

# Recurrent Neural Networks를 활용한 Baltic Dry Index (BDI) 예측

한민수\* · † 유성진

\*한국해양대학교 해운경영학과 대학원 석사과정, † 한국해양대학교 해운경영학부 교수

## Time-Series Prediction of Baltic Dry Index (BDI) Using an Application of Recurrent Neural Networks

Min-Soo Han\* · † Song-Jin Yu

\*Graduate school of National Korea Maritime and Ocean University, Busan 606-791, Korea

† Division of Shipping Management, National Korea Maritime and Ocean University, Busan 606-791, Korea

**요 약** : 장기 해운불황에 따라 불확실성이 증폭되고 있는 상황에서 경기추세의 이해뿐만 아니라 예측 또한 중요해지고 있는 실정이다. 본 논문에서는 최근 특정 복잡한 문제에 대해서 각광받고 있는 인공신경망을 적용하여 BDI 예측을 연구하였다. 사용된 인공신경망은 순환신경망으로 RNN과 LSTM 그리고 비교의 목적으로 MLP를 통해 2009.04.01.부터 2017.07.31.의 기간을 대상으로 연구를 진행하였다. 또한 전통적 시계열 예측방법론인 ARIMA 분석을 실시해 인공신경망들의 예측성과 비교하였다. 결과로 순환신경망인 RNN의 성능이 가장 뛰어났으며 LSTM의 특정 시계열(BDI)에의 적용가능성을 확인할 수 있었다.

**핵심용어** : 장단기 메모리, 순환형 신경망, 건화물운임지수(Baltic Dry Index; BDI), 인공신경망, 시계열 분석

**Abstract** : Not only growth of importance to understanding economic trends, but also the prediction to overcome the uncertainty is coming up for long-term maritime recession. This paper discussed about the prediction of BDI with artificial neural networks (ANN). ANN is one of emerging applications that can be the finest solution to the knotty problems that may not easy to achieve by humankind. Proposed a prediction by implementing neural networks that have recurrent architecture which are a Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM). And for the reason of comparison, trained Multi Layer Perceptron (MLP) from 2009.04.01 to 2017.07.31. Also made a comparison with conventional statistics, prediction tools: ARIMA. As a result, recurrent net, especially RNN outperformed and also could discover the applicability of LSTM to specific time-series (BDI).

**Key words** : Long Short-Term Memory, Recurrent Neural Networks, BDI (Baltic Dry Index), Artificial Neural Networks, Time-Series Analysis

### 1. 서 론

본 연구는 BDI 예측을 위해 인공신경망(Artificial Neural Network; ANN) 중에서도 연속적인 시간 또는 순차적으로 나타나는 자료에 대한 학습 성능이 뛰어난 것으로 알려진 Recurrent Neural Network(RNN)의 응용 모델인 Long Short-Term Memory(LSTM) 신경망을 적용함으로써 해당 신경망의 특정 시계열(BDI)에 대한 적용 가능성을 연구하였다. 또한 여타 신경망 모델과의 성능비교를 위해 Multi-Layer Perceptron(MLP)와 LSTM의 전신이 되는 모델인 RNN에 대

한 학습을 연구·비교하였다. 추가적으로 전통적인 시계열 기법과의 비교를 위해 BDI를 독립변수로 투입하는 단변량 Autoregressive Integrated Moving Average(ARIMA) 분석을 시행하였다.

본 연구에서 연구한 신경망은 모두 동일한 다변량 입력변수를 갖고 있으며 학습에 사용된 시계열 자료는 다음과 같다. BIX(bunker price index)<sup>1)</sup>, [BDI, BCI, BPI, Total bulkcarrier deliveries, Clarksons average bulker earnings, ClarkSea Index]<sup>2)</sup>. 시계열 자료의 기간은 2009년 4월 1일부터 2017년 7월 31일까지의 자료를 활용하였다.<sup>3)</sup>

† 교신저자 : coppers@kmou.ac.kr

\* hanms92@kmou.ac.kr

1) BunkerIndex, "BunkerIndex", [접속일자: 2017년 8월]; www.bunkerindex.com/prices/indices.php.

2) BIX를 제외한 나머지 시계열 자료는 'Clarksons Shipping'의 'Shipping Intelligence Network (SIN)'의 데이터베이스에서 발췌하였음을 밝히며 참고문헌에 인용함.

3) 모형의 분석에는 오픈소스 프로그래밍 언어인 'R-Programming'을 사용하였으며, 이에 포함된 다양한 패키지들을 활용하였음을 밝히며 사용한 패키지들은 참고문헌에 인용함.

## 2. ARIMA와 인공지능망 모델의 BDI 예측 적용 및 해석

ARIMA 모형을 통한 예측에 사용된 BDI 데이터는 2009년 4월 1일부터 2017년 7월 31일까지의 데이터를 사용하였다. 해당 기간은 인공지능망 모형들의 예측에도 동일하게 적용되었다. BDI의 시계열은 Fig 1에 나타내었다.




Fig. 1 BDI 시계열 [2009.04.01. ~ 2017.07.31. (Daily)]

ARIMA 모형의 예측을 위해 BDI만을 사용한 단변량 예측을 시행하였다. 예측 대상기간은 단기예측으로써 5일, 10일, 20일의 결과를 도출하였다. Box-Cox변환과 차분을 통해 정상성 확보와 계절성을 제거하였다. 이후 Fig 2와 3에 각각 ACF와 PACF를 나타내었다. 두 값 모두 시간이 지남에 따라 하향하며 안정화되어가는 것을 확인할 수 있다.




Fig. 2 정상성의 확보와 계절성의 제거 후의 ACF 그래프




Fig. 3 정상성의 확보와 계절성의 제거 후의 PACF 그래프

3장에 기술한 ARIMA 모형의 알고리즘에 따라 해당 데이터에 대한 모형을 실험한 결과 (1,3,0)이 최적으로 나타났다. 해당 모형의 AIC와 BIC는 각각 -2522.48과 -2511.22로 나왔다. P-value에 대한 그림은 다음 Fig. 4에 나타났다. 용-박스 통계량으로부터 도출된 p-value는 0.05 이후로 해당 모형이 통계적 유의성이 있는 것으로 나타났다. 잔차에 대한 ACF 역시 안정화되었다. 해당 모형을 통해 5, 10, 20일의 단기예측을 시행하였다. 시행 결과 값은 Fig 5와 같다.




Fig. 4 잔차의 ACF 값과 용-박스(Ljung-Box) 통계량으로부터 도출된 p-value




Fig. 5 Box-Cox 변환을 원 데이터로 되돌린 예측결과 값

모든 인공지능망은 대략 70대 30의 비율로 학습과 테스트 데이터로 나누어 학습을 시켰다. 학습이 완료된 각 모델들의 예측 성능을 테스트 데이터로 평가하였다. 입력 변수로 사용되는 데이터 세트들 간의 값의 차이가 크기 때문에 정규화하여 학습을 진행하였다. 사용된 정규화는 모두 min-max normalization( $0 < z_i < 1$ )이다. 각 인공지능망들의 입력 층의 노드 수는 입력 변수의 개수 만큼인 6개로 구성하였다. 출력 층의 노드 수는 목표 변수의 개수 만큼인 1개로 구성하여 M:1 관계의 신경망을 디자인 하였다. 입력 변수에 대한 데이터 세트의 조합은 6개로 고정하여 투입하였다. 또한 ARIMA 모형을 통한 예측의 경우처럼 parsimonious한 모형을 지향하도록 설계하였다. 따라서 일정 값 이하의 예측 오차와 학습의 속도를 고려하여 최소한의 은닉 층의 노드 수를 갖도록 하였다.

MLP, RNN, LSTM의 결과 값은 Fig 6에 나타났다. 또한 테스트 데이터에 대한 예측성능을 비교평가하기 위해 MSE, RMSE, MAE, MAPE 값들을 Table 1에 정리하여 나타났다.

Table 1. 각 인공지능망 모형 별 MSE, RMSE, MAE, MAPE

	MLP	RNN	LSTM
MSE	30212.066	25269.133	1590464
RMSE	173.816	158.963	1261.136
MAE	156.802	141.315	1212.233
MAPE	23.789	22.816	181.0035




Fig 6. BDI: MLP, RNN, LSTM의 테스트 데이터에 대한 예측 값

### 3. 결 론

ARIMA의 경우는 단기예측에도 불구하고 지속적으로 우상향하며 불명확한 결과를 보여주었다. 반면에 인공지능망은 전반적으로 테스트 데이터에 대한 예측능력, 즉 학습에 사용하지 않아 인공지능망이 전혀 보지 못한 데이터에도 비교적 뛰어난 예측능력을 보여주었다. RNN이 예측성능지표에서 최저 오차수치를 보여주며 제일 우수한 것으로 나타났고 그다음은 MLP 마지막으로 LSTM으로 나타났다. 본문에서는 RNN과 LSTM이 연속적으로 나타나는 이벤트의 집합인 시계열의 예측에 MLP보다 뛰어날 것으로 예상하였다. RNN의 경우는 MLP보다 뛰어났지만 LSTM은 그렇지 못하였다. 그러나 LSTM의 패턴은 BDI와 매우 유사한 패턴을 보임을 알 수 있어 하이퍼 파라미터의 조정과 변수의 보다 면밀한 선정으로 해당 문제를 극복하고 학습능력을 높일 수 있을 것으로 예상된다. 본 논문은 순환신경망의 종류인 RNN과 LSTM을 BDI에 적용을 처음 시도한 연구라는 점과 순환신경망의 특정 시계열(BDI)에 대한 적용 가능성을 확인할 수 있었던 것에 의의가 있다.

### 참 고 문 헌

[1] Bakshi, G., Panayotov, G., Skoulakis, G.(2011), The Baltic Dry Index as a Predictor of Global Stock Returns, Commodity Returns, and Global Economic Activity, AFA 2012 Chicago Meetings Paper, pp. 1-52.  
 [2] Baltyn, P.(2016), Baltic Dry Index as Economic Leading Indicator in the United States, Management Knowledge

and Learning & Technology, Innovation and Industrial Management, Joint International Conference 2016, pp. 205-211.  
 [3] Bildirici, M.E., Kayikçıl, F., Onat, I.S.(2015), Baltic Dry Index as a Major Economic Policy Indicator: the relationship with Economic Growth, Social and Behavioral Sciences, 210, pp. 416-424.  
 [4] Buscema, M., Sacco, P.L.(2000), Feedforward Networks in Financial Predictions: the Future that Modifies the Present, Expert Systems, 17:3, pp. 149-170.  
 [5] Chiste, C., Vuuren, G.V.(2014), Investigating the Cyclical Behaviour of the Dry Bulk Shipping Market, Maritime Policy & Management, 42:1, pp. 1-19.  
 [6] Elman, J.L.(1990), Finding Structure in Time, institute for Cognitive Science, University of California, San Diego, California.  
 [7] Hochreiter, S., Bengio, Y., Frasconi, P., Schmidhuber, J.(2001), Gradient Flow in Recurrent Nets: the Difficulty of Learning Long-Term Dependencies, Wiley-IEEE Press, pp. 237-243.  
 [8] Hochreiter, S., Schmidhuber, J.(1997), Long Short-Term Memory, Neural Computation, 9:8, pp. 1735-1780.  
 [9] Jordan, M.I.(1986), Serial Order: A Parallel Distributed Processing Approach, ICS Report 8604, Institute for Cognitive Science, University of California, San Diego, California.  
 [10] Kaastra, I., Boyd, M.(1996), Designing a Neural Network for Forecasting Financial and Economic Time Series, Neuro Computing, 10, pp. 215-236.  
 [11] Kavussanos, M.G., Alizadeh-M, A.H.(2001), Seasonality Patterns in Dry Bulk Shipping Spot and Time Charter Freight Rates, Transportation Research Part E, pp. 443-467.  
 [12] Lyridis, D.V., Zacharioudakis, P., Mitrou, P., Mylonas, A.(2004), Forecasting Tanker Market Using Artificial Neural Networks, Maritime Economics & Logistics, 6, pp. 93-108.  
 [13] Papailias, F., Thomakos, D.D., Liu, J.(2017), The Baltic Dry Index: Cyclicalities, Forecasting and Hedging Strategies, Empir Econ., 52, pp. 255-282.  
 [14] Qu, L., Chen, Y., Liu, Z.(2006), Time Series Forecasting Model with Error Correction by Structure Adaptive RBF Neural Network, Proceedings of the 6th World Congress on Intelligent Control and Automation, pp. 6831-6835.  
 [15] Scarsi, R.(2007), The Bulk Shipping Business: Market Cycles and Shipowners' Biases, Maritime Policy &

Management, 34:6, pp. 577-590.

- [16] Sutskever, I., Vinyals, O., Le, Q.V.(2014), Sequence to Sequence Learning with Neural Networks, arXiv:1409.3215v3 [cs.CL], Retrieved from [arxiv.org/abs/1409.3215](http://arxiv.org/abs/1409.3215).
- [17] Thorsen, I.S.(2010), Dry Bulk Shipping and Business Cycles(Master's Thesis, Norwegian School of Economics and Business Administration, Bergen, Norway). Retrieved from [brage.bibsys.no/xmlui/handle/11250/168491](http://brage.bibsys.no/xmlui/handle/11250/168491).
- [18] Tsioumas, V., Papadimitriou, S., Smirlis, Y., Zahran, S.Z.(2017), A Novel Approach to Forecasting the Bulk Freight Market, The Asian Journal of Shipping and Logistics, 33:1, pp. 33-41.
- [19] Uyar, K., Ilhan, U., Ilhan, A.(2016), Long Term Dry Cargo Freight Rates Forecasting by Using Recurrent Fuzzy Neural Networks, 12th International Conference on Application of Fuzzy Systems and Soft Computing, ICAFS, pp. 642-647.
- [20] Vinyals, O., Toshev, A., Bengio, S., Erhan, D.(2015), arXiv:1411.4555v2 [cs.CV], Retrieved from [arxiv.org/abs/1411.4555](http://arxiv.org/abs/1411.4555).
- [21] Werbos, P.J.(1990), Backpropagation Through Time: What It Does and How to Do It, Proceedings of the IEEE, 78:10, pp. 1550-1560.
- [22] Zeng, Q., Qu, C., Ng, A.K.Y., Zhao, X.(2015), A New Approach for Baltic Dry Index Forecasting Based on Empirical Mode Decomposition and Neural Networks, Maritime Economics & Logistics, 18:2, pp. 192-210.
- [23] Zhang, G.P., Qi, M.(2005), Neural Network Forecasting for seasonal and trend time series, European Journal of Operational Research, 160, pp. 501-514.
- [5] RStudio Team(2015), RStudio: Integrated Development for R, RStudio, Inc., Boston, MA, <URL: [www.rstudio.com](http://www.rstudio.com)>.
- [6] Shipping Intelligence Network. BDI, BCI, BPI, Total bulkcarrier deliveries, Clarksons average bulker earnings, ClarkSea Index [Online]. Clarksons. Available at: Shipping Intelligence Network database [Accessed: 14 August 2017].
- [7] Quast, B.A.(2016). rnn: a Recurrent Neural Network in R, <URL: [qua.st/rnn](http://qua.st/rnn)>.

#### <웹 사이트>

- [1] Fritsch, S., Guenther, F.(2016), neuralnet: Training of Neural Network, R package version 1.33, <URL: [CRAN.R-project.org/package=neuralnet](http://CRAN.R-project.org/package=neuralnet)>.
- [2] Hyndman, R.J.(2017), forecast: Forecasting functions for time series and linear models, R package version 8.1, <URL: [github.com/robjhyndman/forecast](https://github.com/robjhyndman/forecast)>.
- [3] Hyndman, R.J., Khandakar, Y.(2008), Automatic time series forecasting: the forecast package for R, Journal of Statistical Software, \*26\*(3), pp. 1-22, <URL: [www.jstatsoft.org/article/view/v027i03](http://www.jstatsoft.org/article/view/v027i03)>.
- [4] R Development Core Team(2008), R: A language and environment for statistical computing, R Foundation for