



Received: 2021/08/12
Revised: 2021/09/02
Accepted: 2021/09/13
Published: 2021/09/30

***Corresponding Author:**

Chang Woo Hong
Tel: +82-2-2123-7436
E-mail: spearw@yonsei.ac.kr

CNN-RNN 기반의 DNN을 활용한 DP 선박의 전력부하 예측

Electric Power Load Forecasting of DP Ships by Using CNN-RNN Based DNN

홍창우^{1*}, 허건²

¹해군본부 소령/연세대학교 전기전자공학부 박사과정

²연세대학교 전기전자공학부 교수

Chang Woo Hong^{1*}, Kyeon Hur²

¹Lieutenant Commander, ROK Navy Headquarter/Ph.D course student,
Dept. of Electrical and Electronic Engineering, Yonsei University

²Professor, Dept. of Electrical and Electronic Engineering, Yonsei University

Abstract

선박의 전력 부하를 예측하는 것은 육상 시스템의 전력 부하를 예측하는 것만큼 중요하다. 특히 환경오염물질 규제에 대한 대응에 따라 발전기의 효율적인 운영 및 PMS 시스템 활용이 중요해지고 있으며, 이는 곧 연비를 증가시키는 방법이다. 이 논문에서는 비선형 전력 부하 특성을 가진 dynamic positioning 선박의 단기 전기 부하를 예측하기 위해 심층 인공 신경망을 사용한다. Dynamic positioning 선박은 함위를 유지하기 위해 스러스터를 사용하며, 이는 큰 전력 부하의 사용이다. 스러스터 부하는 불규칙한 펄스 부하로 상황에 따라 정전을 일으킬 수 있다는 점에서 매우 중요한 요소이다. 제안된 심층 신경망은 CNN과 RNN 알고리즘을 결합하여 다양한 변수를 사용하는 불규칙한 전력 부하를 예측한다. 특히 K-fold cross-validation을 사용하여 제한된 데이터 세트에 대한 모델의 높은 강건도를 달성하였다. 실험 연구는 실제 선박의 항해 시뮬레이션 데이터를 사용하여 전력 부하를 예측하고 서로 다른 CNN-RNN 레이어 깊이에 따른 예측 결과를 비교한다.

Electric power load forecasting of a ship is just as important as predicting the power load of a land system. In particular, in response to environmental pollutant regulations, efficient operation of the generator and utilization of the PMS system are becoming critical, increasing fuel efficiency. This paper uses a deep artificial neural network to predict the short-term electrical load of a dynamic positioning vessel with non-linear power load characteristics. Dynamic positioning ships use thrusters to maintain their ships, which is the use of large power loads. Thruster load is a significant factor in that it can cause a power outage depending on the situation as an irregular pulse load. In particular, the high robustness of the model was achieved for a limited data set using K-fold cross-validation. The experimental study predicts the electric power load using the navigation simulation data of a real ship and compares the prediction results according to different CNN-RNN layer depths.

Keywords

심층 신경망(Deep Neural Network),
DP 선박(Dynamic Positioning Ship),
전력부하 예측(Electric Power Load Forecasting)

Acknowledgement

이 논문은 2021년도 한국해군과학기술학회
하계학술대회 발표 논문임.

1. 서론

전력 수요 예측은 실시간 전력 공급의 안정에 있어서 가장 중요한 요소이다. 계절에 따른 난방이나 냉방 및 휴일 등과 같은 변수를 고려하여 실시간으로 변화하는 전력량에 맞추어 안정적인 전력 공급과 수급이 가능하게 만들기 때문이다.

전력 수요 예측은 실시간, 단기, 중기, 장기 예측의 4단계로 나눌 수 있다. 실시간 전력 수요 예측은 경제급전을 반영한 5분의 예측이며 단기 예측은 발전계획 스케줄링을 반영한 매주, 매일의 예측이다. 중기와 장기 예측은 전력 설비 유지보수나 건설계획을 반영한 예측 계획이다. 단기 전력 수요 예측은 발전단가 결정이나 발전기 운영 계획 등에 활용되며 이를 통해 효율적인 전력계통 운영이 가능하다. 단기 전력 수요 예측의 방법은 크게 통계적 기법과 인공지능 기법으로 나눌 수 있다[1-3].

선박은 발전기와 부하들로 이루어진 소규모의 독립형 마이크로 그리드라고 볼 수 있으며, 효율적이고 안정적인 전력계통 운영을 위해 전력 부하 예측이 필요하다. 특히 차세대 선박에서의 전력 부하는 기존의 내연 기관 추진에서 전기추진 방식(integrated propulsion system, IPS)으로 변화하고 전력 수요가 많이 증가하는 추세이다[4]. 최근 환경문제에 있어 국제해사기구(International maritime organization, IMO)의 MARPOL 73/78(Prevention of Pollution from Ships) 조약이나 IMO 2020에 의해 질소산화물, 황산화물의 배출 규제가 강화됨에 따라 연료

소모효율 중요성이 증대되고 있으며 이에 따라 전기추진 선박 혹은 하이브리드 선박의 보급이 날로 확대되고 있다. 선박에서의 연료 효율은 단순히 환경적인 측면뿐 아니라 경제적 운항을 나타내는 지표이다. 또한, 제한된 연료 탑재 용량으로 얼마큼의 항해일수를 지속할 수 있는지를 결정짓는 요소이다. 선박의 연료 효율을 개선하기 위해 선박용 에너지 저장장치(energy storage system, ESS) 운용에 관한 연구도 활발하게 진행되고 있다[5].

Dynamic positioning(DP) 선박은 플랜트나 시추선 등의 특수목적 선박이 위치 고정을 위해 보조추진기를 이용하여 선박의 위치와 방향을 자동으로 일정하게 유지하는 선박을 말한다. DP 선박은 외력에 의해 선박의 위치가 변화할 때 함위를 유지하기 위해 보조추진기를 사용하며, 이때 모터를 짧게, 고출력으로 사용한다. 이러한 pulse load는 전력 체계의 불안정성을 일으키며, 특히 급격한 위치 변화로 예기치 못한 pulse load가 연속적으로 발생하면 정전이 일어날 수 있다. 따라서 DP 선박의 전력부하 예측은 PMS(power management system)에서 매우 중요하다.

DP 선박의 안정적인 부하 운영에 관한 연구가 많이 있다. 정전의 위험을 방지하기 위해 energy storage를 도입하는 연구가 있었으며[6], 부하 스케줄링을 통해 효율적인 운영의 효과를 입증한 연구가 있었다[7]. 또한 PMS 제어와 load shedding을 통해 정전에 대한 위험을 감소시키는 연구가 있다[8]. 하지만 선박의 전력 부하를 직접 예측하는 연구가 미흡하다.

본 논문에서는 pulse load가 빈번히 발생하는 특징을 가진 DP 선박의 단기 전력 부하를 예측하기 위하여 심층 인공 신경망을 사용하였다. 모델은 CNN(convolutional neural network), LSTM(long short-term memory)을 복합적으로 사용하여 딥스택 구조를 형성하였으며 제한한 예측 모델의 정확성을 향상하기 위해 residual network와 dropout 기법을 사용하였다. 본 논문의 2절에서는 딥러닝 알고리즘을 포함한 연구 배경을 소개하고 3절에서는 제안한 모델과 사례 연구에 관해 서술하였다. 4절에서는 실험 결과에 관해 서술하고, 5절의 결론으로 마무리한다.

2. 본론

2.1 CNN-RNN 기반의 심층신경망

최근 CNN-RNN에 기반한 시계열 예측 모델이 제안되었다. 이러한 심층 신경망 모델은 자연어 처리 및 음성 처

리뿐만 아니라 의료 분야에서 인식하는 비디오 시퀀스 및 도구의 마모 상태를 예측하기 위한 기계적 상태 모니터링에도 사용되고 있다[9].

DNN은 CNN, LSTM 알고리즘을 함께 사용하여 구성되었다. 센서 데이터 입력 후 CNN 클래스는 입력 변수 사이의 특징을 추출할 수 있다. 또한 합성곱을 사용하여 불필요한 정보와 노이즈를 제거하여 RNN 클래스의 입력으로 전송한다. CNN 클래스 이후의 RNN 클래스는 다변량 시계열 요소에서 불규칙한 변화를 나타내는 시간 정보를 모델링하는 데 적합하다. RNN 클래스에서 훈련된 모델은 전력 부하에 대한 불규칙한 추세 요인을 기억할 수 있다. 또한 모델의 정확성과 최적화를 높이기 위해 residual network와 dropout technique를 적용하였다. 또한 제한된 데이터셋에서의 강건한 모델 구축을 위해 K-fold cross-validation을 적용하였다. CNN과 LSTM 레이어의 층수에 따른 파라미터와 정확도의 비교를 위하여 각각 다른 레이어의 층수를 적용하여 실험을 진행하였다.

2.1.1 CNN(convolutional Neural Network)

CNN은 최초 이미지 인식을 위해 개발되었으나 입력 데이터의 공간적/시간적 특징을 추출하는 데에 유용하게 사용된다[10]. CNN은 합성곱과 인공 신경망 구조가 결합한 형태이다. CNN의 특징은 공간적으로 인접한 신호들에 대한 correlation 관계를 비선형 필터를 적용하여 추출하고, 여러 개의 필터를 적용하여 다양한 spatial feature를 추출할 수 있다. 또한 subsampling을 통해 map의 크기를 줄이고, 반복적인 필터 연산을 통해 global feature를 얻을 수 있다. 또 다른 특징으로는 동일한 가중치를 갖는 필터를 데이터에 반복 적용함으로써 변수의 수를 줄여 항상성을 얻는다.

1D CNN은 합성곱을 통한 특징 추출, subsampling, pooling의 세 단계로 진행된다. 첫 번째 단계는 가중치를 가지는 커널이 시간 방향으로 흐르며 다수의 합성곱을 병렬로 연산한다. 두 번째 단계는 첫 번째 단계에서 연산된 값이 활성화 함수를 거쳐 입력 데이터의 특징을 추출하여 feature map으로 출력한다. 세 번째 단계에서는 pooling 함수를 통해 feature map의 특징 데이터를 줄여준다. 세 단계의 반복을 통해 데이터의 특성이 추출되며 fully connected 계층을 통해 $n \times m$ 행렬의 데이터가 $1 \times n$ 의 열벡터 배열로 변경되어 특징을 분류한다. 1D CNN의 수식은 다음과 같다.

$$c_i^{l,j} = \sigma \left(b_j^l + \sum_{m=1}^M W_m^{l,j} x_{i+m-1}^{l-1,j} \right) \quad (1)$$

여기서 l 은 레이어 인덱스, σ 는 활성화 함수, b_j 는 j 번째 피쳐 맵의 바이어스, M 은 커널의 크기, W_m^j 는 j 번째 피쳐 맵의 가중치, m 은 필터의 인덱스이다.

2.1.2 LSTM(long short-term memory)

LSTM은 기존 RNN(recurrent neural network)의 gradient vanish 문제를 해결하기 위해 적용되었다[11]. RNN은 내부에 루프를 가진 네트워크로, 정보의 지속성을 보장한다. 하지만 레이어가 깊어질수록 초기의 가중치가 더는 학습에 영향을 주지 못하는 문제가 발생하며, 이것이 gradient vanish 문제이다. LSTM은 메모리 셀을 통해 장기 메모리를 보존하는 특징을 가진다. RNN과는 차별되는 메모리 특성 때문에 장기 시퀀스의 시간 특성을 추출하는 데 유용하다. LSTM은 입력, 출력, 망각의 세 개의 게이트와 비선형성의 특징을 가지는 활성화 함수는 장기 의존성 문제를 해결하며 시계열 데이터나 자연어 처리에서 활발히 사용되고 있다. LSTM의 가장 중요한 특성은 sequence를 저장하고 이를 학습에 활용하기 때문에 예측을 위해서도 많이 활용된다. LSTM의 수식은 다음과 같다.

$$i^t = \sigma(W_i x^t + R_i y^{t-1} + p_i \odot c^{t-1} + b_i) \quad (2)$$

$$f^t = \sigma(W_f x^t + R_f y^{t-1} + p_f \odot c^{t-1} + b_f) \quad (3)$$

$$o^t = \sigma(W_o x^t + R_o y^{t-1} + p_o \odot c^{t-1} + b_o) \quad (4)$$

식 (2), 식 (3), 식 (4)는 각각 입력 게이트, 망각 게이트, 출력 게이트를 나타낸다. 여기서 σ 는 활성화 함수, W 는 입력 가중치, x^t 는 입력 벡터, R 은 순환 가중치, p 는 피플의 가중치, b 는 편향 가중치이다. 그리고 \odot 는 점별 곱셈이다.

$$c^t = g(W_z x^t + R_z y^{t-1} + b_i) \odot i^t + c^{t-1} \odot f^t \quad (5)$$

$$y^t = h(c^t) \odot o^t \quad (6)$$

식 (5) 및 식 (6)은 각각 셀 상태와 숨겨진 상태를 나타낸다. 여기서 g 및 h 는 비선형 활성화 함수이다.

2.1.3 Residual network and dropout technique

Residual network는 skip connection을 사용하여 복잡성을 증가시키지 않으면서 정확도를 향상하는 기법이다. Skip connection의 기본 개념은 일반적인 구조와 달리 이전 계층의 출력과 다음 계층의 출력을 합하는 것이다. 이렇게 입력에서 더해지는 값을 identity라고 부르며, feature를 추출하기 전과 후를 더해주는 특징을 가지고 있다. 잔여 네트워크는 레이어가 많은 심층 신경망에 적용하여 학습 효과를 향상하는 데 큰 역할을 한다.

$$x_{i+1} = f(x_i) + x_i \quad (7)$$

$$x_{i+n} = x_i + \sum_{i=1}^{i+n-1} f(x_i) \quad (8)$$

잔차 단위는 $f(x)$ 와 x 로 구성되며 x 는 입력 데이터, $f(x)$ 는 각 레이어, $y = f(x)$ 는 표준 네트워크이다. 잔차 네트워크는 방정식 $y = f(x) + x$ 로 표현된다.

Dropout technique은 과적합을 막기 위해 사용되는 기법이다. 드롭아웃은 훈련 시 은닉층의 뉴런을 무작위로 골라 삭제하여 학습하는 기법이다. 삭제된 뉴런의 가중치는 0과 같으며 신호를 전달하지 않는다. 훈련 때는 데이터 학습할 때마다 삭제할 뉴런을 무작위로 선택하고 시험 때는 모든 뉴런에 신호를 전달한다. 드롭아웃을 사용하면 학습 효과를 극대화하면서 과적합을 억제할 수 있다. 드롭아웃은 앙상블 학습과 밀접하다. 학습 시 무작위의 뉴런을 삭제하는 방법은 매번 다른 모델을 학습시키는 것과 같다.

3. 실험 설계

3.1 제안하는 심층 신경망 아키텍처

본 연구에서 제안하는 CNN-RNN based deep neural network 모델의 구성은 Fig. 1과 같다. 모델의 구성은 1D CNN 알고리즘과 RNN 알고리즘 중 LSTM을 사용하여 총 6개 레이어로 구성되었다. 각 레이어 이후에는 출력 노드의 일부를 임의로 삭제하는 dropout technique이 적용되었다. CNN 알고리즘 이후에는 residual network를 사용하여 최초의 입력 데이터와 CNN layer의 학습 결과를 합친다. 이를 통해 복잡한 과정 없이 심층망에서 데이터의 특성 추출을 최적화하고 예측률 향상에 기여할 수 있다. 특

히 residual network는 CNN 알고리즘에서 특징 추출을 위해 일부 삭제된 원본 데이터의 identity를 학습할 수 있다는 장점이 있다.

각 알고리즘의 배치 특징은 시계열 예측에 주로 사용되는 CNN-RNN 알고리즘이 가지는 특성에 따라 살펴볼 수 있다. 최초 전력 부하 데이터 입력 이후 1D CNN 레이어가 배치된다. 1D CNN 레이어에서는 시계열 전력 데이터를 비롯한 여러 변수의 공간적 특성 추출을 수행한다. 합성곱 기능을 통해 데이터를 축소하고 잡음을 제거하여 국부적인 특징을 정확하게 추출한다. 1D CNN 레이어에서 학습된 데이터는 RNN 레이어로 입력되어 학습된다. RNN 레이어의 LSTM 알고리즘은 장단기 기억의 저장 여부 결정을 통해 입력 정보의 시간적 특성을 더욱 잘 추출할 수 있다. 특히 전력 부하의 불규칙한 시간적 추세를 기억한다. 이러한 CNN-RNN 기반의 네트워크는 각각 알고리즘의 특성을 활용하면서 dropout technique와 residual network를 통해 심층 신경망을 구성하여 전력 부하를 학습하여 정확한 예측을 가능케 한다. 실험에 사용된 하이퍼파라미터는 Table 1과 같다.

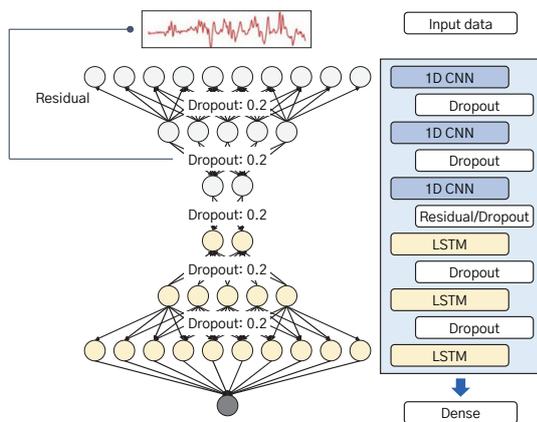


Fig. 1. Deep neural network architecture

Table 1. Hyperparameters for proposed deep neural network architecture

Hyperparameter	Value
Number of units	128-64-6-6-64-128
Normalization	Min-max normalization
Activation function	ReLu
Validation	10 % of data
Optimizer algorithm	Adam
Epochs	1,000 (early stopping)

3.2 DP 선박 데이터셋

전력 부하 예측 대상 선박은 수선간장(length between perpendicular) 약 250 m, 배수량 약 110,000톤의 shuttle tanker이다. 해당 선박은 worst case failure가 발생하더라도 동력 유지가 가능해야 하는 DP class 2의 시스템을 탑재하고 있으며, 보조추진기는 선수와 선미에 각 두 대씩 갖추고 있다. 데이터는 외력을 반영한 HIL(hardware in the loop) simulator data이며 일주일간의 약 4만 포인트의 데이터이다.

일주일간의 항해 중 최대 전력부하는 약 14 MW이며, 학습에 사용된 변수는 풍향, 풍속, 전/후부 보조 추진모터의 부하에 외력에 대한 학습효과를 향상하기 위하여 풍속 변화율을 추가하여 총 6개이다.

3.3 평가 지표(evaluation metric)

전력 부하 예측의 정확도를 나타내기 위해 본 연구에서는 mean squared error(MSE)와 mean absolute error(MAE), 그리고 root mean squared error(RMSE)를 사용하였다.

MSE와 MAE는 실제 값과 측정값의 차이를 구하고, 이를 평균화하는 것에 공통점이 있으며 손실함수와 회귀지표로 주로 쓰인다. RMSE는 MSE의 과장된 값을 보완하기 위해 많이 쓰인다. RMSE는 다음과 같이 나타낸다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^n (\hat{y}_i - y_i)^2} \tag{9}$$

여기서 n 은 전체 데이터의 개수, y 는 i 번째 지점에서의 실제 부하, \hat{y} 는 i 번째 지점에서의 예측 전력 부하이다.

3.4 K-fold cross-validation

제한된 데이터 세트에서의 모든 데이터 추세를 포괄하기 위해 K-fold cross-validation을 사용하였다. K-fold cross-validation은 학습 데이터를 K 개의 하위 샘플로 나눈다. 검증을 위한 데이터를 제외하고 나머지 $K-1$ 개의 하위 샘플을 학습에 사용한다. 학습 알고리즘은 K 번 반복되고 각 샘플은 한 번씩 검증된다. 학습 및 검증 샘플은 독립적으로 구현되며 K-fold 결과를 평균하여 단일 추정치를 생성할 수 있다.

4. 결과 및 고찰

4.1 K-fold cross-validation에 대한 결과

전력 부하 예측을 위한 프로그램으로 파이썬(케라스 라이브러리)을 사용하였다. 총 반복 횟수는 1,000회이며 학습에 진전이 없을 때 조기에 종료하는 early stopping을 적용하였다. 입력 데이터는 더욱 나은 학습효과를 위해 0에서 1 사이의 값으로 정규화하였다. 1주일의 항해 전력 부하 중 118시간을 학습하여 이후 50시간에 대한 전력 부하를 예측한 결과는 Figs. 2-3와 같다. 예측 데이터의 부하는 평균 6메가에서 최대 12메가까지의 dynamic한 변동을 나타내지만, 잘 학습된 모델은 실제 부하를 유사하게 추종함을 확인할 수 있다. 특히 Fig. 2는 K값을 10으로 설정한 K-fold cross-validation한 모델이며 학습 데이터의 모든 추세를 포괄하는 효과를 나타냈다. Fig. 3은 K-fold cross validation을 하지 않은 경우의 전력부하 예측 결과이다. K-fold cross-validation을 한 사례와는 다르게 변동하는 부하의 상승을 추종하지 못하는 것을 볼 수 있다. Table 2에서는 K-fold cross-validation을 적용한 모델과 적용하지 않은 경우의 오차를 비교하였다. MSE, MAE, RMSE 모두 K-fold cross-validation을 적용하지 않았을 때 오차가 큰 것을 확인할 수 있다.

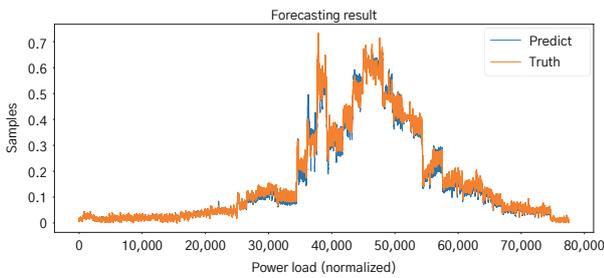


Fig. 2. Electric power load forecasting result (K-fold cross validation case)

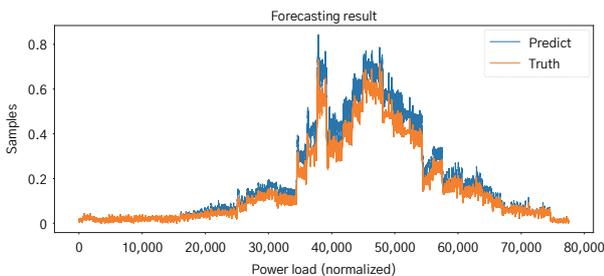


Fig. 3. Electric power load forecasting result (normal model case)

Table 2. Accuracy comparison of the proposed model with normal model

Case	RMSE	MAE	MAPE
K-fold cross-validation case	0.018	0.012	14.51
Normal case	0.066	0.041	31.022

4.2 서로 다른 레이어 수를 적용하였을 때의 결과

Table 3에서는 CNN-RNN 구조의 DNN에서 각 알고리즘의 레이어가 깊어질 때 증가하는 파라미터와 RMSE 정확도를 비교하였다. 레이어가 깊어짐에 따라 파라미터 수는 매우 증가하였으나 정확도는 3의 CNN 레이어와 3의 LSTM 레이어를 사용한 사례에서 가장 높은 정확도를 보였다. 특히 5개의 CNN 레이어와 5개의 LSTM 레이어를 사용한 사례에서 학습에 사용하는 파라미터의 수가 가장 많음에도 불구하고 가장 높은 RMSE 오차율을 보이는 것은 해당 데이터 세트에 비해 모델이 과적합임을 의미한다. 이를 통해서 CNN-RNN 바탕의 DNN 아키텍처를 구성할 때 데이터 세트와 변수의 특성에 따라 과적합이 아닌 수준의 레이어 깊이를 선택해야 함을 실험 결과를 통해 알 수 있다.

Table 3. RMSE accuracy comparison by layer depth

Layer depth	Description	Parameters	RMSE
2	1 CNN layer +1 LSTM layer	69,936	0.0417
4	2 CNN layer +2 LSTM layer	71,876	0.0363
6	3 CNN layer +3 LSTM layer	130,176	0.0180
8	4 CNN layer +4 LSTM layer	141,156	0.0335
10	5 CNN layer +5 LSTM layer	150,532	0.0578

5. 결론

선박에서의 전력 부하 예측은 육상 계통에서의 전력 부하 예측과 마찬가지로 매우 중요하다. 특히 환경 오염 배출물질의 규제와 연료소비 효율 향상을 위해 전기추진 선박의 보급이 늘어나고, 전력 부하의 지속적 상승에 따라 선박용 ESS 운용이 연구되는 등 선박에서의 단기 전력부

하 예측을 통한 효율적인 계통 운영이 요구되는 추세이다. 본 연구에서는 비선형적 특징을 가진 dynamic positioning 선박의 단기 전력 부하를 예측하기 위하여 심층 인공 신경망을 사용하였다. 제안된 모델은 총 여섯 개의 레이어로 구성되어 있으며, CNN과 LSTM 알고리즘을 사용하여 복잡한 부하 패턴의 시간적, 공간적 특성을 학습하였다. 또한 dropout technique과 residual network를 적용하여 과적합을 방지하고 예측 정확도를 향상하였다.

학습 데이터는 HILS로 구성된 11,000톤급의 DP선박인 shuttle tanker의 1주일치 항해 데이터를 사용하였다. 학습 결과 예측 데이터가 부하 변동을 정확하게 추종함을 확인할 수 있었다. 특히 제한된 데이터 세트에서의 모델 학습의 한계를 극복하기 위해 K-fold cross-validation을 사용하여 정확도를 향상했다. 또한 서로 다른 레이어 깊이를 사용하였을 때 파라미터와 정확도의 최적점을 발견할 수 있음을 확인하였다. 향후 실제 선박의 운용 데이터나, 전기추진 선박 등의 학습 데이터를 활용한 모델의 발전 및 검증에 관한 연구가 필요하다.

참고문헌

- [1] Kim, Si-Yeon, Hyun-Woo Jung, Jeong-Do Park, Seung-Mook Baek, Woo-Seon Kim, Kyung-Hee Chon, and Kyung-Bin Song. "Weekly maximum electric load forecasting for 104 weeks by seasonal ARIMA model." *Journal of the Korean Institute of Illuminating and Electrical Installation Engineers*, Vol. 28, no. 1 (2014): 50-56.
- [2] Lee, K. Y., Y. T. Cha, and J. H. Park. "Short-term load forecasting using an artificial neural network." *IEEE transactions on power systems*, Vol. 7, no. 1 (1992): 124-132.
- [3] Hsu, Che-Chiang, and Chia-Yon Chen. "Regional load Forecasting in Taiwan — Applications of Artificial Neural networks." *Energy Conversion and Management*, Vol. 44, no. 12 (2003): 1941-1949.
- [4] Sulligoi, Giorgio, Andrea Vicenzutti, and Roberto Menis. "All-electric Ship Design: From Electrical Propulsion to Integrated Electrical and Electronic Power Systems." *IEEE Transactions on Transportation Electrification*, Vol. 2, no. 4 (2016): 507-521.
- [5] Ku, Hyun-Keun, Hye-Rim Seo, and Jang-Mok Kim. "Lithium-ion Battery Energy Storage System for Power Quality Improvement in Electrical Propulsion Ships." *The Transactions of the Korean Institute of Power Electronics*, Vol. 20, no. 4 (2015): 351-355.
- [6] Cuculić, Aleksandar, Dubravko Vučetić, Rene Prenc, and Jasmin Čelić. "Analysis of Energy Storage Implementation on Dynamically Positioned Vessels." *Energies*, Vol. 12, no. 3 (2019): 444.
- [7] Satpathi, Kuntal, VSK Murthy Balijepalli, and Abhisek Ukil. "Modeling and Real-time Scheduling of DC Platform Supply Vessel for Fuel Efficient Operation." *IEEE Transactions on Transportation Electrification*, Vol. 3, no. 3 (2017): 762-778.
- [8] Lauvdal, Trygve, and A. K. Ådnanes. "Power Management System with Fast Acting Load Reduction for DP Vessels." In *Dynamic Positioning Conference*, pp. 17-18. 2000.
- [9] Sainath TN, Vinyals O, Senior A, Sak H. Convolutional, Long Short-term Memory, Fully Connected Deep Neural networks. In 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2015 Apr 19 (pp. 4580-4584). IEEE.
- [10] LeCun, Yann, Léon Bottou, Yoshua Bengio, and Patrick Haffner. "Gradient-based Learning Applied to Document Recognition." *Proceedings of the IEEE*, Vol. 86, no. 11 (1998): 2278-2324.
- [11] Hochreiter, Sepp, and Jürgen Schmidhuber. "Long Short-term Memory." *Neural Computation*, Vol. 9, no. 8 (1997): 1735-1780.