

제한된 데이터 환경에서의 일반화 가능한 태양광 예측을 향하여 : 이질적인 지점을 위한 Task-Agnostic Meta-Learning 프레임워크

이해중, 송근주, 김홍석

서강대학교

lhj910120@hmail.com, kjsing4089@gmail.com, hongseok@sogang.ac.kr

Toward Generalizable Photovoltaic Power Forecasting under Limited Data : A Task-Agnostic Meta-Learning Framework for Heterogeneous Sites.

Haejoong Lee, Keunju Song, Hongseok Kim

Sogang Univ

요약

태양광 발전량은 지역 및 시간에 따라 큰 변동성을 가지며, 특히 데이터가 부족한 신규 발전소에서는 예측이 어렵다. 본 연구는 미국 동부 500개 사이트의 데이터를 활용해, 다양한 환경에서도 일반화 가능한 예측 모델을 구축하고자 Task-Agnostic Meta-Learning (TAML)을 적용하였다. TAML은 기존 Transfer Learning 및 MAML의 한계를 보완하며, 7일간 과거 발전량으로 다음날을 예측하는 실험을 통해 support set 크기(~ 4 주)에 따른 성능을 비교하였다. RMSE, SMAPE(%), NMAE-10(%) 기준 평가 결과, TAML은 기존 기법보다 일관적으로 우수한 성능을 보였다.

I. 서론

기후 변화 대응 및 재생에너지 전환의 가속화에 따라, 태양광 발전은 주요 전력 공급원으로 빠르게 자리잡고 있다. 그러나 태양광 발전은 일사량, 기후 조건, 계절 변화 등에 따라 출력이 불규칙하게 변동하며, 이러한 간헐성과 예측 불확실성은 전력 계통 운영 및 수급 계획에 큰 부담을 준다. 특히 실시간 운영, 에너지 저장 시스템 제어, 전력 시장 거래 등 다양한 응용에서 정확한 태양광 발전량 예측은 필수적이다. 따라서 다양한 환경 조건과 지역적 특성을 고려한 정확하고 일반화 가능한 발전량 예측 모델 개발이 중요한 연구 과제로 떠오르고 있다. 본 연구는 미국 동부 지역의 데이터를 기반으로, 다양한 태양광 발전 사이트 간의 이질성과 데이터 불균형 문제를 극복하기 위해 메타러닝 기반 접근법을 탐구한다.

II. 본론

미국 동부 지역은 지리적, 기후적 조건이 다양하게 분포되어 있으며, 각 사이트는 서로 다른 발전량 패턴을 보인다. 그림 1은 실험에 사용된 총 875개의 사이트를 훈련(250개), 검증(125개), 테스트(500개) task로 나눈 분포를 나타낸다. 이와 같이 각 task는 계절, 일사량, 위도 등의 차이로 인해 고도로 이질적인 발전량 시계열을 생성한다. 이러한 특성은 하나의 통합 모델이 모든 사이트에서 좋은 예측 성능을 내기 어렵게 하며, 사이트 간 다양성을 반영할 수 있는 메타러닝 기반 접근이 필수적임을 시사한다.

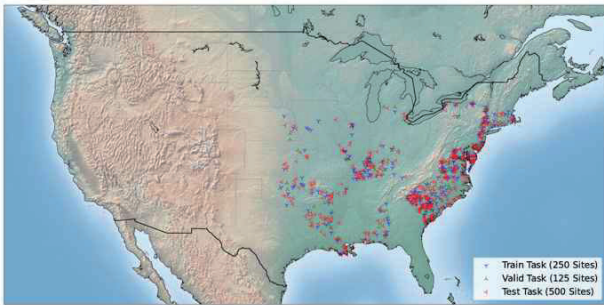


그림 1 NREL East States 발전소 분포

특히 신규 태양광 발전소의 경우, 설치 초기에는 과거 데이터가 거의 존재하지 않아 발전량 예측 모델을 학습하거나 적용하는 데 큰 어려움이 있다. 이러한 데이터 부족 문제를 극복하기 위한 접근으로는, 사전 학습된 모델을 활용하는 Transfer Learning [4]이나, 여러 task에서 빠르게 적응 가능한 초기 가중치를 학습하는 Model-Agnostic Meta-Learning (MAML) [1] 등의 메타러닝 기법을 고려해볼 수 있다. 그러나 Transfer Learning은 source 도메인에 지나치게 의존하는 경향이 있으며, target 사이트의 특성이 source와 다를 경우 일반화 성능이 급격히 저하될 수 있다. 한편, MAML은 task 간 빠른 적응을 가능하게 하지만, task 간 loss 분포의 편차가 클 경우 학습이 불안정해지고 특정 task에 편향될 위험이 있다.

이에 본 연구에서는 Task-Agnostic Meta-Learning (TAML) [2]에서 제안한 알고리즘을 활용하여, 데이터가 부족한 환경에서도 효과적으로 새로운 task에 적용할 수 있는 태양광 예측 모델을 구축하고자 한다. TAML은 메타러닝 과정에서 task 간 loss 분포의 불균형도를 정량화하고, 이를 정규화 함으로 학습에 반영함으로써, 특정 task에 편향되는 문제를 완화한다. 이를 통해 TAML은 기존의 MAML 기반 메타러닝 방식보다 더 공정하고 안정적인 task 적응 성능을 달성하며, 특히 이질적인 환경을 가진 태양광 발전 사이트들 간의 일반화 성능을 향상시키는 데 효과적이다. 사용한 TAML의 학습 절차는 Algorithm 1의 의사코드로 요약된다.

Algorithm 1 Task-Agnostic Meta Learning for Few-Shot Regression

Require: $p(\mathcal{T})$: distribution over taskRequire: α, β, λ : hyperparametersRandomly Initialize θ

while not done do

Sample batch of tasks $\mathcal{T}_i \sim p(\mathcal{T})$ for all \mathcal{T}_i doSample K samples from $p(\mathcal{T})$ Evaluate $\nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}(f_{\theta})$ and $\mathcal{L}_{\mathcal{T}_i}(f_{\theta})$ using K samples.

Compute adapted parameters using gradient descent.

 $\theta_i \leftarrow \theta - \alpha \nabla_{\theta} \mathcal{L}_{\mathcal{T}_i}$ Sample \mathcal{D}^{query} from \mathcal{T}_i for meta update.

end for

if Inequality Measures Based TAML then

Update $\theta \leftarrow \theta - \beta \nabla_{\theta} [E_{\mathcal{T}_i \sim p(\mathcal{T})} \mathcal{L}_{\mathcal{T}_i}(f_{\theta}) + \lambda \mathcal{I}_{\mathcal{E}}(\{\mathcal{L}_{\mathcal{T}_i}(f_{\theta})\})]$ using \mathcal{D}_i^{query} , $\mathcal{L}_{\mathcal{T}_i}$, and $\mathcal{I}_{\mathcal{E}}$

end if

end while

$$L_{\epsilon} = \frac{1}{M} \sum_{i=1}^M \frac{l_i}{\bar{l}} \ln \frac{l_i}{\bar{l}} \quad (1)$$

여기서 l_i 는 각 task의 loss, \bar{l} 는 loss의 평균, M 은 샘플링된 task 수를 의미한다.

본 연구에서는 미국 에너지부 산하 NREL (National Renewable Energy Laboratory) [3]에서 제공하는 미국 동부 지역의 태양광 발전 데이터를 기반으로, 11월~12월 기간의 발전량 예측 문제를 다루었다. 모델은 7일간의 과거 발전량 데이터를 입력으로 받아, 다음날(day-ahead) 발전량을 예측하도록 설계되었으며, 이와 같은 조건 하에서 다양한 메타러닝 기반 예측 방법들의 일반화 성능을 비교하였다.

- **Fully-Trained** : 사전 학습된 모델을 기반으로 새로운 사이트의 발전량을 예측하는 전이 학습 방식
- **Model-Agnostic Meta-Learning (MAML)**: 다양한 task를 대상으로 빠른 적응을 가능하게 하는 메타러닝 기법으로, 소수의 학습 샘플만으로도 새로운 사이트에 효과적으로 적응할 수 있음
- **Task-Agnostic Meta-Learning (TAML)**: task 간의 불균형 문제를 완화하고 전반적인 일반화 성능을 향상시키기 위해, 메타러닝 단계에서 task의 분포 정보를 고려하지 않는 학습이며 Theil index를 통해 loss 분포의 불균형도를 정량화하고, 이를 정규화 항으로 활용하여 공정하고 안정적인 학습을 유도

세 가지 기법은 동일한 실험 설정 하에 비교되었으며, RMSE, SMAPE, NMAE-10% 등의 정량적 지표를 통해 일반화 성능을 평가하였다. 모든 실험은 고정된 random seed 하에 5회 반복 수행되었으며, 평균과 표준편차로 결과를 정리하였다. 그림 3은 meta-test 단계에서 support set 크기(초기~4주)에 따른 성능 비교 결과를 시각화한 것이다. 실험 결과, support data가 증가할수록 예측 성능이 개선되는 경향을 보이며, TAML은 모든 조건에서 베이스라인(Fully-Trained, MAML)보다 일관되게 우수한 성능을 보였다.




그림 3 meta-test 과정에서 support set 크기에 따른 성능 평가 시각화 (seed 고정 : 5회)

	init model			1-week data			2-week data			4-week data		
	RMSE	SMAPE (%)	NAME -10(%)	RMSE	SMAPE (%)	NAME -10(%)	RMSE	SMAPE (%)	NAME -10(%)	RMSE	SMAPE (%)	NAME -10(%)
MLP (Fully-Trained)	0.1243 ± 0.0010	31.7140 ± 0.4289	14.3817 ± 0.3375	0.1197 ± 0.0005	30.7823 ± 0.1361	13.7788 ± 0.1014	0.1193 ± 0.0005	30.8817 ± 0.1780	13.8883 ± 0.1645	0.1186 ± 0.0004	30.8544 ± 0.1253	13.9002 ± 0.1314
MLP (MAML-Trained)	0.1218 ± 0.0016	31.3759 ± 0.7453	14.0823 ± 0.3853	0.1125 ± 0.0004	29.3510 ± 0.1330	13.1592 ± 0.0768	0.1108 ± 0.0006	28.9779 ± 0.1706	12.9657 ± 0.0981	0.1090 ± 0.0005	28.9036 ± 0.1661	12.7216 ± 0.0793
MLP (TAML-Trained)	0.1092 ± 0.0053	34.2597 ± 4.6056	13.9023 ± 1.7072	0.1102 ± 0.0001	28.5119 ± 0.2118	12.9867 ± 0.0616	0.1048 ± 0.0001	27.6173 ± 0.1401	12.1947 ± 0.0529	0.1039 ± 0.0001	28.1467 ± 0.2065	12.1082 ± 0.0498

표 1 meta-test 과정에서 support set 크기에 따른 성능 평가 결과 (seed 고정 : 5회)

III. 결론

본 연구에서는 미국 동부 지역의 이질적인 태양광 발전 사이트를 대상으로, 데이터가 제한된 환경에서도 일반화 가능한 예측 모델을 구축하기 위한 Task-Agnostic Meta-Learning (TAML) 기법을 활용하고 실험적으로 검증하였다. TAML은 메타러닝 과정에서 task 간 손실 loss의 불균형도를 정량화하고 이를 학습에 반영함으로써, 기존 Transfer Learning 및 MAML 기반 모델이 가지는 task 편향 문제를 효과적으로 완화하였다.

실험 결과, 다양한 support data 크기(init, 1주~4주)에 걸쳐 TAML은 전반적으로 더 낮은 RMSE, SMAPE(%), NMAE-10(%) 성능을 달성하였으며, 특히 소량의 데이터로도 빠르고 안정적인 적응이 가능함을 확인하였다. 이러한 결과는 TAML이 이질적인 재생에너지 데이터 환경에서 보다 공정하고 일반화된 예측 모델을 설계하는 데 유용한 프레임워크임을 시사한다.

ACKNOWLEDGMENT

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술연구원(KETEP) 지원을 받아 수행한 연구 과제입니다. (No. 202300321745)

참 고 문 헌

- [1] Finn, Chelsea, Pieter Abbeel, and Sergey Levine. "Model-agnostic meta-learning for fast adaptation of deep networks." International conference on machine learning. PMLR, 2017.
- [2] Jamal, Muhammad Abdullah, and Guo-Jun Qi. "Task agnostic meta-learning for few-shot learning." Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2019.
- [3] N.R.E.L. (NREL), "Solar power data for integration studies," 2006, accessed: March 14, 2025. [Online]. Available: <https://www.nrel.gov/grid/solar-power-data.html>
- [4] S. M. Miraftebadeh, C. G. Colombo, M. Longo, and F. Foadelli, "A day-ahead photovoltaic power prediction via transfer learning and deep neural networks," Forecasting, vol. 5, no. 1, pp. 213 - 228, 2023.