

基于专家知识与多尺度深度学习的无线网络KPI预测方法

张旭，谭小兵，侯妤欣，徐陆骏，田溪，刘子豪，周长华，罗今朝，陈佳，左金虎、
温明媚、王远欢

复旦大学，中国移动集团数智化部

主办单位：中国计算机学会（CCF）

承办单位：中国计算机学会互联网专委会、中国科学院计算机网络信息中心、中国移动研究院、清华大学

协办单位：华为2012实验室、阿里云、中兴通讯、中国移动九天团队、南开大学、西安电子科技大学、清华大学计算机科学与技术系、神州灵云

目录 CONTENTS

第一章节 背景与挑战

第二章节 总体设计

第三章节 数据处理

第四章节 统一架构：基于多尺度深度学习与专家知识的无线网络KPI预测模型

第五章节 实验展示


总结与展望

第一章节

背景与挑战

背景与挑战

- 人们使用无线网络需求增大，但每个基站、小区能承载的用户、数据流量是有限的，过载则会出现卡顿、掉线等情况，影响用户体验，阻碍业务发展。
- 包含2w6+小区，每个近2k时间点，70+特征的庞大无线网络序列数据，包含 KPI 性能指标、工程参数、MR 指标等。



海量数据



如何数据处理？



如何训练模型？

围绕无线网络的容量规划场景的任务目标：

1. 时序预测：无附加条件的设计算法预测出网络状态的
未来走势，运维工程师结合自己的经验调整网络。
2. 因果时序预测：基于网络功率参数这一条件，预测
对应的网络状态未来走势。



探索数据

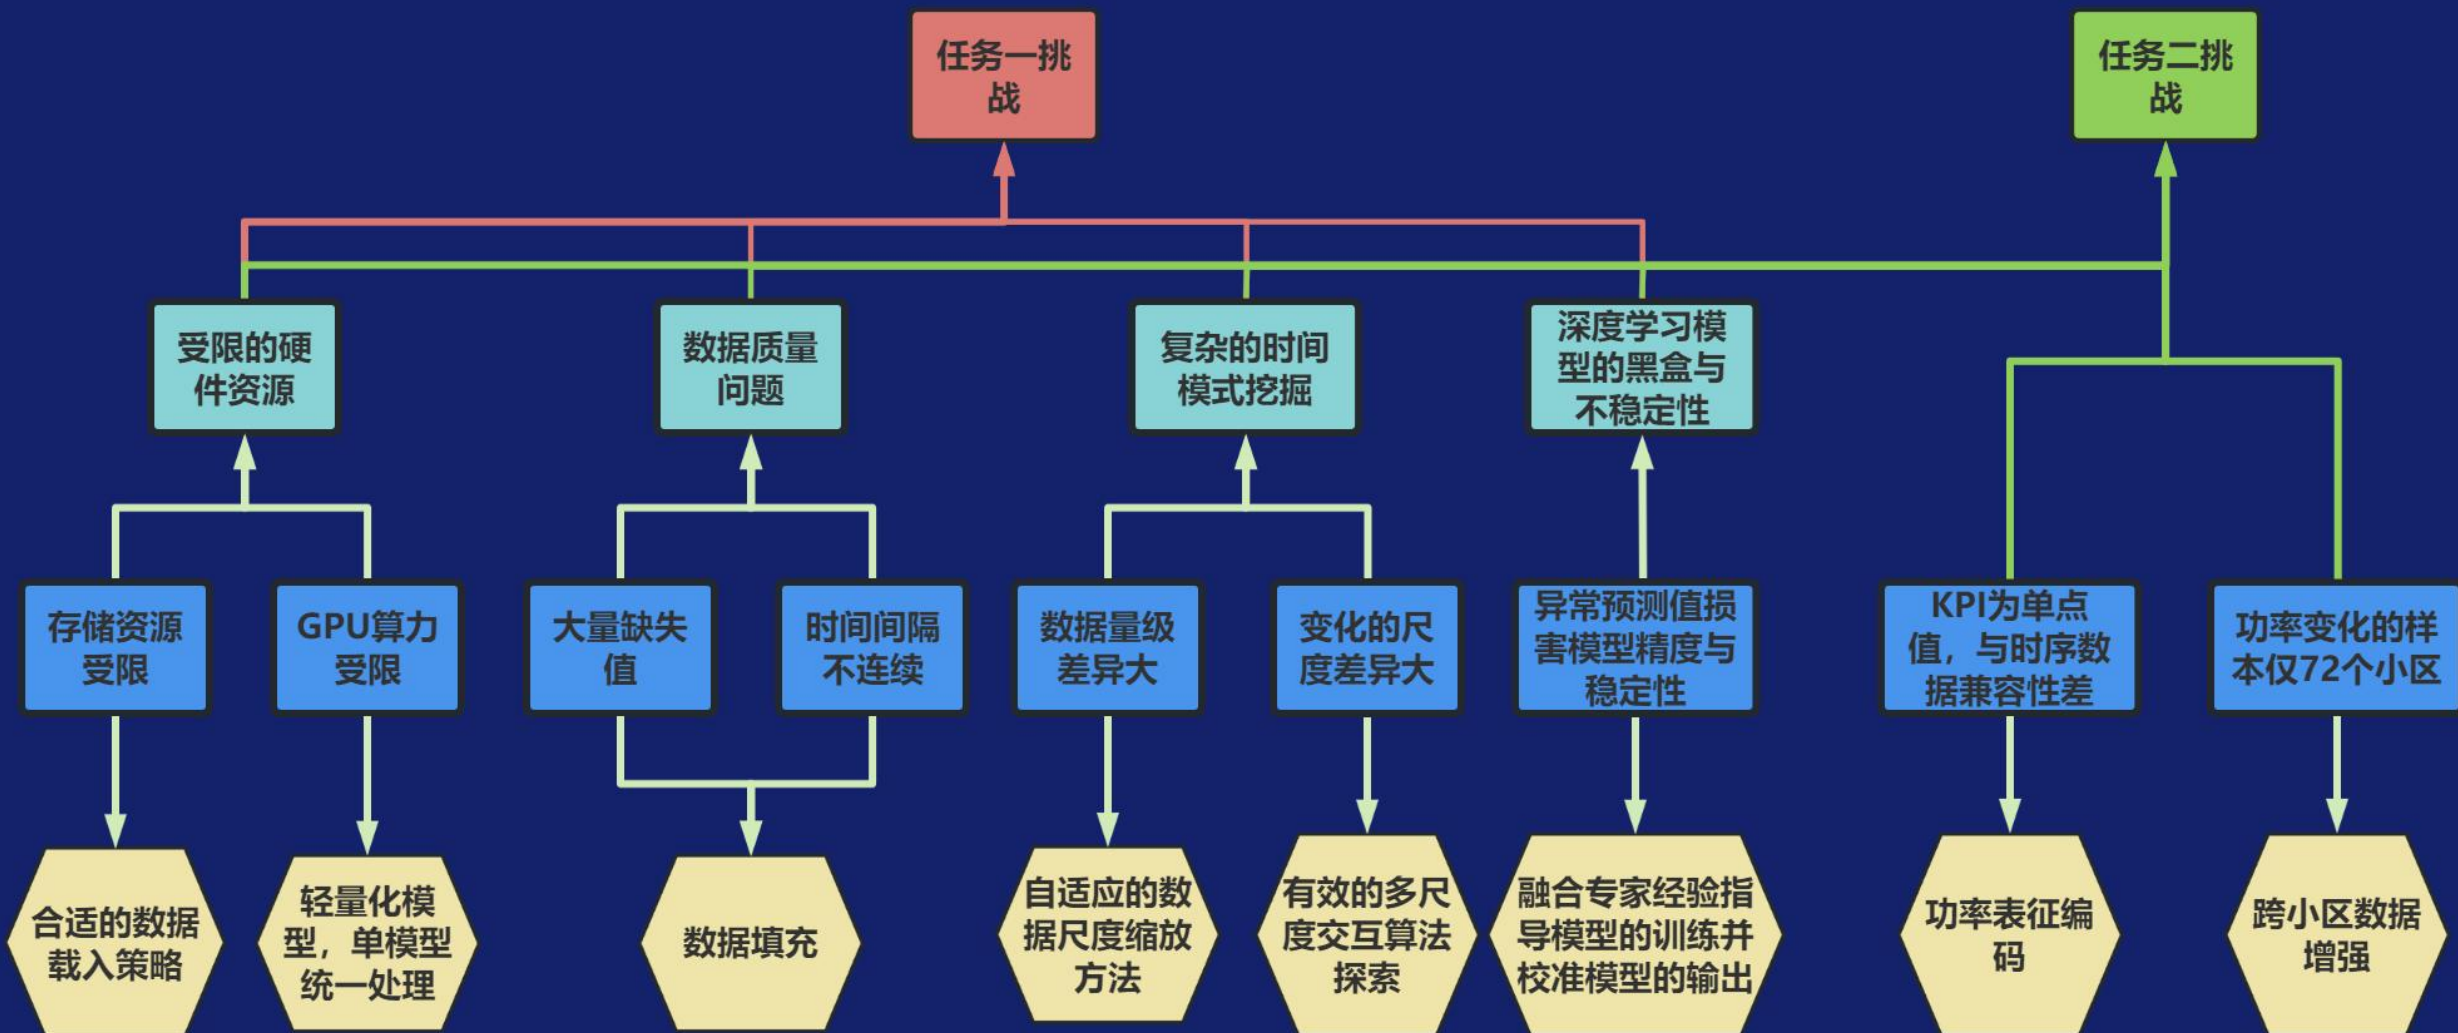


挖掘与利用规则



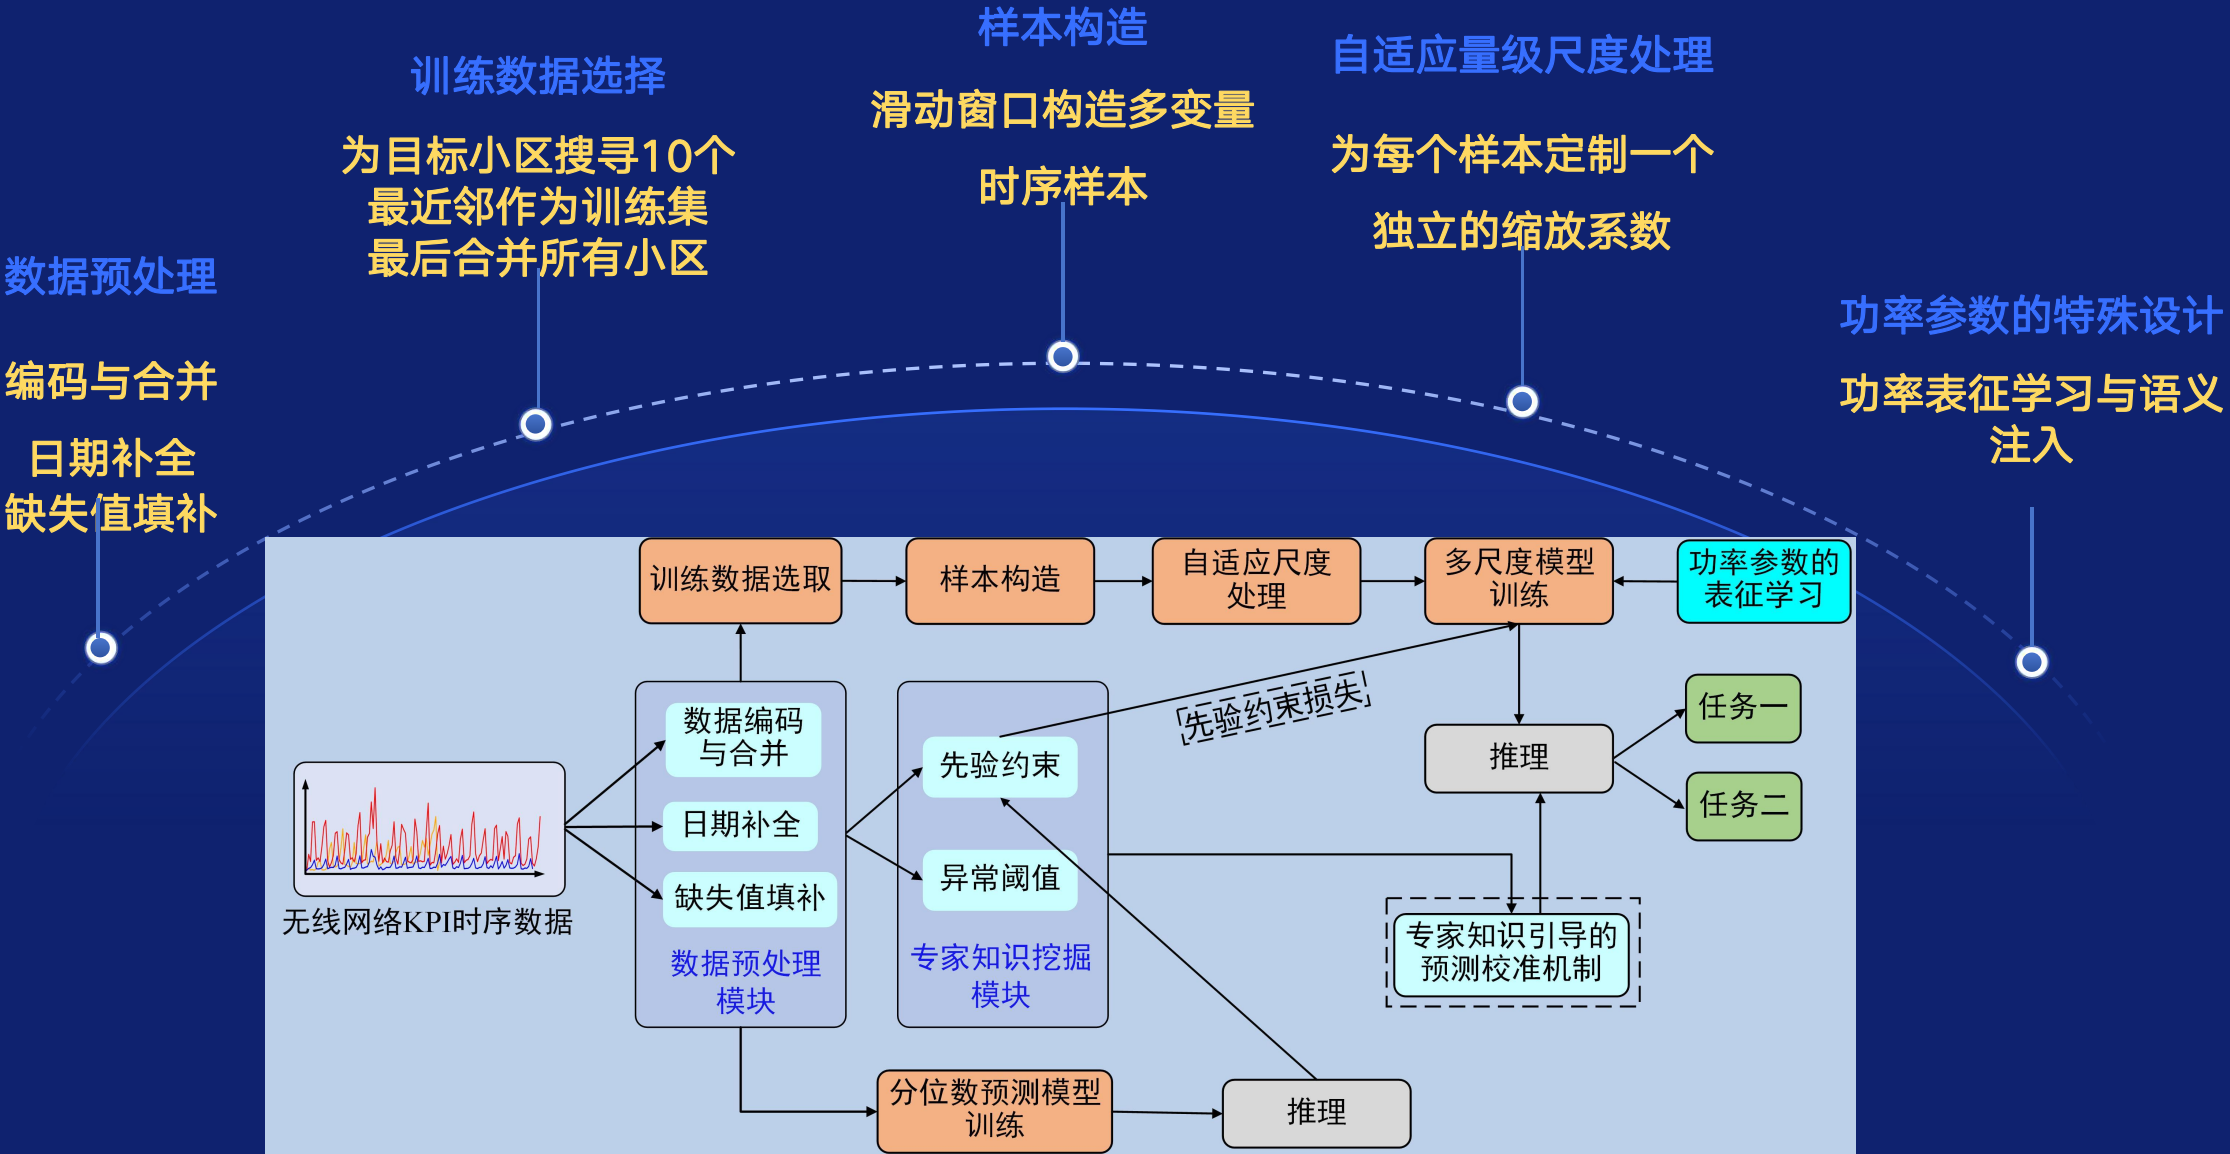
针对性训练方法

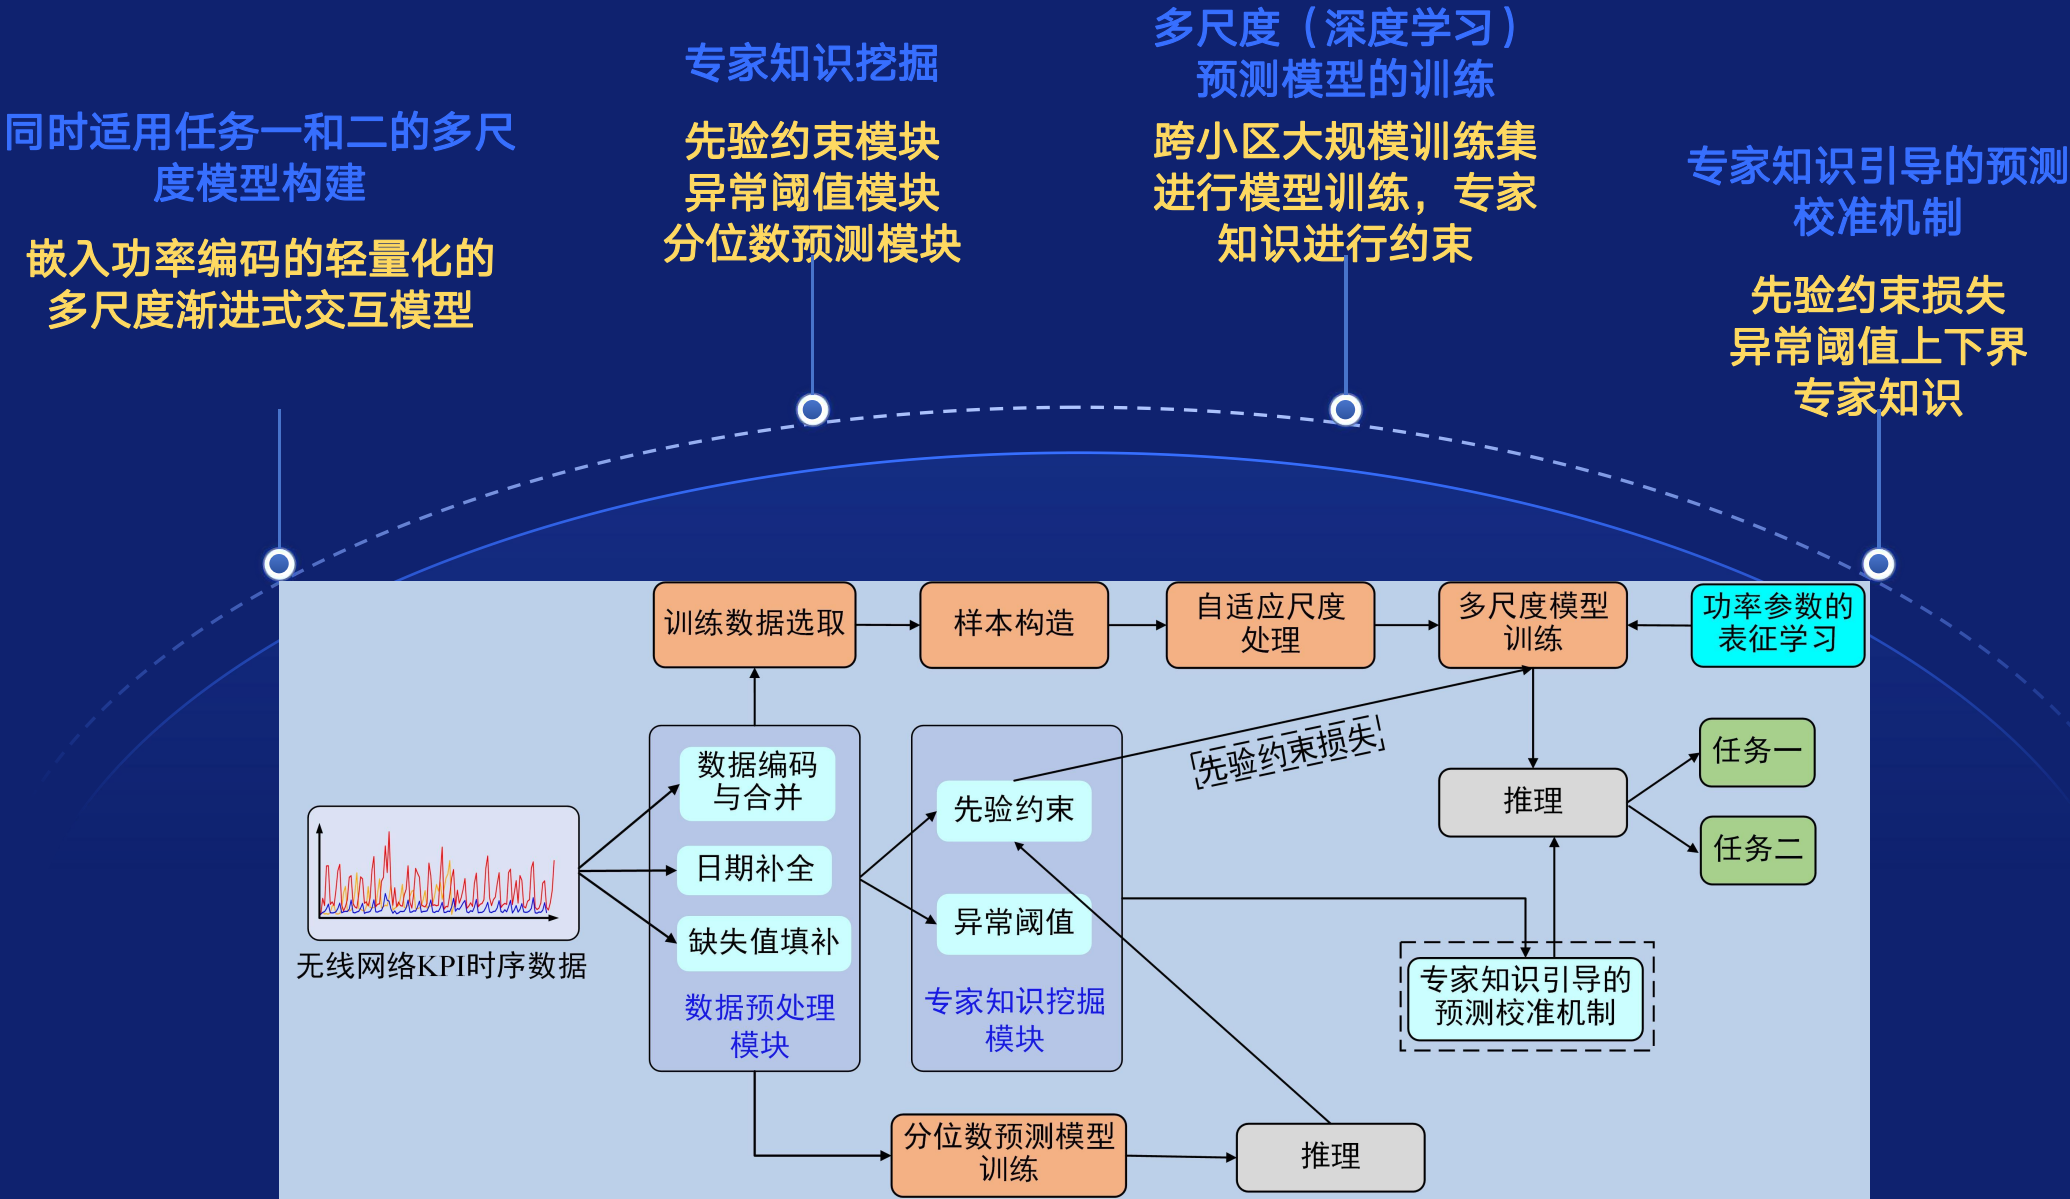




第二章节

总体设计





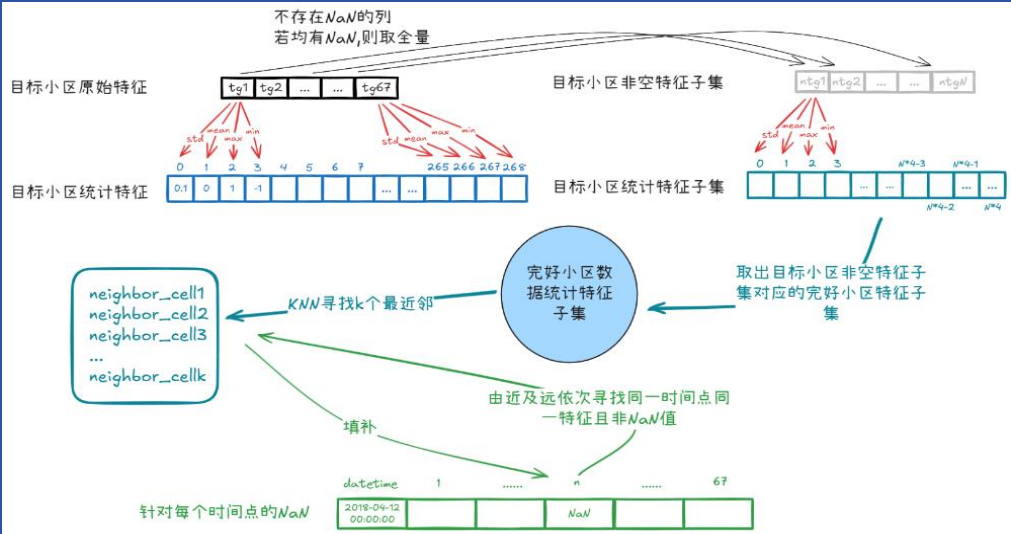
第三章节

数据处理




2018-04-23 07:45:00	2018-04-23 10:45:00	2018-04-23 09:45:00	2018-04-23 10:45:00
2018-04-23 15:00:00	2018-04-23 18:00:00	2018-04-23 10:30:00	2018-04-23 11:15:00

日期不连续



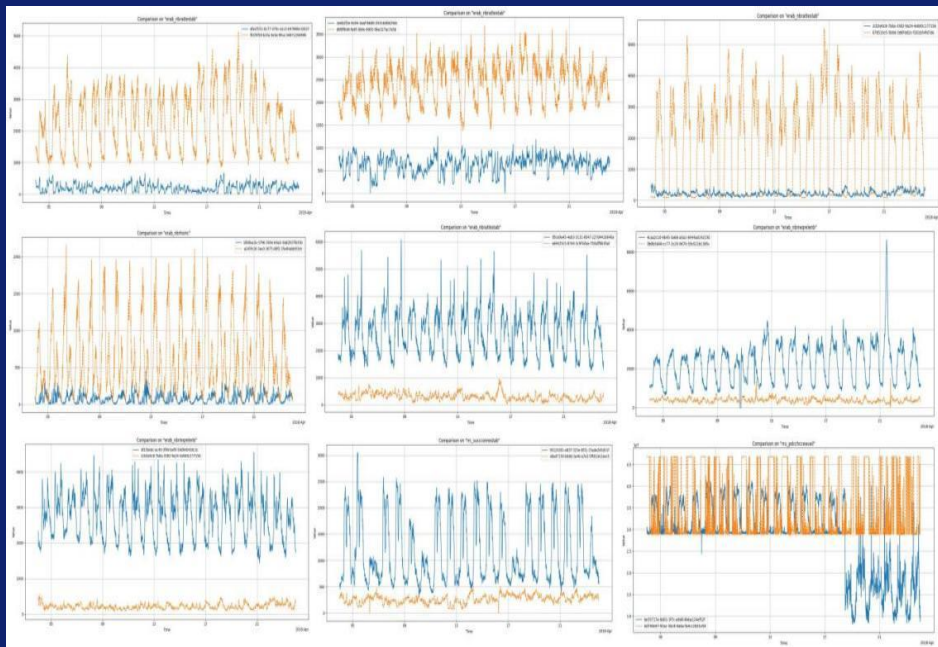
KNN
近邻填充缺失值



相似时间模式小区联合训练

数据处理——自适应尺度缩放


KPI序列模式相似，量级尺度不同



传统归一化或标准化算法



受异常值影响大且不利于区分量级差异大的时间模式，不利于联合跨小区样本进行训练



自适应尺度缩放算法（实验室自研算法

[1]

数值上便于模型收敛；不同小区的时间模式更可区分，增加了样本多样性；实现跨小区数据大规模联合训练



第四章 节

基于多尺度深度学习与专家知识的无线网络 KPI预测模型

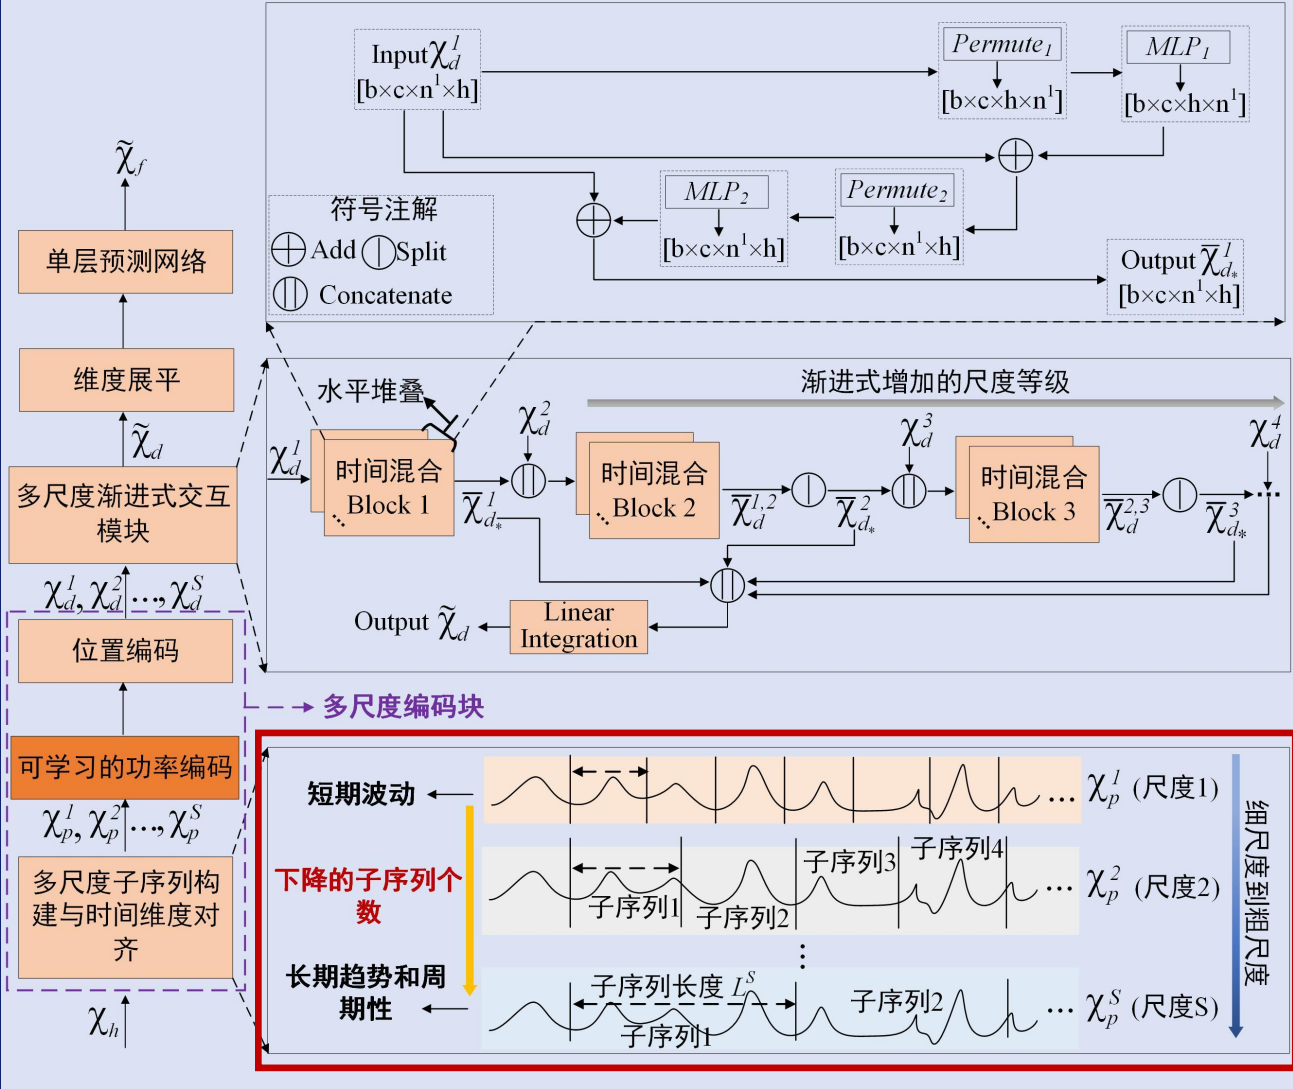
统一架构：基于多尺度深度学习与专家知识的无线网络KPI预测模型

(实验室自研算法, 处于同行评审阶段)

AIOPS | 2025 CCF国际AIOps挑战
赛25 CCF International AIOps Challenge

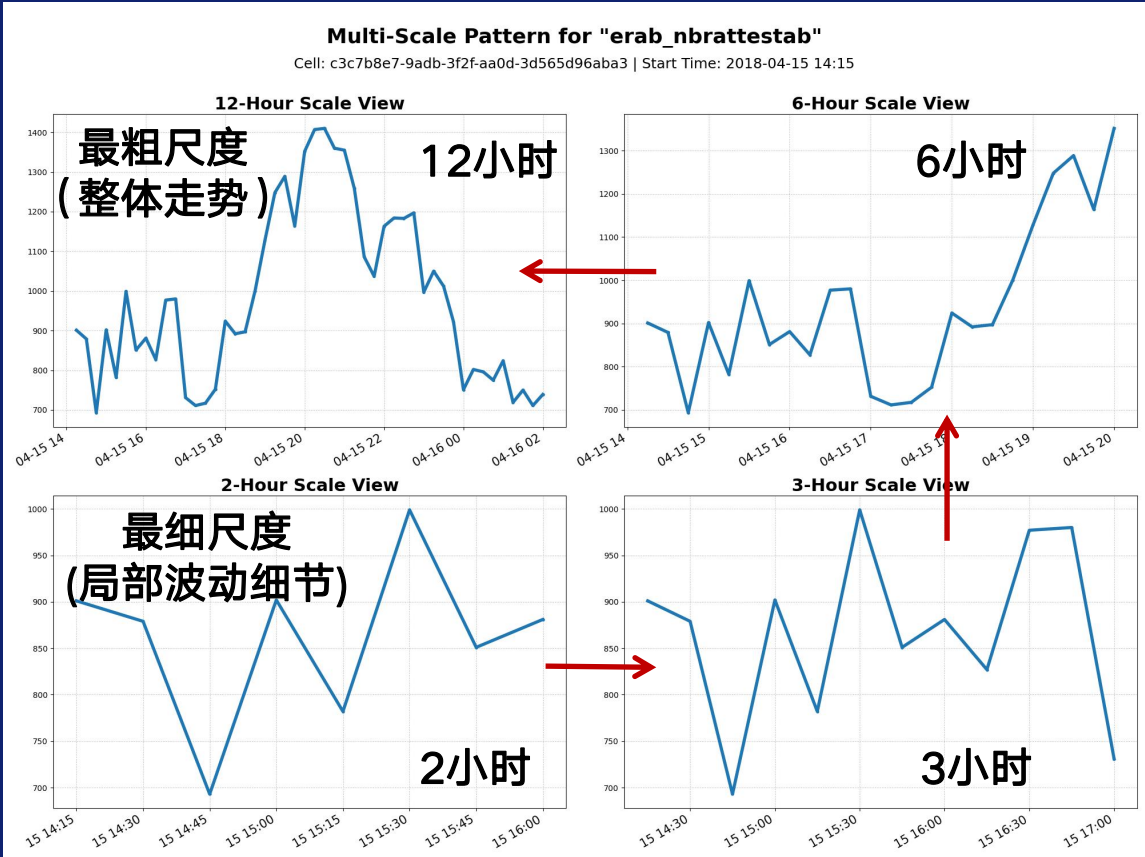
维度注解 $[b \times c \times n^1 \times h] \rightarrow$ 样本维度 \times 变量个数 \times 子序列个数 \times 隐藏层维度

MLP₁ 用于子序列之间的混合, MLP₂ 用于子序列内部的混合



多尺度输入构建

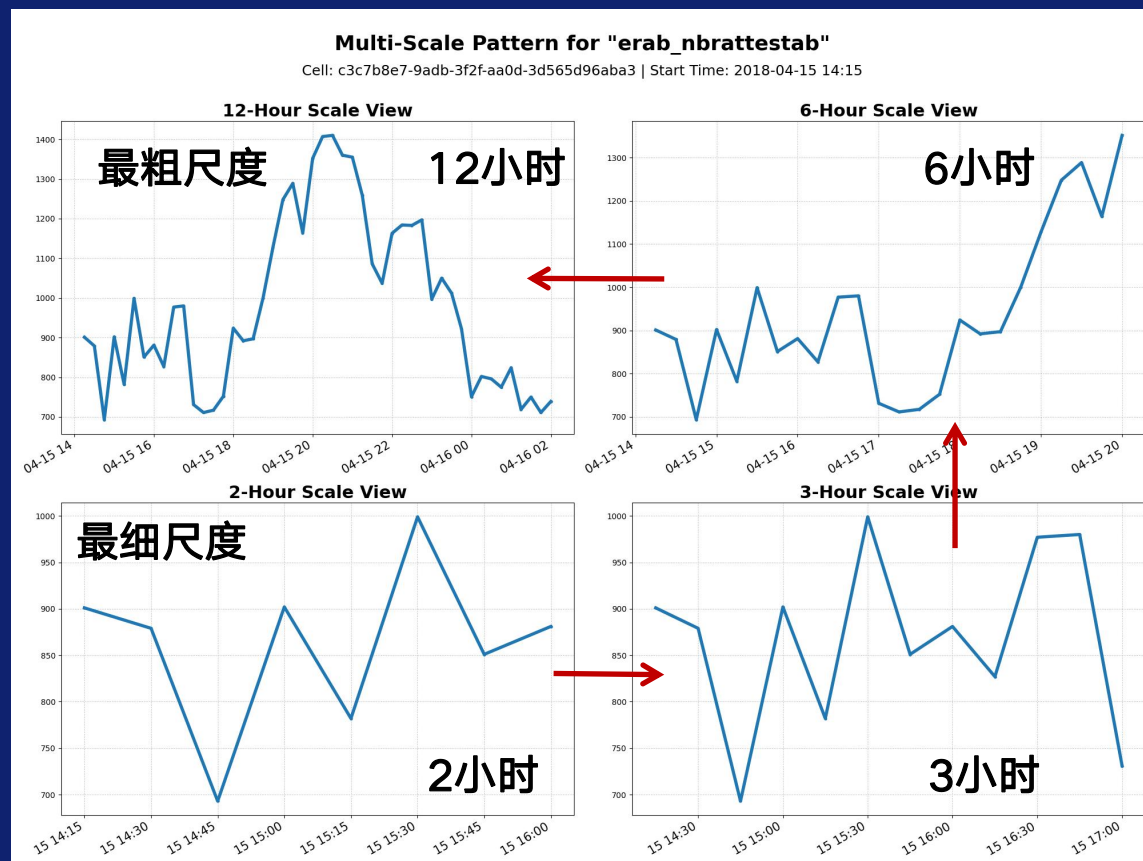
- 通过把完整的历史序列分割为**不同个数和不同长度**的子序列来构建多尺度输入。



统一架构：基于多尺度深度学习与专家知识的无线网络KPI预测模型

(实验室自研算法, 处于同行评审阶段)

AIOPS | 2025 CCF国际AIOps挑战赛
25 CCF International AIOps Challenge

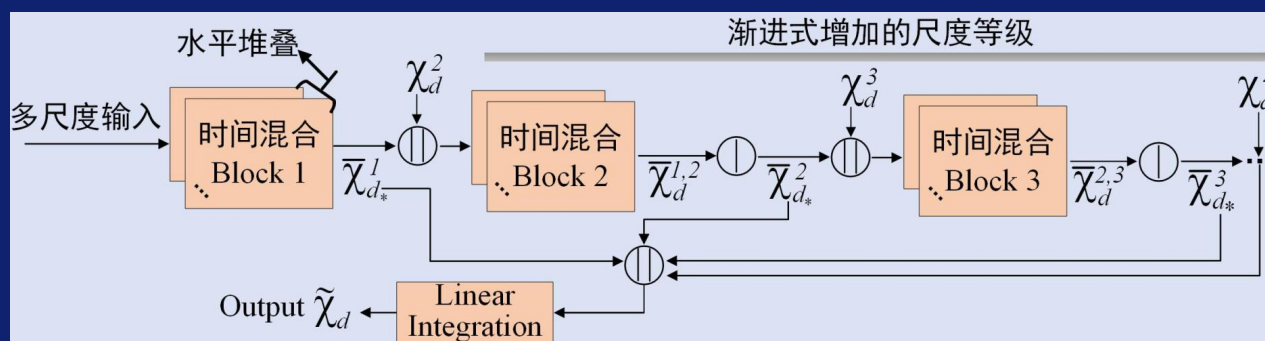


多尺度输入构建

- 粗尺度（12小时与6小时采样长度）用于捕捉KPI序列整体走势。
- 细尺度（3小时与2小时采样长度）用于捕捉KPI的局部波动细节。

考虑模式噪声的多尺度渐进式交互

- 随着尺度变化，KPI序列模式的语义产生变化。
 - 尺度间隔越大，模式语义差别越大。
 - 跨多个尺度进行语义建模可能在尺度之间引入不兼容的噪声信号，损害特征表达能力。
 - 我们提出仅在邻近尺度之间进行渐进式交互。
- 优势：抵抗噪声并提升时间特征提取能力、降低内存开销。



统一架构：基于多尺度深度学习与专家知识的无线网络KPI预测模型

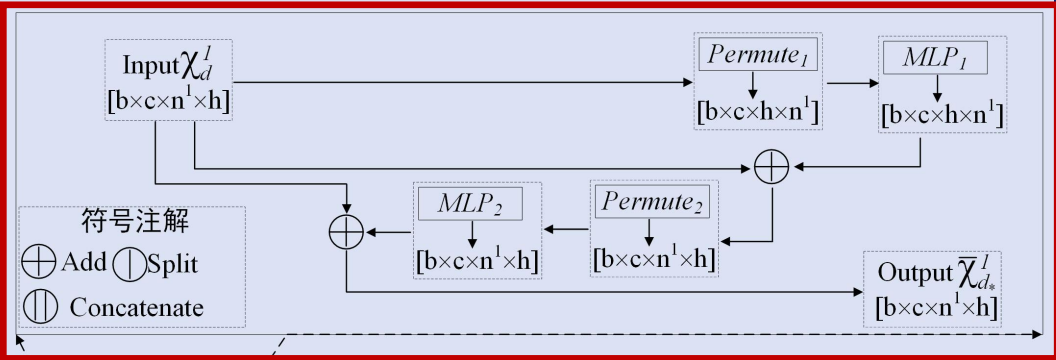
(实验室自研算法, 处于同行评审阶段)

AIOPS

2025 CCF国际AIOps挑战
赛25 CCF International AIOps Challenge

维度注解 $[b \times c \times n^1 \times h] \rightarrow$ 样本维度 \times 变量个数 \times 子序列个数 \times 隐藏层维度

MLP₁ 用于子序列之间的混合, MLP₂ 用于子序列内部的混合



单层预测网络

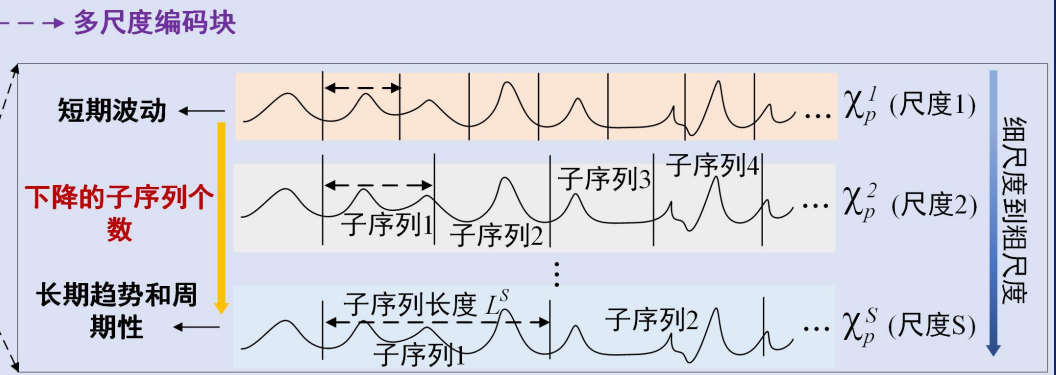
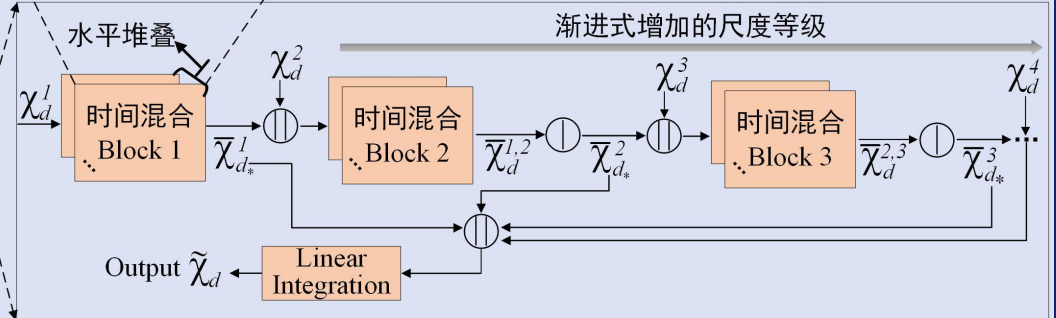
维度展平

多尺度渐进式交互模块

位置编码


功率离散化编码

多尺度子序列构建与时间维度对齐



轻量化的模型架构

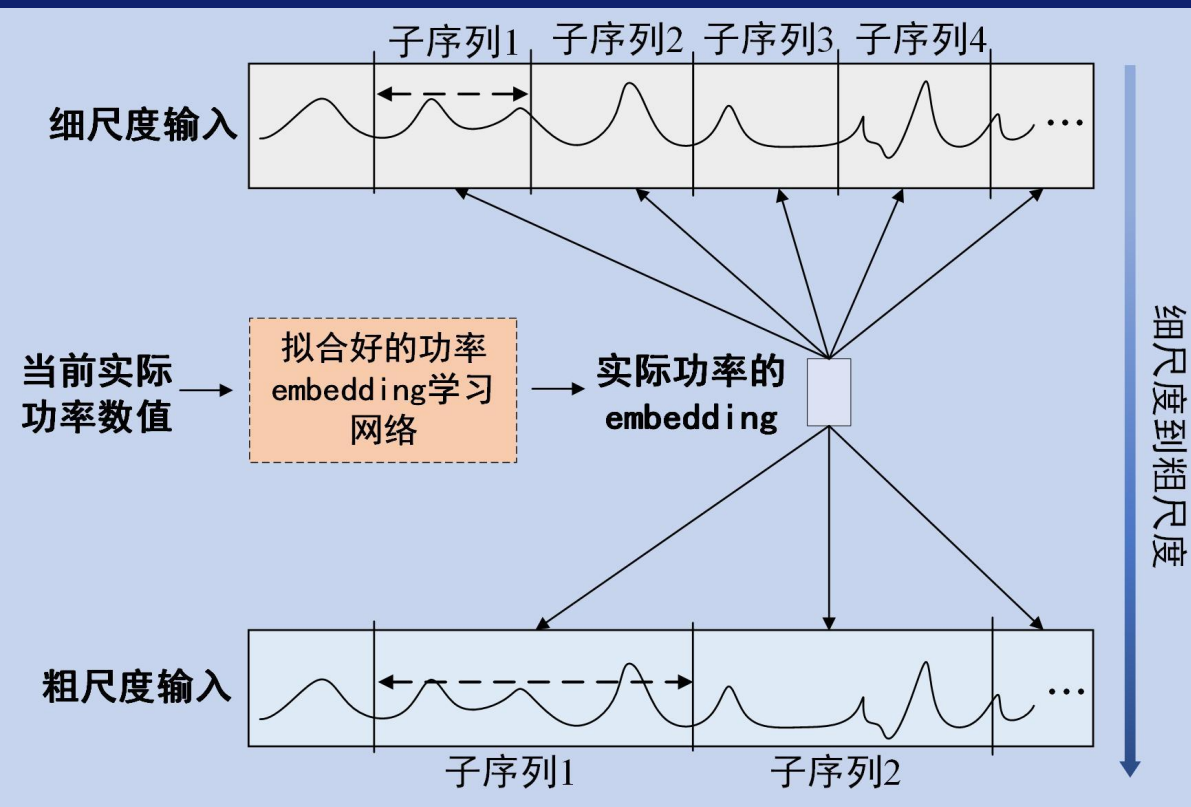
- 渐进式交互模块内存开销更低。
- 仅通过MLP在序列之间与内部进行复杂时间模式的交互与提取。



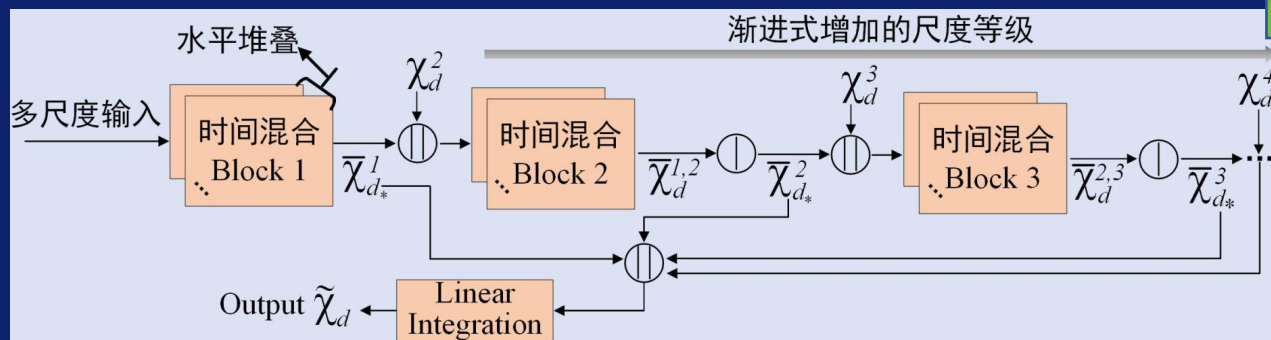
统一架构：基于多尺度深度学习与专家知识的无线网络KPI预测模型

(实验室自研算法, 处于同行评审阶段)

AIOPS | 2025 CCF国际AIOps挑战
赛 25 CCF International AIOps Challenge



强化功率条件与预测目标KPI之间的关联性



功率变化对样本构建

- 单个小区**时间维度**上的功率变化对（仅72个小区）。
- 小区之间在**样本维度**上的功率变化对（数据增强）。

通过离散化编码或连续型编码模块将每个功率参数被转化为可学习的embedding

类似位置编码那样将功率embedding嵌入到不同尺度输入的特征表示中

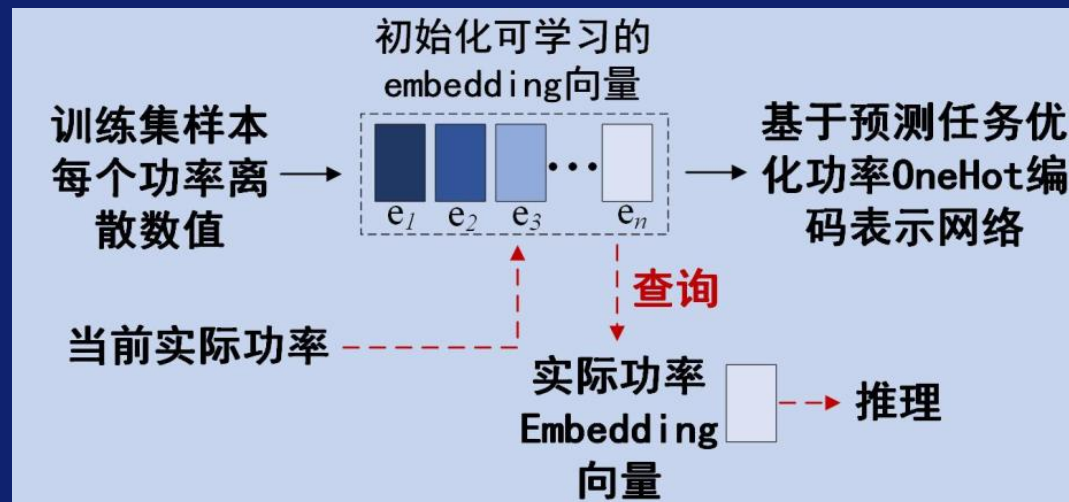
考虑模式噪声的多尺度渐进式交互

建模功率条件-历史时间模式-未来时间模式之间的关联

统一架构：基于多尺度深度学习与专家知识的无线网络KPI预测模型

(实验室自研算法, 处于同行评审阶段)

AIOPS | 2025 CCF国际AIOps挑战
赛 25 CCF International AIOps Challenge



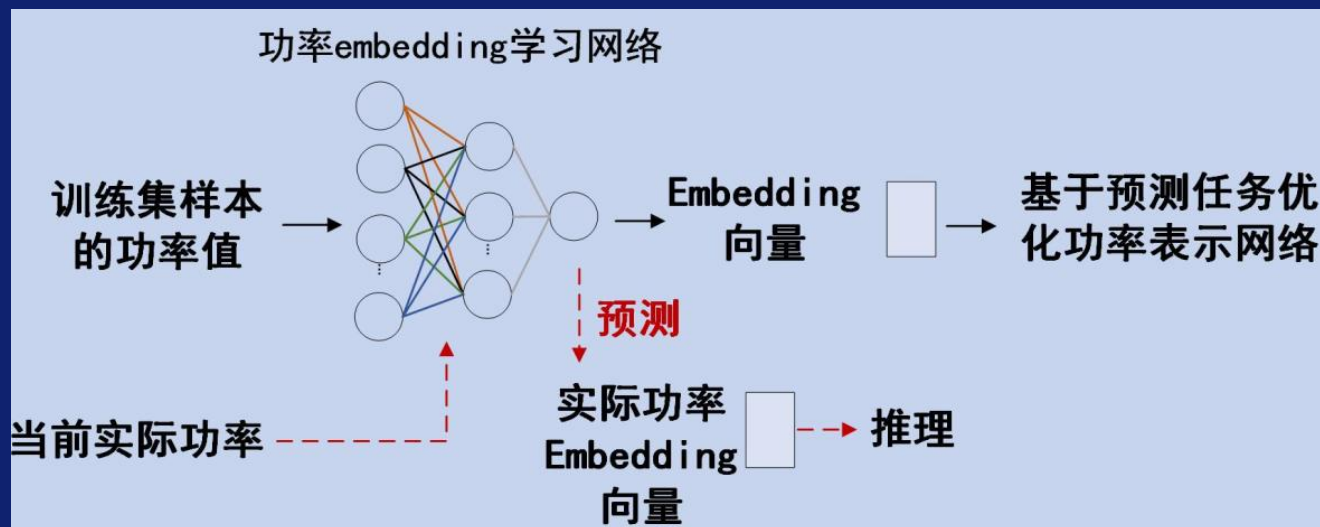
离散功率编码学习

此次比赛训练集功率值覆盖了测试集，因此离散功率编码学习也适用

为离散数值学习有意义的向量

通过功率索引查询相应的功率向量

无法泛化到未知的功率值



连续功率表征网络学习

学习特征表示神经网络

通过连续数值和神经网络预测功率的表征

可以泛化到未知的功率值

统一架构：基于多尺度深度学习与专家知识的无线网络KPI预测模型

(实验室自研算法, 处于同行评审阶段)

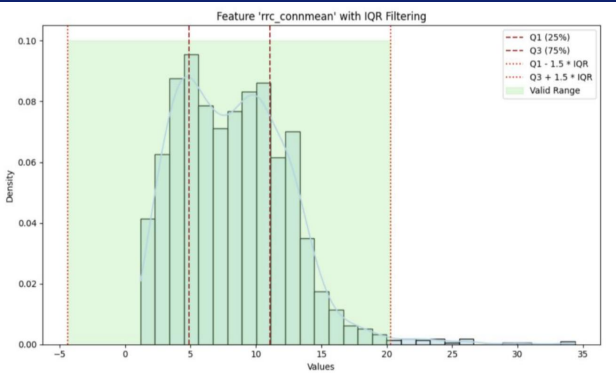
AIOPS | 2025 CCF国际AIOps挑战赛
25 CCF International AIOps Challenge

专家知识挖掘作为先验约束

异常阈值

通过四分距算法来挖掘时间模式的异常阈值上下界作为专家知识

$$[Q1 - 1.5 \times IQR, Q3 + 1.5 \times IQR]$$
$$IQR = Q3 - Q1$$



分位数

枚举3 - 7天的日期组合

分位数值预测2018年4月23日不同KPI值

选出最佳组合

将该组合整体向后平移一天预测

前一天数据
(最近邻日期)

.....

最佳日期组合 (best_combo)	小区 ID (cell_id)	SMAPE
2018-04-19 2018-04-21 2018-04-22	ecadb961-b347-3d6e-a1ff-e89ffad8357d	37.712
2018-04-20 2018-04-21 2018-04-22	efe5be5a-5acd-3717-b3c4-ac83339d20f3	34.808
2018-04-18 2018-04-21 2018-04-22	17e6a3a6-d075-3789-99ce-251d215c5a02	44.247
2018-04-17 2018-04-19 2018-04-21	9b75c3e4-9fdc-39c2-aed1-e7137c5192d8	36.168
2018-04-17 2018-04-18 2018-04-22	eb59139e-3fe2-343f-a99c-1cd79188d250	41.576
2018-04-18 2018-04-21 2018-04-22	c2f72346-bc92-3f39-a395-69f32a02faa9	38.403

统一架构：基于多尺度深度学习与专家知识的无线网络KPI预测模型

(实验室自研算法, 处于同行评审阶段)

AIOPS | 2025 CCF国际AIOps挑战
赛25 CCF International AIOps Challenge

多尺度预测模型的训练

$$L = 0.85 \times L_{SMAPE}(\bar{X}_f, X_f) + 0.15 \times L_{SMAPE}(\bar{X}_f, X_f^e)$$

真实值

专家知识

模型预测值

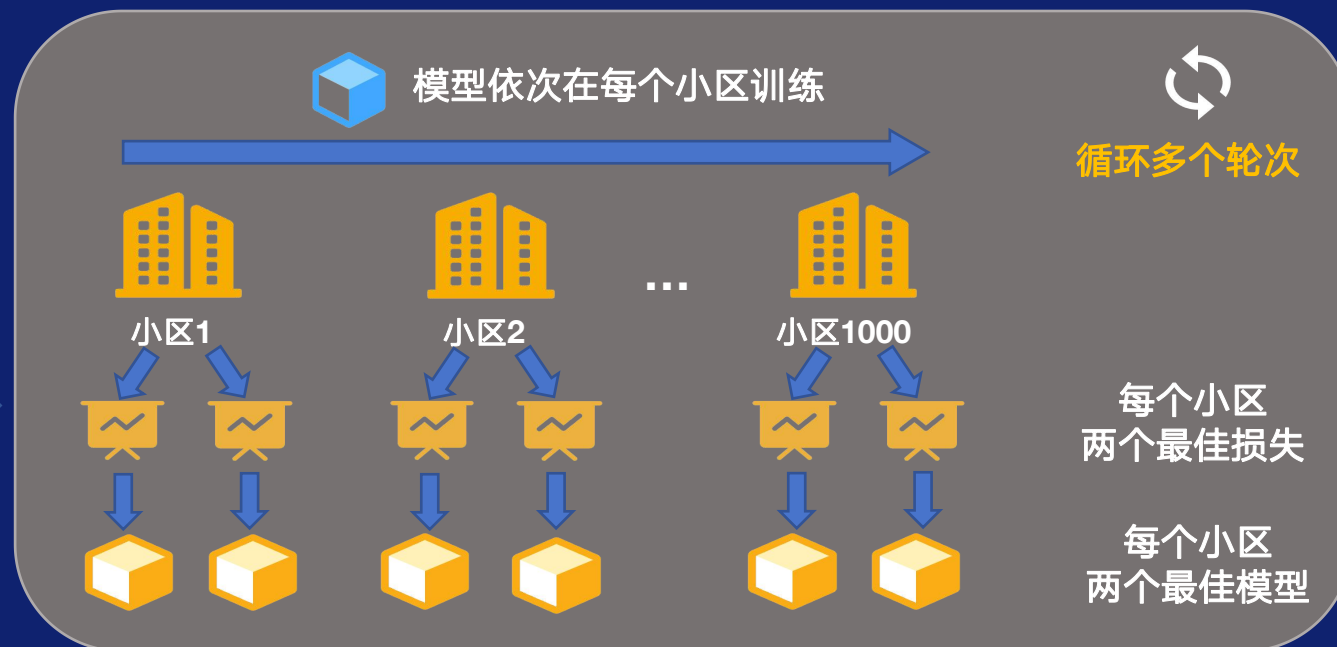
约束模型的预测分布不过于偏离专家知识的分布，降低异常预测风险，提高稳定性与鲁棒性

利用验证集损失探索合适的网络架构与损失函数

把验证集也加入训练集


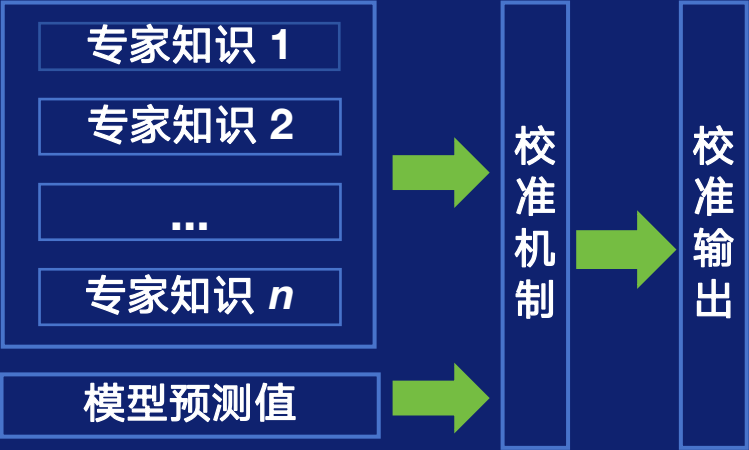

联合训练
(9000个小区)

微调训练
(1000个小区)



专家知识引导的预测校准机制

将专家知识翻译为时间序列用于约束上下界，既利用深度学习预测算法有效的全局预测能力，又利用专家知识去除深度学习局部的异常预测，降低模型黑盒风险，提升稳定性。




精心的设计：（1）下界由异常阈值下界掌控（2）上界由专家知识掌控（3）上下界之外的值均截断为专家知识

第五章节

实验展示


所提方法关键设计的有效性



所提方法关键设计的有效性

任务二因果预测

Smape error




基于专家知识的迭代校准优化

- 对模型输出值进行多个专家知识的迭代校准可以持续提升预测精度。
- 降低模型由于异常输入给出异常预测而损害业务利益的风险，提升稳定性。
- 既发挥了深度学习强大全局拟合能力的优势，又缓解了其在局部预测异常时带来的性能骤降的问题。


多尺度渐进式交互架构

- **多尺度输入**帮助模型更好地捕捉复杂的时间模式，从而提高预测精度。
- **渐进式交互**能避免不相邻尺度信息之间的噪声干扰，并能抵抗数据中的噪声模式，使模型性能更稳定、更出色。




交叉注意力机制

- 引入基于小区特征、时间信息的交叉注意力机制增加了预测误差。
- 大量小区共享着相似的时间序列模式，而小区与时间特征导致过于关注“个性”，忽略“共性”，损害了模型泛化性。



与先进时序预测算法的精度、效率比较



[1] TimeXer, NeurIPS2025

[2] DeformableTST, NeurIPS2025

[3] PDF, ICLR2025

[4] CARD, ICLR2024


[5] ModernTCN, ICLR2024

[6] PatchTST, ICLR2024


[7] Ours, Under Review

历史窗口长度的选择


- 功率变化后时间模式会出现较大波动，短窗口对于这类局部波动剧烈的模式预测更好，而历史窗口长度过大时，预测性能将出现显著降低[1]。
- 上述结论与我们最新的研究成果一致[1]。



- 不处理潜在波动大的时序数据训练效果更好：（1）一方面说明未来待预测模式存在波动大的情况（2）另一方面得益于提出的渐进式多尺度交互架构可以抵抗噪声并提升样本利用率。
- 虽然进行NAN填充之后精度没有提升，**但几乎不损失精度**，这在方案开发过程中帮助很大：
 - （1）填充的数据在专家知识挖掘（异常阈值、近邻专家、分位数专家等）方面起着关键作用，**尤其是部分小区在23号存在大量缺失值**。
 - （2）减少了深度学习、机器学习算法探索对于缺失值的处理，大大提升了开发的效率。
 - （3）用于构造有效历史窗口的推理样本，**部分小区在23号存在大量缺失值**，但我们需要预测24号的KPI值。



针对本赛题任务一和任务二，本团队提出了一种融合专家知识的多尺度深度学习统一预测框架，利用自适应量级处理与渐进式多尺度交互模型提升预测精度与鲁棒性，在无线网络KPI预测任务中实现了高效、低成本且具备推广潜力的解决方案。



Final score=任务一 Score*0.6+任务二 Score*0.4



OpenAIOps AIOPS | 2025 CCF国际AIOps挑战赛
2025 CCF International AIOps Challenge

THANKS

主办单位：中国计算机学会（CCF）

承办单位：中国计算机学会互联网专委会、中国科学院计算机网络信息中心、中国移动研究院、清华大学

协办单位：华为2012实验室、阿里云、中兴通讯、中国移动九天团队、南开大学、西安电子科技大学、清华大学计算机科学与技术系、神州灵云