引用格式:侯小娥,王宁,寿绍安,等.基于时域融合变换器的配电网电能质量预测模型[J].电力科学与技术学报,2025,40(6):156-163.
Citation: HOU Xiao'e, WANG Ning, SHOU Shaoan, et al. Prediction model for power quality of distribution networks based on temporal fusion transformer[J]. Journal of Electric Power Science and Technology,2025,40(6):156-163.

基于时域融合变换器的配电网电能质量预测模型

侯小娥,王　宁,寿绍安,李　富,张　洁,魏文婷
(国网宁夏电力有限公司吴忠供电公司,宁夏 吴忠 751100)

摘　要:电能质量的异常检测对于配电网的可靠运行至关重要,其精准性直接关系到电网系统的稳定性和安全性。而在实际工作中,通过人力对异常情况进行实地分析不仅费时费力,且无法做到提前治理。为此,提出一种结合特征筛选、信号分解和基于注意力的深度神经网络的配电网电能质量异常预测模型。首先,采用基于最大互信息系数(maximal information coefficient,MIC)的快速相关性滤波算法(fast correlation-based filter,FCBF)组合特征筛选方法对输入数据进行特征选择。其次,将选定的输入特征和相应组件输入时域融合变换器(temporal fusion transformer,TFT)模型进行预测,输出电压偏差、频率偏差和谐波畸变率等电能质量异常预测结果。与传统模型相比,该模型显著降低了复杂性和计算时间,并能提高故障诊断的准确性。该方法实现了对电能质量的实时监测,推动了配电网运维日常管理的智能化、可视化。

关　键　词:时域融合变换器;电能质量;故障预测;深度学习
DOI:10.19781/j.issn.1673-9140.2025.06.015　　**中图分类号**:TM711　　**文章编号**:1673-9140(2025)06-0156-08

Prediction model for power quality of distribution networks based on temporal fusion transformer

HOU Xiao′e, WANG Ning, SHOU Shaoan, LI Fu, ZHANG Jie, WEI Wenting
(Wuzhong Power Supply Company, State Grid Ningxia Electric Power Co., Ltd., Wuzhong 751100, China)

Abstract: Anomaly detection of power quality is crucial for the reliable operation of the distribution network, and its accuracy is directly related to the stability and security of the power grid system. In practice, it is not only time-consuming and laborious to analyze the anomaly in the field by manpower but also impossible to manage the anomaly in advance. To this end, a prediction model for power quality anomaly of distribution networks, which combines feature screening, signal decomposition, and an attention-based deep neural network, is proposed. First, the fast correlation-based filter (FCBF) algorithm based on maximal information coefficient (MIC) is combined with a feature screening method to select features of the input data. Then, the selected input features and corresponding components are fed into the temporal fusion transformer (TFT) model for prediction, and the prediction results of power quality anomalies such as voltage deviation, frequency deviation, and harmonic distortion rate are output. The complexity and computation time are significantly reduced, and the accuracy of fault diagnosis is potentially improved by the model, compared to conventional models. The real-time monitoring of power quality is realized, and the intelligence and visualization of the daily management of distribution network operation and maintenance are promoted.

Key words: temporal fusion transformer; power quality; fault prediction; deep learning

电能质量已成为保障电力系统运行稳定性和设备可靠性的关键因素。随着电力系统结构日益复杂、敏感设备数量增加,电能质量管理的重要性进一步提升。然而,传统电能质量监测方法难以实

收稿日期:2025-01-08;**修回日期**:2025-03-28
基金项目:国网宁夏电力有限公司科技项目(SGNXWG00HLXX2310924)
通信作者:侯小娥(1985—),女,副高级工程师,主要从事大数据分析、数字化建设等方面的研究;E-mail:63097233@163.com

现对故障的准确预测与识别，进而限制了问题的及时处理和系统的优化运行[1-3]。近年来，随着机器学习技术的发展，许多学者将其运用于电力系统故障预测。文献[4]首先利用小波变换提取配电网干扰信号，随后采用支持向量机（support vector machine，SVM）进行识别；文献[5]提出两级 SVM 分类器模型：第一级用于识别微电网运行模式、发电量及负荷变化并进行故障预测，第二级用于确定故障类型并实现定位；文献[6]提出基于可调 Q 小波变换和双多类支持向量机的扰动信号自动识别方法。SVM 在小样本条件下通常能取得较好效果，但电力系统运行产生的海量数据会导致计算量激增、预测精度下降。文献[7]以电压、功率频率、总谐波失真和闪变严重程度等作为离网系统的电能质量指标，研究温度、电池状态及 PQ 参数等因素对电能质量的影响，并采用随机森林模型进行预测。文献[8]采用 K-medoids 方法对电能数据进行聚类，并基于聚类结果选取电能质量阈值。文献[9]基于模糊聚类算法提出一种兼顾数据聚类特性的电能质量划分方法，克服了传统方法灵活性不足的问题。文献[10]利用模糊聚类设定电能质量阈值，结合遗传算法优化的反向传播（back propagation，BP）神经网络，对天气、功率及电能质量历史数据等因素进行综合分析，实现多级预警。文献[11]依据电能质量非周期性特征，提出融合混沌理论与最小二乘支持向量机的预测模型，并借助粒子群优化算法调优模型参数，进一步提升预测效果。文献[12]将聚类、动态时间规整（dynamic time warping，DTW）和蒙特卡罗算法相结合，对电能质量进行分析预测，但蒙特卡罗算法存在结果不稳定的缺陷。文献[13]考虑多种可能影响电能质量的外部环境因素，首先利用 ReliefF 算法筛选出强关联因素，随后综合 Elman 神经网络、随机森林及 RBF-SVM 模型进行预测。文献[14]在考虑气象因素和有功负荷对电压影响的基础上，首先采用改进的核主成分分析（kernel principal components analysis，KPCA）算法进行数据降维，随后构建 GA-BP 神经网络预测电压偏差。文献[15]研究气象因素对电能质量的影响，先采用 PCA 对气象数据降维，再通过近邻传播（affinity propagation，AP）聚类和 K-Means 聚类进行数据处理，最终构建 BP 神经网络预测电压偏差。文献[16]以电压偏差、短时闪变和电压总谐波畸变率作为电能质量预测评估指标，利用长短期记忆（long short-term memory，LSTM）网络预测电能质量变化趋势。文献[17]提出基于自回归移动平均数（autoregressive integrated moving average model，ARIMA）时间序列模型与 LSTM 网络的电压偏差预测模型，结果表明组合模型的预测效果优于单一模型。文献[18]将 LSTM-TCN 模型用于分布式光伏功率预测，并与 XGBoost、ELM 预测模型对比，结果显示 LSTM-TCN 具备更高的准确度。文献[19]利用双向长短期记忆网络（bidirectional long short-term memory，BiLSTM）实现负荷预测，效果优于单向 LSTM 模型。然而，LSTM 在单向时间序列预测时难以捕捉长距离依赖关系[20]。

针对电力系统运行中数据结构日益复杂、特征维度庞大的问题，本文提出一种基于 TFT 神经网络的配电网电能质量异常预测模型。首先采用基于最大互信息系数（maximal information coefficient，MIC）的快速相关性滤波（fast correlation-based filter，FCBF）方法进行复合特征筛选；随后将筛选后的特征输入时域融合变换器（temporal fusion transformer，TFT）网络进行预测，输出三相不平衡、低电压、重过载等电能质量异常；最后将本模型与 LSTM 网络和 BP 神经网络进行比较。本文选取宁夏某地区配电网的电能数据作为算例进行分析，结果表明该方法具备较高的预测精度。

1　模型设计

1.1　MIC 方法

MIC 算法是一种用于捕捉两变量之间关系强度的非参数方法。MIC 通过评估不同数据集子集的互信息并选择最大值来计算。它包括划分数据集、计算每个子集的互信息并归一化、选择最高值。这种方法可量化线性或非线性相关性，保留强相关变量的信息，并处理弱相关变量之间的非线性关系。互信息计算公式为

$$I(X;\ Y)=\sum_{x\in X}\sum_{y\in Y}p(x,y)\log_{10}\frac{p(x,y)}{p(x)p(y)} \tag{1}$$

式中，X、Y 为一对随机变量，将平面分成 $x\times y$ 的网格；x、y 分别为 X 和 Y 方向的划分数；$p(x,y)$ 为联合概率分布；$p(x)$、$p(y)$ 为边缘概率分布。

为了将不同划分下的互信息标准化，MIC 通过最大可能的划分数 $B(n)$ 进行归一化：

$$M(X;\ Y)=\max_{x,y\leqslant B(n)}\frac{I(X;\ Y)}{\log_{10}\min(x,y)} \tag{2}$$

式中，n 为样本大小；$B(n)$ 为依赖于样本大小的划分

数限制，用于标准化互信息值。按照MIC方法的建议，通常设置为$B=n^{0.6}$，能在保证计算效率的同时保留变量间的复杂关系。

最后，对所有可能的网格划分组合，MIC选择归一化后的最大互信息值作为2个变量之间关系强度的度量值，即

$$\mathrm{MIC}(X,Y)=\max_{x,y}M(X,Y) \tag{3}$$

1.2 FCBC方法

FCBF算法是一种特征选择方法，主要用于从高维数据集中快速筛选出与目标变量强相关的特征，同时过滤冗余特征。该算法利用对称不确定性(symmetrical uncertainty，SU)度量来量化特征之间的相关性，并通过定义相关性和冗余性来进行特征选择。

定义2个随机变量$X=\{x_1,x_2,\cdots,x_i\}(i=1,2,\cdots,m)$，$Y=\{y_1,y_2,\cdots,y_j\}(j=1,2,\cdots,m)$，随机变量$X$的信息熵$H(X)$和随机变量$X$在变量$Y$条件下的信息熵$H(X|Y)$的定义分别为

$$H(X)=-\sum_i P(x_i)\log_2 P(x_i) \tag{4}$$

$$H(X|Y)=-\sum_j P(y_i)P(x_i|y_i)\log_2 P(x_i) \tag{5}$$

式中，$P(x_i)$、$P(y_j)$分别为随机变量X和Y取值x_i和y_i的概率；$P(x_i|y_j)$为$Y=y_i$时，$X=x_i$的概率。随机变量X和Y之间相关信息的测量方法定义为互信息，两者之间的互信息为

$$I(X;Y)=H(X)-H(X|Y) \tag{6}$$

通过$S_{\mathrm{U}}(X,Y)$衡量变量X和Y的相关性，即

$$S_{\mathrm{U}}(X,Y)=2\times\frac{I(X;Y)}{H(X)+H(Y)} \tag{7}$$

S_{U}值介于0和1之间，值越大表示2个变量之间的相关性越强。对于每个特征F_i，计算其与目标变量C的SU值$S_{\mathrm{U}}(F_i,C)$。如果$S_{\mathrm{U}}(F_i,C)$大于设定的阈值δ，则认为该特征与目标变量相关，可以保留。在筛选出与目标变量相关的特征后，进一步检查这些特征之间的冗余性。对于每一对特征F_i，如果$S_{\mathrm{U}}(F_i,F_j)>S_{\mathrm{U}}(F_i,C)$，则认为$F_j$是冗余特征，并将其移除。

1.3 TFT神经网络

TFT是一种基于原始Transfoemer模型的深度学习模型，专为时间序列预测而设计[21]。TFT结合了Transformer和循环神经网络(recurrent neural network，RNN)，旨在有效捕捉序列数据中的长期依赖关系和时间模式。虽然基于Transformer的模型因其并行化能力而广受欢迎，但由于缺乏对时间的内在理解，在处理顺序数据时可能会遇到困难。TFT通过引入一种结合了位置嵌入和注意力机制的新型架构来解决这一局限性，使其能够有效地建立顺序依赖关系模型。TFT架构如图1所示。

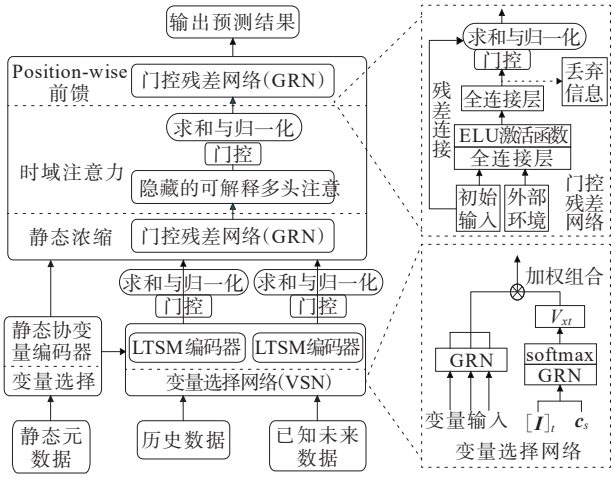

图1 TFT网络架构

Figure 1 TFT network architecture

TFT的输入分为3个不同的部分：历史输入、已知未来输入、静态输入。历史输入可表示为$X(t)=[X_1,X_2,\cdots,X_t]$。未来输入表示为$X(t)=[X_{t+1},X_{t+2},\cdots,X_{t+\tau}]$，作为先验变量，与预测目标位于同一时间范围内。这里τ为预测步长，即要预测的未来时间单位数。静态输入包括与时间无关的变量。TFT的网络结构主要由以下部分组成。

1）门控残差网络(gate residual network，GRN)，GRN在处理时间序列数据方面具有优越性。它的工作原理是对输入数据进行线性变换，然后通过一个sigmoid门控层来确定每个变换特征的相关性。这种门控机制能过滤信息并确定优先级，只允许最相关的特征影响模型的预测。此外，在GRN中加入残差连接有助于在反向传播过程中使梯度流动更加顺畅，从而增强模型从短期和长期时间依赖关系中学习的能力。GRN的表达式为

$$\mathrm{GRN}_\omega(a,c)=\mathrm{LayerNorm}(a+\mathrm{GLU}_\omega(\eta_1)) \tag{8}$$

$$\eta_1=W_{1,\omega}\eta_2+b_{1,\omega} \tag{9}$$

$$\eta_2=\mathrm{ELU}(W_{2,\omega}a+W_{3,\omega}c+b_{2,\omega}) \tag{10}$$

式中，a为输入量；b为偏差；c为上下文信息；W为权重值；LayerNorm为层归一化；GLU为门控线性单元；η_1、η_2为中间层；ω为权重共享；ELU为线性单元激活函数。GLU的表达式如下：

$$\mathrm{GLU}_\omega(\gamma)=\sigma(W_{4,\omega}\gamma+b_{4,\omega})\odot(W_{5,\omega}\gamma+b_{5,\omega}) \tag{11}$$

式中，$\sigma(\cdot)$为 sigmoid 激活函数；$\odot$ 为逐元素相乘。

2）TFT 通过变量选择网络（VSN）进行变量选择。这些网络有助于为每个预测步骤确定最相关的变量。通过为输入分配重要性权重，VSN 可以有效地滤噪音，使 TFT 能够专注于最能预测未来趋势的数据。这一机制通过识别时间序列数据中的关键影响变量，提高了模型的预测精度。设 $\xi_t^{(j)}$ 为第 j 个变量在 t 时刻经过转换后的输入，其中 $[\boldsymbol{I}]_t = \left[\xi_t^{(1)^{\mathrm{T}}}, \xi_t^{(2)^{\mathrm{T}}}, \cdots, \xi_t^{(m_x)^{\mathrm{T}}}\right]^{\mathrm{T}}$，为 t 时刻所有历史输入的矩阵。向 GRN 输入 $[\boldsymbol{I}]_t$ 和外部环境向量 $\boldsymbol{c}_s$，然后通过 Softmax 层得到变量选择权重：

$$V_{xt} = \mathrm{Softmax}(\mathrm{GRN}_{V_x}([\boldsymbol{I}]_t, \boldsymbol{c}_s)) \tag{12}$$

Softmax 层对权重进行归一化处理，确保其总和为 1。每经过一个步长，$\xi_t^{(j)}$ 就被输入到 GRN 进行非线性处理，即

$$\xi_t^{(j)} = \mathrm{GRN}_{\xi(j)}(\xi_t^{(j)}) \tag{13}$$

最后，根据变量选择权重对处理后的特征进行加权和组合，即

$$\xi_t = \sum_{j=1}^{m_x} v_{xt}^{(j)} \xi_t^{(j)} \tag{14}$$

3）可解释多头注意力机制：TFT 模型采用自注意力机制来学习不同时间步长的长期关系，该模型在基于变换器架构的多头注意力机制基础上进行了改进，以增强时间序列预测的可解释性。自注意力的公式为

$$\mathrm{Attention}(\boldsymbol{Q}, \boldsymbol{K}, \boldsymbol{V}) = \mathrm{Softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_k}}\right)\boldsymbol{V} \tag{15}$$

式中，$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 分别为查询、键、值 3 种矩阵；d_k 为键向量的维度。

在自注意力的基础上，多头注意力机制引入了多个注意力头，从而并行地对不同维度的输入信息进行处理。每个子空间对应的注意力头表达式为

$$H_i = \mathrm{Attention}(\boldsymbol{W}_i^{\mathrm{Q}}, \boldsymbol{W}_i^{\mathrm{K}}, \boldsymbol{W}_i^{\mathrm{V}}) \tag{16}$$

式中，$\boldsymbol{W}_i^{\mathrm{Q}}, \boldsymbol{W}_i^{\mathrm{K}}, \boldsymbol{W}_i^{\mathrm{V}}$ 分别为第 i 个注意力头的查询、键、值变换矩阵。最后，将各注意力头进行线性整合，得到多头注意力的输出为

$$\mathrm{MultiHead}(\boldsymbol{Q}, \boldsymbol{K}, \boldsymbol{V}) = \mathrm{Concat}(H_1, H_2, \cdots, H_h)\boldsymbol{W}^{\mathrm{O}} \tag{17}$$

式中，$\boldsymbol{W}^{\mathrm{O}}$ 为输出变换矩阵；Concat(•)为拼接。

4）分位数损失函数。TFT 通过同时预测每个时间步的不同百分位数来生成点预测区间，分位数通常包括 10%、50% 和 90%，代表了下限、中位数和上限的预测值。对于每个分位数 τ，通过计算对应的分位数损失函数，并将所有分位数的损失值相加，作为整体损失函数并进行优化。表达式如下：

$$L(\Omega, W) = \sum_{y_t \in \Omega} \sum_{q \in Q} \sum_{\tau=1}^{\tau_{\max}} \frac{QL(y_t, \bar{y}(q, t-\tau, t))}{M\tau_{\max}} \tag{18}$$

$$QL(y_t, \bar{y}, q) = q(y - \bar{y})_+ + (1-q)(y - \bar{y})_+ \tag{19}$$

式中，Ω 为包含 M 个样本的训练集；W 为权重值；Q 为输出分位数；$(\cdot)_+$ 为 $\max(0, \cdot)$；$y - \bar{y}$ 为真实值与预测值之差；$q \in Q$。

2　配电网电能质量异常预测模型

2.1　电能质量异常预测模型构建

本文提出了一种基于 MIC-FCBF 和 TFT 神经网络的配电网电能质量异常预测模型。具体步骤如下：

1）采集温度、湿度、气压等环境数据与配电网有功负荷等电力数据；

2）对数据进行归一化处理；

3）对输入数据应用 MIC-FCBF 组合特征选择方法进行特征筛选，过滤冗余数据；

4）将筛选后的最佳特征输入 TFT 网络并对电能质量进行预测。

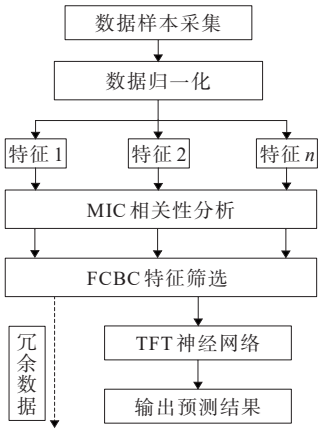

图 2　电能质量异常预测模型流程

Figure 2　Flow of prediction model for power quality anomaly

2.2　数据的预处理

在深度学习中，数据归一化是常见的数据预处理步骤，其主要目的是改善模型训练效果和加快收敛速度。输入数据的特征值范围过大或过小时，可能会导致数值计算中的不稳定，归一化可以将数据缩放到一个统一的范围，有助于减少不同特征之间的尺度差异，加快模型的收敛速度，从而减少训练时间。

本文采用以下式子进行归一化处理：

$$x_{\text{norm}}=\frac{x-x_{\min}}{x_{\max}-x_{\min}} \tag{20}$$

式中，x 为初始数据；$x_{\min}$ 为数据集中最小值；$x_{\max}$ 为数据集中最大值，归一化后的数据分布在[0,1]。

3 配电网电能质量预测结果与分析

配电网电能质量受到多种因素的影响，这些因素可能来自系统负载特性以及外部环境等。本文综合外部环境、负荷因素和历史电能数据等因素，如表1所示。本文选取宁夏某地区2024年4～6月的配电网监测系统数据，数据由地方电网公司提供，包含多条10 kV配电线路的运行记录。预测点位选取某典型工业区变压器低压侧的电能智能监测点，以环境、负荷以及历史电能数据作为输入，分别以电压偏差、频率偏差和谐波畸变率作为预测输出，实际配电系统中频率偏差通常维持在±0.02 Hz以内，异常波动相对罕见。为了增强模型对潜在频率异常的识别能力，本文在训练集中人工筛选并引入了历史运行过程中出现的频率异常数据段，从而使模型能够学习频率异常模式的特征表示。为检验TFT神经网络的预测效果，本文另采用BP神经网络、LSTM和RNN进行预测，模型参数设置如表2所示，各模型预测结果如图3～5所示。

表1 电能质量影响因素

Table 1 Influencing factors of power quality

影响因素	特征
环境影响	温度
	湿度
	降水量
	风速
	风向
	光照强度
负荷类别	第一产业负荷
	第二产业负荷
	第三产业负荷
	居民生活负荷
	其他负荷
历史电能数据	电压偏差
	频率偏差
	谐波畸变率
	有功功率
	无功功率

表2 模型参数设置

Table 2 Model parameter settings

模型	模型参数设置
TFT神经网络	学习率=0.01，注意头数量=1，隐藏层数量=16，隐藏层神经元数量=5，每次迭代数据集大小=80。
BP神经网络 LSTM RNN	学习率=0.01，隐藏层神经元数量=100，迭代次数=200。

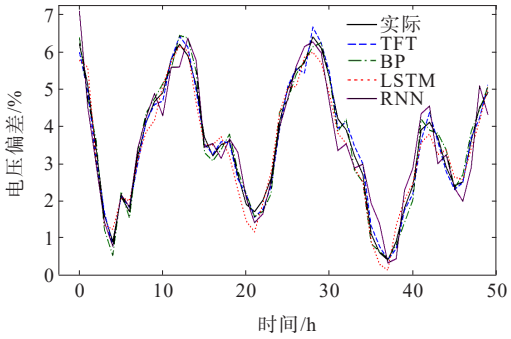

图3 电压偏差预测结果

Figure 3 Voltage deviation prediction results

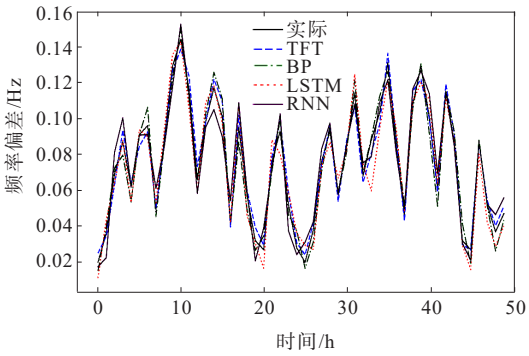

图4 频率偏差预测结果

Figure 4 Frequency deviation prediction results

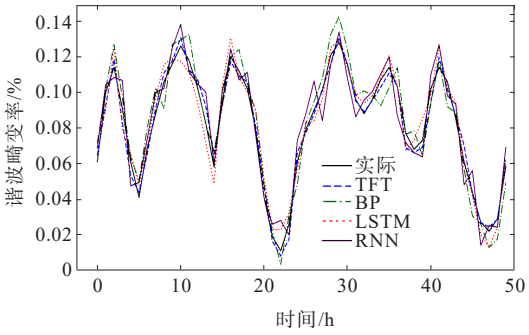

图5 谐波畸变率偏差预测结果

Figure 5 Deviation prediction results of harmonic distortion rate

本文采用 e_{MEA}、e_{RMSE}、e_{R^2} 评价指标对模型预测效果进行评估，通常 e_{MEA}、e_{RMSE} 越接近 0，e_{R^2} 越接近 1，代表模型的预测效果越好。计算公式分别为

$$e_{MAE}=\frac{1}{n}\sum_{1}^{n}\left|y_i-\tilde{y}_i\right| \tag{21}$$

$$e_{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i-\check{y}_i)^2} \tag{22}$$

$$e_{R^2}=1-\frac{\sum_{i=1}^{n}(y_i-\check{y}_i)^2}{\sum_{i=1}^{n}(y_i-\bar{y}_i)^2} \tag{23}$$

其中，n 为样本数量；y_i 为第 i 个样本的实际值；$\check{y}_i$ 为第 i 个样本的预测值；$\bar{y}$ 为样本实际值的均值。

模型评价结果如表 3 所示，在对电压偏差、频率偏差和谐波畸变率的预测中，TFT 神经网络的评价得分均优于其他预测模型，表明 TFT 神经网络在数据环境复杂的配电网电能质量预测方面表现出更高的精确性。

为了验证不同类型输入特征对电能质量预测精度的影响，本文设计 3 组实验：实验 A，包含环境因素、负荷因素、历史电能质量特征（全特征组合）；实验 B，剔除环境因素，仅保留负荷和历史特征；实验 C，剔除负荷因素，仅保留环境和历史特征。表 4 展示了各组合下的预测性能指标。

整体来看，采用全部特征（实验 A）时模型表现最佳，3 个预测任务的 e_{MAE} 与 e_{RMSE} 最小，e_{R^2} 最高。

在电压偏差预测中，剔除负荷类型信息（实验 C）显著提高了误差（e_{MAE} 由 0.159 6 上升至 0.191 5），说明负荷类型对电压波动影响较大。这与实际配电网中不同类型负荷引起电压波动的规律相符。

表 3　模型评价结果

Table 3　Model evaluation results

预测指标	预测模型	e_{MAE}	e_{RMSE}	e_{R^2}
电压偏差	TFT 神经网络	0.159 6	0.180 9	0.987 6
	BP 神经网络	0.228 4	0.259 0	0.974 5
	LSTM	0.284 3	0.317 7	0.961 7
	RNN	0.385 6	0.450 8	0.922 8
频率偏差	TFT 神经网络	0.004 1	0.004 7	0.979 4
	BP 神经网络	0.005 3	0.006 1	0.965 4
	LSTM	0.007 1	0.008 5	0.932 2
	RNN	0.006 8	0.008 1	0.938 3
谐波畸变率	TFT 神经网络	0.003 9	0.004 7	0.977 6
	BP 神经网络	0.007 9	0.009 1	0.916 5
	LSTM	0.006 3	0.007 2	0.947 1
	RNN	0.008 3	0.009 4	0.910 9

表 4　不同输入特征组合下的预测性能比较

Table 4　Comparison of prediction performance under different combinations of feature inputs

预测指标	组合方式	e_{MAE}	e_{RMSE}	e_{R^2}
电压偏差	实验 A	0.159 6	0.180 9	0.987 6
	实验 B	0.176 3	0.201 5	0.975 8
	实验 C	0.191 5	0.214 6	0.968 7
频率偏差	实验 A	0.004 1	0.004 7	0.979 4
	实验 B	0.006 3	0.007 2	0.941 2
	实验 C	0.004 8	0.005 5	0.969 5
谐波畸变率	实验 A	0.003 9	0.004 7	0.977 6
	实验 B	0.005 7	0.006 9	0.936 4
	实验 C	0.004 1	0.004 9	0.973 2

对于频率偏差，当剔除环境因素（实验 B）后，模型精度明显下降（e_{R^2} 从 0.979 4 下降至 0.941 2），表明环境因素（如温度、风速）通过影响新能源出力或用电行为，对频率稳定性具有间接作用。

在谐波畸变率预测中，模型在缺少环境因素时也表现出较大误差提升，验证了谐波水平对外界环境变化的敏感性，特别是在大量非线性负载存在的场景中。

总体来看，环境因素与负荷特征的引入对于全面刻画电能质量波动规律具有重要意义，有助于提升模型的泛化能力和预测准确性。

4　结语

本文构建了基于 TFT 神经网络的配电网电能质量预测模型，对电压偏差、频率偏差和谐波畸变率 3 个电能质量指标进行预测。首先考虑了外部环境、负荷类别作为电能质量影响因素，结合历史电能数据作为输入，通过 MIC-FCBC 方法对输入特征进行降维处理，然后将优化的特征数据输入 TFT 神经网络进行预测，最后与 BP 神经网络、LSTM、RNN 模型进行对比分析。结果表明，TFT 神经网络相比传统的预测模型具有良好的电能质量预测能力。

参考文献：

[1]　林泽源，王宗尧，张凡，等．考虑氢能应用的光伏直流

微电网中储能容量配置寻优方法研究[J]. 高压电器, 2024, 60(7): 78-87.
LIN Zeyuan, WANG Zongyao, ZHANG Fan, et al. Research on optimization method for energy storage capacity configuration in photovoltaic DC micro grid considering hydrogen energy application[J]. High Voltage Apparatus, 2024, 60(7): 78-87.

[2] 付宽, 王洪新, 刘杰, 等. 基于马尔可夫变迁场和EfficientNet的复合电能质量扰动识别[J]. 电网与清洁能源, 2024, 40(4): 74-83.
FU Kuan, WANG Hongxin, LIU Jie, et al.Recognition of composite power quality disturbances based on MTF-efficientnet convolutional neural network[J].Power System and Clean Energy, 2024, 40(4): 74-83.

[3] 时帅, 陈子文, 黄冬梅, 等. 基于MTF可视化和改进DenseNet神经网络的电能质量扰动识别算法[J]. 电力科学与技术学报, 2024, 39(4): 102-111.
SHI Shuai, CHEN Ziwen, HUANG Dongmei, et al. An identification method based on MTF visualization and improved DenseNet for power quality disturbances[J]. Journal of Electric Power Science and Technology, 2024, 39(4): 102-111.

[4] HUANG J S, JIANG Z H, RYLANDS L, et al. SVM-based PQ disturbance recognition system[J]. IET Generation, Transmission & Distribution, 2018, 12(2): 328-334.

[5] AISWARYA R, NAIR D S, RAJEEV T, et al. A novel SVM based adaptive scheme for accurate fault identification in microgrid[J]. Electric Power Systems Research, 2023, 221: 109439.

[6] THIRUMALA K, PRASAD M S, JAIN T, et al. Tunable-Q wavelet transform and dual multiclass SVM for online automatic detection of power quality disturbances[J]. IEEE Transactions on Smart Grid, 2018, 9(4): 3018-3028.

[7] 李琦, 许素安, 施阁, 等. 基于S变换和IWOA-SVM的复合电能质量扰动识别[J]. 智慧电力, 2023, 51(5): 30-35+50.
LI Qi, XU Su'an, SHI Ge, et al. Identification of composite power quality disturbance based on S-transform and IWOA-SVM[J]. Smart Power, 2023, 51(5): 30-35+50.

[8] 卢验锋, 郜幔幔, 钟红梅, 等. 考虑数据聚类特性的电能质量分级预警阈值设置方法[J]. 电力电容器与无功补偿, 2016, 37(3): 88-94.
LU Yanfeng, GAO Manman, ZHONG Hongmei, et al. Graded early warning threshold setting method of power quality considering the data clustering features[J]. Power Capacitor & Reactive Power Compensation, 2016, 37(3): 88-94.

[9] 向星宇, 刘敬之, 曲全磊, 等. 基于RF-PSO-BP的电能质量稳态指标预测[J]. 电子设计工程, 2023, 31(22): 116-120.
XIANG Xingyu, LIU Jingzhi, QU Quanlei, et al. Power quality steady state index prediction based on RF-PSO-BP[J]. Electronic Design Engineering, 2023, 31(22): 116-120.

[10] 武晨晨, 苗霁, 祝佳楠, 等. 遗传算法优化BP神经网络的电能质量预测预警研究[J]. 电工电气, 2021(9): 18-22.
WU Chenchen, MIAO Ji, ZHU Jianan, et al. Power quality prediction and warning based on BP neural network optimized by genetic algorithm[J]. Electrotechnics Electric (Jiangsu Electrical Apparatus), 2021(9): 18-22.

[11] 张成, 赵涛, 朱爱华,等. 弱电网下并联逆变器稳定性及电能质量治理研究[J]. 电力工程技术, 2022, 41(3): 224-230.
ZHANG Cheng, ZHAO Tao, ZHU Aihua, et al. Stability and power quality control of parallel inverters in weak current network[J]. Electric Power Engineering Technology,2022,41(3): 224-230.

[12] 卢珏, 孙云莲, 谢信霖, 等. 基于改进组合预测的电能质量预警研究[J].电工电能新技术,2020(9): 65-73.
LU Jue, SUN Yunlian, XIE Xinlin, et al. Research on power quality early warning based on improved combined forecasting[J]. Advanced Technology of Electrical Engineering and Energy, 2020, 39(9): 65-73.

[13] 于西西, 杨秀, 王知芳, 等. 基于改进KPCA和GA-BP神经网络的电能质量稳态指标预测[J]. 水电能源科学, 2019, 37(5): 189-193.
YU Xixi, YANG Xiu, WANG Zhifang, et al. Power quality steady state indices forecasting based on improved kernel principal component analysis and GA-BP neural network[J]. Water Resources and Power, 2019, 37(5): 189-193.

[14] 王知芳, 杨秀, 潘爱强, 等. 基于改进集成聚类和BP神经网络的电压偏差预测[J]. 电工电能新技术, 2018, 37(5): 73-80.
WANG Zhifang, YANG Xiu, PAN Aiqiang, et al. Voltage deviation forecasting based on improved ensemble clustering and BP neural network[J]. Advanced Technology of Electrical Engineering and Energy, 2018, 37(5): 73-80.

[15] VANTUCH T, MIŠÁK S, JEŽOWICZ T, et al. The power quality forecasting model for off-grid system supported by multiobjective optimization[J]. IEEE Transactions on Industrial Electronics, 2017, 64(12): 9507-9516.

[16] 赵长伟, 骈睿珺, 杜天硕, 等. 基于LSTM的重要用户电

能质量趋势预测分析模型[J]. 电力系统及其自动化学报, 2022, 34(7): 26-33.
ZHAO Changwei, PIAN Ruijun, DU Tianshuo, et al. Trend prediction and analysis model for power quality of important users based on LSTM[J]. Proceedings of the CSU-EPSA, 2022, 34(7): 26-33.

[17] 朱继忠, 苗雨旺, 董朝阳, 等. 基于 Attention-LSTM 与多模型集成的短期负荷预测方法[J]. 电力工程技术, 2023, 42(5): 138-147.
ZHU Jizhong, MIAO Yuwang, DONG Zhaoyang, et al. Short-term load forecasting method based on Attention-LSTM and multi-model integration[J]. Electric Power Engineering Technology, 2023, 42(5): 138-147.

[18] 陈建军, 李良杰, 卢泽汉. 基于改进 LSTM-TCN 模型的分布式光伏功率预测研究[J]. 电子设计工程, 2024, 32(16): 187-190+195.
CHEN Jianjun, LI Liangjie, LU Zehan. Research on distributed photovoltaic power prediction based on improved LSTM-TCN model[J]. Electronic Design Engineering, 2024, 32(16): 187-190+195.

[19] GUO Y X, LI Y, QIAO X B, et al. BiLSTM multitask learning-based combined load forecasting considering the loads coupling relationship for multienergy system [J]. IEEE Transactions on Smart Grid, 2022, 13(5): 3481-3492.

[20] 唐竹, 肖宇航, 郭淳, 等. 基于 CEEMDAN 模态分解和 TCN-BiGRU 的短期电力负荷预测[J]. 智慧电力, 2024, 52(12): 59-64+72.
TANG Zhu, XIAO Yuhang, GUO Chun, et al. Short-term electricity load forecasting based on CEEMDAN decomposition and TCN-BIGRU model[J]. Smart Power, 2024, 52(12): 59-64+72.

[21] LIM B, ARıK S Ö, LOEFF N, et al. Temporal Fusion Transformers for interpretable multi-horizon time series forecasting[J]. International Journal of Forecasting, 2021, 37(4): 1748-1764.