

FedOPF-FM: 계층적 그래프 연합학습 기반 최적조류계산 파운데이션 모델

송근주, 김기백*, 김홍석

서강대학교, *아르곤 국립 연구소

kjsong4089@sogang.ac.kr, *kimk@anl.gov, hongseok@sogang.ac.kr

FedOPF-FM: Towards the OPF Foundation Model with Hierarchical Graph Federated Learning Approach

Song Keunju, Kim Kibaek*, Kim Hongseok

Sogang Univ., *Argonne National Lab.

요약

전력망은 기후 변화에 따른 분산자원 투입 증가, 데이터 센터로 인한 부하 급증으로 인해 시스템 복잡성과 불확실성이 증가하고 있다. 이러한 형태의 전력망을 운영함에 있어 기존 수학적 최적화 모델은 수렴 불안정성의 증가로 주어진 시간내에 해결하지 못하는 문제점이 있다. 그로 인해 최근 파운데이션 모델 기반의 빠른 적응성을 활용하려는 시도가 있으나, 특성상 전력망 데이터는 매우 민감하고 불균형적 문제가 있어 파운데이션 모델 설계에 한계가 있다. 따라서 이를 해결하기 위해 본 논문에서는 계층적 그래프 연합학습 기반 최적조류계산 파운데이션 모델을 개발하여 데이터 프라이버시를 보호하며 최적조류계산 문제를 빠르게 해결할 수 있는 방법을 제안한다.

I. 서론

기후변화 및 데이터 센터의 설치로 현대 전력망은 분산자원으로 인한 불확실성과 부하 급증으로 인한 복잡성이 증가하고 있는 추세이다. 따라서 기존의 수학적 최적화 모델로는 주어진 시간내에 해를 도출하지 못해 전력망 운영 시 유연한 대처가 어려운 문제점이 있다. 이를 해결하기 위해 최근 전력망에서도 파운데이션 모델을 설계하려는 노력이 있으나[1], 전력망 데이터는 매우 민감하여 공유가 어렵기 때문에 국가 혹은 사업자 간 파운데이션 모델 설계가 제한되는 실정이다. 또한 불균형 데이터 특성이 내재되어 있어 파운데이션 모델 설계 시 오히려 성능이 저하될 수 있는 우려도 존재한다. 따라서 본 논문에서는 계층적 그래프 연합학습을 통해 데이터 프라이버시 보장 및 전력망의 이중특성을 고려하며 일반화 성능을 향상하는 파운데이션 모델을 제안한다. 시뮬레이션 결과, 우리는 제안한 파운데이션 모델이 최적조류계산 문제에 대해 약 99% 이상의 정확도로 최소 73초의 빠른 파인튜닝 소요시간을 확보할 수 있음을 확인하였다.

II. 본론

우리는 전력망 데이터의 높은 민감성을 고려하여 데이터 공유 없이 파운데이션 모델을 설계하기 위해 연합학습을 고려하였다. 연합학습은 클라이언트와 서버로 구성되어 있으며, 상호 간에는 데이터가 아닌 모델 학습 파라미터를 공유한다. 먼저 서버에서 초기 모델을 클라이언트에게 전달해주면 클라이언트는 그 모델을 바탕으로 보유하고 있는 데이터에 대해 학습을 수행한다. 이후 클라이언트는 학습이 끝난 모델을 서버로 전달해주며, 서버는 이를 취합해 연산하여 모델을 업데이트한다. 이 과정을 반복하면 클라이언트는 직접적인 데이터 공유 없이도 일반화 성능이 향상된 모델을 확보할 수 있다. 하지만 전력망 데이터는 불균형성이 내재된 이중 그래프 형태로, 일반적인 연합학습을 적용했을 시 클라이언트 드리프트 현상이 발생하여 성능이 저하되는 단점이 있다[2]. 따라서 이를 해결하기 위해 클라이언트 모델 파라미터 정보에 군집 분석을 적용한 군집 연합학습[3]이

있지만, 그룹 개수별로 서버 모델이 존재하기 때문에 파운데이션 모델 설계에 구조적인 한계가 있다. 따라서 우리는 군집 분석을 통해 구성된 그룹 모델들에 대하여 상단에 단일 글로벌 모델로 취합할 수 있는 계층적 연합학습 구조를 개발하였다. 일반화 성능을 고려하기 위해 우선 글로벌 모델은 학습이 끝난 클라이언트 모델을 취합하여 업데이트를 수행한 뒤, 그룹 모델들과의 파라미터 차이를 계산하여 이를 클라이언트로 전달한다. 이후 각 클라이언트는 해당 정보를 손실함수에 반영해 그룹과 글로벌 모델간의 차이를 최소화하는 그룹-글로벌 보정 학습을 진행한다. 이 과정을 통해 우리는 전력망 데이터 프라이버시 보호, 이중 형태로 인한 드리프트 방지, 그리고 일반화 성능이 뛰어난 파운데이션 모델을 확보할 수 있다. 그림 1은 제안한 기법의 전체 구조를 나타낸다.

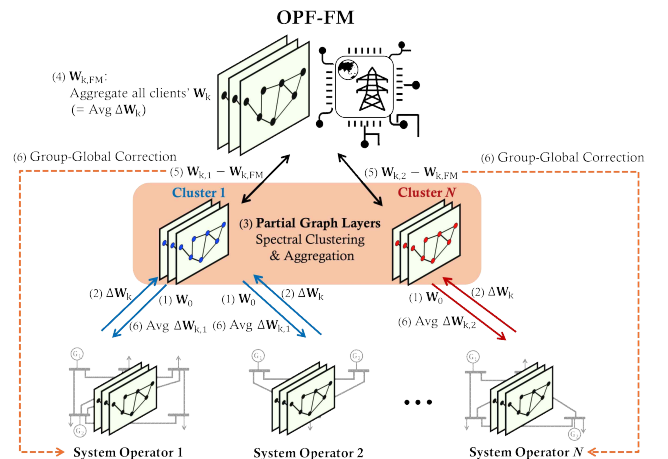


그림 1 제안하는 계층적 그래프 연합학습 구조

III. 결론

실험을 위해 우리는 PGLib 전력망 데이터셋[4]을 통해 12개의 전력망을

가져와 클라이언트로 구성하였다. 각 클라이언트의 데이터셋은 주어진 전력망의 부하 값에 대해 $\pm 20\%$ 범위로 랜덤하게 변동을 주어 각각 학습데이터 100개, 검증데이터 200개를 생성하였다. 표1은 실험에 사용한 12개 전력망의 구조 정보를 나타낸다.

전력망	버스 개수	발전기 개수	선로 개수
IEEE 14	14	5	20
IEEE 57	57	7	80
PGLib 60	60	23	88
IEEE 73	73	33	120
PEGASE 89	89	12	210
IEEE 118	118	54	186
IEEE 162	162	12	284
SNEM 197	197	35	286
PGLib 250	250	42	339
GOC 793	793	89	913
PEGASE 1354	1354	260	1991
Wisconsin 1664	1664	78	2462

표 1 전력망 구조 정보

표2는 제안하는 계층적 연합학습 구조(HGFL)의 성능을 확인하기 위해 연합학습에서 널리 쓰이는 FedAvg[5]와 군집 연합학습의 방법론 중 하나인 CFL-GP[3]와 비교한 결과이다. FedAvg 경우 특히 PEGASE 1354 클라이언트가 상대적으로 성능이 급격히 저하되었음을 확인할 수 있으며, 이는 전력망 데이터가 불균형의 이중 형태임을 보여준다. 반면 CFL-GP와 제안하는 HGFL은 전반적으로 비슷하게 높은 성능을 보여주고 있어 HGFL 기법이 클라이언트의 성능 저하 없이 일반화 성능이 높은 파운데이션 모델을 설계할 수 있음을 보여준다.

Bus systems	Method	Cost	Opt. gap (%)	P_g (%)	Q_g (%)	V_m (%)	s_{ij} (%)	Active PF (%)	Reactive PF (%)
IEEE 14	FedAvg	2196.59	1.05	100	97.1	100	100	100	100
	CFL-GP	2174.87	0.05	100	98.9	100	100	100	100
	HGFL	2176.85	0.14	100	96.2	100	100	100	100
IEEE 57	FedAvg	37686.04	0.10	91.57	96.71	98.35	100	100	100
	CFL-GP	37276.50	-0.98	87.64	97.71	98.94	100	100	100
	HGFL	38331.49	1.82	95.21	93.64	98.54	100	100	100
PGLib 60	FedAvg	96248.80	3.12	99.09	100	99.47	99.92	100	100
	CFL-GP	93821.18	0.51	98.46	100	99.78	99.90	100	100
	HGFL	96870.03	3.78	98.07	100	98.72	99.91	100	100
IEEE 73	FedAvg	727799.84	-0.68	99.09	99.27	87.44	98.75	100	100
	CFL-GP	727737.81	-0.69	99.17	98.82	87.11	98.73	100	100
	HGFL	728363.72	-0.61	98.91	99.73	84.38	98.82	100	100
PEGASE 89	FedAvg	101196.52	3.21	99.08	93.25	100	99.97	100	100
	CFL-GP	101116.37	3.13	99.13	93.71	99.89	99.97	100	100
	HGFL	100985.62	2.99	99.08	94.21	99.17	99.97	100	100
IEEE 118	FedAvg	97684.86	0.47	100	99.15	99.96	99.93	100	100
	CFL-GP	97639.24	0.42	100	99.36	99.92	99.94	100	100
	HGFL	97651.45	0.43	100	99.43	100	99.93	100	100
IEEE 162	FedAvg	112384.57	3.68	99.79	98.58	96.24	99.50	100	100
	CFL-GP	111243.73	2.62	99.88	99.13	95.91	99.85	100	100
	HGFL	112508.74	3.79	99.79	99.08	96.10	99.86	100	100
SNEM 197	FedAvg	22463	50.24	99.57	100	99.98	100	100	100
	CFL-GP	15154	1.36	99.89	100	99.99	100	100	100
	HGFL	15174	1.49	98.86	100	99.99	100	100	100
PGLib 250	FedAvg	540142.29	0.06	99.83	100	99.98	100	100	100
	CFL-GP	540079.84	0.04	99.69	100	99.98	100	100	100
	HGFL	540121.77	0.05	99.89	100	98.49	100	100	100
GOC 793	FedAvg	293930.28	3.56	100	96.35	99.96	99.97	100	100
	CFL-GP	290342.96	2.30	100	99.13	99.99	99.95	100	100
	HGFL	290970.31	2.52	100	99.39	99.99	99.94	100	100
PEGASE 1354	FedAvg	1340853.58	6.49	99.96	73.70	93.41	99.97	100	100
	CFL-GP	1310063.48	4.05	99.92	93.19	99.99	99.99	100	100
	HGFL	1311519.32	4.16	99.92	95.86	99.99	99.99	100	100
Wisconsin 1664	FedAvg	223374.39	0.26	99.93	99.21	99.96	99.99	100	100
	CFL-GP	223453.54	0.29	99.96	99.30	99.97	99.99	100	100
	HGFL	223303.07	0.23	99.94	99.31	99.98	99.99	100	100

표 2 연합학습 기반 최적조류계산 실험 결과

표3은 제안하는 HGFL을 통해 설계된 최적조류계산 파운데이션 모델(FedOPF-FM)에 대한 파인튜닝 결과이다. 빠른 적응성을 확인하기 위해 클라이언트로 구성된 전력망이 아닌 새로운 전력망에 대해 파인튜닝을 진행하였으며, 초기 랜덤 모델 파라미터로 설정하여 학습하는 Local training 방식과 비교하였다. 특히 우리는 한국전력거래소에서 제공한 실제 국내 전력망 데이터를 사용하여 제안하는 모델의 실용성을 확인하였다. 표4는 새로운 전력망의 구조 정보를 나타낸다.

전력망	버스 개수	발전기 개수	선로 개수
KPX 4492	4492	182	5969
GOC 3970	3970	123	6641

표 4 전력망 구조 정보

실험 결과, FedOPF-FM 기반의 파인튜닝 방식이 Local training 대비 높은 성능을 보였으며, 각각 약 73초, 242초의 빠른 소요시간을 보였다. 그림 2, 3은 각 전력망의 학습 손실 커브를 나타내며, 파인튜닝 방식이 빠른 학습 수렴성을 보여주는 걸 확인할 수 있다.

Bus systems	Method	Cost	Opt. gap (%)	P_g (%)	Q_g (%)	V_m (%)	s_{ij} (%)	Active PF (%)	Reactive PF (%)
KPX 4492	FedOPF-FM	124404.33	2.58	99.80	100	99.96	100	99.99	99.91
	Local training	126460.70	4.27	99.82	100	99.91	100	99.99	99.92
GOC 3970	FedOPF-FM	3915533.5	2.11	99.35	91.37	100	99.98	100	100
	Local training	3920566.75	2.25	99.29	91.87	100	99.98	100	100

표 3 FedOPF-FM 파인튜닝 실험 결과




그림 2 KPX 4492 전력망에 대한 학습 손실 커브 결과




그림 3 GOC 3970 전력망에 대한 학습 손실 커브 결과

ACKNOWLEDGMENT

This work was supported by the Global Research Lab through the National Research Foundation of Korea (NRF) funded by the Ministry of Science and ICT under Grant RS-2025-02215243.

참 고 문 헌

- [1] H. F. Hamann, et al. "Foundation models for the electric power grid". *Joule* 8.12 (2024): 3245-3258.
- [2] H. Kang, et al. "FedAND: Federated learning exploiting consensus ADMM by nulling drift." *IEEE Transactions on Industrial Informatics* 20.7 (2024): 9837-9849.
- [3] H. Kim, H. Kim, and G. D. Veciana. "Clustered federated learning via gradient-based partitioning." *Forty-first international conference on machine learning*. 2024.
- [4] S. Babaeinejadsarookolae, et al. "The power grid library for benchmarking ac optimal power flow algorithms." *arXiv preprint arXiv:1908.02788* (2019).
- [5] B. McMahan, et al. "Communication-efficient learning of deep networks from decentralized data." *Artificial intelligence and statistics*. PMLR, 2017.