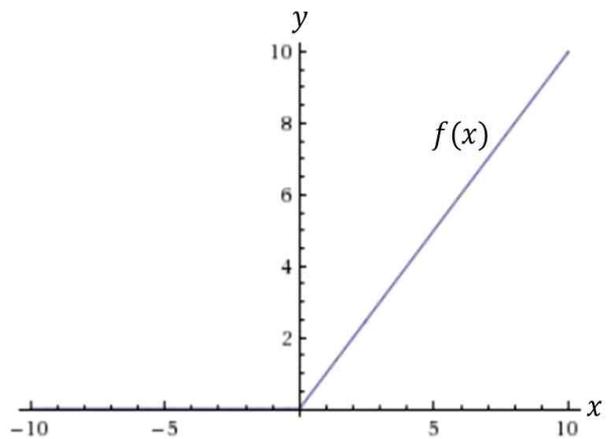


Fig. 3 Relu Function

최적화 함수로는 Adam optimization algorithm을 사용하였다. 구현하기가 간단하고 전산이 효율적이며 적은 메모리로도 동작이 가능하기 때문이다. 변수 초기화(Weight initialization)는 he initialization을 사용하였다. 그리고 신경망의 은닉계층 수를 수정해가며 학습을 진행하였고, 마지막으로 현재 신경망이 훈련 데이터를 알맞게 학습 하였는가를 확인하기 위한 비용함수로 평균 제곱오차(Mean square error)를 사용하였다.

2.3 데이터 구성

신경망 데이터 구성 중 가장 흔하게 사용하는 방법은 수집된 데이터를 Fig. 4와 같이 Training(학습 데이터)와 Testing(테스트 데이터)로 나누어 사용하는 것이다. 세분화 시키면 Validation(검증 데이터)로 하나 더 나눌 수 있다.

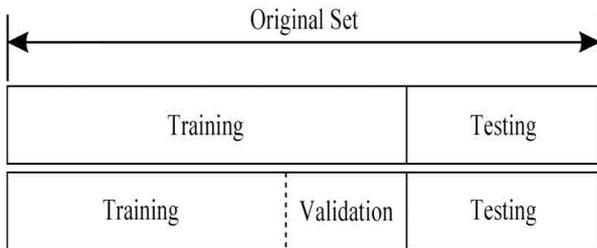


Fig. 4 How to organize neural network data

원래 가지고 있던 데이터인 Original Set을 Training Set 과 Validation Set으로 나누어 사용하게 된다. Training Set은 학습 시킬 추정 변수들을 결정하는데 사용한다. 즉, 컴퓨터가 학습하는 과정에 사용되는 데이터를 말한다. 그 과정에서 가중치와 Bias가 경사하강법(Gradient descent)에 의해서 결정된다. Validation Set은 실제 학습된 모델을 평가하기 전에 Learning Rate와 Regulation에 사용했던 값을 튜닝하는데 사용하게 된다. 쉽게 말하면 최종 테스트 전 스스로 검증과정을 거치는 것으로 생각하면 된다. Testing Set은 실제 학습된 모델을 평가하는데 사용되는 데이터다. 이 데이터를 이용해 심층신경망 알고리즘이 얼마나 잘 학습 되었는지를 평가하게 된다.

수집된 선박 데이터를 이용하여 중량추정 방법에 상관분석을 통해 검토해본 결과 변수들 간의 상관도가 유사하고 추정된 선체 중량에 컨테이너 선박의 특성을 반영하기 위한 새로운 변수개발이 필요하였다. 따라서 선박의 주요치수 및 선형 계수 등을 포함하여 초기단계에 설계자가 활용할 수 있는 변수를 정리하였다(Cho, 2011). Table 1은 수집된 총 110 Case 중에 Training Set에 해당되는 93 Case의 데이터의 범위를 정리하였다. Testing Set은 17 Case에서 Training Set의 Parameter range에 포함되는 14 Case와 Training Set의 Parameter range를 벗어나는 3 Case의 데이터로 분류하였으며, Input 값을 Table 2에 나타내었다.

Table 1 The Parameter data range

Parameter	Range of parameter	
Data distribution	93	
Input	L	158.0 ~ 308.0 m
	B	27.2 ~ 42.8 m
	D	13.8 ~ 24.6 m
	Td (design)	8.75 ~ 13.0 m
	Ts (scantling)	9.2 ~ 14.5 m
	Disp.	26,400 ~ 134,500 ton
	TEU	1,600 ~ 8,500 TEU
C _b	0.58 ~ 0.78	
Output	Light weight	7,050 ~ 33,200 ton

Table 2 Testing set(Out of range)

Parameter	Data			
Input	L	316.4	318	321
	B	48.3	48.2	45.6
	D	27.2	26.8	27.2
	Td (design)	13	12.5	13
	Ts (scantling)	16	14	15
	Disp.	170,123	160,648	146,854
	TEU	11,000	10,500	9,200
	C _b	0.68	0.73	0.65

신경망에 학습시키기 전 데이터 정규화(Normalization)를 실시하여 값들을 일정한 규칙에 따라 변형하였다(Ahn, 2003). 그 식은 다음과 같다.

$$\bar{d} = \frac{d - Min}{Max - Min} \quad (2)$$

입력변수를 학습하기 전에 결정해야할 조건들은 Table 3와 같이 설정하고 학습하였다.

Table 3 Learning condition

Condition	Value
Batch size	50
No. of Hidden layer	10, 8, 4
Learning rate	0.001 ~ 0.00001
No. of learning	5000 ~ 30000

3. 연구결과

각 신경망의 은닉계층 수에 따라 Training & Validation의 비용함수(Cost Function)가 최소가 될 때 까지 Learning rate와 학습횟수를 조율하며 학습시켰고, 신경망 은닉계층의 깊이가 깊어질수록 비용함수가 낮게 그려지는 것을 확인하였다. 앞에서 결정한 Learning condition으로 반복적인 학습을 통하여 각 은닉계층별 Learning rate은 0.0001, 학습횟수는 10,000번을 했을 때 가장 좋은 결과를 얻을 수 있었다. 아래 Fig. 5와 같이 은닉계층 수에 따라 가장 잘 학습된 비용함수를 차트로 나타내었다.

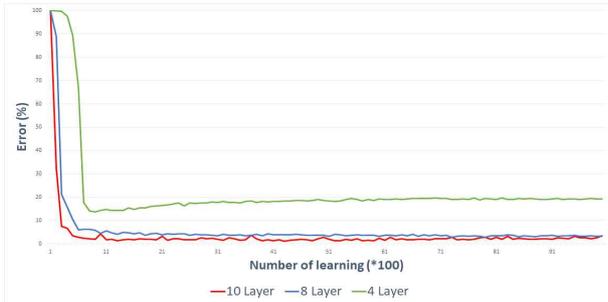


Fig. 5 Cost function according to the number of hidden layers

각 은닉계층별 가장 학습이 잘된 심층신경망에 Testing Set(17 Case)을 입력하여 경하중량을 추정하였다. 아래 Table 4에 은닉계층마다 Testing Set의 각각 오차율과 평균오차율이 가장 낮은 결과 값을 나타내었다. Testing Set의 결과에서도 신경망의 깊이에 따라 평균 오차율이 낮아진 것을 확인할 수 있었고, Parameter range를 벗어나는 15~17 Case의 결과는 대부분 평균 오차율 보다 낮은 값을 보였다.

심층신경망 기법을 통하여 추정된 경하중량과 함께 추가적으로 경험식을 이용하여 경하중량을 추정하였다. 식(3)은 총 경하중량 추정식(Empirical formula 1)이고, 식(4)은 선체강재중량(W_s), 의장품중량(W_o), 기관부중량(W_m) 각각의 경험식과 그것을 합산한 경하중량(Empirical formula 2)이다. 다음과 같은 식으로 추정하여 경하중량을 계산하였으며, Testing Set의 오차율은 Table 5와 같다(Kwon, 2015).

$$\Delta_L = C_1 \cdot (L \cdot B \cdot D/10^3)^{0.8} \quad (3)$$

$$\begin{aligned} W_s &= C_2 \cdot L^{1.6} \cdot (B+D) \cdot C_b^{1/3}/10^3 \\ W_o &= k_o(L \cdot B) \\ W_m &= k_m \cdot PS_{MCO} \\ \Delta_L &= W_s + W_o + W_m \end{aligned} \quad (4)$$

여기서, C_1 은 325(325~350), C_2 은 50(50~54), k_o 은 0.3(0.30~0.35), k_m 은 0.066(0.066~0.075), PS_{MCO} 은 주기관의 연속최대출력이며, L은 수선간장, B은 선폭, D은 깊이, C_b 은 방형계수이다.

Table 4 Error of test data by number of hidden layers

Test data	10 Layer	8 Layer	4 Layer
1	1.26E+00	4.51E+00	1.12E+00
2	3.75E+00	3.22E+00	7.76E+00
3	7.40E+00	1.09E+01	5.09E+00
4	4.20E+00	5.89E+00	8.18E+00
5	3.75E+00	5.42E+00	1.29E-01
6	9.47E+00	1.27E+01	1.79E+01
7	9.69E+00	1.15E+01	1.38E+01
8	8.33E+00	9.18E+00	1.32E+01
9	1.27E+01	1.47E+01	1.90E+01
10	8.60E+00	1.02E+01	1.71E+01
11	4.48E+00	6.16E+00	1.34E+01
12	1.36E+01	1.50E+01	1.80E+01
13	1.49E+01	1.63E+01	1.82E+01
14	1.01E+01	1.21E+01	1.48E+01
15	1.08E+01	1.39E+01	1.47E+01
16	4.48E-01	3.77E+00	1.20E+00
17	1.67E+00	1.05E+00	2.59E+00
Average	7.36E+00	9.21E+00	1.09E+01

Table 5 Error of test data by Empirical formulas

Test data	Empirical formula 1	Empirical formula 2
1	2.05E+01	1.73E+01
2	1.88E+01	1.46E+01
3	3.43E+01	1.48E+01
4	3.15E+00	2.90E+00
5	2.05E+01	2.44E+01
6	1.53E+01	1.58E+01
7	9.96E+00	1.56E+01
8	1.29E+01	1.97E+01
9	1.87E+01	1.17E+01
10	3.34E+00	1.91E+01
11	8.05E+00	2.07E+01
12	4.37E+00	9.86E+00
13	3.39E+00	4.96E+00
14	2.63E+00	1.37E+01
15	7.76E+00	1.27E+01
16	1.47E+01	1.50E+01
17	8.11E+00	1.19E+01
Average	1.21E+01	1.44E+01

최종적으로 위 결과의 오차율을 이용하여 경하중량을 추정하였고, 실제 경하중량과의 차이를 비교하기 위해 다음 Fig. 6와 같이 그래프로 나타내었다. DNN은 은닉계층이 10 Layer일 때, 가장 낮은 오차율을 갖는 값을 이용하여 추정된 경하중량이다. 심층 신경망을 이용하여 추정한 경하중량이 경험식으로 추정한 경하중량보다 실제 경하중량에 대부분 가까이 추정되는 것을 확

인할 수 있었다.

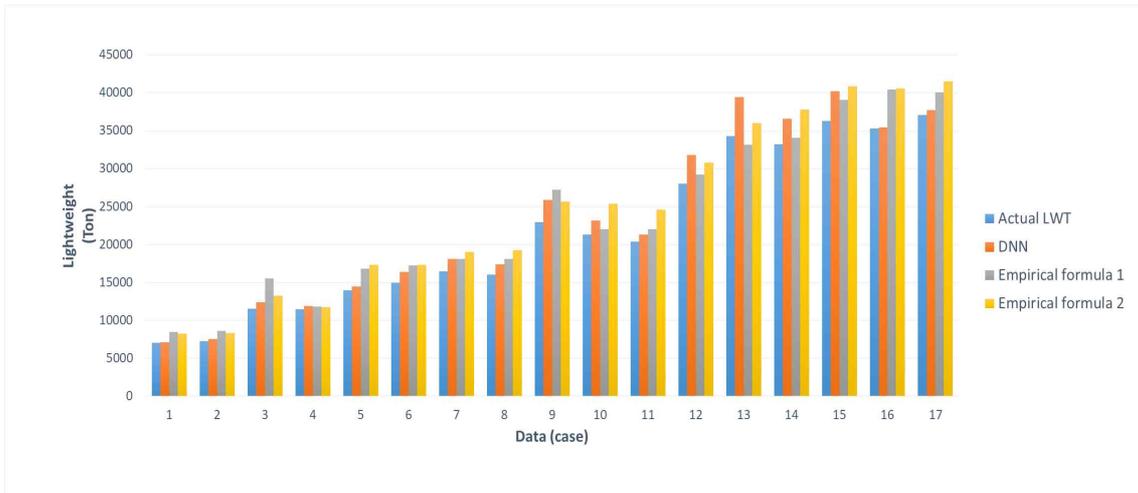


Fig. 6 Result of Test data(17 Case)

4. 결론

본 연구에서는 다음과 같은 결과를 얻을 수 있었다.

(1) 심층 신경망의 Training과 Testing Set의 결과를 통하여 은닉계층이 깊어질수록 약 2~3% 차이로 더 낮은 오차율을 얻을 수 있다.

(2) 가장 비용함수가 낮았던 은닉계층이 10Layer인 심층신경망을 이용한 경하중량 추정이 기존의 경험식과 비교하였을 때 오차율이 약 5~7% 더 낮은 것을 확인할 수 있었다.

(3) Parameter range를 벗어나는 3 Case를 시험했을 때, 오차율이 각 은닉계층별 평균 오차율에 근사하거나 더 낮은 오차율을 보였다.

현재 많은 기업 및 연구 단체에서 딥러닝에 투자를 하고 있으며 다양한 라이브러리 지원으로 쉽게 딥러닝 알고리즘을 구현할 수 있는 환경이 되었다. 향후 조선업에서도 수많은 데이터를 활용하여 심층신경망 알고리즘 기반의 중량 데이터 분석이 가능하다면 초기설계의 경하중량 추정의 시간적인 단축과 유사선이 없을 때의 설계에서 과도한 마진을 적용하지 않고도 중량 추정이 가능할 것으로 보인다. 이에 따라 재료비 측면의 선가의 절감과 설계선 범위 외의 추정도 가능할 것으로 기대한다.

후 기

이 논문은 2018년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2011-0030013)

참 고 문 헌

Cho, Y.J., 2011. A Development of the Ship Weight Estimating Method by a Statistical Approach. *Journal of the Society of Naval Architects of Korea* pp.426-434.

Ahn, H.J., 2003. Inference of Light Weight and Propeller Weight using Neuro Fuzzy System. *Pusan National University*.

Kim, J.H., 2018. A study on Machine Learning for Prediction of the Shipbuilding Lead Time. *Korea Maritime and Ocean University*.

Oh, S.J. & Bae, J.H. & Lim, C.O. & Park, B.C. & Shin, S.C., 2017. Prediction for Maximum Stress of Piping Using Machine Learning Algorithm. *Proceedings of the Annual Autumn Conference, SNAK, Yeosu, 2-3 November, 2017*, pp.368-372.

Ryu, S.I., 2017. Artificial Intelligence Leading the Fourth Industrial Revolution - Focusing on Deep Running. *DegiEco Report No F01506822*.

Kwon, Y.J., 2015. *Theory of Ship Design for Teaching at University*. Dong Myeong Publishers.

The Society of Naval Architects of Korea, 2015. *Shipbuilding Technology*. Ji Sung Publishers.