

Power/Energy Track

Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network

Weicong Kong, Zhao Yang Dong

IEEE TRANSACTIONS ON SMART GRID(2019)

Contents

01 Introduction

02 Problem Statement

03 LSTM Architecture

04 Proposed Method


05 Experimental Results

06 Conclusion

01 Introduction

Short-Term Residential Load Forecasting

단기 전력수요예측은 앞으로 몇 분에서 몇 시간 동안 얼마나 많은 전력이 사용될지를 예측하는 기술이다. 기존에는 도시 전체나 변전소처럼 **큰 규모의 부하를 예측하는 연구**가 대부분이었지만, 스마트그리드가 발전하면서 **개별 가정의 전력 사용량을 예측하는 기술의 중요성**이 점점 커지고 있습니다.



01 Introduction

Short-Term Residential Load Forecasting

단기 전력수요예측은 앞으로 몇 분에서 몇 시간 동안 얼마나 많은 전력이 사용될지를 예측하는 기술이다. 기존에는 도시 전체나 변전소처럼 **큰 규모의 부하를 예측하는 연구**가 대부분이었지만, 스마트그리드가 발전하면서 **개별 가정의 전력 사용량을 예측하는 기술의 중요성**이 점점 커지고 있습니다.

01 Introduction

왜 개별 가정 부하예측이 중요할까?

개별 가정의 전력 사용량을 정확하게 예측하면 ESS를 언제 충전하고 방전할지 결정할 수 있고, 수요반응(DR)을 통해 피크 시간대의 전력 사용을 줄일 수도 있다. 또한 전기요금을 절감하고 스마트그리드 운영의 효율성을 높일 수 있다.



01 Introduction

개별 가정부하의 특징

개별 가정의 전력 사용량은 **사람의 생활 패턴에 직접적인 영향**을 받는다.

예를 들어 아침에는 커피포트와 전기밥솥을 사용하고, 낮에는 외출로 인해 사용량이 줄어들며, 저녁에는 세탁기나 TV, 에어컨 등을 사용하면서 전력 소비가 크게 증가한다.

이처럼 생활 습관에 따라 전력 사용량이 계속 변하기 때문에 개별 가정의 부하예측은 계통 부하를 예측하는 것보다 훨씬 어렵다.



02 Problem Statement

기존 예측 기법의 한계

기존에도 다양한 부하예측 방법이 연구되었다. 대표적으로 ARIMA, Artificial Neural Network(ANN), K-Nearest Neighbor(KNN), Extreme Learning Machine(ELM) 등이 있다. 기존 방법은 비선형 데이터를 처리할 수 있지만, **장기간의 시간적 의존성(Long-Term Dependency)을 충분히 학습하지 못한다**. 즉, 현재 시점의 데이터는 잘 학습할 수 있지만, 시간이 오래 지난 정보가 현재 소비에 미치는 영향을 충분히 반영하지 못한다는 한계가 있다.

기존 모델	한계
ARIMA	비선형 패턴 학습 어려움
ANN	장기 의존성 학습 어려움
KNN	데이터 증가 시 계산량 증가
ELM	시간 정보 반영이 제한적

03 LSTM Architecture

Recurrent Neural Network (RNN)

먼저 LSTM을 이해하기 위해서는 RNN을 알아야 한다. 일반적인 신경망은 입력과 출력이 서로 독립적이지만, RNN은 **이전 시점의 정보를 다음 시점으로 전달하면서 데이터를 학습**한다. 그래서 시계열 데이터나 자연어처럼 순서가 중요한 데이터를 처리하는 데 많이 사용된다. 하지만 RNN은 학습이 반복될수록 Gradient가 점점 작아지는 **Vanishing Gradient 문제가 발생**하여 **오래된 정보를 제대로 기억하지 못하는 한계**가 있다.

03 LSTM Architecture

Structure of LSTM Cell

① Forget Gate → 이전 정보 중 불필요한 정보를 삭제

② Input Gate → 새로운 정보를 저장

③ Output Gate → 현재 예측에 필요한 정보를 출력

Cell State → 장기 기억(Long-Term Memory)

즉, LSTM은 기억하고, 업데이트하고, 출력하는 과정을 반복하면서 데이터를 학습합니다.

03 LSTM Architecture

Mathematical Representation of LSTM

1. Forget Gate $f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$

→ 이전 정보를 얼마나 유지할지 결정

2. Input Gate $i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$

→ 새로운 정보를 얼마나 저장할지 결정

3. Cell State $C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t$

→ 이전 기억과 새로운 정보를 결합

4. Output Gate $o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$
 $h_t = o_t \odot \tanh(C_t)$

→ 최종 출력 생성

이러한 구조 덕분에 LSTM은 오랜 시간의 데이터를 기억할 수 있으며, 개별 가정의 전력 사용 패턴과 같은 **장기적인 시간 의존성을 효과적으로 학습**할 수 있습니다.

04 Perposed Method

전체적인 프레임워크




Fig. 7. The LSTM based forecasting framework.

논문에서 제안한 전체 예측 과정이다.

먼저 스마트미터로부터 전력 사용 데이터를 수집한다.

수집된 데이터는 전처리 과정을 거쳐 학습 가능한 형태로 변환된다.

이후 LSTM이 시간적인 특징을 학습하고

마지막 Feed Forward Neural Network가 최종 전력 사용량을 예측한다.

즉, LSTM은 특징을 추출하고, 마지막 신경망이 예측값을 출력하는 구조이다.

04 Perposed Method

입력데이터 구성

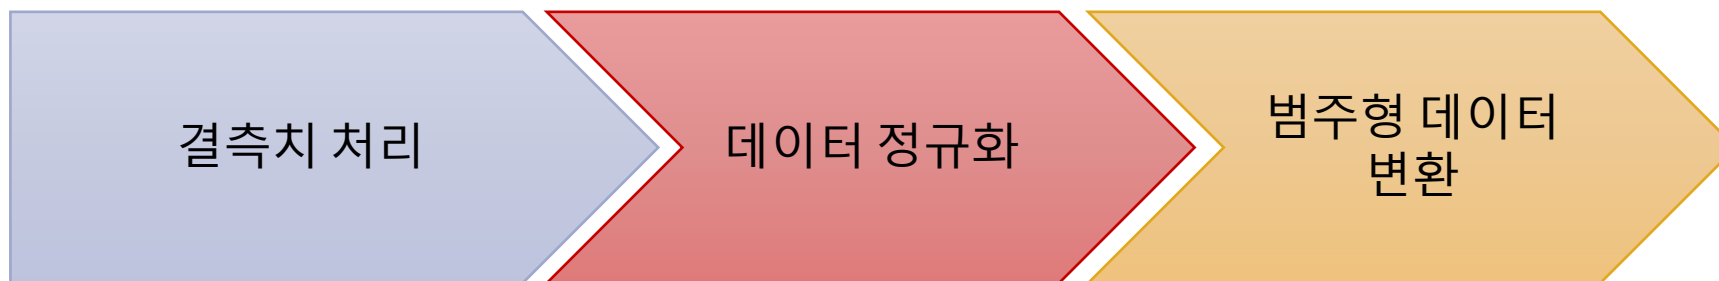
- Historical Load → 과거 전력 사용량
- Time Index → 시간 정보
- Day of Week → 요일 정보
- Holiday → 공휴일 여부

예를 들면 **공휴일과 평일은 생활 패턴이 다르기 때문에 같은 시간이라도 전력 사용량이 달라질 수 있다.** 그래서 이러한 정보를 함께 입력하여 예측 성능을 높였다.

04 Perposed Method

데이터 전처리


학습하기 전에 데이터를 전처리한다. 먼저 결측치를 처리하고, 데이터의 크기를 일정하게 맞추기 위해 정규화를 수행한다. 또한 요일이나 공휴일과 같은 범주형 데이터는 One-Hot Encoding을 사용하여 숫자로 변환한다. 이 과정을 거쳐 LSTM이 데이터를 효과적으로 학습할 수 있도록 한다.



04 Perposed Method

Forecasting Process

예측 과정은 크게 두 단계이다. 첫 번째는 LSTM이 과거 전력 사용 데이터를 분석하여 시간적인 패턴을 학습한다. 예를 들어 매주 금요일 저녁에는 전력 사용량이 증가하는 패턴과 같은 장기적인 특징을 기억한다. 두 번째는 Feed Forward Neural Network가 LSTM이 추출한 특징을 이용하여 최종 전력 사용량을 예측한다.



05 Experimental Results

기존 모델과 성능 비교

LOAD FORECASTING MAPE SUMMARY

<i>Method/Scenario</i>	<i>Avg. MAPE individual forecasts</i>	<i>Avg. MAPE Aggregating forecasts</i>	<i>Avg. MAPE forecasting the aggregate</i>
LSTM/2 time steps	44.39 %	8.18%	9.14%
LSTM/6 time steps	44.31%	8.39%	8.95%
LSTM/12 time steps	44.06%	8.64%	8.58%
Empirical mean	136.46%	32.54%	32.54%
MAPE minimisation	46.00%	34.91%	27.28%
BPNN-D/1 day	80.02%	11.69%	14.50%
BPNN-D/2 days	75.28%	11.67%	14.48%
BPNN-D/3 days	74.10%	11.66%	14.42%
BPNN-T/2 time steps	49.62%	8.37%	9.54%
BPNN-T/6 time steps	49.04%	8.29%	9.55%
BPNN-T/12 time steps	49.49%	8.36%	9.17%
KNN/2 time steps	74.83%	15.37%	11.23%
KNN/6 time steps	71.19%	14.61%	12.10%
KNN/12 time steps	81.13%	15.23%	15.30%
ELM/2 time steps	122.90%	33.68%	Not tested
ELM/6 time steps	136.49%	35.35%	Not tested
ELM/12 time steps	123.45%	30.05%	Not tested
IS-HF	96.76%	20.43%	32.09%

논문에서는 제안한 LSTM 모델을 기존의 BPNN, KNN, ELM 등과 비교하였다.

실험 결과 모든 예측 시간 구간에서 LSTM이 가장 낮은 MAPE를 기록하였다.

즉, 예측 오차가 가장 작았으며, 가장 정확한 부하예측 성능을 보였다.

Model	특징
BPNN	일반 신경망
KNN	거리 기반
ELM	빠른 학습
LSTM	장기 의존성 학습

05 Experimental Results




Fig. 8. The MAPE minimisation forecast and the empirical mean forecast.




Fig. 9. The Statistics of the best approaches.

06 Conclusion

한계 및 발전가능성

이 연구는 **스마트미터 데이터를 활용하여 개별 가정의 전력 사용량을 정확하게 예측**할 수 있음을 보여준다. 또한 이러한 예측 기술은 ESS 운영, Demand Response, 전력요금 최적화 등 다양한 스마트그리드 분야에 활용될 수 있다.

다만 본 연구는 **제한된 기간의 데이터를 사용**하였기 때문에 계절 변화나 다양한 기상 조건을 충분히 반영하지 못한 한계가 있다.

향후에는 기상 데이터, 사용자 행동 데이터 등을 함께 활용하거나 Transformer, GRU와 같은 최신 딥러닝 모델과 비교한다면 더욱 높은 예측 성능을 기대할 수 있다.

Power/Energy Track

Thank you

송실대학교 전기공학부 학술 소모임 NOVA

발표자 : 박현호