

# 数据为中心的AI技术 在电力系统运行控制中的应用

郭庆来

清华大学

guoqinglai@tsinghua.edu.cn

致谢：周艳真博士、博士生兰健、曾泓泰、王奕



AI

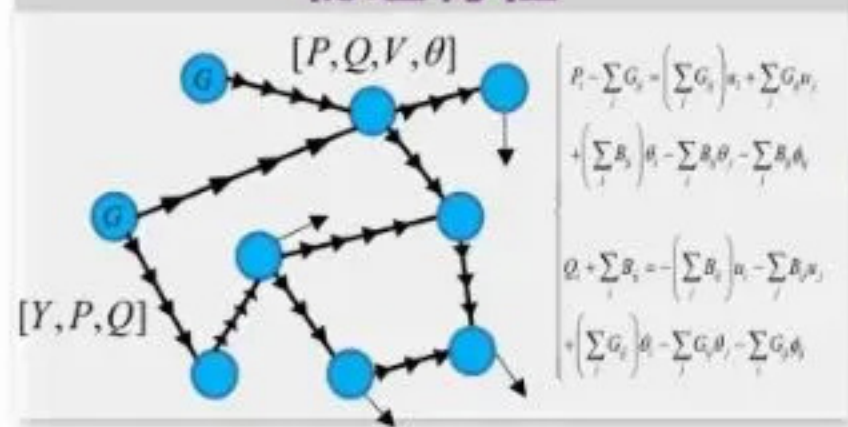
# 研究背景

## 电力系统调度决策是保障电网安全经济运行的核心环节

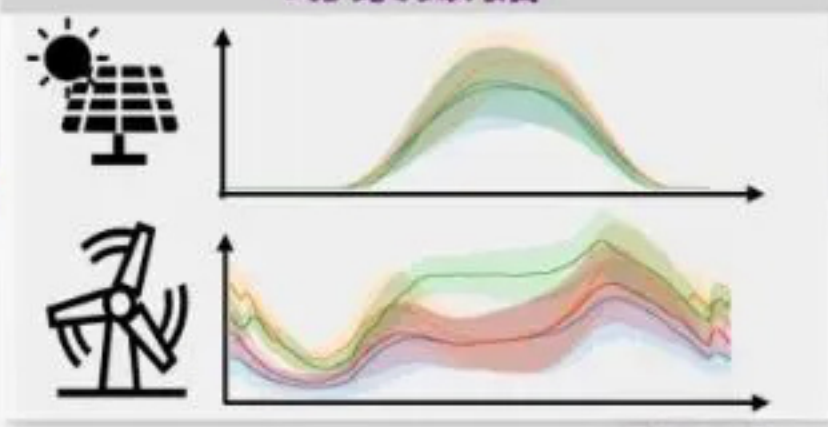
### 电网调度决策




#### 物理特性



#### 场景数据




#### 安全约束



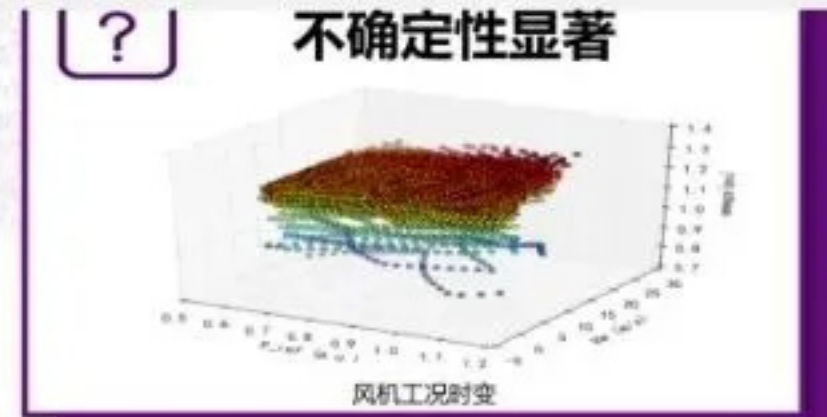
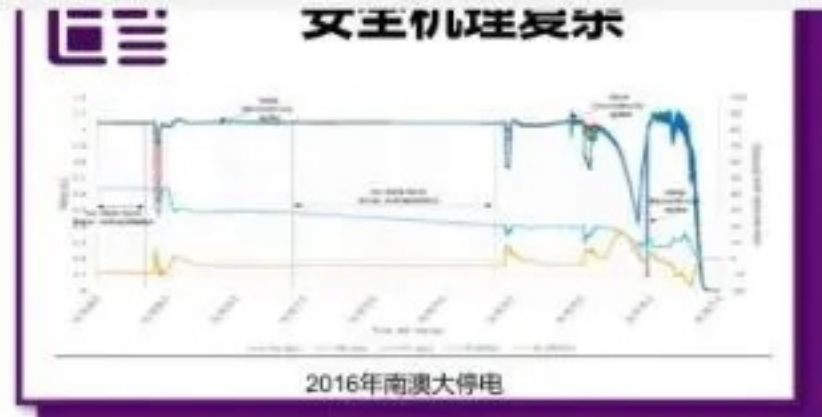
# 研究背景

随着新型电力系统建设，海量新能源广泛接入，系统结构和特性机理发生重大变化，为电力系统分析决策带来严峻挑战

风光发电装机容量 (单位: 亿千瓦)



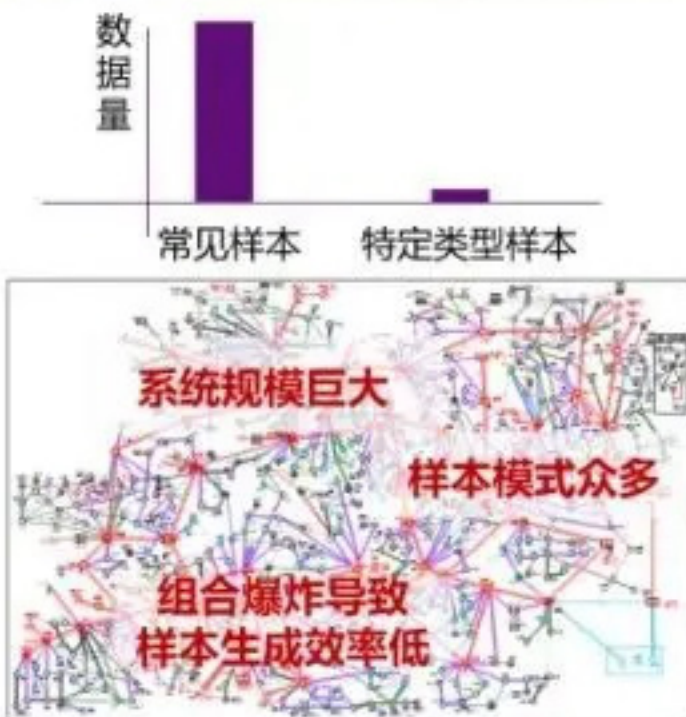
专家经验方法难以为继，亟需人工智能辅助



# 研究背景

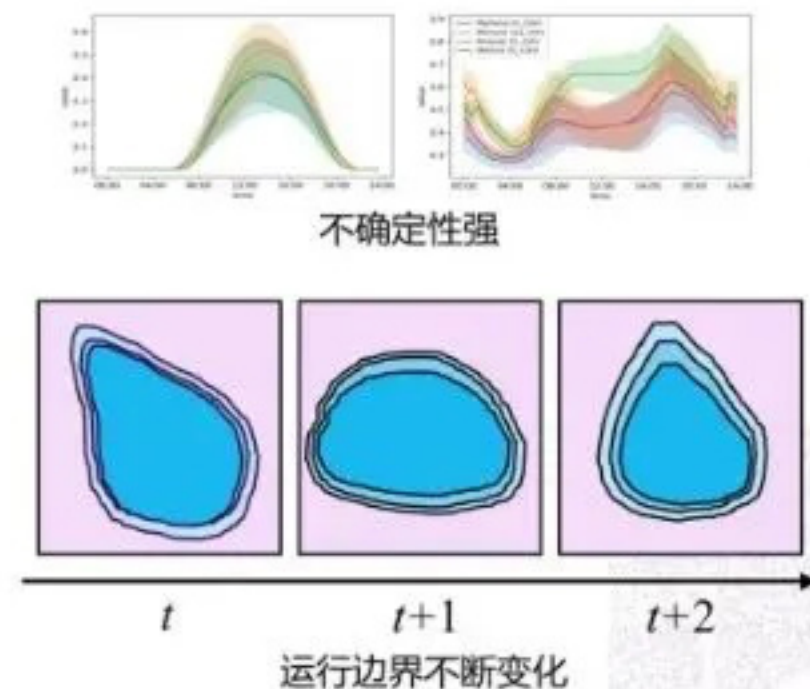
## 人工智能也有其局限性，在电力系统分析控制应用中仍面临诸多挑战

场景数量呈组合爆炸，  
特定样本生成难、效率低



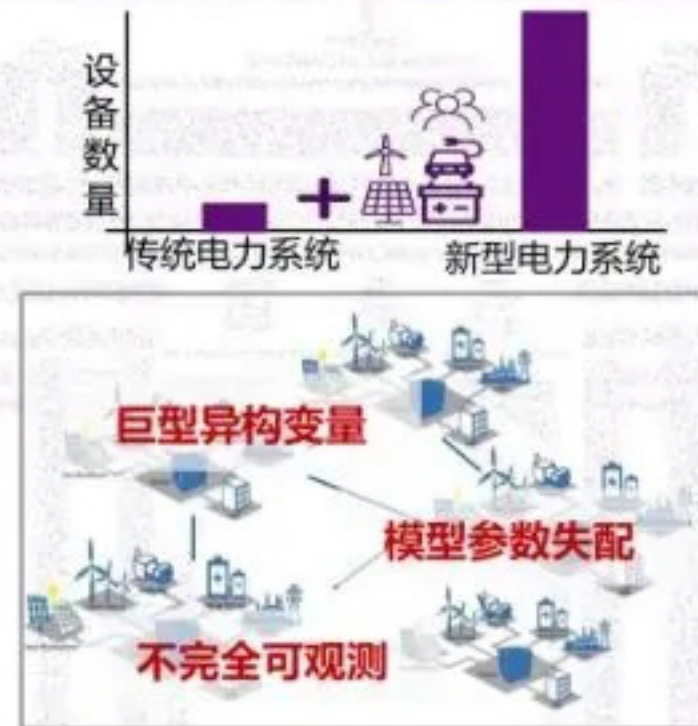
数据样本

运行不确定性强，机理复杂，  
传统人工智能适应性不足



安全分析

巨型非线性空间，模型缺失，  
隐私泄露风险，调控难度大



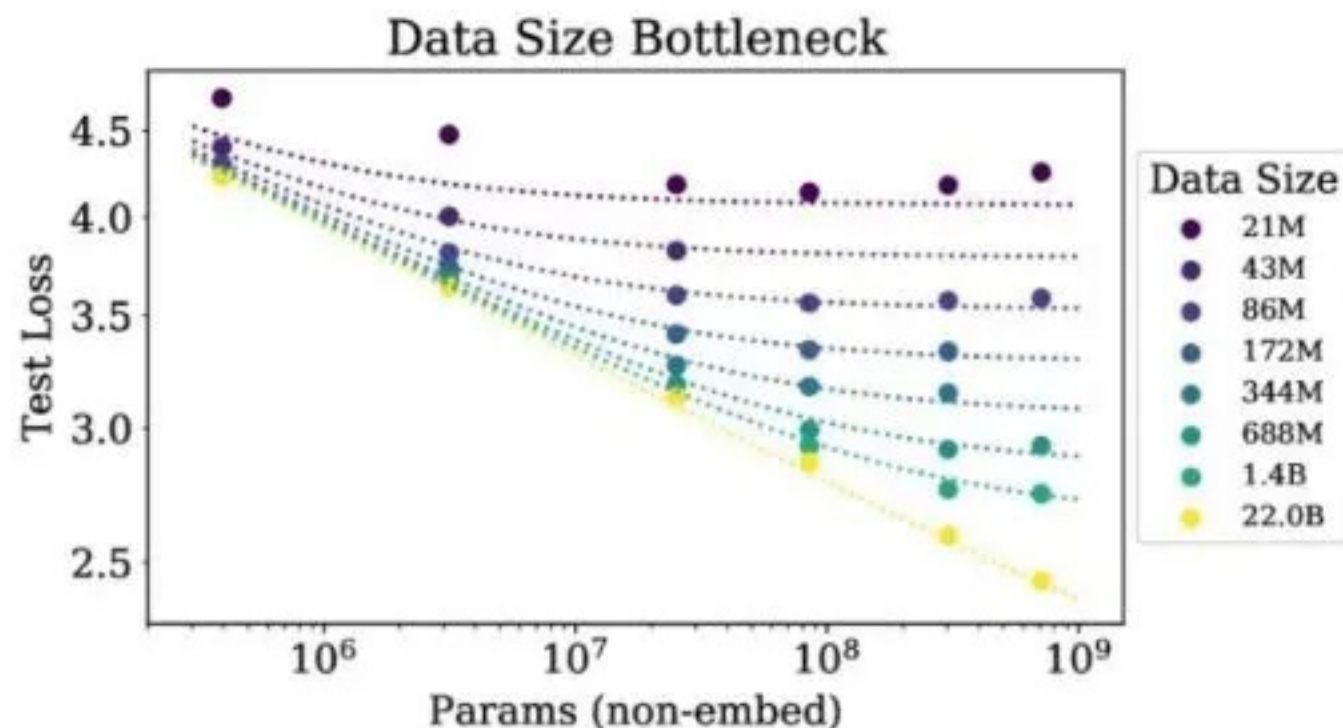
调度控制

# 研究背景



# 研究背景

**研究表明，在相同的AI模型参数条件下，使用更大规模、更高质量数据，训练得到的模型性能越高，关注数据本身是提升AI性能的关键**



- [1] Kaplan, Jared, et al. "Scaling laws for neural language models." arXiv preprint arXiv:2001.08361 (2020).  
[2] Andrew, Ng. "MLOps: From Model-centric to Data-centric AI", DeepLearningAI.

# 研究背景



人工智能领域先驱 Andrew Ng

“更好的AI  
= **80%**的数据  
+ **20%**的算法”



更好的**数据**



训练



更好的**AI**

GPT-1

**4.8G**原始数据

GPT-2

**40G**人工筛选数据

GPT-3

**570G**人工筛选数据

ChatGPT

带有**人类偏好**的数据

**Data-centric AI**

以数据为中心的人工智能

## 电力研究者如何拥抱AI?



AI做什么?




电力专家做什么?

或许Data-Centric AI是一个启发

# Data-centric AI在电力系统应用的核心难点


## 01 分类问题的类别不平衡



**典型问题：**暂态稳定评估

**难点：**少类样本不足以支撑模型训练，生成样本不足以刻画边界


## 02 回归问题的分布不均衡



**典型问题：**断面安全裕度预测

**难点：**所需的样本数量不足，针对每个场景单独训练模型难度较高

## 03 优化问题的数据质量提升




$$\min f(x)$$
$$st. g(x) \leq 0$$



**典型问题：**大规模优化调度的模仿学习

**难点：**大规模优化调度涉及变量约束规模巨大，数值条件差，求解速度和精度要求高

## 04 多方数据的隐私保护需求



**典型问题：**多主体交互下的多方协同计算

**难点：**如何在不泄露原始数据的前提下对数据进行分析计算，保证数据“可用不可见”



**Data-centric AI**

## **进展1 – 基于生成式AI的暂态稳定评估数据增强技术**

**面向电力系统AI分类问题**

# 问题提出

- 暂态稳定分析的样本集存在失稳样本数量占比少的数据不均衡问题
- 人工智能方法在不均衡样本集上效果较差，迫切需要进行数据增强

实际电网运行失稳情况极少



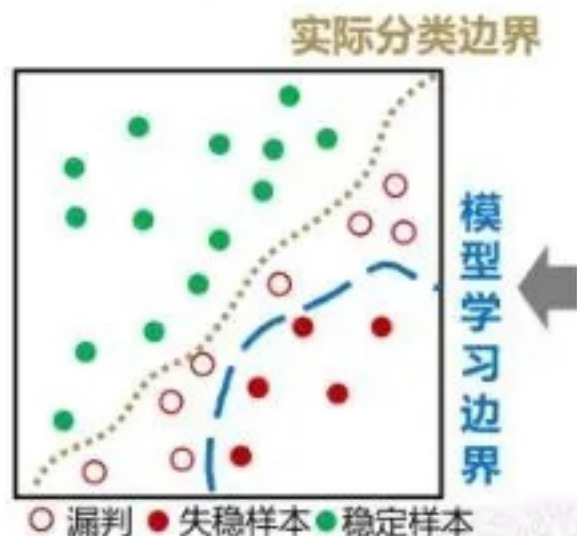
人工智能方法对训练数据敏感性

不均衡样本集



实际运行  
不稳定样本极少

仿真不稳定样本  
难获取



数据量问题[1]:

$$R_{EXP}(f) \leq \underbrace{R_{EMP}(f)}_{\text{训练误差}} + \sqrt{\frac{1}{2N} \left( \log d + \log \frac{1}{\delta} \right)}$$

样本量      模型复杂度

数据平衡性问题:

$$P(c_0|x) = \frac{P(x|c_0)P(c_0)}{P(x)} < \frac{P(x|c_1)P(c_1)}{P(x)} = P(c_1|x)$$

**迫切需要对数据进行增强，提升暂态稳定评估的性能**

# 技术路线1.1: 基于Wasserstein距离的生成对抗网络

- 生成式人工智能方法通过训练大量数据来学习数据的内在规律和特征
- 生成对抗网络是现有研究中最常用的基本生成模型

## 🤖 典型生成式AI模型


高斯混合模型 (GMM)  
流模型 (Flow-based Models)  
变分自编码器 (VAE)  
扩散模型 (Diffusion Models)  
自回归模型 (AutoRegressive Models)  
生成对抗网络 (GAN)



## ⚠️ 传统GAN存在梯度消失和模式崩溃




当 $P_g(x)$ 和 $P_{data}(x)$ 完全不重合时  
JS散度恒等于常数 $\log 2$   
目标函数对参数的梯度为0



当生成器学到了 $P_{data}(x)$ 某一种特征  
如生成重复样本或有限多样性的样本时  
判别器难以提供梯度更新参数

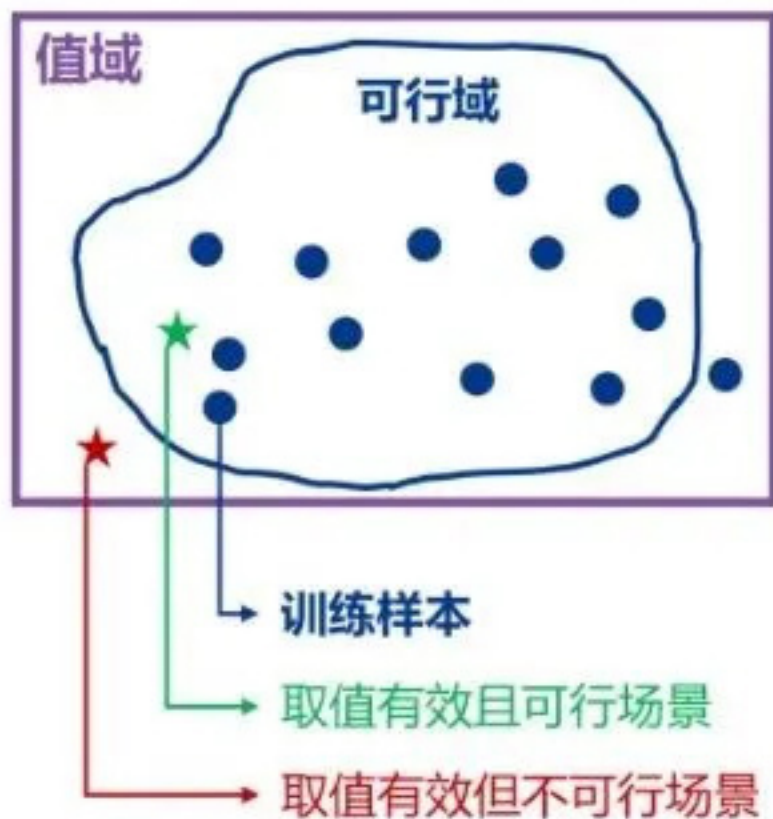
## ✅ 采用基于Wasserstein距离的改进模型

- 将原模型的JS散度替换为Wasserstein距离
- 采用满足1-lipschitz约束的神经网络作为判别器



# 技术路线1.2: 考虑电力系统约束的改进生成对抗网络训练方法

- 传统生成对抗网络未考虑物理约束, 新生成的运行场景可能存在不可行的情况
- 在损失函数中加入考虑物理约束的惩罚项, 保证生成样本满足基本约束



生成模型本身的不确定性+训练误差

新生成的运行场景可能存在不可行的情况

解决思路: 在损失函数中加入考虑物理约束的惩罚项

- 等式约束  $J(x) = 0$   
潮流平衡约束:  $\sum P_G - \sum P_L - P_{loss} = 0$
- 不等式约束  $H(x) \leq 0$   
上下界约束:  $x_i^{\min} \leq x_i \leq x_i^{\max}$   
考虑直流潮流的线路功率上下界约束:

$$\theta = B_0^{-1} P^{SP}$$
$$P_{ij} = (\theta_i - \theta_j) / x_{ij} \Rightarrow P_{ij}^{\min} \leq P_{ij} \leq P_{ij}^{\max}$$

- 损失函数惩罚统一形式

$$\xi(x) = \alpha_J |J(x)|^2 + \alpha_H \text{ReLU}(H(x))$$

改进的目标函数:

$$\min_G \max_D V = \mathbb{E}_{x \sim P_{\text{data}}(x)} D(x) - \mathbb{E}_{z \sim P_z(z)} D(G(z)) - \lambda_{\text{GP}} \text{GP} + \lambda_c \xi(G(z))$$

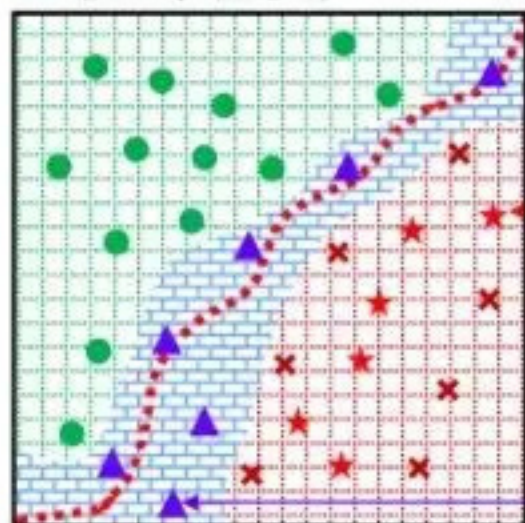
基于Wasserstein距离的改进方法

保证生成样本满足基本约束

# 技术路线1.3：面向少数类别和分类边界样本的暂稳评估数据增强

## □ 针对暂稳分类的数据需求，提出面向少数类别和分类边界样本的数据增强方法

- ⋯ 真实稳定边界
- 模型学习稳定域
- ⊥ 模型学习失稳域
- ⊥ 模型不确定域



- 初始数据集的稳定样本
- × 初始数据集的失稳样本
- ★ 拟生成的少数类样本
- ▲ 拟生成的分类边界样本

### ★ 面向少数类别样本的暂态稳定评估数据增强方法

核心难点：如何充分利用多数稳定样本得到性能较高的失稳生成模型？


解决方案：利用判别器最大化  $W(P_{us}, P_G)$  和  $W(P_{us}, P_S)$ ，重构模型训练过程

$$\min_G \max_D V = \underbrace{(1 + \rho) \mathbb{E}_{x \sim P_u(x)} D(x)}_{\text{maximize}} - \mathbb{E}_{z \sim P_G(z)} D(G(z)) - \underbrace{\rho \mathbb{E}_{x \sim P_u(x)} D(x)}_{\text{maximize}} - \lambda_{GP} GP + \lambda_c \xi(G(z))$$

### ▲ 面向分类边界样本的暂态稳定评估数据增强方法

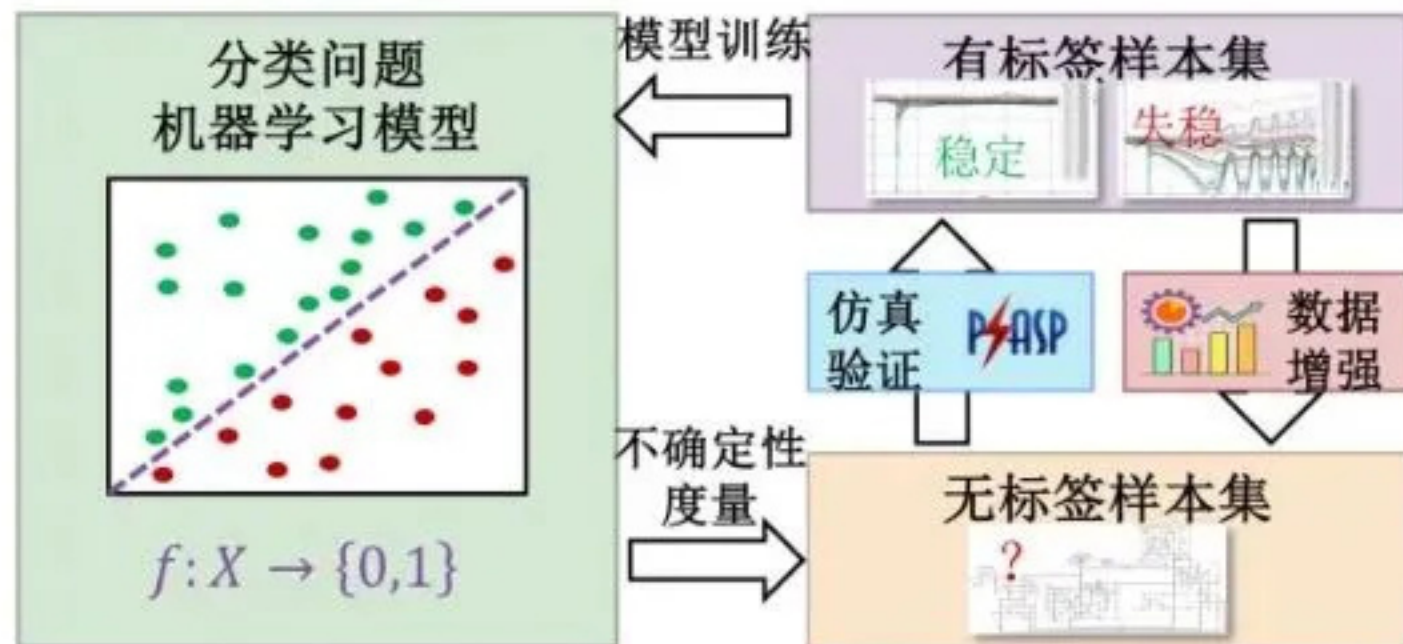
核心难点：如何不断发现并生成已有数据未覆盖的样本，提升模型性能？

解决方案：通过生成模型与判稳模型的对抗学习，消除判稳模型的不确定域



# 技术路线1.4：基于信息熵的样本高效标注方法

□ 样本标注费时费力，提出基于信息熵的样本高效标注方法，降低样本生成代价

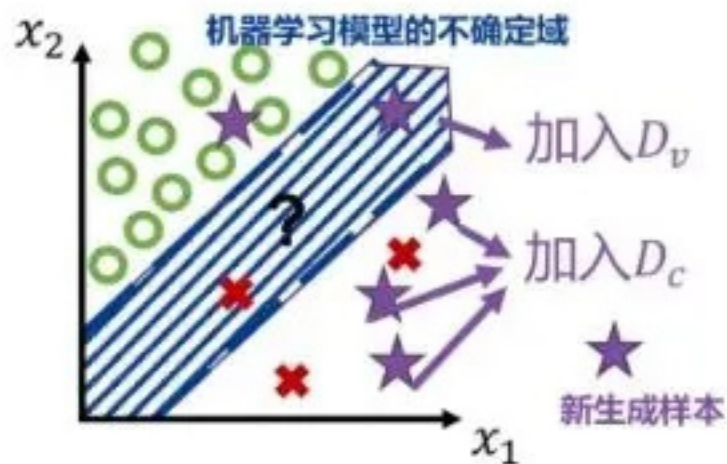


- **最大信息熵准则**：根据模型输出结果 $f(x)$ 计算 $H(x)$ 对 $D_w$ 中数据进行排序，优先选择 $H(x)$ 较大的样本加入 $D_v$ 中，进行时域仿真得到样本标签

$$H(x) = -p_1 \log p_1 - p_2 \log p_2$$

- **样本偏差准则**：将满足 $f(x) \neq y_G$ 条件的样本，即生成模型认为其暂态失稳而预测模型认为其是稳定的样本，将其加入 $D_v$ 中，进行时域仿真得到样本标签

- **确定性准则**：选择 $H(x) = 0$ 且 $f(x) = 1$ 的样本加入 $D_c$

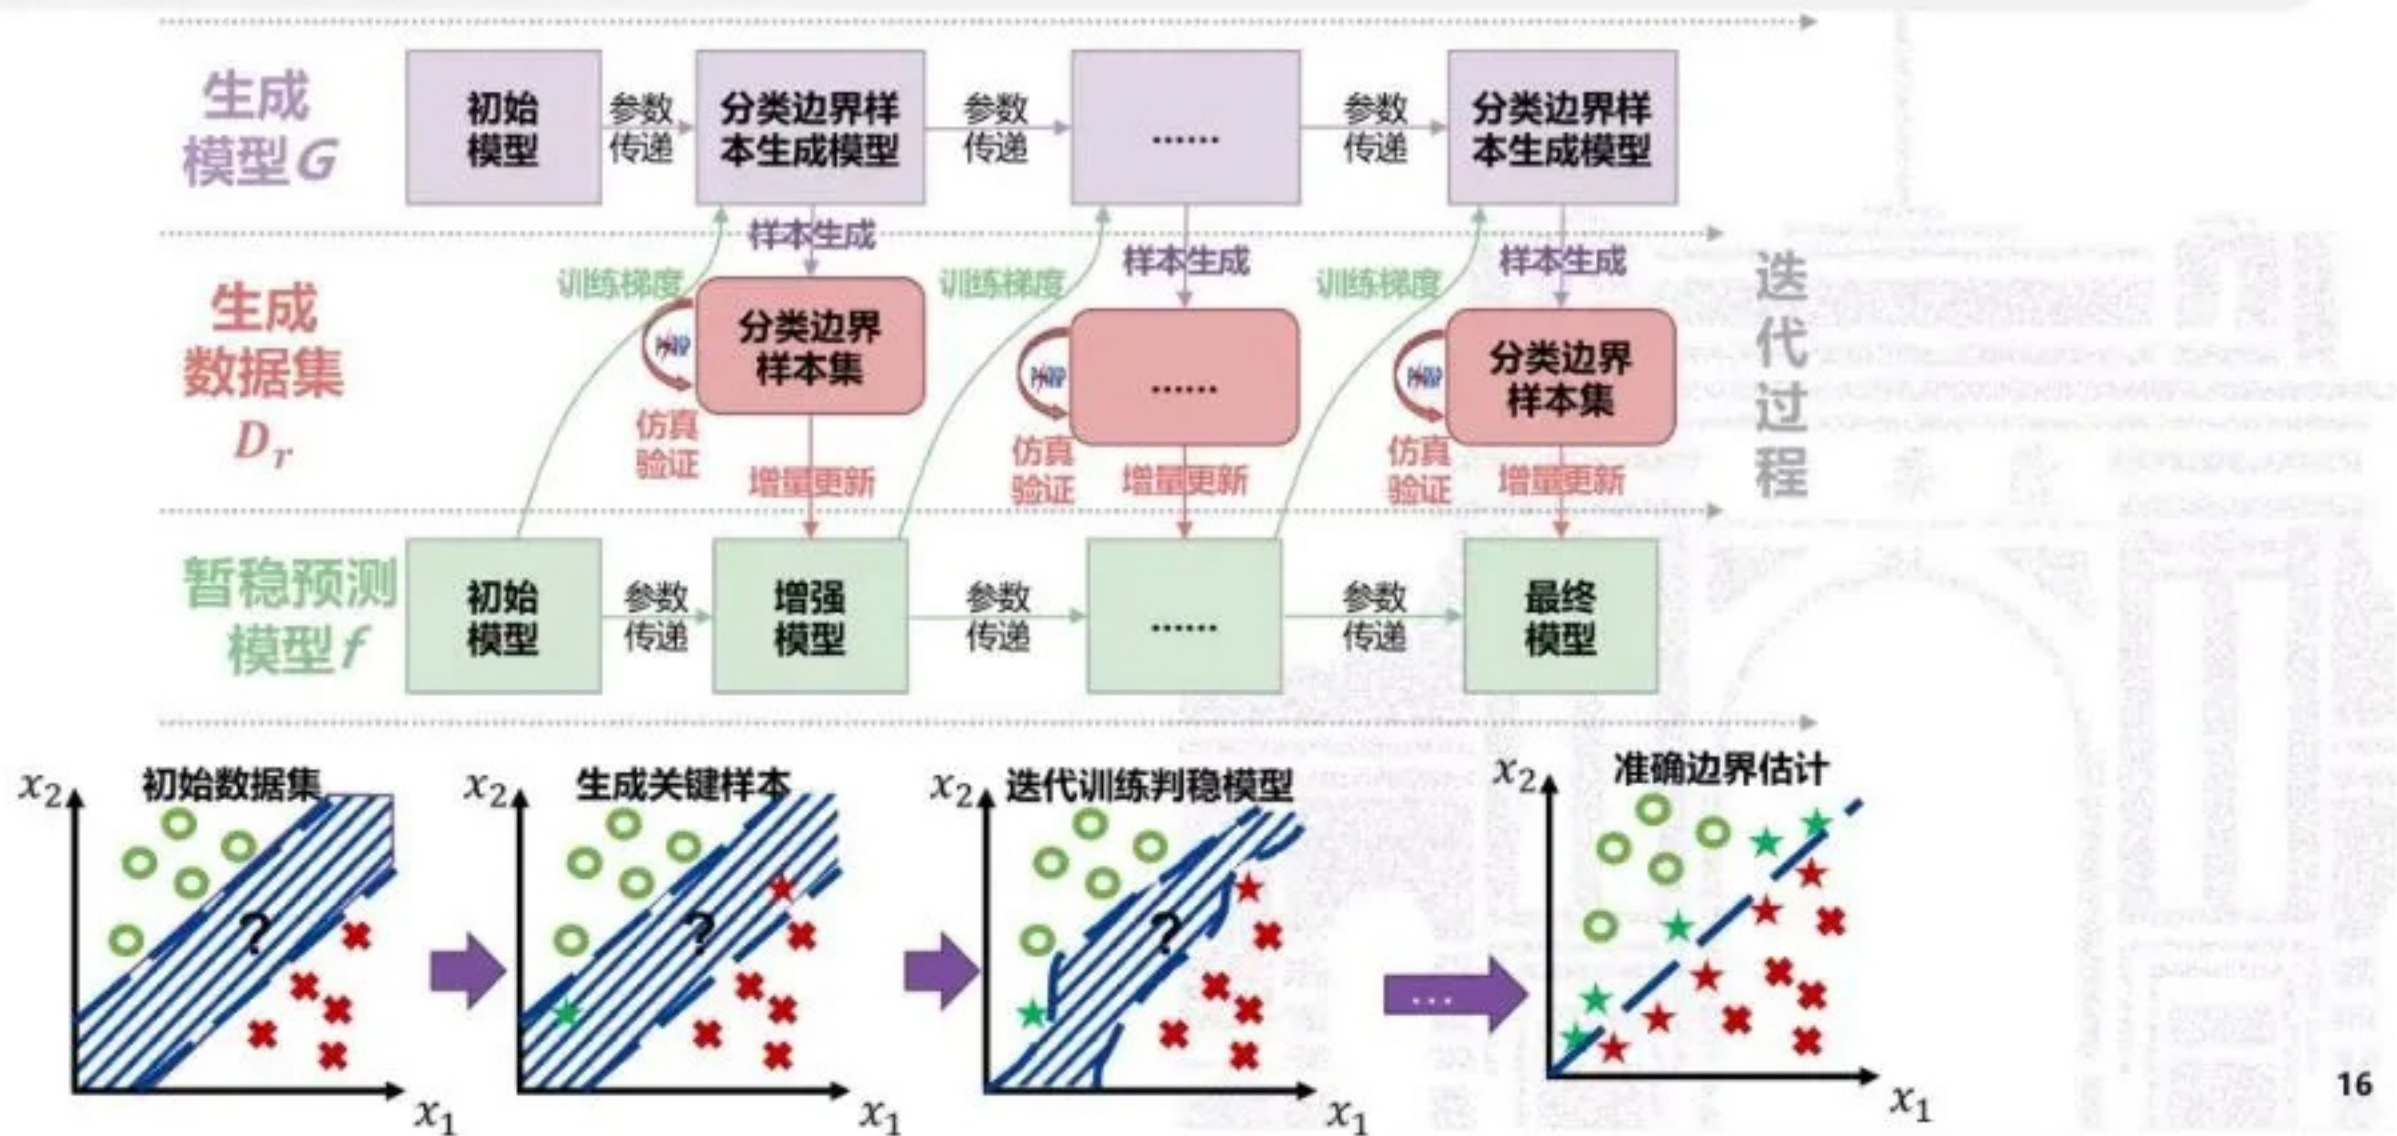


对 $D_v$ 进行仿真标注  
对 $D_c$ 进行自动标注

增强后数据集  
 $D_{aug} = D \cup D_v \cup D_c$


# 技术路线1.5: 提升暂稳评估性能的对抗训练方法

通过生成模型与判稳模型的对抗学习，消除判稳模型的不确定域，在迭代训练中使暂稳评估模型趋于最优模型



# 算例验证

□ 基于中国电科院根据实际电网数据建立的300节点系统生成样本，基于不同的生成模型，各生成1000条样本，对于样本生成结果进行仿真校验其暂态稳定性



暂态稳定仿真结果 (蒙特卡洛仿真)

线路命名	系统编号	首端节点	末端节点	失稳样本占比
线路A	111	Bus 1B-12	Bus 1B-11	26.18%
线路B	275	Bus 2W-2	Bus 2W-3	22.09%
线路C	77	Bus 3L-52	Bus 3L-51	26.34%

➤ 不同生成模型有效性的对比

生成样本有效率 (失稳样本/所有样本)


	GAN	GMM	VAE	DDPM	wGAN-GP	所提方法
线路A	82.1%	87.2%	81.3%	92.3%	87.1%	91.2%
线路B	64.4%	85.4%	72.8%	88.1%	81.7%	89.4%
线路C	84.6%	86.4%	83.8%	87.9%	86.8%	92.5%

所提方法利用数量更多的稳定样本作为模型训练时的梯度罚项，相对于其他生成模型表现出更高的暂态稳定场景生成精度


# 算例验证

- 将所提样本标注方法应用于300节点系统，可以显著降低仿真标记时间
- 该方法也可用于变化场景下模型更新的样本生成，显著降低模型更新时间

样本选择后的样本分布



不同仿真策略暂稳校验耗时



在300节点数据集上，利用基于信息熵的样本选择方法后，可以显著降低仿真标记时间

## 暂态稳定评估：NPCC48机系统，重负荷、线路退出运行

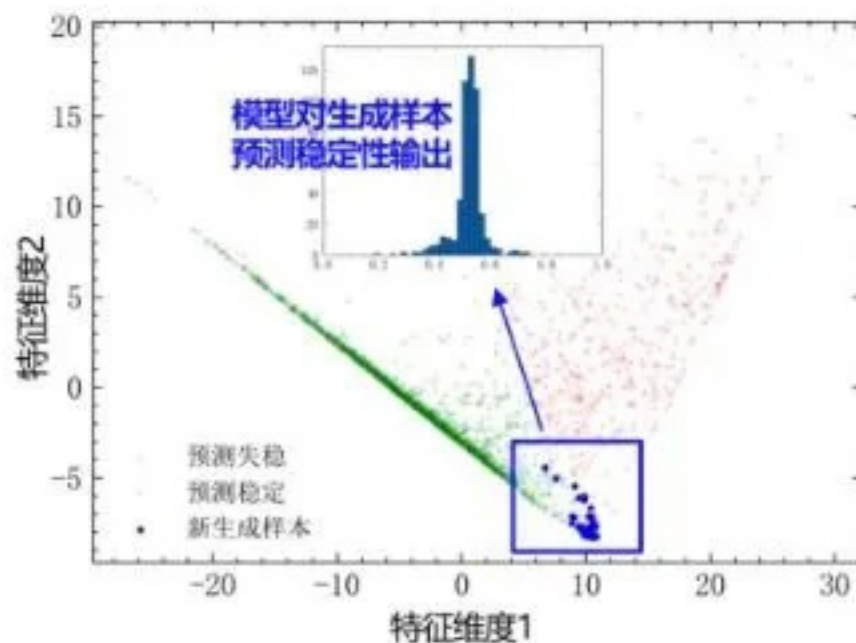
准确率	数据量	训练时间
<p>97.16%    98.02%</p> <p>随机生成重新训练    主动迁移学习</p>	<p>74520    2070</p> <p>随机生成重新训练    主动迁移学习</p>	<p>2043.33s    62.19s</p> <p>随机生成重新训练    主动迁移学习</p>

基于最大信息熵准则的样本标注策略可用于场景变化时AI模型在线更新过程快速生成少量标注样本，结合主动迁移学习，能够在保证准确率的同时，显著降低计算时间，使在线快速更新模型成为可能

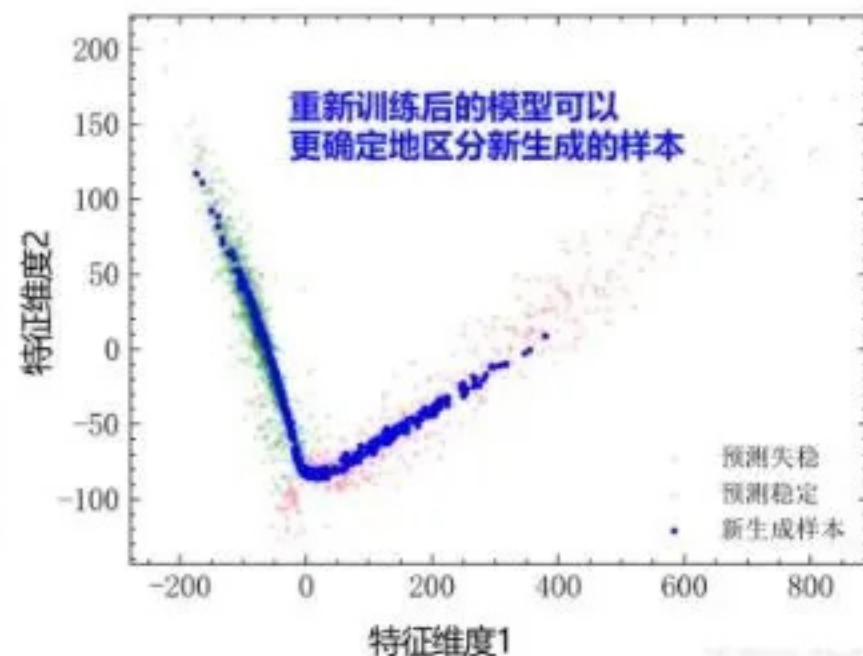
# 算例验证

在原有暂态稳定评估模型基础上，进一步采用所提方法生成分类边界样本，并通过对抗训练迭代提升判别模型准确度

初始模型特征提取层降维结果



对抗训练后模型的特征提取层降维结果



稳定评估模型对抗训练迭代过程的测试指标



注：第5轮训练生成模型未在 $T_{max}$ 轮次内达到更新阈值

随着每一轮次新生成的样本补充至训练集中，暂稳评估模型对于系统运行场景的辨识能力逐步提升，有效增强了原始模型不确定区域的辨识能力。




**Data-centric AI**

## **进展2 – 考虑输电断面安全裕度的特定场景样本生成**

**面向电力系统AI回归问题**

# 问题提出

- 输电断面是运行方式分析需要考虑的重要因素，有利于实现电网降维监控
- 电网运行方式面临组合爆炸，运方人员难以根据实际需求生成所需的典型运行方式，面临样本生成难度大、生成效率低、所需类型样本不足的问题



$$TTC = \max \sum_{i \in \Omega} P_{ii}(u, \bar{y}_0)$$

s.t.  $u_{min} \leq u \leq u_{max}$  (控制变量上下限约束)

$f^0(\bar{y}_0, u) = 0$  (故障前潮流有解)


$\bar{y}_{0min} \leq \bar{y}_0 \leq \bar{y}_{0max}$  (故障前潮流满足各类约束)

$f^1(\bar{y}_1, u) = 0$  (故障后潮流有解)

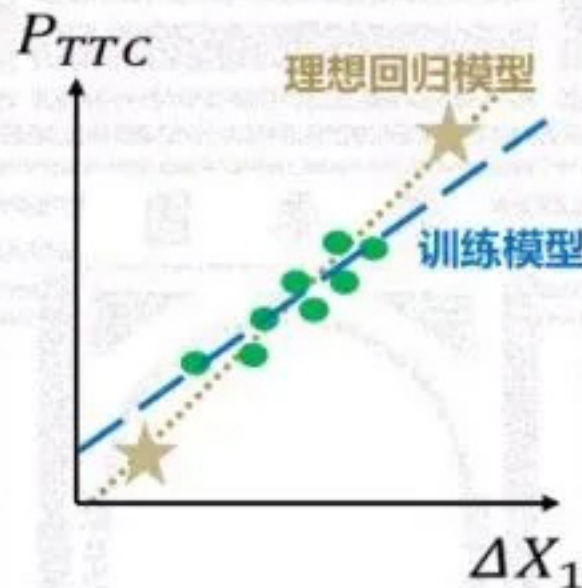
$\bar{y}_{1min} \leq \bar{y}_1 \leq \bar{y}_{1max}$  (故障后潮流满足各类约束)

$\dot{x}(t) = F_i(x(t), y(t))$  (暂态过程满足微分代数方程组约束)

$H(x(t), y(t)) \leq 0$  (暂态稳定判据)



不均匀数据集影响回归性能



针对性仿真难度大

拓扑结构 电网参数 依从变量

$$f(A, p, D, u, x) = 0$$

不可控变量

如：负荷水平

可控变量

如：发电机出力

变量  $D, u$  复杂非线性映射 → 断面安全裕度

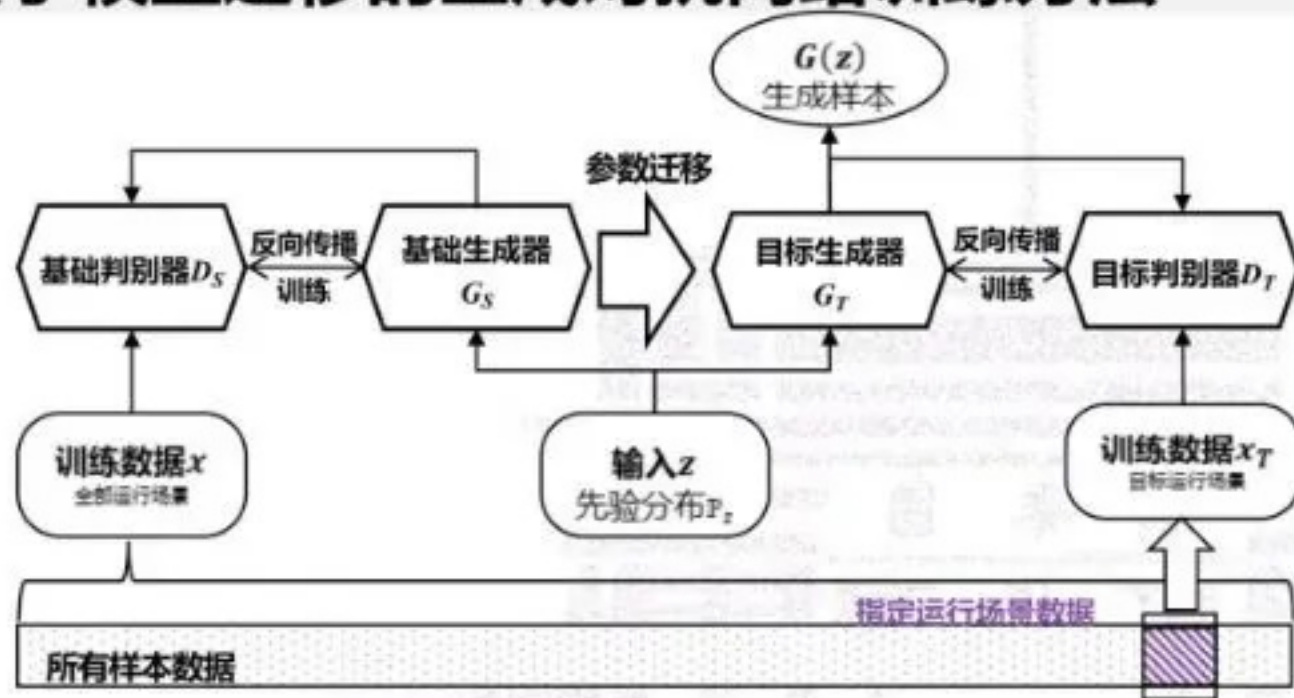
**迫切需要考虑不同断面裕度需求，精准生成指定运行场景**

## 技术路线2.1：基于模型迁移的生成对抗网络训练方法

- 特定输电断面裕度的场景样本数量严重不足，导致生成模型训练难度大
- 为充分利用潜在有用信息，提出基于模型迁移的生成对抗网络训练方法

算法 3.1：考虑模型迁移的生成模型训练算法

- 1: for  $t = 0, \dots, N_p$ , do:
- 2: 自目标样本集  $D_T$  中抽取  $m$  个样本  $\{x_T\}_{i=1}^m \in D_T$
- 3: 自非目标样本集  $D_{nT}$  中抽取  $m$  个样本  $\{x_{nT}\}_{i=1}^m \in D_{nT}$   
生成随机插值样本
- 4:  $\hat{x}^{(i)} = \alpha^{(i)} x_T^{(i)} + (1 - \alpha^{(i)}) x_{nG}^{(i)}, \alpha \sim \text{Uniform}(0,1)$   
计算判别器损失函数:
- 5:  $L_{D_T} \leftarrow \frac{1}{m} \sum_{i=1}^m \left[ D(x_{nT}^{(i)}) - D(x_T^{(i)}) + \lambda (\|\nabla_x D(\hat{x}^{(i)})\|_2 - 1)^2 \right]$   
更新判别器参数:
- 6:  $\theta_{D_T} \leftarrow \text{Adam}(\nabla_{\theta_{D_T}} L_{D_T}, \theta_{D_T}, \alpha_{adam}, \beta_1, \beta_2)$
- 7: end for
- 8: 基于源域模型参数  $\theta_{G_s}$  初始化目标域生成模型  $G_T$
- 9: while 模型参数  $\theta$  未收敛或未达到最大训练批次, do:
- 10: # 参考技术路线1.2训练生成模型
- 11: 结束训练



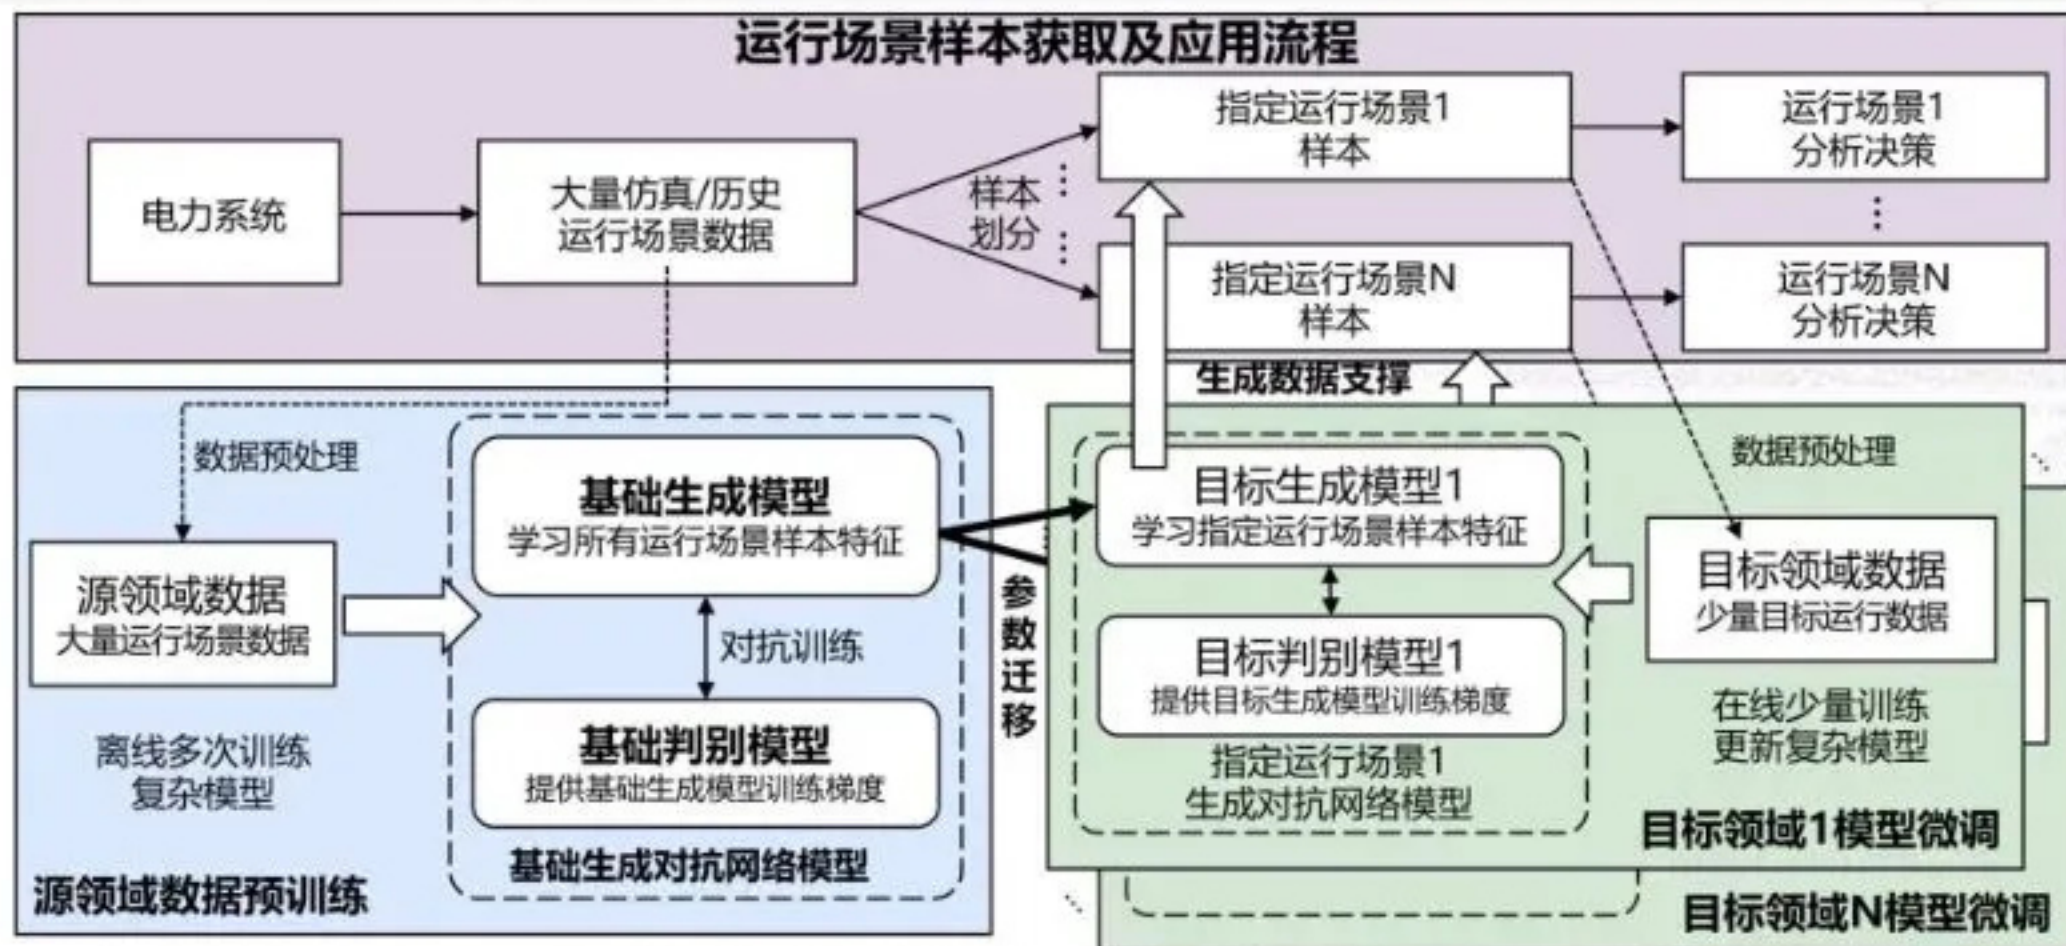
$$\theta^* = \arg \min_{\theta} L(\theta; D_{\text{target}})$$

- 源域模型学习所有运行场景样本的共性特征
- 目标域模型学习目标运行场景的关键特征

利用少量特定运行场景样本实现参数微调，**计算速度快、样本利用率高、准确性好**

## 技术路线2.2：面向特定运行场景的样本生成基本方法

- 基于模型迁移训练方法，进一步提出面向特定运行场景的样本生成基本方法，可以针对性地生成不同断面裕度的运行场景



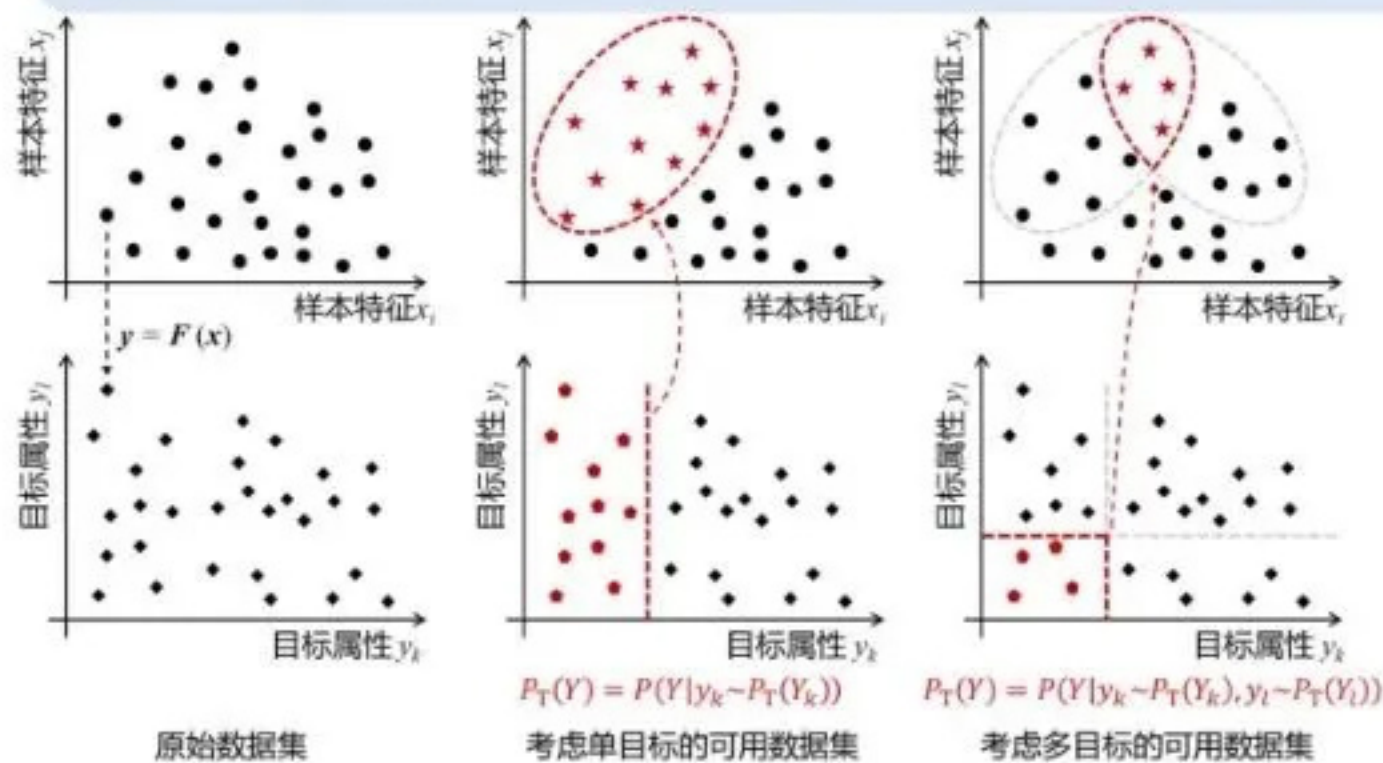
**离线训练阶段：**通过所有运行场景数据集训练生成对抗网络，得到基础生成模型 $G_S$

**在线应用阶段：**利用有限目标样本参数微调得到目标生成模型 $G_T$ ，实现样本高效生成

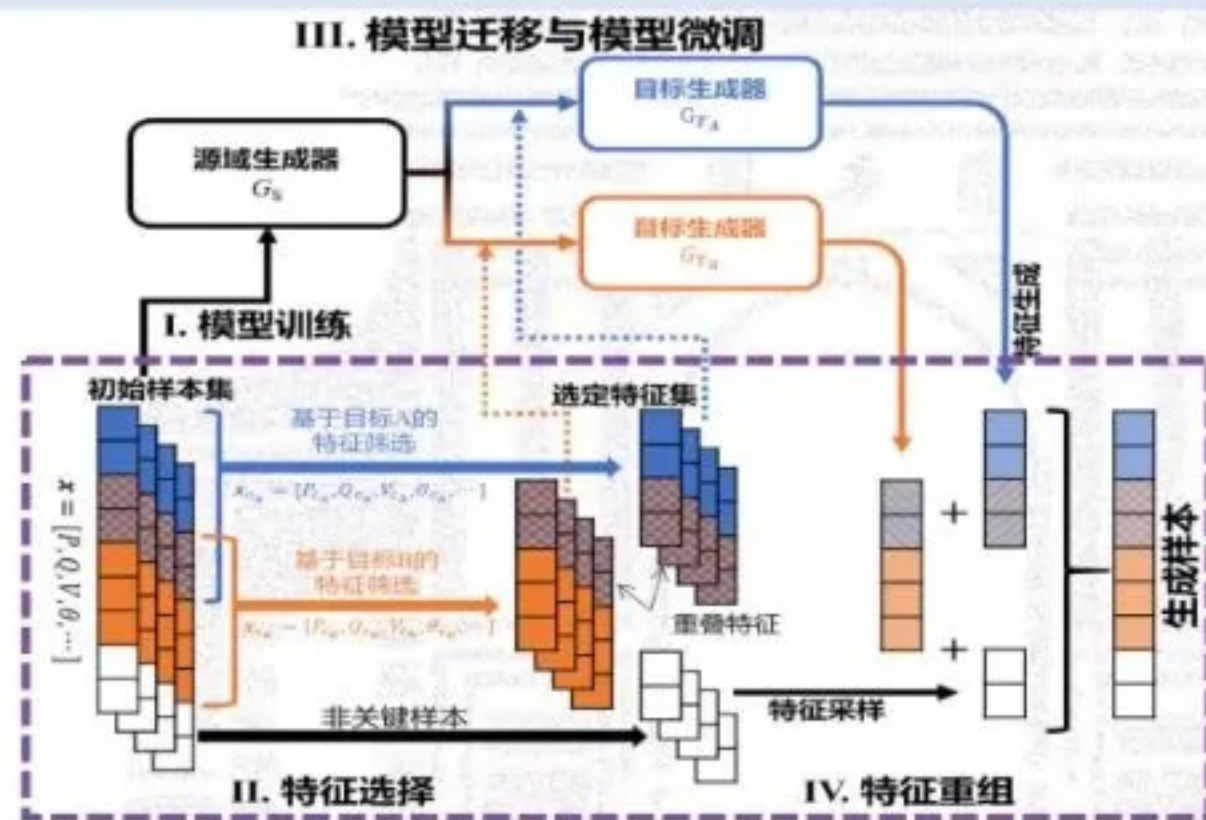
# 技术路线2.3：基于特征选择和特征重组的多目标场景生成方法

针对存在复杂耦合关系的输电断面，提出基于特征选择和特征重组的多目标场景生成方法，选择与目标样本最相关的特征，结合改进生成对抗网络迁移训练形成单一属性生成模型，利用特征组合获得完整方式样本

将原有一个生成模型直接生成复杂样本转化为多个子目标的生成模型的组合方法，提高数据利用效率和生成样本有效率




$x$ : 样本数据(例如: 发电机有功Pg)  $y$ : 目标属性(例如: 选定断面裕度)




# 算例验证

□ 在新英格兰10机39节点系统上进行算例分析，选定4个输电断面的不同安全裕度进行研究，通过不同方法的对比验证了所提方法的有效性





采用10%和50%作为断面安全裕度划分准则



不同方法生成样本有效率对比

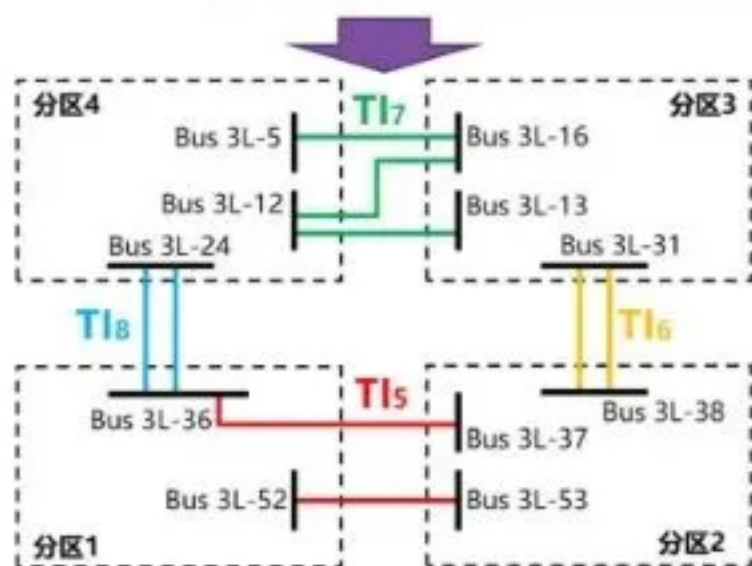

场景	方法	断面1	断面2	断面3	断面4
紧急 低裕度	GMM	63.6%	59.1%	50.1%	55.7%
	VAE	53.2%	48.1%	49.8%	72.4%
	GAN	59.6%	44.5%	53.2%	55.0%
所提方法		<b>93.9%</b>	<b>77.3%</b>	<b>84.6%</b>	<b>96.7%</b>
正常 高裕度	GMM	71.5%	56.2%	72.3%	48.9%
	VAE	65.3%	68.8%	73.3%	42.3%
	GAN	63.8%	73.8%	74.5%	51.3%
所提方法		<b>86.0%</b>	<b>83.1%</b>	<b>81.5%</b>	<b>69.7%</b>

模型迁移前后对比 (断面1)

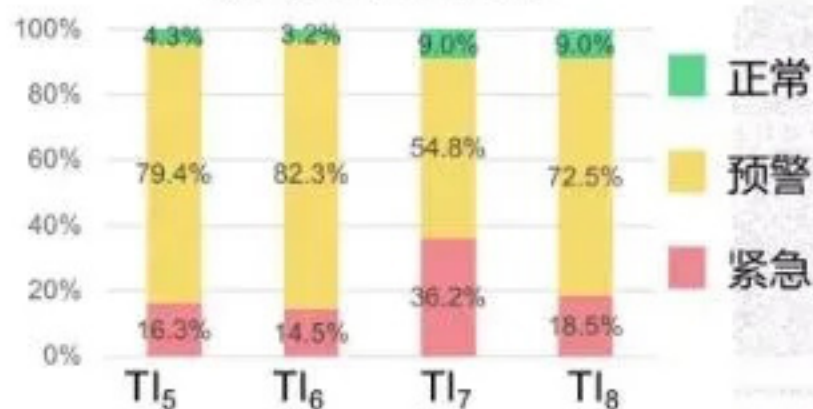


# 算例验证

在电科院模拟实际电网的300节点算例上进行算例分析，选定4个输电断面的不同安全裕度进行研究，通过不同方法的对比验证了所提方法的有效性



断面安全裕度分布



不同方法生成样本有效率对比

场景	方法	断面1	断面2	断面3	断面4
紧急 低裕度	GMM	37.9%	40.8%	53.2%	49.2%
	VAE	48.4%	52.1%	64.8%	50.7%
	GAN	43.7%	49.8%	55.4%	50.4%
正常 高裕度	所提方法	<b>86.4%</b>	<b>85.9%</b>	<b>92.7%</b>	<b>84.1%</b>
	GMM	20.4%	26.1%	31.8%	42.8%
	VAE	41.2%	39.8%	35.2%	44.0%
正常 高裕度	GAN	40.6%	25.6%	38.7%	20.4%
	所提方法	<b>71.9%</b>	<b>68.4%</b>	<b>76.8%</b>	<b>72.3%</b>

# 算例验证

□ 在新英格兰10机39节点系统和电科院300节点系统上分别验证了不同方法考虑多个目标下的场景生成有效率，算例表明，所提方法生成样本有效率显著提高

## ◆ 10机39节点系统


场景	原始数据集	GMM	VAE	GAN	所提方法
$Y_{1,E} \cap Y_{2,E}$	1.29%	43.6%	35.4%	24.1%	<b>97.6%</b>
$Y_{1,E} \cap Y_{3,E}$	0.89%	14.8%	19.8%	14.4%	<b>92.9%</b>
$Y_{1,E} \cap Y_{4,E}$	2.63%	52.6%	52.1%	48.4%	<b>94.4%</b>
$Y_{2,E} \cap Y_{3,E}$	0.27%	21.8%	10.7%	13.7%	<b>90.2%</b>
$Y_{3,E} \cap Y_{4,E}$	0.18%	17.8%	4.5%	6.6%	<b>87.5%</b>
$Y_{1,E} \cap Y_{2,N}$	1.99%	48.6%	43.3%	28.4%	<b>98.1%</b>
$Y_{3,E} \cap Y_{4,N}$	0%	\	\	\	<b>92.7%</b>
$Y_{1,E} \cap Y_{2,E} \cap Y_{3,E}$	0%	\	\	\	<b>69.9%</b>
$Y_{1,E} \cap Y_{2,N} \cap Y_{3,E}$	0%	\	\	\	<b>72.4%</b>
$Y_{1,N} \cap Y_{3,E} \cap Y_{4,E}$	0%	\	\	\	<b>63.4%</b>
$Y_{1,E} \cap Y_{2,E} \cap Y_{4,E}$	0%	\	\	\	<b>59.8%</b>

## ◆ 电科院300节点系统

场景	原始数据集	GMM	VAE	GAN	所提方法
$Y_{5,E} \cap Y_{6,E}$	1.41%	40.4%	24.4%	28.9%	<b>77.6%</b>
$Y_{5,E} \cap Y_{7,E}$	7.44%	88.6%	49.1%	52.2%	<b>96.4%</b>
$Y_{5,E} \cap Y_{8,E}$	1.53%	69.4%	66.8%	63.5%	<b>75.2%</b>
$Y_{6,E} \cap Y_{7,E}$	2.15%	70.5%	72.4%	67.7%	<b>81.5%</b>
$Y_{7,E} \cap Y_{8,E}$	2.37%	82.1%	73.5%	57.6%	<b>83.3%</b>
$Y_{5,E} \cap Y_{6,N}$	0.92%	12.8%	19.7%	12.4%	<b>72.1%</b>
$Y_{7,E} \cap Y_{8,N}$	0.0%	\	\	\	<b>55.6%</b>
$Y_{5,E} \cap Y_{6,E} \cap Y_{7,E}$	0.60%	25.8%	29.1%	18.2%	<b>65.4%</b>
$Y_{5,E} \cap Y_{6,E} \cap Y_{7,E} \cap Y_{8,E}$	0.0%	\	\	\	<b>64.8%</b>

# 算例验证

- 利用数据生成方法得到断面裕度评估训练用数据集，进行AI回归模型训练
- 在相同AI模型结构的基础上，使用增强后的数据集能够显著提升AI模型在断面紧急情况场景下的准确率，能够更多地避免漏警情况的发生



断面名称	基于初始数据集 $D$		基于增强数据集 $D_A$	
	全测试集	断面紧急状态	全测试集	断面紧急状态
T11	0.9972	0.3512	0.9977	0.9305
T12	0.9951	0.1230	0.9921	0.8678
T13	0.9892	0.2194	0.9903	0.9147
T14	0.9834	0.4857	0.9917	0.8935
T15	0.9765	0.7851	0.9789	0.9433
T16	0.9439	0.7469	0.9421	0.9035
T17	0.9814	0.9257	0.9703	0.9551
T18	0.9603	0.5760	0.9682	0.8934



**Data-centric AI**


## **进展3-以数据为中心的大规模机组组合AI加速方法**

**面向电力系统AI辅助优化问题**


# 问题提出

- 机组组合问题的**高效求解**是保障电网安全经济运行的关键
- 机组组合**变量约束规模巨大**，**矩阵数值条件差**，**求解速度及精度要求高**
- 迫切需要使用AI加速机组组合，训练出高性能的AI智能体

## 机组物理特性



## 电网安全约束



## 机组发电计划

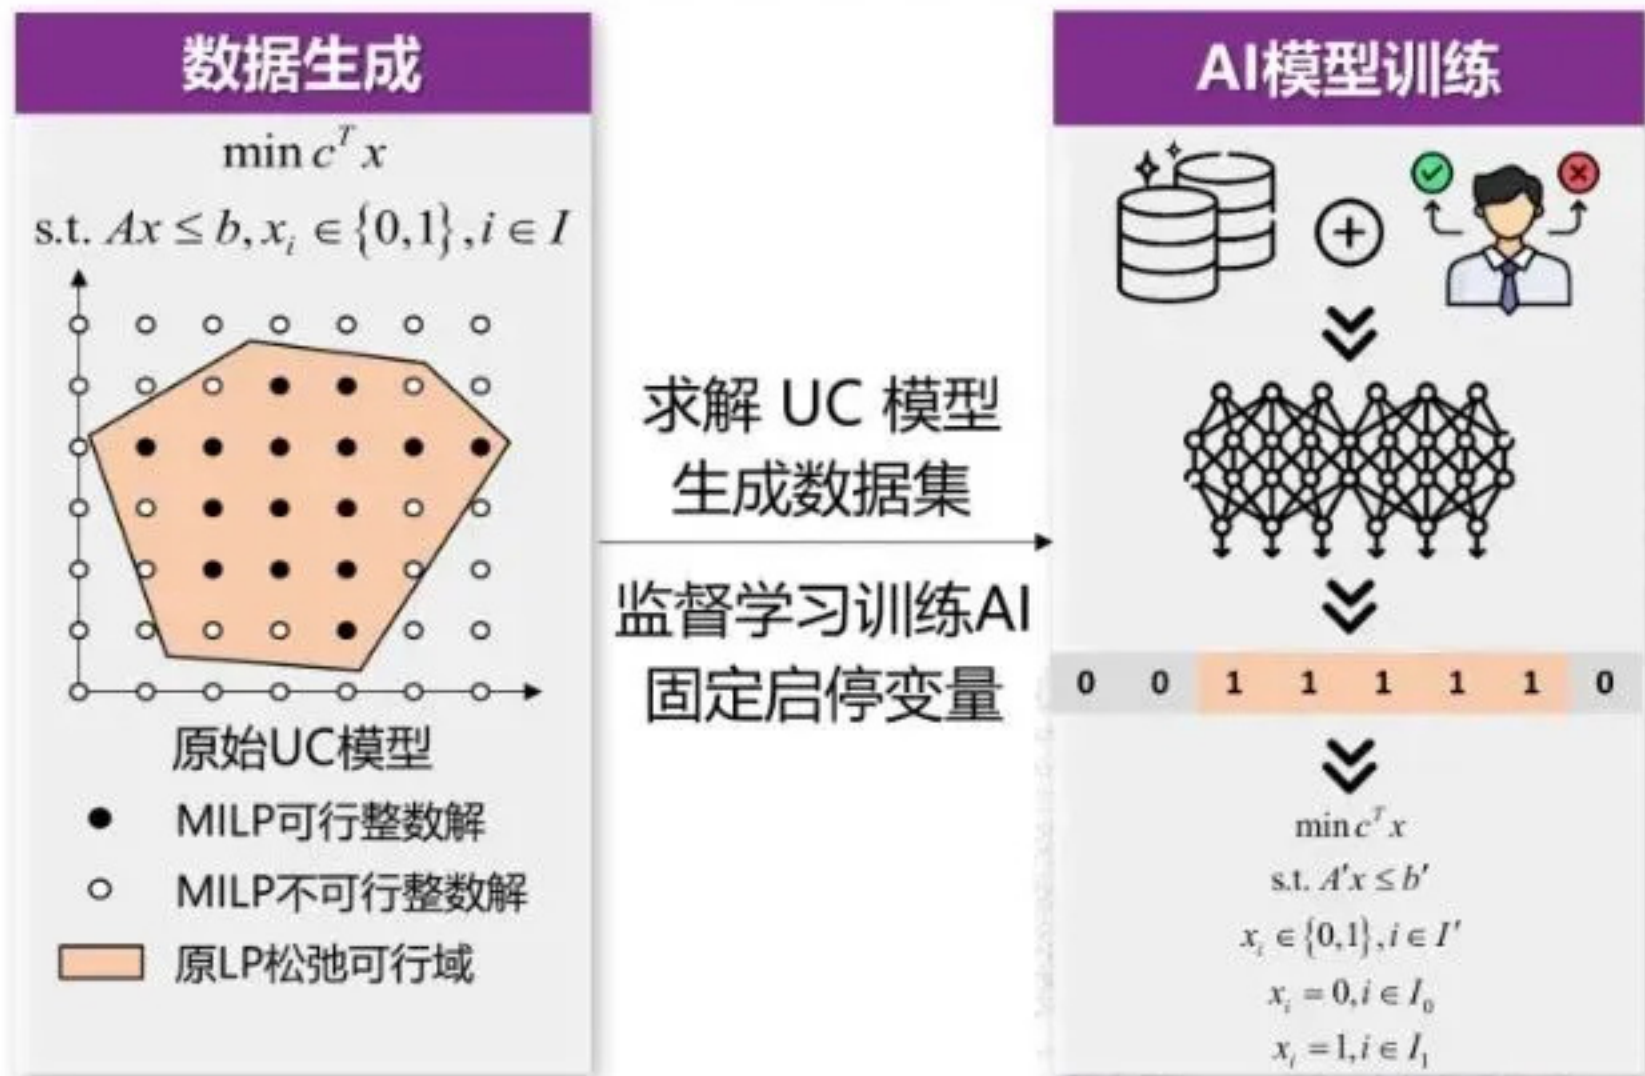
机组出力

0	10	15	20	15	10	0	0
0	0	20	25	28	30	20	0
0	0	0	0	0	0	0	0
0	0	0	0	30	40	50	60
30	35	40	42	37	32	35	40
0	0	0	35	40	35	0	0
20	30	25	30	35	40	45	40
0	25	30	30	25	0	0	0
0	0	0	0	0	0	0	0

时间

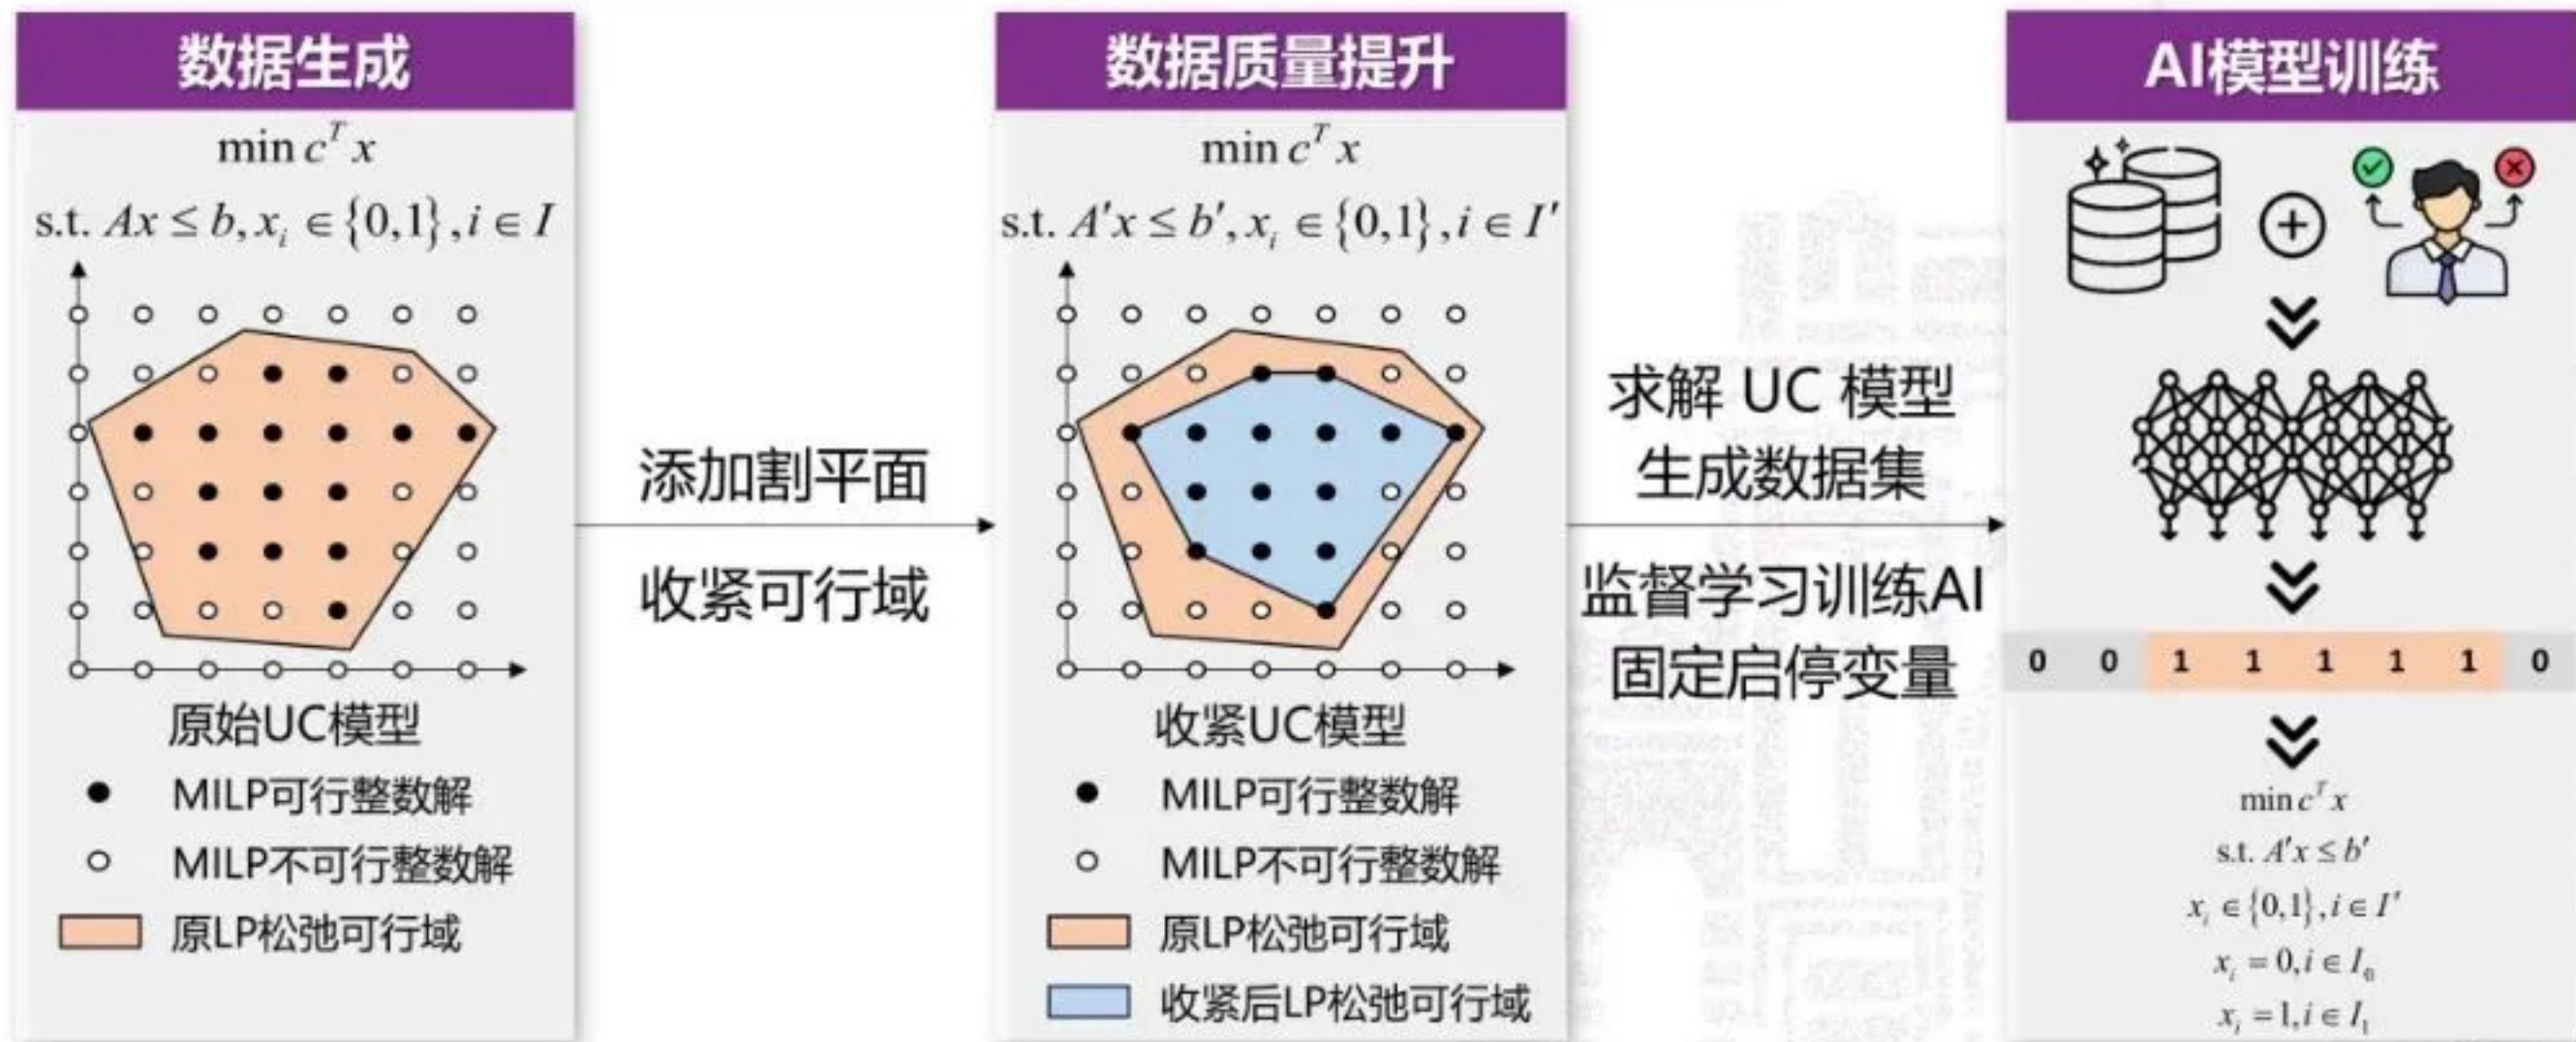
# 整体框架

- 通过求解机组组合模型为AI提供数据集，利用监督学习训练AI预测机组启停，通过AI固定优化中的启停变量来加速机组组合求解



# 技术路线3.1：基于割平面收紧的机组组合数据高效生成

提出支撑大规模机组组合的高质量数据高效生成方法，通过添加割平面收紧可行域，提升数据质量，同时也提高了数据生成效率



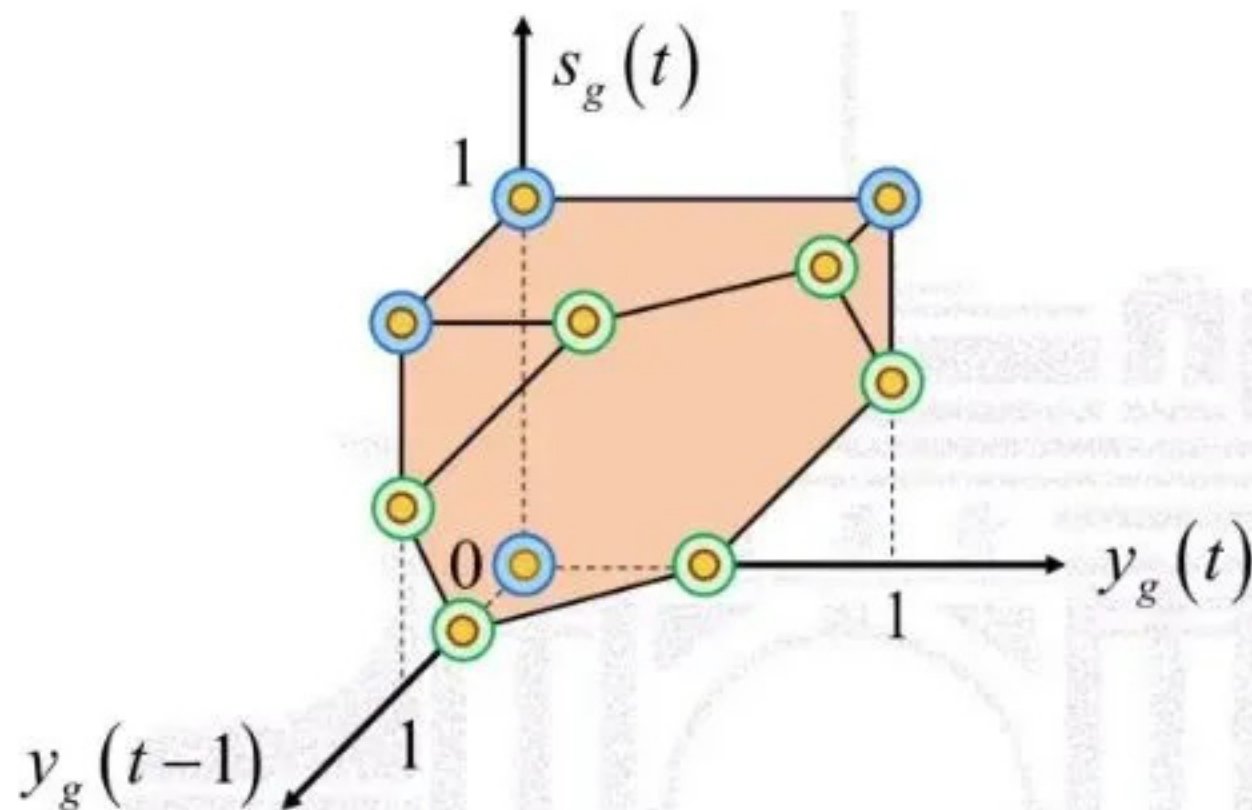
## 技术路线3.2：优化模型可行域收紧

### □ 以最小连续开机时间约束为例进行说明

$s_g(t) \in [0,1]$  → 发电机  $g$  在  $t$  时刻的开关状态  
 $y_g(t) \in [0,1]$  → 发电机  $g$  在  $t$  时刻的启动动作  
 $z_g(t) \in [0,1]$  → 发电机  $g$  在  $t$  时刻的关停动作

#### 基线程序中的最小连续开机时间约束

$$\sum_{i=t-UT_g}^{t-1} s_g(i) \geq UT_g \cdot z_g(t)$$



●  $UT_g = 2$  时原问题可行整数解

●  $UT_g = 2$  时可行域极点

■  $UT_g = 2$  时可行域投影

## 技术路线3.2：优化模型可行域收紧

### □ 以最小连续开机时间约束为例进行说明

$s_g(t) \in [0,1]$  → 发电机  $g$  在  $t$  时刻的开关状态  
 $y_g(t) \in [0,1]$  → 发电机  $g$  在  $t$  时刻的启动动作  
 $z_g(t) \in [0,1]$  → 发电机  $g$  在  $t$  时刻的关停动作


#### 基线程序中的最小连续开机时间约束

$$\sum_{i=t-UT_g}^{t-1} s_g(i) \geq UT_g \cdot z_g(t)$$



#### 收紧后的最小连续开机时间约束

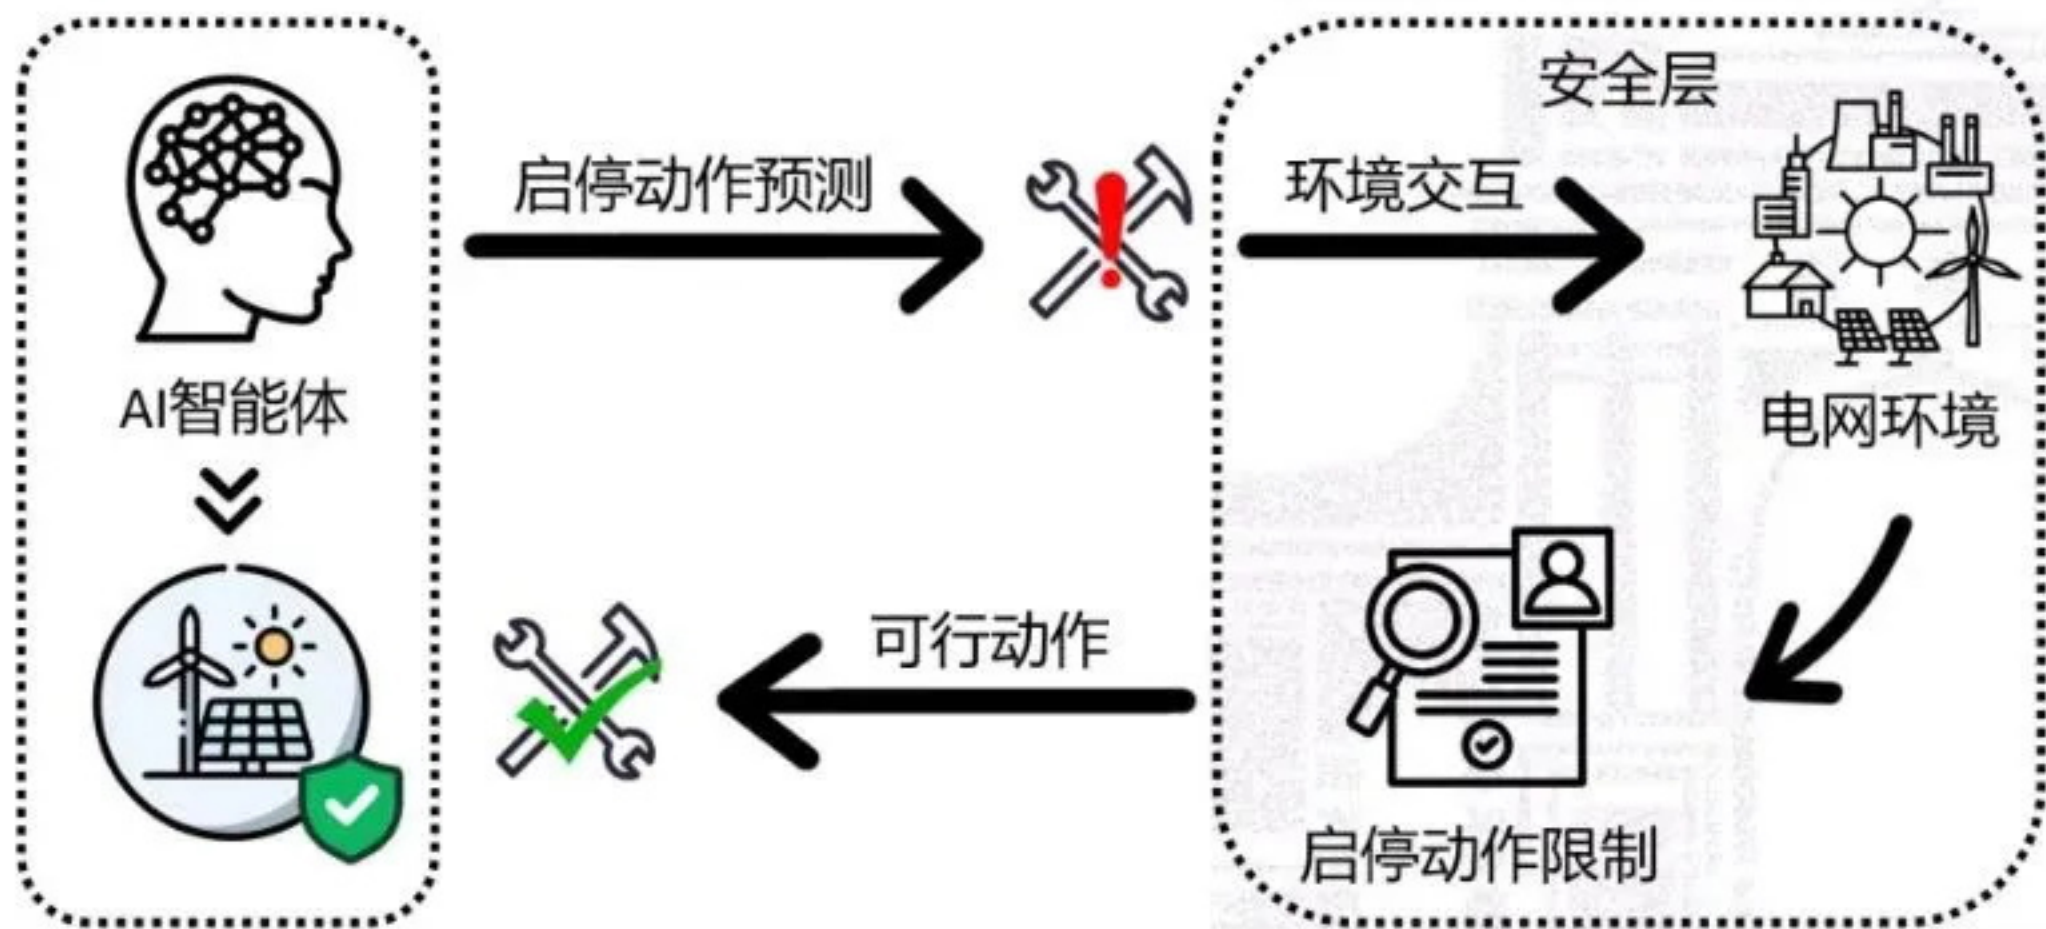
$$\sum_{i=t-UT_g+1}^t y_g(i) \leq s_g(t)$$



- $UT_g = 2$  时原问题可行整数解
- $UT_g = 2$  时可行域极点
- $UT_g = 2$  时可行域投影

## 技术路线3.3：基于监督学习的发电机启停预测

- 对于训练后的AI智能体，无法从理论上保证AI策略一定满足电网运行的硬约束
- 为此，在以自回归方式进行序贯决策时，我们在神经网络末端引入**安全层**，安全层将AI启停动作与电网仿真环境进行交互，**利用可行动作空间对AI启停动作的输出范围进行限制**，使AI启停动作满足约束，提升智能体的安全性和可靠性



# 算例验证

- 相关方法应用于第五届南网AI竞赛，对基线程序中 5 类约束进行收紧，共计约 30 万条，约占所有约束的 50%
- 针对 30 天训练数据，均设置求解器相对容差  $\leq 1\%$  时终止然后求解机组组合

## 平均求解时间(s)



## 平均求解容差



## 总求解时间




# 技术成效

- 相关技术用于2023年南方电网第五届电力调度AI应用大赛，在结果最优值与计算速度综合评分中获得**第一名并夺冠**，同时**包揽了创新奖、可视化奖**
- 相关技术**获得阿里巴巴达摩院AIR项目《基于AI的新型电力系统大规模实时调度增强技术研究》的继续资助**



## 以数据为中心的 大规模机组组合AI加速方法

汇报人：曾泓泰 王铮澄  
指导教师：郭庆东教授  
汇报单位：清华大学  
时间：2023年12月27日





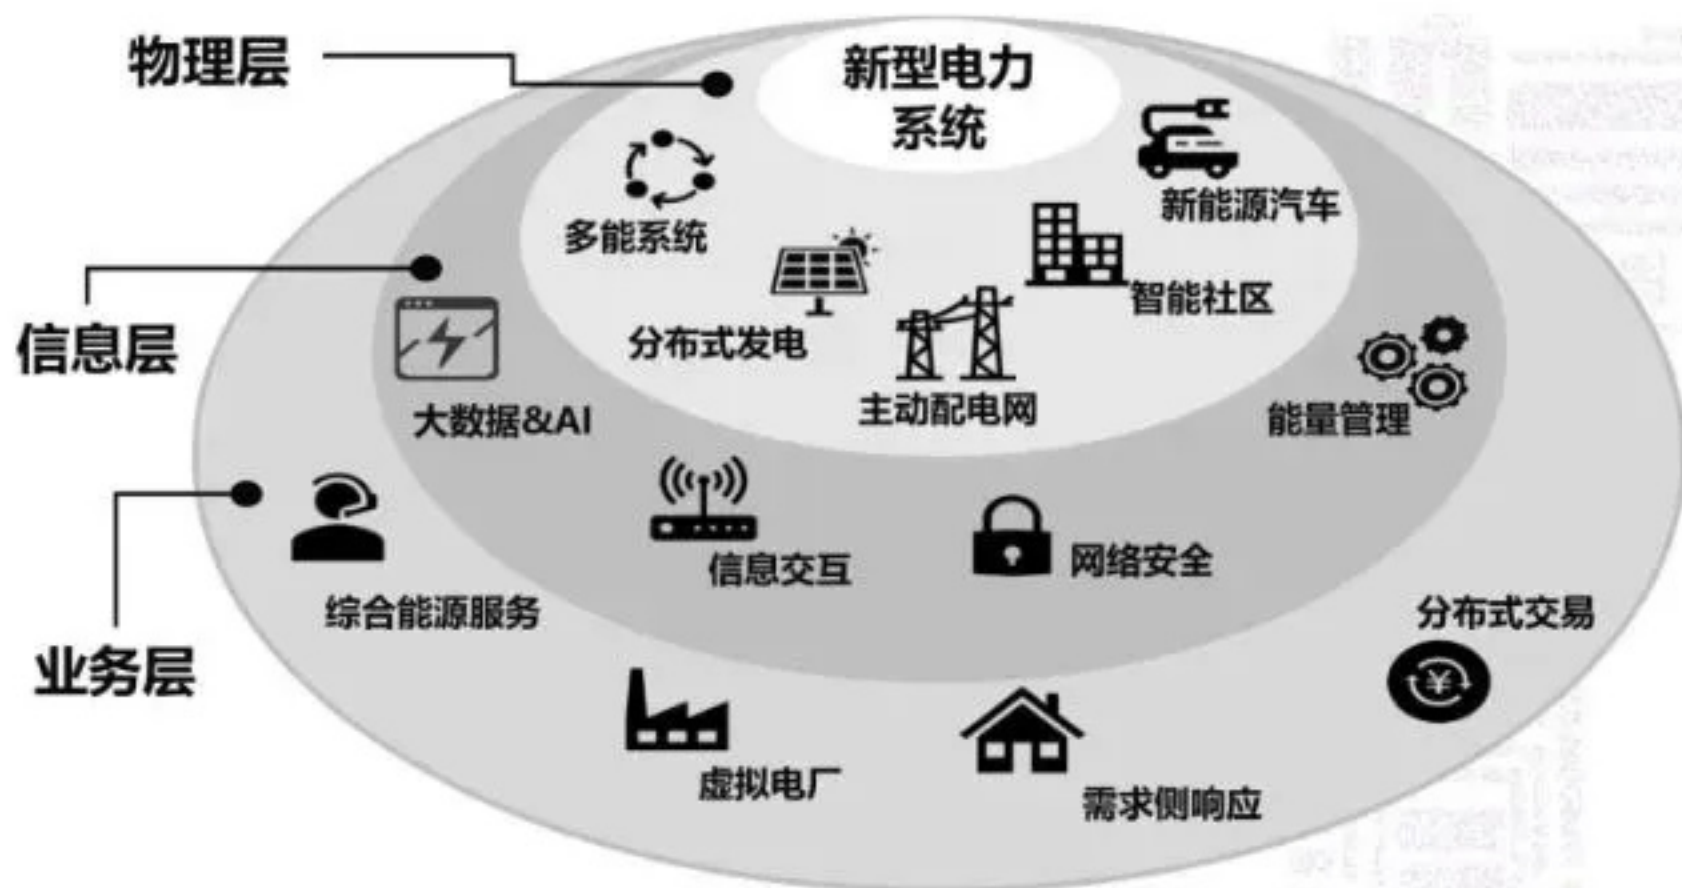
## Data-centric AI

### 进展4 - 多主体互动下考虑隐私保护的多方协同计算

解决数据“可用不可见”的联邦学习应用

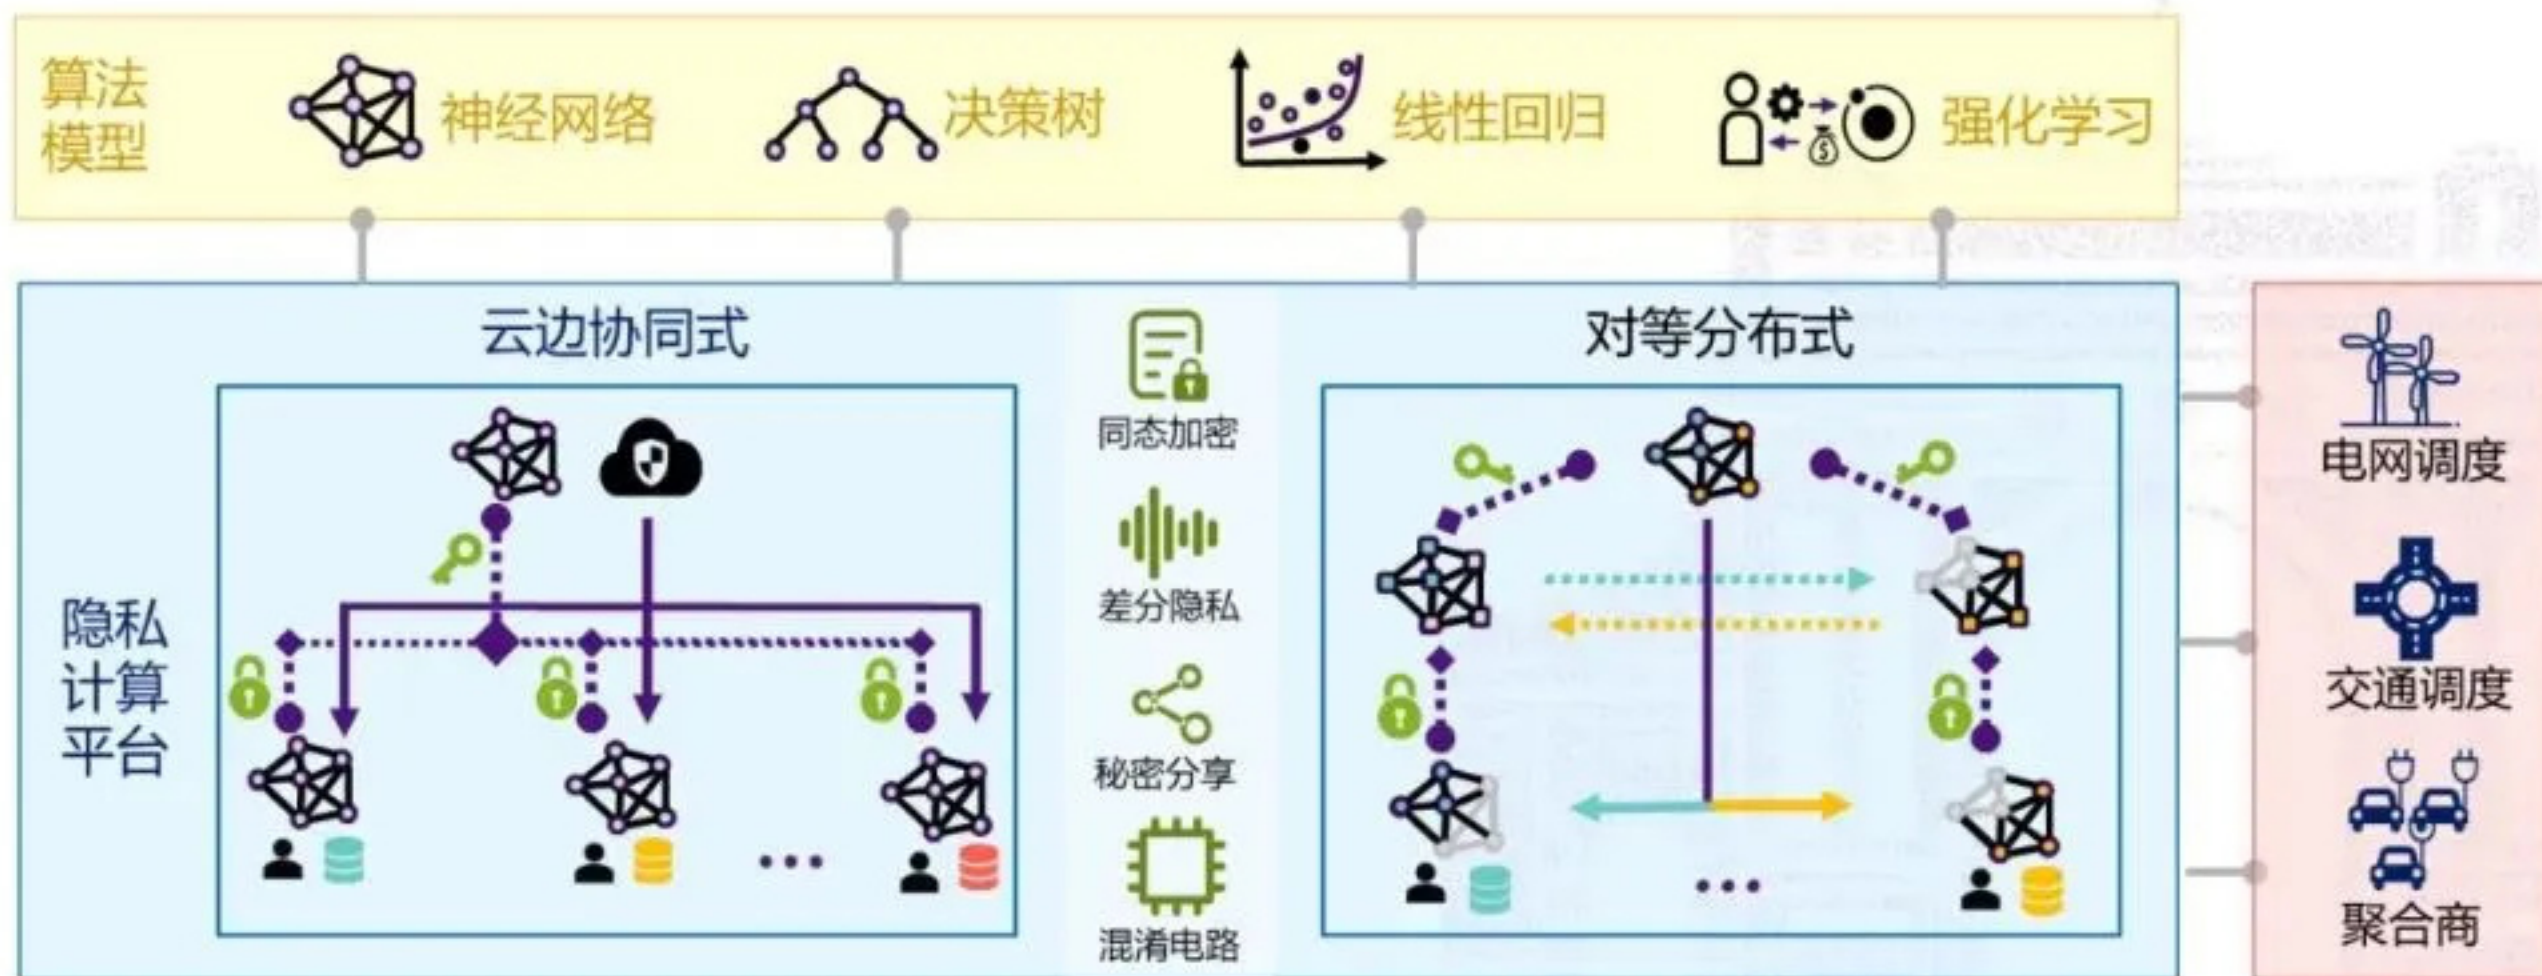
# 问题提出

- **多主体交互**是新型电力系统运行面临的新挑战
- 传统的协同优化计算过程将泄露不同主体的敏感运行信息
- 迫切需要考虑**隐私保护**的多方协同计算技术，打破数据壁垒，释放数据价值



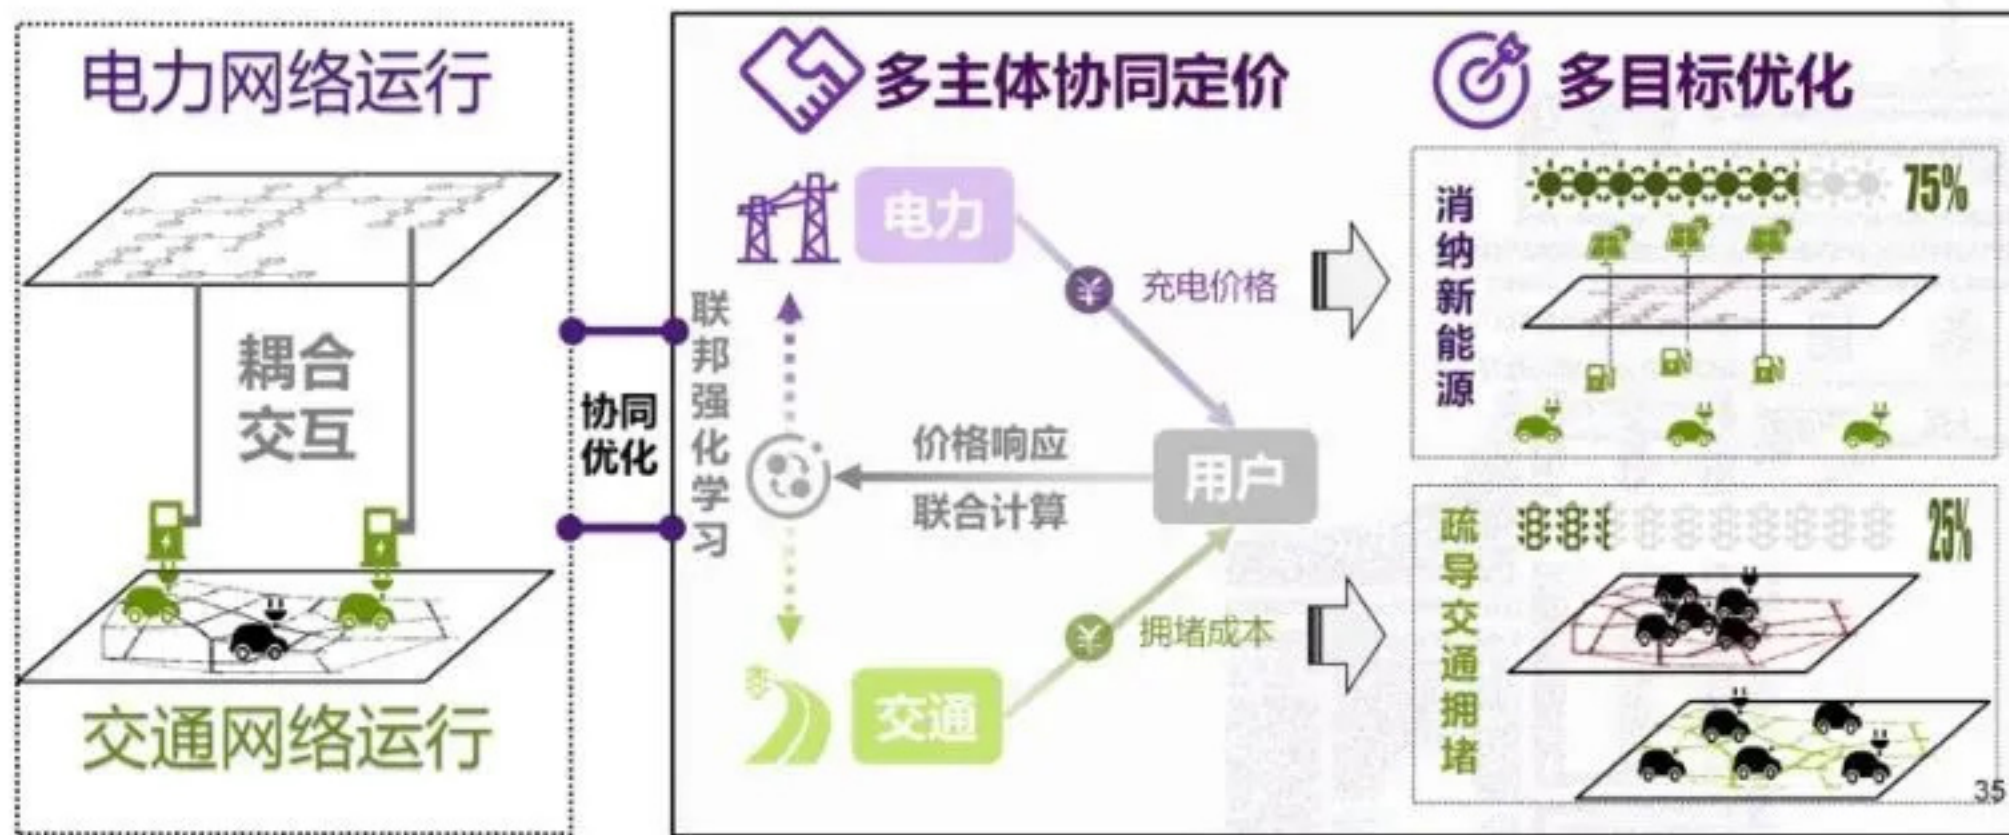
# 基本原理：联邦学习

- 联邦学习是一种保障多方数据安全的分布式机器学习架构，在数据不可见下实现可用聚合，使多方数据的“**可用不可见**”成为可能



# 场景一：交通网与电力网协同调控问题

- 海量电动汽车加强电力网、交通网耦合，需两网协同实现全局调控
- 协同优化计算过程将**泄露电力网和交通网的敏感运行信息**
- 耦合模型的复杂性和决策信号的时间耦合性**限制调控的动态灵活性**



以强化学习打破动态限制，以联邦架构击溃数据壁垒

# 技术路线4.1：基于联邦强化学习的电力-交通网安全协同调控

- 将电力-交通网协同调控问题建模为马尔可夫决策过程，通过**与仿真环境交互**学习最优策略
- 搭建纵向联邦式训练架构，通过**本地提取原始状态数据的高维特征**，避免信息直接泄露
- 在信息交互环节**融合差分隐私技术**，加强保障电力网和交通网敏感运行信息安全

## ■ 本地Q网络

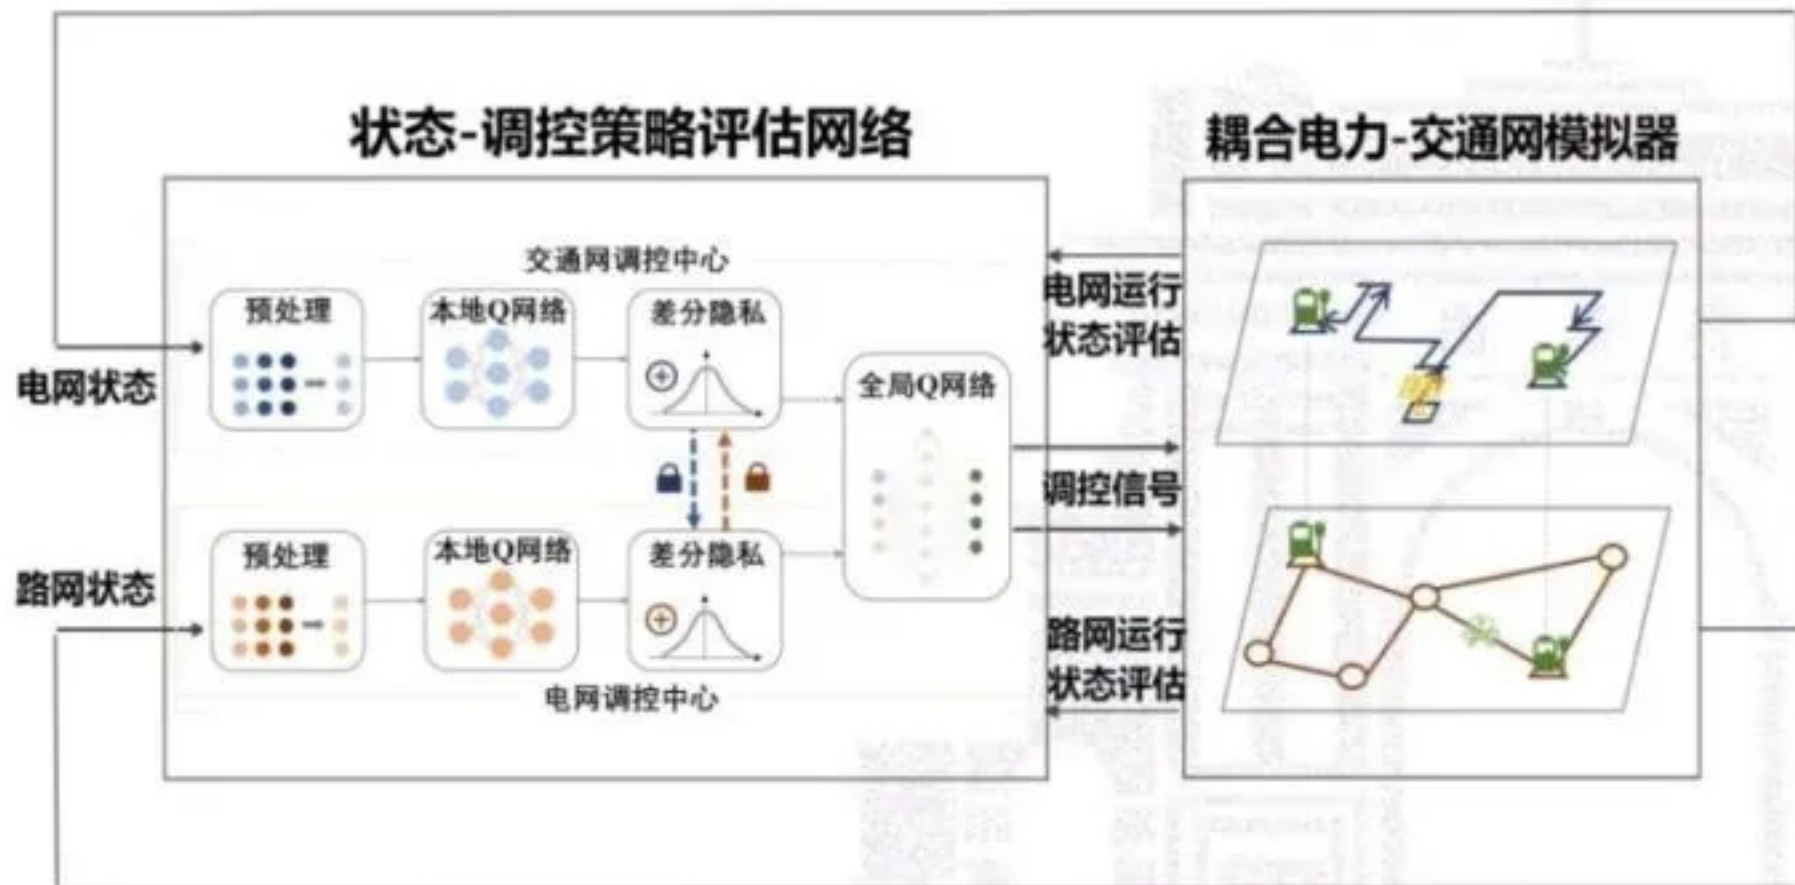
分别从状态信息中提取高维特征

## ■ 差分隐私模块

聚合前对高维特征进行随机噪声扰动

## ■ 全局Q网络

聚合电力网、交通网所提取高维特征，输出**全局视角下的调控策略评估**

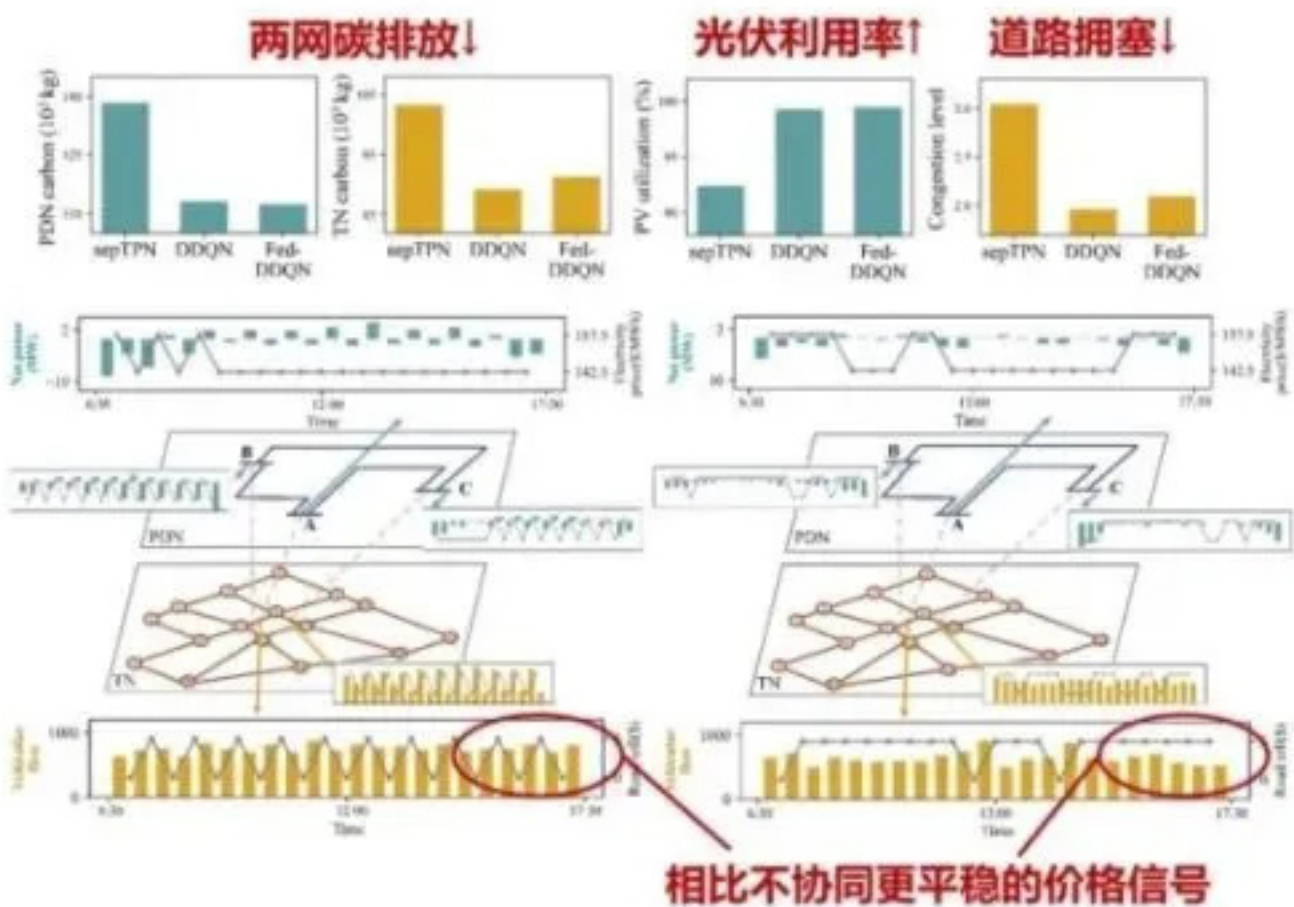


纵向联邦强化学习架构下的电力-交通网协同调控策略优化


# 算例验证

- 通过所提动态协同定价方法，引导EV用户的驾驶、充电行为，实现城市能源网**降碳减排**
- 相关技术受到国家重点研发计划《电-气-热-储多能系统协同优化控制与韧性提升技术》支持


✓ 交通-电力网碳排显著降低，运行明显改善



✓ 保护敏感运行数据，不影响训练性能



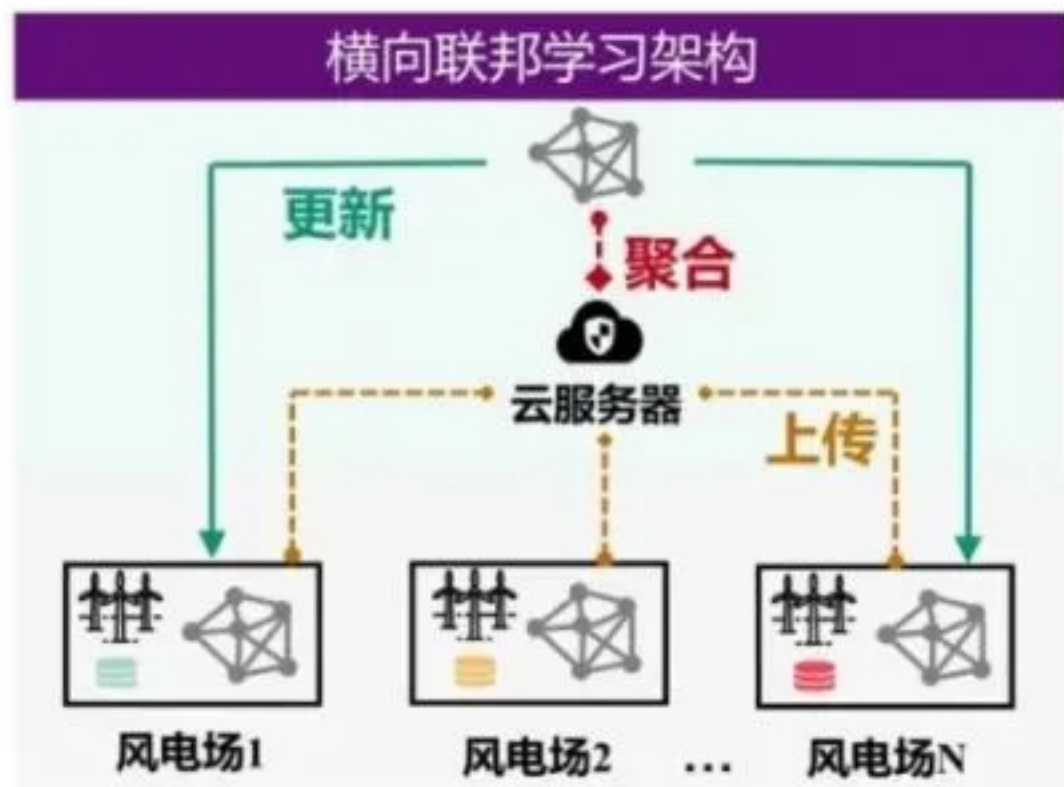
扰动交互的中间数据真实值



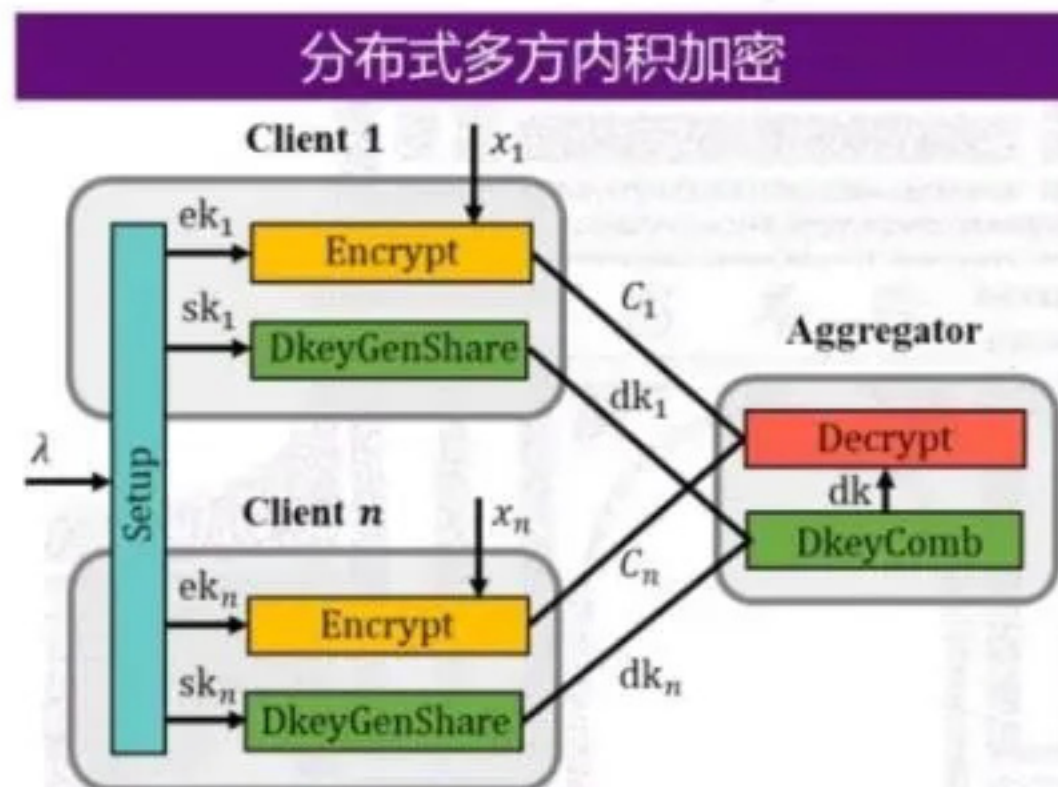
和无隐私保护方法下相近的测试性能

## 场景二：风电场协同预测

- 准确的风电出力预测是电网可靠稳定运行的关键保障
- 单个风电场**难以收集足量历史数据**训练准确度更高的预测模型，且风电场间**不愿共享原始数据**
- 从每轮迭代中的**模型参数可逆向推理出部分原始数据\***，安全性保障亟需加强



原始数据保存在本地，避免直接泄露

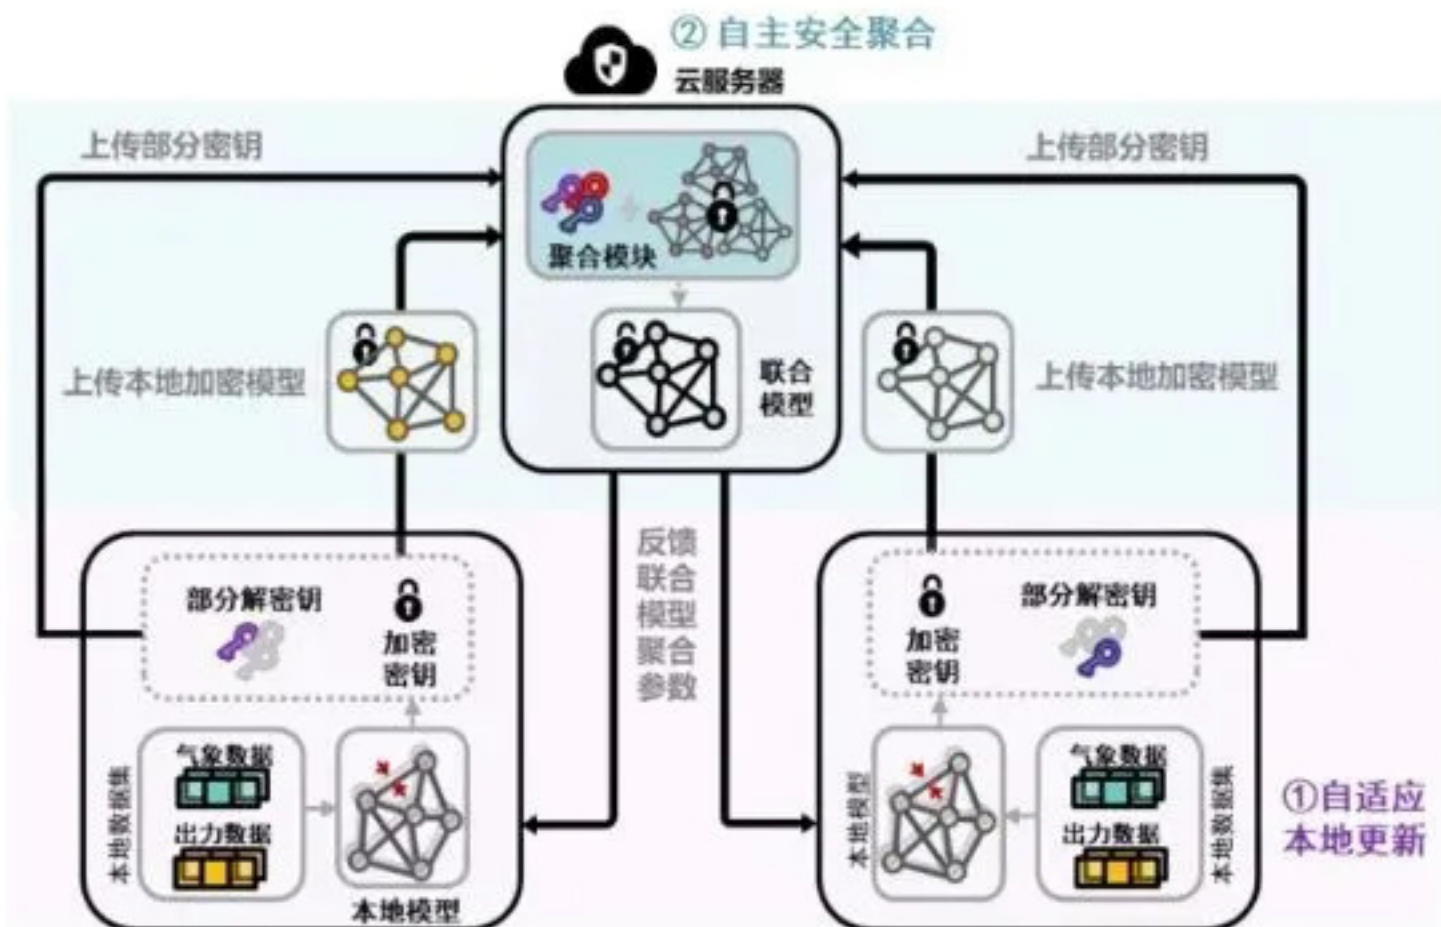


以密文形式实现多方交互计算，加强安全性

\*V. Mohbukuri, R. M. Farizi, S. Pouriye, Y. Huang, A. Dehghantanha, and G. Srivastava, "A survey on security and privacy of federated learning," *Future Generation Computer Systems*.

## 技术路线4.2：基于安全联邦的风电场协同预测

- 采用**分布式多方内积加密技术**实现模型参数的安全聚合，云端对加密模型解密后得聚合结果
- 考虑到各风电场持有数据的统计异质性，通过**动态限制每轮迭代的更新幅度**，提升收敛性能



基于安全多方加密的横向联邦式协同训练架构

### ① 自适应本地更新

各风电场利用本地数据集，如气象数据、出力数据，进行本地模型的动态自适应训练

$$L_i^t(\theta_i^t) = \mathbb{E}[(\phi_i(s_\tau; \theta_i^t) - y_\tau)^2] + \frac{\mu_t}{2} \|\theta_i^t - \theta_a^{t-1}\|_2^2$$
$$\mu_t = \max\{\bar{\mu} - \eta t, \underline{\mu}\}$$

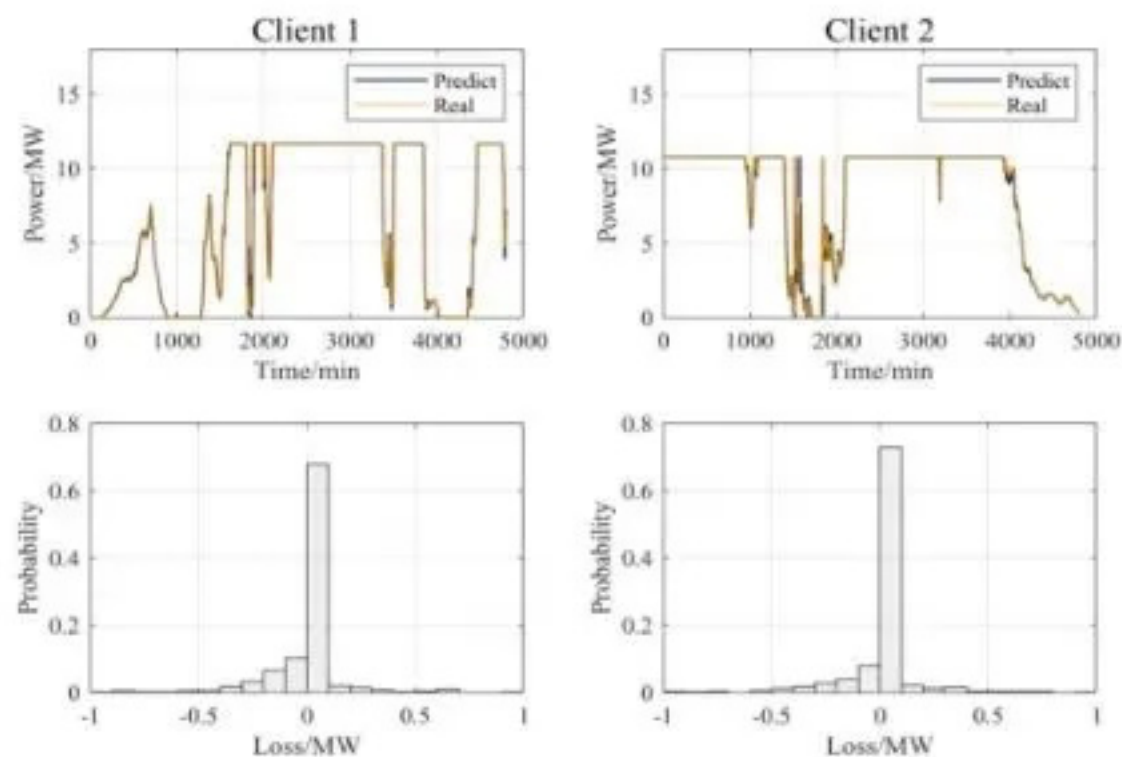
### ② 自主安全聚合

各风电场生成部分解密密钥，连同加密模型参数上传云端，在**无第三方机构分发密钥**的条件下，云端生成完整的解密密钥，并计算模型参数的聚合结果

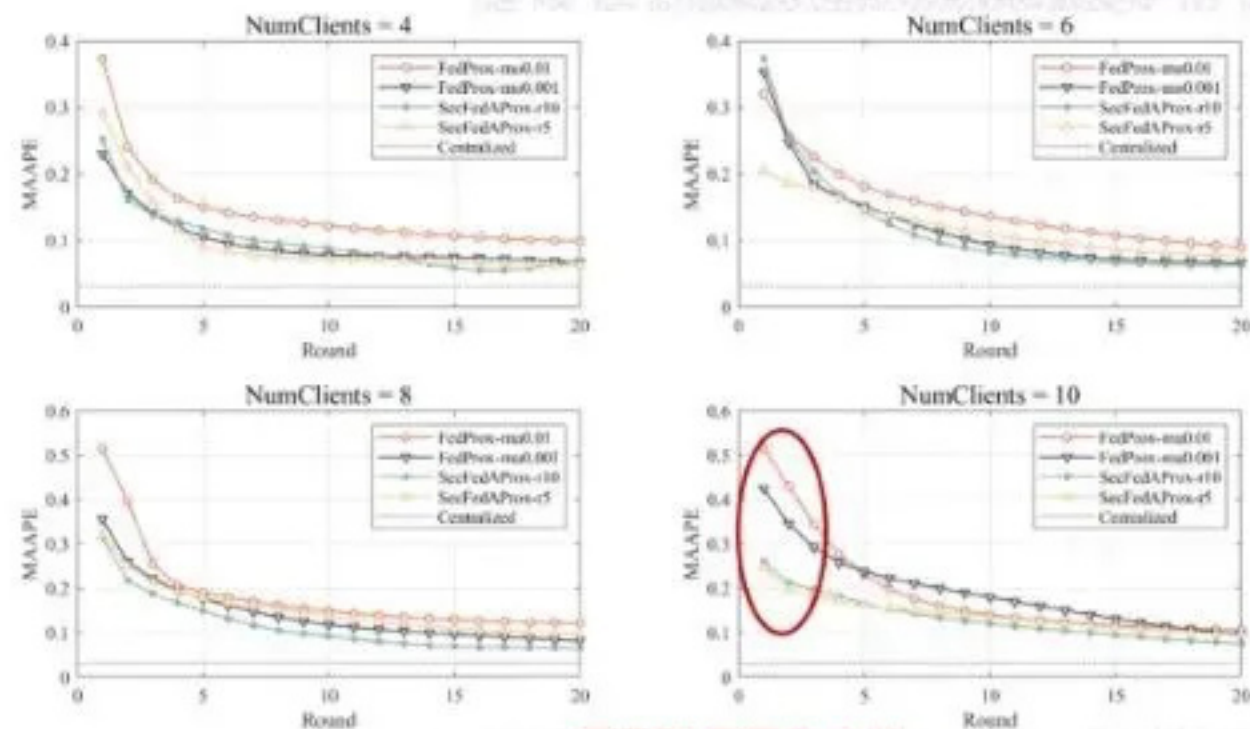
# 算例验证

- 在**加强的隐私安全保护**下，通过聚合地理临近风电场数据集，充分挖掘风电出力时空相关性，提升了预测准确度；且所提的改进算法收敛性能更优
- 相关技术受到国家电网公司科技项目《公专互动网络环境下的新型业务系统安全风险评估与主动防控技术研究》、清华大学-港华能源投资有限公司零碳智慧园区支持

## ✓ 优异的预测性能



## ✓ 稳定快速的收敛性能



显著快于已有方法

## 相关论文

1. Lan J, Zhou Y, Guo Q, et al. Data Augmentation for Data-driven Methods in Power System Operation: A Novel Framework using Improved GAN and Transfer Learning[J]. IEEE Transactions on Power Systems, 2024: 1-13.
2. Z. Wang, Y. Zhou, Q. Guo, and H. Sun, "Interpretable neighborhood deep models for online total transfer capability evaluation of power systems," IEEE Transactions on Power Systems, vol. 37, no. 1, pp. 260-271, June 2022.
3. Z. Wang, Y. Zhou, Q. Guo and H. Sun, "The total transfer capability assessment of transmission interfaces combining causal inference and multi-task learning," IEEE Transactions on Power Systems, vol. 39, no. 1, pp. 453-464, Jan. 2024.
4. Tianyu Hu, Qinglai Guo, Xinwei Shen, Hongbin Sun, Rongli Wu and Haoning Xi. Utilizing unlabeled data to detect electricity fraud in AMI: a semi-supervised deep learning approach[J]. IEEE Transactions on Neural Networks and Learning Systems. 2019, 30(11):3287-3299.
5. Tian-en Huang, Qinglai Guo, and H. Sun. A distributed computing platform supporting power system security knowledge discovery based on online simulation[J]. IEEE Transactions on Smart Grid, 2017, 8(3): 1513-1524.
6. Zeng H, Zhou Y, Guo Q, et al. A distributed deep reinforcement learning-based approach for fast preventive control considering transient stability constraints[J]. CSEE Journal of Power and Energy Systems, 2021, online
7. Yanzhen Zhou, Qinglai Guo, Hongbin Sun, et al. A novel data driven approach for transient stability prediction of power systems considering the operational variability [J]. International Journal of Electrical Power & Energy Systems, 2019 (107) : 379-394
8. Tian-en Huang, Qinglai Guo, Hongbin Sun, Chin-Woo Tan, and Tianyu Hu. A deep learning approach for power system knowledge discovery based on multitask learning[J]. IET Generation Transmission & Distribution.
9. 郭庆来, 兰健, 周艳真, 等. 基于混合智能的新型电力系统运行方式分析决策架构及其关键技术[J]. 中国电力, 2023, 56(9): 1-13.
10. 兰健, 郭庆来, 周艳真, 等. 基于生成对抗网络和模型迁移的电力系统典型运行方式样本生成[J]. 中国电机工程学报, 2022, 42(8): 2889-2900.
11. 王铮澄; 周艳真; 郭庆来; 孙宏斌; 考虑电力系统拓扑变化的消息传递图神经网络暂态稳定评估, 中国电机工程学报, 2021, 41(7): 2341-2349
12. 王铮澄; 周艳真; 郭庆来; 孙宏斌; 面向变化场景的输电断面极限评估主动迁移学习方法, 中国电机工程学报, 2023, 43(15): 5732-5745.

**感谢各位专家， 敬请指导！**