

报告题目： AI大模型技术在电力系统中的应用 及发展趋势

报告人：赵俊华
单位：香港中文大学（深圳）
时间：2025年6月10日





香港中文大學(深圳)
The Chinese University of Hong Kong, Shenzhen

01 大语言模型与智能体技术简介

人工智能AI近代史：从早期的逻辑程序到神经网络的兴起



*来源：艾瑞 2023年AIGC场景应用展望研究报告



什么是语言模型

一个前缀输入



你好。



人类



语言模型



建模

给定相同前缀，语言模型是输出能近似人类语言分布的模型。

LLM架构与训练：预训练阶段





Figure 12-3. The three steps of creating a high-quality LLM.

学习文字接龙(prefix LM), 无需标注, 自监督 (self-supervised)

书籍
论文
新闻
网络爬虫

私有知识库

开源数据集
(数学、推理)



LLM架构与训练：预训练阶段

预训练模型三要素


以及更多钱



- **大数据**：知识的来源，包含各种语言现象及语义知识，直接决定了模型的学习范围
- **大模型**：容纳大数据的载体，通常由深度神经网络构成，学习大数据中的统计信息与抽象知识
- **大算力**：处理大数据和大模型的并行计算集群，通常包含GPU、TPU等高性能运算设备



大数据
(无标注文本)



大模型
(深度神经网络)



大算力
(并行计算集群)

如何训练自己的LLM？微调训练

直接全量参数微调问题：


- LLM参数量巨大，7b=70亿参数
- 耗费GPU资源多，通常需要A100*8以上(百万RMB)
- 训练时间长，需要数周时间



解决方案：LoRA(Low-Rank Adaptation of Large Language Models)

核心优势：

- 训练参数量少，70亿参数使用LoRA只需要训练百万级别参数
- 微调效果好，LoRA效果不差于全参数微调，优于其他微调方式
- GPU要求低，3090*4即可微调7b模型




Model & Method	# Trainable Parameters	E2E NLG Challenge				
		BLEU	NIST	MET	ROUGE-L	CIDEr
GPT-2 M (FT)*	354.92M	68.2	8.62	46.2	71.0	2.47
GPT-2 M (Adapter ^L)*	0.37M	66.3	8.41	45.0	69.8	2.40
GPT-2 M (Adapter ^L)*	11.09M	68.9	8.71	46.1	71.3	2.47
GPT-2 M (Adapter ^H)	11.09M	67.3 $\pm$ 0.6	8.50 $\pm$ 0.07	46.0 $\pm$ 0.2	70.7 $\pm$ 0.2	2.44 $\pm$ 0.01
GPT-2 M (FT ^{Top2})*	25.19M	68.1	8.59	46.0	70.8	2.41
GPT-2 M (PreLayer)*	0.35M	69.7	8.81	46.1	71.4	2.49
GPT-2 M (LoRA)	0.35M	70.4 $\pm$ 0.1	8.85 $\pm$ 0.02	46.8 $\pm$ 0.2	71.8 $\pm$ 0.1	2.53 $\pm$ 0.02
GPT-2 L (FT)*	774.03M	68.5	8.78	46.0	69.9	2.45
GPT-2 L (Adapter ^L)	0.88M	69.1 $\pm$ 0.1	8.68 $\pm$ 0.03	46.3 $\pm$ 0.0	71.4 $\pm$ 0.2	2.49 $\pm$ 0.0
GPT-2 L (Adapter ^L)	23.00M	68.9 $\pm$ 0.3	8.70 $\pm$ 0.04	46.1 $\pm$ 0.1	71.3 $\pm$ 0.2	2.45 $\pm$ 0.02
GPT-2 L (PreLayer)*	0.77M	70.3	8.85	46.2	71.7	2.47
GPT-2 L (LoRA)	0.77M	70.4 $\pm$ 0.1	8.89 $\pm$ 0.02	46.8 $\pm$ 0.2	72.0 $\pm$ 0.2	2.47 $\pm$ 0.02


Table 3: GPT-2 medium (M) and large (L) with different adaptation methods on the E2E NLG Challenge. For all metrics, higher is better. LoRA outperforms several baselines with comparable or fewer trainable parameters. Confidence intervals are shown for experiments we ran. * indicates numbers published in prior works.

从人类反馈中学习-强化学习 (RLHF)

语言模型的社会化



LLM架构与训练：各个训练阶段综合来看..



带着笑脸的修格斯。（由 twitter.com/anthrupad 提供）

Agent(自主智能体)考古学：通用定义

自主智能体



能够自动感知环境
能够在环境中自主行动
能够通过环境反馈自主学习

--- Maes (1995)




WIKIPEDIA
The Free Encyclopedia


典型实例




DeepMind Lab, 2016



Embodied QA, FAIR, 2018



LLM Agent: 关键能力—使用工具



常用工具:

- API
- 搜索引擎
- 爬虫
- 代码
- 绘图

LLM Agent: 关键能力—任务分解与试错

Trial and Error



LLM Agent: 关键能力—Long-term Memory



A long-term memory

- Read and write
- Stores experience, knowledge, skills, ...
- Persist over new experience

Instruction: ...
Thought: ...
Action: ...
Obs: ...
Thought: ...
.....




THE TRAGEDY OF A THREE SECOND MEMORY

Long-term Memory与RAG区别:
可读写性


与Human Brain Mapping:

Type by content	Definition	Examples
Episodic memory	Stores experience	Generative agents [Park et al., 2023]
Semantic memory	Stores knowledge	
Procedural memory	Stores skills	Voyager [Wang et al., 2023]



LLM Agent: 关键能力—自主学习

- Fine-tuning model weights (the most obvious) - **FireAct**
- Optimizing prompts across tasks – **LLM are Human-level Prompt engineers**
- Improve the agent's own codebase – **SWE-agent**
- Write down examples/events to retrieve later – **Generative Agent**
- Append self-reflection to prompt to try again - **Reflexion**
- Combine multiple approaches



Reflexion, 2023



Fine-Tuning and Prompt Optimization: Two Great Steps that Work Better Together

Dilara Soylu Christopher Potts Omar Khattab


Stanford University



Generative agents, 2023




Large Language Models Are Human-Level Prompt Engineers, 2023



SWE-agent, 2024

LLM Agent: 新的模型能力获取范式



智能体时代模型能力获取的新范式



香港中文大學(深圳)
The Chinese University of Hong Kong, Shenzhen

02 LLM Agents在电力系统研究中的应用思考

大模型的核心能力



自然语言与常识理解



逻辑推理



Mathematical Modeling

数学建模与公式推导



代码生成

LLM Agent在新型电力系统中的应用思考

LLM Agent的潜在应用领域：


- 机器人（机巡、客服、公文写作等）
- workflow重构（调度运行规划）
- 信息-物理-社会系统(CPSSE)仿真
- 多模态数据融合（数字化服务）
- 电力系统机理研究（AI4S）

- 在调度运行等核心领域，大模型的**推理可靠性**与“**幻觉**”问题，决定了大模型尚不能完全替代人工。
- 已经应用良好的各种基于因果模型的工具**无需替代**。
- 可以考虑采取**因果模型 + 大模型 + 符号串模型（SPT） + 小模型融合**的技术路线。

薛禹胜, 新型能源体系（CPSS-EEE）的多目标协调规划, <https://mp.weixin.qq.com/s/fodienZxB24j9MRX6qFa9w>


赵俊华, 文福拴, 黄建伟, 等. 基于大语言模型的电力系统通用人工智能展望：理论与应用 [J]. 电力系统自动化, 2024, 48 (6) : 13-28.

在Agent的框架下实现多类模型的融合




- 适用于误决策代价比较小的简单机器人场景;
- 不适用于需要对电力系统精确量化的场景;
- 适用于需要引入文本、视频等多种模态数据，且误决策代价较小的场景;

在Agent的框架下实现多类模型的融合




- 实现推理与计算的统一;
- 较好的模拟因果模型背后的物理机理;
- 神经网络架构尚有待探索;
- 可解释性不足;

在Agent的框架下实现多类模型的融合



- 推理大模型作为“大脑”，主要负责问题的规划、任务的分解与高层次推理；
- PINN可在尽量保留因果模型准确性的前提下，大幅提高计算速度；
- 因果模型可在部分必要场景下，保证决策结果的可靠性；
- 符号模型可以在推理中提取形式化知识，保证智能体整体框架的可解释性；

在Agent的框架下实现多类模型的融合



- 必要的场景中，可以将人引入多智能体框架中；
- 人可以向智能体提供反馈，并作为最终决策者判定决策质量；
- 决定人什么时候介入是一个待解决的课题；

信息物理社会系统仿真

- 大模型的“智能涌现”现象，再次表明复杂系统的研究问题无法完全在还原论的框架下解决。
- 受薛禹胜院士的**整体还原论 (WRT)** 方法论的启发，我们在思考如何将大模型应用于解决复杂的信息物理社会系统 (CPSSE) 的仿真问题。
- WRT以CPSSE框架刻画复杂系统，以**混合动态仿真**来提取对象系统的**高维仿真轨迹**，基于轨迹动力学的时空保熵映射，将复杂系统的研究从线性的“**局部还原**”提升为非线性的“**整体保熵还原**”。
- 大语言模型可以基于仿真或实测轨迹数据，基于其内化的理论常识，以**一定概率**在局部**自主**进行逻辑推理，实现对**复杂系统局部的可解释性**。
- 基于大模型内化的理论常识，大模型也可以用作**严格因果模型**与**近似模型**的选择器。
- 在CPSSE中，社会行为的建模是研究难点。
- 我们的初步研究表明，大语言模型已具有模仿人进行**系统性逻辑思维**的能力。因此，可以在CPSSE仿真中，结合真人、因果模型和大语言模型，实现更精确的**人机混合仿真**。
- 大模型的**推理可靠性**与“**幻觉**”问题，目前尚无法完全解决。现阶段，“**人机混合智能**”可能是最符合电力系统实际的解决方案。
- CPSSE仿真问题解决后，通过CPSSE对实际系统进行反馈，构建大模型驱动的数字孪生，是研究的终极目标。

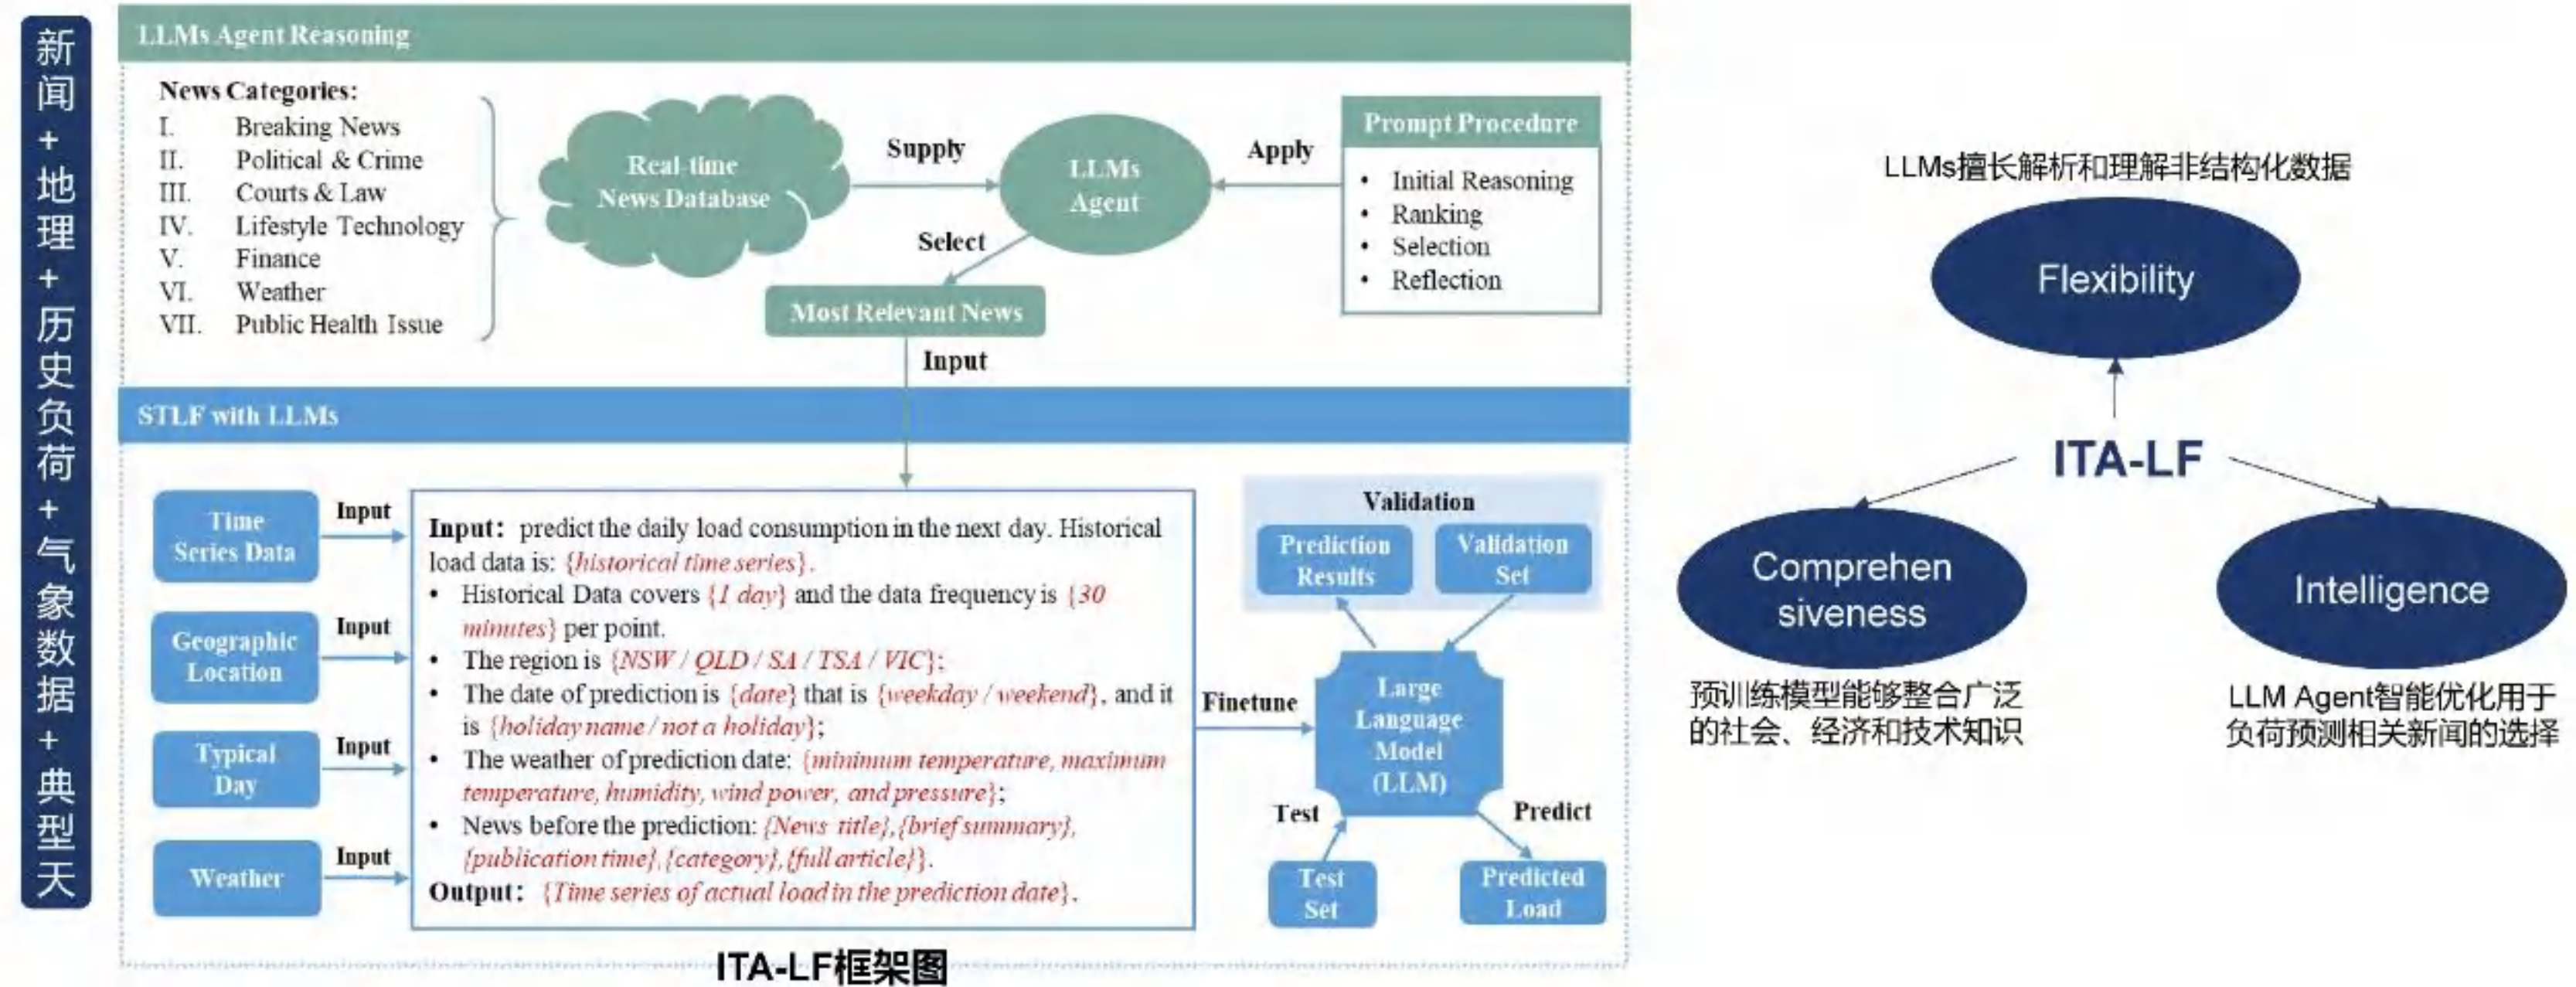


香港中文大學(深圳)
The Chinese University of Hong Kong, Shenzhen

03 LLM Agents的应用初探




基于大语言模型实现高适应性负荷预测（多模态数据融合）

- **传统方法局限：** 1. 难以应对特殊事件发生时，短期电力负荷的快速变化或极端波动； 2. 不能适应超出历史数据涵盖范围的新场景； 3. 无法基于文本数据（新闻事件）进行预测推理。
- **提出Intelligent Text-Analytic Load Forecasting (ITA-LF)：** LLM能够基于语言有效处理、整合非结构化及海量多源数据，**通过Agent筛选实时相关新闻并理解文本逻辑**，显著提升预测的适应性和精确度。




基于大语言模型实现高适应性负荷预测

新闻事件相关的文本数据的引入，有效提升在特定事件发生时负荷预测精确度。



- Agent对新闻事件的筛选，在提升大模型输入token效率的同时增强预测精确度：




- 基于新闻和负荷数据的ITA-LF预测效果普遍优于现有方法：

TABLE I
PERFORMANCE METRICS OF DIFFERENT MODELS

Model	MSE	RMSE	MAE	MAPE	Accuracy
LSTMa	481 006.30	693.55	523.23	21.25%	82.08%
SARIMA	475 200.06	689.35	421.82	11.61%	89.93%
ReFormer	169 355.11	411.53	283.97	11.26%	89.93%
Informer	216 422.27	465.21	331.17	11.91%	88.65%
AutoFormer	224 497.31	473.81	323.89	11.93%	89.20%
ITA-LF (Case 1)	154 388.74	392.92	216.56	6.71%	93.92%
ITA-LF (Case 3)	107 780.74	328.30	182.54	6.09%	94.70%
ITA-LF (Case 2)	89 334.67	298.89	166.27	5.42%	95.06%
ITA-LF (Case 4)	66 818.94	258.49	144.68	4.65%	95.61%

基于大语言模型实现高适应性负荷预测


- 预测效果普遍优于现有方法，在不同时间和地理维度的适应性强，显著提升预测的适应性和精确度：



基于LLM的负荷预测显著提升准确性和可靠性，优化对突发变化的应对，突出了语言处理在整合非结构化信息中的作用，标志负荷预测及时序决策研究范式的转变。

调度大模型研究背景

基于前期研究，我们发现可以将**调度、市场行为以大语言模型的形式建模**（语言模型化），解决传统调度支撑体系中**调度行为没有有效建模工具**的问题。我们希望实现调度行为数据(包含语音、拓扑结构、文本等多模态数据)、调度规程及系统工况等数据的**统一表示**，基于大语言模型多智能体实现**调度行为的理解、推理、操作序列生成、智能博弈策略生成、市场波动响应及决策优化**等目标，提高调度安全性与效率。



调度大模型数据处理


初版领域数据集

- 教材，论文集，章程等
- 调度场景数据等



大模型训练数据集

- 领域对话问答数据集



```
{
  "instruction": "Describe the main reason for winding failure in electrical transformers.",
  "input": "<noinput>",
  "output": "Insulation deterioration, often caused by moisture, overheating, vibration, voltage surges, and mechanical stress during transformer through faults, is the major reason for winding failure."
},
{
  "instruction": "Explain the potential causes of tap changer failures in transformers.",
  "input": "<noinput>",
  "output": "Tap changer failures can be caused by a malfunction of the mechanical switching mechanism, high resistance load contacts, insulation tracking, overheating, or contamination of the insulating oil."
},
{
  "instruction": "What are the possible reasons for transformer bushing failures?",
  "input": "<noinput>",
  "output": "Possible reasons for transformer bushing failures include general aging, contamination, cracking, internal moisture, loss of oil, vandalism, and external flashover caused by animals."
},
{
  "instruction": "Provide an example of a statistic related to transformer faults.",
  "input": "<noinput>",
  "output": "Statistics show that winding failures most frequently cause transformer faults."
},
{
  "instruction": "Suggest some measures to prevent transformer winding failures.",
  "input": "<noinput>",
  "output": "To prevent transformer winding failures, measures such as ensuring proper insulation, controlling moisture levels, avoiding overheating, minimizing vibration, protecting against voltage surges, and reducing mechanical stress during faults can be implemented."
},
}
```

调度大模型交互页面



业务场景支持:

- 经济调度
- 操作监护
- 黑启动

调度大模型评价指标



测试集评测体系：

- 评测围绕调度大模型在事实性、逻辑性、稳定性、公平性、安全性、表达能力**六大类二十四个子维度**展开评估。

测试集题型设定：

- 客观题：判断题、选择题、问答题
- 主观题：问答题

评测方法：

- 客观题：GPT-4 + 评测脚本
- 主观题：GPT-4 + 人工评测

传统经济学仿真面临的困难



传统方法**大多依赖于数学模型**。当仿真涉及**多个参与者和复杂策略**时，传统方法往往**难以应用**，因为计算和分析的复杂度极高。



动态博弈求解难度大：在**动态**和**不完全信息**的博弈情境中，传统方法很难求得收敛解。



泛化性较差：对于那些需要快速适应新信息和变化的实际应用场景，传统的数学方法缺乏灵活性。

大模型经济学仿真的潜力



推理能力：LLMs拥有处理复杂问题和理解复杂语境的能力，这使它们能够理解和分析复杂的博弈策略。



泛化能力：得益于LLM出色的zero-shot能力，**快速适应市场的动态变化。**结合大量历史案例，提高仿真的准确性和效率。




代理模拟：将LLM与多代理仿真结合，通过模拟市场中player行为或策略，为市场仿真提供了一种新的思路。

研究进展

背景回顾

基于大语言模型的市场仿真一般性结构框图

- 市场仿真基础单元：**市场主体、市场环境和规则、市场外部性。**
- 在电力市场中，分别对应：**“网源荷储”主体和监管主体、电力系统和市场规则、系统和市场外部扰动。**
- 大模型技术应用：**直接交易决策建模、市场规则辅助建模、外部扰动参数生成。**




研究进展

背景回顾


提示词工程和检索增强生成技术

- 提示词工程（Prompt Engineering）：模拟电力交易员工作环境，给出**机组工况**、**断面阻塞**、**燃料成本**、**碳成本**、**系统运行情况**等模式化提示语，引导LLM思考方向做更深度逐步推理；

- 检索增强生成（Retrieval-Augmented Generation, RAG）可适配、理解现货和备用市场**相关论文**、**政策文件**、**国内外市场研报**、**仿真模型数据**、**市场运行数据**、**系统工况数据**等多场景多模态数据，LLM无需增量训练即可初步理解应用领域知识。




提示词工程框架对比



检索增强生成技术框架


均衡的重要性

- 企业：确定供需平衡点，帮助企业制定合理的碳排放策略
- 政策制定者：提高市场效率，优化政策设计，促进碳排放权的有效配置



现有研究局限性

- 依赖数学模型：传统方法大多依赖数学模型，计算和分析复杂度高
- 复杂环境求解困难：在动态和不完全信息的情境中，传统方法难以构建数值解
- 泛化性较差：传统方法在应对新信息和变化时缺乏灵活性
- 难以捕捉复杂市场动态：随着数据和复杂性增加，传统方法难以全面、精确地捕捉市场动态



大语言模型优势

- 精确理解与分析市场动态：大语言模型在处理复杂数据和市场动态方面表现出色，能够深入理解市场机制，提供精确分析。
- 强大的推理与适应能力：大语言模型具备卓越的推理能力和泛化能力，能够迅速适应市场的动态变化，提供高精度的预测结果。
- 多主体策略模拟与优化：将大语言模型与代理模型结合，能有效模拟多主体行为和策略，显著提升数值解的求解效率和准确性。



求解框架



核心技术

指令工程

- 定义： 设计和优化提示词，引导大语言模型生成所需输出
- 应用： 构建求解策略和判断策略提示词
- 优势： 提高模型响应的准确性和效率



工具调用

- 定义： 动态调用外部工具或函数完成特定任务
- 应用： 利用求解工具和判断工具，特别是通过Python进行均衡求解
- 优势： 提高求解精度和效率

多代理模型

- 定义： 由多个自主决策的代理组成，模拟市场参与者行为。
- 应用： 各代理执行特定任务，如生成、评估和调整策略，最终求解市场均衡。
- 优势： 提供更准确的市场预测和均衡解。

碳市场模型构建



数据来源与处理

	A	B	C	D
1	季度	净交易额	加权价格	企业
2	2021Q1	91	48.83824176	Xingtai pov
3	2021Q2	-868	51.46421907	Xingtai pov
4	2021Q3	53	52.48660377	Xingtai pov
5	2021Q4	55	54.15709091	Xingtai pov
6	2022Q1	81	56.24271605	Xingtai pov
7	2022Q2	59	57.8940678	Xingtai pov
8	2022Q3	56	59.45357143	Xingtai pov
9	2022Q4	-230768	63.42164133	Xingtai pov
10	2023Q1	-1069	64.88495935	Xingtai pov

碳市场交易
仿真数据


碳市场企业
机组信息

碳市场企业
配额与排放数据

求解所需周期各
企业的净交易配
额量和加权价格

回归分析、
系数显著

可供实验的碳
市场企业
(富余碳配额
量，价格弹性)



回归系数 a: 3.160367029089367
p值: 0.0025152265417496948

结果示例：指令工程

综上，基于碳市场的设定，写一下四个玩家的KKT方程并求解。

为了求解四个玩家在碳市场中的KKT方程并找到最优的 b_i 和 $b_{i,4}$ 的表达式，我们需要联立方程并求解。让我们详细推导并实现代码。

KKT条件

我们需要满足以下KKT条件：

1. **Stationarity**: 拉格朗日函数对 $b_{i,j}$ 的偏导数应为零。
2. **Primal Feasibility**: 约束条件 $A_i + \sum_{j=1}^4 -Q_{i,j} \geq 0$ 应满足。
3. **Dual Feasibility**: 拉格朗日乘子 $\lambda_i \geq 0$ 。
4. **Complementary Slackness**: $\lambda_i(A_i - S_i) = 0$ 。

定义变量和参数

我们假设每个公司的碳配额需求函数为：

$$Q_{i,j} = a_i P_j + b_{i,j}$$

价格 P_j 为：

$$P_j = -\frac{\sum_{i=1}^4 b_{i,j}}{\sum_{i=1}^4 a_i}$$

拉格朗日函数

拉格朗日函数可以写为：

$$\mathcal{L}_i = \sum_{j=1}^4 P_j Q_{i,j} + (1+r_1)(1-r_2)P_4(A_i - S_i) + \lambda_i(A_i - S_i)$$

$$\text{其中 } S_i = \sum_{j=1}^4 Q_{i,j}$$

结果示例：工具调用

好的，我们将这些具体的值代入方程，并使用 SymPy 来求解。以下是完整的代码实现：

```
python
import sympy as sp

# 定义变量
b11, b12, b13, b14 = sp.symbols('b11 b12 b13 b14')
b21, b22, b23, b24 = sp.symbols('b21 b22 b23 b24')
b31, b32, b33, b34 = sp.symbols('b31 b32 b33 b34')
b41, b42, b43, b44 = sp.symbols('b41 b42 b43 b44')
lambda1, lambda2, lambda3, lambda4 = sp.symbols('lambda1 lambda2 lambda3 lambda4')

# 具体数值
a1_val, a2_val, a3_val, a4_val = 7379, 3813, 839, 788
A1_val, A2_val, A3_val, A4_val = 339800, 184200, 22880, -461
r1_val, r2_val = 0.1, 0

# 对每个 b_i,j 求导数并联立方程求解
equations = []
for i in range(4):
    for j in range(4):
        if j == 3: # 处理最后一期
            eq = sp.Eq(sp.diff(Lagrangians[i], b[i][j]), 0)
            equations.append(eq)
        elif j < 3: # 处理前三期
            eq = sp.Eq(sp.diff(Lagrangians[i], b[i][j]), 0)
            equations.append(eq)

# 添加约束条件的方程
for i in range(4):
    eq = sp.Eq(constraints[i], 0)
    equations.append(eq)
```

代码示例：多代理模型

评估模型回应生成质量

```
evaluation_prompt =
evaluation_prompt_gen(strategy, final_response)
evaluation_output, evaluation_cost =
chatgpt_agent(evaluation_prompt)


score_match = re.search(r"'score': '([0-9]+)'", evaluation_output)
if score_match:
    score = score + float(score_match.group(1))
    print(score)
else:
    # 如果没有找到匹配的score, 则打印错误信息
    score = 0
    print("No valid score found in the response.")
```

评估模型生成解是否为均衡解


```
def equilibrium_judge(game_setting, sr_response):
    prompt = equilibrium_prompt(game_setting,
sr_response)
    equilibrium_response = chatgpt_agent(prompt)
    cleaned_python_code =
clean_markdown_code(equilibrium_response)

    return execute_python_code(cleaned_python_code)
```


各类型机组占比情况



企业富余碳配额情况



企业季度价格弹性系数情况



示例: 企业参数

	大国企	中国企	气企	私企
产能 (MW)	1,995	1,200	344	100
燃料类型	煤炭	煤炭	天然气	煤炭
富余配额 (t)	430,000	128,400	22,080	-43,300
价格弹性系数	7,278	4,161	839	499

注: 以机会收益中的(1+预期上涨率)*(1 - 配额折算率)=0.8为例。


碳价格

	第一期	第二期	第三期	第四期
碳价格 (元)	18.65	18.65	18.65	74.71

交易量

交易量 (t)	第一期	第二期	第三期	第四期
大国企	102,575.11	102,575.11	102,575.11	-78,266.31
中国企	2,351.56	2,351.56	2,351.56	-42.75
气企	-42,227.9	-42,227.9	-42,227.9	31,925.46
私企	-62,698.77	-62,698.77	-62,698.77	46,383.61

碳价格随r值的变化



注: $r\text{值} = 1 - (1 + \text{预期上涨率}) * (1 - \text{配额折算率})$ 。

- **期末价格与交易量异常:** 由于机会收益与最后一期碳价格直接相关, 企业为了实现自身利益最大化, 使得碳市场在最后一期供需发生了剧烈变化, 导致碳价格在最后一期大幅波动。
- **大型企业具备操纵市场能力:** 大型国企具备足够的市场影响力, 在低价时控制供应量以稳定或提高价格, 在高价时通过抛售获利或引导市场波动。

➤ 碳价格与r值的关系:

- r值为负表示碳配额会折损, 企业会在配额折损前抛售碳配额, 以避免更大损失。**r值越小(负值越大), 碳价格越低**, 反映出市场抛售压力增加。
- r值为正表示碳价格预期会上涨, 企业没有抛售碳配额的动力。因此只有当碳价格为负(**存在激励或补贴**)时, 企业才会进行交易。

AI4S是未来的蓝海



香港中文大學(深圳)
The Chinese University of Hong Kong, Shenzhen

AI4S是结合人工智能、高性能计算及先进数学工具的通用计算框架或系统，旨在推动科学研究和工程领域中复杂问题的高效解决。

- AI4S融合了深度学习、强化学习、生成模型等现代智能技术，能够在科学建模、模拟、优化、因果推断、知识发现和预测等方面提供强大的跨领域支持。
- 随着新能源和电力电子设备的渗透率不断提高，电力系统的**物理机理**正在经历**由量变到质变**的深刻转型，电力系统建模与分析的基础理论需要重构。
- 当前主网计算规模已达10万节点以上（BPA机电暂态+RTDS电磁暂态节点），涉及数百万个参数，潮流方式超100种，按年度8760小时运行方式进行在线实时计算需考虑超10亿算例。
- 在大模型辅助下进行科学问题的**机理研究**是未来各领域的重要发展趋势。
- 大模型辅助新型电力系统的机理研究（例如**动态建模、稳定性分析的解析方法、电力市场的博弈均衡**等）

陶哲轩宣布“等式理论计划”成功，人类AI协作，57天完成2200万+数学关系证明



量子位 | 十天前

2024-11-25 17:41 42 点赞 1 评论 0 分享

分享

鱼羊一水 发自 四喜寺

量子位 | 公众号 QbitAI

57天，人类和AI合作搞定了4694个等式之间22028942个蕴含关系！

大神陶哲轩激动宣布：等式理论计划，成功。

陶哲轩神预言，Transformer破解百年三体难题，凭数学直觉找到李雅普诺夫函数

张磊云 - 2024-10-08 19:00

Meta用Transformer解决132年前全局李雅普诺夫问题。



李雅普诺夫函数

【导读】Transformer解决了三体问题？Meta研究者发现，132年前的数学难题——发现全局李雅普诺夫函数，可以被Transformer解决了。[我们不认为Transformer是在推理，它可能是出于对数学问题的深刻理解，产生了超级直觉。] AI可以搞基础数学研究了，陶哲轩预言再成真。

- **大模型及智能体技术正在很多领域颠覆基础研究与工业应用。**
- **大模型及智能体在电力系统中有广泛的应用场景。**
- **机器代人是较为容易落地实现的场景。**
- **利用多智能体框架可以实现多类别模型的有效融合。**
- **信息-物理-社会系统的仿真、运行、规划是我们要解决的核心问题，但仍有很多的难题有待攻克。**
- **AI4S是解决新型电力系统核心理论问题的希望。**

感谢聆听!

Email: zhaojunhua@cuhk.edu.cn

