

A Multi-Head RNN-based Architecture for Short-term Electricity Demand Forecasting

Minwook Sua*, Hyunchul Ahn**

*PhD Candidate, Graduate School of Business IT, Kookmin University, Seoul, Korea

**Professor, Graduate School of Business IT, Kookmin University, Seoul, Korea

[Abstract]

In this paper, we propose a short-term electricity demand forecasting approach that integrates power-related and meteorological data through feature selection and applies a Multi-Head RNN/LSTM/GRU model. By leveraging the strengths of multiple recurrent neural network architectures, the proposed method aims to enhance forecasting accuracy. Furthermore, we fuse power data with meteorological data, identify the combination of features exhibiting the best predictive performance, and apply this to a Multi-Head RNN/LSTM/GRU model. This approach is expected to support informed decision-making in power supply management and contribute to the stable operation of modern power grids.

▶ **Key words:** Electrical Power Demand Forecasting, Time Series, Feature Selection, Multi-Head RNN/LSTM/GRU, Deep Learning

[요약]

본 논문은 전력 관련 데이터와 기상 데이터를 통합하여 특징 선택(feature selection)을 수행하고, Multi-Head RNN/LSTM/GRU 모델을 적용한 단기 전력 수요 예측 접근법을 제안한다. 다양한 순환 신경망(RNN) 구조의 강점을 결합함으로써, 제안된 방법은 예측 정확도를 향상시키는 것을 목표로 한다. 또한, 전력 데이터와 기상 데이터를 융합하고, 가장 좋은 예측 성능을 가진 특징 변수들의 조합을 찾아서, 멀티 헤드 RNN/LSTM/GRU 모델에 적용한다. 이러한 접근법은 전력 공급 관리와 의사결정 지원에 기여하고, 현대 전력망의 안정적 운영을 뒷받침할 것으로 기대된다.

▶ **주제어:** 전력 수요 예측, 시계열, 특징 선택, 멀티 헤드 RNN/LSTM/GRU, 딥러닝

• First Author: Minwook Sua, Corresponding Author: Hyunchul Ahn
*Minwook Sua (mwsua@kookmin.ac.kr), Graduate School of Business IT, Kookmin University
**Hyunchul Ahn (hcahn@kookmin.ac.kr), Graduate School of Business IT, Kookmin University
• Received: 2025. 10. 17, Revised: 2025. 10. 31, Accepted: 2025. 11. 24.

I. Introduction

산업 발전과 더불어 데이터 센터 등 첨단 기술 설비가 급격히 증가하면서 전 세계적으로 블랙아웃(대규모 정전) 위험이 높아지고 있다. 특히 급격한 기후 변화와 이에 따른 냉·난방 장치 사용량의 급증은 전력 수요의 절대량과 변동성을 동시에 확대시켜 전력 수요 예측을 한층 어렵게 만들고 있다. 이러한 변화에 대응하기 위해 전력 수요에 영향을 미치는 다양한 요인을 고려한 고도화된 예측 모델 개발에 대한 연구가 활발히 진행되고 있다.

이와 맞물려 산업통상자원부는 최근 「제11차 전력수급 기본계획」을 발표하였다[1]. 해당 계획은 2024년부터 2038년까지의 15년 중장기 전력 수급 전망을 기반으로 전력 설비 확충, 송·변전 설비 계획, 수요 관리, 분산형 전원 확대 등의 정책 방향을 제시한다. 이러한 전력 인프라 확장 계획을 효과적으로 실행하기 위해서는 무엇보다 정확하고 신뢰할 수 있는 단기 전력 수요 예측이 필수적이다.

단기 전력 수요 예측 방법은 크게 통계적 기법과 머신러닝 기반 기법으로 나눌 수 있다[2]. 통계적 기법은 전력 수요와 기온 등 보조 변수 간의 수학적 관계를 이용해 미래 수요를 예측하며, 지수평활법이나 시계열 분석법이 대표적이다. 예를 들어, Holt-Winters 지수평활 모델은 시계열 데이터의 추세(trend)와 계절성(seasonality)을 고려하여 미래 수요를 추정한다. 또한 자동회귀이동평균(ARMA)과 시계열 데이터의 비정상성, 추세, 계절성을 반영한 계절형 ARIMA(SARIMA) 모델 역시 널리 사용되며, 한국 전체 및 지역별 전력 수요 예측 연구에 적용된 바 있다[2]. 이러한 통계적 기법은 모델 구조가 단순하고 해석이 용이하다는 장점이 있으나, 변수 간 비선형적 관계를 충분히 반영하지 못한다는 한계가 있다.

이러한 한계를 보완하기 위해 최근에는 딥러닝 기반 예측 모델이 활발히 연구되고 있다. 특히 시계열 예측에서 우수한 성능을 보이는 순환 신경망(Recurrent Neural Network, RNN)[3], 장·단기 메모리 손실 문제를 개선한 Long Short-Term Memory(LSTM)[4], 그리고 계산 효율성과 작업 유형에 따라 더 나은 성능을 보일 수 있는 Gated Recurrent Unit(GRU)등이 전력 수요 예측에 적용되고 있다[9]. 그러나 기존 연구들은 주로 단일 모델(RNN, LSTM, GRU 중 하나)을 활용하거나, 다변량 데이터 통합 및 특징 선택(feature selection)을 충분히 반영하지 못하는 경우가 많았다.

한편 최근에는 시계열 데이터 분석에서 멀티 헤드(Multi-Head) 구조가 주목받고 있다. 이는 하나의 입력 데

이터를 여러 병렬적 ‘헤드(head)’로 분할해 학습함으로써 모델이 서로 다른 패턴과 상관관계를 동시에 학습하도록 하여 예측 성능을 개선한다. 특히 금융 분야에서는 멀티 헤드 LSTM을 활용해 기업 파산 예측 성능을 향상시킨 연구가 보고되었다[5]. 그러나 전력 수요 예측 분야에서는 여전히 멀티 헤드 구조를 다양한 RNN 계열 모델(RNN, LSTM, GRU)에 동시에 적용하고, 전력 및 기상 데이터를 통합적으로 활용한 연구가 부족하다.

이에 본 논문은 전력 관련 데이터와 기상 데이터를 통합한 후 특징 선택(feature selection)을 수행하고, 멀티 헤드 구조를 적용한 RNN/LSTM/GRU 모델을 활용하여 단기 전력 수요 예측 정확도를 향상시키는 방법을 제안한다. 본 연구는 기존 통계적 기법의 비선형성 한계와 기존 딥러닝 연구의 단일 모델 의존성을 동시에 보완하며, 실무적 의사결정 지원과 전력망 안정적 운영에 기여할 수 있는 새로운 예측 프레임워크를 제시하고자 한다.

II. Preliminaries

1. Studies on Electricity Demand Forecasting

단기 전력 수요 예측을 위해 과거에는 전통적인 통계적, 계량적 방법이 주로 활용되어 왔으며, 대표적으로 선형 회귀(Linear Regression) 기반 방법이 있다. 선형 회귀 기반 방법은 전력 수요를 기온, 요일, 계절, 시간대 등의 독립 변수와의 선형 관계로 가정하여 예측한다. 이러한 방법은 단순하고 해석이 용이하다는 장점이 있지만, 전력 수요 데이터가 가지는 비선형적 패턴을 충분히 반영하지 못한다는 한계를 가진다.

최근에는 딥러닝(Deep Learning) 기반의 예측 방법이 활발히 연구되고 있다. 특히 시계열 데이터 처리에 강점이 있는 순환 신경망(RNN)이 주목받았다[3]. RNN은 입력 시퀀스의 순서를 고려하여 이전 시점의 은닉 상태(hidden state)를 현재 시점 연산에 반영함으로써 메모리 기능을 가지며, 자연어 처리, 음성 인식, 전력 수요 예측 등 다양한 분야에서 활용된다. 그러나 RNN은 학습 과정에서 기울기 소실(vanishing gradient) 문제와 학습 속도 지연, 병렬 처리 어려움 등의 한계를 가진다.

이러한 RNN의 문제를 개선하기 위해 LSTM과 GRU 모델이 제안되었다. LSTM은 입력 게이트, 망각 게이트, 출력 게이트와 셀 상태(cell state)를 도입하여 필요한 정보는 장기간 기억하고 불필요한 정보는 잊어버릴 수 있도록 설계됨으로써 긴 시퀀스에서도 안정적으로 학습할 수 있

대[6]. GRU는 LSTM의 구조를 단순화하여, 업데이트 게이트와 리셋 게이트 두 가지를 사용해 연산량을 줄이면서도 경쟁력 있는 예측 성능을 제공한다[7].

그러나 기존 딥러닝 기반 전력 수요 예측 연구들은 대부분 단일 헤드 구조를 중심으로 이루어져 왔으며, 특징 변수들을 하나의 통합된 시계열 입력으로 처리하는 방식이 일반적이다. 특히 다양한 특징을 독립된 시계열로 분리하여 멀티 헤드 구조로 학습하는 방식, 그리고 특징 선택을 결합해 멀티 헤드 시계열 예측 모델의 성능을 체계적으로 향상시키려는 접근은 거의 시도되지 않았다. 즉, 기존 연구는 개별 특성 간 상호작용을 단일 입력 벡터로 단순 통합하여 처리함으로써, 전력 수요에 영향을 미치는 다양한 요인의 시계열적 차이를 충분히 반영하지 못했다는 한계를 가진다.

2. Deep Learning Techniques for Time Series Data

2.1 Recurrent Neural Network(RNN)

순환 신경망은 은닉층이 순환 구조를 가지며, 이전 시점의 은닉층 출력을 현재 시점의 입력으로 재활용하여 시계열 데이터의 시간적 의존성을 모델링한다[9]. Fig. 1은 간단한 순환 신경망의 구조를 예시로 보여준다. Fig. 1의 왼쪽 구조가 기본구조이고, 기본구조를 시간흐름에 따라 분석해 보면 화살표 오른쪽의 그림처럼 표현된다. 여기서 x 는 입력층, h 는 은닉층을, o 는 출력층을 의미하며, V, W, U 는 연결 계수를 나타낸다. 그리고 하위 첨자 t 및 $t-1$ 은 시점을 의미한다. 이러한 구조 덕분에 RNN은 시계열 데이터 처리에서 좋은 성능을 보이지만, 앞서 언급한 기술적 소실과 학습 효율성 한계가 존재한다.




Fig. 1. Structure of RNN[9]

2.2 Long-Short Term Memory(LSTM)

LSTM 셀을 사용한 순환 신경망은 긴 시퀀스 데이터에서도 기술적 소실(vanishing gradient) 문제를 효과적으로 완화하여 안정적으로 학습할 수 있다. 최근 음성 인식, 자연어 처리, 이미지 자동 주석 달기 등의 분야에서 활용되는 대부분의 순환 신경망은 LSTM 구조를 기반으로 하고 있다[6].

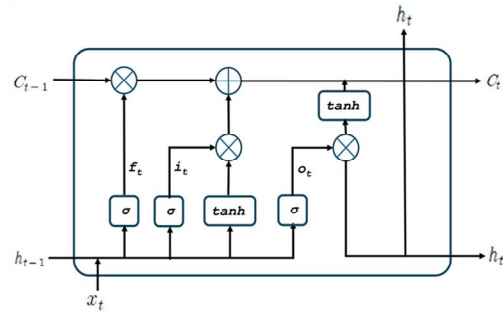


Fig. 2. Structure of LSTM cell [6]

Fig. 2의 LSTM 셀은 셀 상태(cell state)를 유지하면서 입력 게이트(Input Gate), 망각 게이트(Forget Gate), 출력 게이트(Output Gate)를 이용해 정보의 흐름과 출력값을 조절한다. 입력 게이트는 새로운 입력값을 얼마나 받아들일지 결정하고, 망각 게이트는 이전 셀 상태를 어느 정도 잊을지를 결정하며, 출력 게이트는 현재 시점에서 얼마나 정보를 출력할지를 제어한다. 여기서 여기서 C_t 는 셀 상태(cell state), h_t 는 셀의 출력(hidden state)을 나타낸다. i_t, f_t, o_t 는 각각 입력게이트, 망각게이트 출력게이트를 의미하며, σ 와 \tanh 는 활성화 함수로 각각 시그모이드(sigmoid) 함수와 하이퍼볼릭 탄젠트(hyperbolic tangent) 함수이다.

LSTM 셀은 다음과 같은 방식으로 동작한다. 기존 셀 상태에 망각 게이트의 출력값을 곱하여 이전 정보 중 불필요한 부분을 제거하고, 현재 입력값과 이전 단계 출력값을 처리한 결과에 입력 게이트의 출력값을 곱해 필요한 새로운 정보를 추가한다. 이 과정을 통해 새로운 셀 상태가 생성되며, 최종적으로 이 셀 상태에 출력 게이트의 출력값을 곱해 최종 출력이 결정된다.

2.3 Gated Recurrent Unit(GRU)

GRU는 [10]에서 처음 소개된 모델로, LSTM과 마찬가지로 게이트(gate)의 개념을 활용하는 RNN의 한 변형이다 [11][12]. Fig. 3는 GRU의 기본 구조를 보여준다.

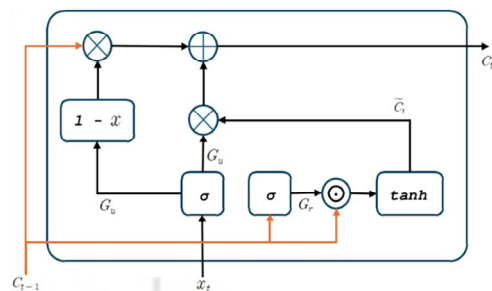


Fig. 3. Structure of GRU cell [9]

GRU는 입력 정보를 처리하기 위해 두 개의 게이트, 즉 업데이트 게이트(update gate)와 리셋 게이트(reset gate)를 사용한다. 먼저 업데이트 게이트의 연산 과정을 살펴보면, 이 게이트는 이전 시점의 은닉 상태(hidden state)와 현재 시점의 입력 중 어느 쪽에 더 많은 가중치를 부여할지를 결정한다. 업데이트 게이트 G_u 는 수식적으로 다음과 같이 표현된다.

$$G_u = \sigma(W_u[C_{t-1}, x_t] + b_u) \quad (1)$$

수식 (1)에서 σ 은 시그모이드 활성화함수를 의미하며, W_u 는 가중치 행렬, C_{t-1} 은 이전 시점의 출력값, x_t 는 현재 시점의 입력값, 그리고 b_u 는 업데이트 게이트의 바이어스 항을 의미한다.

리셋게이트는 이전 시점의 출력값을 새로운 현재 시점의 출력이 될 출력 후보값에 얼마나 포함시킬 것인지 결정해 준다. 현재 시점의 출력 후보값과 리셋게이트의 연산을 수식적으로 표현하면 다음의 수식 (2), (3)과 같다.

$$\tilde{C}_t = \tanh(W_c[G_r \odot C_{t-1}] + b_c) \quad (2)$$

$$G_r = \sigma(W_r[C_{t-1}, x_t] + b_r) \quad (3)$$

수식 (2)에서 C_t 는 현재 시점에서의 출력 후보값을 나타내고, W_c 와 b_c 는 각각 가중치 행렬과 바이어스 항을 나타낸다. 그리고 G_r 은 리셋게이트 값을 나타내고 \odot 는 행렬의 성분곱 연산을 의미한다. 그리고 수식 (3)에서의 W_r 과 b_r 은 리셋게이트의 가중치 행렬과 바이어스 항을 나타낸다.

마지막으로 업데이트 게이트 G_u 를 이용해 이전 시점의 출력값과 새로 계산된 현재 시점에서의 출력 후보값을 가중합하여 GRU의 최종 출력값을 결정한다. 이를 나타내는 수식은 다음과 같다.

$$C_t = G_u \odot \tilde{C}_t + (1 - G_u) \odot C_{t-1} \quad (4)$$

수식 (4)에서 G_u 값은 시그모이드 함수의 출력값이기 때문에 그 출력 범위가 0에서 1로 제한되게 된다. 이 때, 만약 G_u 의 값이 0이라면 최종 출력에서 C_t 는 반영되지 않고 C_{t-1} 을 그대로 취하게 된다. 반대로 만약 G_u 의 값이 1이라면 C_{t-1} 은 현재 시점의 출력에 전혀 반영되지 않고 C_t 를 출력값으로 결정하게 된다. 이러한 순환 연산 과정

은 입력이 모두 연산되고 출력되는 과정이 끝날 때까지 반복된다.

III. Research Model

기존의 단기 전력 수요 예측 연구들은 주로 시계열 딥러닝 알고리즘인 RNN, LSTM, GRU를 활용해 전력 수요 데이터를 예측해 왔으나, 대부분의 접근법은 단일 입력 변수(univariate series)에 집중하거나 제한적인 다변량 입력만을 사용하는 경우가 많았다[14]. 이러한 방식은 다양한 변수 간 상호작용과 복잡한 패턴을 충분히 반영하지 못해 예측 성능을 높이는 데 한계가 있었다. 또한 기존 연구에서 활용된 딥러닝 구조는 대부분 단일 헤드(single-head) 형태로, 하나의 입력 시퀀스만을 기반으로 학습하기 때문에 서로 다른 데이터 패턴을 병렬적으로 학습하거나 변수 그룹별 특성을 독립적으로 포착하기 어렵다는 제약이 존재한다. 이러한 구조적 한계를 극복하고자 본 연구는 Fig. 4에 제시된 바와 같이 전력 수요 데이터와 기상 데이터를 통합하고, 멀티 헤드(Multi-Head) 구조를 적용한 RNN/LSTM/GRU 기반 예측 모델을 제안한다.

제안된 모델은 입력 시계열 데이터를 여러 개의 헤드(head)로 분할하여 각각 병렬적으로 학습하도록 설계되었다[3]. 각 헤드는 전력 및 기상 변수 집합의 서로 다른 패턴과 시계열적 특성을 학습하며, 병렬적으로 학습된 각 헤드의 출력 표현을 통합(concatenate)하여 최종 예측층에 전달한다. 이러한 구조는 단일 헤드 모델이 포착하기 어려운 다차원적 패턴을 동시에 학습할 수 있도록 하며, 특히 전력 수요 예측에서 중요한 기온, 습도, 시간대, 계절성 등의 외생적 요인을 보다 정교하게 반영할 수 있게 한다. 결과적으로 멀티 헤드 구조는 다양한 데이터 특징을 분리하여 학습한 후 종합함으로써 모델의 표현력을 크게 확장한다.

또한 본 연구에서는 멀티 헤드 구조의 성능을 극대화하기 위해 모델 학습 전에 특징 선택(feature selection)을 수행하였다. 이를 통해 전력 및 기상 데이터의 여러 변수 조합을 탐색하고, 각 조합을 멀티 헤드 RNN, LSTM, GRU에 적용하여 예측 성능을 체계적으로 평가할 수 있도록 하였다. 이러한 절차는 단순히 다변량 입력을 사용하는 것에서 나아가, 변수 선택과 멀티 헤드 구조를 결합해 가장 효과적인 입력 특성 집합을 찾아내는 프레임워크를 제공한다는 점에서 의미가 있다.

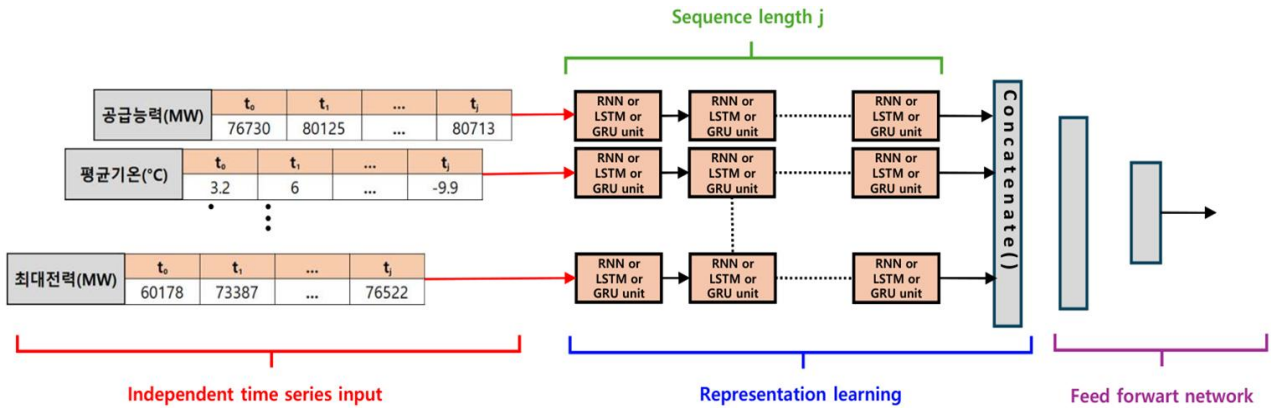


Fig. 4. Multi-Head RNN/LSTM/GRU Model

IV. Experiments

1. Data Collection and Experimental Procedure

본 연구의 실험은 제안한 멀티 헤드(Multi-Head) RNN/LSTM/GRU 모델의 전력 수요 예측 성능을 검증하기 위해 수행되었다. 실험에 사용된 데이터는 전력거래소 전력통계정보시스템[8]에서 제공하는 일별 전력 수요 데이터와 기상청 공공 데이터[13]에서 제공하는 일별 기상 데이터를 기반으로 하였다. 두 데이터는 날짜를 기준으로 병합하였으며, 추가적으로 요일 정보를 생성하여 입력 변수로 포함하였다. 최종 데이터셋은 2019년 1월 1일부터 2024년 12월 31일까지의 자료를 포함하며, 사용된 입력 변수는 요일(DOW), 설비용량(Inst. Cap.), 공급능력(Sup. Cap.), 최대전력(Peak Dem.), 공급예비력(Res. Power), 공급예비율(Res. Ratio), 평균기온(Avg. Temp.), 최저기온(Min. Temp.), 최고기온(Max. Temp.), 강수량(Precip.)의 총 9개이다. 이 중 최대전력을 예측 대상(target variable)으로 설정하였다.

전체 데이터셋은 학습(training)용 2019~2022년 자료 1,461건, 검증(validation)용 2023년 자료 365건, 테스트(test)용 2024년 자료 366건으로 분할하였다. 제안 모델의 성능을 평가하기 위해 입력 변수의 가능한 모든 조합을 고려하여 멀티 헤드 RNN, LSTM, GRU를 각각 학습시켰으며, 총 511개의 변수 조합(최대전력 단일 컬럼 제외)을 생성하였다. 각 조합별로 평균절대백분오차(MAPE)를 산출하여 모델의 예측 정확도를 비교하였고, 동일한 데이터셋을 활용해 단일 헤드(single-head) RNN/LSTM/GRU 모델을 학습하여 성능을 대조하였다. 이러한 절차를 통해 멀티 헤드 구조가 기존 단일 헤드 모델에 비해 예측 정확도를 향상시킬 수 있는지를 검증하였다.

2. Experimental Environment

본 연구에서 사용된 데이터셋은 총 2,192건으로 구성되었으며, 앞서 언급한 기간에 따라 훈련용, 검증용, 테스트용으로 분리하였다. Table 1은 실험 데이터셋의 전체적인 구성을 나타낸다. 실험에 사용된 하드웨어 및 소프트웨어 환경은 Table 2에 요약되어 있으며, 단일 헤드 모델과 멀티 헤드 모델의 학습에 적합한 옵티마이저와 하이퍼파라미터 설정은 동일하며 Table 3에 정리하였다.

Table 1. Data Configuration

Data Type	Period	No. of Samples
Training	2019 ~ 2022	1,461
Validation	2023	365
Test	2024	366

Table 2. Experimental Environment

Type	Environment
H/W	CPU : Ryzen 7 5800H GPU : Internal Radeon 3GB M/M : 32GB
S/W	OS : Windows 11 Python 3.10.12

Table 3. Optimizer and Hyperparameters

Type	Parameters
Optimizer	Optimizer : Adam Batch size : 32 Epochs : 20 Learning rate : 0.001

3. Experimental Results

Table 4는 단일 헤드 RNN, LSTM, GRU 모델을 활용해 최대전력(MW)을 예측한 결과를 나타낸다. 단일 컬럼을 입력으로 사용했을 때 RNN, LSTM, GRU의 MAPE는 각

각 2.71%, 5.39%, 3.50%로, RNN이 가장 낮은 예측 오차를 보였다. Figs. 5, 6, 7은 각각 단일 헤드 RNN, LSTM, GRU를 적용한 실제값과 예측값을 비교한 그래프다.

Table 4. Results of the Single-Head Algorithms

Model	MAPE	MAE	RMSE	R ²
RNN	2.71%	1962.71	2998.36	0.8946
LSTM	5.39%	3817.50	4660.94	0.7453
GRU	3.50%	2514.23	3392.68	0.8651




Fig. 5. Comparison between Actual and Predicted Values using Single-Head RNN




Fig. 6. Comparison between Actual and Predicted Values using Single-Head LSTM




Fig. 7. Comparison between Actual and Predicted Values using Single-Head GRU

Table 5는 본 연구에서 제안한 멀티 헤드(Multi-Head) RNN/LSTM/GRU 모델의 예측 성능을 요약한다. 총 511개의 입력 변수 조합 중 MAPE가 가장 낮은 조합을 기준으로 각 알고리즘의 예측 결과를 제시하며, 제안 모델이

기존 단일 헤드 구조 대비 성능이 개선됨을 보여준다. 또한 멀티 헤드 구조에서 반복적으로 높은 성능을 보인 입력 변수 조합을 분석한 결과, 공급능력, 공급예비력, 평균기온, 강수량이 핵심적으로 포함되는 것으로 나타났다. 이는 전력 수요 예측에서 전력 공급 지표와 기상 요인이 중요한 역할을 하며, 멀티 헤드 구조가 이러한 변수의 상호작용을 효과적으로 학습할 수 있음을 시사한다. Figs. 8, 9, 10은 각각 멀티 헤드 RNN, LSTM, GRU를 적용한 실제값과 예측값을 비교한 그래프다.

Table 5. Results of the Multi-Head Algorithms

Model	Selected Features	MAPE	MAE	RMSE	R ²
RNN	Inst. Cap., Sup. Cap., Res. Power, Avg. Temp., Max Temp., Precip.	2.64%	1911.80	2949.42	0.898
LSTM	Sup. Cap., Res. Power, Res. Ratio, Avg. Temp., Precip., DOW	3.11%	2252.94	3234.16	0.877
GRU	Sup. Cap., Res. Power, Avg. Temp., Min Temp., Precip., DOW	2.77%	1998.97	2874.70	0.903




Fig. 8. Comparison between Actual and Predicted Values using Multi-Head RNN



Fig. 9. Comparison between Actual and Predicted Values using Multi-Head LSTM




Fig. 10. Comparison between Actual and Predicted Values using Multi-Head GRU

V. Conclusions

본 연구는 전력 수요와 기상 데이터를 융합하여 단기 전력 수요를 보다 정확하게 예측하기 위해 멀티 헤드 RNN/LSTM/GRU 모델을 제안하였다. 제안 모델은 다양한 입력 변수 조합을 활용한 특징 선택과 멀티 헤드 구조를 결합함으로써 기존 단일 헤드 기반 모델보다 우수한 평균절대백분오차(MAPE) 성능을 달성하였으며, 이를 통해 전력 수요 예측 정확도가 효과적으로 향상될 수 있음을 실증적으로 확인하였다.

모델의 성능은 국내 전력거래소와 기상청에서 수집한 실제 데이터를 기반으로 검증되었으며, 이는 제안 방법이 실무 환경에서도 적용 가능하고 일반화될 잠재력을 가짐을 시사한다. 특히 다양한 전력 공급 지표와 기상 요인을 통합적으로 학습함으로써, 전력 수요 예측을 필요로 하는 조직이 보다 신뢰도 높은 의사결정을 내리는 데 실질적인 도움을 제공할 수 있을 것으로 기대된다. 또한 조직별 도메인 특성에 따라 추가적인 독립 변수를 포함하면 예측 성능을 한층 더 향상시킬 수 있는 가능성을 제시한다.

그러나 본 연구에는 몇 가지 한계가 존재한다. 첫째, 입력 변수 조합을 탐색하는 과정에서 변수 수가 증가할수록 가능한 조합의 수가 기하급수적으로 늘어나 연산 복잡도가 급격히 증가한다. 둘째, 다양한 하이퍼파라미터 설정에 따른 성능 비교를 충분히 수행하지 못했다는 점도 제한점으로 남아 있다.

향후 연구에서는 특징 선택 과정을 보다 효율적으로 수행할 수 있는 탐색 알고리즘이나 최적화 기법을 적용할 필요가 있으며, 하이퍼파라미터 조정에 따른 모델 성능 변화를 체계적으로 비교, 분석할 필요가 있다. 이러한 연구가 이루어진다면, 전력 수요 예측의 실용성을 한층 더 높여 산업 현장에서의 의사결정 지원 도구로 활용될 수 있을 것이다.

REFERENCES

- [1] Y. K. Kim, "Major Outlook of the 11th Basic Plan for Electricity Supply and Demand," *Journal of the Korean Society of Mineral and Energy Resources Engineers*, Vol. 62, No. 2, pp. 179-185, 27 March 2025. DOI: 10.32390/ksmer.2025.62.2.179.
- [2] C. H. Kim, "Estimating Short-Term Load Forecasting in Korea Using Multiple Exponential Smoothing," *Korea Electrotechnology Research Institute (KERI) Report*, pp. 1-76, June 2013.
- [3] J. L. Elman, "Finding Structure in Time," *Cognitive Science*, Vol. 14, No. 2, pp. 179-211, March 1990. DOI: 10.1207/s15516709cog1402_1.
- [4] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, Vol. 9, No. 8, pp. 1735-1780, November 1997. DOI: 10.1162/neco.1997.9.8.1735.
- [5] M. Pellegrino, G. Lombardo, G. Adosoglou, S. Cagnoni, P. M. Pardalos, and A. Poggi, "A Multi-Head LSTM Architecture for Bankruptcy Prediction with Time Series Accounting Data," *Future Internet*, Vol. 16, No. 3, p. 79, 17 January 2024. DOI: 10.3390/fi16030079.
- [6] H. H. Kim, "Forecasting Time-Series Data Using LSTM/GRU Recurrent Neural Networks," *Korea National Open University, Master's Thesis*, July 2017.
- [7] H. S. Kim, H. C. Song, S. K. Ko, B. T. Lee, and J. W. Shin, "RNN-LSTM Based Short-Term Electricity Demand Forecasting Using Holiday Information," *Proceedings of The Institute of Electronics and Information Engineers Conference*, pp. 552-555, Nov. 2016.
- [8] Electric Power Statistics Information System (EPSIS), Korea Power Exchange. Available: <https://episis.kpx.or.kr>
- [9] D. G. Lee, Y. G. Sun, I. S. Sim, Y. M. Hwang, S. W. Kim, and J. Y. Kim, "Prediction of Power Consumptions Based on Gated Recurrent Unit for Internet of Energy," *Journal of IKEEE*, Vol. 23, No. 1, pp. 120-126, March 2019. DOI: 10.7471/ikeee.2019.23.1.120.
- [10] K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, "Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation," *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1724-1734, October 2014. DOI: 10.3115/v1/D14-1179.
- [11] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," *NIPS 2014 Workshop on Deep Learning*, Montreal, Canada, pp. 1-9, Dec. 2014.
- [12] R. Jozefowicz, W. Zaremba, and I. Sutskever, "An Empirical Exploration of Recurrent Network Architectures," *Proceedings of the 32nd International Conference on Machine Learning (ICML)*, Lille, France, pp. 2342-2350, July 2015.

- [13] Open MET Data Portal, Korea Meteorological Administration.
Available: <https://data.kma.go.kr>
- [14] S. J. Kwon and Y. S. Yoon, "The Prediction of Durability Performance for Chloride Ingress in Fly Ash Concrete by Artificial Neural Network Algorithm," Journal of the Korea Institute for Structural Maintenance and Inspection, Vol. 26, No. 5, pp. 127-134, October 2022. DOI: 10.11112/jksmi.2022.26.5.127.

Authors



Minwook Sua received his Master's degree from the Graduate School of Software Technology at Kookmin University, Korea, in 2021. He is currently pursuing a Ph.D. at the Graduate School of Business IT at

Kookmin University. His primary research interests include electricity demand forecasting and machine learning-based predictive modeling.



Hyunchul Ahn received his B.S. degree in Industrial Management and his M.E. and Ph.D. degrees from the KAIST Graduate School of Management, South Korea. He is currently a Professor at the Graduate School

of Business IT, Kookmin University. His research interests include AI applications in finance and marketing, as well as information systems adoption.