

DOI: 10.20189/j.cnki.CN/61-1527/E.202505011

基于粒度编解码框架的多元时间序列预测

赵 丹, 任获荣, 任锦程
(西安电子科技大学 机电工程学院, 西安 710071)

摘 要: 针对多元时间序列预测中变量关联复杂、非线性显著及局部波动频繁等问题, 提出一种融合模糊信息粒化与 CNN-LSTM (convolutional neural network and long short-term memory) 编码器-解码器结构的预测方法。首先, 采用固定时间窗口对原始序列进行三角形模糊粒化处理, 实现数据降噪与动态结构压缩; 然后, 构建由卷积神经网络和长短期记忆网络组成的深度预测模型, 用于提取局部空间特征与建模时间依赖关系, 从而实现从序列到点的高精度预测。最后, 在 2 个典型多元时间序列数据集, 即电网实时能源需求量与西安空气质量指数 (air quality index, AQI) 数据集上进行了验证。实验结果表明, 所提方法在能源预测任务中的平均绝对误差、平均绝对百分比误差和均方根误差分别为 269.637、0.022 和 374.072, 较 CNN-LSTM 基线模型分别降低了 26.69%、35.29% 和 20.58%; 在 AQI 预测任务中同样取得最优表现, 3 个误差分别降低了 22.82%、35.65% 和 28.38%, 表现出较强的泛化能力和模型稳定性。证明所提方法适用于非平稳、多变量时序预测场景, 在城市能源调度与环境质量监测等方面具有良好应用前景。

关键词: 多元时间序列预测; 深度学习; 模糊信息粒化; 编解码器

中图分类号: TJ410

文献标志码: A

开放科学标识码(OSID):

文章编号: 2097-2741(2025)05-0117-10



听语音
与作者互动
聊科研

Granularity Encoder-Decoder Framework-Based Multivariate Time Series Prediction

ZHAO Dan, REN Huorong, REN Jincheng

(School of Mechano-Electronic Engineering, Xidian University, Xi'an 710071, China)

ABSTRACT: A prediction method that integrated fuzzy information granulation and a convolutional neural network and long short-term memory (CNN-LSTM) encoder-decoder structure was proposed to address the problems of complex variable correlations, significant nonlinearity, and frequent local fluctuations in multivariate time series prediction. First, the original time series was preprocessed using triangular fuzzy granulation within a fixed time window, achieving noise reduction and dynamic structure compression. Subsequently, a deep hybrid prediction model com-

收稿日期: 2025-03-11

修回日期: 2025-06-24

录用日期: 2025-06-30

基金项目: 西安电子科技大学研究生创新基金项目 (YJSJ24001)

第一作者: 赵丹 (1993—), 女, 硕士研究生, 主要从事复杂系统多元时间序列研究。E-mail: zhaodan014@163.com

引用格式: 赵丹, 任获荣, 任锦程. 基于粒度编解码框架的多元时间序列预测[J]. 火箭军工程大学学报, 2025, 39 (5): 117-126.
ZHAO Dan, REN Huorong, REN Jincheng. Granularity encoder-decoder framework-based multivariate time series prediction[J]. Journal of Rocket Force University of Engineering, 2025, 39 (5): 117-126.

posed of a convolutional neural network and a long short-term memory network was constructed to extract local spatial features and model temporal dependencies, enabling high-precision point prediction from series. Finally, the proposed method was validated on two representative multivariate time series datasets, namely the real-time power grid energy demand and the Xi'an air quality index (AQI) datasets. The results show that the MAE, MAPE, and RMSE of the proposed method in energy prediction tasks are 269.637, 0.022, and 374.072, respectively, reflecting reductions of 26.69%, 35.29%, and 20.58% compared with the CNN-LSTM baseline. In the AQI prediction task, the method likewise achieves superior predictive accuracy, with error reductions of 22.82%, 35.65%, and 28.38%, respectively. These outcomes demonstrate the strong generalization capability and robust stability of the proposed model. The proposed model is suitable for non-stationary and multivariate time series prediction scenarios, offering promising applications for urban energy dispatch and environmental quality monitoring.

KEYWORDS: multivariate time series prediction; deep learning; fuzzy information granulation; encoder-decoder

随着工业物联网与智能传感技术的普及,多元时间序列数据驱动的装备健康管理已成为保障关键设备安全运行的核心手段,为预防性维护、资源调度优化提供关键决策依据^[1-3]。尤其是在多元时间序列预测任务中,为状态评估与决策提供重要的信息支撑。

然而,多元时间序列数据通常存在维度高、变量间耦合强、非线性显著等问题,传统的统计建模方法,如自回归(auto regressive, AR)模型、移动平均(moving average, MA)模型和自回归移动平均(auto regressive moving average, ARMA)模型仅适合于平稳和单变量的时间序列建模问题。基于ARMA模型的求和自回归移动平均(auto-regressive integrated moving average, ARIMA)模型,又称Box-Jenkins模型^[4-5],难以对非线性多维度的复杂时间序列建模。而浅层机器学习模型,如支持向量机(support vector machine, SVM)^[6]、基于随机森林的极限学习机集成模型^[7]以及文献[8]提出的基于改进语义贝叶斯网络的多变量时间序列预测方法受限于复杂的计算,容易陷入局部最优甚至直接失效,难以有效挖掘其内在规律,导致预测精度不高。

近年来,深度神经网络在多元时间序列预测领域表现出显著优势^[9-11],其中,卷积神经网络(convolutional neural network, CNN)能够提取时间序列中的局部时空模式。文献[12]将CNN应用到电力负荷预测任务中,结果表明,相比于多层感知器(multilayer perceptron, MLP),CNN取得了更佳的预测效果。长短期记忆网络(long short-

term memory, LSTM)能够建模长时间依赖特征^[13-15],被广泛应用于多元序列建模任务中。但现有模型大多依赖于对原始序列的直接建模,忽略了对序列内部细粒度变化特征的挖掘,特别是在面向复杂系统预测场景时,存在特征提取不充分、建模结构单一等问题。

针对上述问题,本文主要从预测模型结构优化与数据表示两个方面展开。一方面,近年来已有研究通过改进编码器-解码器结构,以实现多尺度、多变量时序特征的联合建模,从而提升模型的时序表达能力;另一方面,模糊信息粒化(fuzzy information granulation, FIG)作为一种有效的预处理方法,逐渐被应用于时间序列预测领域。该方法通过构建模糊隶属度函数,将连续序列划分为多个模糊信息粒,能够有效提取序列的主要趋势和局部动态特征,在抑制噪声干扰和缓解数据波动性方面具有显著优势,从而能够提升模型的鲁棒性与泛化能力。

为提升模型对多元时间序列中复杂动态变化的建模能力,提出一种结合模糊信息粒化与CNN-LSTM结构的多元时间序列预测模型。首先,通过模糊信息粒化方法对原始序列进行窗口切分和模糊建模,从而提取细粒度的动态变化信息和稳定的趋势特征;然后,构建基于CNN-LSTM的编码器-解码器网络,在编码端引入卷积层以提取局部特征,在解码端利用LSTM进行时间动态建模,实现多尺度、多变量信息的有效融合与预测。以能源时间序列数据为例进行实证分析,采用均方根误差(root mean squared error, RMSE)、

平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE) 等多个评价指标评价所提预测方法的有效性。

1 数据表示

信息粒化 (information granulation, IG) 这一概念最早由 Zadeh^[16] 提出。从本质上讲, 信息颗粒是通过不可区分性、功能相近性、相似性、函数性等来划分对象的集合, 是将详细的数字数据构造造成一些有意义的、语义健全的实体 (信息粒), 在人类认知和决策活动中起着关键作用。而模糊信息粒是使用模糊集来表示的信息粒, 在许多情况下, 模糊信息粒能明确地反映所描述事物的特性^[17], 因而建立模糊信息粒是必要的。

对多元时间序列进行模糊信息粒化主要包括两个步骤。一是窗口划分, 将原始的多元时间序列分割成若干子序列, 并将每个子序列作为操作窗口; 二是信息模糊化, 对产生的每个窗口进行模糊化, 生成若干模糊集, 即为模糊信息粒。

对于给定的多元时间序列, 将整个多元时间序列的每一个变量的单元时间序列 X 看作一个窗口, 进行模糊化, 在 X 上建立一个模糊粒子 g , 即找到一个模糊概念 G , 就能够合理描述时间序列 X 。此时, 确定了 G 即确定了模糊粒子 g , 模糊粒子 g 与模糊概念 G 的关系可表示为

$$g \triangleq x \text{ is } G \quad (1)$$

式中: $\triangleq$ 为“被定义为”; x 为论域 X 的变量; is 为“属于”或“隶属于”关系; G 为以 X 为论域的模糊集合。

模糊化的本质是确定函数 A 的过程, A 是模糊概念 G 的隶属函数, 本文采用三角形模糊粒子获

取窗口数据的最大值、最小值和平均值, 其隶属函数可表示为

$$A(x, a, m, b) = \begin{cases} 0, & x < a \\ \frac{x-a}{m-a}, & a \leq x < m \\ \frac{b-x}{b-m}, & m \leq x < b \\ 0, & x \geq b \end{cases} \quad (2)$$

式中: a 、 m 、 b 分别为原始时间序列数据变化的最小值、平均值和最大值。

2 预测模型

2.1 CNN 编码器模型

CNN 作为一种典型的端到端深度学习模型, 具有无需依赖人工构造特征、可自动提取数据多层次语义信息的能力^[18]。相比传统特征工程方法, CNN 在特征表达能力、鲁棒性及泛化性能等方面展现出显著优势。其网络结构主要由卷积层、池化层和全连接层等基本单元构成, 通过逐层提取与压缩输入数据中的关键特征, 完成高效的特征编码与表达。其中, CNN 编码器的特征提取过程如图 1 所示。

为建模多元时间序列间复杂的潜在依赖关系, 在编码器中引入单层一维卷积神经网络结构作为特征提取模块, 输入序列形式为

$$X_{t-L:t-1} = [x_{t-L:t-1}^{(1)}, x_{t-L:t-1}^{(2)}, \dots, x_{t-L:t-1}^{(N)}] \quad (3)$$

式中: L 为序列长度; N 为特征维度; 上标 (1), (2), ..., (N) 为第 1 个, 第 2 个, ..., 第 N 个特征; $X_{t-L:t-1}$ 为从时间步 $t-L$ 到 $t-1$ 的输入序列。

通过在多元时间序列上施加多个一维卷积核, 执行跨变量的全维度卷积操作, 可有效提取序列中各变量间的局部关联特征, 构建高层次语义表




图 1 CNN 编码器编码过程

Fig. 1 Coding process of CNN encoder

示, 该全维卷积过程为

$$C^{(k)} = W^{(k)} * X_{t-L:t-1} \quad (4)$$

式中: $W^{(k)}$ 为第 k 个卷积核; $C^{(k)}$ 为全维度卷积过程提取的第 k 个特征图; “*” 为哈达玛积运算。

在特征提取过程中, 网络引入了 k 个形状相同的卷积核 $W^{(1)}, W^{(2)}, \dots, W^{(k)}$, 分别提取对应的特征图 $C^{(1)}, C^{(2)}, \dots, C^{(k)}$ 。本文中所有卷积核大小均设定为 $1 \times N$, 即 $W^{(k,c)} \in R^{1 \times N}$, c 为通道数, R 为卷积核所作用的维度空间。最终, Flatten层将池化后的多通道特征图沿垂直方向进行展平操作, 形成固定长度的一维编码向量, 并作为 CNN-LSTM 编解码框架中编码器的输出表示, 用于后续的时序建模。

2.2 LSTM解码器模型

LSTM 在循环神经网络 (recurrent neural network, RNN) 的基础上发展而来, 通过引入门控机制对历史状态信息进行有选择地保留或舍弃, 从而有效缓解传统 RNN 在长期依赖建模中的梯度消失与爆炸问题。

本文所设计的 LSTM 解码模块中, 输入层接收来自编码器输出的序列信息, 并将其逐步传入 LSTM 网络结构。每一时间步由多个 LSTM 单元组成, 以捕捉时序数据中的动态演变特征。随后, TimeDistributed层实现跨时间步的参数共享机制, 即每个时间点的神经元使用相同的权重与偏置, 从而保持时序结构的一致性。接下来, 全连接层对序列表示进行非线性映射, 最终通过输出层生成预测结果。其中, 输出层仅包含 1 个神经元, 代表目标变量的预测值。LSTM 解码器的解码过程如图 2 所示。

2.3 粒度 CNN-LSTM 编解码模型

基于链式组合策略, 构建了一种融合模糊信息粒化与 CNN-LSTM 结构的多元时间序列预测模型, 实现了端到端的细粒度预测。该模型整体由输入层、粒化层、编码层、解码层及输出层组成, 采用“模糊信息粒化+CNN 编码器+LSTM 解码器”的模块化协同建模机制, 结合数据预处理、空间特征提取与时间依赖建模的优势, 构建了粒度 CNN-LSTM 编解码模型, 其结构如图 3 所示。

首先, 模型输入层接收的原始多元时间序列数据, 经过模糊信息粒化处理, 将连续时序片段转换为具有语义表示能力的模糊信息粒。该过程不仅压缩了输入空间、减少了噪声干扰, 还增强




图 2 LSTM解码器解码过程

Fig. 2 Decoding process of LSTM decoder




图 3 粒度 CNN-LSTM 编解码模型训练结构

Fig. 3 Training structure of the granular CNN-LSTM coding and decoding model

了模型对局部变化趋势与不确定性特征的感知能力, 为后续深度建模提供了更稳定的输入表达。其次, 编码阶段采用 CNN 编码器, 自适应提取粒化后序列中的局部模式与边缘特征。通过设置多个卷积核对各观测变量维度进行全局滑动卷积, CNN 不仅能够捕捉变量间的短期耦合特征, 还具备较强的平移不变性, 适用于检测周期性、突变性等局部模式, 从而获得更加抽象且具有判别性的深层特征表示。最后, 在解码阶段, LSTM 解码器接收由 CNN 编码后的高维特征向量, 进一步建模序列在时间维度上的动态演化过程。LSTM 通过门控机制有效捕捉特征表示的长期与短期依赖关系, 具备较强的时间记忆与泛化能力, 能够根据历史粒度特征对目标时刻的状态进行精准预测。基于该粒度 CNN-LSTM 编解码架构的多元时间序列预测方法, 可实现从序列到目标点的高精度细粒度建模。

3 数据预处理

能源及时间序列数据集具有数据量大、维度高、波动性强等特点, 因而在建模之前需进行系统性的预处理。首先, 需要对原始数据进行初步清洗与整理, 分离出预测指标与其他特征变量。其次, 预测指标因其易受异常扰动影响, 采用小波软阈值方法进行去噪处理, 以提升其稳定性和有效性。随后, 联合处理后的预测指标与其余特征变量, 利用最大信息系数 (maximal information coefficient, MIC) 评估特征与目标变量之间的相关性, 实现冗余特征的剔除与关键特征的筛选。最后, 对选定特征进行数据归一化处理, 为后续建模提供统一、标准化的输入空间, 以提升模型训练效率与预测精度。

3.1 小波软阈值去噪

为提升模型对复杂时间序列的建模能力, 对多元时间序列中目标预测指标进行去噪处理是必要的手段。采用小波变换对预测变量进行多尺度分解, 通过提取不同尺度下的信号特征, 有效去除高频噪声, 保留时间序列的关键趋势信息, 从而提升模型训练的稳定性与预测精度。小波变换的多尺度分解过程如图 4 所示。

由图 4 可知, 通过多尺度将原始序列分解为一个低频分量 a_n 和多个高频分量 b_n 的线性叠加, a_n 为原始信号的近似表达, b_n 为所含噪声信息的具

体描述。因此, 小波分解过程为

$$f(t) = a_n + b_1 + b_2 + \cdots + b_n \quad (5)$$

式中: n 为高频分量的个数。




图 4 小波变换多尺度分解过程

Fig. 4 Multiscale decomposition process of wavelet transform

软阈值函数处理得到的信号具有平滑性, 信号内部不会产生附加的震荡。阈值计算方法为

$$T = \lambda \sqrt{2 \ln M} \quad (6)$$

式中: M 为信号的尺寸或长度; λ 为噪声方差估计。

最后, 通过小波逆变换重构低频分量及去噪后的高频分量。

3.2 特征选择

最大信息系数^[19]是一种衡量变量间非线性关系强度的统计指标, 可用于定量分析多特征变量之间的相关性。该方法通过对变量 D 和变量 S 构成的散点图进行多种分辨率的网格划分, 计算每种划分下的互信息值, 并对这些值进行归一化处理。最终, 选择使归一化互信息值最大的网格划分, 其对应的值即为两变量之间的 MIC 值。

设给定变量 $D = \{d_1, d_2, \dots, d_j\}$ 和 $S = \{s_1, s_2, \dots, s_j\}$, j 为样本个数, 则变量 D 和变量 S 之间的互信息计算公式为

$$I(D; S) = \sum_{s \in S} \sum_{d \in D} p(d, s) \lg \frac{p(d, s)}{p(d)p(s)} \quad (7)$$

式中: $p(d, s)$ 为变量 D 和变量 S 的联合概率密度函数; $p(d)$ 为 D 的边缘概率密度函数; $p(s)$ 为 S 的边缘概率密度函数。

MIC 的计算公式为

$$\text{MIC}(D; S) = \max_{d \times s \leq B} \frac{I(D; S)}{\lg \min(D; S)} \quad (8)$$

式中: B 为网格划分时 $z \times q$ 的上限值; z 和 q 分别为横纵方向上的网格划分数。

B 常取样本个数 i 的 0.6 次方^[20]。MIC 的取值范围在 $[0, 1]$ 之间, 两变量之间的 MIC 值越接近 0, 变量之间的相关性越弱; MIC 值越接近 1, 变量之间的相关性越强。

3.3 数据归一化

在实际数据中, 常常存在离群或异常样本, 这类数据不仅会延长模型训练时间, 还可能干扰网络的收敛过程。为提升模型的训练效率和稳定性, 本文对输入特征采用 Z-score 标准化方法进行归一化处理。该方法通过对每个特征变量减去其均值, 用差除以标准差, 实现不同量纲特征的统一。归一化计算方式为

$$f_{\text{scale}} = \frac{f - f_{\text{mean}}}{f_{\sigma}} \quad (9)$$

式中: f 为数据集中单个特征指标的取值集合; f_{scale} 为特征指标归一化后的结果; f_{mean} 为特征指标的平均值; f_{σ} 为特征指标的标准差。

4 结果分析

4.1 数据集介绍

为验证所提模型的通用性与有效性, 选取两个具有代表性的实际数据集进行实验, 即能源负荷预测数据集与西安市空气质量历史监测数据集。

4.1.1 能源负荷数据集

该数据集来自 2017 竞赛官网 (<http://www.drhongtao.com/gefcom/2017>), 共包含 77 419 个小时级样本, 记录了能源系统运行过程中包括露点温度、干球温度等 12 个影响因素。各个因素变量分别为实时电力负荷需求、日前电力负荷预测、日前电力市场价格、日前能源成本、日前拥塞成本、日前边际损耗成本、实时电力市场价格、实时能源成本、实时拥塞成本、实时边际损耗成本、干球温度和露点温度。目标变量为电网的实时能源负荷需求量, 其数据具有高频率、强季节性与显著周期性等特点。为更好模拟实际预测场景, 本研究选取该数据集中末尾 6% 时间序列样本作为实验数据, 用于模型预测能力的检验。

4.1.2 空气质量数据集

该数据来源于公开环境监测平台 (<https://www.aqistudy.cn/historydata>), 共包含 1 097 条样本记录。每条记录涵盖 8 个特征指标, 包括空气质量指数 (air quality index, AQI)、PM2.5、PM10、NO₂、SO₂、CO、O₃ 和温度。其中, AQI 作为综合反映污染程度的关键变量, 被选定为预测目标, 构成典型的多元时间序列预测任务。

4.2 模糊信息粒化处理

为增强模型对短期趋势和周期性模式的表达

能力, 以 96 个采样点 (4 天) 为一个操作窗口, 对原始多元能源监测时间序列进行模糊信息粒化处理。该设定主要参考了电力负荷等典型时间序列中常见的 3~7 天短周期变化特征, 能够在压缩数据维度的同时, 保留关键动态信息。针对原始天气时间序列, 从数据特性出发, AQI 受气象因素、污染物累积效应等影响, 具有一定的短期滞后性与缓变趋势。以 3 天为一个操作窗口进行模糊表示, 有助于保留污染演化的连续性特征, 抑制高频波动对模型学习造成的干扰, 提升预测稳定性。另外, 从粒化目的来看, 模糊粒化的核心是以模糊集合的方式对局部时间段的信息进行压缩与概括, 从而增强模型对时序数据整体结构的把握能力。3 天粒度在不丢失关键信息的前提下, 实现了对原始序列的有效降噪与压缩, 提升了模型的表达鲁棒性。

在模糊信息粒化过程中, 选用三角形模糊粒子对原始时间序列数据进行模糊建模。该方法具有形式简单、计算高效、定义明确等优点, 在模糊系统与时间序列预处理等领域中被广泛应用。其隶属度函数具备线性下降特性, 能在保证关键特征不失真的同时, 实现一定程度的信息压缩和噪声平滑, 适用于数据波动性较强的时序场景, 从而得到各个操作窗口的区间下界值 a 、区间上界值 b 以及平均值 m 。能源时间序列中电网能源实时需求量子序列进行模糊信息粒化后的粒化图如图 5 所示, 经过 4 天窗口的模糊信息粒化后, 原始能源需求序列的高频波动被平滑, 周期性变化特征得到凸显, 平均值能反映整体趋势, 上界值与下界值能保留极值信息。西安按天气时间序列中子序列进行模糊信息粒化后的粒化图如图 6 所示, 空气质量指数在 3 天窗口粒化后整体波动得到抑制, 同时, 上界值能有效捕捉到污染峰值, 平均值能揭示缓变趋势。

4.3 模型预测结果

采用留出法将数据集以 7:3 划分为训练集和测试集, 粒度 CNN-LSTM 编解码模型在测试集上的预测结果以及误差值分别如图 7 和图 8 所示。如图 7 所示, 在能源时间序列数据集上, 模型预测值与实际值曲线在整体走势上高度一致, 能够较好地反映出电网实际负荷的周期性变化与波动特征, 表明所构建模型在训练集上的拟合能力较强, 具有良好的预测性能。尤其在峰值和谷值变化区间, 模型预测结果能够紧跟实际波动, 说明其对

复杂负荷变化具有一定的学习和拟合能力。

如图 8 所示, 在西安天气时间序列数据集上, 模型预测值与实际观测值曲线在整体走势上高度一致, 表明模型具有较强的拟合能力与预测精度。两者在多数时间点上的数值接近, 尤其在日常波动区间内, 模型能够准确反映实际 AQI 的变化趋势。尽管在部分极端峰值 (如 2022 年 3 月初的突增) 处存在一定的偏差, 但整体预测趋势仍能较好地覆盖实际数据波动范围, 表明模型对异常点

具有一定的响应能力。总体而言, 该模型对 AQI 的动态变化具有较好的拟合效果和一定的鲁棒性。

4.4 对比实验与评价指标

使用对比试验中的基线模型对粒度 CNN-LSTM 编解码模型的有效性进行验证, 并采用 CNN 进行对比试验, 以验证编解码模型在多元时间序列上的预测优势, 以及 LSTM 作为解码器对编码向量在时间域上的同步解码能力。采用 LSTM 进行对比试验, 以验证 CNN 作为编码器对




图 5 能源时间序列子序列能源实时需求量粒化图

Fig. 5 Granulation graph of real-time energy demand in the energy time series subsequence




图 6 西安天气时间序列子序列空气质量指数粒化图

Fig. 6 Granulation graph of the air quality index in the Xi'an weather time series subsequence




图 7 电网实时能源需求量预测值和实际值的比较

Fig. 7 Comparison between predicted and actual values of real-time energy demand of the power grid




图 8 西安天气AQI预测值和实际值的比较

Fig. 8 Comparison between predicted and actual values of AQI of Xi'an

多元时间序列深层次特征的提取能力，以及编解码模型在多元时间序列上的预测优势。

采用MAE、MAPE和RMSE，对模糊信息粒化的多元时间序列预测模型进行评价，其表达式为

$$MAE = \frac{1}{i} \sum_{t=1}^i |\hat{y}_t - y_t| \quad (10)$$

$$MAPE = \frac{100\%}{i} \sum_{t=1}^i \left| \frac{\hat{y}_t - y_t}{y_t} \right| \quad (11)$$

$$RMSE = \sqrt{\frac{1}{i} \sum_{t=1}^i (y_t - \hat{y}_t)^2} \quad (12)$$

式中： y_t 为真实值； $\hat{y}_t$ 为预测值； i 为预测值的个数。

采用不同模型分别在测试集上进行测试，得到各模型在不同预测性能评估指标下的预测误差，如表1所示。表1展示了不同模型在能源时间序列和西安天气时间序列2个时间序列数据集上的预测性能。评价指标（MAE、MAPE、RMSE）数值越小，则表示模型拟合效果越好、泛化能力越强。

表 1 各模型在不同预测性能评价指标下的预测误差对比
Table 1 Comparison between prediction errors of various models under different predictive performance evaluation indicators

数据集	预测指标	模型	评价指标		
			MAE	MAPE	RMSE
能源时间序列	电网实时需求量	CNN	621.931	0.048	731.247
		LSTM	487.587	0.036	647.139
		CNN-LSTM	367.785	0.034	471.027
		本文方法	269.637	0.022	374.072
西安天气时间序列	空气质量指数	CNN	43.476	2.043	54.373
		LSTM	36.098	0.405	52.201
		CNN-LSTM	29.476	0.317	43.752
		本文方法	22.749	0.204	31.334

在能源数据集上, 本文方法在所有评价指标中均取得最优结果, MAE、MAPE 和 RMSE 分别为 269.637、0.022 和 374.072, 显著优于 CNN、LSTM 以及 CNN-LSTM 3 种对比模型。与性能最接近的 CNN-LSTM 相比, 本文方法的 MAE、MAPE 和 RMSE 分别降低了 26.69%、35.29% 和 20.58%, 表现出更强的预测精度和泛化能力。而传统 CNN 模型在该任务中的误差最高, RMSE 高达 731.247, 说明其在处理复杂时序数据方面存在局限。

在西安天气空气质量预测任务中, 各模型的整体误差相对降低。其中, CNN-LSTM 相较于单一模型已有显著提升, 但本文方法仍在所有指标上取得最优。MAE、MAPE 和 RMSE 分别为 22.749、0.204 和 31.334, 相较于 CNN-LSTM 模型, 本文方法分别降低了 22.82%、35.65% 和 28.38%, 进一步提升了模型的预测精度与稳定性, 验证了本文方法在不同任务场景下的广泛适用性与优势。

5 结论

本文模型充分发挥了 CNN 在提取序列局部特征方面的优势, 同时借助 LSTM 对时间依赖模式的建模能力, 有效增强了对复杂时序结构的建模表达力。同时, 模糊信息粒化技术通过对原始数据的模糊压缩与信息保留, 提升了模型在面对多噪声、强耦合、非线性序列时的泛化稳定性。

本文模型在多元时序预测任务中均表现出更

高的预测精度与更强的鲁棒性, 相较于传统神经网络模型, 该模型不仅更能适应多变量序列间的协同演化关系, 还在序列存在突变、异常或非平稳波动时展现出更稳定的性能, 验证了其适用性与实用性。

本文聚焦于提升多元时间序列的细粒度建模与预测能力, 通过模糊信息粒化方法增强了模型的鲁棒性和泛化能力, 为复杂时序建模问题提供了一种新思路。与已有的基于深度学习的序列预测方法相比, 本文方法在预测效果和稳定性方面具有一定的提升, 体现了模糊信息粒与深度结构融合策略的优势。

尽管本文模型在多元时间序列预测任务中取得了较好的效果, 但仍存在一定的局限性。首先, 模糊信息粒化过程中, 窗口大小的选取和粒子类型的设置可能对模型性能存在一定影响。本文采用固定窗口长度和三角形模糊粒子的方式, 虽然在当前任务中表现良好, 但未对不同粒化参数进行系统敏感性分析, 尚缺乏通用性评估。其次, 模型目前仍以单尺度时间粒度进行建模, 尚未引入跨尺度建模或多模态信息融合, 其在更复杂任务场景下的拓展性可能受到限制。

未来的研究将从以下几个方面进行拓展: 一是系统分析不同粒化窗口长度和模糊粒子函数(如梯形、高斯等)对模型预测性能的影响, 构建自适应粒化机制; 二是引入注意力机制或图神经网络, 增强模型对多变量间结构性关系的建模能力; 三是探索融合因果发现与模糊信息处理方法, 进一步提升模型的解释性与泛化能力, 从而更好应对复杂非平稳时序数据的建模挑战。

参考文献

[1] WU C C, YEH W C, HSU W D, et al. Prediction of fatty liver disease using machine learning algorithms[J]. Computer Methods and Programs in Biomedicine, 2019, 170: 23-29.

[2] 张萌, 贺绍鹏, 朱文立, 等. 数据驱动的电工装备市场规模预测架构研究[J]. 电力大数据, 2022, 25(11): 56-62.

ZHANG M, HE S P, ZHU W L, et al. Research on data-driven prediction framework of electrical equipment market scale[J]. Power Systems and Big Data, 2022, 25(11): 56-62.

[3] 贺小星, 花向红, 鲁铁定, 等. 时间跨度对 GPS 坐标序列噪声模型及速度估计影响分析[J]. 国防科技

- 大学学报, 2017, 39(6): 12-18.
- HE X X, HUA X H, LU T D, et al. Effect of time span on GPS time series noise model and velocity estimation[J]. Journal of National University of Defense Technology, 2017, 39(6): 12-18.
- [4] CONTRERAS J, ESPINOLA R, NOGALES F J, et al. ARIMA models to predict next-day electricity prices[J]. IEEE Transactions on Power Systems, 2003, 18(3): 1014-1020.
- [5] ZHANG G P. Time series forecasting using a hybrid ARIMA and neural network model[J]. Neurocomputing, 2003, 50: 159-175.
- [6] TOAN T D, TRUONG V. Support vector machine for short-term traffic flow prediction and improvement of its model training using nearest neighbor approach[J]. Transportation Research Record, 2021, 2675(4): 362-373.
- [7] TAJEUNA E G, BOUGUESSA M, WANG S R. Modeling regime shifts in multiple time series[J]. ACM Transactions on Knowledge Discovery from Data, 2023, 17(8): 1-31.
- [8] DAS M, GHOSH S K. SemBnet: a semantic Bayesian network for multivariate prediction of meteorological time series data[J]. Pattern Recognition Letters, 2017, 93: 192-201.
- [9] LI S W, HUANG H, LU W. A neural networks based method for multivariate time-series forecasting[J]. IEEE Access, 2021, 9: 63915-63924.
- [10] WANG X Y, LIU H, DU J Z, et al. A long-term multivariate time series forecasting network combining series decomposition and convolutional neural networks[J]. Applied Soft Computing, 2023, 139: 110214.
- [11] 杨海民, 潘志松, 白玮. 时间序列预测方法综述[J]. 计算机科学, 2019, 46(1): 21-28.
- YANG H M, PAN Z S, BAI W. Review of time series prediction methods[J]. Computer Science, 2019, 46(1): 21-28.
- [12] LI Z W, LIU F, YANG W J, et al. A survey of convolutional neural networks: analysis, applications, and prospects[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(12): 6999-7019.
- [13] 管业鹏, 苏光耀, 盛怡. 双向长短期记忆网络的时间序列预测方法[J]. 西安电子科技大学学报, 2024, 51(3): 103-112.
- GUAN Y P, SU G Y, SHENG Y. Time series prediction method based on the bidirectional long short-term memory network[J]. Journal of Xidian University, 2024, 51(3): 103-112.
- [14] 樊围国, 陈珂翰. 基于浣熊算法优化双向长短期记忆网络的碳价预测[J]. 电力科学与工程, 2023, 39(7): 34-41.
- FAN W G, CHEN K H. Carbon price prediction of bidirectional long short term memory network optimized by Coati optimization algorithm[J]. Electric Power Science and Engineering, 2023, 39(7): 34-41.
- [15] 徐冬梅, 王逸阳, 王文川. 基于贝叶斯优化算法的长短期记忆神经网络模型年径流预测[J]. 水电能源科学, 2022, 40(12): 42-46.
- XU D M, WANG Y Y, WANG W C. Prediction of annual runoff using long short-term memory neural network model based on Bayesian optimization algorithm[J]. Water Resources and Power, 2022, 40(12): 42-46.
- [16] ZADEH L A. Fuzzy sets as a basis for a theory of possibility[J]. Fuzzy Sets and Systems, 1999, 100: 9-34.
- [17] HAO Y D, JIANG S R, YU F S, et al. Linear dynamic fuzzy granule based long-term forecasting model of interval-valued time series[J]. Information Sciences, 2022, 586: 563-595.
- [18] 左亚尧, 王铭锋, 洪嘉伟, 等. 一种基于集成学习的多元时间序列预测方法[J]. 小型微型计算机系统, 2020, 41(12): 2475-2479.
- ZUO Y Y, WANG M F, HONG J W, et al. Prediction method of multivariate time series based on ensemble learning[J]. Journal of Chinese Computer Systems, 2020, 41(12): 2475-2479.
- [19] 曾千千, 曾安, 潘丹, 等. 基于最大信息系数的贝叶斯网络结构学习算法[J]. 计算机工程, 2017, 43(8): 225-230.
- ZENG Q Q, ZENG A, PAN D, et al. Bayesian network structure learning algorithm based on maximum information coefficient[J]. Computer Engineering, 2017, 43(8): 225-230.
- [20] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Stroudsburg, PA, USA: ACL, 2014: 1724-1734.

(编辑: 夏菁)