

引用格式: 周一飞, 刘刚, 李子轩, 等. 基于门控注意力网络的电流互感器在线监测方法 [J]. 电子科技大学学报, 2025, 54(5): 652-659.
ZHOU Y F, LIU G, LI Z X, et al. An online monitoring method for current transformers based on a gated attention Transformer model[J]. Journal of University of Electronic Science and Technology of China, 2025, 54(5): 652-659.

基于门控注意力网络的电流互感器 在线监测方法



周一飞¹, 刘刚¹, 李子轩², 叶子阳¹, 李金嵩¹, 易黎³, 徐杰^{2*}

(1. 国网四川省电力公司营销服务中心(计量中心), 成都 610072; 2. 电子科技大学信息与通信工程学院, 成都 611731;
3. 国网四川省电力公司绵阳供电公司, 绵阳 621050)

摘要: 随着电网服务需求的不断提高, 电力互感器作为电网系统重要设备, 对其在线监测和状态评估提出了更高的要求。传统电磁式电流互感器需停电进行离线校准, 难以反映真实运行状态, 增加了运维复杂性和成本, 影响了电能计量准确性和电网稳定性。针对电流互感器误差在线监测缺乏标准互感器作为参考的难题, 提出了一种基于门控注意力 Transformer (Gatedformer) 模型的在线监测方法, 可通过学习多路电流数据特征, 准确预测未来电流互感器标准值, 从而计算其误差值。该方法通过维度转置操作能够有效利用注意力机制集中于时序特征的相关性, 增强多路数据之间的特征解耦能力; 门控注意力机制则进一步优化了时间序列依赖关系的捕捉效果, 显著提升了长时间序列预测的性能。实验结果显示, 模型在三路电流数据集上的平均预测误差为 0.09%, 为实现电流互感器在线监测提供了有力支撑。

关键词: 电流互感器; 时间序列预测; 深度学习; 门控注意力网络

中图分类号: TP183

文献标志码: A

DOI: 10.12178/1001-0548.2024269

An online monitoring method for current transformers based on a gated attention Transformer model

ZHOU Yifei¹, LIU Gang¹, LI Zixuan², YE Ziyang¹, LI Jinsong¹, YI Li³, and XU Jie^{2*}

(1. State Grid Sichuan Electric Power Company Marketing Service Center (Metrology Center), Chengdu 610072, China;

2. School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China;

3. State Grid Sichuan Electric Power Company Mianyang Supply Company, Mianyang 621050, China)

Abstract: With the continuous increase in the demand for power grid services, higher requirements arise for the online monitoring and condition assessment of current transformers as important equipment in the power grid system. Traditional electromagnetic current transformers require power-off for offline calibration, making it difficult to reflect their actual operating status, increasing operational complexity and costs, and affecting the accuracy of energy metering and the stability of the power grid. Addressing the issue of the lack of a standard transformer as a reference for online error monitoring of current transformers, this paper proposes an online monitoring method based on the gated attention Transformer (Gatedformer) model. This method uses multiple current data inputs, leverages the Gatedformer model to learn data features, and accurately predicts future standard values of current transformers. Specifically, the method embeds time point variables through the attention mechanism to capture multivariable correlations, uses a gated attention network to capture the long-term dependency characteristics of time series, and applies a feedforward network to learn nonlinear representations. The experimental results show that under the condition of predicting the standard current value window for the next day, the model achieves an average prediction error of 0.09% in the online monitoring of current transformers on the three-channel current dataset, outperforming existing models.

Key words: current transformer; time series prediction; deep learning; gated attention network

收稿日期: 2024-09-27

基金项目: 国网四川省电力公司科技项目 (52199723000W)

作者简介: 周一飞, 主要从事电能计量方面的研究。

*通信作者 E-mail: xuj@uestc.edu.cn

电流互感器作为电力系统中关键的传感器和保护设备, 其运行状态直接影响电力系统的安全稳定和电力交易的公正透明。现有模式下, 电流互感器现场监测、维护等均需要专业人员到现场开展相关工作, 在这个过程中会造成一定人力、经济和时间成本的浪费。除此以外, 这种离线检测的方式很难发现设备在运行周期内的故障缺陷, 不能及时检修。随着电力系统规模的扩大和技术复杂性的增加, 传统的人工巡检和定期维修方式已经难以满足现代电网对于设备状态实时感知和智能管理的需求。在此背景下, 研究电流互感器误差在线监测算法显得尤为迫切和必要。

近年来, 针对电流互感器误差的在线监测技术, 研究人员已经提出了一系列方案。这些方案可以系统地分为两大类: 第一类聚焦于设计硬件装置与信号注入的方法, 搭建在线监测系统; 第二类则着重于使用大数据与人工智能的方法对采集数据进行分析计算, 进而实现对电流互感器的在线监测。针对第一类方法, 文献 [1] 从理论上分析二次回路各工况的等值关系, 设计了一种基于 10 kHz 阻抗谱特性的计量电流互感器在线监测系统, 通过将 10 kHz 的高频信号注入二次回路中, 实时监控互感器二次回路的状态。文献 [2] 通过研究不同状态下的回路等效电路, 采用了基于微型互感器耦合和矢量电压电流法的回路 10 kHz 阻抗测量技术, 研制了电流互感器二次回路状态监测装置。文献 [3] 设计了一种电流互感器二次回路接地点监测装置, 通过 PLC 编程控制程序、继电器合理配合, 实时在线监测发电厂电流互感器二次回路接地点的接地情况。文献 [4] 通过构建电流互感器在不同负荷不同状态下的等效电路模型, 结合电工原理及计量回路中电流的基波和谐波分析方法研制了一款电流互感器二次侧接入状态在线监测装置, 通过该装置能够实现对不同负荷下互感器的正常连接、开路、短路和回路整流状态的准确识别。文献 [5] 基于设备智能化、通信网络化、信息数字化、信息共享化和应用互动化五大特点, 提出了一种智能变电站在线监测系统思路, 通过相关技术, 完成智能变电站在线检测整合系统的设计。文献 [6] 提出了一种基于傅里叶变换的电压电流传感器长期运行误差在线测试方法, 研发了由标准电压电流转换器、采集器和工控机构成的电压电流传感器误差在线测试装置, 开展了空心线圈和低功耗电流传感器、电容分压和电阻分压电压传感器四类传感器的在线误差实

时测试, 找出了这四类传感器在长期工作条件下误差变化的基本规律, 提出了降低不同类型传感器长期运行误差的技术措施。针对第二类方法, 文献 [7] 提出了一种误差在线检测方法, 通过在互感器二次侧施加异频信号, 根据二次侧的异频电压、电流建立起互感器一次侧和二次侧的传递关系, 采用 BP 神经网络算法得到互感器计量误差, 通过仿真验证了方法的准确性。该方法本质上是一种带电检测方法, 并且在实际应用中仍存在一定局限性。文献 [8] 基于互感器误差与二次负荷之间的关系, 提出了一种在线监测方案, 通过测量额定负荷和空载负荷下的误差, 可得到任意负载下的误差。该文献仅从理论分析角度提出在线监测方法, 需要在实际应用场景中做进一步验证。文献 [9] 通过建立电子式电流互感器误差模型, 提出基于聚类径向基函数神经网络的误差状态预测方法, 针对变量单位和数量级不同的问题, 采用 Z-score 标准化法对数据进行预处理, 采用 K-means 聚类算法对输入变量进行聚类分析, 但聚类算法初始聚类中心的选择具有随机性, 可能陷入局部最优的陷阱。综上所述, 尽管国内外研究取得一定进展, 但目前针对电流互感器误差的在线监测方法主要聚焦于设计硬件装置与信号注入, 在大数据与人工智能分析方面, 国内相关理论研究较为薄弱, 还处于探索、研究及试点阶段。

1 基于 Gatedformer 的电流互感器在线监测方法

电流互感器具有标定的准确度等级, 但随着设备老化, 其实际误差可能会超过标定容限。因此, 在计算电流互感器误差时, 通常需要引入已知准确度的标准电流互感器, 通过比较两个电流互感器的二次侧电流差异来确定误差。因此, 标准电流互感器的电流值是计算误差的重要依据。然而, 传统方法需要在每条电路中物理接入一台标准电流互感器, 导致大量时间、人力和经济成本浪费, 尤其在电力系统日益复杂的背景下, 传统方法的局限性愈发明显。

在电流互感器的误差分析中, 比差与角差是两大核心要素, 两者共同决定了互感器的测量准确性。然而, 在众多实际应用场景中, 特别是电力系统保护和电能计量领域, 由于比差直接影响测量结果的线性度, 成为决定系统性能的关键因素。因此, 本文聚焦于构建一种高效、准确的比差预测模型, 以应对日益增长的电力系统监测需求。

针对电流互感器误差在线监测计算缺乏标准互感器作为参考的难题, 本文提出一种基于门控注意力的 Transformer 模型 (Gatedformer) 的电流互感器在线监测方法, 整体框架如图 1 所示。首先, 平台通过实时采集多路电流互感器二次侧分布式电流数据, 得到分布式电流数据集, 分布式电流数据集中包括每条电路三相分别的实际二次侧电流值、电压值、频率等信息。考虑到分布式电流数据的采样间隔为 15 min, 本文界定 4 种不同跨度的历史窗口, 分别包括 96、192、384 和 672 个数据点, 对应

1 天、2 天、4 天和 7 天的观测周期, Gatedformer 模型在此基础上, 能有效捕捉窗口内的长短期时间序列特征, 基于此, 本文配置 4 种预测时段: 12、24、48、96 个时间单位 (1 个时间单位 15 min), 映射至一天自然周期, 进一步根据划定的预测窗口对未来时刻的 2 次侧标准电流互感器值进行预测, 并将预测值作为标准电流互感器值, 本文中称之为虚拟标准值。通过该时刻实际采集到的电流值与虚拟标准值进行误差计算, 精确量化电流互感器的实际运行误差, 实现了对电流互感器误差的在线监测。

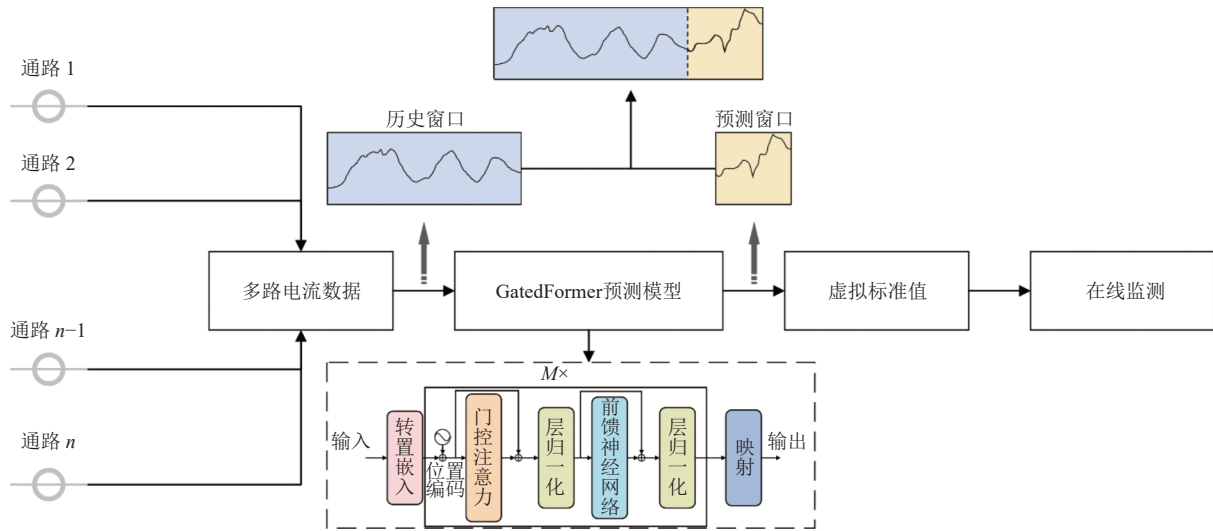


图 1 电流互感器整体框架图

2 Gatedformer 模型的构建

2.1 问题定义及符号表示

Gatedformer 模型的输入为给定时间间隔内各个节点的电流值, 它被用于预测, 以进行电流互感器误差在线监测。假设输入时间段为 P 个时刻的历史电流值, 表示为 $X = X_{t-P+1}, X_{t-P+2}, \dots, X_t \in \mathbb{R}^{P \times N}$, 其中 N 代表了该时刻检测的 N 路电流互感器的电流; 假设输出为预测的 Q 个时刻的电流值, 表示为 $Y = X_{t+1}, X_{t+2}, \dots, X_{t+Q}$ 。本文目标就是构造一个时间序列预测算法 f , 能够精确地预测出 Y , 通过比较预测值 Y 和真实电流标准值误差来评估模型预测性能:

$$X_{t+1}, X_{t+2}, \dots, X_{t+Q} = f(X_{t-P+1}, X_{t-P+2}, \dots, X_t) \quad (1)$$

2.2 模型描述

Gatedformer 模型主要利用 Transformer 的编码器结构, 通过将原始 Transformer 的嵌入层进行维度转置, 模型可以将时序作为一个向量输入, 这有助于模型更加关注时间序列在时间上的相关性; 同时, 本文在编码器结构中引入门控注意力机制, 能

够在特征进入多头注意力处理之前先评估时序部分的趋势性信息, 用于学习时间序列的长期时间依赖性; 然后, 模型使用层归一化统一不同变量的特征分布, 以及使用前馈网络进行特征编码; 最终通过线性投影层映射出预测结果。Gatedformer 模型的整体结构如图 2 所示。

2.2.1 转置嵌入层

传统的 Transformer 模型通常将一个时刻的多个变量特征视为向量, 然而这无法很好地提取电流的长期时序关系。本文引入的转置嵌入层将同一电流互感器的整条时间序列映射成高维的特征表示^[10], 以此独立地刻画了该电流互感器整个历史过程。输入的转变如式 (2) 所示:

$$X \in \mathbb{R}^{P \times N} \rightarrow X \in \mathbb{R}^{N \times N} \quad (2)$$

然后 X 通过一个线性层进行升维, 本文用 D 来表示:

$$X \in \mathbb{R}^{N \times P} \rightarrow X \in \mathbb{R}^{N \times D} \quad (3)$$




图2 Gatedformer 模型整体结构

2.2.2 门控注意力机制

对于长时间序列预测问题, 关键的目标是从历史数据中提取非线性关系。先前的工作大多都是针对原始注意力机制进行改进, 如对注意力结构进行压缩, 只选取特定区域的注意力^[11]。本文不通过对注意力机制内部结构进行改变, 而是在特征输入注意力结构前, 构建一个门控网络结构进行特征预提取, 该部分内容可以作为一个通用的插件适用在注意力机制前, 如图2所示。该模块分别用2个卷积层作为过滤器和门结构, 通过tanh和sigmoid激活层获得电流值在时间序列上的非线性关系。由于在之前的转置嵌入层中形成了以时间序列为向量特征的输入, 因此, 门控注意力机制能够捕获电流互感器在时序上的趋势特征。该模块定义如下:

$$\text{filter} = \tanh(\text{convs}(X)) \quad (4)$$

$$\text{gate} = \text{sigmoid}(\text{convs}(X)) \quad (5)$$

$$\mathbf{X}_{\text{gate}} = \text{filter} \odot \text{gate} \quad (6)$$

式中, \mathbf{X}_{gate} 表示经过门控网络结构后作为注意力机制的输入向量。此后利用常规的注意力机制来揭示不同电流互感器所测电流的相关性, 定义如下所示:

$$\mathbf{Q} = \mathbf{X}_{\text{gate}} \mathbf{W}_Q, \mathbf{K} = \mathbf{X}_{\text{gate}} \mathbf{W}_K, \mathbf{V} = \mathbf{X}_{\text{gate}} \mathbf{W}_V \quad (7)$$

$$\mathbf{A} = \text{Softmax}\left(\frac{\mathbf{Q}(\mathbf{K})^T}{\sqrt{d_h}}\right) \quad (8)$$

式中, $\mathbf{W}_Q, \mathbf{W}_K, \mathbf{W}_V \in R^{D \times D}$ 是可学习参数, 通过矩阵

运算获得注意力分数 $\mathbf{A} \in R^{N \times D \times D}$, 能够捕获不同时刻的局部和全局动态特征和各种时间趋势。最后, 门控注意力机制输出结果为:

$$\mathbf{Z} = \mathbf{A} \mathbf{V} \quad (9)$$

式中, \mathbf{Z} 是单层注意力块输出向量; \mathbf{V} 是注意力机制中各个向量对应的值。

2.2.3 层归一化

层归一化的目的是提高深度学习训练的稳定性和收敛性^[12]。传统的Transformer中, 层归一化会导致各个变量的分布趋于一致, 减少了变量间的差异性。如果采集的时间点未按时间对齐, 操作可能会引入非因果或延迟过程之间的交互噪声。本文在嵌入层引入转置方式, 将各个电流互感器电流的时间序列作为向量处理。由于同一节点的电流值高度相关, 采用层归一化可以有效处理转置后的向量, 如式(10)所示。此外, 所有序列作为变量标记都被归一化为正态分布, 减少了因测量不一致引起的差异。相反, 在以前的架构中, 不同时间步的标记被归一化, 导致序列过度平滑, 其中Mean是平均函数, Var是方差函数。

$$\text{LayerNorm}(\mathbf{Z}) = \left\{ \frac{\mathbf{z}_n - \text{Mean}(\mathbf{z}_n)}{\sqrt{\text{Var}(\mathbf{z}_n)}} \mid n = 1, 2, \dots, N \right\} \quad (10)$$

2.2.4 前馈神经网络

Transformer利用前馈神经网络作为编码向量表示的基本构建块^[13], 传统模型中形成的向量是同一时间采集的多个变量特征, 很难反映一段时间序列的语义信息。而本文引入的转置嵌入层将一个变

量的时间序列映射为一个向量，能够针对独立时间序列进行相同的线性操作，这在最近的一些线性预测器^[14]和通道独立策略模型^[15]中得以证明。线性层的神经元同样可以学习到时间序列的内在属性，如频率谱，周期性、幅值等。因此，使用前馈神经网络能够使得模型泛化性能更好。这里所说的前馈神经网络，本质其实就是一个线性层，可以直接用一个 MLP（全连接层）实现。

2.2.5 线性投影层

输出层部分为了避免逐步预测会产生误差累积的后果，本文使用一个线性投影层直接对未来多个预测时刻进行输出，该多步预测方法能够显著减轻预测误差的累积。

3 实验分析

3.1 数据集

为了验证 Gatedformer 模型在电流互感器在线监测中的效果，本文利用精密电流互感器测试平台提供的数据集进行了实验。该平台模拟了实际电网中一进两出的电气结构和 3 条支路母线电流变化。实验数据集包括模拟电流互感器的一进两出电气结构，其中出线支路额定一次电流为 100 A，进线支路额定一次电流为 200 A，所有互感器的额定二次电流统一为 1 A，工作频率为 50 Hz。系统采用三相四线制 AC220V 供电，并使用高精度采样单元提取站级电流互感器的微弱二次电流信号。通过使用校验仪整检装置作为高精度的标准电流源，测试范围覆盖了 1%~120% 额定电流，结果显示各通道均已完成校准。实验平台按照日和周的周期收集了 70 078 条标准电流值数据，并设置 15 min 为 1 个时间间隔。假设每个采样间隔内实际电流负载保持不变，即电流误差在同一百分比数值范围内波动。为了充分验证所建立的算法在电流互感器计量性能在线评估中的效果，利用上述实验平台的状态评估系统数据集进行了多组实验。

3.2 实验设置

本文实验显卡配置为 NVIDIA GeForce GTX 1080Ti，显存大小为 12 GB，编程语言为 Python3.9，框架为 Pytorch1.7.1，在 Linux 系统上进行实验测试。

Gatedformer 模型中主要的超参数分别是历史时间段 P ，预测未来的时间段 Q ，模型堆叠块数 M ，输入 X 的高层维度嵌入 D 。本文将 P 设置为

672，这是包含了完整一周的历史电流数据，能够让模型学习到每天和每周的周期信息； Q 设置了 4 个值，12、24、48、96，能够更好地验证模型对于未来预测的准确性； M 设置为 3； D 设置为 1 024，经过验证该设计能够让模型的性能更好；模型的 epoch 设置为 10，batchsize 为 128。

为了全面衡量模型的预测精度，本文选取了均方误差（MSE）、平均绝对误差（MAE）和平均绝对百分比误差（MAPE）作为评价指标。均方误差通过计算预测值与真实值之间误差的平方平均值，能够有效反映出预测误差的整体大小，尤其对较大误差更为敏感。平均绝对误差通过计算预测值与真实值之间误差的绝对值平均值，直观反映出预测误差的平均水平，并且不受异常值的过多影响。平均绝对百分比误差则通过计算预测值与真实值之间误差的百分比平均值，提供了一种无量纲的误差评价方式，使得不同量级数据的误差具有可比性。3 个指标互为补充，从不同角度全面评估模型的预测精度：

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (11)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (12)$$

$$\text{MAPE} = 100\% \times \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (13)$$

式中， n 为样本个数； y_i 为真实值； \hat{y}_i 为预测值。

3.3 基线模型对比

本文选取了目前在时间序列预测领域表现优异的模型进行对比，以此来验证本文所提出的模型能够更好地适配电流互感器在线预测的任务。

在实验结果部分，本文所提出的模型与 Autoformer^[16]，FiLM^[17]，FEDformer^[18]，DLinear^[14]，Reformer^[19]，Informer^[20]，NonstationaryTransformer^[21]，Transformer^[22]，TiDE^[23]，PatchTST^[15]，Pyraformer^[24]，LightTS^[25]，Crossformer^[26]，TimesNet^[27] 等经典以及先进的时间序列预测模型在不同预测窗口（12、24、48、96）下展开了详尽的比较，以 15 min 为一个时刻点，预测未来一天中不同时间长度的电流互感器的电流值。实验结果如表 1 所示，列出了各模型在 MSE、MAE、MAPE 等性能指标上的表现，这进一步验证了 Gatedformer 在电流互感器中电流预测任务中的卓越性能。

表 1 模型对比结果表

模型	预测窗口											
	12			24			48			96		
	MSE	MAE	MAPE	MSE	MAE	MAPE	MSE	MAE	MAPE	MSE	MAE	MAPE
Autoformer ^[16]	0.520	0.564	1.186	1.015	0.731	1.362	0.265	0.416	0.844	0.092	0.243	0.489
FiLM ^[17]	0.229	0.378	0.667	0.117	0.241	0.440	0.205	0.339	0.685	0.139	0.296	0.613
FEDformer ^[18]	0.100	0.255	0.489	0.058	0.187	0.388	0.108	0.260	0.534	0.068	0.204	0.414
DLinear ^[14]	0.055	0.170	0.323	0.106	0.229	0.420	0.184	0.316	0.605	0.254	0.398	0.780
Reformer ^[19]	0.027	0.126	0.279	0.030	0.132	0.283	0.022	0.113	0.254	0.015	0.096	0.209
Informer ^[20]	0.017	0.104	0.227	0.019	0.112	0.247	0.017	0.106	0.235	0.020	0.111	0.238
NonstationaryTransformer ^[21]	0.011	0.083	0.188	0.013	0.089	0.196	0.016	0.098	0.210	0.020	0.111	0.228
Transformer ^[22]	0.011	0.081	0.178	0.013	0.114	0.173	0.011	0.083	0.172	0.006	0.060	0.111
TiDE ^[23]	0.009	0.074	0.150	0.009	0.074	0.150	0.009	0.074	0.150	0.009	0.076	0.154
PatchTST ^[15]	0.011	0.081	0.111	0.011	0.080	0.110	0.011	0.082	0.113	0.011	0.083	0.112
Pyraformer ^[24]	0.005	0.045	0.109	0.019	0.071	0.156	0.055	0.131	0.285	0.121	0.207	0.444
LightTS ^[25]	0.003	0.044	0.095	0.003	0.045	0.095	0.004	0.048	0.101	0.004	0.050	0.103
Crossformer ^[26]	0.006	0.043	0.094	0.018	0.062	0.126	0.049	0.103	0.219	0.113	0.181	0.381
TimesNet ^[27]	0.003	0.040	0.090	0.005	0.057	0.129	0.007	0.065	0.149	0.008	0.071	0.160
Gatedformer	0.002	0.038	0.084	0.002	0.038	0.085	0.003	0.040	0.086	0.003	0.043	0.090

可以发现, 先前的各模型对长时间序列的依赖以及长时间预测的波动性可能存在一定挑战。特别地, TimesNet 模型在公开数据集中表现较佳, 但在预测较长窗口 (如 24、48 和 96) 时性能明显下降。相比之下, 本文提出的模型在预测未来 96 个窗口时保持了稳定性, 凸显了 Gatedformer 在长时间序列预测中的稳健性, 有助于更准确地检测电流互感器的电流值。此外, 在较长的预测窗口 (48 和 96) 下, Gatedformer 的 MSE 和 MAE 显著低于其他模型, 证明了其在长期时间序列数据建模方面的优异性能。这一结果再次印证了 Gatedformer 在电流互感器中电流预测任务中的优越性。

最终结果如表 1 所示, 当使用基于 Gatedformer 的电流互感器在线监测方法, 将先一周的时间电

流值作为历史窗口进行预测时, MAPE 可用于评估预测误差百分比, 模型对电流互感器标准电流值的预测误差仅为 0.09%。这一结果再次凸显了 Gatedformer 在处理时间序列预测任务时的高效性和准确性, 为电流互感器在线监测提供了可靠的解决方案, 进一步验证了该方法在实际应用中的有效性和可靠性。

3.4 消融实验

在消融实验中, 本文验证了 Gatedformer 模型在捕捉长期依赖关系方面的优势, 并探究了门控机制对于模型性能的影响。本文选用多个过去时序窗口 {96, 192, 384, 672} 进行对比, 即利用过去最长一周电流互感器的电流值预测未来一天的电流值, 通过表 2 中的结果展示了有无门控网络时模型的表现情况。

表 2 历史时间窗口和门控网络消融实验

历史时间窗口	门控网络	预测窗口评估指标											
		12			24			48			96		
		MSE	MAE	MAPE	MSE	MAE	MAPE	MSE	MAE	MAPE	MSE	MAE	MAPE
96	×	0.004 9	0.051 8	0.115 2	0.006 4	0.057 0	0.124 4	0.008 5	0.067 5	0.143 7	0.013 2	0.085 5	0.183 2
	√	0.004 6	0.049 1	0.109 8	0.005 9	0.054 5	0.118 5	0.007 7	0.064 5	0.137 4	0.010 9	0.079 1	0.168 4
192	×	0.003 7	0.046 6	0.101 6	0.004 4	0.050 9	0.110 1	0.005 5	0.056 8	0.122 4	0.007 4	0.067 2	0.145 5
	√	0.003 3	0.044 1	0.097 0	0.003 9	0.048 0	0.103 4	0.005 1	0.054 4	0.115 8	0.006 6	0.063 2	0.135 4
384	×	0.003 8	0.048 1	0.102 2	0.004 0	0.049 1	0.105 1	0.004 9	0.053 5	0.117 3	0.006 5	0.061 4	0.131 8
	√	0.003 5	0.046 3	0.099 8	0.003 8	0.048 1	0.102 6	0.004 4	0.051 7	0.111 1	0.005 6	0.058 2	0.124 7
672	×	0.002 4	0.039 0	0.086 6	0.002 5	0.039 0	0.085 8	0.002 6	0.040 1	0.086 5	0.003 1	0.043 3	0.092 3
	√	0.002 3	0.037 7	0.083 9	0.002 4	0.038 4	0.084 8	0.002 6	0.040 0	0.086 4	0.003 0	0.042 5	0.090 4

如图 3 所示, 通过对比不同的时间窗口, 可以观察到 Gatedformer 模型随着回望时间窗口的变

长, 评估指标的值越小, 代表着其效果越好, 因此, 在长时间预测区间下表现更佳。具体而言, 当历史回望窗口为 672 个时间间隔时, 即一周电流值的时间跨度时, Gatedformer 的预测效果更佳, 这表明该模型能够很好地学习到电流互感器电流值一周的周期性信息。此外, 在所有时间窗口下, 使用门控网络的 Gatedformer 模型都表现出了更好的性能, 如图 3 所示。这表明门控网络对于提取长时间序列依赖关系具有显著的帮助, 从而提升了模型的预测能力。

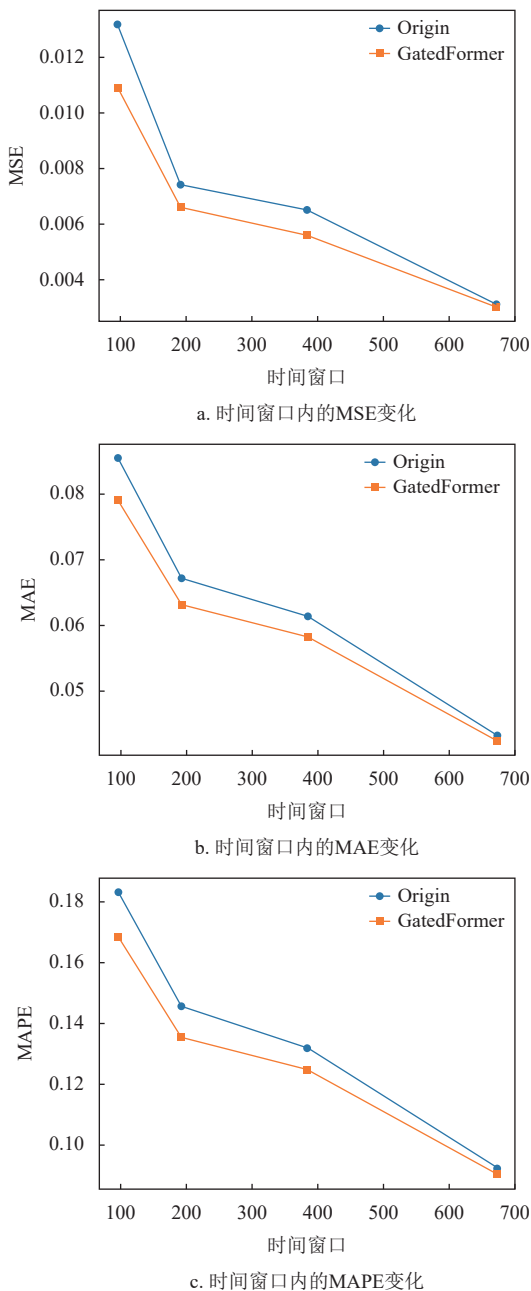


图3 回望窗口时间变化效果图

综上所述, 消融实验结果充分验证了 Gatedformer

模型在捕捉长期依赖关系和处理长时间跨度数据方面的优势, 并突出了门控机制对于模型性能的重要性。这一发现进一步巩固了 Gatedformer 在时间序列预测任务中的可靠性和有效性, 特别是在电流互感器在线监测领域, 其引入能够很好地预测虚拟标准值, 提高了系统的监测精度和稳定性。

4 结束语

本文提出了一种融合维度转置与门控注意力机制的 Gatedformer 模型, 用于电流互感器在线监测。维度转置操作能够有效利用注意力机制集中于时序特征的相关性, 增强多路数据之间的特征解耦能力; 门控注意力机制则进一步优化了时间序列依赖关系的捕捉效果, 显著提升了长时间序列预测的性能。实验结果表明, Gatedformer 在三路电流数据集上的平均预测误差仅为 0.090%, 展现了很好的精度和鲁棒性。该模型为电力设备多路非线性时序数据的建模与预测提供了新思路, 同时具备较强的适应性和可拓展性, 未来将在算法通用性与实时性优化方面继续深入研究。

参考文献

- [1] 曹宇. 计量电流互感器二次回路在线监测技术研究[J]. *电气技术与经济*, 2024(3): 14-15.
CAO Y. Research on on-line monitoring technology of secondary circuit of metering current transformer[J]. *Electrical Equipment and Economy*, 2024(3): 14-15.
- [2] 王斌武, 刘俭, 张军. 计量电流互感器二次回路在线监测技术研究[J]. *电子测量技术*, 2022, 45(17): 29-35.
WANG B W, LIU J, ZHANG J. Research on on-line monitoring technology of secondary circuit of metering current transformer[J]. *Electronic Measurement Technology*, 2022, 45(17): 29-35.
- [3] 张瑞明. 一种电流互感器二次回路多点接地在线监测装置及其监测方法的研究[J]. *山西电力*, 2021(5): 34-37.
ZHANG R M. Research on a multi-point grounding online monitoring device of current transformer secondary circuit and its monitoring method[J]. *Shanxi Electric Power*, 2021(5): 34-37.
- [4] 侯战斌, 郭飞, 闻志国, 等. 电流互感器二次侧接入状态在线监测装置技术[J]. *科技和产业*, 2020, 20(4): 181-185.
HOU Z B, GUO F, WEN Z G, et al. On-line monitoring device technology for secondary side circuit access state of current transformer[J]. *Science Technology and Industry*, 2020, 20(4): 181-185.
- [5] 弥潇, 曹炆, 肖莞. 智能变电站在线监测系统设计[J]. *电气时代*, 2021(10): 60-62.
MI X, CAO Y, XIAO G. Design of online monitoring system for smart substation [J]. *Electrical Times*, 2021, (10): 60-62.

- [6] 韩筛根, 陈驰, 王自桢. 配网用电压电流传感器误差在线测试装置设计及应用[J]. 高压电器, 2020, 56(12): 235-241.
HAN S G, CHEN C, WANG Z Z. Design and application of error online testing device for voltage and current sensors in distribution network[J]. High Voltage Apparatus, 2020, 56(12): 235-241.
- [7] 李贺龙, 袁晓蕾, 赵晓健, 等. 基于BP神经网络的互感器计量误差在线检测[J]. 电气自动化, 2019, 41(6): 83-85.
LI H L, YUAN X L, ZHAO X J, et al. On-line detection of instrument transformer measurement error based on BP neural network[J]. Electrical Automation, 2019, 41(6): 83-85.
- [8] 张蓬鹤, 邓泽官, 王龙华, 等. 计量用互感器在线监测系统的研制[J]. 电测与仪表, 2009, 46(7): 41-44.
ZHANG P H, DENG Z G, WANG L H, et al. The development of the metric transformer online monitoring system[J]. Electrical Measurement & Instrumentation, 2009, 46(7): 41-44.
- [9] 胡琛, 张竹, 杨爱超, 等. 电子式电流互感器误差模型及误差状态预测方法[J]. 电力工程技术, 2020, 39(4): 187-193.
HU C, ZHANG Z, YANG A C, et al. Error model and forecasting method for electronic current transformers[J]. Electric Power Engineering Technology, 2020, 39(4): 187-193.
- [10] LIU Y, HU T G, ZHANG H R, et al. iTransformer: Inverted transformers are effective for time series forecasting[EB/OL]. (2023-10-10)[2024-09-01]. <https://arxiv.org/abs/2310.06625>.
- [11] GENG Z L, XU J, WU R S, et al. STGAformer: Spatial-temporal Gated Attention Transformer based Graph Neural Network for traffic flow forecasting[J]. Information Fusion, 2024, 105: 102228.
- [12] BA J L, KIROS J R, HINTON G E. Layer normalization [EB/OL]. [2024-09-01]. <https://doi.org/10.48550/arXiv.1607.06450>.
- [13] HORNIK K. Approximation capabilities of multilayer feedforward networks[J]. Neural Networks, 1991, 4(2): 251-257.
- [14] ZENG A L, CHEN M X, ZHANG L, et al. Are transformers effective for time series forecasting?[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(9): 11121-11128.
- [15] NIE Y Q, NGUYEN N H, SINTHONG P, et al. A time series is worth 64 words: Long-term forecasting with transformers[EB/OL]. [2024-09-01]. <https://doi.org/10.48550/arXiv.2211.14730>.
- [16] WU H, XU J, WANG J, et al. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting[J]. Advances in Neural Information Processing Systems, 2021, 34: 22419-22430.
- [17] ZHOU T, MA Z Q, WANG X, et al. Film: Frequency improved legendre memory model for long-term time series forecasting[J]. Advances in Neural Information Processing Systems, 2022, 35: 12677-12690.
- [18] ZHOU T, MA Z Q, WEN Q S, et al. Fedformer: Frequency enhanced decomposed transformer for long-term series forecasting[C]//International Conference on Machine Learning. Baltimore: PMLR, 2022: 27268-27286.
- [19] KITAEV N, KAISER Ł, LEVSKAYA A. Reformer: The efficient Transformer[EB/OL]. [2024-09-01]. <https://doi.org/10.48550/arXiv.2001.04451>.
- [20] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12): 11106-11115.
- [21] LIU Y, WU H, WANG J, et al. Non-stationary transformers: Exploring the stationarity in time series forecasting[J]. Advances in Neural Information Processing Systems, 2022, 35: 9881-9893.
- [22] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017: 6000-6010.
- [23] DAS A, KONG W H, LEACH A B, et al. Long-term forecasting with tide: Time-series dense encoder[EB/OL]. [2024-09-01]. <https://arxiv.org/abs/2304.08424>.
- [24] LIU S Z, YU H, LIAO C, et al. Pyraformer: Low-complexity pyramidal attention for long-range time series modeling and forecasting[EB/OL]. [2024-09-01]. <https://openreview.net/pdf?id=0EXmFzUn51>.
- [25] ZHANG T, ZHANG Y Z, CAO W, et al. Less is more: Fast multivariate time series forecasting with light sampling-oriented MLP structures[EB/OL]. [2024-09-04]. <https://doi.org/10.48550/arXiv.2207.01186>.
- [26] ZHANG Y H, YAN J C. Crossformer: Transformer utilizing cross dimension dependency for multivariate time series forecasting[C]//The 11th International Conference on Learning Representations. Kigali: ICLR, 2023: 5268-5288.
- [27] WU H X, HU T, LIU Y, et al. Timesnet: Temporal 2D-variation modeling for general time series analysis [C]//The 11th International Conference on Learning Representations. Kigali: ICLR, 2023: 6423-6445.