

**案例名称：** AI 赋能 —— 电网安全卫士：万节点级复杂大  
电网紧急控制智慧决策系统

**专业学位类别：** 电气工程、能源动力专业硕士

**适用课程：** 《现代电力系统分析》、《现代控制理论》、  
《复杂网络与群体智能》、《电力自动化系统》、  
《人工智能在电力系统中的应用》

**作者姓名：** 姚伟

**工作单位：** 华中科技大学

# AI赋能——电网安全卫士：万节点级复杂大电网紧急控制智慧决策系统<sup>1</sup>

**摘 要：**新型电力系统高维复杂、波动性强等特征加剧失稳风险，电网失稳严重危害国民生活和社会秩序。仿真分析并预先制定控制措施是保障大电网安稳运行的支撑技术。现有技术需大量人工参与，易出错、效率低、成本高，难以适应万节点级新型电力系统爆炸性增长的数据分析量。本案例针对上述问题，提出以下创新技术：1) 融入电网知识的两阶段智能精准决策算法；2) 并行分支网络决策快速性提升技术。3) 轻依赖新标注的差异化电网迁移技术。以多省互联的万节点级大电网决策为例，准确率高于97.5%，单次平均耗时<10s、差异化电网迁移需新标注样本≤10%。系统已应用于中国电力科学研究院仿真中心、国网湖北省电力有限公司等5家企业，工程实用价值高，受到国内外电力领域权威专家的高度评价。

**关键词：**新型电力系统；人工智能；智能决策；万节点级；案例研究

**Abstract:** The characteristics such as high dimensional complexity and strong volatility of the renewable power system increase the risk of instability, which seriously jeopardizes the national life and social order. Simulation analysis and pre-formulation of control measures is a supporting technology to ensure the stable operation of large power grids. Existing technologies require a large number of manual participation, are error-prone, inefficient, and costly, and are difficult to adapt to the explosive growth of

---

<sup>1</sup> (1)本案例系教育部学位与研究生教育发展中心2024年度工程案例项目成果(项目名称：AI赋能——电网安全卫士：万节点级复杂大电网紧急控制智慧决策系统；项目编号：GC-241048701；首席专家：姚伟)。

(2)本案例复制权、发表权、信息网络传播权等相关权益由教育部学位与研究生教育发展中心依法享有，如有相关需要，请取得教育部学位与研究生教育发展中心授权。

(3)本案例只供课堂讨论之用，并无意暗示或说明某种行为是否有效。

data analysis of the new 10,000-node-level power system. This case proposes the following innovative techniques to address the above problems: 1) A two-stage intelligent and precise decision-making algorithm incorporating grid knowledge; 2) A parallel branch network decision-making rapidity enhancement technique; and 3) A differentiated grid migration technique that lightly relies on new annotations. Taking the decision-making of a multi-province interconnected 10,000-node large power grid as an example, the accuracy rate is higher than 97.5%, the average time consumed for a single decision is <10s, and the differentiated grid migration needs new labeled samples  $\leq 10\%$ . The system has been applied to five enterprises, including the Simulation Center of China Electric Power Research Institute and State Grid Hubei Electric Power Company, with high engineering utility value and highly evaluated by authoritative experts in the field of electric power.

**Keywords:** renewable power system; artificial intelligence; intelligent decision making; 10,000 node level; case study

# 目录

<b>1. 工程项目背景及现状 .....</b>	<b>5</b>
1.1 新型电力系统安全稳定问题 .....	5
1.2 大电网故障预防：人工主导的仿真分析与决策 .....	5
1.3 人工智能与大电网智能决策技术 .....	6
<b>2. 工程的实施过程 .....</b>	<b>7</b>
<b>3. 工程方案分析论证 .....</b>	<b>8</b>
3.1 技术一：融入电网知识的两阶段智能精准决策算法 .....	8
3.2 技术二：并行分支网络决策快速性提升技术 .....	15
3.3 技术三：轻依赖新标注的差异化电网迁移技术 .....	22
<b>4. 实施效果 .....</b>	<b>26</b>
4.1 电网智慧决策支持系统功能及应用 .....	26
4.2 系统决策性能 .....	28
4.3 工程应用效果 .....	29
<b>5. 结语部分 .....</b>	<b>30</b>
<b>参考文献 .....</b>	<b>30</b>

# 1. 工程项目背景及现状

## 1.1 新型电力系统安全稳定问题

目前，中国的电力系统在发电装机总容量、非化石能源发电装机容量、远距离输电能力及电网规模等多个指标上，均位居全球首位<sup>[1]-[5]</sup>。截止 2022 年底，我国各种电源的总装机容量已达到 25.6 亿千瓦，而西电东送的规模大约在 3 亿千瓦左右。全国电网构成了多省电网互联的万节点级的复杂电网互联结构，形成以东北、华北、西北、华东、华中、南方六大区域电网为主体、区域间有效互联的电网络格局。区域电网通常由 4-5 个省级电网互联而成，节点数可达上万个。

为了推进新型电力系统建设，国家大力发展以光伏、风能、核能等为代表的新能源发电装置，2021 年全年的非化石能源装机总量为 10.8 亿千瓦，占发电装机总量的 45.4%，占比接近一半。新型电力系统的主要特征：以风电、光伏新能源逐步成为主体能源，装机容量会大幅度提升，从而导致新型电力系统的本质改变。由于新能源具有间歇性、随机程度大和发电波动性大等特点，电力系统的调节与控制变得更加困难，系统的平衡和安全问题也更加突出<sup>[6]-[10]</sup>。系统低惯量、低阻尼、弱电压支撑等特征明显<sup>[11]-[13]</sup>。系统主体的多元化、电网结构的复杂化以及运行方式的多样化特点愈加显现，这对电力系统的安全、高效和稳定运行带来了更大的挑战。

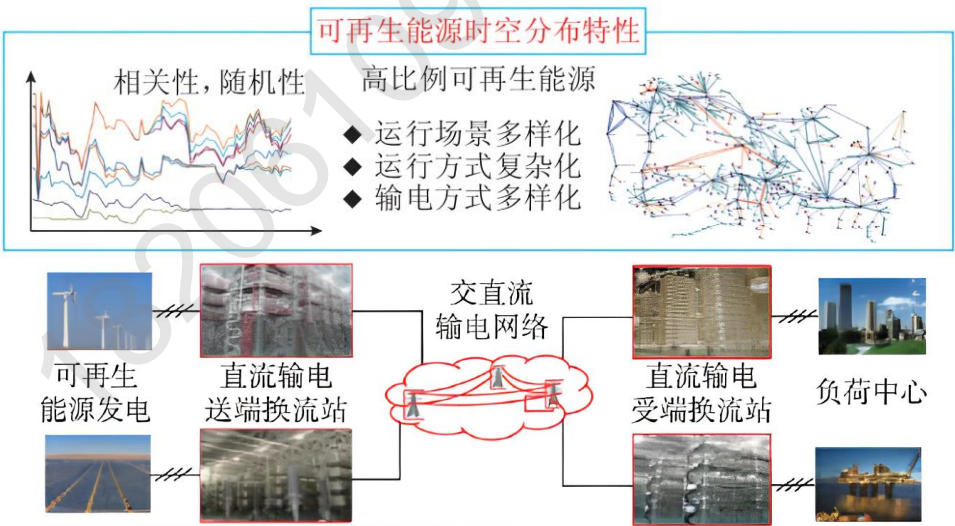


图 1-1 新型电力系统的双高特性与稳定挑战

因此，新型电力系统波动性强、高维复杂、运行方式多样，且我国电力系统规模庞大，多因素共同导致电力系统安全稳定运行存在巨大挑战亟待攻克。

## 1.2 大电网故障预防：人工主导的仿真分析与决策

电网仿真技术是电力系统规划和运行的支撑性技术，对保障电力系统的安全稳定运行起着至关重要的作用<sup>[14]-[16]</sup>。电力系统每年运行方式和潜在暂态故障的

控制策略制定都依赖电网仿真。近年来,高性能计算技术水平的飞升为实际大电网的仿真计算速度带来了巨大提升,也产生了海量的仿真数据,这些数据呈现出高维、稀疏、冗余、强时空关联的特征,给仿真数据的分析带来了巨大的困难<sup>[3]</sup>。**依赖人工的仿真数据处理方法已经无法满足愈加复杂的大型电网仿真分析需求。**

制定紧急控制决策是仿真分析的关键环节。当发生可能导致系统失稳的严重故障时,需要采取紧急控制措施维持电力系统稳定,这构成了我国电网安全稳定保障体系中的第二道防线<sup>[17]</sup>。在紧急控制决策的制定过程中,专家通过试凑法<sup>[18]</sup>以及仿真分析计算来确定决策的效果。如果决策不能使系统恢复稳定,则需要反复尝试新决策直到能使系统稳定为止。这种人工方法存在如下局限:首先,决策过程的有效性在很大程度上取决于相关系统的具体运行经验,因此很难将这些方法应用到不同的系统或运行模式中。其次,反复尝试决策和仿真计算耗费大量时间和精力,导致决策效率低下。最后,专家的分析精度有限,有时可能无法确定最佳解决方案,从而导致次优决策,造成更大的电力损失。

现阶段国家电网主网架一次仿真计算将输出上百万个变量,国网调度中心每年需进行 4 次大规模仿真,每次需要 100 余人参与且历时一到两个月,分析 50 万个以上的故障情况,耗时耗力。现有的人工进行分析将带来效率低下、误差和缺漏难以控制、依赖专家经验等问题,电网安全稳定运行的高要求和海量仿真数据的分析困难使得对智能化仿真数据分析的需求越来越大。

### 1.3 人工智能与大电网智能决策技术

国家能源局《加快推进能源数字化智能化发展》意见指出:应探索人工智能及数字孪生在电网智能辅助决策和调控方面的应用。引入人工智能技术,有望扩展大电网仿真分析的深度和精度,有效减少人工参与,然而实现决策的智能化仍面临着许多技术挑战。

尽管近年来国内外学者不断提出将人工智能技术应用到电力系统的安全稳定评估与控制当中,但是这些方法大多关注在线应用场景,然而现有的机器学习技术仍处于“弱人工智能”阶段,具有诸多的局限性,需要满足样本充足、信息完备、有容错率等要求<sup>[19]</sup>,这带来的人工智能技术可解释性较弱、鲁棒性不足以及在线场景容错率低等问题限制了其在在线场景的发展。而在大电网仿真数据分析领域,其对模型的应用要求有所降低,一方面所有的电网变量和数据都可以准确获取,另一方面仿真数据分析处于离线场景中,具有较高的容错率,大电网仿真数据分析是更契合现阶段人工智能技术实际情况的应用场景,满足将新一代人工智能技术应用到电网工程实际中的条件。

近年来,计算能力的提升极大促进了电压稳定控制人工智能技术的发展。文献[20]引入了一种基于深度强化学习的方法,设计出一种紧急控制方案,将发电

机制和切负荷整合在一起制定紧急控制。文献[21]采用主成分分析提取系统特征，并利用人工神经网络将系统状态映射到适当的电压稳定控制策略。文献[22]提出了一种分层数据驱动方法：第一层神经网络确定最佳切负荷位置，第二层神经网络确定所需的精确切负荷量。尽管这些研究取得了初步成果，但在应对电压失稳问题时，现有方法往往未能细化不同失稳形式的具体特征，导致在某些情况下难以获得有效的控制措施。此外，人工智能在大规模电网中的应用面临诸多挑战，包括可选负荷种类繁多、负荷切除量的连续性以及高维输出变量等问题。这些因素增加了训练的复杂性，使得一次性获得有效控制措施变得困难。

总而言之，目前运用人工智能进行电网智能决策主要尚存在决策准确度、决策速度慢、迁移应用难的技术难题。

## 2. 工程的实施过程

该工程历经 4 年攻关与应用实践，受到首批国家自然科学基金智能电网联合基金集成项目(重大类)(U1866602)：基于数字仿真的大电网人工智能分析方法研究的资助。此外，本案例受到国家电网总部科技项目 2 项(基于预想故障信息的电网动态安全评估与决策及其应用研究、新一代人工智能技术在未来电网安全分析与决策中的应用研究)、国家电网华中分部科技项目 1 项(基于数据-知识混合驱动的电网安全稳定分析关键技术研究)等的资助。具体实施流程如下：

- 1) 发现问题：该工程案例于 2020 年 8 月于国网调度中心调研，发现了现有的人工进行分析决策效率低下、误差和缺漏难以控制、依赖专家经验等问题。为了攻克当前难题，组建“电网智控团队”，开启项目研究。
- 2) 创新思路：通过国内外的技术调研与多次研讨，团队与 2020 年 12 月提出并确定项目的创新思路：深度融合电力领域知识与人工智能的大电网智能决策方案。目标实现高效、准确、全面的智慧决策。
- 3) 科研攻关：团队于 2020 年 12 月至 2021 年 3 月进行样本生成与模型训练，首先生成大量的电力系统样本，并通过筛选得到失稳样本，针对样本需要制定相应决策方法，采用样本进行人工智能模型的训练。于 2021 年 4 月至 2021 年 6 月进行决策对象与措施量设计，针对电力系统中的失稳样本，采取先筛选决策对象再确定决策措施量的两阶段方法进行决策的制定。于 2021 年 6 月至 2022 年 12 月进行并行分支网络研究，破解节点数庞大电网受限的模型训练耗时与决策精准度问题，提升了方案的有效适用规模。于 2022 年 12 月至 2022 年 4 月进行模型迁移与应用设计，通过所提出的迁移学习方法，降低迁移学习时的所需样本标注量，使得模型能够适应全场景。

#### 4) 技术突破:

- ① 百节点级标准测试系统: 2021 年 6 月, 基于所提出的技术一融入电网知识的两阶段智能精准决策算法, 成功实现在百节点级标准测试电网中决策成功率 100%, 并将技术落地研发了决策原型系统。
- ② 千节点级省级电网决策系统: 2021 年 12 月, 基于技术一和所提出的技术二并行分支网络决策快速性提升技术, 突破千节点级电网决策, 在湖北省级电网测试成功。
- ③ 万节点级区域电网智慧决策系统 2022 年 4 月, 通过对技术一和技术二的改进研究, 首次突破万节点级电网决策, 并开发万节点级电网失稳紧急控制智慧决策支持系统。

5) 工程应用与技术迭代: 2022 年 4 月至今, 团队先后与中国电力科学研究院仿真中心、国网湖北省电力有限公司等 5 家企业开展应用合作。并在应用测试中不断对所提方案迭代提升。

### 3. 工程方案分析论证

#### 3.1 技术一: 融入电网知识的两阶段智能精准决策算法

针对人工决策错漏易发、误差难控的问题, 本案例基于人工智能技术, 提出了一种两阶段决策紧急控制方法。在第一阶段, 通过全面分析仿真数据确定各种电压不稳定模式, 并基于此为有效切负荷点的优先排序提供依据。第二阶段, 采用 LightGBM 算法来精确估算所需的切负荷量。然后, 按照确定的优先级, 将这些数量分配给之前确定的关键负荷点。实施切负荷操作后, 根据切负荷后系统的稳定性对切负荷量进行微调。基于东北电网验证了算法的有效性。

##### 3.1.1 精准控制决策框架

图 3-1 所示为进行精准电力系统决策控制的基本框架, 包含离线预决策与实时工况匹配两个阶段。第一阶段根据暂态稳定经验知识筛选切负荷点, 第二阶段根据智能算法确定切负荷量。



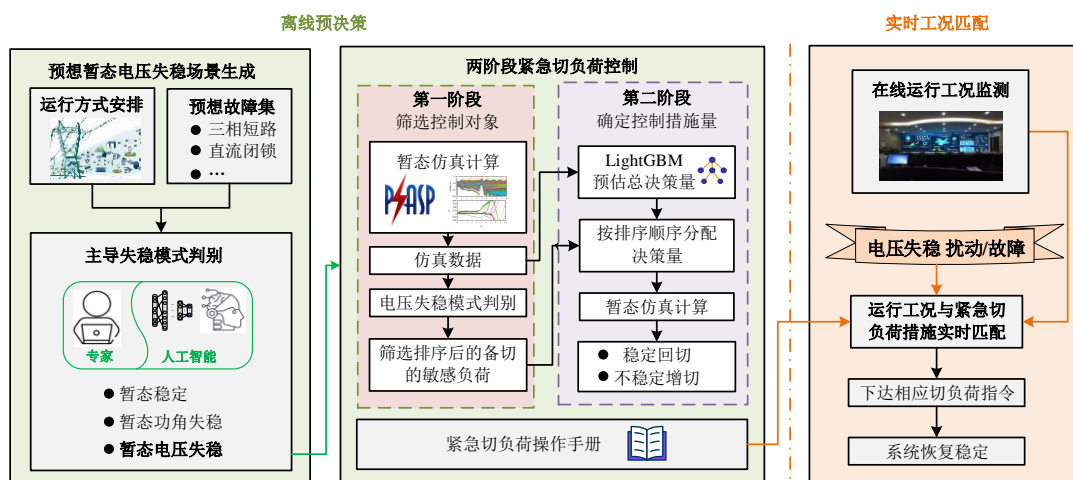


图 3-1 精准决策控制的离线预决策-实时工况匹配框架

### 3.1.2 第一阶段-筛选控制对象

技术一区分了纯电压失稳、耦合电压失稳和混合电压失稳这三种暂态电压失稳的表现形式。针对每种失稳形式，采用了各种不同的切负荷节点筛选方法，以提高确定最佳切负荷节点的效率。

#### 1) 纯电压失稳模式

图 3-2 所示为在纯电压失稳模式下电压与功角曲线。在这种运行工况和故障条件下，故障切除后，母线电压持续下降，而所有发电机的相对功率角保持稳定。这种电压失稳与功率角失稳的相互解耦的故障现象表明，该区域由于电力系统故障导致了电压失稳。

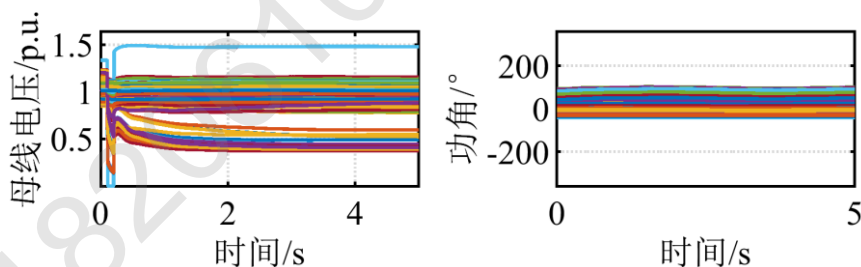


图 3-2 纯电压失稳下电压和功角曲线

负荷序列由负荷电压从低到高排序获得

$$\begin{cases} \mathbf{L} = [\mathbf{L}_s^{V_1}, \dots, \mathbf{L}_s^{V_i}, \mathbf{L}_s^{V_{i+1}}, \dots, \mathbf{L}_s^{V_n}] \\ \text{s.t. } V_1 \leq \dots \leq V_i \leq V_{i+1} \leq \dots \leq V_n \end{cases} \quad (1)$$

式中， $\mathbf{L}_s^{V_n}$  表示  $t_0$  时刻依据母线电压由低到高排序得到的负荷节点  $n$ 。通过低电压筛选方法，可以得到按照优先级顺序选择的敏感负荷。

#### 2) 耦合电压失稳模式

如图 3-3 所示，在电压失稳模式耦合情况下，电压与功角之间的相互作用变

得非常明显。当系统发生故障并随后排除故障时，母线电压会继续下降，表现出振荡行为，从而导致失稳。电压下降导致某些发电机的功角大幅摆动，造成功率角失稳。在这种耦合状态下，电压失稳和功角失稳相互影响，电压失稳是主要模式，因此被归类为系统级电压失稳。




图 3-3 耦合电压失稳下电压和功角曲线

通过暂态稳定模拟，可以分析负载无功功率随时间变化的情况，从而筛选出两种可能的负荷序列。

第一个负荷序列考虑的是故障发生前后负载无功功率的突然变化。根据无功功率变化的大小从大到小排序，得到候选负荷序列 1：

$$\begin{cases} L_1 = [L_{s1}^{\Delta Q_1}, \dots, L_{s1}^{\Delta Q_i}, L_{s1}^{\Delta Q_{i+1}}, \dots, L_{s1}^{\Delta Q_n}] \\ \text{s.t. } \Delta Q_1 \geq \dots \geq \Delta Q_i \geq \Delta Q_{i+1} \geq \dots \geq \Delta Q_n \end{cases} \quad (2)$$

第二个负荷序列考虑了故障持续时间内负载的无功功率大小。根据无功功率大小按从大到小排序，得到候选负荷序列 2：

$$\begin{cases} L_2 = [L_{s2}^{Q_1}, \dots, L_{s2}^{Q_i}, L_{s2}^{Q_{i+1}}, \dots, L_{s2}^{Q_n}] \\ \text{s.t. } Q_1 \geq \dots \geq Q_i \geq Q_{i+1} \geq \dots \geq Q_n \end{cases} \quad (3)$$

由于故障发生后，无法预先知道哪种负荷序列更为有效。只需首次迭代时分别试切相同的负荷量，选取灵敏度大的负荷序列，即：

$$L = \max(s(L_1), s(L_2)) \quad (4)$$

### 3) 混合电压失稳模式

在图 3-4 所示的混合电压失稳模式下，电压和功角会发生复杂的变化。尽管系统故障已经切除，但某些母线电压可能会持续下降并表现出振荡行为，最终导致不稳定。另一些则保持低水平。随着母线电压下降，发电机功角逐渐偏离，导致功角失稳。两种电压失稳形式交织在一起，形成系统级的电压失稳。




图 3-4 混合电压失稳下电压和功角曲线

首先，利用前述为解决耦合电压失稳定而设计的方法，确定系统中最敏感的负载序列，并根据这些负荷的重要性和对系统稳定性的影响，按照优先级顺序依次进行负荷切除。在每次切除负荷后，都会实时监测电压失稳的表现，以评估切负荷的效果。当切除的负荷达到一定量级时，送端方向的无功功率支持变得足够强大。此时，电压失稳的性质将从耦合失稳转变为纯电压失稳。接着按照处理纯电压失稳的方式进行操作，使得系统电压重新回到可接受范围。

### 3.1.3 第二阶段-确定控制措施量

本案例中，将仿真数据输入 LightGBM 从而决策总切负荷量，提高决策效率。随后基于前述优先级设置为各负荷分配切负荷决策量。结合暂态稳定仿真校验控制措施，并调整决策量以确保稳定性。

LightGBM 算法输入数据为故障后观察窗口内的暂态稳定仿真时序数据输出为系统初始切负荷总量。这种方法直接拟合输入和输出之间的关系，能够更快、更精确地确定在瞬态电压失稳不稳定期间所需的初始切负荷量。与传统方法不同，该模型不仅提高了计算效率，还缩短了决策过程。因此，它为维持电力系统的稳定提供了更可靠的保证。

电压不稳定性和功角失稳通常是相互关联的，因此两者都被用作模型的输入特征。输入特征包括从观测窗口内的功角和电压值，将其按照时间序列对应拼接。并将其转换为一维向量，以便使用 LightGBM 进行处理。这样做能够更好地捕捉电压和功角之间的耦合关系，提高模型的预测准确性。

$$\mathbf{f} = [U_{1,1}, U_{1,2} \cdots U_{1,B} \cdots U_{T,1}, U_{T,2} \cdots U_{T,B}, \delta_{1,1}, \delta_{1,2} \cdots \delta_{1,M} \cdots \delta_{T,1}, \delta_{T,2} \cdots \delta_{T,M}] \quad (5)$$

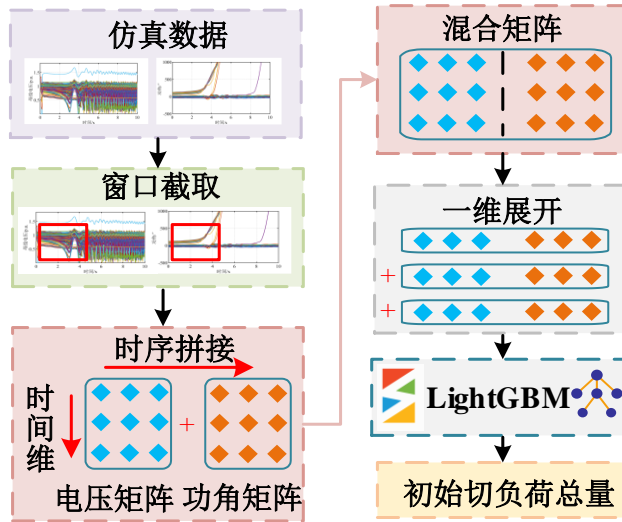


图 3-5 LightGBM 预估初始决策总量框架

式中， $f$  为输入模型的一维向量； $U_{i,j}$  ( $i=1, 2, \dots, T$ ,  $j=1, 2, \dots, B$ ) 表示  $i$  时刻  $j$  号母线的电压； $\delta_{i,k}$  ( $i=1, 2, \dots, T$ ,  $k=1, 2, \dots, M$ ) 表示  $i$  时刻第  $k$  台发电机的功角值。 $T$  为观察窗口的采样点数， $B$  为系统母线总数， $M$  为系统发电机总数。根据上文得到融合智能算法的电力系统两阶段切负荷流程图如图 3-6 所示。

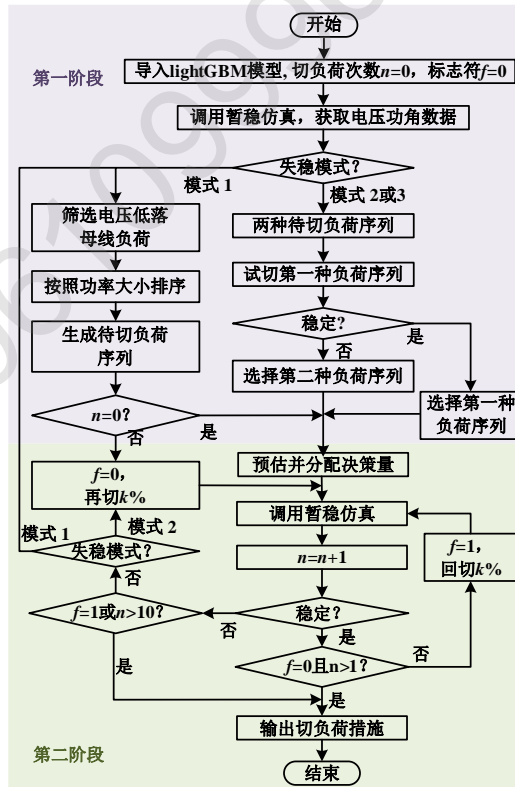


图 3-6 融合智能算法的两阶段切负荷流程图

### 3.1.4 测试与分析

为了检验所提方法在制定决策的快速性、决策结果的有效性以及切负荷准确

性方面的优势，采用我国东北电网模型进行算例分析。采用 PSASP 软件进行暂态仿真，基于 Pytorch 搭建 LightGBM 模型的训练框架。

### 1) 切负荷节点选择的有效性验证

本节比较了综合筛选法和两种识别电压失稳现象的特定方法。第一种方法根据故障发生后 0.5 秒内的电压幅值将负载从低到高排列。第二种方法根据故障前后负载电导的变化将负载从高到低排列。

比较设置 1：图 3-7 展示了所有电压失稳样本中不同筛选方法的总体比较结果。结果表明，本文所提方法的总体有效率为 97.5%。平均而言，该方法需要 10.33 次迭代，耗时 299.95 秒，削减负荷 1003.93 兆瓦。这些结果表明，筛选出的负荷点更加有效和灵敏。




图 3-7 不同负荷筛选方法对比

比较设置 2：根据负载的灵敏度依次削减负载，直至系统稳定。试验削减量设定为 3000 兆瓦，迭代步长为 50%。如果负荷削减量超过 3500 兆瓦，则认为不存在可行的解决方案。表 3-2 列出了各种故障条件下的比较结果，其中斜线表示该方法没有解决方案。从表中可以看出，低电压筛选法和电导变化筛选法在某些条件下（工况 1、2、3 和 4）无法提供可行的解决方案。相比之下，本文提出的方法成功地找到了这些条件下的可行解决方案。此外，在工况 2 和工况 4 中，本文提出的方法所需的切负荷量大大减少。

此外，我们还比较了相同负载切割量下的瞬态电压恢复情况。将不同工作条件下的最终切割负载量与其他筛选方法获得的负载序列进行比较。结果如图 3-8 所示，电压振荡表示没有可行的解决方案。图中显示，本文提出的方法在所有工作条件下都能获得可行的解决方案，且负载削减量相同。相比之下，低电压筛选法和基于低电压筛选的电导变化筛选法只能解决部分工况。

表 3-2 不同工况决策切负荷量大小对比

工况	失稳模式	切负荷量 (MW)		
		低电压筛选	导纳变化筛选	所提方法
1	耦合失稳	/	730.5	819.2
2	耦合失稳	1923.2	/	1821.1
3	混合失稳	778.0	/	405.4




图 3-8 不同筛选方法不同故障工况下对比图

## (2) 利用 LightGBM 预估决策量方法的有效性验证

在 1762 个有解的样本中, 将 70%用于模型训练, 剩余 30%用于测试。在训练集进行模型的训练后, 在测试集进行测试。比较 LightGBM 的预估方法与卷积神经网络(Convolutional Neural Network, CNN)和随机森林(Random Forest, RF)的预估效果。定义所有样本的平均绝对偏差(Mean Absolute Deviation, MAD)和平均相对偏差(Mean Relative Deviation, MRD)。

$$MAD = \frac{1}{N_t} \sum_{i=1}^{N_t} |y_i^{\text{real}} - y_i^{\text{predicted}}| \quad (6)$$

$$MRD = \frac{1}{N_t} \sum_{i=1}^{N_t} |y_i^{\text{real}} - y_i^{\text{predicted}}| / y_i^{\text{real}} \quad (7)$$



图 3-9 所示为对比结果。可以发现，所采用算法的预测精度相较于 CNN 和 RF 更高，其平均绝对偏差(MAD)为 21.75MW，平均相对偏差(MRD)为 3.19%。此外，LightGBM 的预测速度也更快，训练时间为 611.80 秒。




图 3-9 不同切负荷总量预估方法比较

### (3) 两阶段切负荷方法决策效果检测

首先，根据模拟数据确定有效的切负荷点。随后，采用 LightGBM 算法确定更精确的切负荷量，然后根据优先级将其分配到相应的负荷点。最后，结合暂态仿真进行微调，以确定最终的削减负载量。对 519 个测试样本进行了遍历模拟，并与传统的循环迭代试错法进行了比较。结果见表 3-3。

表 3-3 两阶段决策方法与循环迭代方法对比

算法	平均迭代次数	平均耗时(s)	平均切负荷量 (MW)
循环迭代	9.43	278.34	909.69
两阶段决策	4.58	189.03	863.83

如表 3-3 所示，估计决策量提供了迭代的初始值，大大减少了平均迭代次数和平均耗时。这种改进使决策过程更加高效和快速。此外，根据预估的决策量进行微调，可最大限度地减少不必要的负载过度切除，从而获得更准确的决策结果。。

### 3.2 技术二：并行分支网络决策快速性提升技术

针对人工决策耗时耗力，且现有人工智能技术中神经网络的输出层极大影响决策复杂度的问题，本研究通过数据驱动的方法，提出了一种基于深度强化学习（DRL）的智能紧急切机决策算法。首先，我们详细解释了分支竞争 Q 学习算法的核心原理，并建立了智能紧急切机决策的综合框架。针对可控发电机产生的指数决策空间问题，我们介绍了两种新颖的求解策略。此外，我们还研究了行动与决策之间的两种转换关系，从而为智能系统开发出四种独特的决策结构。最后，我们在 10 机 39 节点系统上对这些智能配置进行了严格测试。结果表明，该算法对紧急切割决策非常有效。

### 3.2.1 分支竞争 Q 学习算法

图 3-10 所示的分支竞争 Q 网络 (BDQ) 是双重竞争 Q 网络的多分支变体。它专为处理多维行动空间而设计。

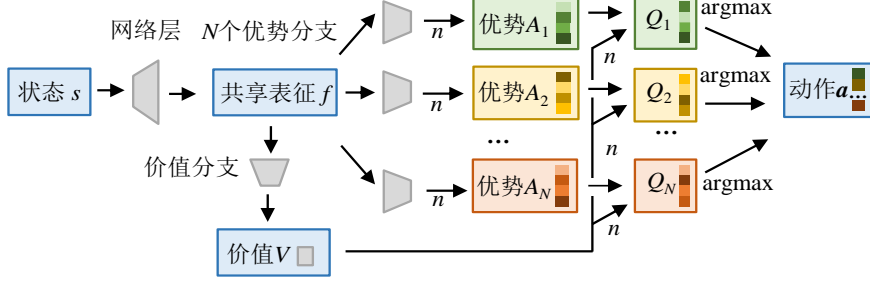


图 3-10 分支竞争 Q 网络的结构

在 BDQ 网络中，输入  $s$  通过深度神经网络层进行处理，以创建共享表征  $f$ ，然后价值分支将这  $f$  映射到输出价值  $V(s)$ 。对于一个动作的每个组成部分，输出都是由一个主导分支输入决定的，与分支动作及其维度空间相对应。每个分支的行动状态值函数的推导过程与竞争 Q 网络类似。

$$Q_d(s, a; \theta) = V(s) + \left[ A_d(s, a_d) - \frac{1}{|A_d|} \sum_{a'_d \in A_d} A_d(s, a'_d) \right] \quad (8)$$

在更新 Q 网络时，每个分支的目标 Q 值  $Y_d$  的计算方法与双重 Q 网络的计算方法相同，即：

$$Y_d = r + \gamma Q_d(s', \arg \max_{a'_d \in A_d} Q_d(s', a'_d; \theta); \theta^-) \quad (9)$$

对于 BDQ 算法，其损失函数一般定义为所有分支 Q 值和目标 Q 值间的均方误差，即：

$$L = \mathbb{E}_{(s, a, r, s') \sim D} \left[ \frac{1}{N} \sum_d (Y_d - Q_d(s, a_d; \theta))^2 \right] \quad (10)$$

如下表3-4所示，将智能决策算法的神经网络复杂度进行对比，并针对单分支的双Q学习智能体每次只能决策单个控制对象的问题，采取多分支竞争Q网络，每次同时决策多个控制对象的多个动作，融入增量式决策经验知识，关联前后控制措施，训练效率进一步提升163.5%。进一步采用基于样本的并行强化学习算法，训练效率提高12倍。

### 3.2.2 智能紧急控制决策制定

#### 1) 智能紧急控制决策框架

如图 3-11 所示，基于 DQN 系列算法的智能紧急切机决策通用框架分为两个主要部分。左侧是需要做出紧急切机决策的电力系统环境。右侧是利用 DQN



系列算法的 DRL 智能体。这两个组件之间的接口包括一个处理输入特征的特征到状态转换功能（ $f \rightarrow s$ ），以及一个将所选动作转换为实际切换决策的动作到决策转换功能（ $u \leftarrow a$ ）。

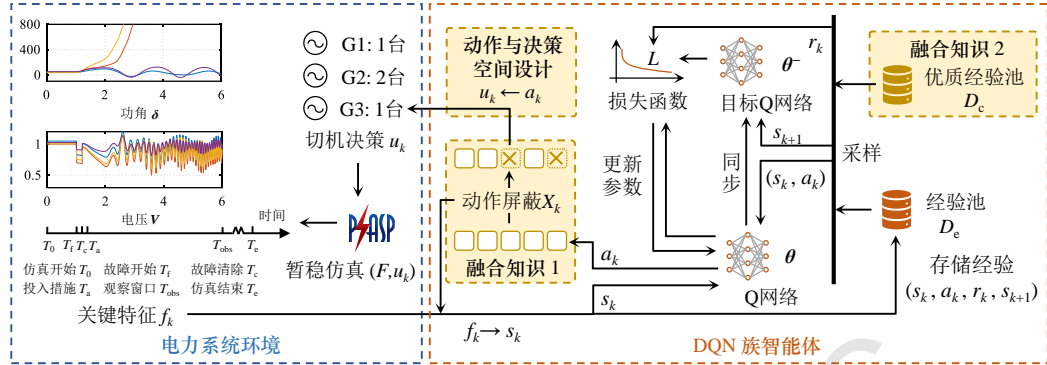


图 3-11 基于知识融合 DRL 的电力系统智能紧急切机决策框架

## 2) 动作与决策空间设计

DRL 算法生成的动作必须转化为切机决策,才能在电力系统环境中有效发挥作用。因此,设计动作和决策空间至关重要。这涉及两个关键方面:第一,当智能体就多个可控发电机节点做出决策时,处理多维决策空间;第二,定义数学转化关系,将智能体的行动转化为环境中的可执行决策。

多维决策空间的处理方法有两种:一种是将其转化为线性决策空间,另一种是使用 BDQ 网络。

方法 1: 线性决策空间。决策空间设计如下图 3-12 所示,本节为减载控制设计了线性决策空间。基于事件的减载(ELS)的作用空间随负荷个数线性增加。有效减小了动作空间的大小。神经网络的输出选择与负荷的动作选择之间仍然存在一一对应的关系。负荷的动作选择可以用一个简单的转换来表示。




图 3-12 线性决策空间与指数决策空间的对比

如图 3-12 所示,决策过程中智能体基于前一步决策只选择一个节点进行调整,其他节点的决策保持不变。因此,决策空间的大小与节点数量成正比。

下式展示了决策过程中第  $t+1$  步的决策：

$$\begin{cases} u_{0(i)} \leftarrow 0, i \in \{0, 1, \dots, n_G\} \\ u_{t+1} \leftarrow u_t, u_{t+1(i_{t+1})} \leftarrow v_{t+1(i_{t+1})} \end{cases} \quad (11)$$

该决策方法通过动作空间的转换使智能体训练难度降低，实际上在智能体决策尝试次数上进行了一定妥协。

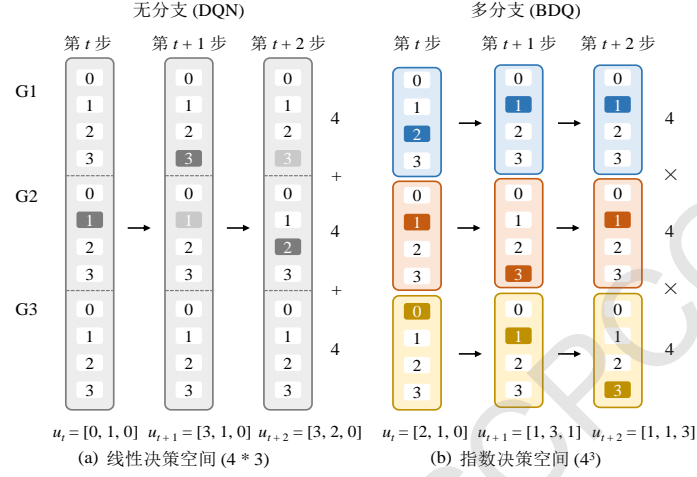


图 3-13 线性决策空间与指数决策空间的对比

方法 2: BDQ 网络。BDQ 决策空间如图 3-13 (b)所示，利用分支竞争 Q 网络 (BDQ) 可以有效地解决指数决策空间问题。理想情况下，这种智能体经过训练后，只需一步就能针对所有预期故障条件做出有效决策。。决策  $u_t$  可表示为，

$$\begin{cases} x_{t(i)} = \pi^\varepsilon(s_t, a_t, \varepsilon_t) \\ u_t = [u_{t(1)}, u_{t(2)}, \dots, u_{t(n_G)}] \\ u_{t(i)} = v_{t(i)} = x_{t(i)} - 1, i \in \{1, \dots, n_G\} \end{cases} \quad (12)$$

其中  $a_{t(i)}$  为第  $t$  步第  $i$  个子动作神经网络的输出。

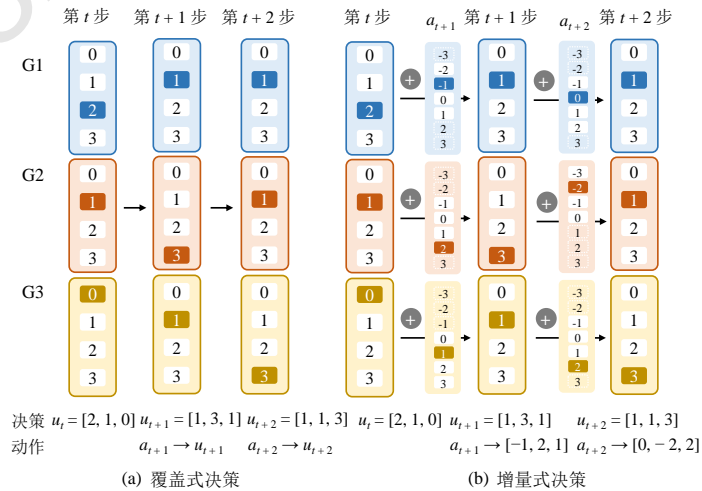


图 3-14 覆盖式与增量式决策

动作-决策转换关系：基于动作和决策之间的转换关系，存在覆盖式决策和增量式决策两种不同的决策方式。图 3-14 为采用覆盖式决策方式时决策结构和采用增量式决策时决策结构的对比。通过基于 **BDQ** 的决策方法对两种决策结构进行说明。决策发电机序号  $x_{t+1}$  由动作  $a_{t+1}$  转换而来，他们之间的关系可以由下式表示：

$$\begin{cases} x_{t+1(i)} = \pi^\varepsilon(s_{t+1}, a_{t+1(i)}, \varepsilon_{t+1}) \\ v_{t+1(i)} = x_{t+1(i)} - n_{Gi} - 1 \\ u_{t+1(i)} = u_{t(i)} + v_{t+1(i)} \end{cases}, 1 \leq i \leq n_G \quad (13)$$

引入动作屏蔽可得序号  $x_{t+1(i)}$ :

$$x_{t+1(i)} = \begin{cases} \arg \max_x Q(s_{t+1}, a_{t+1(i)}^x), & 1 - \varepsilon_{t+1} \text{ 的概率} \\ x_{\text{random}} & \varepsilon_{t+1} \text{ 的概率} \end{cases} \quad (i \in \{1, 2, \dots, n_G\}, x_{t+1(i)} \notin X_{t+1(i)}) \quad (14)$$

为了防止智能体做出不切实际的决策，可以在强化学习过程中引入行动掩码。这可以避免代理做出不切实际的决策。因此，在采用增量决策结构时，必须将掩码集  $\mathbf{X}_{t+1}$  作为状态的一部分输入给代理。增量决策下的状态  $s$  可表示如下：

$$s_t = (V_t, \phi(\mathcal{D}_t), X_t) \quad (15)$$

### 3) 基于知识经验引导的探索策略

案例的一种知识融合策略是利用知识经验让智能体随机决策时在有限范围内进行尝试。如图 3-15 所示,对随机决策方式进行一定的限制,每次只从功角摆飞切机节点集合  $I_{t+1}^u$  中随机选择一个节点  $i_{t+1}^s$  来切机,然后随机确定切除发电机的数量。相对应的每个屏蔽子集可以表示为:

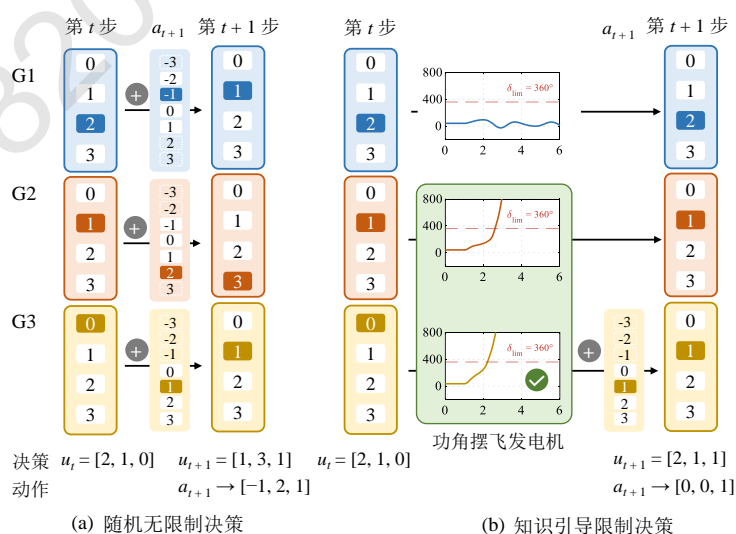


图 3-15 随机无限制决策与知识引导限制决策的对比

$$I_{t+1}^u = \{i \mid S(\delta_i^{t+1}) = 1, i = 1, 2, \dots, n_G\} \quad (16)$$

$$X_{t+1(i)} = \begin{cases} \{x_{t+1(i)} \mid x_{t+1(i)} < -u_{t(i)} + n_{Gi} + 1 \text{ 或 } x_{t+1(i)} > -u_{t(i)} + 2n_{Gi} + 1\}, i = i_{t+1}^s \\ \{x_{t+1(i)} \mid x_{t+1(i)} \neq n_{Gi}\}, i \neq i_{t+1}^s \end{cases} \quad (17)$$

本案例利用已有的知识和经验，确保智能代理在有限的范围内做出随机决策。此方法不仅限制探索空间，还提高决策效率和准确性，使其更快找到最优解。由此得到更优决策性能。

#### 4) 多样本源混合采样的训练策略

本案例的另一种智能紧急切机决策融合知识的策略是利用专家制定的高质量决策来训练智能体。通过这种方法，智能体可以学习到优质决策的特点，从而显著提升其决策性能。

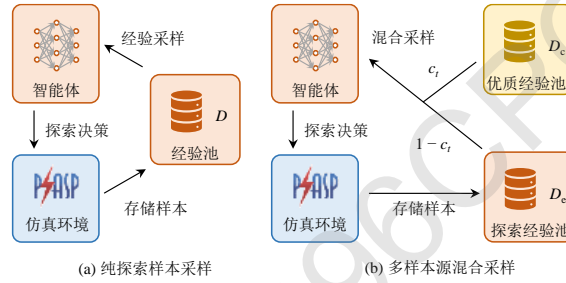


图 3-16 纯探索样本采样与多样本源混合采样的对比

图 3-16 (b)中，为提升智能体的性能尝试采用两个样本源混合训练，第一个样本是纯探索的经验池  $D_e$ ，其中包含智能体在探索过程中积累的经验数据，另一个样本池称为优质经验池  $D_c$ ，包含高质量的决策数据，这些数据可以由专家手动制定，也可以通过优化算法生成。为了充分利用这两种样本来源，在每次混合取样过程中，都会从纯探索经验池  $D_e$  和优质经验池  $D_c$  中抽取一部分样本，然后合并成一批规模为  $B$  的样本。这种多样本源混合采样策略能够帮助智能体在训练过程中既保持探索的多样性，又能够借鉴优质决策的特点，从而提升整体性能。

#### 5) 并行强化学习的紧急控制决策

如图 3-17 所示，本案例基于并行强化学习方法对前面章节提出的智能紧急切机决策智能体进行训练加速，采用的结构与 Ape-X 算法类似。算法整体框架由评估器阵列、执行器阵列、样本处理器阵列和学习器构成。执行器阵列负责在环境中执行动作并收集相应的数据，评估器阵列对执行器的表现进行评估，样本处理器阵列负责处理和整理收集到的数据，而学习器则利用这些数据进行模型更新。通过这种并行化的训练方法，智能体能够更快地学习和优化其决策策略，从而在紧急切机场景中表现得更加高效和可靠。



这表明增量式 BDQ 结构在管理复杂决策问题方面更加高效和有效，能更好地适应动态变化的环境，从而提高智能体的决策能力。




图 3-19 四种 DQN 算法的决策性能比较

### 3) 并行计算加速训练的验证

本节为验证并行算法加速的可行性，分别采用串行与并行方法，结合知识经验引导探索和多源数据混合采样两种方法，使用增量式 BDQ 框架进行训练。训练结果如图 3-20 所示。




图 3-20 并行方式训练智能体决策性能对比

通过比较串行训练法和并行训练法的测试结果，可以发现它们的最终收敛性能非常相似，串行训练法在性能上略胜一筹。不过，就训练速度而言，并行强化学习大大加快了进程。具体来说，串行训练法需要大约 8 个小时才能达到收敛，而并行训练法将这一时间缩短到了大约 3 个小时。这表明，尽管两种方法在最终性能上相近，但并行训练显著提高了训练效率，使得智能体能够更快速地达到收敛状态，从而节省了大量时间和计算资源。

## 3.3 技术三：轻依赖新标注的差异化电网迁移技术

为充分利用源域样本信息，降低对差异化电网标注样本的要求，本项目提出一种将主动学习和迁移学习结合的双向主动迁移学习 (bidirectional active transfer



learning, Bi-ATL) 框架。该框架可以用较少的新标注样本将基于 DL 的电力系统稳定性评估 (power system stability assessment, PSSA) 模型从原始运行方式 (源域) 迁移到未学习的新运行方式 (目标域)。基于双向主动学习 (bidirectional active learning, Bi-AL), 形成了一个综合源域和目标域样本中有用信息的混合样本集。然后, 基于混合样本集, 采用微调方法对源域模型进行微调, 利用源域模型中的信息, 使现有的源域模型适应目标域。通过整合 Bi-AL 和迁移学习, 源域数据、源域模型和目标域数据的三方知识得到了充分的利用。

### 3.3.1 双向主动迁移学习框架

针对人工方法在差异化电网需从头开始决策, 依赖专家经验、耗时耗力的问题, 所提出的轻依赖新标注的差异化电网迁移技术只需10%新样本标注, 即可达到迁移前准确率, 解决模型不适用变化场景的难题, 保证系统在差异化电网中的适应性。所提方法框架如下:

1) 为了进一步减少将深度学习模型迁移到未学习的运行方式时所需的标注样本的数量, 将Bi-AL方法与fine-tune联合, 形成Bi-ATL框架。与单独的fine-tune不同, 所提出的框架充分利用了所有可用的资源, 包括源域模型、已标注的源域样本和少数待标注的目标域样本, 其标签是通过主动向专家询问人类获得的。Bi-ATL方法的总体框架如图3-21中所示。

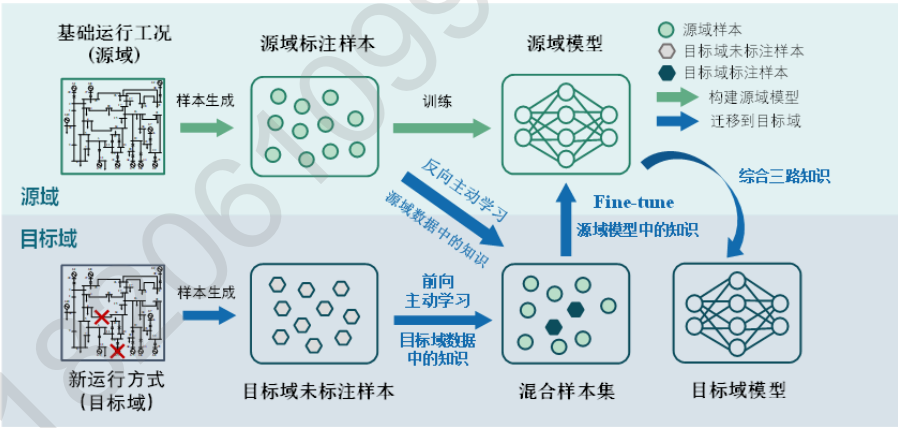


图 3-21 所提双向主动迁移学习框架

#### 2) 双向主动学习：利用源域和目标域样本中的信息

传统主动学习为单向主动学习, 只能主动选择目标域样本而忽略了源域样本。而双向主动学习包含前向主动学习和反向主动学习, 能综合源域和目标域的信息。

前向主动学习: 利用目标域样本的信息, 也称为query(+), 是标准的主动学习方法, 其目的是基于不确定性采样方法, 从目标域无标注样本池中选择一批的最具信息含量的样本, 可以通过边际概率抽样或信息熵抽样来实现:

$$\begin{aligned}
x_{\text{margin}}^+ &= \arg \min_{x \in \mathcal{U} \subseteq \mathcal{D}_T} \text{margin}(x) \\
&= \arg \min_{x \in \mathcal{U} \subseteq \mathcal{D}_T} P_{M_{\theta_t}}(\hat{y}_1 | x) - P_{M_{\theta_t}}(\hat{y}_2 | x)
\end{aligned} \tag{18}$$

式中  $\mathbb{P}_{\mathcal{M}_{\theta_t}}(\hat{y}_1 | x)$  和  $\mathbb{P}_{\mathcal{M}_{\theta_t}}(\hat{y}_2 | x)$  分别为模型  $\mathcal{M}_{\theta_t}$  预测概率值中最可能和第二可能的类别的概率。具有较小边际概率的样本被认为具有较高的信息含量。信息熵采样为：

$$\begin{aligned}
x_{\text{entropy}}^+ &= \arg \max_{x \in \mathcal{U} \subseteq \mathcal{D}_T} \text{entropy}(x) \\
&= \arg \max_{x \in \mathcal{U} \subseteq \mathcal{D}_T} \sum_i P_{M_{\theta_t}}(\hat{y}_i | x) \log P_{M_{\theta_t}}(\hat{y}_1 | x)
\end{aligned} \tag{19}$$

其中  $y_i$  遍历各类别。高信息熵的样本被认为具有较高的信息含量。

前向主动学习重复  $B^+$  次，并通过专家标注主导失稳模式后形成目标域标注样本集  $\{(\mathcal{X}_t^+, \mathcal{Y}_t^+)\} = \{(x_i, y_i) | (x_i, y_i) \in \mathcal{D}_T, x_i \in \mathcal{X}_t^+\}$ 。

反向主动学习：利用源域样本信息。的启发式方法是，如果目标域模型对源域样本的判断与源域模型对其的判断不同，则源域样本不能适应目标域。因此，后向主动学习会移除使后验概率变化最大化的源域样本。具体的采样函数设计如下：

$$x^- = \arg \max_{x \in \mathcal{D}_S} \|P_{M_{\theta_t}}(y | x) - P_{M_{\theta_0}}(y | x)\|_1 \tag{20}$$

式中  $\mathbb{P}_{\mathcal{M}_{\theta_t}}(\mathbf{y} | x)$  和  $\mathbb{P}_{\mathcal{M}_{\theta_0}}(\mathbf{y} | x)$  分别为  $\mathcal{M}_{\theta_t}$  和  $\mathcal{M}_{\theta_0}$  预测的不同类别的后验概率向量，L1范数  $\|\cdot\|_1$  目的在于综合后验概率各维度的变化。类似地，反向主动学习重复  $B^-$  次，从而挑选出一批（ $B^-$  个）偏离目标域样本的源域样本，并将其从源域中删除。所删除的源域样本记为

$$\{(\mathcal{X}_t^-, \mathcal{Y}_t^-)\} = \{(x_i, y_i) | (x_i, y_i) \in \mathcal{D}_S, x_i \in \mathcal{X}_t^-\} \tag{21}$$

双向主动学习：前向主动学习和反向主动学习的结合。如图3-22所示，前向主动学习和反向主动学习在Bi-ATL框架中组合，充分利用源域样本和目标域样本中的信息，形成混合样本集，以达到减少目标域标注成本的目的。



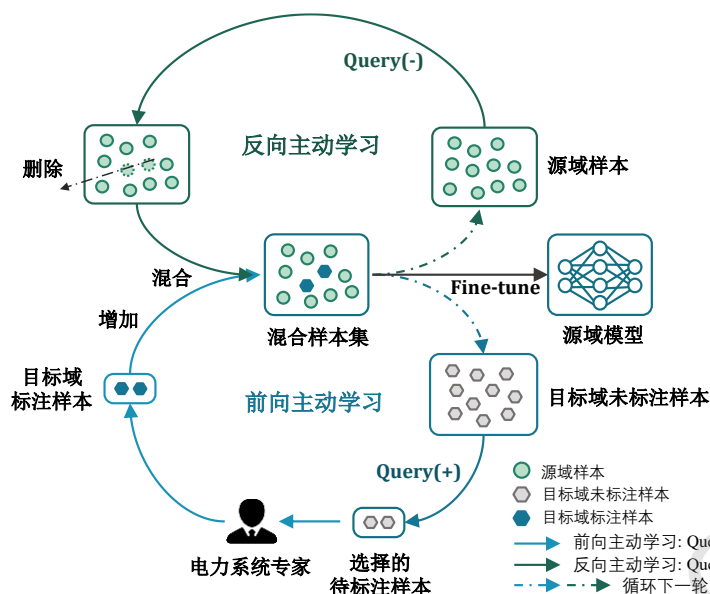


图 3-22 双向主动学习框架

### 3) 迁移学习：利用源域模型中的信息

在样本层面，混合样本集继承了源域的有价值的数据，并引入了目标领域的新数据。然后在模型参数层面，采用fine-tune方法基于混合样本集对源域模型进行微调以利用源模型中的信息。有了三方面的信息，Bi-ATL框架比传统的迁移学习方法更有效，更适用于PSSA场景。

### 3.3.2 测试与分析

选用仿真分析中的我国东北电网模型进行算例分析，验证所提Bi-ATL框架在有效性、准确性和适应性方面的优势以及三路信息：源域样本、源域模型和目标域样本的作用。通过多组对比实验分别验证主动学习效果、双向主动学习和迁移学习效果，结果分别如图3-23和图3-24所示。




图 3-23 单独的正向、反向主动学习和双向主动学习在东北电网中的效果曲线




图 3-24 所提 Bi-ATL 框架和其他设置的迁移学习在东北电网中的效果曲线

结果表明，源域模型、源域样本和少量目标域标注样本都对模型迁移起到了一定的作用，基于模型迁移和基于样本迁移的综合的迁移效果最好。因此，所提Bi-ATL框架在实际大电网中的适应性得到了验证。

## 4. 实施效果

### 4.1 电网智慧决策支持系统功能及应用

#### 4.1.1 系统中各模块功能

1) 数据管理：集中管理潮流、暂稳等仿真数据，生成 AI 训练样本，提供应用数据并保存结果，支持电网地理图可视化。

2) 仿真知识库：收集专家知识，构建知识库，提供知识驱动模型，补充数据驱动模型。

3) 决策模型训练：提供常见模型，利用仿真数据训练 AI 模型，进行数据预处理、模型选择、训练和发布。

4) 模型管理服务：管理训练发布的模型，支持平台训练和自定义模型上传，本文智能切机决策模型可通过此方式上传。

5) 决策模型应用：选择模型执行特定应用，实现不同故障下的紧急控制决策。

6) 决策模型迁移模块：将训练好的模型迁移至新电网状态，结合新样本训练，形成新状态下的决策智能体，实现智慧决策。

### 4.1.2 决策系统实施

本节介绍万节点级电网失稳紧急控制智慧决策支持系统实现智能决策的应用流程及操作结果。

1) 工况及样本导入：首先，用户需要访问数据管理功能模块。在该模块中，用户应上传设想故障集的相关基础数据，包括各种潮流运行工况、预想故障场景。并上传由仿真系统生成的该工况下的失稳样本。

2) 决策智能体训练：点击决策训练按钮，系统将对导入的失稳样本进行训练，直至训练完成。

3) 决策智能体导出与上传：训练好的智能体可导出至本地用于后续决策的直接导入。可导入此前生成的已训练的智能体，用于决策应用。

4) 智慧决策应用：训练所需的样本仅为少量故障情况。选择该工况实际面临的大规模待决策故障集(如图 4-1 所示)，点击指挥决策即将已训练好的智能体遍历待决策故障集。对于每个失稳工况，决策前后的功角、电压信息可在界面显示以直观查看决策效果(如图 4-2 所示)。智慧决策直至所有预想故障决策完成，并可以导出决策表用于实际工程。

5) 决策迁移：点击迁移按钮，可导入已训练好的智能体和新运行工况。完成后导入新工况下的样本集，再次进行模型训练生成新工况下的智能体。在新工况下，智能体导出及智慧决策同上。



图 4-1 万节点级电网智慧决策支持系统故障决策信息



图 4-2 万节点级电网智慧决策支持系统故障决策结果

4.2 系统决策性能

本案例为国内首创运用人工智能实现电力系统的智能决策支持，主要性能超越国内与国际的方法和研究，如表 4-1 所示。以万节点级大电网决策为例：

- 1) 准确率大于 97.5%
- 2) 单次平均耗时<10s
- 3) 差异化电网迁移需新标注样本≤10%

作为同类技术的国内外研究与工程比较，现有智能决策研究尚处于理论阶段，且测试规模均小于百节点级，新加坡南洋理工大学 ERI@N 团队和美国的 PNNL 国家实验室所提先进决策均仅测试于 39 节点系统。万节点电网决策平均耗时 9.52 秒，短于现有工程人工决策方法的 1/6。

表 4-1 决策系统各指标与国际先进技术比较

电网规模	核心技术指标	美国PNNL 国家实验室 <sup>①</sup>	南洋理工大学 ERI@N团队 <sup>②</sup>	华中科技大学 电网智控团队 <sup>③</sup>	结论
百节点级	决策成功率	92.22%	98%	100%	超越
	单次决策时间	130ms	1ms	10ms	部分超越
	迁移所需样本	100%	100%	<10%	超越
万节点级	决策成功率	×	×	>97.5%	突破
	单次决策时间	×	×	<10s	突破
	迁移所需样本	×	×	<10%	突破



## 4.3 工程应用效果

### 4.3.1 万节点系统上线试运行——中国电力科学研究院

中国电力科学研究院是国家电网公司直属科研单位，是中国电力领域最高科研机构。系统于 2022 年 4 月进行产品试用，辅助进行电网方式计算。系统在电力系统研究所上线试运行，至今已连续在线运行超过 12 个月。试运行期间的大量测试结果表明，该系统大幅度降低了仿真分析耗时，在测试中平均可缩短工作耗时 5-6 倍。试运行期间对万节点级的西北电网进行了多运行方式的安全风险分析评估和预想故障离线分析，实现了万节点级大电网的安全风险快速评估和稳控策略智能快速生成，有效提升了电网分析工作效率和效果。如推广应用到全国电网，预计每年可产生增供电效益数亿元，并节约数千万的人力成本，具有很高的经济效益和实用价值。

应用证明	
项目名称	万节点级电网失稳紧急控制智慧决策支持系统
应用单位	中国电力科学研究院有限公司
单位注册地址	北京市海淀区清河小营东路 15 号
应用起止时间	2022 年 4 月至今
具体应用情况： 万节点级电网失稳紧急控制智慧决策支持系统于 2022 年 4 月由我院引进 1 套进行产品试用，辅助进行电网方式计算。系统在电力系统研究所上线试运行，至今已连续在线运行超过 12 个月。试运行期间的大量测试结果表明，该系统大幅度降低了仿真分析耗时，在测试中平均可缩短工作耗时 5-6 倍。试运行期间对万节点级的西北电网进行了多运行方式的安全风险分析评估和预想故障离线分析，实现了万节点级大电网的安全风险快速评估和稳控策略智能快速生成，有效提升了电网分析工作效率和效果。如推广应用到全国电网，预计每年可产生增供电效益数亿元，并节约数千万的人力成本，具有很高的经济效益和实用价值。 特此证明！	
应用单位（盖章）： 2023 年 4 月 10 日	

图 4-3 万节点应用情况及效果说明

### 4.3.2 省域电网应用范例——国网湖北省电力科学研究院

国网湖北电科院是全国最早成立的电力试验研究院(所)之一，是国网湖北省电力有限公司重要的技术支撑力量、科技创新高地。系统于 2022 年 3 月引进国网湖北电科院，用于湖北电网运行方式安排分析并提供辅助决策，至今已连续运行超过 12 个月。试运行期间对湖北电网进行了多运行方式的安全风险分析评估

和预想故障离线预决策,实现了千节点级省级电网的安全风险快速评估和稳控策略智能快速生成,有效避免了电网关键安全风险的错漏,有力保障了电网安全运行,与此同时还大幅提升了电网分析工作效率。

### 4.3.3 助力企业科研攻关——武汉启亦电气有限公司

系统于 2022 年 6 月在武汉启亦公司进行产品试用,辅助完成承接的国家电网公司和南方电网公司的电网仿真分析方面的科研项目。在不同电网方式和预想故障下,该系统可以在分钟级的时间内给出万节点级的大电网的稳控策略方案,大幅度提高了电网专家的工作效率。同时,通过该系统进行辅助智能决策,发现了人工分析未发现的薄弱线路,并可自动生成的电网运行方式,可有效解决电网潜在的运行风险。该系统技术水平高,实用性强,可进一步推广应用。

## 5. 结语部分

本案例创新人工智能技术,并与电网仿真分析有机融合,研发了一套万节点级电网失稳紧急控制智慧决策支持系统,将大规模电网决策制定过程由纯人工制定转变为智能化支持,解决当前易出错、效率低、人力和时间成本高的痛点,适应新型电力系统的发展需求。研制的万节点级电网失稳紧急控制智慧决策支持系统,能够实现万节点级电网智能决策,准确率高于 97.5%,单次平均耗时<10s、差异化电网迁移需新标注样本 $\leq 10\%$ 。系统应用于中国电力科学研究院等多家单位。每年可产生增供电效益数亿元,并节约数千万人力成本,具有极高的经济效益和实用价值。其大幅提升电网分析工作效率,有效避免了电网关键安全风险的错漏,有效解决未来大规模新型电力系统潜在运行风险。

## 参考文献

- [1] 汤涌. 电力系统数字仿真技术的现状与发展. 电力系统自动化, 2002(17): 66-70.
- [2] 戴汉扬, 汤涌, 宋新立, 苏志达, 顾卓远, 项胤兴, 等. 电力系统动态仿真数值积分算法研究综述. 电网技术, 2018, 42(12): 3977-3984
- [3] Y. Tang, Y. Huang, H. Wang, C. Wang, Q. Guo, W. Yao. Framework for artificial intelligence analysis in large-scale power grids. CSEE Journal of Power and Energy Systems, 2018, 4(4), 459-468
- [4] 黄彦浩, 于之虹, 谢昶, 史东宇, 周孝信. 电力大数据技术与电力系统仿真计算结合问题研究. 中国电机工程学报, 2015, 35(01): 13-22
- [5] 汤涌, 姚伟, 王宏志, 王灿, 郭强, 王甜婧, 黄彦浩. 电网仿真分析与决策的

人工智能方法. 中国电机工程学报, 2022, 42(15): 5384-5406

- [6] J. Chai, H. Zeng, A. Li, E. Ngai. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, 2021, 6: 100134.
- [7] A. Bouguettay, H. Zarzour, A. Taberkit, A. Kechida. A review on early wildfire detection from unmanned aerial vehicles using deep learning-based computer vision algorithms. *Signal Processing*, 2022, 190: 108309
- [8] I. Lauriola, A. Lavelli, F. Aiolli. An introduction to deep learning in natural language processing: Models, techniques, and tools. *Neurocomputing*, 2022, 470: 443-456.
- [9] T. Sun, X. Liu, X. Qiu, X. Huang. Paradigm shift in natural language processing. *Machine Intelligence Research*, 2022, 19(3): 169-183
- [10] C. Gao, X. Wang, X. He, Y. Li. Graph neural networks for recommender system. *Proceedings of the Fifteenth ACM International Conference on Web Search and Data Mining*. 2022: 1623-1625
- [11] M. Afsar, T. Crump, B. Far. Reinforcement learning based recommender systems: A survey. *ACM Computing Surveys*, 2022, 55(7): 1-38.
- [12] Y. LeCun, Y. Bengio, G. Hinton. Deep learning. *Nature*, 2015, 521(7553): 436-444.
- [13] I. Goodfellow, Y. Bengio, A. Courville. *Deep learning*. MIT press, 2016
- [14] M. Khodayar, G. Liu, J. Wang, M. Khodayar. Deep learning in power systems research: A review. *CSEE Journal of Power and Energy Systems*, 2020, 7(2): 209-220
- [15] A. Ozcanli, F. Yaprakdal, M. Baysal. Deep learning methods and applications for electrical power systems: A comprehensive review. *International Journal of Energy Research*, 2020, 44(9): 7136-7157
- [16] E. Mocanu, P. Nguyen, M. Gibescu. Deep learning for power system data analysis. *Big data application in power systems*. Elsevier, 2018: 125-158
- [17] Z. Shi, W. Yao, Z. Li, Y. Zhao, R. Zhang, Y. Tang, et al. Artificial intelligence techniques for stability analysis and control in smart grids: Methodologies, applications, challenges and future directions. *Applied Energy*, 2020, 278: 115733
- [18] R. Zhang, Z. Shi, W. Yao, Y. Huang, Y. Tang, J. Wen. Fast Shapelet Learning for Power System Dominant Instability Mode Identification. *2021 International Conference on Power System Technology (POWERCON)*. IEEE, 2021: 2033-2037

- [19]田芳, 黄彦浩, 史东宇, 夏天, 裘微江, 胡晓波, 等. 电力系统仿真分析技术的发展趋势[J]. 中国电机工程学报, 2014, 34(13): 2151-2163
- [20]Huang Q, Huang R, Hao W, et al. Adaptive power system emergency control using deep reinforcement learning[J]. IEEE Transactions on Smart Grid, 2019, 11(2): 1171-1182.
- [21]Cai H, Ma H, Hill D J. A data-based learning and control method for long-term voltage stability[J]. IEEE Transactions on Power Systems, 2020, 35(4): 3203-3212.
- [22]Li Q, Xu Y, Ren C. A hierarchical data-driven method for event-based load shedding against fault-induced delayed voltage recovery in power systems[J]. IEEE Transactions on Industrial Informatics, 2020, 17(1): 699-709.
- [23]胡泽, 曾令康, 姚伟, 等. 电力系统两阶段紧急切负荷控制智能预决策[J]. 中国电机工程学报, 2024, 44(04):1260-1272.
- [24]石重托, 姚伟, 黄彦浩, 等. 基于 SE-CNN 和仿真数据的电力系统主导失稳模式智能识别[J]. 中国电机工程学报, 2022, 42(21):7719-7731.
- [25]李舟平. 数据—知识融合驱动的电力系统智能紧急切机决策及原型系统设计[D]. 华中科技大学, 2022.
- [26]李舟平, 曾令康, 姚伟, 等. 基于知识融合和深度强化学习的智能紧急切机决策[J]. 中国电机工程学报, 2024, 44(05):1675-1688.

---

(1) 本案例授权中国专业学位案例中心使用, 中国专业学位案例中心享有复制权、修改权、发表权、发行权、信息网络传播权、改编权、汇编权和翻译权。

(2) 由于企业保密的要求, 在本案例中对有关名称、数据等做了必要的掩饰性处理。

(3) 本案例只供课堂讨论使用, 并无意暗示或说明某种工程方案(路径)是否有效。