

# 两阶段深度学习、随机森林与回声状态网络 非侵入式负荷分解研究

熊宇轩<sup>1</sup>, 张梓欣<sup>2</sup>, 李姝昱<sup>2</sup>, 胡万乐<sup>2</sup>

<sup>1</sup>上海理工大学机械工程学院, 上海

<sup>2</sup>上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2026年4月8日; 录用日期: 2026年6月4日; 发布日期: 2026年6月16日

## 摘要

在全球碳中和发展趋势下, 新型电力系统对需求侧用电精细化管理提出了更高要求, 非侵入式负荷分解 (Non-Intrusive Load Monitoring, NILM) 作为用户用电行为感知的核心技术, 成为智能电网领域的研究热点。针对当前NILM领域研究多聚焦于单一模型的结构优化, 缺乏不同技术范式模型在统一基准下的系统性横向对比, 工程应用技术选型缺乏量化参考的问题, 本文对两阶段深度学习、随机森林、回声状态网络 (Echo State Network, ESN) 和隐马尔可夫模型 (Hidden Markov Model, HMM) 四类分别代表分层深度学习、传统集成学习、轻量化储备池计算和传统概率图模型范式的NILM方法开展系统性研究。首先, 构建了NILM任务的数学模型与物理约束体系, 针对四类模型的核心特性, 分别完成了适配负荷分解任务的结构设计、特征构建与参数配置; 随后, 在统一原始数据、统一可比样本、统一评价指标体系和统一后处理规则下, 从分解精度、负荷适应性、抗噪声鲁棒性、推理效率与轻量化性能四个维度开展对比实验。实验结果表明, 随机森林模型在无噪声场景下分解精度最优, 平均MAE为0.2064、平均R<sup>2</sup>达到0.9573; 两阶段深度学习模型综合性能次之, 平均MAE为0.6101, 并在5%输入噪声下仍保持较小性能波动, 表现出较好的鲁棒性; HMM模型整体精度弱于前两者, 但具有参数量少、推理速度快、可解释性强等优势, 可作为传统NILM方法的代表性基线; ESN模型具备训练机制简单和轻量化潜力, 但在当前实验设置下平均MAE为2.4199、平均R<sup>2</sup>为-5.4685, 基础分解精度不足, 难以满足实际工程应用需求。本文研究明确了四类模型的优劣势、适用边界及工程定位, 可为不同资源约束和不同精度需求下的NILM技术选型提供系统参考。

## 关键词

非侵入式负荷分解, 两阶段深度学习, 随机森林, 回声状态网络, 模型对比

# Two-Stage Deep Learning, Random Forest, and Echo State Network for Non-Intrusive Load Decomposition: A Comparative Study

Yuxuan Xiong<sup>1</sup>, Zixin Zhang<sup>2</sup>, Shuyu Li<sup>2</sup>, Wanle Hu<sup>2</sup>

文章引用: 熊宇轩, 张梓欣, 李姝昱, 胡万乐. 两阶段深度学习、随机森林与回声状态网络非侵入式负荷分解研究[J]. 电气工程, 2026, 14(2): 49-62. DOI: 10.12677/jee.2026.142005

<sup>1</sup>School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai

<sup>2</sup>School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: April 8, 2026; accepted: June 4, 2026; published: June 16, 2026

## Abstract

Against the backdrop of global carbon neutrality, the emerging power system has imposed higher requirements on the refined management of demand-side electricity consumption. As a core technology for perceiving user-side electricity-use behavior, Non-Intrusive Load Monitoring (NILM) has become a major research focus in smart grids. To address the fact that most existing NILM studies concentrate on optimizing a single model, while lacking systematic horizontal comparisons among different technical paradigms under a unified benchmark, this paper conducts a comparative study of four NILM methods: two-stage deep learning, Random Forest, Echo State Network (ESN), and Hidden Markov Model (HMM), representing hierarchical deep learning, traditional ensemble learning, lightweight reservoir computing, and conventional probabilistic graphical modeling, respectively. First, the mathematical formulation and physical constraint system of the NILM task are established. Then, model design, feature construction, and parameter configuration are carried out according to the characteristics of the four methods. Subsequently, comparative experiments are conducted under a unified raw dataset, unified comparable samples, unified evaluation metrics, and unified post-processing rules, from four perspectives: disaggregation accuracy, load adaptability, noise robustness, and inference efficiency with lightweight performance. The experimental results show that the Random Forest model achieves the best disaggregation accuracy under noise-free conditions, with an average MAE of 0.2064 and an average  $R^2$  of 0.9573. The two-stage deep learning model ranks second overall, with an average MAE of 0.6101, and maintains only a small performance degradation under 5% input noise, demonstrating strong robustness. The HMM model is less accurate than the above two methods, but it offers clear advantages in terms of interpretability, parameter efficiency, and inference speed, making it a representative traditional NILM baseline. In contrast, the ESN model, although simple in training mechanism and potentially lightweight, yields an average MAE of 2.4199 and an average  $R^2$  of  $-5.4685$  under the current experimental setting, indicating insufficient basic disaggregation accuracy for practical engineering applications. Overall, this study clarifies the strengths, limitations, application boundaries, and engineering roles of the four methods, and provides a systematic reference for NILM model selection under different resource constraints and accuracy requirements.

## Keywords

Non-Intrusive Load Decomposition, Two-Stage Deep Learning, Random Forest, Echo State Network, Model Comparison

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

### 1.1. 研究背景与意义

在全球碳中和的发展趋势下，电力系统的供需结构发生深刻变革，以新能源为主体的新型电力系统

对需求侧的精细化、智能化管理提出了更高要求[1]。居民用电作为电力消费的重要组成部分，其用电行为的精准感知是实现需求侧响应、电网削峰填谷、用户节能服务的核心基础[2]。

负荷监测技术主要分为侵入式与非侵入式两类。侵入式负荷监测需要为家庭内每一个用电设备安装独立的智能采集装置，虽然可以获得精准的单设备用电数据，但存在部署成本高、安装维护复杂、用户隐私侵入性强的问题，难以大规模推广。而非侵入式负荷监测(NILM)仅需在家庭入户端安装单个智能电表，通过采集的总有功功率序列，利用算法反推出各电器的运行状态与实时功率，有效解决了侵入式方案的痛点，具备低成本、易部署、隐私保护性强的优势，成为智能电网与能源互联网领域研究热点[3]。

## 1.2. 国内外研究现状

自 1992 年 Hart 提出非侵入式负荷监测的核心框架[4]以来，NILM 技术经历了多轮技术迭代，主要可分为传统方法、传统机器学习方法与深度学习方法三大类[5][6]。

传统方法以隐马尔可夫模型(Hidden Markov Model, HMM)及其衍生模型为核心，包括因子隐马尔可夫模型(Factorial Hidden Markov Model, FHMM)、分层隐马尔可夫模型等，通过对电器的稳态运行状态建模，实现负荷分解。但这类方法需要预先掌握电器的状态先验信息，对多状态、运行模式复杂的电器建模难度大，面对多设备同时运行的场景泛化能力差，同时存在计算复杂度高、易陷入局部最优的问题[7]。此外，整数规划、遗传算法等优化方法也被应用于 NILM 任务，但同样存在对初始值敏感、收敛速度慢的局限。

传统机器学习方法以 K 近邻(K-Nearest Neighbor, KNN)、支持向量机(Support Vector Machine, SVM)、随机森林等集成学习算法为代表，这类方法通过人工设计时域、频域的负荷特征，将 NILM 转化为分类与回归问题，相比传统 HMM 方法降低了对先验信息的依赖，在中小规模数据集下具备较好的表现。但这类方法的性能高度依赖人工特征工程的质量，需要专家经验设计高区分度的特征，面对低功率电器、功率重叠的复杂场景，人工特征难以捕捉足够的有效信息，分解精度受限[8]。

深度学习方法凭借端到端的特征学习能力，摆脱了对人工特征工程的依赖，成为当前 NILM 领域的主流研究方向。Seq2Seq、Seq2Point[9]、带注意力机制的循环神经网络[10]等结构被广泛应用于负荷分解任务，在大规模数据集下展现出了远超传统方法的分解精度与泛化能力。但现有深度学习模型大多采用单阶段的端到端结构，多输出回归过程中需同时处理不同功率尺度电器的耦合映射，存在启停瞬间识别精度不足、小功率电器分解误差大的问题。

综合来看，当前 NILM 领域的研究多聚焦于单一模型的结构优化，缺乏对深度学习、传统集成学习、储备池计算、隐马尔可夫模型四类主流范式的系统性横向对比，不同模型的优劣势、适用场景尚未形成统一的参考标准，难以指导实际工程中的技术选型。

## 1.3. 本文主要工作与创新点

针对现有研究的不足，本文的主要工作与创新点如下：

1) 在同一实测数据集、统一评价指标体系和统一可比样本构造规则下，对两阶段深度学习、随机森林、回声状态网络和隐马尔可夫模型四类代表性 NILM 方法开展系统性横向对比研究。四类模型分别对应分层深度学习、传统集成学习、轻量化储备池计算和传统概率图模型四种典型技术范式，弥补了现有研究多聚焦单一模型优化、缺乏跨范式量化比较与工程选型参考的不足。

2) 针对四类模型的核心特性，分别完成了适配 NILM 任务的结构设计与针对性建模：针对两阶段深度学习模型，设计了总功率区间分段训练与“组级粗分解 - 设备级细分解”的两阶段分层结构，实现负荷结构的降维解耦与分步优化；针对随机森林模型，构建了基于 50 步滑动窗口和状态分段的多输出回归流程，增强对局部时序特征和复杂非线性关系的拟合能力；针对 ESN 模型，优化了适配负荷时序特性的

储备池参数配置，并完成基于岭回归的输出层训练；针对 HMM 模型，构建了基于总功率时序统计特征的 Gaussian HMM 基线框架，并通过 BIC 完成隐状态数选择，使其作为国际上较常用的传统 NILM 对比基准纳入统一实验体系。

3) 从分解精度、负荷类型适应性、抗噪声鲁棒性、训练与推理效率、模型轻量化与可解释性等多个维度，系统分析四类模型的优劣势与适用边界。研究结果不仅给出了四模型在当前数据集上的总体排序，也进一步揭示了不同模型与不同负荷类型之间的匹配关系：随机森林更适合追求高精度的场景，两阶段深度学习更适合兼顾精度与鲁棒性的场景，HMM 适合作为轻量化、可解释的传统基线，ESN 则为后续储备池结构和输入表示优化提供了诊断性参照。

## 2. 非侵入式负荷分解问题描述

### 2.1. 非侵入式负荷分解问题的数学模型

非侵入式负荷分解(NILM)是一种无需在单个用电设备端加装计量装置，仅通过用户入户总电表采集的总有功功率序列，还原各用电设备分项有功功率序列的技术，其核心物理基础为交流电路的有功功率叠加守恒原理。

#### 2.1.1. 总功率与各电器功率的守恒关系

对于离散采样的负荷时间序列，定义符号体系如下：设采样时间戳为  $t \in \{1, 2, \dots, T\}$ ，其中  $T$  为总采样点数；家庭内目标用电设备总数为  $N$ ； $P_{\text{total}}(t)$  为  $t$  时刻入户端测得的总有功功率； $P_i(t)$  为第  $i$  个用电设备在  $t$  时刻的有功功率； $\varepsilon(t)$  为  $t$  时刻的综合误差项，包含电表测量噪声、线路功率损耗、未纳入建模的小型负荷功率扰动等，正常工况下其幅值远小于总有功功率，可视为加性高斯白噪声处理[11]。

基于有功功率守恒原理，总有功功率与各设备分项功率满足如下数学关系：

$$P_{\text{total}}(t) = \sum_{i=1}^N P_i(t) + \varepsilon(t), t = 1, 2, \dots, T \quad (1)$$

式(1)为 NILM 任务的核心物理约束，明确了总功率与各电器功率的叠加关系，也是负荷分解模型构建的基础。

#### 2.1.2. 问题目标与优化目标函数

NILM 的核心任务目标为：在仅可观测总有功功率序列  $\{P_{\text{total}}(t)\}_{t=1}^T$  的前提下，反演得到所有目标设备的分项有功功率预测序列  $\{\hat{P}_i(t)\}_{t=1}^T$ ，其中  $\hat{P}_i(t)$  为第  $i$  个设备有功功率的预测值，优化的核心目标是最小化预测功率与真实功率之间的误差。

为量化预测结果与真实值的整体偏差，本研究采用对大误差惩罚更强、适配负荷数据波动特性的均方误差(Mean Squared Error, MSE)作为误差度量基准[12]，构建以误差最小化为核心的优化目标函数：

$$\min_{\{\hat{P}_i(t)\}} L = \frac{1}{NT} \sum_{t=1}^T \sum_{i=1}^N (\hat{P}_i(t) - P_i(t))^2 \quad (2)$$

其中  $L$  为整体损失函数，优化目标为找到使损失最小的预测功率序列  $\{\hat{P}_i(t)\}$ 。

为保证分解结果符合实际物理意义，优化过程中需引入两项刚性约束：

1) 非负约束：用电设备的有功功率不可能为负值，因此需满足

$$\hat{P}_i(t) \geq 0, \forall i \in \{1, 2, \dots, N\}, \forall t \in \{1, 2, \dots, T\} \quad (3)$$

2) 总功率一致性约束：预测的各设备功率之和应尽可能与实测总有功功率一致，因此需满足

$$\left| \sum_{i=1}^N \hat{P}_i(t) - P_{\text{total}}(t) \right| \leq \delta, \forall t \in \{1, 2, \dots, T\} \quad (4)$$

其中  $\delta$  为允许的最大偏差阈值，用于平衡模型拟合能力与结果的物理合理性，本文中  $\delta$  设置为总功率实测值的 1%。

## 2.2. 数据集介绍

本文所采用的数据集为上海理工大学实验室环境实测负荷数据集，数据以 xlsx 格式存储，记录了实验环境下总负荷及各目标电器分负荷的功率数据，功率单位为瓦特(W)。共包含 3618 组有效样本，无缺失值与异常值。

从数据结构上看，数据集共包含 5 列变量，其中前 4 列为目标电器的实际功率，最后 1 列为总功率，具体包括：电脑、冰箱、手机充电器、台灯、总功率。其中，总功率列由上述 4 个目标电器功率逐行相加得到，能够反映多电器同时运行时的聚合负荷特征。

目标电器的选择覆盖了实验室场景中具有不同负荷特性的典型设备：冰箱属于相对稳定且具有周期波动特征的负荷，电脑属于中等功率且持续运行型负荷，手机充电器具有较明显的开关变化特征，台灯则属于低功率、小波动负荷。这样的设备组合使数据集同时包含了稳定负荷、波动负荷和低功率负荷，有助于验证 NILM 方法在不同负荷类型下的分解能力。

## 3. 基于两阶段深度学习的负荷分解模型

### 3.1. 模型设计思路

本文提出一种“分段建模 + 两阶段分解”的联合结构负荷分解模型，以总负荷数据为输入、目标电器分项功率为输出，通过“先粗分解、后细分解”的层次化建模思路，将高耦合的多输出回归任务拆解为两个相互衔接的子任务。模型第一阶段先从总功率中提取高、低功耗组的组级中间分量，完成负荷结构的粗粒度建模；第二阶段基于中间分量完成电器级的细粒度分解。

同时，模型引入总功率区间分段训练机制，按总功率范围将样本等宽分箱划分为 5 个区间，每个区间独立训练一套两阶段模型，适配不同功率水平下的电器组合差异，降低全局单模型的拟合压力，提升模型的工况适应能力与分解稳定性。

### 3.2. 第一阶段粗粒度分解模型

第一阶段的核心任务是学习总功率到粗粒度组级中间分量的映射关系。该阶段的监督目标由训练数据自动构造：以数据文件最后一列为总负荷列，其余列为各电器真实分量功率；计算各分量在训练集上的平均功率。参考负荷分组与分阶段建模的相关研究思路[13]-[15]，本文以训练集中各分量平均功率的中位数作为阈值，将电器划分为高功率组与低功率组，并对两组功率逐时间步求和，得到维度固定为 2 的两个中间分量，作为第一阶段的学习目标。

该阶段的模型实现为类 First Stage Predictor，默认采用两层全连接的多层感知机结构：输入层维度为 1，对应单时间步总负荷值；两层隐藏层神经元数分别为 256、128，每层后均接入批归一化(BatchNorm1d)、ReLU 激活函数与 Dropout 层(dropout 率设置为 0.2)；输出层维度为 2，对应两个组级中间分量。训练阶段采用对负荷异常值不敏感的 Robust Scaler 完成数据缩放，以均方误差(MSE Loss)为损失函数，以 Adam 算法为参数优化器(学习率设置为  $1e-3$ )，引入  $\text{patience} = 10$  的早停机制抑制过拟合；训练完成后，通过平均绝对百分比误差(MAPE)、MAE、RMSE 与决定系数  $R^2$  四项指标完成模型效果评估。该阶段的核心

作用是实现负荷结构的降维与解耦，为后续细粒度分解提供具备物理意义的结构化输入。

### 3.3. 第二阶段细粒度分解模型

第二阶段的核心任务是学习组级中间分量到各电器分项功率的多输出回归映射，输入为第一阶段输出的 2 维中间分量，输出维度等于目标电器的数量，由数据分量列数自动确定(本文中为 4)。

该阶段的模型实现为类 Second Stage Predictor，默认采用全连接结构，包含输入层、两层共享隐藏层(全连接层 + BatchNorm1d + ReLU)与输出层，隐藏层神经元数分别为 256、128，同时预留了 CNN、LSTM、GRU、Transformer 等多种网络结构[16]的扩展接口，具备良好的模块化与可扩展性。训练阶段以真实的组级中间分量为输入、真实电器分项功率为监督目标，训练流程与第一阶段保持一致。

推理阶段的完整流程为：首先根据输入总功率匹配对应区间的分段模型，通过该分段的第一阶段模型预测得到中间分量，再将中间分量输入第二阶段模型得到初始预测结果，对结果反缩放恢复原始功率量纲后，施加非负约束将负功率截断为 0，保证分解结果符合电器功率的物理意义。

该阶段的核心作用是完成从组级功率到设备级功率的精细化映射，将复杂的多输出映射拆解为更易学习的子任务，降低不同功率尺度电器对回归效果的干扰，提升模型的层次化表达能力与结果可解释性。

## 4. 基于随机森林的负荷分解模型

### 4.1. 随机森林算法原理

随机森林(Random Forest, RF)是由 Breiman 于 2001 年提出的集成学习算法[17]，核心基于 Bagging (Bootstrap Aggregating)思想，通过构建多棵决策树并集成输出结果，提升模型精度与稳定性。

集成学习通过组合多个基学习器实现更优的泛化性能，Bagging 采用自助采样法(Bootstrap Sampling)从原始数据集中有放回地抽取多个子集，独立训练多棵决策树，回归任务中对所有树的结果取平均值输出，有效降低模型方差、抑制过拟合。随机森林以分类与回归树(Classification and Regression Tree, CART)为基学习器，节点分裂时引入随机特征子空间策略，仅选取部分特征完成最优分割，双重随机性提升基学习器差异性，进一步增强模型泛化能力。

对于回归任务，随机森林最终输出为所有决策树预测值的算术平均，表达式如下：

$$\hat{y}(x) = \frac{1}{T} \sum_{t=1}^T h_t(x) \quad (5)$$

其中， $T$  为决策树数量， $h_t(x)$  为第  $t$  棵树对输入  $x$  的预测值。在负荷分解任务中，该算法用于构建总功耗特征与单电器功耗的映射关系。

### 4.2. 特征构建与选择

特征质量直接决定负荷分解模型性能，本文结合用电时序特性构建多层次特征体系[18]，具体如下：

1) 基础时序特征：仅使用当前时刻的总功耗作为输入信息量不足，因此采用滑动窗口构造历史序列特征，滑动窗口长度  $L$  设置为 50，弥补单一时刻总功耗信息量不足的问题。

2) 统计与差分特征：为进一步增强特征表达，引入差分特征(当前时刻与前一时刻的功率差值，反映功耗变化速率)、短窗口移动均值(窗口长度 3，捕捉局部波动)、长窗口移动均值(窗口长度 20，捕捉长期趋势)、移动标准差(窗口长度 10，反映功耗的波动程度)。

3) 状态特征：为区分不同的用电模式，本文采用变化点检测方法对总功耗序列进行阶段划分，基于 findchangepts 函数，以均值变化为统计量自动识别状态分割点，生成状态标签  $S_t$ ，该标签作为额外特征

参与模型训练。

4) 时间编码特征：引入正弦、余弦时间编码，捕捉负荷用电的周期性规律。

综合以上特征，每个样本的输入特征向量可表示为：

$$F(t) = [P_{t-L+1}, \dots, P_t, \Delta P_t, MA_s(t), MA_l(t), STD(t), S_t, \sin(t), \cos(t)] \quad (6)$$

### 4.3. 模型训练与优化

本文实现基于状态的随机森林负荷分解模型，采用状态分治策略完成训练与预测，整体流程如下：

1) 数据预处理：读取标准化数据集，通过滑动窗口将时序数据转换为监督学习格式，共生成  $T-L$  个有效样本，并依据状态标签  $S_t$  将全部样本按不同状态分组，形成若干子数据集。

2) 分状态模型训练[19]：为适配不同用电模式下的映射关系，为每个用电状态分别训练立的随机森林模型。具体步骤为：对每个状态  $k$ ，提取该状态对应的训练样本子集，清理样本中的 NaN 或 Inf 值；采用 fitrensemble 函数，指定 Method 为 Bag，决策树数量设为 50，最小叶子节点数设为 5，节点分裂随机特征数为特征总数的 1/3，构建该状态的随机森林模型；保存所有状态模型至本地文件。

3) 预测流程：预测时，首先根据待预测点的状态标签选择对应模型，然后输入对应的特征向量，得到各电器的预测功耗，最终所有预测结果汇总形成完整的负荷分解曲线。

模型训练时采用 5 折交叉验证监控泛化性能，由于随机森林本身对过拟合具有较强的抵抗能力，超参数调优重点关注窗口长度与状态划分的合理性。

### 4.4. 模型优势与局限

随机森林应用于非侵入式负荷分解具备显著优势：第一，模型非线性拟合能力强，无需预设函数形式，可有效捕捉总功耗与各电器功耗之间的复杂非线性关系；第二，结合状态分治策略后，模型能够根据不同用电模式建立独立的映射规律，显著提升分解精度，实验结果表明，该策略使冰箱 ON/OFF 状态的 MAE 分别降低了约 15%；第三，对异常值和噪声具有较强的容忍性，鲁棒性高[16]；第四，可通过特征重要性分析，评估各输入特征对分解结果的贡献，可解释性较好；第五，相较于神经网络，随机森林训练速度快、参数调优简单，适合工程部署。

同时模型存在局限性：第一，缺乏对时间序列上下文的长程记忆能力，窗口长度有限时可能遗漏远距离影响，对于周期较长的电器(如冰箱)，需要较大窗口才能获得良好效果；第二，状态分治策略的效果高度依赖变化点检测的准确性，若状态划分不合理，可能导致某些状态样本不足或模型过拟合；第三，对训练数据中未出现的新型用电模式泛化能力有限，需要动态更新状态库；第四，输入特征的构造仍需领域知识，自动化程度低于端到端深度学习模型。

综上，该模型适用于用电模式较为稳定、状态可明确划分，对实时性和可解释性有较高要求，训练数据规模中等的负荷分解场景。

## 5. 基于回声状态网络的负荷分解模型

### 5.1. 回声状态网络理论基础

回声状态网络(Echo State Network, ESN)是一种适用于时序数据建模的递归神经网络[20]，由输入层、储备池(隐藏层)与输出层三部分构成，其核心优势在于解决了传统递归神经网络易出现的梯度消失、梯度爆炸问题。ESN 的训练过程仅需优化输出层权重，输入层与储备池的连接权重初始化后保持固定，大幅简化了模型优化流程。

储备池是 ESN 的核心模块, 由大量随机稀疏连接的递归神经元组成, 可将低维输入序列映射至高维状态空间, 有效捕捉时序数据的长期依赖关系与非线性特征。模型性能主要由 5 个核心参数决定[21]: 谱半径(储备池连接矩阵最大特征值的绝对值, 需满足  $\lambda < 1$  以保障网络稳定性)、储备池规模(神经元数量, 决定模型特征表达能力)、输入缩放因子(控制输入信号对储备池的驱动程度)、稀疏度(储备池神经元连接比例)、泄漏率(控制模型对历史信息的保留程度)。

## 5.2. 面向负荷分解的 ESN 模型构建

本文针对 NILM 任务, 构建了以总负荷时序数据为输入、目标电电子负荷功率为输出的 ESN 分解模型, 模型整体采用“输入层-储备池层-输出层”的经典三层结构[22][23]。设输入序列为  $e(m) \in \mathbb{R}$ , 表示第  $m$  个时间步的总负荷值; 储备池状态向量为  $x(m) \in \mathbb{R}^{N_x}$ , 其中  $N_x$  为储备池神经元数量; 输出向量为  $y(m) \in \mathbb{R}^4$ , 对应 4 个目标电器的预测值。模型前向传播过程可表示为:

$$x(m+1) = (1-\alpha)x(m) + \alpha \cdot \tanh(W_{in}e(m+1) + Wx(m)) \quad (7)$$

$$y(m) = W_{out} \cdot [x(m); e(m)] \quad (8)$$

其中,  $W_{in} \in \mathbb{R}^{N_x \times 1}$  为输入权重矩阵,  $W \in \mathbb{R}^{N_x \times N_x}$  为储备池内部连接权重矩阵,  $W_{out} \in \mathbb{R}^{4 \times (N_x+1)}$  为输出权重矩阵,  $\alpha$  为泄漏率参数, 取值范围为  $(0,1]$ 。

模型核心设计如下:

- 1) 储备池参数配置: 结合负荷数据的时序特性与样本规模, 最终确定储备池规模  $N_x = 1500$ 、谱半径  $\lambda = 0.9605$ 、输入缩放因子  $IS = 0.0110$ 、稀疏度  $SD = 0.1$ 、泄漏率  $\alpha = 0.2588$ , 在模型表达能力、计算效率与泛化性能间取得平衡。
- 2) 输出层训练方法: 输出层采用带 L2 正则化的岭回归求解输出权重矩阵, 正则化系数设为  $2.46 \times 10^{-7}$ , 在保证拟合精度的同时抑制过拟合风险。
- 3) 总和一致性约束: 设计后处理校正机制, 在预测完成后按总负荷实测值等比例调整子负荷预测结果, 确保各子负荷预测值之和与总负荷一致, 提升分解结果的物理合理性。
- 4) 评价指标: 采用 MAE、RMSE、 $R^2$ 、MAPE 与对称平均绝对百分比误差(SMAPE)五项指标, 全面量化模型分解精度。

## 5.3. 模型超参数优化策略

针对 ESN 性能高度依赖参数配置、人工调参效率低且易陷入局部最优的问题, 本文设计了网格搜索与随机搜索相结合的超参数优化框架[24]。

该框架以 RMSE 为核心优化目标, 搜索范围覆盖储备池规模、输入缩放因子、谱半径、泄漏率、岭回归正则化系数 5 个核心参数, 其中储备池规模搜索范围为  $[500, 3000]$ , 输入缩放因子搜索范围为  $[0.01, 0.3]$ , 谱半径搜索范围为  $[0.7, 1.0]$ , 泄漏率搜索范围为  $[0.01, 0.5]$ , 正则化系数搜索范围为  $[10^{-7}, 10^{-2}]$ 。通过多指标加权融合的综合评分函数评估参数组合性能, 同时引入早停与断点续传机制降低计算开销。搜索过程分为两步: 首先通过随机搜索预筛选 100 组参数, 锁定最优参数邻域; 随后通过网格搜索在邻域内开展 50 组精细化搜索, 最终得到全局最优参数组合。

# 6. 基于隐马尔可夫模型的负荷分解模型

## 6.1. 模型引入与基本原理

隐马尔可夫模型(Hidden Markov Model, HMM)是非侵入式负荷分解领域中最具代表性的传统概率模

型之一，也是早期 NILM 研究中被广泛采用的经典方法。HMM 通过引入不可直接观测的隐状态，对负荷运行过程中的状态转移规律进行建模，能够从聚合总功率序列中推断电器的潜在运行模式。本文引入 HMM 的目的，并非将其作为主要优化对象，而是将其作为一种国际上广泛认可的传统基准方法纳入统一对比框架。一方面，HMM 能够为后续发展出的机器学习和深度学习 NILM 方法提供理论与方法上的基础参照；另一方面，将 HMM 纳入实验比较，有助于增强本文模型对比研究的完整性，并为不同技术范式之间的性能差异提供国际认可的参考基线。

## 6.2. HMM 模型构建

本文采用高斯隐马尔可夫模型(Gaussian HMM)构建负荷分解基线。模型输入不直接使用各电器分负荷，而仅使用总功率及其时序特征；四个目标电器的真实功率仅用于训练阶段建立状态到功率的映射关系，以及测试阶段计算误差指标。

为增强模型对总功率动态变化的表征能力，本文从总功率序列中构造 6 维观测特征，包括原始总功率、滚动中值平滑总功率、一阶差分、二阶差分、局部滑动均值和局部滑动标准差。通过上述特征，HMM 不仅能够利用当前时刻的总功率信息，还能够感知局部变化趋势、突变程度和波动强度，从而提升隐状态识别能力。

在数据划分上，HMM 与两阶段深度学习模型保持一致，采用 `train_test_split (test_size = 0.2, random_state = 42)` 的方式划分训练集和测试集，其中训练集占 80%，测试集占 20%，测试样本数为 724。为便于与其他模型进行可视化对比，选取测试集中 300 个样本用于绘制预测曲线。

模型训练过程中，将隐状态数设置在 2 至 6 之间进行搜索，并采用贝叶斯信息准则(BIC)选择最优状态数。最终实验结果表明，当隐状态数取 6 时，模型在拟合能力与复杂度之间达到较优平衡，因此本文采用 6 状态 Gaussian HMM 作为最终 HMM 模型。

## 6.3. 预测流程与改进策略

原始 HMM 在完成状态解码后，通常采用“隐状态 - 平均功率”映射方式，即将某一隐状态直接对应为该状态下电器真实功率的平均值。该方法虽然具有较强可解释性，但容易使预测曲线呈现明显的阶梯化特征，不利于连续功率分解结果的展示。

为在保留 HMM 状态建模思想的基础上提高预测曲线的连续性，本文采用“Gaussian HMM + 隐状态内 Ridge 线性校准”的方式生成最终结果。具体而言，HMM 首先负责识别样本所属隐状态；随后，对每个电器、每个隐状态分别建立轻量级 Ridge 回归模型，用于学习该状态内“总功率特征 - 电器功率”之间的线性映射关系；当某一状态样本不足时，则退回使用全局 Ridge 回归器。测试阶段根据样本解码得到的隐状态，调用对应的 Ridge 校准模型进行功率预测，并对预测结果统一施加非负约束。

该改进方式并未改变 HMM 作为传统概率图模型基线的基本定位，而是在其状态建模框架下增加简单的线性校准步骤，使预测值能够随总功率变化连续调整，从而提高结果图的可读性与展示效果

## 7. 实验设置与结果分析

本章在统一数据源、统一测试样本、统一评价指标和统一后处理规则的基准条件下，对两阶段深度学习模型、随机森林模型、回声状态网络(ESN)和隐马尔可夫模型(HMM)四类 NILM 方法开展系统性对比实验。为保证横向比较的公平性，本文不直接沿用各模型原始工程中的独立测试集，而是在统一原始数据上重新构造可比样本，并在相同真实标签、相同评价口径和一致的物理约束后处理下完成结果统计与可视化分析。通过整体精度对比、抗噪声鲁棒性测试以及推理效率与轻量化性能分析，量化不同模型

的分解能力与适用边界，为 NILM 技术的工程化选型提供可复核的实验依据。

## 7.1. 实验基础设置

### 7.1.1. 实验数据集与统一可比样本构造

本次实验采用统一数据文件 NILM.xlsx 作为四模型对比的数据来源。该数据文件包含电脑、冰箱、手机充电器、台灯 4 类目标电器的真实功率，以及由 4 个分负荷逐时刻相加得到的总功率列“四合一相加”。实验中，总功率列作为各模型的核心输入信号，4 类目标电器的真实分项功率作为监督标签与评价基准。目标负荷覆盖持续运行型、周期启停型、趋势变化型和低功率负荷等典型家用用电场景，能够较全面地检验不同 NILM 模型的分解能力。

由于四个模型原始工程中的训练/测试划分方式并不完全一致，为保证比较公平，本文未直接使用各自独立测试集，而是在统一原始数据上重新构造可比测试样本。具体流程为：首先读取 ESN 工程中的测试总功率序列；随后将该测试序列逐点映射回 NILM.xlsx 中的原始样本位置；再考虑到随机森林模型需要 50 步历史窗口输入，剔除原始索引小于 50 的样本；最后在剩余样本上分别运行两阶段深度学习、随机森林、ESN 和 HMM 模型，并使用同一批真实分负荷标签计算指标。按上述规则处理后，最终得到 1189 个统一可比测试样本。该统一样本构造方式使不同模型的评价结果建立在相同输入口径和相同标签口径之上，从而增强了实验结果的可复现性与比较的严谨性。

### 7.1.2. 评价指标、对比模型与实验设置

为全面量化模型性能，本文采用平均绝对误差(MAE)、均方根误差(RMSE)、决定系数( $R^2$ )、归一化分解误差(NDE)以及能量相对误差(Energy Relative Error) 5 项指标进行评价。其中，MAE 和 RMSE 用于衡量预测值与真实值之间的绝对偏差，且 RMSE 对较大误差更加敏感； $R^2$  用于反映模型对真实负荷变化趋势的解释能力；NDE 用于描述归一化分解误差；能量相对误差则反映预测能量与真实能量之间的偏差，更贴近 NILM 在能耗统计场景中的应用需求。为验证模型在现场测量扰动下的稳定性，本文进一步在总功率输入中叠加 0%、1%、3%和 5%的高斯白噪声，噪声标准差由测试集总功率标准差乘以相应比例得到。需要说明的是，鲁棒性实验中的整体  $R^2$  为将 4 类负荷预测结果整体展开后计算得到，因此与逐负荷平均  $R^2$  不完全一致；在分析抗噪声性能时，需结合 MAE 与 RMSE 变化综合判断。

本次实验选取四类代表不同技术范式的 NILM 模型作为对比对象，分别为两阶段深度学习模型、随机森林模型、回声状态网络模型和隐马尔可夫模型。两阶段深度学习模型采用固定历史训练结果进行离线推理，不重新训练，以避免重新训练带来的随机扰动影响已有结果的一致性；随机森林模型采用 50 步历史总功率窗口作为输入，并在不同状态段内分别建立分负荷回归器；ESN 模型使用已完成参数搜索后的最优配置；HMM 模型采用 Gaussian HMM，并在 2 至 6 个隐状态之间搜索，最终根据 BIC 选择 6 个隐状态。上述设置均与各模型方法章节中的结构设计和参数说明保持一致。

## 7.2. 模型误差特性分析

不同模型对不同负荷类型的适应性存在明显差异，电脑负荷最能体现模型对复杂连续波动的处理能力，随机森林在电脑负荷上的 MAE 为 0.4874、 $R^2$  为 0.8773，显著优于其他模型，说明历史窗口特征对识别短时功率变化具有重要作用；两阶段深度学习在该负荷上的  $R^2$  为 0.2315，说明其虽然能够学习整体功率水平，但对高频波动的跟踪能力仍有限；HMM 在电脑上的  $R^2$  为负，说明有限隐状态难以有效表达此类复杂连续负荷；ESN 则在电脑负荷上表现最差，未能形成有效拟合。

冰箱负荷具有较为稳定的运行模式和明显的启停特征，因此对状态信息和局部时序结构较为敏感。在该负荷上，随机森林  $R^2$  达到 0.9718，表现最佳；两阶段深度学习和 HMM 的  $R^2$  分别为 0.5381 和 0.5365，

二者接近,说明深度分层建模和传统状态建模对冰箱这类状态型负荷均有一定适应性;ESN在冰箱负荷上虽绝对误差不算最大,但 $R^2$ 为负,说明其对趋势变化的解释能力不足。手机充电器负荷具有较明显的阶段性趋势变化,随机森林和两阶段深度学习在该负荷上的 $R^2$ 分别达到0.9975和0.9801,均表现出很强的趋势拟合能力;HMM在手机充电器上的 $R^2$ 也达到0.9186,说明其能够较好识别总体变化方向,但MAE高达2.8981,表明状态映射方式对具体功率幅值的估计不够精细。台灯属于低功率、小波动负荷,随机森林在台灯上的MAE仅为0.0227, $R^2$ 达到0.9825;两阶段深度学习和HMM在台灯上的绝对误差分别为0.0868和0.0850,数值较为接近,均能保持较好的绝对偏差控制;ESN在该负荷上的 $R^2$ 明显为负,说明其在小信号提取上存在显著不足。

### 7.3. 综合性能对比分析

#### 7.3.1. 整体分解精度对比

四类模型在统一可比样本上的整体分解精度量化结果图1所示。需要强调的是,图中及表中的所有指标均在统一可比样本集上、基于相同真实标签和统一后处理规则计算得到,因此具有直接横向比较意义。从总体精度看,随机森林模型表现最优,其平均MAE、平均RMSE、平均 $R^2$ 、平均NDE和平均能量相对误差均为四模型中最佳,说明滑动窗口特征与集成树回归在当前NILM数据集上具有很强的适配性。两阶段深度学习模型整体排名第二,其平均MAE为0.6101,平均 $R^2$ 为0.5544,明显优于HMM和ESN,说明分阶段学习策略能够较好地处理总功率到分负荷功率之间的复杂非线性映射。HMM整体精度弱于随机森林和两阶段深度学习,但优于ESN,表明作为传统概率图模型基线,其在当前任务中仍具备一定分解能力。ESN模型平均 $R^2$ 为负,说明其在多个负荷上的预测效果低于简单均值预测基线,当前参数与输入形式尚不足以支撑高质量分解。

从能量相对误差看,随机森林和两阶段深度学习分别达到0.0006和0.0029,说明两者不仅在瞬时功率层面具有较高精度,在总体能量估计上也更具优势,适合面向用户能耗统计、负荷分析与需求侧管理等应用场景。相比之下,HMM与ESN的能量相对误差明显更高,说明其在长期能量累积估计方面仍存在较大改进空间。




Figure 1. Overall accuracy comparison of four types of model test sets

图1. 四类模型测试集整体精度对比

#### 7.3.2. 抗噪声鲁棒性对比

为验证模型在实际计量场景中的抗干扰能力,本次实验在输入总功率中叠加0%、1%、3%、5%的高斯白噪声,测试模型性能的衰减程度,结果如图2所示。鲁棒性实验除输入噪声扰动外,其余模型版本、测试样本、评价流程和后处理规则均保持不变,从而保证不同噪声水平下结果比较的唯一变量为输入扰动强度。

从鲁棒性表现看,两阶段深度学习模型在精度和稳定性之间取得了较好的平衡。当噪声比例由0%升

至 5%时，其 MAE 仅由 0.6101 增加至 0.6525，误差增长幅度较小，说明该模型对输入扰动具有较强适应能力。随机森林在无噪声条件下精度最高，但对输入噪声最为敏感，MAE 由 0.2064 上升至 0.8280，约增长 4 倍，表明基于 50 步历史窗口的输入结构在噪声叠加时会同时放大多维特征扰动，从而影响树模型的分裂路径与预测结果。HMM 和 ESN 在噪声增强时 MAE 变化较小，但这种“稳定性”不能简单等同于更强的鲁棒性：HMM 输出受到隐状态划分与状态映射机制约束，输入轻微扰动未必会改变状态序列，因此数值波动较小，但其无噪声条件下的基准误差本身较高；ESN 则由于整体分解精度较弱，噪声叠加未显著进一步恶化其误差水平。因此，从工程角度看，两阶段深度学习更适合被视为兼顾较高精度与较强抗噪性的均衡模型，而随机森林更适合于噪声较低的干净测量场景。




Figure 2. Comparison of average MAE and R<sup>2</sup> of four types of models under different noise levels (Unit: W)  
图 2. 不同噪声水平下四类模型平均 MAE 和 R<sup>2</sup> 对比(单位: W)

### 7.3.3. 推理效率与轻量化对比

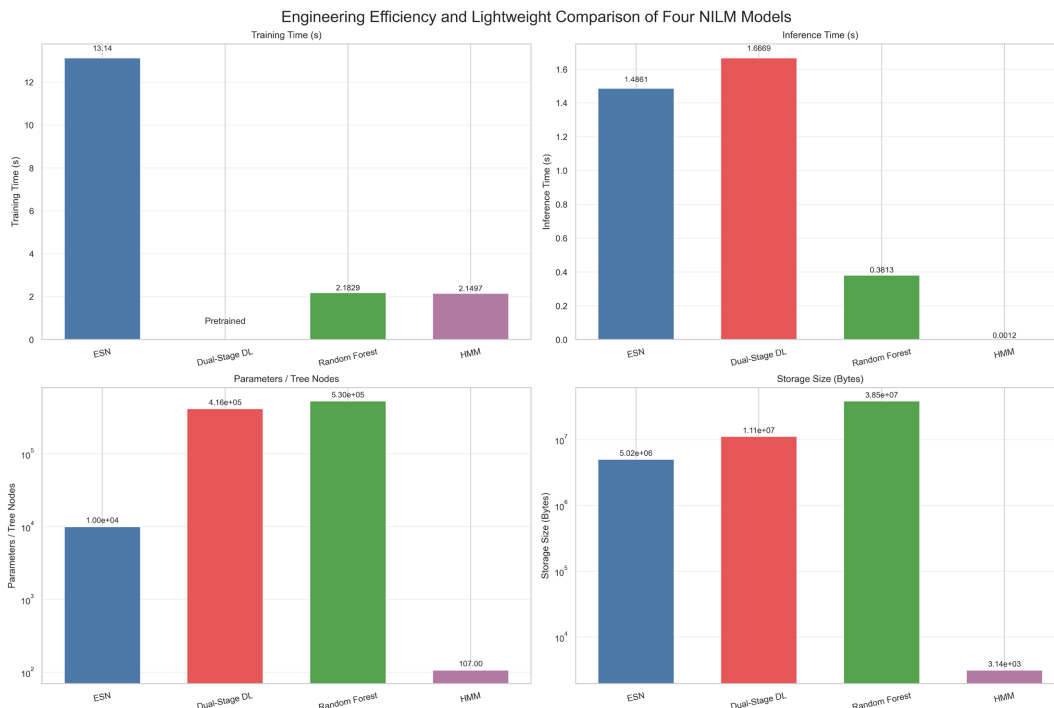


Figure 3. Comparison of training time, reasoning time, parameter quantity, and storage scale for four types of models  
图 3. 四类模型训练时间、推理时间、参数量与存储规模对比

除分解精度外，模型的训练开销、推理效率、参数规模与存储体积也是 NILM 工程部署中的关键因素。四类模型在工程性能维度上的结果如图 3 所示。从工程指标看，HMM 在轻量化和推理效率方面具有最显著优势，其参数量仅 107，存储规模约 3 KB，单次推理时间仅 0.0012 s，适合作为低资源场景下的传统基线模型，也适合强调可解释性与快速部署的边缘端应用。随机森林虽然整体精度最高，推理时间也较短，但模型存储体积最大，约为 38 MB，说明其高精度是以较大模型规模为代价获得的。两阶段深度学习模型的数量和存储体积均处于较高水平，推理流程也更复杂，但其优势在于兼顾精度与抗噪性。ESN 理论上具有训练机制简单、只训练输出层等优点，但在当前实验设置下，储备池规模较大，使其实际推理效率并未明显优于随机森林。

## 8. 结论与展望

### 8.1. 结论

本文针对非侵入式负荷分解任务，系统研究了两阶段深度学习、随机森林、回声状态网络和隐马尔可夫模型四类分别代表不同技术范式的 NILM 方法，在统一原始数据、统一可比样本、统一评价体系和统一后处理规则下，完成了四类模型的结构设计、实现与性能对比分析。主要结论如下：

1) 若仅以分解精度为目标，四模型总体排序为：随机森林 > 两阶段深度学习 > HMM > ESN；若综合考虑精度与鲁棒性，两阶段深度学习表现更均衡；若强调轻量化、推理速度与可解释性，则 HMM 具有明显优势；ESN 则更适合作为后续优化研究对象，而不宜作为当前场景下的优选工程方案。上述结果表明，不同 NILM 模型的优劣并非单纯由模型复杂度决定，而是取决于模型结构、输入表示、负荷类型和部署目标之间的匹配程度。

2) ESN 在本文中的失败并非单一由参数规模不足引起，而更可能源于以下几个方面的叠加影响：第一，输入特征过于单一，主要依赖总功率序列，缺乏与随机森林相当的显式局部时序窗口或更丰富的统计特征支持；第二，储备池虽然能够提供动态状态表示，但当前参数配置下未能有效分离多电器耦合场景中的隐含模式；第三，输出层采用岭回归，整体表达能力仍偏线性，难以精细恢复复杂负荷的非线性叠加关系；第四，电脑等高频波动负荷和台灯等低功率弱信号负荷，本身就对模型的动态分辨率和细节恢复能力提出了更高要求。因而，本文的实验结果实际上表明：ESN 在当前“单总功率输入 + 固定储备池 + 线性输出层”的设定下，不适合作为本研究场景中的主力分解模型，但其失败结果仍具有诊断价值，可为后续在输入表示、储备池结构和输出层设计上的改进提供明确方向。这一发现也与本文前述四模型对比结果相一致。

### 8.2. 展望

针对本文的研究内容，未来的研究方向可从以下几个方面展开：

1) 针对低功率电器、功率高度重叠的复杂场景，进一步优化两阶段深度学习模型的特征提取结构，结合多尺度卷积、注意力机制等结构，提升对弱特征的捕捉能力，降低小功率电器的分解误差。

2) 研究三类模型的优势融合策略，比如利用随机森林的状态识别能力与两阶段模型的功率回归能力，构建混合模型，兼顾分解精度、鲁棒性与推理效率，适配边缘设备的部署需求。

3) 提升模型的跨场景泛化能力，研究小样本、零样本学习在 NILM 中的应用，实现对训练集中未见过的电器类型的有效分解，降低模型对标注数据的依赖。

针对边缘设备的落地需求，结合模型量化、剪枝等轻量化技术，对两阶段深度学习模型与随机森林模型进行压缩优化，实现高精度、低延迟、低功耗的 NILM 边缘端部署。

## 参考文献

- [1] 舒印彪, 张丽英, 张运洲, 等. 我国电力碳达峰、碳中和路径研究[J]. 中国工程科学, 2021, 23(6): 1-14.
- [2] 田世明, 王蓓蓓, 张晶. 智能电网条件下的需求响应关键技术[J]. 中国电机工程学报, 2014, 34(22): 3576-3589.
- [3] 程祥, 李林芝, 吴浩, 等. 非侵入式负荷监测与分解研究综述[J]. 电网技术, 2016, 40(10): 3108-3117.
- [4] Hart, G.W. (1992) Nonintrusive Appliance Load Monitoring. *Proceedings of the IEEE*, **80**, 1870-1891. <https://doi.org/10.1109/5.192069>
- [5] 张石清, 王伟, 钱亚冠, 等. 面向深度学习的非侵入式负荷监测研究进展[J]. 计算机系统应用, 2023, 32(3): 25-47.
- [6] Huber, P., Calatroni, A., Rumsch, A. and Paice, A. (2021) Review on Deep Neural Networks Applied to Low-Frequency NILM. *Energies*, **14**, Article 2390. <https://doi.org/10.3390/en14092390>
- [7] Makonin, S., Popowich, F., Bajic, I.V., Gill, B. and Bartram, L. (2016) Exploiting HMM Sparsity to Perform Online Real-Time Nonintrusive Load Monitoring. *IEEE Transactions on Smart Grid*, **7**, 2575-2585. <https://doi.org/10.1109/tsg.2015.2494592>
- [8] 邓晓平, 张桂青, 魏庆来, 等. 非侵入式负荷监测综述[J]. 自动化学报, 2022, 48(3): 644-663.
- [9] Zhang, C., Zhong, M., Wang, Z., Goddard, N. and Sutton, C. (2018) Sequence-to-Point Learning with Neural Networks for Non-Intrusive Load Monitoring. *Proceedings of the AAAI Conference on Artificial Intelligence*, **32**, 2604-2611. <https://doi.org/10.1609/aaai.v32i1.11873>
- [10] 李希今, 王祥任, 刘金石. 基于循环神经网络与注意力机制的波动预测模型[J]. 吉林大学学报(理学版), 2025, 63(5): 1397-1403.
- [11] Zeifman, M. and Roth, K. (2011) Nonintrusive Appliance Load Monitoring: Review and Outlook. *IEEE Transactions on Consumer Electronics*, **57**, 76-84. <https://doi.org/10.1109/tce.2011.5735484>
- [12] Kelly, J. and Knottenbelt, W. (2015) Neural NILM: Deep Neural Networks Applied to Energy Disaggregation. *Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments*, Seoul, 4-5 November 2015, 55-64. <https://doi.org/10.1145/2821650.2821672>
- [13] Jazizadeh, F., Becerik-Gerber, B., Berges, M. and Soibelman, L. (2014) An Unsupervised Hierarchical Clustering Based Heuristic Algorithm for Facilitated Training of Electricity Consumption Disaggregation Systems. *Advanced Engineering Informatics*, **28**, 311-326. <https://doi.org/10.1016/j.aei.2014.09.004>
- [14] Ma, H., Jia, J., Yang, X., Zhu, W. and Zhang, H. (2021) MC-NILM: A Multi-Chain Disaggregation Method for NILM. *Energies*, **14**, Article 4331. <https://doi.org/10.3390/en14144331>
- [15] Mauch, L. and Yang, B. (2016) A Novel DNN-Hmm-Based Approach for Extracting Single Loads from Aggregate Power Signals. 2016 *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Shanghai, 20-25 March 2016, 2384-2388. <https://doi.org/10.1109/icassp.2016.7472104>
- [16] Hachana, S., Fourer, D., Auger, F., Sethom, H.B.A. and Miègeville, L. (2021) Comparative Evaluation of Non-Intrusive Load Monitoring Methods Using Relevant Features and Transfer Learning. *Energies*, **14**, Article 2726. <https://doi.org/10.3390/en14092726>
- [17] Breiman, L. (2001) Random Forests. *Machine Learning*, **45**, 5-32. <https://doi.org/10.1023/a:1010933404324>
- [18] Barbhuyan, M.E. and Goswami, P.K. (2023) Effective Feature Selection and Deep Learning-Based Classification for Non-Intrusive Load Monitoring. *Electric Power Components and Systems*, **51**, 2293-2306. <https://doi.org/10.1080/15325008.2023.2209089>
- [19] 陈铭龙. 基于机器学习的非侵入式电力负荷分解研究[D]: [硕士学位论文]. 福州: 福建工程学院, 2020.
- [20] Jaeger, H. (2001) The “Echo State” Approach to Analysing and Training Recurrent Neural Networks. German National Research Center for Information Technology.
- [21] 孙婧瑜. 回声状态网络的结构机制及应用研究[D]: [博士学位论文]. 北京: 北京邮电大学, 2024.
- [22] Jaeger, H. and Haas, H. (2004) Harnessing Nonlinearity: Predicting Chaotic Systems and Saving Energy in Wireless Communication. *Science*, **304**, 78-80. <https://doi.org/10.1126/science.1091277>
- [23] Yildiz, I.B., Jaeger, H. and Kiebel, S.J. (2012) Re-Visiting the Echo State Property. *Neural Networks*, **35**, 1-9. <https://doi.org/10.1016/j.neunet.2012.07.005>
- [24] Viehweg, J., Worthmann, K. and Mäder, P. (2023) Parameterizing Echo State Networks for Multi-Step Time Series Prediction. *Neurocomputing*, **522**, 214-228. <https://doi.org/10.1016/j.neucom.2022.11.044>