

# 최적 에너지 스케줄링을 위한 의사결정 중심의 확률론적 가정 부하 예측

김민수, 손민재, 송근주, 김재홍\*, 김홍석

서강대학교, \*LG전자

minsookim@sogang.ac.kr, hongseok@sogang.ac.kr

## Decision-focused Probabilistic Residential Load Forecasting for Optimal Energy Storage Scheduling

Minsoo Kim, Minjae Son, Keunju Song, Jaehong Kim\*, Hongseok Kim

Sogang University, \*LG Electronics

### 요약

본 논문에서는 에너지 스케줄링의 성능을 올리는데 도움이 되는 확률론적 주거 부하와 태양광 발전(PV) 예측 알고리즘을 제안한다. 단 하나의 예측 결과가 나오는 결정론적 예측과는 달리, 확률적 예측은 다양한 가능한 결과들과 그 확률을 제공함으로써, 에너지 수요와 PV 생산의 불확실성을 더 잘 반영한다. 그러나 확률론적 예측을 통해 생성되는 시나리오와 추정되는 불확실성이 실제 예측 결과가 사용되는 시스템의 최적화 성능을 높일 수 있는 것은 보장되지 않는다. 본 논문에서는 최적 의사 결정 중심의 확률적 예측을 바탕으로, 가정 에너지를 더 효율적이고 실용적으로 관리하는 방법을 제시한다. 또한, 재생 가능 에너지원의 통합과 지속 가능한 가정 에너지 관리를 위한 새로운 접근 방식을 제시한다. 실제 취득된 가정 에너지 및 태양광 데이터를 통해 시뮬레이션 결과, 제안한 알고리즘은 기존 예측 방법론과 비교했을 때 예측 성능은 떨어지지 않고 최적 가정 에너지 운용 비용이 최대 약 50% 감소했음을 확인했다.

### I. 서론

최근 전 세계적으로 재생 가능 에너지원의 채택이 증가하는 추세 속에서, 특히 주거용 태양광 발전(PV) 시스템의 통합이 중요한 관심사로 부상하고 있다 [1]. 이에 따라 가정 부하의 소비와 발전의 균형을 맞추기 위한 효율적인 에너지 관리와 전력망의 안정성을 위한 더 정교한 예측 기법이 필요하게 되었다. 기존의 결정론적 예측 방법은 정확한 단일 결과를 제공하지만, 이는 다양한 미래 시나리오와 그에 따른 불확실성을 충분히 반영하지 못한다는 큰 한계가 있다 [2]. 반면, 확률적 예측은 여러 가능한 결과와 그 확률을 제공함으로써 에너지 수요와 PV 출력의 불확실성을 보다 포괄적으로 반영한다 [3].

가정 에너지 관리의 경우, 예측 결과를 이용하여 전날 미리 (Day-ahead) 배터리 스케줄링을 하는 경우가 있다. 이때, 확률론적 예측을 통해 얻은 예측 결과를 day-ahead scheduling에 사용한다면 결정론적 예측보다 불확실성을 더 잘 반영하게 되어 실제 시스템 운용 시 가정 에너지 관리 비용이 더 적게 계산된다. 그러나 더 좋은 확률론적 예측 성능이 더 좋은 실제 시스템 운용 비용을 항상 보장하지 않는다 [4]. 왜냐하면 부하 예측 모델을 학습하기 위해 실제 부하 데이터를 레이블로 사용하는데, 이때 시스템 운용 비용을 줄이도록 학습되지는 않기 때문이다 [5]. 그러므로 본 논문에서는 확률론적 예측 모델을 시스템의 최적 의사 결정 중심으로 학습하는 방법(Decision-focused learning, DFL)을 제시한다. 이를 통해 실제 의사결정 과정을 예측 모델 학습에 통합하여 확률적 예측의 이점을 최대한 활용하면서, 실제 가정 에너지 운용 시 비용도 더 적게 사용할 수 있는 방법을 제안한다.

본 논문의 기여도는 다음과 같다. 첫째, 예측의 성능을 높이고 실제 가정 에너지 관리시 비용을 줄이도록 학습된 DF-MBLSTM을 제안했다. 제안

한 모델은 가정 부하와 태양광의 확률론적 예측을 동시에 수행하는 multi-task learning을 수행한다. multi-task learning으로 학습된 예측 모델의 출력은 가정 에너지 최적화를 위한 문제를 푸는데 사용되고, 그 후 implicit function theorem에 의해 backpropagation이 수행되어 학습이 된다. 두 번째, 실제 가정 부하 및 태양광 데이터를 통해 제안한 알고리즘을 기존 방법론들과 비교한 결과, 예측 성능은 유지되면서 최적 가정 에너지 비용이 최대 약 50% 감소했다.

### II. 본론

$$\mathcal{L}_{\text{tot}} = \mathcal{L}_{\text{pred}} + \alpha \mathcal{L}_{\text{opt}}, \quad (1)$$

$$\begin{aligned} \nabla_{\mathbf{w}} \mathcal{L}_{\text{tot}} &= \frac{\partial \mathcal{L}_{\text{pred}}}{\partial \mathbf{w}} + \alpha \frac{\partial \mathcal{L}_{\text{opt}}}{\partial \mathbf{w}} \\ &= \frac{\partial \mathcal{L}_{\text{pred}}}{\partial \mathbf{w}} + \alpha \frac{\partial \mathcal{L}_{\text{opt}}}{\partial \hat{\mathbf{z}}} \frac{\partial \hat{\mathbf{z}}}{\partial \hat{\mathbf{y}}} \frac{\partial \hat{\mathbf{y}}}{\partial \mathbf{w}}, \end{aligned} \quad (2)$$

제안한 방법론의 손실함수는 식(1)과 같다. 식(1)에서 첫번째 항은 일반적인 부하 예측을 위한 MSE이다. 여기서 두번째 항의 손실함수는 decision-focused learning을 위한 항으로써, 해당 부분도 같이 학습해나가는 것으로 최적 의사결정 중심의 확률론적 예측이 가능해진다. 하지만 해당 항은 최적화 문제를 풀어서 해결해야하므로 식(2)와 같이 직접적으로 backpropagation을 위한 미분을 계산 할 수 없다.

$$L(\mathbf{z}, \boldsymbol{\lambda}, \boldsymbol{\mu}, \hat{\mathbf{y}}) = C_{\text{tot}}^m + \boldsymbol{\lambda}^T \mathbf{g}(\mathbf{z}, \hat{\mathbf{y}}) + \boldsymbol{\mu}^T \mathbf{h}(\mathbf{z}, \hat{\mathbf{y}}), \quad (3)$$

이를 극대화하기 위해, 주어진 최적 가정 에너지 스케줄링을 위한 최적화 문제를 식(3)과 같이 Lagrange function으로 나타낸다. 그 후, KKT condition을 고려하여 식(5)와 같이 표현한다.

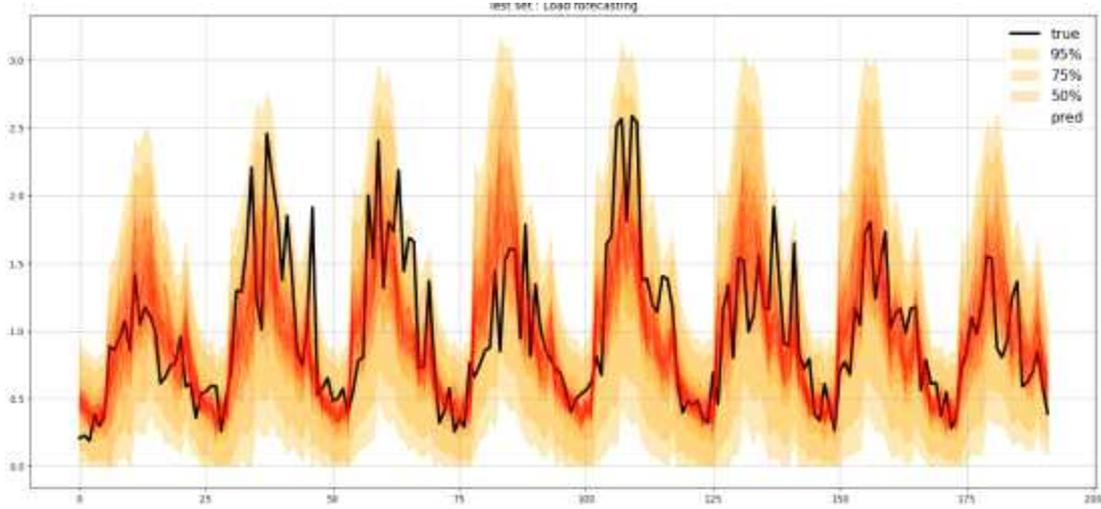


그림 1 DF-MBLSTM을 통한 부하 예측 결과

$$\Phi(\mathbf{z}, \boldsymbol{\lambda}, \boldsymbol{\mu}, \hat{\mathbf{y}}) = \begin{bmatrix} \nabla_{\mathbf{z}} C_{\text{tot}}^n + \nabla_{\mathbf{z}} \mathbf{g}(\mathbf{z}, \hat{\mathbf{y}})^T \boldsymbol{\lambda} + \nabla_{\mathbf{z}} \mathbf{h}(\mathbf{z}, \hat{\mathbf{y}})^T \boldsymbol{\mu} \\ \text{diag}(\boldsymbol{\lambda}) \mathbf{g}(\mathbf{z}, \hat{\mathbf{y}}) \\ \mathbf{h}(\mathbf{z}, \hat{\mathbf{y}}) \end{bmatrix} \quad (4)$$

$$\frac{\partial(\hat{\mathbf{z}}, \hat{\boldsymbol{\lambda}}, \hat{\boldsymbol{\mu}})}{\partial \hat{\mathbf{y}}} = - \left( \frac{\partial \Phi}{\partial(\hat{\mathbf{z}}, \hat{\boldsymbol{\lambda}}, \hat{\boldsymbol{\mu}})} \right)^{-1} \frac{\partial \Phi}{\partial \hat{\mathbf{y}}}, \quad (5)$$

$$\frac{d\Phi}{d\hat{\mathbf{y}}} = \frac{\partial \Phi}{\partial(\hat{\mathbf{z}}, \hat{\boldsymbol{\lambda}}, \hat{\boldsymbol{\mu}})} \frac{\partial(\hat{\mathbf{z}}, \hat{\boldsymbol{\lambda}}, \hat{\boldsymbol{\mu}})}{\partial \hat{\mathbf{y}}} + \frac{\partial \Phi}{\partial \hat{\mathbf{y}}} = 0, \quad (6)$$

이렇게 KKT condition을 나타내면, 최적 가정 에너지 스케줄링을 위한 최적화 문제는 결국 식(5)의 root finding method의 결과로 찾을 수 있다. 이후, implicit function theorem을 사용하여 식 (1)의 두번째 항인 decision-focused loss function을 미분할 수 있게되어 식 (6)과 같이 최적화 문제를 통과하여 학습이 가능해진다.

Method	Optimality gap (%)
LSTM	17.28
QLSTM [3]	10.18
DeepAR [6]	10.65
BLSTM [7]	12.16
MBLSTM	12.35
DF-MBLSTM (proposed)	9.66

표 1 Optimality gap 비교

5가지 baseline과 실험한 결과, 제안한 DF-MBLSTM의 Optimality gap이 가장 작게 계산되었다. 또한, DF-MBLSTM의 예측 결과는 그림 1과 같다.

### III. 결론

본 논문에서는 주거용 태양광 발전(PV) 및 부하 예측에서 의사결정 중심 학습과 확률적 예측의 통합한 DF-MBLSTM을 제안했다. 이를 가정 에너지 관리 시스템에 적용하여 제안한 DF-MBLSTM을 적용하면 실제 운용 비용이 적게 드는 확률적 예측이 가능함을 보였다. 이 연구는 에너지 부문

에서의 지속 가능한 발전을 지향하는 새로운 전략과 방향을 제시하며, 미래의 에너지 시스템 설계 및 운영에 대한 근본적인 변화를 촉진할 것으로 기대된다. 또한, 이 연구는 예측 모델과 의사결정 과정의 통합이 어떻게 실질적인 의사결정에 적용될 수 있는지를 확인 할 수 있으며, 이는 에너지 분야뿐만 아니라 다른 많은 분야에서도 적용 가능한 가치 있는 접근 방식이 될 것이다.

### ACKNOWLEDGMENT

본 연구는 한국에너지기술연구원(KETEP)의 지원을 받아 수행한 연구 과제입니다.(RS-2023-00321745)

### 참고 문헌

- [1] Kim, Minsoo, et al. "Stochastic optimization of home energy management system using clustered quantile scenario reduction." *Applied Energy* 349 (2023): 121555.
- [2] Ryu, Seunghyoung, Jaekoo Noh, and Hongseok Kim. "Deep neural network based demand side short term load forecasting." *Energies* 10.1 (2016): 3.
- [3] Wang, Yi, et al. "Probabilistic individual load forecasting using pinball loss guided LSTM." *Applied Energy* 235 (2019): 10-20.
- [4] Donti, Priya, Brandon Amos, and J. Zico Kolter. "Task-based end-to-end model learning in stochastic optimization." *Advances in neural information processing systems* 30 (2017).
- [5] Mandi, Jayanta, et al. "Decision-focused learning: Foundations, state of the art, benchmark and future opportunities." *arXiv preprint arXiv:2307.13565* (2023).
- [6] Salinas, David, et al. "DeepAR: Probabilistic forecasting with autoregressive recurrent networks." *International Journal of Forecasting* 36.3 (2020): 1181-1191.
- [7] Xu, Lei, Maomao Hu, and Cheng Fan. "Probabilistic electrical load forecasting for buildings using Bayesian deep neural networks." *Journal of Building Engineering* 46 (2022): 103853.