

基于元认知二型模糊神经网络的电力负荷区间预测方法

孙晨暄¹ 韩红桂^{2,3} 伍小龙^{2,3} 房方¹

摘要 针对电力负荷呈现高度非线性和强不确定性等特征导致关键指标难以准确预测的问题,提出一种基于元认知二型模糊神经网络的区间预测方法.首先,设计基于多值映射的二型模糊规则,利用区间估计技术将规则后件由单值标量扩展为区间向量,处理不确定性导致的负荷序列变量关联关系偏差并捕捉变量间的非线性关系.其次,构建基于误差补偿机制的二型模糊神经网络,引入动态反馈结构实时感知并补偿累积误差和模型偏差,实现关键指标高精度预测.再次,设计基于区间覆盖率和区间宽度的元认知学习算法,通过实时评估区间可靠性自适应优化二型模糊神经网络边界估计值,提高区间预测的置信度.最后,将提出的元认知二型模糊神经网络应用于城市电力负荷预测任务.验证结果显示,该方法能够提供高置信度且精确的预测区间.

关键词 元认知二型模糊神经网络; 区间预测; 区间覆盖率; 区间宽度

引用格式 孙晨暄, 韩红桂, 伍小龙, 房方. 基于元认知二型模糊神经网络的电力负荷区间预测方法. 自动化学报, 2026, 52(6): 1145-1156

DOI 10.16383/j.aas.c250480

CSTR 32138.14.j.aas.c250480

Interval Prediction Method of Power Load Based on Metacognitive Type-2 Fuzzy Neural Network

SUN Chen-Xuan¹ HAN Hong-Gui^{2,3} WU Xiao-Long^{2,3} FANG Fang¹

Abstract The prediction of the key indicators is a challenging problem due to the high nonlinearity and strong uncertainties in power load data. To solve this problem, a metacognitive type-2 fuzzy neural network (MCT2FNN)-based interval prediction method is proposed. First, a type-2 fuzzy rule based on multi-value mapping is designed to extend rule consequents from scalar values to interval vectors by using interval estimation technology. It can handle the variable correlation bias caused by uncertainty and capture the nonlinear relationship between the variables in the load series. Second, a type-2 fuzzy neural network (T2FNN) with an error compensation mechanism is established. In this network, a dynamic feedback structure is introduced to perceive and compensate for cumulative errors and model biases in real time, which can achieve high precision prediction of key indicators. Then, an interval coverage probability and interval width-based metacognitive learning algorithm is designed to adaptively optimize the boundary estimates of T2FNN through the real-time assessment of interval reliability, which can improve the confidence level of interval predictions. Finally, the proposed MCT2FNN is applied to interval prediction tasks for the urban power system. The experimental results demonstrate that the method can provide high-confidence and precise prediction intervals for power systems.

Keywords metacognitive type-2 fuzzy neural network; interval prediction; interval coverage probability; interval width

Citation Sun Chen-Xuan, Han Hong-Gui, Wu Xiao-Long, Fang Fang. Interval prediction method of power load based on metacognitive type-2 fuzzy neural network. *Acta Automatica Sinica*, 2026, 52(6): 1145-1156

收稿日期 2025-09-17 录用日期 2025-10-30
Manuscript received September 17, 2025; accepted October 30, 2025

一流学科人才培养计划 (XM2512302) 资助
Supported by First Class Discipline Talent Cultivation Program (XM2512302)

本文责任编辑 罗彪

Recommended by Associate Editor LUO Biao

1. 华北电力大学控制与计算机工程学院 北京 102206 2. 北京工业大学信息科学技术学院 北京 100124 3. 北京工业大学计算智能与智能系统北京市重点实验室 北京 100124

1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206 2. School of Information Science and Technology, Beijing University of Technology, Beijing 100124 3. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing University of Technology, Beijing 100124

电力负荷预测作为负荷动态变化规律挖掘的核心技术,为电网供需平衡调控、能源调度优化及电力系统实时决策提供科学依据,在智能电网建设、新能源消纳、配电网高效运行等关键领域具有不可替代的作用^[1-2].然而,受系统运行过程复杂性和环境扰动因素影响,电力负荷普遍呈现高度非线性和强不确定性的非平稳特征^[3-5].数据驱动的点预测技术通过建立输入-输出映射关系提供单一预测值,其结果难以度量电力负荷变化的内在不确定性,无法有效量化电网运行中负荷峰谷波动、供需失衡等风险边界^[6-7].因此,开展电力负荷的区间预测研究,

对提升电网运行安全性、优化资源配置效率具有重要意义^[8-9].

区间预测作为不确定性量化的有效工具,利用统计学和机器学习技术估计特定置信水平下目标值的上下界,为电力系统提供可靠的不确定性量化依据.区间预测方法依据误差分布假设的差异性,可分为参数估计法与非参数估计法^[10-11].参数估计法通过假设误差的概率分布模型构建预测区间,典型方法包括 Beta 分布拟合^[12-13]、高斯过程回归^[14]等.Zhang 等^[15]提出一种基于 Lorenz 扰动分布的区间预测方法,引入 Lorenz 扰动项量化电力负荷的不确定因素,实现电力负荷的区间预测.结果表明,该方法能够有效描述负荷波动幅度和趋势,为不确定性量化提供了概率性描述.Lu 等^[16]设计一种基于层次贝叶斯的区间预测模型,利用拉普拉斯分布替代高斯分布捕捉系统误差的左偏特性,显著提升了区间预测精度.Wan 等^[17]提出一种基于高斯过程回归的区间预测方法,利用平方指数核函数表征预测误差分布的不确定性,实现了关键指标的区间预测.周平等^[18]提出一种基于 Stacking 学习的区间预测方法,利用高斯核函数计算建模误差集的标准差,将其叠加于预测输出以获取区间上下界,实现时间序列预测区间的构建.仿真结果证明,所提方法能够获得可靠的预测区间.然而,上述方法高度依赖预设概率分布与实际数据特性的匹配度.若实际误差分布与预设分布偏差过大,易导致预测区间覆盖度不足,降低模型性能^[19-20].

非参数估计法无需预设误差分布形式,利用数据驱动机制直接从数据中挖掘不确定性规律,生成预测区间.该类方法在处理电力负荷序列数据时具有自适应性^[21-22].例如,Guan 等^[23]提出一种基于上下界估计的区间预测模型,利用多输入双输出的多层感知器模拟电力负荷潜在的波动范围边界,实现了负荷的区间预测.He 等^[24]提出一种基于神经网络的区间预测方法,利用小波神经网络捕捉电力负荷序列的时间特征,确定负荷区间上下界.然而,该方法将上、下边界视为独立变量进行建模,忽略边界之间的关联性,易导致区间宽度估计失准,降低了区间估计的可靠性^[25].为弥补边界关联性建模的不足,基于方差估计的区间预测方法得到广泛研究^[26-27].Xu 等^[28]提出一种基于神经网络的区间预测模型,该方法利用蒙特卡洛方法估计输出误差的置信区间,捕捉系统不确定性,提升了负荷区间预测的准确性和可靠性.Tang 等^[29]提出一种基于误差的预测方法,利用门控循环单元构建区间预测模型,同步输出目标变量的预测值及预测误差,通过叠加策

略生成预测区间.Zhou 等^[30]提出一种基于最优边界椭圆学习算法的长短期记忆神经网络区间预测方法,利用最优边界椭圆学习算法将输出预测值扩展为不确定性区间,实现区间估计.实验结果表明,该方法能够获得覆盖率高、间隔宽度窄的预测区间.Zhang 等^[31]设计一种基于强化学习的负荷区间预测方法,利用强化学习框架执行分位数比例选择和分位数估计任务,通过将分位数对应的预测结果直接映射为电力负荷预测区间的下界与上界,实现电力负荷的区间预测.然而,上述方法缺乏不确定性传递机制,难以满足高可靠性场景下对区间预测的性能要求^[32-33].二型模糊神经网络通过将模糊规则从确定性数值扩展到连续模糊区间,增强了对复杂非线性关系的表征能力,能够有效处理时间序列的不确定性,已成为一种通用的非参数区间预测方法^[34].Khanesar 等^[35]设计一种基于二型模糊逻辑系统的区间预测方法,利用二型模糊集刻画输入变量的不确定性边界,通过规则推理获取区间结果.Liu 等^[36]提出一种二型模糊粒度神经网络,利用粒间关联度优化区间生成过程,提升了预测区间与实际波动的一致性.然而,二型模糊神经网络通常采用静态规则库,导致误差的置信区间缺乏动态调整机制,难以适配电力负荷的动态演化特性.因此,构建兼具自适应性与可靠性的动态预测区间是当前研究的核心挑战.

为此,本文通过分析电力负荷的不确定性来源及其对建模的影响,提出元认知二型模糊神经网络(metacognitive type-2 fuzzy neural network, MCT2FNN),以实现负荷区间预测.该方法主要有以下优势:

- 1) 针对电力负荷数据强非线性与不确定性耦合特性,提出一种基于多值映射的二型模糊规则.该规则通过区间隶属函数描述模糊集的变化范围,有效表征变量间的非线性关系并捕捉电力负荷序列数据的内在不确定性.

- 2) 为提高二型模糊神经网络建模电力负荷的能力,设计一种误差补偿机制调整模型参数,结合网络内部的自适应参数调整和外部的误差补偿机制共同提高模型性能.该机制利用动态反馈结构,实现模型输出点的自适应补偿,显著提高模型对电力负荷的预测精度.

- 3) 面向电力负荷区间预测的实际需求,提出一种元认知学习算法自适应优化输出区间的上下界估计值,实现动态输出区间的构建.该算法根据电力负荷波动规律,捕捉过程变化趋势并量化不确定性幅度.通过动态调整区间宽度,提高预测区间宽度

与时序波动的匹配度, 获得兼具高覆盖性与紧致性的预测区间。

1 电力负荷序列特性分析

电力负荷序列呈现出显著的非线性与不确定性特征^[32]。

1.1 非线性

电力负荷序列的非线性本质源于其动态趋势与变量关联关系的复杂性, 具体表现为^[3-5]:

1) 动态趋势非线性. 电力负荷序列的演化趋势并非呈现线性增长或衰减, 而是受多重因素交互影响或系统模式突变, 表现出非均匀、非稳态的非线性特征, 如指数增长、周期性波动叠加趋势项、阶段性饱和等。

2) 变量关联关系非线性. 电力负荷序列系统中变量关联关系可能呈现阈值效应、滞后反馈或多变量交互形成的复杂耦合效应, 导致其表现出非线性特征. 由于电力负荷序列中各时刻观测值与其影响因素之间存在复杂的非线性依赖关系, 线性模型或静态函数难以准确刻画其动态演化规律。

1.2 不确定性

电力负荷序列不确定性源于系统内、外部的动态耦合作用, 具体体现为^[3-5]:

1) 环境与用户行为的不确定性. 该类不确定性是负荷波动的主要诱因, 表现为环境因素的随机干扰与用户用电行为的不可控性. 随机性环境因素(如突发事件、系统噪声)通过非线性传递路径作用于时间序列生成过程, 导致过程变量波动, 增加了负荷序列的不确定性。

2) 负荷序列生成模式的不确定性. 序列生成模式的不确定性源自电力系统内在演化机制的动态漂移, 即序列的统计特性随时间逐渐或突然变化. 序列生成模式的不确定性可以表示为

$$f_m(\cdot) = f_m^0(\cdot) + \varepsilon_m \quad (1)$$

其中, $f_m(\cdot)$ 为负荷序列在第 m 个模式下的生成函数; $f_m^0(\cdot)$ 为该模式的理想表征; ε_m 为第 m 个生成模式的不确定性; $m = 1, \dots, M$, M 为电力负荷序列包含的模式总数。

3) 采集和建模误差. 电力负荷序列的采集过程受传感器精度、采样频率、传输损耗等因素影响, 测量结果往往存在不确定性, 这可以表示为

$$\mathbf{X}(t) = \mathbf{X}_0(t) + \varepsilon_X(t) \quad (2)$$

其中, $\mathbf{X}(t)$ 为变量的测量值; $\mathbf{X}_0(t)$ 为变量的真实

值; $\varepsilon_X(t)$ 为不确定性。

针对电力负荷序列建模时, 由于对其生成机制的认知有限, 模型难以完全拟合变量间的真实关系. 将过程变量 $\mathbf{X}(t)$ 映射到非线性函数 $g(\cdot)$ 上, 表示为

$$\begin{aligned} \hat{y}(t) &= g(\mathbf{X}_0(t)) + \varepsilon(t) = \\ &g(\mathbf{X}(t) - \varepsilon_X(t)) + \varepsilon(t) \end{aligned} \quad (3)$$

其中, $\hat{y}(t)$ 为 t 时刻电力负荷的实际检测值; $\varepsilon(t)$ 为不确定性因素导致的误差项。

数据驱动模型旨在拟合过程变量 $\mathbf{X}(t)$ 与关键指标 $y(t)$ 之间的非线性关系, 表示为

$$y(t) = f(\mathbf{X}(t), \Phi(t)) \quad (4)$$

其中, $f(\cdot)$ 为过程变量与关键指标的非线性关系; $y(t)$ 为数据驱动模型 t 时刻的输出; $\Phi(t)$ 是数据驱动模型 t 时刻的参数。

由于电力负荷序列具有非线性与不确定性耦合特性, 数据驱动模型难以准确刻画其动态变化, 缺乏置信边界表征能力, 导致模型的准确性不足. 因此, 考虑上述不确定性因素, 采用区间预测方法动态捕捉不确定性传播路径并量化不确定性, 获得关键指标的预测区间 $[y_L(t), y_U(t)]$, 其中 $y_L(t)$ 和 $y_U(t)$ 分别为 t 时刻关键指标的区间下界与区间上界估计值。

2 基于元认知二型模糊神经网络的电力负荷区间预测

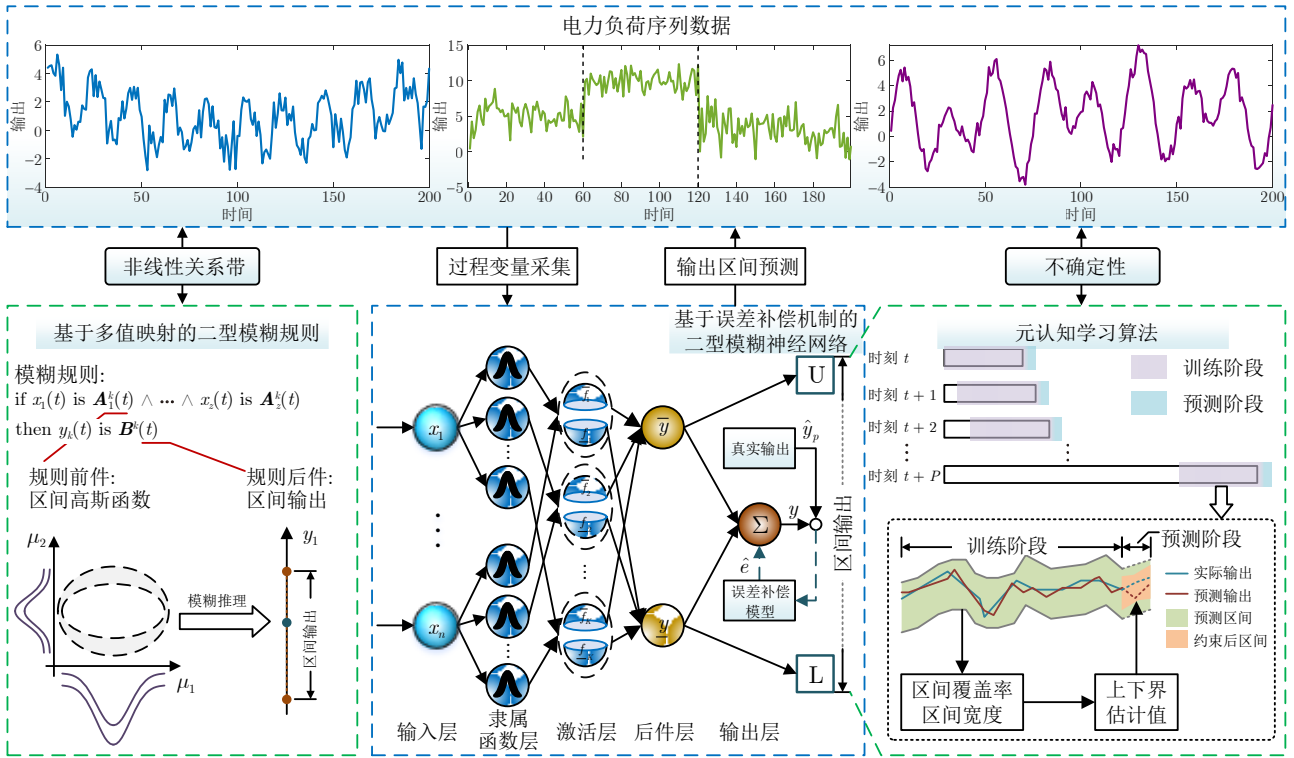
针对电力负荷序列的非线性和不确定性导致关键指标难以准确预测的问题, 本文设计一种基于元认知二型模糊神经网络的区间预测方法, 该方法的总体结构如图 1 所示。

2.1 基于多值映射的二型模糊规则

针对电力负荷序列中非线性和生成环节及测量环节的不确定性, 本文提出一种基于多值映射的二型模糊规则, 表征时间序列变量间的非线性关系带和不确定性. 该规则可以用“if-then”表示为

$$\begin{aligned} \text{if } x_1(t) \text{ is } \mathbf{A}_1^k(t) \wedge \dots \wedge x_z(t) \text{ is } \mathbf{A}_z^k(t) \\ \text{then } y_k(t) \text{ is } \mathbf{B}^k(t) \end{aligned} \quad (5)$$

其中, $k = 1, 2, \dots, K$, K 是二型模糊规则的数量; \wedge 表示模糊合取算子; $y_k(t)$ 是第 k 条二型模糊规则; $\mathbf{B}^k(t)$ 是区间输出集; $\mathbf{A}_z^k(t)$ 是第 k 条二型模糊规则中第 z 个输入变量的模糊集合. $\mathbf{A}_z^k(t)$ 对应的区间隶属函数包括上隶属函数 $\bar{\mu}_{ik}(t)$ 和下隶属函数 $\underline{\mu}_{ik}(t)$, 表示为



注: μ_1 和 μ_2 分别表示第 1 个输入和第 2 个输入对应的隶属函数, U 和 L 分别表示区间上界和下界, 电力负荷序列数据的采样间隔为 15 min.

图 1 基于元认知二型模糊神经网络的电力负荷区间预测方法

Fig.1 Interval prediction method of power load based on metacognitive type-2 fuzzy neural network

$$\bar{\mu}_{ik}(t) = \begin{cases} e^{-\frac{(x_i(t)-\underline{c}_{ik}(t))^2}{2\sigma_{ik}^2(t)}}, & x_i(t) \leq \underline{c}_{ik}(t) \\ 1, & \underline{c}_{ik}(t) < x_i(t) \leq \bar{c}_{ik}(t) \\ e^{-\frac{(x_i(t)-\bar{c}_{ik}(t))^2}{2\sigma_{ik}^2(t)}}, & x_i(t) > \bar{c}_{ik}(t) \end{cases} \quad (6)$$

$$\underline{\mu}_{ik}(t) = \begin{cases} e^{-\frac{(x_i(t)-\bar{c}_{ik}(t))^2}{2\sigma_{ik}^2(t)}}, & x_i(t) \leq \frac{\bar{c}_{ik}(t) + \underline{c}_{ik}(t)}{2} \\ e^{-\frac{(x_i(t)-\underline{c}_{ik}(t))^2}{2\sigma_{ik}^2(t)}}, & x_i(t) > \frac{\bar{c}_{ik}(t) + \underline{c}_{ik}(t)}{2} \end{cases} \quad (7)$$

其中, $x_i(t)$ 是 t 时刻第 i 个变量的输入变量; $\bar{c}_{ik}(t)$, $\underline{c}_{ik}(t)$ 和 $\sigma_{ik}(t)$ 是 t 时刻第 k 个二型模糊规则第 i 个变量的上中心、下中心和宽度; e 为自然指数函数.

$B^k(t)$ 对应的区间输出包括上输出 $y_{1k}(t)$ 和下输出 $y_{2k}(t)$, 计算为

$$y_{1k}(t) = \prod_{i=1}^z \bar{\mu}_{ik}(t) \quad (8)$$

$$y_{2k}(t) = \prod_{i=1}^z \underline{\mu}_{ik}(t) \quad (9)$$

基于多值映射的二型模糊规则的输入为 z 个变量 $(x_1(t), x_2(t), \dots, x_z(t))$, 输入维度为 z . 输入变量定义域为 $D_x = [0, 1]$, 规则数量定义域为 $D_k = \{1, 2, \dots, K\}$. 基于式 (6) ~ (7), 上隶属函数和下隶属函数值域均为 $D_\mu = [0, 1]$; 规则的输出变量为区间向量 $[y_{2k}(t), y_{1k}(t)]$, 输出维度为 2; $y_{1k}(t)$ 和 $y_{2k}(t)$ 的值域均为 $D_y = [0, 1]$.

首先, 基于多值映射的二型模糊规则利用二型高斯函数拟合序列变量间关联关系, 捕捉变量间非线性关系. 其次, 模糊规则引入区间隶属函数, 通过对输入的模糊集进行分布建模, 有效刻画了输入变量的不确定性. 同时, 模糊规则通过多维输入空间到区间输出空间的映射 ($\mathbf{R}^z \rightarrow \mathbf{R}^2$) 表征变量关联关系的波动范围. 最后, 通过模糊推理估计输出区间, 在准确捕捉变量间的非线性关联特征的同时, 全面覆盖不确定性引起的变化范围, 实现变量关联偏差的处理.

2.2 基于误差补偿机制的二型模糊神经网络

为实现电力负荷序列关键指标的预测, 本文建立一种基于误差补偿机制的二型模糊神经网络, 利用梯度下降算法实现二型模糊神经网络参数的自适应更新. 此外, 该网络引入误差补偿机制以评估模

型学习性能并补偿模型预测偏差.

2.2.1 二型模糊神经网络

二型模糊神经网络结构如下:

输入层. 输入层由 z 个神经元组成, 用于获取电力负荷序列中的关键特征变量, 可以将负荷数据传递到网络的下一层. 该层输出为

$$x_i(t) = u_i(t) \quad (10)$$

其中, $i = 1, \dots, z$, z 是输入变量的个数, 由过程变量的数量决定; $u_i(t)$ 为负荷相关的第 i 个输入变量.

隶属函数层. 隶属函数层由 K 个神经元组成, 通过区间隶属函数描述输入变量的不确定性, 将输入数据转换为模糊值. 该层表达式如式 (6) ~ (7) 所示.

激活层. 激活层由 K 个神经元组成, 通过“与操作”将不同输入变量的隶属度进行组合运算, 生成每条模糊规则的激活度. 该层数学表达式如式 (8) ~ (9) 所示.

后件层. 后件层由 2 个神经元组成, 用于处理激活层的输出, 生成区间输出值. 后件层利用模糊推理将输入变量的模糊化信息结合起来. 该层上界输出和下界输出 $\bar{y}(t)$ 和 $\underline{y}(t)$ 表示为

$$\bar{y}(t) = \frac{\sum_{k=1}^K \left(\sum_{i=1}^z a_{ik}(t)x_i(t) \right) y_{1k}(t)}{\sum_{k=1}^K y_{1k}(t)} \quad (11)$$

$$\underline{y}(t) = \frac{\sum_{k=1}^K \left(\sum_{i=1}^z a_{ik}(t)x_i(t) \right) y_{2k}(t)}{\sum_{k=1}^K y_{2k}(t)} \quad (12)$$

其中, $a_{ik}(t)$ 是第 k 个规则第 i 个变量的权重.

输出层. 输出层将后件层的模糊结果解模糊化. 该层的数学表达式为

$$y(t) = (1 - q(t))\bar{y}(t) + q(t)\underline{y}(t) \quad (13)$$

其中, $y(t)$ 是输出值; $q(t) \in (0, 1)$ 是比例系数.

为实现二型模糊神经网络参数的自适应优化, 损失函数 $L(t)$ 定义如下:

$$L(t) = \frac{1}{2}(\hat{y}(t) - y(t))^2 \quad (14)$$

其中, $\hat{y}(t)$ 是 t 时刻负荷的真实值.

本文采用梯度下降算法, 计算损失函数对参数的梯度, 沿负梯度方向逐步调整网络参数, 最小化损失函数, 获取最优解. 该学习算法的详细过程见文献 [6].

2.2.2 误差补偿机制

为解决序列中非线性和不确定性导致的预测误

差, 误差补偿机制通过分析历史误差的动态规律, 动态补偿预测模型的输出, 提高关键指标点预测的精度. 具体而言, 通过实时监测模型的预测误差, 将预测误差反馈到误差补偿模型中估计校正误差. 然后, 将校正量补偿至二型模糊神经网络, 减少预测误差. 校正误差 $\hat{e}(t)$ 可以表示为

$$\hat{e}(t) = \sum_{p=1}^P [\lambda_p(t-1)(\hat{y}_p(t) - y_p(t))] \quad (15)$$

其中, P 是滑窗内训练样本的个数; $\lambda_p(t-1)$ 是 $t-1$ 时刻第 p 个校正因子; $y_p(t)$ 是 t 时刻第 p 个训练样本的输出值; $\hat{y}_p(t)$ 是 t 时刻第 p 个训练样本的真实值. 比例因子 $\lambda(t-1) = [\lambda_1(t-1), \dots, \lambda_P(t-1)]$ 更新为

$$\lambda(t-1) = \hat{e}(t-1)(\mathbf{G}^T(t-1)\mathbf{G}(t-1))^{-1}\mathbf{G}^T(t-1) \quad (16)$$

其中, $\hat{e}(t-1) = [\hat{e}(t-P), \dots, \hat{e}(t-1)]$.

$$\mathbf{G}(t-1) = \begin{bmatrix} e_1(t-P) & \dots & e_1(t-1) \\ \vdots & \ddots & \vdots \\ e_P(t-P) & \dots & e_P(t-1) \end{bmatrix} \quad (17)$$

$$P = \begin{cases} t, & t < P_0 \\ P_0, & t \geq P_0 \end{cases} \quad (18)$$

其中, $e_1(t-1) = \hat{y}_1(t-1) - y_1(t-1)$ 为 $t-1$ 时刻第 1 个训练样本的预测误差; $e_P(t-P) = \hat{y}_P(t-P) - y_P(t-P)$ 为 $t-P$ 时刻第 P 个训练样本的预测误差; $\mathbf{G}(t-1) \in \mathbf{R}^{P \times P}$; P_0 为预设的滑窗内训练样本数.

因此, 基于误差补偿机制的二型模糊神经网络的模型输出 $h(t)$ 为

$$h(t) = y(t) + \hat{e}(t) \quad (19)$$

如图 1 所示, 该机制通过实时监测模型历史真实值 $\hat{y}_p(t)$ 与预测输出 $y_p(t)$ 的差异计算预测误差 $e_p(t)$, 将误差序列反馈至误差补偿模型中获得校正量 $\hat{e}(t)$. 因此, 基于式 (19), 获得校正后的模型输出 $h(t)$.

该机制的核心思想是利用历史误差和当前预测误差的相关性, 动态调整误差补偿模型的参数, 弥补二型模糊神经网络的预测误差. 该方法利用网络内部参数自适应迭代和外部动态误差反馈校准的双驱动调节策略, 实现对输出变量的精确预测.

2.3 元认知学习算法

针对电力负荷序列中建模环节的不确定性, 本文设计一种基于区间覆盖率和区间宽度的元认知学

习算法, 动态调整预测区间的上下界以适应序列中的数据波动, 实现关键指标的区间预测.

2.3.1 预测区间评估指标

预测区间评估指标包括区间覆盖率 (interval coverage probability, ICP) 和区间宽度 (interval width, IW), 表达式为

$$\text{ICP}(t) = \frac{1}{P} \sum_{p=1}^P r_p \quad (20)$$

$$r_p = \begin{cases} 1, & y_p(t) \in [\eta_1(t)\underline{y}_p(t), \eta_2(t)\bar{y}_p(t)] \\ 0, & y_p(t) \notin [\eta_1(t)\underline{y}_p(t), \eta_2(t)\bar{y}_p(t)] \end{cases} \quad (21)$$

其中, $p = 1, 2, \dots, P$; r_p 为 t 时刻第 p 个样本的区间归属指示函数; $\eta_1(t)$ 和 $\eta_2(t)$ 为 t 时刻估计系数. 若 $\eta_1(t) = 1, \eta_2(t) = 1$, 则表示无缩放, 输出区间宽度由模型原始不确定性决定; 若 $\eta_1(t) < 1, \eta_2(t) < 1$, 则会缩小区间宽度, 增强区间紧致性; 若 $\eta_1(t) > 1, \eta_2(t) > 1$, 则会扩大区间宽度, 提高区间覆盖率.

$$\text{IW}(t) = \frac{\sum_{p=1}^P [\eta_2(t)\bar{y}_p(t) - \eta_1(t)\underline{y}_p(t)]}{P \left(\max_{p=1, \dots, P} y_p(t) - \min_{p=1, \dots, P} y_p(t) \right)} \quad (22)$$

ICP 定义为实际输出值在预测区间内的比例. 高覆盖率说明预测区间能够有效涵盖输出变量的实际变化范围, 是保障区间预测可信度的关键指标. IW 指预测区间上下界的差值. 较窄的 IW 代表预测区间具有更高的紧致性, 可为调控提供明确的数值参考; 过宽的 IW 由于信息模糊, 失去对实际调控的指导意义. 模型的学习目标是通过调整预测模型的参数, 使得 ICP 达到预设值, 保证预测区间的可信度. 在保证 ICP 满足需求的前提下, 尽可能减小预测区间宽度, 提高预测的精度和实用性.

2.3.2 基于元认知的学习算法

为满足学习目标并确保预测区间的合理性, 本文提出基于元认知的学习算法自适应优化输出区间的上下界估计值.

1) 学习算法

由于学习目标具有离散性, 无法求导, 因此基于梯度类算法无法求解. 为此, 本文设计基于元认知的粒子群优化算法来更新参数. 第 i 个粒子表示为

$$\boldsymbol{\theta}_i(t-1) = [\eta_{i,1}(t-1), \eta_{i,2}(t-1)] \quad (23)$$

粒子更新公式为

$$\begin{aligned} \mathbf{v}_i(t) &= \kappa \mathbf{v}_i(t-1) + d_1 r_1 (\boldsymbol{\theta}_i(t-1) - \boldsymbol{\theta}_{i,p}(t-1)) + \\ & d_2 r_2 (\boldsymbol{\theta}_i(t-1) - \boldsymbol{\theta}_g(t-1)) \end{aligned} \quad (24)$$

$$\boldsymbol{\theta}_i(t) = \boldsymbol{\theta}_i(t-1) + \mathbf{v}_i(t) \quad (25)$$

其中, $\mathbf{v}_i(t)$ 为 t 时刻第 i 个粒子的更新速度; κ 为惯性权重; $d_1 = 2$ 为自我认知系数; $d_2 = 2$ 为社会认知系数; r_1 和 r_2 为区间 $(0, 1)$ 的随机数; $\boldsymbol{\theta}_g(t-1)$ 为 $t-1$ 时刻全局最优粒子; $\boldsymbol{\theta}_{i,p}(t-1)$ 为 $t-1$ 时刻第 i 个粒子的个体最优粒子; $i = 1, \dots, I, I$ 为粒子数量.

适应度函数为 ICP 与 IW 的复合函数, 定义为

$$\text{CI}(t) = -\text{ICP}(t)(1 - \text{IW}(t)) \quad (26)$$

通过多次迭代, 不断更新粒子的位置和速度, 逐步逼近最优解.

2) 元认知策略

在电力负荷序列关键指标预测中, 预测区间的上下界具有明确的物理意义: 上界表示关键指标可能达到的最高值, 下界表示关键指标可能达到的最低值. 因此, 确保预测区间的上界始终大于下界符合实际意义, 也能避免预测误差带来的不合理结果. 为实现这一目标, 本文引入元认知策略, 动态调节预测区间的上下界. 为确保预测区间的上界大于下界, 利用元认知策略对预测区间进行监控和修正: 当检测到预测区间不合理时, 元认知策略将自动调整预测区间的上下界, 保证上界大于下界.

情况 1. 针对第 i 个粒子, 若滑窗内所有样本满足 $\eta_2(t)\bar{y}_p(t) < \eta_1(t)\underline{y}_p(t)$, 当 $\forall p \in \{1, \dots, P\}$ 时, 式 (25) 为

$$\boldsymbol{\theta}_i(t) = \boldsymbol{\theta}_i(t-1) \quad (27)$$

情况 2. 若滑窗内部分样本满足 $\eta_2(t)\bar{y}_p(t) < \eta_1(t)\underline{y}_p(t)$, 当 $\exists p \in \{1, \dots, P\}$ 时, 式 (25) 为

$$\boldsymbol{\theta}_i(t) = [\eta_{i,1}(t), \eta_{i,2}(t)] \quad (28)$$

$$\begin{cases} \eta_{i,1}(t) = \eta_{i,1}(t) \\ \eta_{i,2}(t) = \eta_{i,2}(t) + \frac{\max_{p \in \{1, \dots, P\}} (\eta_1(t)\underline{y}_p(t) - \eta_2(t)\bar{y}_p(t))}{\bar{y}_p(t)} \end{cases} \quad (29)$$

在预测区间优化过程中, 引入元认知策略, 实时监测和修正预测区间的上下界. 该策略通过历史粒子与实时时序特征的融合分析, 避免机械校正预测区间导致的参数偏离优化目标, 为后续预测区间寻优提供合适的参数.

为构建基于元认知二型模糊神经网络的区间预

测模型, 算法 1 给出网络学习过程的伪代码。

算法 1. 网络学习过程

- 1) 初始化. 样本数量 N , 二型模糊神经网络规则数 K , 随机初始化隶属函数上中心、下中心、宽度、权重和比例系数, 滑窗内训练样本的个数 P_0 , 最大迭代次数 S , 参数更新过程学习率, 粒子数量 I , $\lambda_p(0) = 1/P_0$, 当前时刻 $t = 1$;
- 2) for $t = 1 : N - P_0$
- 3) for $p = 1 : P$
- 4) 根据式 (6) ~ (13) 计算输出 $y_p(t)$;
- 5) 计算区间二型模糊神经网络参数的导数;
- 6) 利用梯度下降算法更新参数;
- 7) end
- 8) 根据式 (6) ~ (13) 计算输出 $y_1(t), \dots, y_P(t)$;
- 9) 根据式 (15) 计算误差补偿模型的校正误差 $\hat{e}(t)$;
- 10) 根据式 (19) 计算模型输出 $h(t)$;
- 11) 根据式 (16) ~ (18) 更新比例因子 $\lambda(t - 1)$;
- 12) for $i = 1 : I$
- 13) 根据式 (26) 计算第 i 个粒子的适应度;
- 14) 更新第 i 个个体最优粒子 $\theta_{i,p}(t)$;
- 15) end
- 16) 更新全局最优粒子 $\theta_g(t)$;
- 17) 根据式 (24) ~ (25) 更新粒子;
- 18) if $\eta_2(t)\bar{y}_p(t) < \eta_1(t)y_p(t), \forall p \in \{1, \dots, P\}$
- 19) 根据式 (27) 更新粒子;
- 20) else if $\eta_2(t)\bar{y}_p(t) < \eta_1(t)y_p(t), \exists p \in \{1, \dots, P\}$
- 21) 根据式 (28) ~ (29) 更新粒子;
- 22) end
- 23) 获取区间上界 $\eta_2(t)\bar{y}_p(t)$ 和下界 $\eta_1(t)y_p(t)$;
- 24) end

3 实验结果及分析

为了验证方法有效性, 本文基于某地区历史电力负荷数据进行模拟和比较. 所有实验均在 Microsoft Windows10 环境下, 使用 MATLAB 2022b 构建自定义函数和训练元认知二型模糊神经网络. 硬件配置包括 Intel Core Ultra9 处理器, 32 GB RAM, 2.9 GHz 时钟频率的高性能计算机.

3.1 实验设置

1) 数据采集

电力负荷数据采用加利福尼亚大学尔湾分校机器学习数据库中的摩洛哥得土安市某配电网数据^[37]. 输入变量为温度 ($^{\circ}\text{C}$)、湿度 (%)、风速 (m/s)、平均扩散流 (m^3/s)、实时扩散流 (m^3/s), 输出变量为 2 区电力负荷 ($\times 10 \text{ MW}$), 变量采集周期为 1 h.

2) 数据预处理

a) 数据清洗. 去除异常值, 利用基于邻近数据点的平均值填补缺失值.

b) 归一化处理. 将所有输入变量和输出变量进行归一化处理, 使其值域位于 $[0, 1]$ 之间, 以消除不同量纲对模型训练的影响.

3) 模型参数设置

针对二型模糊神经网络的参数, 上中心、下中心、权重和比例系数在区间 $[0, 1]$ 内随机选择, 宽度设置为 1, 规则数为 4. 针对误差补偿机制, 梯度下降算法的更新迭代次数设置为 50 次, 初始学习率为 0.015, 初始校正因子 $\lambda_p(0) = 1/P_0$. 为确定合适的滑动窗口大小 P , 本文对比滑动窗口大小分别为 12、24、36、48、60、72 个样本时的仿真结果, 图 2 显示了数据集在不同滑动窗口大小下的预测性能. 误差棒通过预测 R^2 (R-squared) 在 20 次独立实验下的均值 \pm 标准差进行量化, 反映了结果的波动范围. 结果表明, 滑动窗口尺寸对所提方法的性能有较大影响. 当滑动窗口大小为 24 时, 其预测性能达到最佳且稳定性最强. 此外, 电力负荷数据 (负荷的波动规律、变量关联关系等) 呈现 24 小时日周期特性, 可完整覆盖 1 日的“谷-峰-平”全阶段负荷模型. 因此, 在本实验中, 滑动窗口大小设置为 24, 可以适配电力负荷日内模式的动态性. 本研究采用动态滑动窗口策略进行数据集划分, 通过固定长度的滑动窗口在时间序列上连续移动, 实现训练集与测试集的动态划分. 在每个预测时刻, 模型利用窗口内的历史数据进行训练, 并对下一时刻的负荷值进行预测, 随后窗口向后滑动一个时间步长, 重复上述过程.




图 2 不同滑窗下的性能比较

Fig. 2 The performance comparison under different sliding windows

针对元认知学习算法, 设置迭代次数为 100, 粒子数量为 100, 惯性权重为 1. 由于日内负荷峰谷差通常在 30% ~ 50% 范围内, 同时避免产生 $\eta_1(t)$ 和 $\eta_2(t)$ 小于 0 或 $\eta_1(t)$ 和 $\eta_2(t)$ 大于 2 等不合理的极端值, 设置粒子范围为 [0.5, 1.5], 确保优化过程的稳定性和物理意义合理性.

4) 评价指标

为了准确评估方法性能, 本文利用均方根误差 (root mean squared error, RMSE)、拟合度 (R-squared, R^2)、平均绝对百分比误差 (mean absolute percentage error, MAPE)、ICP、IW、基于适应度函数的复合指标 (composite indicator, CI) 和区间拟合度 (interval R-squared, IR^2) 进行评估.

a) RMSE. 衡量预测值与实际值之间的平均误差, 对较大误差敏感.

$$RMSE = \sqrt{\frac{1}{P} \sum_{p=1}^P (\hat{y}_p(t) - h_p(t))^2} \quad (30)$$

其中, $h_p(t)$ 为模型预测值.

b) R^2 . 衡量模型的好坏, 值越接近 1 表示模型对数据的拟合效果越好.

$$R^2 = 1 - \frac{\sum_{p=1}^P (\hat{y}_p(t) - h_p(t))^2}{\sum_{p=1}^P (\hat{y}_p(t) - y_0(t))^2} \quad (31)$$

其中, $y_0(t)$ 为真实值的平均值.

c) MAPE. 度量预测值与实际值之间的平均绝对误差, 提供对预测结果总体误差水平的直观衡量.

$$MAPE = \frac{1}{P} \sum_{p=1}^P \left| \frac{\hat{y}_p(t) - h_p(t)}{\hat{y}_p(t)} \right| \quad (32)$$

ICP, IW 和 CI 根据式 (20), (22) 和 (26) 计算.

d) IR^2 . 衡量预测区间的好坏, 值越接近 1 表示区间对数据的覆盖效果越好.

$$IR^2 = 1 - \frac{\sum_{p=1}^P \min(Er_{1p}(t), Er_{2p}(t))}{\sum_{p=1}^P (\hat{y}_p(t) - \bar{h}(t))^2} \quad (33)$$

其中, \bar{h} 为模型预测值的平均值.

$$\begin{cases} Er_{1p}(t) = (\eta_2(t)\bar{y}_p(t) - h_p(t))^2 \\ Er_{2p}(t) = (\eta_1(t)\underline{y}_p(t) - h_p(t))^2 \end{cases} \quad (34)$$

3.2 电力负荷实验及结果分析

1) 点预测实验结果

为了验证误差补偿机制的有效性, 本文利用电

力负荷序列数据集比较了五种模型, 包括 MCT2FNN (模型 1)、缺乏误差补偿机制的二型模糊神经网络 (模型 2)、一型模糊神经网络 (type-1 fuzzy neural network, FNN)^[32]、基于经验模态分解的长短期记忆神经网络 (empirical mode decomposition-long short term memory, EMD-LSTM)^[38] 和支持向量机 (support vector machine, SVM)^[39].

图 3 ~ 5 展示了模型 1 和模型 2 的实验结果. 由于模型 1 和模型 2 共享训练阶段的优化框架, 两个模型的训练 RMSE 曲线一致, 如图 3 所示, 根据电力负荷数据特性, 模型的训练 RMSE 呈现动态调整趋势. 从图 4 中可以看出, 模型 1 的预测输出




图 3 电力负荷点预测过程的训练 RMSE

Fig.3 The training RMSE of the point prediction process of power load




图 4 电力负荷点预测过程的测试预测输出

Fig.4 The testing prediction output of the point prediction process of power load




图 5 电力负荷点预测过程的测试预测误差

Fig.5 The testing prediction error of the point prediction process of power load

曲线更紧密贴合真实值的波动特征. 相比于模型 2, 模型 1 由于引入了误差补偿机制, 在负荷峰值、谷值区间的拟合精度更优. 图 5 中, 模型 1 利用误差补偿机制实现大幅误差的主动补偿 (第 101 ~ 130 个样本) 和小幅偏差的精细修正 (第 1 ~ 20 个样本), 证明了该方法在提升预测精度上的优势.

此外, 表 1 展示了模型 1、模型 2、FNN^[32]、EMD-LSTM^[38] 和 SVM^[39] 在测试 RMSE、测试 R² 及测试 MAPE 上的结果. 其中, 平均值 (mean value, Mean) 与标准差 (standard deviation, Dev.) 分别用于评估模型预测的平均值与离散程度, 最小值 (minimum value, Min) 与最大值 (maximum value, Max) 分别界定模型性能的上下界. 为清晰量化误差补偿机制的贡献, 模型 1 与模型 2 的性能差异如下: 模型 1 的测试 RMSE 均值较模型 2 降低 15.0%, 测试 MAPE 均值降低 18.0%. 因此, 误差补偿机制利用动态反馈校正因子 $\lambda_p(t-1)$, 有效抑制了峰谷时段的预测偏差. 基于表 1, 模型 1 具有最小测试 RMSE 均值 (0.1097)、最小测试 MAPE 均值 (0.0418) 和最大测试 R² 均值 (0.9002), 表明模型

1 引入误差补偿机制可以显著提高模型的预测精度. 在 20 次实验结果中, 模型 1 的最大测试 RMSE (0.1420)、最大测试 MAPE (0.0467) 和最小测试 R² (0.8356) 均优于其他方法, 说明了误差补偿机制在参数随机初始化偏差等情况下可以有效约束模型, 校正模型预测误差, 保障所提方法的预测可靠性. 此外, 为客观比较不同模型的综合性能, 图 6 展示了各模型之间的临界差异 (critical difference, CD) 图. 该图利用弗里德曼检验, 检验水平为 0.05, 临界距离为 1.4795. 图中横轴为平均排名, 数值越低表示综合性能越优. 所提方法 MCT2FNN 显示出最佳的整体性能.

2) 区间预测实验结果

为验证所提方法的区间预测有效性, 本文将四种模型进行对比, 包括模型 1、缺乏元认知算法的二型模糊神经网络 (模型 3)、基于模糊策略和神经网络的组合模型 FS-NN (combined interval prediction system based on fuzzy strategy and neural network)^[40] 和基于修正模糊预测区间的模型 MFPI (modified fuzzy prediction interval)^[41]. 图 7 ~ 9 呈现了模型 1 和模型 3 在电力负荷区间预测任务中的训练 CI 变化趋势、测试预测区间覆盖情况及预测区间边界误差. 从图 7 可见, 随训练进程推进, 训练 CI 呈现动态波动, 展示了模型对时变数据特征的持续学习与参数自适应调整过程. 根据图 8 ~ 9, 模型 1 的预测区间不仅有效覆盖真实值的峰谷波动, 且区间宽度与数据波动幅度适配性更优; 模型 3 由于区间过窄导致真实值频繁溢出预测区间. 此外, 模型 3 存在大量上界值小于下界值的情况, 导致预测区间失去意义, 丧失预测可信度. 因此, 模型 1 利用元认知算法平衡了区间覆盖性和精度, 具有良好的区间预测能力.

此外, 表 2 评估了四个模型的 ICP、IW、CI 及 IR². 模型 1 在多项关键指标中均展现出显著优势. 具体而言, 模型 1 的 IW 均值 (0.0014) 和标准差 (0.0007) 较小, 说明其区间宽度控制合理且稳定性良好. 模型 1 的 ICP 均值较模型 3 提升 538.0%, 解决了模

表 1 不同模型性能比较 (点预测结果)

Table 1 The performance comparison of different models (Point prediction results)

模型	测试 RMSE			测试 R ²			测试 MAPE		
	Mean	Dev.	Max	Mean	Dev.	Min	Mean	Dev.	Max
模型 1	0.1097	0.0141	0.1420	0.9002	0.0269	0.8356	0.0418	0.0022	0.0467
模型 2	0.1291	0.0151	0.1646	0.8621	0.0334	0.7789	0.0510	0.0036	0.0570
FNN ^[32]	0.1526	0.0142	0.1748	0.8077	0.0351	0.7497	0.0561	0.0036	0.0624
EMD-LSTM ^[38]	0.1721	0.0111	0.1942	0.7575	0.0311	0.6923	0.0802	0.0065	0.0940
SVM ^[39]	0.2370	—	0.2370	0.5420	—	0.5420	0.1248	—	0.1248




图 6 电力负荷点预测的 CD 图

Fig.6 The CD diagram of the point prediction of power load




图 7 电力负荷区间预测过程的训练 CI

Fig.7 The training CI of the interval prediction process of power load

型 3 因区间过窄导致的覆盖性失效问题. 模型 1 的 IR^2 均值比模型 3 提升了 5.6%, 反映模型 1 对非线性动态趋势的跟踪能力与拟合精度显著增强. 模型 3 由于缺乏元认知算法, 对动态特性的适配能力大幅下降, 区间预测性能不稳定. 通过对比模型 1 和模型 3 的实验结果, 量化了元认知学习算法的有效性. 虽然模型 1 的 ICP 均值 (0.7835) 和 CI 均值 (-1.5652) 指标略差于 MFPI, 但模型 1 的 IR^2 均值 (0.9676) 远高于 MFPI 和其他模型, 表明模型 1 的预测区间与时序真实波动的贴合度更高, 能精准捕捉电力负荷关键指标的变化规律. 此外, 图 10 展




图 8 电力负荷区间预测过程的测试预测输出

Fig.8 The testing prediction output of the interval prediction process of power load




图 9 电力负荷区间预测过程的测试预测误差

Fig.9 The testing prediction error of the interval prediction process of power load

示了 MCT2FNN、模型 3、FS-NN、MFPI 的统计显著性比较结果. 在检验水平为 0.05 条件下临界距离为 1.1726. MCT2FNN 的排名区间与 FS-NN、模型 3 及 MFPI 均无重叠, 说明 MCT2FNN 在统计

表 2 不同模型性能比较 (区间预测结果)

Table 2 The performance comparison of different models (Interval prediction results)

模型	ICP		IW		CI		IR^2	
	Mean	Dev.	Mean	Dev.	Mean	Dev.	Mean	Dev.
模型 1	0.7835	0.0624	0.0014	0.0007	-1.5652	0.1242	0.9676	0.0150
模型 3	0.1228	0.0576	0.0011	0.0012	-0.2456	0.1152	0.9166	0.0274
FS-NN ^[40]	0.5511	0.1363	0.0023	0.0010	-1.1008	0.2719	0.8291	0.0772
MFPI ^[41]	0.8337	0.0601	0.0013	0.0004	-1.6656	0.1192	0.9222	0.0361




图 10 电力负荷区间预测的 CD 图

Fig.10 The CD diagram of the interval prediction of power load

意义上显著优于其他模型. 因此, MCT2FNN 能够为电力负荷序列提供精确且可靠的预测区间.

4 结束语

针对电力负荷序列关键指标难以准确预测的问题, 本文设计元认知二型模糊神经网络, 实现了关键指标可靠的区间预测. 仿真结果显示, MCT2-FNN 引入误差补偿和元认知算法, 建模结果显著优于其他建模方法. 该方法设计区间隶属函数处理负荷序列的不确定性, 利用二型高斯函数拟合关键指标和过程变量的非线性关系; 提出误差补偿机制, 通过误差反馈自适应调整参数, 实时校正预测偏差, 提升预测准确性; 提出元认知学习算法, 自适应地调整区间的上下界估计值, 确保了关键指标区间预测的可靠性.

然而, 本文方法仍存在一定局限性. 现有模型因包含二型模糊逻辑运算与元认知迭代调整, 整体计算复杂度略高于传统时序预测模型, 难以完全适配低延迟需求的场景. 未来将研究模型轻量化设计, 在保证区间预测精度与置信度的前提下, 减少模型计算量与存储成本, 推动其在实时预测与调控系统中的实际应用.

参考文献

- Cao Li-Feng, Yan Gao-Wei, Xiao Shu-Yi, Dong Zhen-Zhu, Dong Ping. Time series prediction method based on domain adaptation physics-informed neural network. *Acta Automatica Sinica*, 2025, **51**(6): 1329–1346
(曹力丰, 阎高伟, 肖舒怡, 董珍柱, 董平. 基于域适应物理信息神经网络的时间序列预测方法. *自动化学报*, 2025, **51**(6): 1329–1346)
- Guo H Y, Wan M J, Wang L D, Liu X D, Pedrycz W. Weighted fuzzy clustering for time series with trend-based information granulation. *IEEE Transactions on Cybernetics*, 2024, **54**(2): 903–914
- Li X, Li L K, Zhang K S, Chen X M, Feng T, Zhao Y, et al. Multivariate correlation self-distillation transformer for time series forecasting with incomplete data. *IEEE Transactions on Industrial Informatics*, 2025, **21**(6): 4734–4744
- Drovtar I, Leinakse M, Tuttlberg K, Kilter J. Utilizing demand response in load modelling for voltage and reactive power control studies. *IEEE Transactions on Power Systems*, 2025, **40**(2): 1389–1400
- Zhu C L, Ma X L, Ding W P, Zhan J M. Long-term time series forecasting with multilinear trend fuzzy information granules for LSTM in a periodic framework. *IEEE Transactions on Fuzzy Systems*, 2024, **32**(1): 322–336
- Ren G R, Liu J Z, Wan J, Wang W, Fang F, Hong F, et al. Investigating the complementarity characteristics of wind and solar power for load matching based on the typical load demand in China. *IEEE Transactions on Sustainable Energy*, 2022, **13**(2): 778–790
- He Y, Zhang H L, Dong Y C, Wang C, Ma P. Residential net load interval prediction based on stacking ensemble learning. *Energy*, 2024, **296**: Article No. 131134
- Jiang F, Wu B, Wen S P, Tian T H. MSDIPN: Multi-scale deep interval prediction network for multivariate time series. *IEEE Transactions on Knowledge and Data Engineering*, 2025, **37**(9): 5452–5466
- Zhang C X, Fu Y. Probabilistic electricity price forecast with optimal prediction interval. *IEEE Transactions on Power Systems*, 2024, **39**(1): 442–452
- Lv M Z, Wang J Z, Wang S, Wang K, Zhao Y, Gao J L. A multi-input and three-output wind speed point-interval prediction system based on constrained many-objective optimization problem. *Information Sciences*, 2025, **720**: Article No. 122531
- Hu J M, Deng Y W, Che J X. A novel wind power interval prediction method based on neural ensemble search and dynamic conformalized quantile regression. *Applied Soft Computing*, 2025, **180**(15): Article No. 113476
- Palm B G, Bayer F M, Cintra R J. Prediction intervals in the beta autoregressive moving average model. *Communications in Statistics-Simulation and Computation*, 2023, **52**(8): 3635–3656
- Pumi G, Valk M, Bisognin C, Bayer F M, Prass T S. Beta autoregressive fractionally integrated moving average models. *Journal of Statistical Planning and Inference*, 2019, **200**: 196–212
- Acharki N, Bertoncello A, Garnier J. Robust prediction interval estimation for Gaussian processes by cross-validation method. *Computational Statistics & Data Analysis*, 2023, **178**: Article No. 107597
- Zhang Y G, Zhao Y, Pan G F, Zhang J F. Wind speed interval prediction based on Lorenz disturbance distribution. *IEEE Transactions on Sustainable Energy*, 2020, **11**(2): 807–816
- Lu J, Ding J L, Liu C X, Chai T Y. Hierarchical-Bayesian-based sparse stochastic configuration networks for construction of prediction intervals. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, **33**(8): 3560–3571
- Wan X, Li X Y, Wang X Z, Yi X H, Zhao Y Z, He X Z, et al. Water quality prediction model using Gaussian process regression based on deep learning for carbon neutrality in papermaking wastewater treatment system. *Environmental Research*, 2022, **211**: Article No. 112942
- Zhou Ping, Liu Jin-Jin. Prediction of blast furnace hot metal quality interval based on stacking. *Control and Decision*, 2021, **36**(2): 335–344
(周平, 刘进进. 基于 Stacking 的高炉铁水质量区间预测. *控制与决策*, 2021, **36**(2): 335–344)
- Han Z Y, Pedrycz W, Zhao J, Wang W. Hierarchical granular computing-based model and its reinforcement structural learning for construction of long-term prediction intervals. *IEEE Transactions on Cybernetics*, 2022, **52**(1): 666–676
- Peng G Z, Cheng Y L, Wang H W, Shen W M. Industrial IoT-enabled prediction interval estimation of mechanical performances for hot-rolling steel. *IEEE Transactions on Instrumentation and Measurement*, 2022, **71**: Article No. 3508010
- Chen C, Lu N Y, Jiang B, Xing Y, Zhu Z H. Prediction interval estimation of aeroengine remaining useful life based on bidirectional long short-term memory network. *IEEE Transactions on Instrumentation and Measurement*, 2021, **70**: Article No. 3527213
- Wang J, Zhou M, Zhang Q, Li N, Su R. Interval prediction of aeroengine remaining useful life based on BCT-Bayesian bidirectional LSTM network. *IEEE Transactions on Aerospace and Electronic Systems*, 2025, **61**(5): 14344–14355
- Guan S P, Xu C Y, Guan T Y. Multistep interval prediction model with adjustable horizon for uncertain power load forecasting. *Energy*, 2025, **335**: Article No. 137768
- He Y Y, Zhu J H, Wang S. A novel neural network-based multiobjective evolution lower upper bound estimation method for electricity load interval forecast. *IEEE Transactions on Systems*,

Man, and Cybernetics: Systems, 2024, **54**(5): 3069–3083

- 25 Guan S P, Xu C Y, Guan T Y. Multistep power load forecasting using iterative neural network-based prediction intervals. *Computers and Electrical Engineering*, 2024, **119**: Article No. 109518
- 26 He X, Zhao W L, Gao Z J, Zhang Q S, Wang W. A hybrid prediction interval model for short-term electric load forecast using holt-winters and gate recurrent unit. *Sustainable Energy, Grids and Networks*, 2024, **38**: Article No. 101343
- 27 Zhu Q L, Xu Y J, Lin Q Z, Ming Z, Tan K C. Clustering-based short-term wind speed interval prediction with multi-objective ensemble learning. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2025, **9**(1): 304–317
- 28 Xu Y, Li J, Dong Y, Du P. Power load combination forecasting system based on longitudinal data selection. *Engineering Applications of Artificial Intelligence*, 2024, **130**: Article No. 107629
- 29 Tang G, Wu Y F, Li C S, Wong P K, Xiao Z H, An X L. A novel wind speed interval prediction based on error prediction method. *IEEE Transactions on Industrial Informatics*, 2020, **16**(11): 6806–6815
- 30 Zhou M, Zhang Y Y, Wang J, Xue T L. LSTM-OBE based interval prediction of effluent BOD for wastewater treatment. *IFAC-PapersOnLine*, 2023, **56**(2): 8488–8493
- 31 Zhang Y F, Wen H L, Wu Q W, Ai Q. Optimal adaptive prediction intervals for electricity load forecasting in distribution systems via reinforcement learning. *IEEE Transactions on Smart Grid*, 2023, **14**(4): 3259–3270
- 32 Zhang L J, Shi Y, Chang Y C, Lin C T. Robust fuzzy neural network with an adaptive inference engine. *IEEE Transactions on Cybernetics*, 2024, **54**(5): 3275–3285
- 33 Ran X H, Tay W P, Lee C H T. Uncertain interval-based risk dispatch approach of power systems under a unified framework of multiple uncertainties. *IEEE Transactions on Industrial Informatics*, 2025, **21**(3): 2053–2063
- 34 Sun C X, Wu X L, Yang H Y, Han H G, Zhao D Z. Multimodal learning-based interval type-2 fuzzy neural network. *IEEE Transactions on Fuzzy Systems*, 2024, **32**(11): 6409–6423
- 35 Khanesar M A, Branson D T. Prediction interval identification using interval type-2 fuzzy logic systems: Lake water level prediction using remote sensing data. *IEEE Sensors Journal*, 2021, **21**(12): 13815–13827
- 36 Liu Y, Zhao J, Wang W, Pedrycz W. Prediction intervals for granular data streams based on evolving type-2 fuzzy granular neural network dynamic ensemble. *IEEE Transactions on Fuzzy Systems*, 2021, **29**(4): 874–888
- 37 Salam A, El Hibaoui A. Comparison of machine learning algorithms for the power consumption prediction: Case study of Tetouan city. In: Proceedings of the 6th International Renewable and Sustainable Energy Conference. Rabat, Morocco: IEEE, 2018. 1–5
- 38 Zhang Y T, Li C L, Jiang Y Q, Sun L, Zhao R B, Yan K F, et al. Accurate prediction of water quality in urban drainage network with integrated EMD-LSTM model. *Journal of Cleaner Production*, 2022, **354**: Article No. 131724
- 39 Waqas S, Harun N Y, Sambudi N S, Arshad U, Nordin N A H M, Bilad M R, et al. SVM and ANN modelling approach for the optimization of membrane permeability of a membrane rotating biological contactor for wastewater treatment. *Membranes*, 2022, **12**(9): Article No. 821
- 40 Niu Y B, Wang J Z, Zhang Z Y, Yu Y N, Liu J J. A combined interval prediction system based on fuzzy strategy and neural network for wind speed. *Applied Soft Computing*, 2024, **155**: Article No. 111408
- 41 Rafique S F, Zhang J H, Rafique R, Guo J, Jamil I. Renewable generation (wind/solar) and load modeling through modified fuzzy prediction interval. *International Journal of Photoenergy*, 2018, **2018**(1): Article No. 4178286



孙晨暄 华北电力大学控制与计算机工程学院讲师。主要研究方向为神经网络设计与优化, 非线性系统智能建模。

E-mail: sunchenxuan@ncepu.edu.cn
(**SUN Chen-Xuan** Lecturer at the School of Control and Computer Engineering, North China Electric Power University. Her research interests include design and optimization of neural networks, and intelligent modeling of nonlinear systems.)



韩红桂 北京工业大学信息科学技术学院教授。主要研究方向为神经网络结构设计与优化, 非线性系统智能优化控制。

E-mail: rechardhan@sina.com
(**HAN Hong-Gui** Professor at the School of Information Science and Technology, Beijing University of Technology. His research interests include structure design and optimization of neural networks, and intelligent optimal control of nonlinear systems.)



伍小龙 北京工业大学信息科学技术学院教授。主要研究方向为非线性系统智能特征建模与智能控制。

E-mail: lewis_wxl@sina.com
(**WU Xiao-Long** Professor at the School of Information Science and Technology, Beijing University of Technology. His research interests include intelligent feature modeling and intelligent control of nonlinear systems.)



房方 华北电力大学控制与计算机工程学院教授。主要研究方向为发电过程建模与控制, 先进能源系统分析与优化。本文通信作者。

E-mail: ffang@ncepu.edu.cn
(**FANG Fang** Professor at the School of Control and Computer Engineering, North China Electric Power University. His research interests include modeling and control of power generation processes, and analysis and optimization of advanced energy systems. Corresponding author of this paper.)