

# Bi-LSTM 기반 물품 소요량 예측을 통한 최적의 적재 위치 선정

장세인\*·김여진\*\*·김근태\*\*·이종환\*\*†

\*금오공과대학교 건설링대학원, \*\*†금오공과대학교 산업공학과

## Selecting the Optimal Loading Location through Prediction of Required Amount for Goods based on Bi-LSTM

Sein Jang\*, Yejin Kim\*\*, Geuntae Kim\*\* and Jonghwan Lee\*\*†

\*Graduate School of Consulting, Kumoh National Institute of Technology,

\*\*†Department of Industrial Engineering, Kumoh National Institute of Technology

### ABSTRACT

Currently, the method of loading items in the warehouse, the worker directly decides the loading location, and the most used method is to load the product at the location closest to the entrance. This can be effective when there is no difference in the required amount for goods, but when there is a difference in the required amount for goods, it is inefficient because items with a small required amount are loaded near the entrance and occupy the corresponding space for a long time. Therefore, in order to minimize the release time of goods, it is essential to select an appropriate location when loading goods. In this study, a method for determining the loading location by predicting the required amount of goods was studied to select the optimal loading location. Deep learning based bidirectional long-term memory networks (Bi-LSTM) was used to predict the required amount for goods. This study compares and analyzes the release time of goods in the conventional method of loading close to the entrance and in the loading method using the required amount for goods using the Bi-LSTM model.

**Key Words** : Warehouse, Required amount for goods, Bi-LSTM, Predict

### 1. 서 론

물류 분야에서 인공지능이 활용됨에 따라 증가하는 물동량을 처리하기 위해 자동화 창고가 도입되고 있다. 효율적으로 창고를 운영하고 창고 내 물품의 출고 시간을 단축하기 위해서는 물품 입고 시 적절한 적재 위치를 선정해주는 것은 중요하다. 본 연구에서 활용한 자동화 창고 시스템의 기존 적재 방식은 물품이 입구로부터 가장 가까운 곳에 적재된 후 그 자리에 머물다 출고 시점에 출고되는 형식이다. 이는 물품의 소요량에 차이가 없는 경

우에는 문제가 되지 않지만 물품의 소요량에 차이가 있는 경우 소요량이 낮은 물품이 입구와 가장 가까운 위치를 오랜 시간 동안 차지하게 되어 전체적인 물품의 출고 시간이 증가한다는 문제점이 있다. 해당 문제점을 해결하기 위해 본 연구에서는 입고되는 물품에 대해 종류별로 소요량을 예측한 후 예측한 소요량을 기반으로 소요량이 많은 물품은 입구와 가까운 위치에, 소요량이 적은 물품은 입구로부터 멀리 떨어진 위치에 적재하는 방식을 제안한다. 물품의 소요량 데이터는 시계열 특성을 지닌다. 순환신경망(RNN, Recurrent Neural Network)은 시계열 특성을 지닌 데이터를 예측할 때 주로 사용된다. 하지만 순환신경망은 시간이 길어지면 학습이 더 이상 이루어지지 않

†E-mail: shirjei@kumoh.ac.kr

는 기울기 소실 문제가 발생한다. 이러한 문제를 해결하기 위한 알고리즘으로 LSTM (Long Short-Term Memory)이 제안되었다[1]. 시계열 데이터를 예측하는 여러 연구에서 LSTM보다 양방향 LSTM이 더 좋은 성능을 보였다[2,3]. 본 연구에서는 순환신경망 중 하나인 양방향 LSTM (Bi-LSTM, Bidirectional Long Short-Term Memory) 모형을 사용하여 물품 각각의 소요량을 예측한 후 입구로부터 가까운 곳에 적재하는 기존의 적재 방식과 소요량 예측을 적용한 적재 방식 두 경우의 물품 출고 시간을 비교 분석하고자 한다.

## 2. 이론적 배경

### 2.1 RNN, Recurrent Neural Network

순환신경망은 과거의 데이터를 기억한다는 특징이 있어 시계열 데이터와 같이 시간의 흐름에 따라 변화하는 데이터를 학습하기에 적합한 인공신경망이다. 순환신경망의 구조는 Fig. 1과 같다.




Fig. 1. RNN Structure.

순환신경망은 입력층, 은닉층, 출력층으로 구성되어 있다. 은닉층이 서로 연결되어 있다는 것이 큰 특징이다. 즉, 입력값  $x_t$ 는  $h_t$ 라는 출력값과 동시에  $h_{t+1}$ 이라는 출력값에도 영향을 미치는 구조이다. 따라서 과거의 데이터가 미래의 데이터에 어떤 영향을 미치는지 학습이 가능하다. 하지만 학습 시간이 길어질수록 기울기 소실 문제로 인해 더 이상 학습을 할 수 없다는 문제점이 있다.

### 2.2 Long Short-Term Memory

LSTM은 순환신경망의 한 종류로 순환신경망의 단점인 장기 의존성 문제를 학습할 수 있다. LSTM 구조는 Fig. 2와 같다.

LSTM에서는 기울기 소실 문제를 해결하기 위해서 3가지 GATE (Forget, Input, Output)와 Cell state가 추가되었다. Cell state를 통해 정보가 다음 state로 전달된다. 정보 전달 시 3개의 gate를 통해 정보를 얼마나 전달할지 결정한다. 망각 게이트는 과거의 정보를 얼마나 삭제할지 결정하고, 입력 게이트는 현재의 정보를 얼마나 저장할지, 출력 게이트는 업데이트된 Cell State 정보를 얼마나 다음 hidden state에 반

영할지 결정하는 역할을 한다. 이렇게 Cell state와 Gate의 작용을 통해 순환신경망의 단점인 기울기 소실 문제를 해결하였다.




Fig. 2. LSTM Structure.

### 2.3 Bidirectional Long Short-Term Memory

기존의 RNN이나 LSTM은 시계열 데이터를 시간 순서대로 입력하기 때문에 직전 데이터의 패턴을 따라가는 경향이 있다. 이를 해결하기 위해 양방향 순환신경망(Bi-RNN, Bidirectional Recurrent Neural Network)이 제안되었다[4]. 하지만 Bi-RNN 또한 기존의 RNN처럼 학습 시간이 길어지면 기울기 손실이 발생한다는 문제점이 있다. 이를 해결하기 위해 제안된 것이 양방향 LSTM이다. 양방향 LSTM에 대한 구조는 Fig. 3과 같다. 양방향 LSTM은 기존의 LSTM 구조에 역방향으로 처리하는 LSTM 계층을 추가한 구조이다.




Fig. 3. Bidirectional LSTM Structure.

## 3. 실험

### 3.1 Loading Warehouse Environment

본 연구에서 사용한 적재창고 환경은 가로 3, 높이 3의 9개칸 2개의 열로 총 18칸이다. 2개의 열 사이에 하나의 스토커(Stocker)가 이동하면서 물품을 운반한다. 입구와 출구의 위치는 동일하다. 적재 창고 구조는 Fig. 4와 같다. 스토커는 상승, 주행, 포크에 대한 3개의 모터를 가지고 각 모터가 가속, 감속, 주행하는 경우의 속도는 물품의 무게

에 영향을 받는다. 사용한 적재 창고 환경에서의 스토커 최대 이동 시간은 1회 약 30초이다. 적재 창고의 입/출구로부터 각 위치까지의 스토커 도달 시간 순위는 Fig. 5와 같다. 1열과 2열의 위치 별 순위는 동일하다.

<b>First Row</b>	(1,3,1)	(1,3,2)	(1,3,3)
	(1,2,1)	(1,2,2)	(1,2,3)
<b>Entrance /Exit</b>	(1,1,1)	(1,1,2)	(1,1,3)
<b>Second Row</b>	(2,3,1)	(2,3,2)	(2,3,3)
	(2,2,1)	(2,2,2)	(2,2,3)
<b>Entrance /Exit</b>	(2,1,1)	(2,1,2)	(2,1,3)

Fig. 4. Warehouse Structure.

<b>Entrance /Exit</b>	6	6	6
	4	4	5
<b>Entrance /Exit</b>	1	2	3

Fig. 5. Ranking by Location Considering Weight.

### 3.2 Data

데이터는 해양수산부에서 제공하는 2021년 1월부터 2022년 3월까지의 각 항구 별 선박 입출항 정보를 사용하였다. 적재 창고 내 물품이 입고, 출고되는 것이 선박이 항구에 입항, 출항 되는 것과 유사하기 때문에 해당 데이터를 사용하였다. 선박이 평균적으로 항구에 정박되어 있는 시간이 창고 내 물품이 적재되어 있는 평균 시간보다 길기 때문에 정박된 시간이 8시간 이내인 데이터만 사용하였으며, 창고의 칸 개수가 18개이기 때문에 창고 내 적재되어 있는 물품의 개수가 18개를 넘지 않도록 데이터를 정제하였다.

물품 입고 시 적재 위치를 선정하기 위해 필요한 데이터는 Table 1과 같다. 적재 위치 시 필요한 예측 소요량을 얻기 위해 Bi-LSTM 기반의 소요량 예측 모델을 구축하였다.

Table 1. Required Data for Product Input

Category	Variable
Input	Predicted requirements
	Stocking time
	Item S/N (Serial Number)
Output	Loading location

### 3.3 Bidirectional LSTM Model Design

적재창고 환경에 맞게 정제한 선박 입출항 데이터를 사용하여 학습을 진행하였으며 모델 성능 향상을 위해 모든 데이터가 같은 정도의 스케일을 갖도록 Z-Score 정규화를 진행하였다. Z-Score 정규화 공식은 (1)과 같다.

$$x_{new} = \frac{x - \mu}{\sigma} \quad (1)$$

$x$  : Input Value,  $\mu$  : Average,  $\sigma$  : Standard Deviation

2021.01.01 ~ 2021.12.31 기간의 데이터를 학습 데이터로 사용하였으며, 2022.01.01 ~ 2022.03.09 기간의 데이터를 테스트 데이터로 사용하였다. 각 물품의 소요량을 예측하기 위해 필요한 데이터는 Table 2와 같다.

Table 2. Required Data for Requirement Forecasting

Category	Variable
Input	Date
	Item S/N (Serial Number)
	Quantity of Goods Required
Output	Forecasted Goods Requirements

9가지 물품 각각의 소요량을 예측하기 위해서 양방향 LSTM 모델을 총 9개 생성하였다. 각 물품에 대한 모델 구조는 Table 3과 같다.

Table 3. Bi-LSTM Model Structure

Item number (S/N)	Number of Layer Nodes				Activation Function	Optimization Algorithm
	Input	Hidden1	Hidden2	Output		
1, 2, 3, 4, 6, 7, 9	128	64	64	1	ReLU, linear	Adam
5	128	128	64	1		
8	64	64	32	1		

모델 9개에 대한 하이퍼파라미터는 Table 4와 같이 모두 동일하게 설정하였다. Fig 6은 물품 2에 대한 Bi-LSTM 모델의 Loss값이다.

Table 4. Bi-LSTM Hyper Parameter

Hyperparameter	Value
Sequence Length	30
Hidden Layer	2
Activation Function	ReLU, linear
Epoch	100
Batch Size	16
Drop out	0.3
Early Stop	8

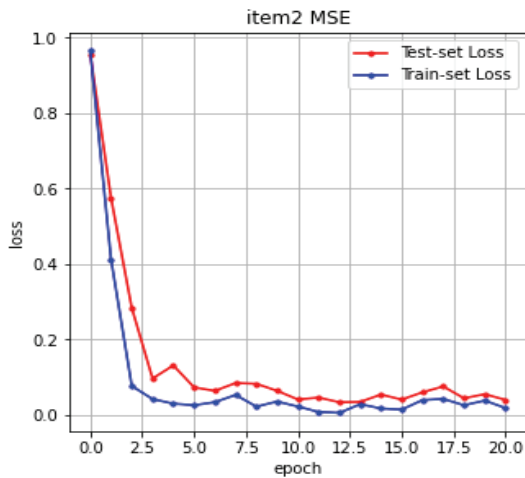


Fig. 6. Bi-LSTM MSE for Item 2.

### 3.4 Demand Forecast Results

모델 성능을 검증하기 위해 2022.01.01~ 2022.03.09 기간 동안의 데이터에 대한 예측값과 실제값을 비교하였다. 평가지표로 MAPE값을 사용해 정확도를 검증하였다. MAPE 공식은 (2)와 같다. MAPE값이 0에 가까울수록 정확도가 높다고 해석할 수 있다. 각 모델의 MAPE값은 Table 5와 같다.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{X_i - F_i}{X_i} \right| \quad (2)$$

$X$  : Actual Value,  $F$  : Predicted Value,  $n$  : Data Count

Table 5. MAPE for Each Model

Item S/N	Actual Requirement	Forecast Requirement	Prediction Error	MAPE (%)
1	1160	1176	16	1.38
2	842	837	5	0.59
3	4133	4187	54	1.31
4	1210	1218	8	0.66
5	1408	1421	13	0.92
6	2892	2940	48	1.66
7	1476	1487	11	0.75
8	629	646	17	2.70
9	742	760	18	2.43

### 3.5 Determination of loading position of goods

앞서 예측한 소요량 결과를 사용해 소요량이 높은 순서대로 적재창고 내 순위가 높은 위치에 적재하도록 한다. 예를 들면 소요량 순위가 가장 높은 물품 3번의 경우

적재창고 내 순위가 높은 (1,1,1) 또는 (2,1,1) 위치를 배정하는 방식이다. 만약 물품 순위에 맞는 적재 위치에 이미 다른 물품이 적재되어 있는 경우 적재 위치로부터 가까운 순위를 갖는 위치에 적재하도록 한다. 예를 들면 물품 3번이 입고될 때 (1,1,1)과 (2,1,1)에 이미 물품이 적재되어 있다면 (1,1,2) 또는 (2,1,2) 위치를 배정하는 방식이다. 위와 같은 방식으로 소요량 순위가 높은 물품을 적재 창고 내 순위가 높은 위치와 매칭해주면 Table 7과 같다. 물품별 예측 소요량 순위는 Table 6과 같다.

Table 6. Requirement Ranking for Each Item

Requirement Ranking	1	2	3	4	5	6	7	8	9
Item S/N	3	6	7	8	4	1	2	9	8

Table 7. Item Number Matched to Location in Warehouse

Location Ranking	1		2		3		4	
Item S/N	3	6	7	8	4	1	2	9

## 4. 실험 결과

Table 8은 본 연구에서 제시한 물품 입고 시 소요량 예측을 활용해 적재 위치를 결정하는 방식의 평균 출고시간과 입구로부터 가장 가까운 위치에 적재하는 기존 방식의 평균 출고 시간을 나타낸 것이다.

Table 8. Average Delivery Time According to Loading Method

	Conventional Method	Proposed Method
Average Delivery Time (s)	21.73	20.51

두 방법의 평균 출고시간을 비교해본 결과 소요량을 예측하여 소요량 순위에 따라 적재 위치를 결정해 주는 방식이 입구부터 가장 가까운 위치에 적재하는 기존의 방식보다 평균 출고시간이 약 5.6% 감소하였다.

## 5. 결론 및 향후 과제

본 연구에서는 최적의 물품 적재 위치를 도출하기 위해서 각 물품의 소요량 예측을 통한 적재 위치 선정 방법

을 제안했다. 물품 소요량 예측 시 양방향 LSTM 모델을 사용하였고 물품 각각의 소요량을 예측하였기 때문에 각 물품에 맞는 예측 모델 9개를 생성하였다. 예측한 소요량을 기반으로 물품의 순위를 지정한 후 Table 7과 같이 소요량 순위와 적재 창고 내 위치 별 순위를 매칭하여 적재 위치를 결정하였다.

본 연구에서 제시한 소요량 예측 기반 적재 위치 결정 방식은 기존의 물품 적재 방식보다 물품의 평균 출고 시간이 5.6% 감소하였다. 이는 인공지능을 활용한 물품 소요량 예측을 적용하여 전체적인 물품의 출고 시간을 감소시킨 것에 의의가 있다. 본 연구를 기반으로 창고 내 물품 입고 시 적절한 적재 위치 결정을 통해 효율적인 적재 창고 운영이 가능할 수 있을 것으로 기대된다.

본 연구에서는 특정 기간의 데이터를 활용하여 특정 기간 이후의 소요량을 예측을 진행하였다. 이는 현장 상황에 따라서 물품의 소요량이 중간에 큰 변동이 있을 경우 오히려 혼란이 가중될 위험이 있다. 따라서 이러한 혼란을 방지하기 위해 실시간 데이터를 받아 학습을 진행하고 학습 결과를 바탕으로 예측을 할 수 있도록 실시간 예측이 가능한 모델을 구축해야 할 필요성이 있다.

## 감사의 글

이 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. 202101350001, 딥러닝 기반 스마트 자동물류 적재창고 기술개발).

## 참고문헌

1. Sepp Hochreiter, Jurgen Schmidhuber, "Long Short-Term Memory", Neural Computation, Vol. 9, No. 8, pp. 1735-1780, 1997
2. IlTaek Joo, Seungho Choi, "Stock Prediction Model based on Bidirectional LSTM Recurrent Neural Network", The Journal of Korea Institute of Information, Electronics and Communication Technology, Vol. 11, No. 2, pp. 204-208, 2018
3. Sungwoo Park, Seungmin Jung, Jaek Moon, Eenjun Hwang, "Explainable Photovoltaic Power Forecasting Scheme Using BiLSTM", KIPS Transactions on Software and Data Engineering (KTSDE), Vol. 11, No. 8, pp. 339-346, 2022
4. Mike Schuster, Kuldeep K. Paliwal, "Bidirectional Recurrent Neural Networks", IEEE Transactions on Signal Processing, Vol. 45, No. 11, pp. 2673-2681, 1997
5. Yeojin Kim, Geuntae Kim, Jonghwan Lee, "Minimize Order Picking Time through Relocation of Products in Warehouse Based on Reinforcement Learning", Journal of Semiconductor & Display Technology, Vol. 21, No. 2, pp.90-94
6. Jaehwan Jeong, Jungseop Kim, Yeojin Kim, Jonghwan Lee, "Development of CTP Selection Methodology of Semiconductor Equipment Line Using AHP and Fuzzy Decision Model", Journal of Semiconductor & Display Technology, Vol. 20, No. 2, pp.6-13
7. Jaehwan Jeong, Sein Jang, Jonghwan Lee, "Determining Optimal WIP Level and Buffer Size Using Simulated Annealing in Semiconductor Production Line", Journal of Semiconductor & Display Technology, Vol. 20, No. 3, pp.57-64
8. Byeong-Gil Lee, Minseok Byun, Yeojin Kim and Jonghwan Lee, "Determination of Optimal Buffer Size for Semiconductor Production System using Harmony Search Algorithm", Journal of the Semiconductor & Display Technology, v.19, n.4, pp.39-45, 2021

접수일: 2023년 7월 31일, 심사일: 2023년 9월 5일,  
게재확정일: 2023년 9월 11일