

基于iTransformer的太阳能仓储工具柜智能供能策略研究

梁远星, 吴臻言, 喻小花, 吴琳恬, 黄丹妮

广东电网有限责任公司广州供电局, 广东 广州

收稿日期: 2025年10月20日; 录用日期: 2025年11月11日; 发布日期: 2025年11月25日

摘要

工具柜在现代工业生产中扮演着重要角色, 但是随着传统产业的发展, 原始的工具柜逐渐开始无法适应复杂的生产环境要求, 在这样的前提下, 智能工具柜应运而生。尽管智能工具柜解决了管理与存储问题, 但其灵活性不足、部署困难及维护成本高, 逐渐成为制约发展的关键因素。本文设计了一种基于智能算法优化供能的太阳能仓储工具柜, 它可以通过iTransformer模型对太阳能供能系统的供电量进行预测, 在太阳能供能充足时, 工具柜维持原模式运行。在太阳能供能不足时, 工具柜中的通讯单元会提醒管理员提前对工具柜进行额外能源供给或者改变工具柜的运行模式。从而保证本智能工具柜可以在以太阳能为主要供能方式的基础上维持稳定运行。

关键词

智能工具柜, 智能算法, iTransformer模型, 太阳能供能调配

Research on Solar Storage Tool Cabinets Optimized for Power Supply Based on Intelligent Algorithms

Yuanxing Liang, Zhenyan Wu, Xiaohua Yu, Lintian Wu, Danni Huang

Guangzhou Power Supply Bureau, Guangdong Power Grid Co., Ltd., Guangzhou Guangdong

Received: October 20, 2025; accepted: November 11, 2025; published: November 25, 2025

Abstract

Tool cabinets play an important role in modern industrial production. However, with the advancement of traditional industries, conventional tool cabinets have gradually become unable to meet

文章引用: 梁远星, 吴臻言, 喻小花, 吴琳恬, 黄丹妮. 基于 iTransformer 的太阳能仓储工具柜智能供能策略研究[J]. 智能电网, 2025, 15(5): 129-136. DOI: 10.12677/sg.2025.155013

the requirements of increasingly complex production environments. Against this backdrop, intelligent tool cabinets have emerged. Although intelligent tool cabinets address the challenges of tool management and storage, their limited flexibility, complex deployment, and high maintenance costs have gradually become key factors restricting further development. In this study, a solar-powered storage tool cabinet optimized by intelligent algorithms is designed. The cabinet employs the iTransformer model to predict the power output of the solar energy supply system. When solar energy is sufficient, the tool cabinet operates in its normal mode. When solar energy is insufficient, the communication module within the cabinet alerts administrators to either provide additional energy in advance or adjust the cabinet's operating mode. In this way, the proposed intelligent tool cabinet can ensure stable operation while relying primarily on solar energy as its main power source.

Keywords

Intelligent Tool Cabinet, Intelligent Algorithm, iTransformer Model, Solar Energy Supply Allocation

Copyright © 2025 by author(s) and Hans Publishers Inc.

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

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



Open Access

1. 引言

工具柜在生产中扮演着重要的角色，它不仅是工具存储的设备，更是提高生产效率、优化管理流程的重要工具[1]。在近些年，随着工业生产复杂度的提高，企业对于种类繁杂的工具的管理成本越来越高，特别是当工具种类较多的时候，这时候对工具使用、维护和记录的复杂度会较高[2]。因此，智能工具柜成为了生产中更好的选择，它可以让员工通过工号与密码自助借领，全程录像监控，远程数据共享，实现生产过程中的工具信息化管理[3]。

智能工具柜集成了多种先进技术，如 RFID、重力感应、自动识别技术等[4]，这些技术使得工具的管理更加自动化和精确。同时它可以通过自动化借还流程，减少了人工操作时间，提高了工作效率[5]。同时智能工具柜通常配备有安全锁和访问控制系统，确保只有授权人员才能使用特定工具。因此，智能工具柜通过技术提升，不仅优化了工具的管理流程，还为企业带来了更高的操作效率和成本节约。尽管智能工具柜在很多场景下具有远超原始工具柜的性能，但同时智能工具柜自身也具有严重的缺陷[6]。这是因为智能工具柜的供能实现依赖于稳定的电力能源供给，在没有有线电源供给的情况下，智能仓储工具柜不仅无法实现其原本的功能，还有可能因为通讯中断影响工具使用安全，降低工厂的生产效率，造成经济损失[7]。

在工业生产现场中，工业设备的供电设备布线是一个非常复杂的问题。对综合布线合理性的设计，需要计算合理性指标的模糊主观向量，确定控制设备综合布线的权重设计，才能完成对控制设备综合布线的合理设计[8]。其中，智能工具柜作为一个需要一定移动能力以及灵活性的设备大大增加了工厂布线的复杂性。同时这让工具柜本身应用的灵活性大大下降。

因此本文设计了一种配备了太阳能供电系统的智能仓储工具柜。这样可以让智能工具柜在一定程度上摆脱有线电源的限制，大大增加了智能工具柜的应用场景，降低了工厂生产布线的难度，节约了生产成本。太阳能供能系统解决了智能工具柜的有线电源支持问题，但是它本身也存在一定的问题。因为智能仓储柜一般搭载了大量的需要稳定供能的电力设备，而太阳能资源是一种受外部条件影响极其严重的能源[9]。在夜晚、阴天或者恶劣天气的情况下，太阳能供电系统可能会产生供电不足的问题，从而影响

工具柜的正常使用。因此如何调配能源供给是本文研究的重点。

2. 智能工具柜供能策略

本文设计的智能仓储工具柜以太阳能为主要供能方式。考虑到太阳能供给的不稳定性，本研究在太阳能仓储工具柜中加入了外部电源充电装置，该充电装置可以在太阳能资源不足时提供额外的能源供给。同时充电装置具有高灵活性的特点，不会影响太阳能仓储柜本身的部署优势。对于本文设计的太阳能仓储工具柜而言，其供能系统中最重要的问题是如何准确地获知太阳能供电系统的发电量。如果能够对太阳能发电系统的发电量做出准确的预测，那么就能够将太阳能发电装置作为主要的供电手段同时维持工具柜的稳定运行。太阳能发电量预测是一个典型的长时间序列预测问题。对于长时间序列预测问题而言，智能算法是一个准确高效而且实用性强的解决方法。

2.1. iTransformer 模型进行长时序预测

iTransformer 网络是 Yong Liu 等研究者在 2024 年提出的一种时间序列预测网络[10]，目前在时间序列预测领域，该网络的预测性能要明显优于其他预测模型。太阳能发电量序列预测任务本质上就是更为复杂的时间序列预测，因此 iTransformer 网络在辐照度序列预测任务也能够实现较好的效果。

iTransformer 网络是通过在 transformer 网络的基础上改进得到的。Transformer 网络在设计上更倾向于处理自然语言问题，它的嵌入层的作用是将自然语言中的词根据词义映射为一个高维词向量，词向量包含原始语句中词的词义特征以及位置特征。但是在辐照度序列中，辐照度的变化特征主要是由环境因素决定的，而环境因素的影响具有很高的不确定性，难以在辐照度序列中找到像自然语言中的“词”一样的包含独立特征的序列片段。因此 transformer 网络在处理时间序列数据时可能会出现特征提取能力差的问题，影响最终预测精度。因此，iTransformer 网络将 transformer 网络的结构倒置，采用线性网络对时间序列进行预测，而采用 Attention 机制对多维输入进行特征提取，以及通道融合。




Figure 1. iTransformer model topology
图 1. iTransformer 模型结构框图

本发明使用的网络模型如图 1 所示，embedding 为模型的嵌入层，作用是将输入的时间序列转化为后续模型可以处理的向量。其数学表达式可以用式(1)以及式(2)表示：

$$X(n,:) = \text{Transpose}(X(:,n)) \quad (1)$$

$$G_p = \text{Embedding}(X(n,:)) \quad (2)$$

其中, X 为 n 维输入序列, G_p 为嵌入后的高维向量。

而在 iTransformer 模型中, 一个环境特征序列被作为一个特征向量输入到后续模型中。Multi-Head Self-attention 为多头自注意力机制层, 它负责提取不同特征之间的相关性关联, 并按照相关性将环境特征向量与目标特征向量融合, 其原理可以用式 3 表示。Add & Norm 层为归一化层, 他们与前馈网络层(Feed Forward)一起完成向量间的通道融合任务, 同时将数据归一化, 消除计算过程中可能出现的量级差异, 其原理可以用式 4 表示。

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3)$$

$$X = X_{norm} \times \delta + \mu \quad (4)$$

其中 X_{norm} 表示归一化值, δ 表示原始数据的标准差, μ 表示原始数据的平均值。

在完成特征通道融合后, 输入向量转化为一个单维时间序列, 将单位时间序列输入到 LSTM 网络中, LSTM 网络[11]是经典的线性神经网络模型, 它是基于 RNN 网络改进的。循环神经网络通过隐藏层之间的链接在不同时间步之间传递特征信息, 从而实现在不同时间步之间的特征的记忆。但是不加选择地在时间步之间传递信息很容易造成无关信息的累积, 从而扩大特征信息之中的噪声占比, 造成模型的梯度爆炸或者梯度消失现象, 严重影响模型的稳定性以及预测精度。LSTM 网络在 RNN 网络的基础上增加了遗忘门、更新门与输出门, 对隐藏层之间的信息传输进行一定的选择, 从而降低无关特征信息累积的可能, 在一定程度上缓解了 RNN 网络预测不问东以及精度低的问题。因此它是线性神经网络可以较好地完成预测任务的网路, 因此本文选择它作为线性预测的模型。

2.2. 模型超参数自优化

在模型运行之前, 需要对模型的超参数进行选择, 模型超参数的值会对模型性能产生较大的影响。而通常来讲, 模型的超参数需要专业研究人员根据经验进行选择, 这会提高工具柜的部署与维护成本, 因此, 本研究选择使用元启发优化算法实现 iTransformer 模型超参数的自优化。Dingo 算法[12]是一种寻优算法, 它的框架与灰狼算法有相似之处, 它们的位置更新方式与最优解搜索方式基本相同。但是灰狼算法没有贪心机制, 所以收敛速度较慢, 而 Dingo 算法将灰狼算法与遗传算法相结合, 加入选优机制提高算法的收敛速度, 同时为了维持原算法的搜索能力, 避免落入局部最优解, Dingo 算法增加了部分其他位置更新方式。其结构框图如图 2 所示。

Dingo 算法首先通过两个随机值 rand1 与 rand2 将初始种群随机分为三组, 三组分别进行三种不同的位置更新行为, 其中围攻行为会在目前全局最优位置附近进行搜索, 这部分的位置更新公式与灰狼算法有很高的相似度。可以用式 5 表示:

$$\bar{x}_i(t+1) = \beta_i \sum_{k=1}^{na} \frac{[\varphi_k(t) - \bar{x}_i(t)]}{na} - \bar{x}_b(t) \quad (5)$$

$$\bar{x}_i(t+1) = \bar{x}_b(t) + \beta_1 e^{\beta_2} (\bar{x}_{r1}(t) - \bar{x}_i(t)) \quad (6)$$

$$\bar{x}_i(t+1) = \frac{1}{2} [e^{\beta_2} * \bar{x}_{r1}(t) - (-1)^\delta * \bar{x}_i(t)] \quad (7)$$

式中 $\bar{x}_i(t)$ 表示第 i 个个体在迭代 t 时的位置; $\bar{x}_b(t)$ 为当前全局最优解; $\bar{\varphi}_k(t)$ 为第 k 个邻居个体的位置; na 为邻居个体数; $\bar{x}_{r1}(t)$ 为随机选取的个体位置; β_1 、 β_1 、 β_2 为控制参数, 用于调节搜索范围与收敛速度; $\delta \in \{0, 1\}$ 为随机变量, 用于决定是否进行反向搜索。




Figure 2. The algorithm flowchart of Dingo
图 2. Dingo 算法流程框图

追捕行为也是在最优解附近进行搜索, 但是它与围攻行为的区别在于, 围攻行为的位置更新与参与这个行为的全部种群个体都有关系, 因此全部参与这个行为的种群点的位置变化具有相似的规律。但参与追捕行为的点的位置变化只与上个迭代的最优解以及全部种群中的某一随机个体的位置有关, 这为位置更新提供了一定的随机性, 从而降低落入局部最优解的概率。它的位置更新可以用式 6 进行。食腐行为的位置更新与最优解无关, 它是在原本位置与任一随机位置之间进行搜索, 这样可以进一步提高位置更新的随机性, 提高模型的搜索能力, 减低落入局部最优解的概率。在数学形式上可以用式 7 表示。

在位置更新之后, 通过适应度筛选, 低于指定适应度的点的位置会被更新, 通过这样的贪心机制, 可以提高模型的收敛速度。在对模型进行超参数优化时, 应该考虑模型的复杂程度。本文使用的 iTransformer 模型相较于传统的线性神经网络较为复杂, 模型运行效率本身较低, 因此更适合收敛速度快的 Dingo 优化算法。Dingo 优化算法完成的工作可以用式(8)到式(11)表示。

$$n_heads_0 = a, d_model_0 = b, batch_size_0 = c \quad (8)$$

$$X_0 = (a, b, c) \quad (9)$$

$$X_1 = DOX(X_0) \quad (10)$$

$$X_i = DOX(X_{i-1}) \quad (11)$$

其中, n_heads_0 、 d_model_0 以及 $batch_size_0$ 为模型中的三个初始超参数值, DOX 为 Dingo 算法模型的整体, X 为输入的超参数向量。

3. 算例分析

3.1. 实验平台构建

本研究的实验平台由硬件实物柜体与软件算法运行环境两部分组成。硬件方面，搭建了一台标准化尺寸(1281 mm×539.7 mm×1281.6 mm)的太阳能仓储工具柜，柜体采用铝合金框架与防锈钢板复合结构，顶部配置两块 200 W 柔性太阳能板，配合倾角设计以提升光能转化效率，内部集成 24 V/15 Ah 磷酸铁锂电池，能够在离网状态下维持连续 7 天稳定供电。整体实验平台如图 3 所示。控制系统基于 Jetson Xavier NX 边缘计算模块，支持人脸识别、传感器采集与能量预测任务的本地化处理，配套的电磁锁、红外传感器与照明系统实现了安全与便利的智能交互。

软件实验环境搭建在服务器端，配置为 Intel Xeon 8 核 CPU、NVIDIA RTX 3080 GPU 及 64 GB 内存，主要用于模型训练与超参数优化。数据集来源于广州供电局仓储中心采集的光伏功率与气象监测数据，覆盖 12 个月、以 1 小时为采样周期，经缺失值填补与归一化处理后，按照 7:1.5:1.5 的比例划分为训练集、验证集和测试集。基线模型选用双层 LSTM 网络，其中隐藏层神经元为 128 个，单次训练样本数为 32，学习率为 $1e-3$ 。优化模型采用 iTransformer 架构，并通过 Dingo 算法在注意力头数、模型维度、学习率、batch size 与 dropout 等参数空间内进行自适应超参数搜索，最终以验证集最优结果确定实验参数并在测试集上评估性能。



Figure 3. Solar storage cabinet test platform of the Guangzhou Power Supply Bureau Supply Chain Center

图 3. 广州供电局供应链中心太阳能仓储柜实验平台

3.2. 实验结果与分析

1) 预测精度对比

为了验证所提出的基于 iTransformer 的太阳能仓储工具柜供能策略的有效性，本文对比了传统 LSTM 模型与 iTransformer+Dingo 优化模型在太阳能发电量预测精度、供能稳定性以及工具柜实际运行表现上的差异。首先对比两类模型在测试集上的预测性能，选取平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)作为评价指标，统计指标结果见表 1。

Table 1. Accuracy comparison of different models in solar power generation forecasting
表 1. 不同模型在太阳能发电量预测中的精度对比

模型	MAE (Wh)	RMSE (Wh)	MAPE (%)	训练时间(min)
LSTM	12.4	18.7	14.2	35
iTransformer	9.8	15.1	11.0	62
iTransformer + Dingo	7.1	10.5	7.3	65

从表 1 可见，iTransformer 相较于传统 LSTM 模型在预测精度上已有明显优势，而结合 Dingo 算法进行超参数自优化后，预测误差进一步降低，MAPE 减小近 50%，证明了模型结构与参数优化的有效性。

2) 供能稳定性对比

在广州仓储中心对所设计的太阳能智能工具柜进行了为期 3 个月的现场运行试验，重点考察其在实际生产环境下的供能稳定性与可靠性。试验过程中，系统实时记录了工具柜的运行状态，并对关键的稳定性指标进行统计与分析，包括：① 停机次数，即因供能不足导致工具柜完全停止运行的次数；② 停机总时长，指累计的工具柜因供能不足而无法工作的总时间；③ 外部电源调用次数，即在太阳能供能不足的情况下需要切换至外部电源以维持正常运行的次数。这些指标能够全面反映系统在复杂环境下的能量调配能力和运行稳定性。统计结果见表 2。

Table 2. Comparison of on-site power supply stability of tool cabinets under different models
表 2. 不同模型下工具柜现场运行供能稳定性对比

指标	LSTM	iTransformer + Dingo 优化
停机次数(次)	8	1
停机总时长(h)	23.6	3.5
外部供电调用次数(次)	12	2

由表 2 可见，优化后的模型显著降低了因供电不足导致的停机风险，外部电源的调用需求也大幅减少，证明本策略有效提升了工具柜的独立运行能力。表 2 中优化模型表现优异的原因主要在于 iTransformer 结合 Dingo 算法显著提升了太阳能发电量预测精度，使工具柜能够提前调度储能电池和外部电源，在光照不足时保持稳定供能，从而有效减少停机次数、缩短停机总时长并降低外部电源调用频率。

3) 能量调度效果对比

本研究进一步统计了在晴天、阴天和雨天三类典型天气下，不同模型的预测精度对供能调度的影响，结果如表 3 所示。

Table 3. Comparison of prediction and scheduling performance under different weather conditions
表 3. 不同天气条件下的预测与调度效果对比

天气条件	模型	预测误差(Wh)	备用电池启用率(%)	外部供电调用率(%)
晴天	LSTM	8.5	12.4	3.1
	iTransformer + Dingo	4.2	8.6	0.5
阴天	LSTM	14.3	37.2	22.7
	iTransformer + Dingo	8.1	21.5	6.2
雨天	LSTM	17.8	52.4	34.5
	iTransformer + Dingo	11.7	33.8	10.4

结果显示, iTransformer + Dingo 优化模型在不同天气条件下均表现出更高的预测精度, 尤其是在阴天和雨天等复杂环境中, 其预测误差显著低于传统 LSTM 模型。高精度的预测使系统能够提前调度备用电池, 有效缓解太阳能供电不足问题, 同时减少了外部电源的调用频率, 从而显著提升了智能工具柜的自适应调度能力和供能稳定性。

通过上述实验可见, 本文提出的基于 iTransformer 的太阳能发电量预测方法, 结合 Dingo 算法实现超参数自优化, 能够有效降低预测误差, 提高预测可靠性。在实际运行中, 该策略不仅减少了停机次数和维护成本, 还通过合理调度备用电池和外部电源, 提高了工具柜在不同天气条件下的灵活性和独立性。实验结果充分证明了本文方法在预测精度提升、供能稳定性保障以及工程应用可行性方面的创新性与有效性。

4. 结论

本文提出的基于 iTransformer + Dingo 优化的太阳能发电量预测与智能供能调度策略, 能够有效提升智能仓储工具柜在复杂环境下的运行性能。实验结果表明, 该方法显著提高了太阳能发电量的预测精度, 使工具柜能够提前调度备用电池和外部电源, 减少停机次数和停机总时长, 同时降低对外部电源的依赖, 保障了系统的独立运行能力。在不同天气条件下, 包括晴天、阴天和雨天, 该策略均表现出良好的适应性和可靠性, 尤其在光照不足的情况下, 通过智能调度备用电池维持稳定供能, 显著提升了工具柜的自适应调度能力。此外, 该方法减少了人工维护和布线复杂度, 提高了工具柜的部署灵活性和工程应用可行性, 为智能工具柜及其他离网太阳能供电系统的能源管理提供了可行的技术方案, 并展示了在工业生产现场推广应用的潜力和价值。

参考文献

- [1] 赵高, 马登秋, 叶振环, 等. 基于 RFID 技术可一键出入库工器具的智能工具柜设计[J]. 机械研究与应用, 2025, 38(3): 64-68.
- [2] 苏浩洋. 智能工具柜的系统分析与应用[J]. 大众标准化, 2025(7): 139-141.
- [3] 熊宇荣, 龚青山, 何伟, 等. 基于物联云平台的机场工具智能管理系统开发[C]//湖北省机电工程学会. 2022 机电创新与产教融合新思考论文集. 2022: 59-67.
- [4] 刘磊, 张新锋, 王成硕. 分析智能工具柜管理系统的详细设计[J]. 电子技术与软件工程, 2020(18): 188-189.
- [5] 吴庆兵. 基于 Android 的智能工具柜控制终端设计[D]: [硕士学位论文]. 北京: 北京交通大学, 2021.
- [6] 李聪. AI 智能工具柜[Z]. 上海: 上海航翼高新技术发展研究院有限公司, 2021-12-26.
- [7] Pech, M., Vrchota, J. and Bednář, J. (2021) Predictive Maintenance and Intelligent Sensors in Smart Factory: Review. *Sensors*, **21**, Article 1470. <https://doi.org/10.3390/s21041470>
- [8] 吴为权. 建筑消防设施的供电及配电线路防火要求分析[J]. 中国高新科技, 2024(21): 88-90.
- [9] 胡宏彬, 景志滨, 郭琦, 等. 考虑出力波动性及间歇性的风能太阳能互补性评估方法[J]. 现代电力, 2025, 42(5): 911-918.
- [10] 王文, 朱文忠, 吴宇浩, 等. 基于 iTransformer 的短期光伏发电功率预测研究[J]. 陕西理工大学学报(自然科学版), 2025, 41(4): 42-49, 97.
- [11] 王长栓, 鲍烨青, 李伟. 一种基于 PC-LSTM 的 GNSS 场景识别方法[J]. 地理空间信息, 2025, 23(8): 110-113, 127.
- [12] 张蓝方. 野狗优化算法的改进及其应用研究[D]: [硕士学位论文]. 南宁: 广西民族大学, 2023.