

# 使用经验小波分解与改进网格聚类的Informer光伏发电预测混合模型

王松青

上海理工大学光电信息与计算机学院, 上海

收稿日期: 2025年1月4日; 录用日期: 2025年2月14日; 发布日期: 2025年2月26日

## 摘要

随着可再生能源的快速发展,光伏发电在电力系统中占据了重要地位。然而,由于光伏发电的功率输出受天气条件影响较大,具有显著的间歇性和随机性,导致预测难度较高。为了提高光伏发电功率的预测精度,本文提出了一种基于改进的Informer模型与天气数据相结合的混合预测方法。首先,收集并预处理光伏发电相关数据,包括光伏历史功率数据与关键气象因素(如温度、辐照度、湿度等)。其次,通过引入经验小波变换对数据进行模态分解处理气象数据。然后,利用基于网格划分的聚类方法(Grid-Based Clustering, GBC)改进局部敏感哈希(Locality Sensitive Hashing, LSH),之后使用该方法对informer模型进行改进。在本文中,尝试结合GBC来选择查询向量中的几个关键向量,改进informer模型中的对查询向量的筛选,从而提高模型预测的准确性。最后使用模拟退火优化算法对超参数进行优化选择,通过真实数据集的实验验证,与Informer相比,数据的MSE, MAE, RMSE和 $R^2$ 分别提高了47.42%、43.37%、27.50%和6.54%。综上所述,所提出的混合模型在预测精度、拟合度等方面均能够实现有效的提高。研究表明,该模型能够为光伏发电的运行调度和电网稳定性提供更加可靠的支持。

## 关键词

Informer, 光伏发电预测, 经验小波变换, 模拟退火优化算法, 基于网格的聚类方法

# Informer Hybrid Model for PV Power Forecasting Using Empirical Wavelet Decomposition with Improved Grid Clustering

Songqing Wang

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Jan. 4<sup>th</sup>, 2025; accepted: Feb. 14<sup>th</sup>, 2025; published: Feb. 26<sup>th</sup>, 2025

文章引用: 王松青. 使用经验小波分解与改进网格聚类的 Informer 光伏发电预测混合模型[J]. 软件工程与应用, 2025, 14(1): 46-62. DOI: 10.12677/sea.2025.141006

## Abstract

With the rapid development of renewable energy, photovoltaic (PV) power generation occupies an important position in the power system. However, the power output of PV power generation is highly affected by weather conditions with significant intermittency and randomness, which leads to high prediction difficulty. In order to improve the prediction accuracy of PV power, this paper proposes a hybrid prediction method based on the combination of the improved Informer model and weather data. Firstly, PV power related data are collected and pre-processed, including PV historical power data and key meteorological factors (e.g. temperature, irradiance, humidity, etc.). Second, the meteorological data are processed by introducing an empirical wavelet transform for modal decomposition of the data. Then, the Locality Sensitive Hashing (LSH) is improved by using Grid-Based Clustering (GBC), after which the informer model is improved using this method. In this paper, an attempt is made to combine GBC to select several key vectors in the query vectors to improve the filtering of the query vectors in the informer model so as to improve the accuracy of the model prediction. Finally, the simulated annealing optimization algorithm is used to optimize the selection of hyper-parameters, which is experimentally verified by the real dataset, and the MSE, MAE, RMSE and  $R^2$  of the data are improved by 47.42%, 43.37%, 27.50% and 6.54%, respectively, when compared with the informer. In summary, the proposed hybrid model is able to achieve effective improvement in prediction accuracy and goodness of fit. It is shown that the model can provide more reliable support for the operation scheduling and grid stability of PV power generation.

## Keywords

Informer, Photovoltaic (PV) Power Prediction, Empirical Wavelet Transform (EWT), Simulated Annealing (SA), Grid-Based Clustering (GBC)

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

### 1.1. 背景

近年来随着温室效应的不断加剧,各种极端气候的出现变得愈加频繁,而导致温室效应的主要来源就是大量温室气体的排放。其中,温室气体的主要排放源便是各种化石燃料的燃烧;化石燃料的燃烧会对环境造成严重的危害,通过抑制其产生的温室气体排放来缓解温室效应的加剧是愈来愈关键的方法。同时由于化石燃料的广泛使用,新能源、可再生能源的使用更加需要提上日程。虽然随着新能源汽车与高铁的普及,化石燃料在载具方面的应用逐渐减少,但是由于现在大多数的发电来源依旧为火力发电设施。因此并没有很大程度地解决温室气体的排放问题,而光伏发电是化石燃料发电的最佳替代品之一。此外,城市能源需求的不断增长,光伏发电系统利用太阳能也减少了对传统能源的消耗,实现能源的高效利用。在城市建筑屋顶大范围安装光伏发电系统,可以显著降低建筑能耗,提高城市可持续资源利用率。同时光伏电站也可以在各种严苛的环境进行有效的发挥作用,甚至在 Kumar 等人[1]的研究中实现了 10 MW 运河顶部安装太阳能电站,表明水体也可以有效地用于经济可能的太阳能发电。因此,据研究统计,全球太阳能容量已从 2012 年的 100 GW 增长到 2022 年 4 月的 1 TW,全球太阳能市场呈指数级增长,预计到 2025 年将超过 2.3 TW [2]。

人工智能(AI)具有显著改善太阳能预测的潜力,其预期影响包括提高准确性、增强短期和长期预测、提高能源效率、降低成本、与能源市场整合、环境效益、电网稳定性等[3] [4]。准确的光伏发电预测对当前的光伏发电系统至关重要。有效降低了光伏发电对电力系统的影响,保证了系统的稳定运行,进一步推动了新型电力系统的建设,促进了低碳发展。此外,精确的光伏发电功率预测提高了太阳能的利用率,从而提高了电站的投资回报率,最大限度地减少了功率限制带来的经济损失。

## 1.2. 相关研究

与光伏发电预测(PVPF)相关的研究工作根据其分析原理分为三大类:物理方法、统计方法和机器学习方法(ML)机器学习已广泛应用于光伏发电预测。Yang 等人[5]采用反向传播(BP)法进行光伏发电功率预测,将不同相似日的预测结果融合,构筑光伏发电功率预测方法。随着人工智能(AI)方法的进步,基于深度学习的模型已经在各个行业得到了开发和实施。深度学习是一种前沿的机器学习方法,在光伏发电功率预测领域得到了广泛的研究。Wang 等人[6]增强了长短期记忆网络(LSTM)模型来预测光伏发电的高频和低频成分。Lee 等人[7]采用两种循环神经网络(RNN)模型,仅使用早晨气象信息来预测高峰地区的每小时光伏发电量。通过实验证明,该方法优于人工神经网络(ANN)和深度神经网络(DNN)。为了满足更长的时间尺度 PVPF 的需求,具有编码器(Encoder)-解码器(Decoder)结构的序列到序列模型应该得到更多的关注。作为一种流行的深度学习模型,Transformer 在自然语言处理(NLP)领域表现优异[8]。与传统的 RNN 和卷积神经网络(CNN) [9]相比,Transformer 使用了一种自注意力机制,能够使得在训练的时候不受位置信息的影响。它可以更好地捕获长序列的全局语义信息。然而,它的高时间复杂度、内存占用和性能下降限制了它在时间序列预测领域的应用。为了克服这些挑战,Zhou 等人[10]提出了 Transformer 的一种变体,称为 Informer,该变体在四个大规模时间序列数据集上进行了测试,并显示出优异的性能。一些研究尝试将 Informer 应用于 PVPF 领域,目的是利用其处理长序列时间序列数据的强大能力。

由于光伏数据的不稳定性,考虑将各种信号处理方法与 informer 结合,或者是结合多种深度学习模型,构建混合模型一般能够更好的处理 PVPF 领域的问题。Cao 等人[11]将传统叠加算法中的 k-fold 交叉验证改进为时间序列交叉验证,用于整合时间序列预测模型。同时结合长短期记忆(LSTM)与 informer,通过整合两种模型的优势,该模型实现了精准的中短期光伏发电功率预测。Li 等人[12]在建筑能耗管理系统领域中,提出了一种将集成经验模态分解(EEMD)与 informer 相结合的混合算法,针对其能耗数据在状态非平稳和长时间的数据非线性的情况。使用 EEMD 将原始数据分解为几个内在模态函数(IMF)组件,然后使用 Informer 进行预测,并使用 PSO 在预测期间调整超参数。最后一步,将 IMF 各分量的预测结果综合起来得到最终的预测结果。该模型大幅提高了预测的准确性。混合 Informer 模型也可以在金融行业发挥其强劲的性能优势。Ren 等人[13]结合小波变换,将 Encoder Forest (EF)与 Informer 相结合;将原始数据分为高频信号分量(CD)和低频信号分量(CA),由 informer 处理低频,EF 处理高频。构建了一种具有较高的预测精度、较强的泛化能力和较强的实用性,而且更适合于股票预测问题的一个混合模型。

## 1.3. 创新性

本文提出一种基于经验小波分解(EWT),基于网格的聚类方法(GBC)改进的 Informer 和模拟退火优化算法(SA)的光伏功率预测方法模型。该模型克服了光伏发电功率预测的局限性,使用混合模型,对现有的模型进行了改进,大幅提高了预测的准确性,本文的创新如下:

(1) 采用 IQR 法对数据进行预处理,移除过大与过小的数据。移除与光伏功率预测相关性不大的特征以减少运算压力。

(2) 采用 EWT 方法对原始数据进行分解, 将天气数据与光伏功率数据均进行分解, 降低数据的波动性与非平稳性, 信号被分解为若干个 IMF 分量与残差项。

(3) 本文尝试对 Informer 模型进行改进, 使用基于网格聚类的哈希机制, 将查询向量划分到指定数量的桶中来寻找最关键几个向量, 从而提高模型的准确性, 降低由于原本随机选择的键向量带来的不确定性。

(4) 使用模拟退火优化算法对改进的 Informer 模型的超参数进行优化, 通过多次的迭代, 得到具有更强的预测准确度的超参数配置。提高模型整体的预测水平。

(5) 本文使用的数据集选用的是位于澳大利亚亚乌鲁鲁附近的尤拉拉太阳能系统站点的数据, 并采用 4 个科学指标来检验模型的有效性, 并将几种传统模型与本文的混合模型进行了比较, 以展现其更优的预测性能。

## 2. 基础知识

### 2.1. Informer

Informer 是 Zhou 等人[10]提出的一种新的时间序列预测模型。Informer 模型相较于 Transformer 增加了一种生成式解码器, 其只需一步即可获得长序列的输出。避免了预测阶段的误差累积传播问题, 提高了长序列预测的效率。同时, Informer 引入自注意力蒸馏(Self-attention Distilling)与 ProbSparse 自注意, 降低了注意力计算过程的时空复杂度。图 1 为 Informer 模型概述:

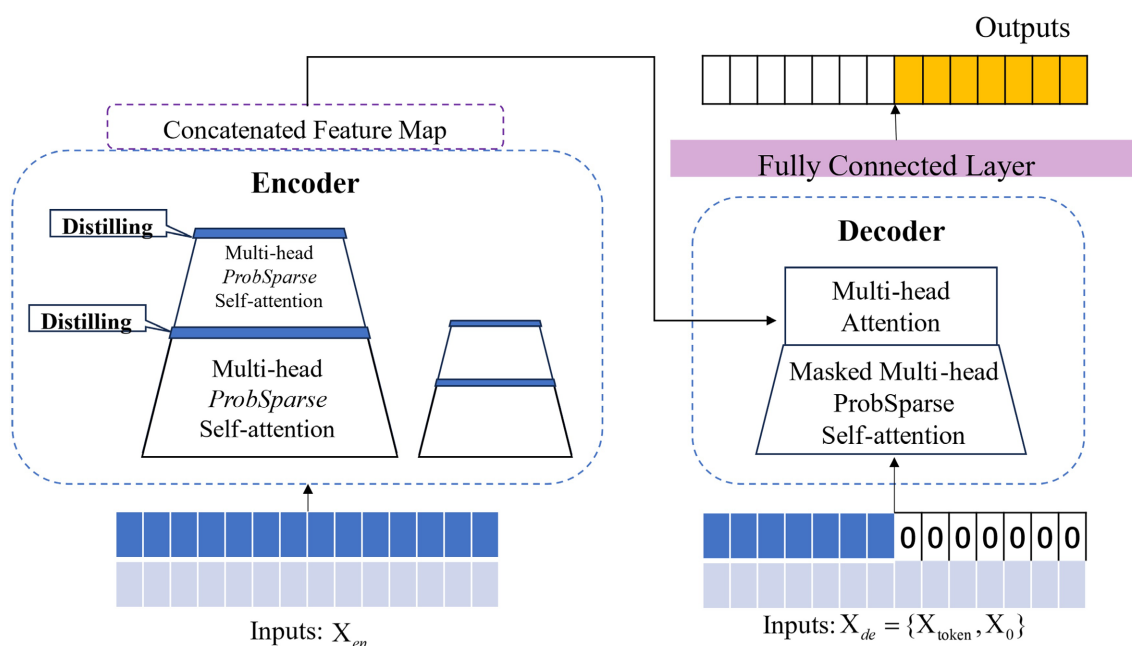


Figure 1. Introduce of the informer

图 1. Informer 模型概述

#### 2.1.1. Self-Attention Distilling

在 Encoder 部分, Informer 使用了一种自注意蒸馏的方法, 降低了算法对内存和时间的需求。向量输入后, 将第  $t$  个输入序列塑造为一个矩阵  $X_{en}^t \in \mathbb{R}^{L_x \times d_{model}}$ 。

在 ProbSparse 的机制下 Encoder 特征映射后会产生具有值(Value)的冗余项。使用 Distilling 操作, 提

取具有主导特征的项并在下一层生成集中的自注意特征映射。对输入的时间维度进行大幅缩减。该 Distilling 操作按照下式进行操作：

$$X'_{j+1} = \text{MaxPool}\left(\text{ELU}\left(\text{Conv1d}\left(\left[X'_j\right]_{AB}\right)\right)\right) \quad (1)$$

其中 Conv1d 函数用于处理一维时间序列的卷积。指数线性单元(Exponential Linear Unit, ELU)表示激活函数，最后进行最大池化(MaxPool)操作，用于增强注意细化机制的稳定性。

### 2.1.2. ProbSparse Self-Attention

给出了一种更有效的方法找出那些更为关键的  $u$  个向量。由公式(3)可以得知

$$\ln \sum_{j=1}^{L_K} e^{\frac{q_i k_j^T}{\sqrt{d}}} \geq M(q_i, K) \geq \frac{1}{L_K} \sum_{j=1}^{L_K} \frac{q_i k_j^T}{\sqrt{d}}, \text{ 那么我们可以给出最大均值度量式:}$$

$$\overline{M}(q_i, K) = \max_j \left\{ \frac{q_i k_j^T}{\sqrt{d}} \right\} - \frac{1}{L_K} \sum_{j=1}^{L_K} \frac{q_i k_j^T}{\sqrt{d}} \quad (2)$$

在长尾分布下，随机抽样  $U = L_K \ln L_Q$  点积对来计算  $\overline{M}(q_i, K)$ ，然后将其他点积对用 0 填充。之后从其中选择 Top- $u$  个作为  $\overline{Q}$ 。以此完成对查询向量的筛选，也即完成对自注意部分计算的复杂度简化完成。其  $L_K = L_Q = L$  使得 ProbSparse 自注意的总时间复杂度和空间复杂度为  $O(L \ln L)$ 。

## 2.2. Grid-Based Clustering in the Frame of Locality Sensitive Hashing

### 2.2.1. Locality Sensitive Hashing

Kitaev 等人[14]提出一种 Reformer 的模型改进 transformer 以减少其运算量，并增加其模型的精度。在 Reformer 模型中，作者引入了一种局部敏感哈希(Locality Sensitive Hashing)注意的方法，改进 Transformer 中的点积注意部分。

局部敏感哈希即为将每个向量  $x$  分配到哈希(hash)  $h(x)$ ，邻近的向量有高概率被分配到相同的哈希  $h(x)$ ，也即附近的向量高概率得到相同的哈希值。但正如上文所述，哈希总有可能有一个小概率相似的项目落在不同的哈希桶中，这种概率可以通过使用不同的哈希函数  $\{h^{(1)}, h^{(2)}, \dots\}$  进行多轮哈希来降低：

$$P_i = \bigcup_{r=1}^{n_{\text{rounds}}} P_i^{(r)} \quad (3)$$

其中  $P_i^{(r)} = \{j : h^{(r)}(q_i) = h^{(r)}(q_j)\}$ ， $P_i$  定义为查询(query)位置  $i$  尽可以关注到的单个哈希桶

$$P_i = \{j : h(q_i) = h(q_j)\}。$$

### 2.2.2. Grid-Based Clustering

基于网格的聚类算法是一种时间复杂度较低，可以并行运算的简单高效的聚类算法。比起 K-means 算法省去了冗长的迭代过程。通过可控的区间划分大小，灵活调整采样。也同时由于时直接基于内容进行的分组，采样结果稳定。其基本理念为，将数据空间划分为若干个单元，这些单元构成网络，然后在网络结构上进行聚类。

由上述内容可知，该种基于网格的聚类方法，其关键取决于网格单元的正确划分。本文中考虑将该种基于网格的聚类方法与 LSH 相结合，通过 LSH 的多轮哈希，来更新网格的选择，来增加模型的鲁棒性，使其更加适合处理长序列。网格划分与哈希桶概念相似，但处理更加高效，都能够避免直接计算大规模点积造成的计算复杂度过高的问题。

首先将定义每个维度网格的数量:

$$g = n_{\text{buckets}}^{1/d} \quad (4)$$

其中  $n_{\text{buckets}}$  为总桶数,  $d$  为向量的维度。其次, 初始化网格边界为范围  $[-1, 1]$ 。

### 2.3. LSH-GBC-Informer

本文模型通过将数据预处理后将其标准归一化映射到区间  $[-1, 1]$ 。针对 Informer 提出的基于 Transformer 的 ProbSparse 自注意机制, 其存在并行计算能力弱, 同时关键查询向量筛选较为简单的问题, 不可避免地存在一定的鲁棒性不足, 计算能力弱的问题。本文结合使用网格聚类改进的 LSH 聚类算法对该部分进行改进, 提高了其并行计算能力, 增加了处理长序列问题上的预测精度。在原模型的每一步中的 ProbSparse 自注意部分使用本文的混合聚类方法进行改进, 查看图 2 对本文提出的改进法的介绍。

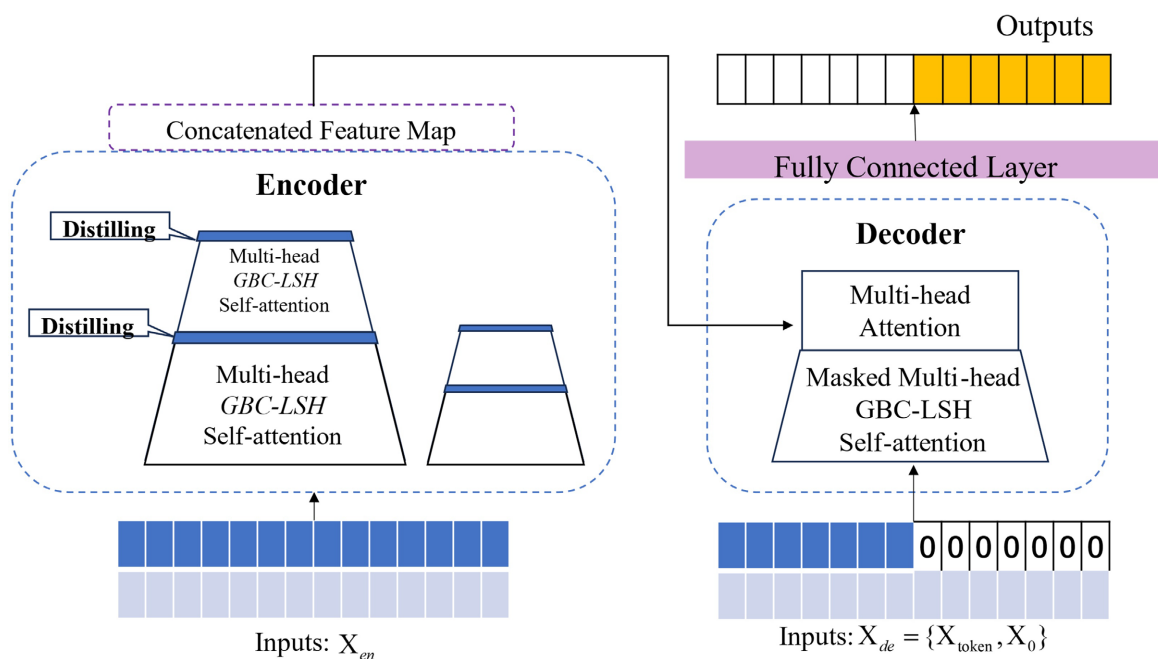


Figure 2. Frame of GBC-LSH-Informer

图 2. GBC-LSH-Informer 模型框架

### 2.4. Optimization Algorithm

对于模型的超参数, 不易通过手动调整来获得最优的超参数。Informer 模型有比较多的超参数, 而且超参数的调节范围也比较大, 通过优化算法进行迭代多次模型参数的选取也会更有可能得到最优的参数, 提高模型的预测准确性。本文选择使用模拟退火优化算法来对模型的超参数进行调整。

#### 2.4.1. Simulated Annealing Optimization

Kirkpatrick 等人[15]提出了一种基于物理退火过程的数学模拟。其基本思想为模仿金属退火的物理过程。

模拟退火的过程由以下几步构成: 首先是, 在一个高有效的温度下的“融化”系统; 其次, 缓缓降低温度直到系统进入“冻结”, 并且不再出现变化。系统的最终状态的总体特征一般会在温度比较高的时候出现, 细节部分一般在较低温度下形成。下图 3 给出模拟退火优化的算法流程示意图。

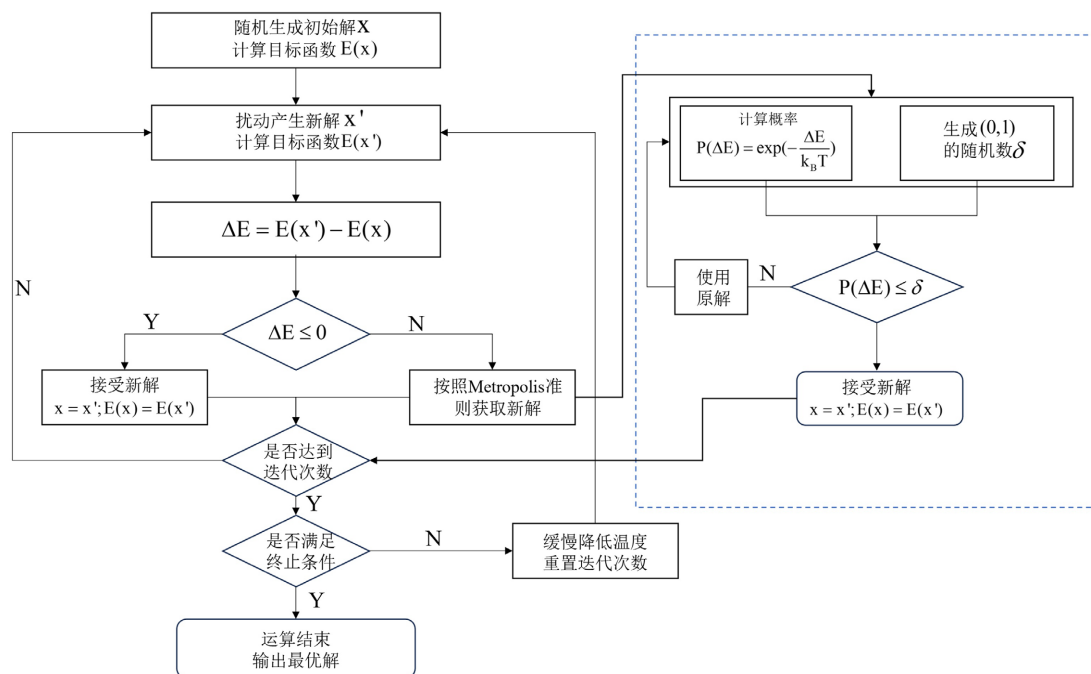


Figure 3. Flowchart of simulated annealing optimization

图 3. 模拟退火优化算法流程图

#### 2.4.2. SA in Informer

在本文中，使用模拟退火优化算法对 Informer 模型的超参数进行优化，通过多次迭代，最终得到预测精度最高的超参数组合和预测结果。首先，我们将几个超参数作为模拟退火算法的初始解，超参数的取值范围给定，再设定初始温度  $T$  和降温速率  $\alpha$ ，设定迭代次数。其次，生成随机初始解后，进入模型使用这些超参数进行训练，得到第一次训练结果，保存对应的超参数与 4 个评测指标作为该次迭代的结果。然后，提供扰动，产生新的超参数，更新温度  $T = \alpha T$ ，投入模型中进行训练。之后一直重复上述步骤，知道满足迭代次数，可以在结果中得到最优的超参数结果，与其对应的评价指标数据。

### 2.5. Empirical Wavelet Transform

经验小波变换(Empirical Wavelet Transform, EWT)是 Gilles [16]提出的一种处理非平稳信号与多分量信号的基于信号分解的分析方法。适应性和灵活性是其主要优势，能够适应性地构建信号的频带分解。通过为每个频带构造小波基函数，是根据频带自适应生成，能够更好地捕捉信号的局部特征。同时通过频带划分和上述自适应滤波器设计，减少了模态混叠现象。与传统小波相比，它也能提供更加精确的频带划分，与 EMD 相比也具有更低的计算复杂度。

### 3. EWT-GBC-Informer-SA 算法流程

本文构建了一种基于 Informer 模型的混合模型，使用了 EWT 进行数据分解，使用 GBC 对 Informer 部分自注意部分进行改进，使用 SA 对模型的超参数进行优化，算法的基本流程如下(图 4)：

- 一：获取光伏电站数据，包含有功功率，辐照指数等；
- 二：进行数据预处理，使用 IQR 去除异常值，标准化；
- 三：使用 EWT 对数据进行模态分解，将分解后的数据一起作为训练特征；
- 四：引入 GBC 在 LSH 框架下对 Informer 模型的自注意机制部分进行改进，使用 GBC 来为每个与查

- 询(Query)向量寻找相邻的键(Key)向量，构建 GBC-Informer 模型；
- 五：对数据进行分组，分为训练集、测试集与验证集，然后将训练数据放入 GBC-Informer 进行训练；
- 六：使用模拟退火算法 SA 对选定的几个超参数进行优化，使用优化后的超参数进行再一轮训练，直至达到停止条件；
- 七：输出多次训练与优化后模型训练预测结果的科学指标，与其他模型进行比较。

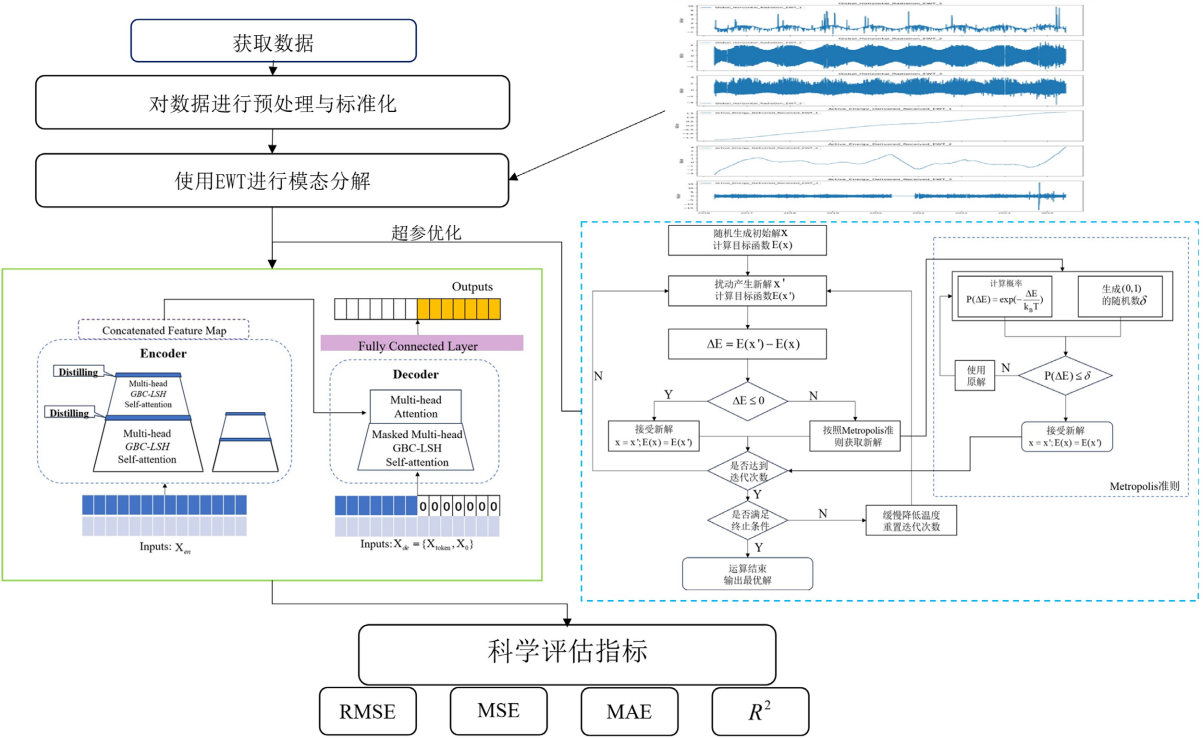


Figure 4. Flowchart of Informer + GBC + EWT + SA  
图 4. Informer + GBC + EWT + SA 模型算法流程图

4. 数据集与评价指标

4.1. 数据集

本文采用的光伏发电数据来自 dka 太阳能中心，一个关于光伏发电系统的公共网站[17]。该网站的数据来源于位于澳大利亚的乌鲁鲁附近的尤拉拉太阳能系统 3B 站点。该光伏系统位于沙漠平原，日照充足，紫外线指数在 11 至 15 之间[18]。数据集的时间跨度为 2016 年 4 月 1 日至 2024 年 6 月 4 日，数据分辨率为 5 分钟，表 1 列出有关特征的详细信息。其中，有功功率 Active Power 为预测的目标特征。

Table 1. Details of the features included in the dataset  
表 1. 数据集中包含的特征统计信息(已去除异常值)

Name	Unit	Min	Mean	Max	Std
Current_Phase_Average_Mean	NA	0.0	11.304	55.428	15.985
Active_Energy_Delivered_Received	Kwh	3009.271	279141.807	553932.0	152195.696
Wind_Speed	m/s	$-8.99 \times 10^9$	-12332.533	15.347	10073696.274
Weather_Temperature_Celsius	°C	$-8.99 \times 10^9$	-12312.157	46.580	10073740.228

续表

Global_Horizontal_Radiation	$W/m^2$	-17.719	390.541	9999.898	3667.172
Wind_Direction	Degree	$-8.99 \times 10^9$	-12167.341	359.0	10073696.469
Weather_Daily_Rainfall	Mm	$-8.99 \times 10^9$	-20183.745	0.294	10078144.540
Max_Wind_Speed	m/s	$-8.99 \times 10^9$	-11209.417	24.300	10045831.118
Air_Pressure	Hpa	$-8.99 \times 10^9$	-11377.447	974.210	10073697.343
Hail_Accumulation	NA	$-8.99 \times 10^9$	-20557.518	0.0	10783344.404
Pyanometer_1	$W/m^2$	-15.800	570.709	99999.89	5497.271
Temperature_Probe_1	$^{\circ}C$	0.0	43.707	319.744	10.804
Temperature_Probe_2	$^{\circ}C$	0.0	43.768	263.893	10.804
Active_Power	kw	3009.27	7.692	40.507	11.162

上述数据将会在训练前将其标准化，训练集、测试集和验证集的比例为 7:2:1。

## 4.2. 评价指标

本文为评估模型的有效性和准确性，使用了 4 个误差评估指标均方误差 MSE，平均绝对误差 MAE，均方根误差 RMSE，判定系数  $R^2$ 。

$$MSE = \frac{1}{r} \sum_{i=1}^r (q_i - p_i)^2 \quad (5)$$

$$RMSE = \sqrt{\frac{1}{r} \sum_{i=1}^r (q_i - p_i)^2} \quad (6)$$

$$MAE = \frac{1}{r} \sum_{i=1}^r |q_i - p_i| \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^r (q_i - p_i)^2}{\sum_{i=1}^r (q_i - \overline{p_i})^2} \quad (8)$$

其中  $p_i$  表示预测值， $q_i$  表示真实值， $\overline{p_i}$  表示  $p_i$  的平均值， $n$  表示样本总数。 $R^2$  的范围在 0 到 1 之间，其数值越接近 1，则表示模型的预测结果拟合度越高，MSE，MAE，RMSE 越接近 0，则表示模型预测结果与真实值之间的误差越小，预测结果越好。

## 5. 对比实验与结果

为了提高光伏发电预测模型的准确性与可靠性，本文提出了一种使用了 SA 优化算法与改进的 Informer 模型结合的混合模型。在本节中，我们将 Informer + GBC + EWT + SA 模型与多个改进的模型和单一预测模型进行比较。进行比较的模型分别为 BP，LSTM，GRU，Informer，Informer + GBC，Informer + GBC + SA，Informer + GBC + EWT + SA。本文通过多次实验对比了本文提出的改进对 Informer 模型的改进效果，还比较了使用 GBC 改进 LSH 后的 Informer 模型与原 LSH-Informer 的效果。

### 5.1. 模型间对比

为验证混合 Informer 模型和改进 GBC 在光伏功率预测中的可行性。本文设置了 6 个对照组：BP，

LSTM, GRU, Informer, Informer + GBC, Informer + SA + GBC, 将这些对照组与本文提出的混合模型 Informer + GBC + EWT + SA 进行比较。表 2 给出了拟议模型与其余六个模型 MSE, MAE, RMSE,  $R^2$  值。

**Table 2.** Comparison of the PV prediction result

**表 2.** 光伏发电预测结果对比

Method	MSE	MAE	RMSE	$R^2$
BP	0.1681	0.2355	0.4099	0.8282
LSTM	0.1429	0.1972	0.3780	0.8534
GRU	0.1362	0.1891	0.3691	0.8604
Informer	0.1223	0.1971	0.3498	0.8788
Informer + Grid	0.0926	0.1459	0.3043	0.9083
Informer + Grid + SA	0.0707	0.1208	0.2659	0.9299
Informer + Grid + EWT + SA	<b>0.0595</b>	<b>0.1146</b>	<b>0.2440</b>	<b>0.9410</b>

本文实验模型参数如下：批量大小 batch\_size 为 256, d\_ff 全连接层维度为 2048, d\_model 模型维度选取范围为 16, 32, 64, 128; 随即调整多头注意力机制中头数 n\_head 为 4 或 8; dropout 值选区范围为 0.05~0.1; 注意力机制参数 factor 在 16, 32, 64 中选取; 学习率 learning\_rate 的取值范围为 1E-5 到 1E-3。BP 的最大训练数为 120, 学习率为 0.0001, 训练目标误差为 0.00001。

如表 2 所示, 与传统模型 BP, LSTM, GRU 相比, Informer 模型在各个指标均具有更好的指标。因此本文选择以 Informer 为基础进行混合模型的开发, 经过对比实验, 本文提出的混合 Informer + GBC + EWT + SA 的性能与精度确实有着更优异的成绩其 MSE, MAE, RMSE 最低,  $R^2$  最高。图 6 显示了 7 个模型在这四个指标上的表现雷达图。

Informer 模型的 MSE 为 0.1223, MAE 为 0.1971, RMSE 为 0.3498,  $R^2$  为 0.8788。Informer + GBC 模型的 MSE 为 0.0926, MAE 为 0.1459, RMSE 为 0.3043,  $R^2$  为 0.9083。与 Informer 模型相比, 每一项指标均有所提升, 显著显现了 GBC 该进对模型预测精度的提升。具体来说, MSE 降低了 0.0297, MAE 降低了 0.0512, RMSE 降低了 0.0455,  $R^2$  提升了 0.0295。与 Informer 相比 MSE, MAE, RMSE 分别降低了 24.28%, 25.97%, 13.01%,  $R^2$  提升了 3.35%。由此可见 GBC 能够显著降低模型的误差, 其中效果最明显的是在指标 MAE 中体现。而提升相对较小的是拟合度  $R^2$ 。这些结果能够证明 GBC 是一项提高 Informer 的有效方案。

使用 SA 优化, 得 Informer + GBC + SA 模型的 MSE 为 0.0707, MAE 为 0.1208, RMSE 为 0.2659,  $R^2$  为 0.9299。与 Informer 相比, MSE 降低了 0.0516, MAE 降低了 0.0763, RMSE 降低了 0.839,  $R^2$  提升了 0.0511。SA 的引入使得模型能够通过多次迭代优化超参数的选择, 使得模型的预测精度进一步提升。与 Informer + GBC 相比 MSE 降低了 0.0219、即 23.55%, MAE 降低了 0.025、即 17.13%, RMSE 降低了 0.0384、即 12.61%,  $R^2$  提升了 0.0232、即 2.55%。通过以上数据可以看出 SA 的作用主要提升显著表现在 MSE 上, 其次是在 MAE 上, 因此, 我们可以确定, SA 超参数优化对于 Informer 是一个合理的改进。

引入 EWT 对数据进行模态分解后将各模态作为特征进行训练, 由此我们可以得到 Informer + GBC + EWT + SA 模型评价指标 MSE 为 0.0595, MAE 为 0.1146, RMSE 为 0.2440,  $R^2$  为 0.9410。具体来说, 与 Informer 相比 MSE 降低了 0.0628, MAE 降低了 0.0825, RMSE 降低了 0.1058,  $R^2$  提升了 0.0622。也就是说 MSE, MAE, RMSE, 分别降低了 51.34%, 41.85%, 30.24%,  $R^2$  提升了 7.07%。证明了改进的

Informer 模型，即 Informer + GBC + EWT + SA 模型可以达到较高的预测精度。图 5 展示了 BP, LSTM, GRU, Informer, Informer + GBC, Informer + GBC + SA 和 Informer + GBC + EWT + SA 的评价指标对比，清晰地表明了模型的可行性。

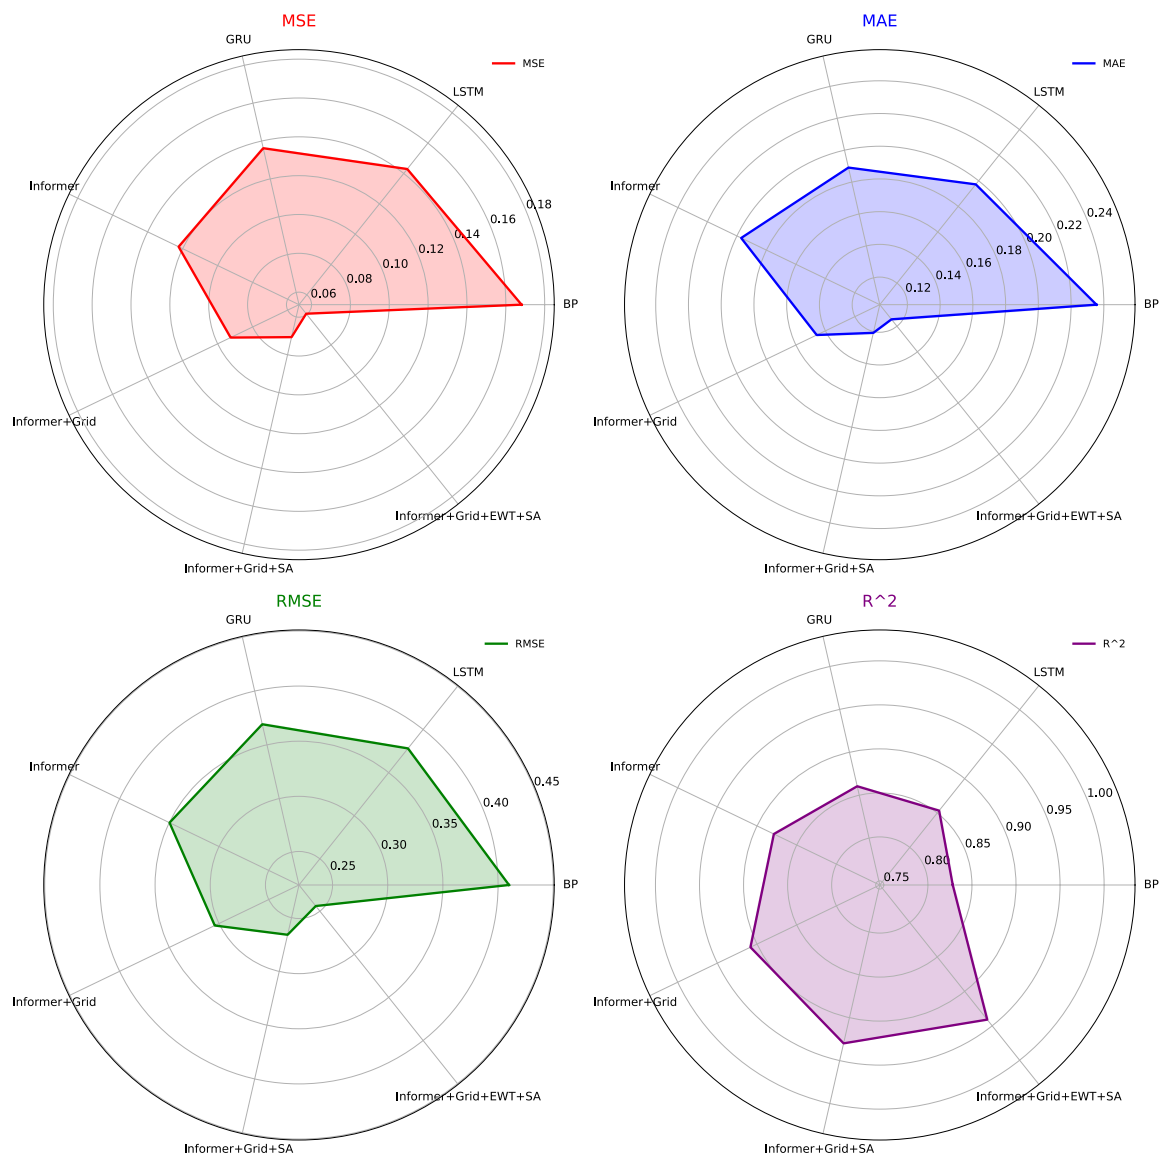


Figure 5. Comparison of various models

图 5. 7 个模型在 MSE, MAE, RMSE,  $R^2$  四个指标对比

## 5.2. 混合模型中改进权重

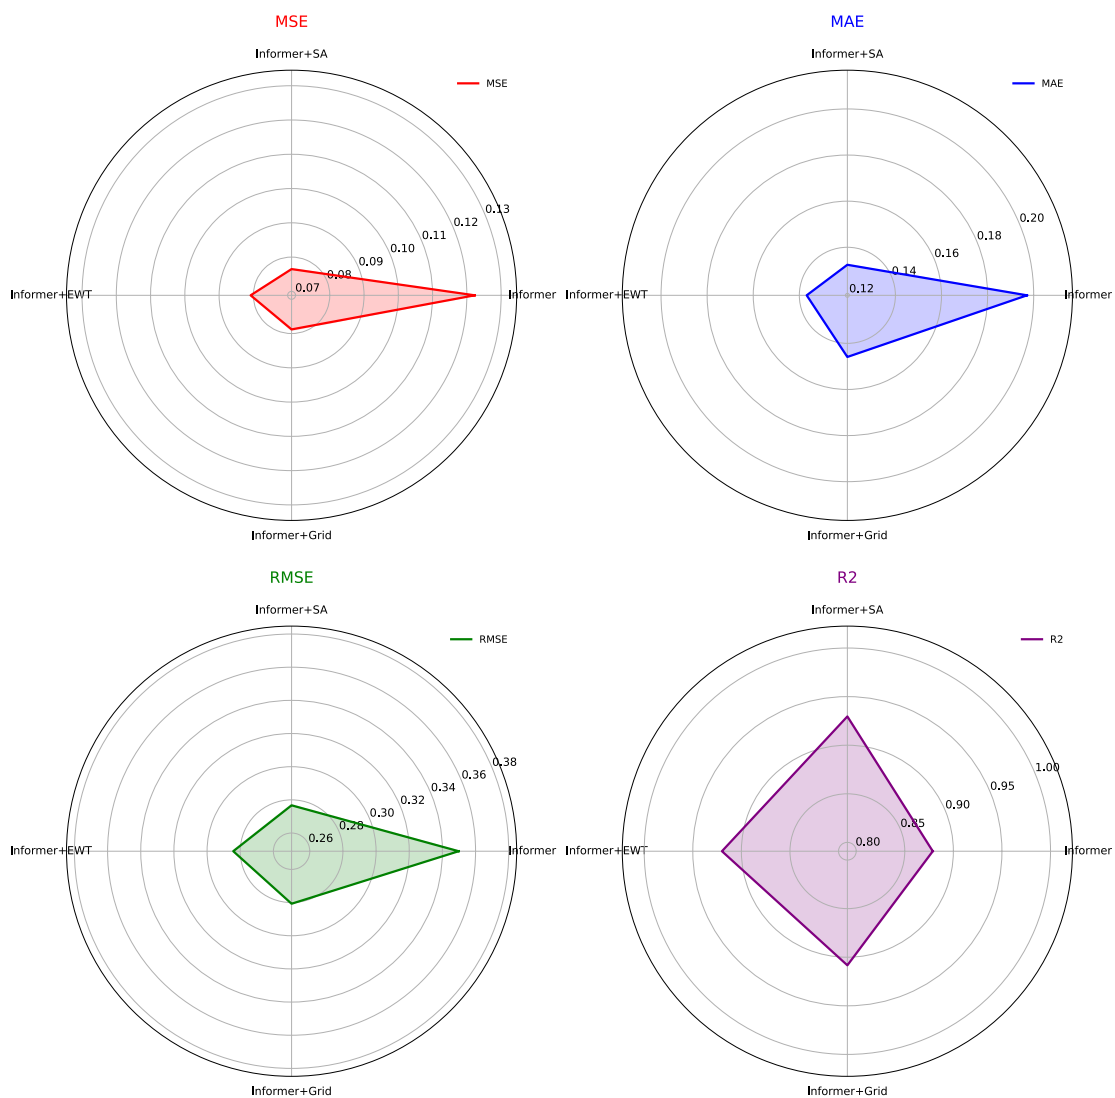
本文使用了三个方法针对 Informer 进行了改进，分别是经验小波变换 EWT，在 LSH 框架下的基于网格的聚类 GBC，模拟退火优化算法。其中 EWT 实现了对预处理后的数据进行模态分解；GBC，即 Grid-Based Cluster，实现了对 Informer 模型中 Probsparse 机制的改进；模拟退火优化算法通过多次迭代对模型的超参数进行优化。我们将在本部分中讨论本文使用的这三个改进方法对模型的改进权重。表三，展示了仅使用一个方法下对模型的性能的影响，以及混合模型中 SA 模拟退火算法对超参数进行迭代调试的作用。

### 5.2.1. 改进权重

**Table 3.** Comparison of the hybrid models

**表 3.** 混合模型对比

Method	MSE	MAE	RMSE	$R^2$
Informer	0.1223	0.1971	0.3498	0.8788
Informer + SA	<b>0.0765</b>	<b>0.1324</b>	<b>0.2767</b>	<b>0.9296</b>
Informer + EWT	0.0808	0.1368	0.2842	0.9200
Informer + EWT + SA	<b>0.0656</b>	<b>0.1146</b>	<b>0.2536</b>	<b>0.9350</b>
Informer + Grid	0.0788	0.1459	0.2807	0.9083
Informer + Grid + SA	<b>0.0707</b>	<b>0.1208</b>	<b>0.2659</b>	<b>0.9299</b>



**Figure 6.** Comparison of single algorithm

**图 6.** 单算法对比图

表 3 中分别给出 Informer, Informer + SA, Informer + EWT, Informer + EWT + SA, Informer + GBC,

Informer + GBC + SA 六个模型的评价指标。首先分析不同的方法对模型的改进权重。如表 3 所示, 在 MSE 指标上, Informer 为 0.1223, Informer + SA 为 0.0765, Informer + EWT 为 0.0808, Informer + GBC 为 0.0788, 可以看出模拟退火优化 SA 在 MSE 上有着更高的权重。MSE 一般用于反应模型的整体误差水平, 对偏离真实值较远的预测值更加敏感。因此可以得出, 模拟退火优化 SA 能够更好地针对模型的整体误差做出优化。在 MAE 指标上, Informer 为 0.1971, Informer + SA 为 0.1324, Informer + EWT 为 0.1368, Informer + GBC 为 0.1459, 可以看出 SA 依旧有着比较优秀的表现, 对于其他两个方法, 在 MAE 上表现优秀。MAE 表示模型预测值与实际值之间的平均偏差, 对于模型来说, 主要用于反应模型的稳定性。因此 SA 对于模型的稳定性有着比较优秀的成绩。在 RMSE 与  $R^2$  上依旧是 SA 有着优势, 四种模型的评价指标 RMSE 分别为 0.3498, 0.2767, 0.2842, 0.2807;  $R^2$  分别为 0.8788, 0.9296, 0.9200, 0.9299。由此可见 SA 总体上相较于其他两种方法有着较高的优化权重, 对模型性能优化起到至关重要的作用。SA 对 Informer 的提升 MSE 为 37.44%, MAE 为 32.82%, RMSE 为 20.89%,  $R^2$  为 5.78%; EWT 对 Informer 的 MSE 为 33.93%, MAE 为 30.59%, RMSE 为 18.75%,  $R^2$  为 4.68%; GBC 对 Informer 的 MSE 为 35.56%, MAE 为 25.97%, RMSE 为 19.75%,  $R^2$  为 3.35%。根据上述数据我们可以得出结论: SA 为三种方法中对模型改进权重最为高的一项, 同时在四种评价指标中 SA 对模型性能提升最高的为  $R^2$ , 即 SA 拥有较为强的能力来改善模型的拟合度, 能够有效的提高模型的预测精度。图 6 为该四个模型的雷达图对比。

### 5.2.2. SA 下的 EWT 与 GBC

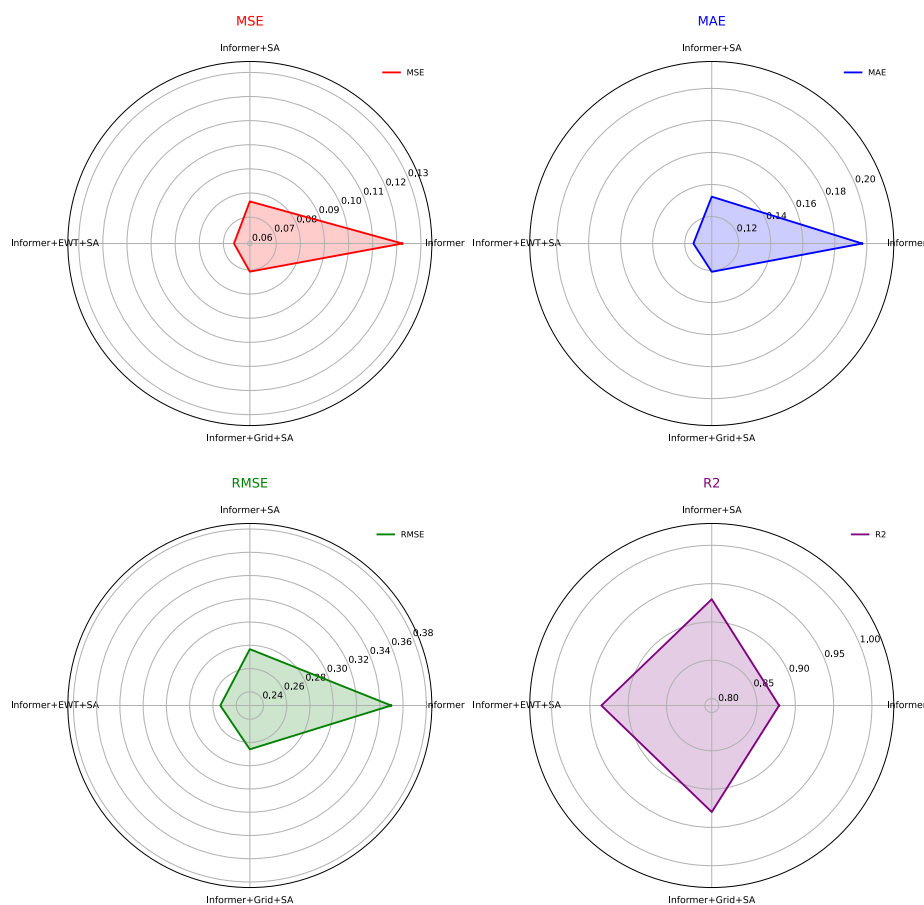


Figure 7. EWT and GBC with SA  
图 7. SA 下的 EWT 与 GBC

进一步的, 由于 SA 是三种方法中改进权重最大的一种方法, 因此我们分析同样在 SA 优化的情况下哪种方法对模型可以提供更加大的提升。由表 3 中的评价指标数据, Informer 分别是 MSE 为 0.1223, MAE 为 0.1971, RMSE 为 0.3498,  $R^2$  为 0.8788; Informer+SA 分别是 MSE 为 0.0765, MAE 为 0.1324, RMSE 为 0.2767,  $R^2$  为 0.9296; Informer+EWT+SA 分别是 MSE 为 0.0656, MAE 为 0.1146, RMSE 为 0.2536,  $R^2$  为 0.9350; Informer+GBC+SA 分别是 MSE 为 0.0707, MAE 为 0.1208, RMSE 为 0.2659,  $R^2$  为 0.9299。如图 7 所示, 通过对比, 可以得到结果: EWT 与 GBC 相比, EWT 对模型的改进效果, 在同为 SA 多次迭代的情况下, 有着更好的表现。与 Informer+SA 相比 Informer+EWT+SA, 其评价指标结果提升了 MSE 为 14.24%, MAE 为 13.44%, RMSE 为 8.34%,  $R^2$  为 0.58%。参考上一小节的数据结果, 在非 SA 迭代的情况下, GBC 有着更好的改进效果。由此可以给出推论。EWT 模态分解方法, 将数据分为三个模态, 然后将各个模态均作为输入的特征来进行训练, 即从原本 12 个特征变为 36 个特征进行训练, 能够对模型进行改进, 但是由于增加了特征数量, 使得运算变得复杂, 同时也导致了在未经过迭代优化的情况下, 过多的特征导致训练结果不稳定的问题。总体上在不使用 SA 进行参数优化的情况下 GBC 更能带来稳定而切实的提升, 而在使用 SA 的情况下, EWT 其多特征模态分解的能力能够给模型带来更加优异的成绩。

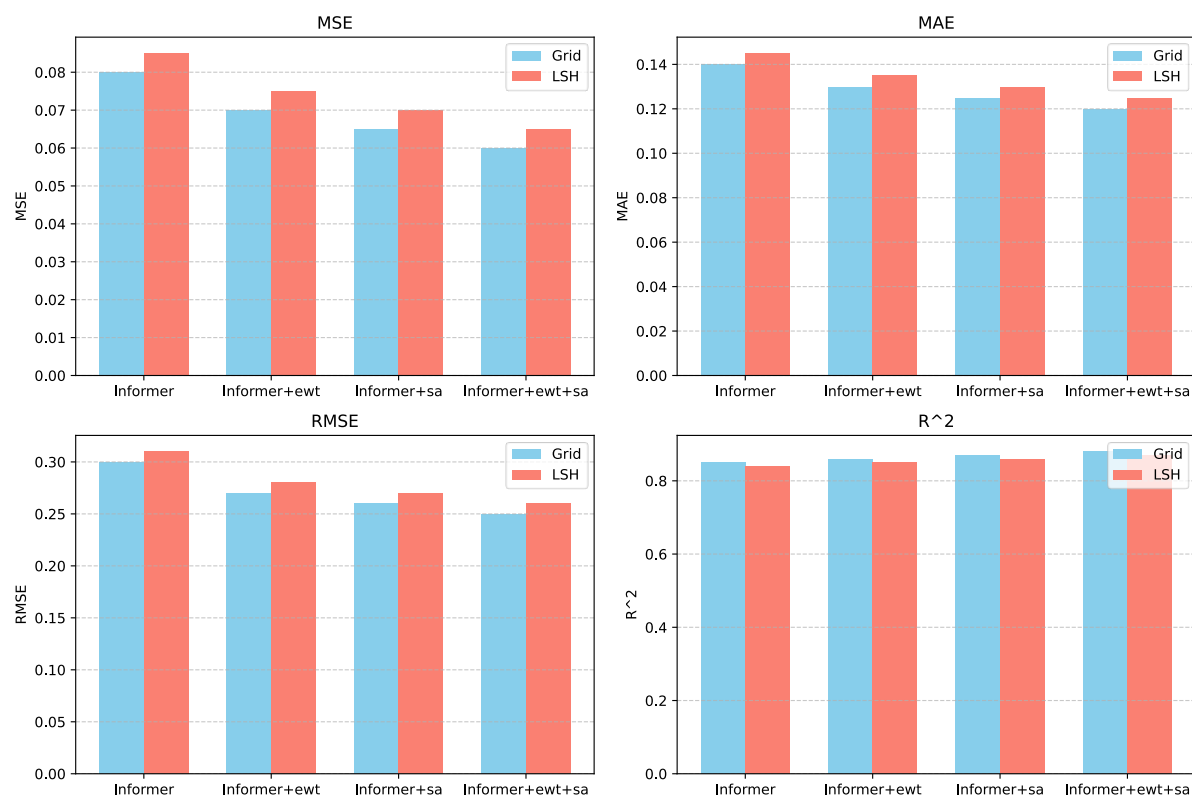
### 5.3. 基于 LSH 框架下的 GBC 改进有效性

本文针对模型 Informer 中 ProbSparse attention 部分进行了改进。此改进意在提升模型的预测精度与运算速度, 参考 Kitaev [14] 在 Reformer 中提出的使用局部敏感哈希 LSH 对自注意机制的改进, 本文考虑了一种更加效率, 且能够更好提高预测精度的基于网格的聚类 GBC, 将其放入 LSH 框架中, 代替桶选择的部分, 保留原 LSH 中多轮哈希部分。表 4 中给出了 LSH 与 GBC 在各种模型选择时的评价指标情况。Informer+GBC 的评价指标 MSE 为 0.0788, MAE 为 0.1329, RMSE 为 0.2807,  $R^2$  为 0.9219; Informer+LSH 的评价指标 MSE 为 0.0836, MAE 为 0.1281, RMSE 为 0.2891,  $R^2$  为 0.9172; Informer+EWT+GBC 的评价指标 MSE 为 0.0701, MAE 为 0.1263, RMSE 为 0.2646,  $R^2$  为 0.9306; Informer+EWT+LSH 的评价指标 MSE 为 0.0715, MAE 为 0.1385, RMSE 为 0.2961,  $R^2$  为 0.9131; Informer+SA+GBC 的评价指标 MSE 为 0.0707, MAE 为 0.1208, RMSE 为 0.2659,  $R^2$  为 0.9299; Informer+SA+LSH 的评价指标为 MSE 为 0.0724, MAE 为 0.1242, RMSE 为 0.2692,  $R^2$  为 0.9282; Informer+EWT+SA+GBC 的评价指标 MSE 为 0.0595, MAE 为 0.1146, RMSE 为 0.2440,  $R^2$  为 0.9410; Informer+EWT+SA+LSH 的评价指标 MSE 为 0.0710, MAE 为 0.1205, RMSE 为 0.2665,  $R^2$  为 0.9296。一共 6 组数据, 分别为在仅有 Informer 模型下, LSH 与 GBC 的改进效果对比; 在 EWT 下的对比, 在 SA 算法进行迭代后的对比; 在 EWT 与 SA 均使用的情况下, 完整的混合模型间的对比。如图 8 所示四个评价指标在四种情境下 LSH 与 GBC 的对比。

**Table 4.** Evaluation metrics of LSH and GBC in various model

**表 4.** LSH 与 GBC 在各种模型选择时的评价指标

Method	MSE	MAE	RMSE	$R^2$
Informer + Grid	<b>0.0788</b>	<b>0.1329</b>	<b>0.2807</b>	<b>0.9219</b>
Informer + LSH	0.0836	0.1281	0.2891	0.9172
Informer + EWT + Grid	<b>0.0701</b>	<b>0.1263</b>	<b>0.2646</b>	<b>0.9306</b>
Informer + EWT + LSH	0.0715	0.1385	0.2961	0.9131
Informer + SA + Grid	<b>0.0707</b>	<b>0.1208</b>	<b>0.2659</b>	<b>0.9299</b>
Informer + SA + LSH	0.0724	0.1242	0.2692	0.9282
Informer + EWT + SA + Grid	<b>0.0595</b>	<b>0.1146</b>	<b>0.2440</b>	<b>0.9410</b>
Informer + EWT + SA + LSH	0.0710	0.1205	0.2665	0.9296



**Figure 8.** Comparison of LSH and GBC in various models  
**图 8.** 不同指标下模型间的 LSH 与 GBC 对比

由图 8 中所示，我们使用柱状图来更清晰地表现在四种不同的模型下 GBC 与 LSH 的评价指标改进情况。首先是评价指标 MSE 表示了模型的整体误差水平，我们可以看出在各种模型下均是 GBC 能够获得更低的值。Informer, Informer + EWT, Informer + SA, Informer + EWT + SA 中，GBC 比 LSH 分别低了 6.09%, 1.99%, 2.41%, 19.32%，由以上数据可得，在完整的混合模型中 GBC 的整体误差水平的改进表现最为明显。第二个评价指标为 MAE，表示了模型的稳定性，四个模型下，GBC 比 LSH 分别低了 -3.61%, 9.65%, 2.81%, 5.14%，由以上数据可得，在仅有 EWT 的混合模型中 GBC 的稳定性改进表现最好，而在 Informer 基础模型下，LSH 能获得更好的稳定性。第三个评价指标为 RMSE，表示了模型的综合误差水平，GBC 比 LSH 分别低了 2.99%, 11.90%, 1.24%, 9.22%，由以上数据可得，依旧是在仅有 EWT 的混合模型中，GBC 的综合误差的改进表现最好，其次就是在完整混合模型中的表现。最后一个评价指标为  $R^2$ ，表示了模型的拟合优度，GBC 比 LSH 分别高了 0.5%, 1.91%, 0.18%, 1.22%，由以上数据可得，与 RMSE 结果相似，仅有 EWT 的情况下模型解释数据变异能力的改进效果最好，其次是完整模型。

## 6. 总结与展望

### 6.1. 总结

本文提出了一种改进的基于 Informer 的光伏发电预测混合模型，结合了经验小波分解(EWT)、基于网络的聚类方法(GBC)与模拟退火优化算法(SA)。本文的研究从数据预处理、特征分解、模型改进及优化、模型训练与验证等多个方面进行了详细分析。

与 Informer 模型相比, Informer + EWT + GBC + SA 的评价指标 MSE, MAE, RMSE 分别降低了 51.34%, 41.85%, 30.24%,  $R^2$  提升了 7.07%。在单改进方法的权重中可以通过实验数据得知, SA 的改进权重最高, 即相较于 EWT 与 GBC, SA 对模型的改进效果最为明显。提出的 Informer + GBC + EWT + SA 模型在多个实验对比中表现出优异的性能, MSE、MAE, RMSE 和均取得显著提升, 充分验证了模型改进的可行性与优越性。

本文研究为光伏发电功率预测领域提供了一个新的工具, 具有重要的理论和实用价值。在理论上, 本研究中描述的模型拓宽了光伏发电功率预测的研究领域。在实际应用中, 提高光伏预测的准确性有利于提高太阳能的利用率。同时, 它还能减少发电厂因限电造成的损失, 提高收益率。同时也展示了混合模型在解决复杂时间序列预测问题中的潜力。本文提出的 Informer + GBC + EWT + SA 模型在光伏预测方面具有优势。研究结果表明, Informer + GBC + EWT + SA 模型具有更高的预测精度和解释数据变异的能力。

## 6.2. 展望

尽管本文模型在性能上取得了显著提升, 但仍存在以下几点不足和未来改进方向: 本文模型主要针对单一站点的光伏发电数据进行验证, 未来可尝试在多站点数据上测试模型的适用性, 以提高模型的通用性。在数据特征选择方面, 可结合更多影响光伏发电的外部因素(如地理特征、云层分布)进行建模, 进一步提升预测精度。尽管本文改进了 Informer 模型的效率, 但多特征输入与参数优化增加了计算复杂度。未来可探索更轻量化的改进方案, 兼顾性能与效率。随着光伏发电系统和气象条件的变化, 数据分布可能发生变化。优化模型, 使其能够动态适应数据变化, 提高实时预测能力。

本文的研究成果主要验证于实验数据, 未来可尝试将模型应用于实际光伏电站的发电调度系统, 评估其在实际运行中的稳定性与经济效益。通过对模型进一步优化与扩展, 本文研究有望为光伏发电预测及智能电网调度提供更加精准和高效的解决方案, 助力新能源的可持续发展。

## 参考文献

- [1] Kumar, M., Chandel, S.S. and Kumar, A. (2020) Performance Analysis of a 10 MWP Utility Scale Grid-Connected Canal-Top Photovoltaic Power Plant under Indian Climatic Conditions. *Energy*, **204**, Article ID: 117903. <https://doi.org/10.1016/j.energy.2020.117903>
- [2] (2019) Solar Power Europe, Global Market Outlook—Intersolar Europe. United States Solar PV Market Overview, 31.
- [3] Khan, S.U., Khan, N., Ullah, F.U.M., Kim, M.J., Lee, M.Y. and Baik, S.W. (2023) Towards Intelligent Building Energy Management: AI-Based Framework for Power Consumption and Generation Forecasting. *Energy and Buildings*, **279**, Article ID: 112705. <https://doi.org/10.1016/j.enbuild.2022.112705>
- [4] Alassery, F., Alzahrani, A., Khan, A.I., Irshad, K. and Islam, S. (2022) An Artificial Intelligence-Based Solar Radiation Prophecy Model for Green Energy Utilization in Energy Management System. *Sustainable Energy Technologies and Assessments*, **52**, Article ID: 102060. <https://doi.org/10.1016/j.seta.2022.102060>
- [5] Yang, X., Wang, S., Peng, Y., Chen, J. and Meng, L. (2023) Short-term Photovoltaic Power Prediction with Similar-Day Integrated by BP-AdaBoost Based on the Grey-Markov Model. *Electric Power Systems Research*, **215**, Article ID: 108966. <https://doi.org/10.1016/j.epsr.2022.108966>
- [6] Wang, L., Mao, M., Xie, J., Liao, Z., Zhang, H. and Li, H. (2023) Accurate Solar PV Power Prediction Interval Method Based on Frequency-Domain Decomposition and LSTM Model. *Energy*, **262**, Article ID: 125592. <https://doi.org/10.1016/j.energy.2022.125592>
- [7] Lee, D. and Kim, K. (2021) PV Power Prediction in a Peak Zone Using Recurrent Neural Networks in the Absence of Future Meteorological Information. *Renewable Energy*, **173**, 1098–1110. <https://doi.org/10.1016/j.renene.2020.12.021>
- [8] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., et al. (2017) Attention Is All You Need. In: Guyon, I., Von Luxburg, U., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S. and Garnett, R., Eds., *31st Conference on Neural Information Processing Systems (NIPS 2017)*, Long Beach, 4–9 December 2017.

- 
- <https://arxiv.org/abs/1706.03762>
- [9] Wang, K., Qi, X. and Liu, H. (2019) Photovoltaic Power Forecasting Based LSTM-Convolutional Network. *Energy*, **189**, Article ID: 116225. <https://doi.org/10.1016/j.energy.2019.116225>
  - [10] Zhou, H., Zhang, S., Peng, J., Zhang, S., Li, J., Xiong, H., *et al.* (2020) Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. arXiv: 2012.07436.
  - [11] Cao, Y., Liu, G., Luo, D., Bavirisetti, D.P. and Xiao, G. (2023) Multi-timescale Photovoltaic Power Forecasting Using an Improved Stacking Ensemble Algorithm Based LSTM-Informer Model. *Energy*, **283**, Article ID: 128669. <https://doi.org/10.1016/j.energy.2023.128669>
  - [12] Li, F., Wan, Z., Koch, T., Zan, G., Li, M., Zheng, Z., *et al.* (2023) Improving the Accuracy of Multi-Step Prediction of Building Energy Consumption Based on EEMD-PSO-Informer and Long-Time Series. *Computers and Electrical Engineering*, **110**, Article ID: 108845. <https://doi.org/10.1016/j.compeleceng.2023.108845>
  - [13] Ren, S., Wang, X., Zhou, X. and Zhou, Y. (2023) A Novel Hybrid Model for Stock Price Forecasting Integrating Encoder Forest and Informer. *Expert Systems with Applications*, **234**, Article ID: 121080. <https://doi.org/10.1016/j.eswa.2023.121080>
  - [14] Kitaev, N., Kaiser, L. And Levskay, A. (2020) Reformer, The Efficient Transformer. arXiv: 2001.04451.
  - [15] Kirkpatrick, S., Gelatt, C.D. and Vecchi, M.P. (1983) Optimization by Simulated Annealing. *Science*, **220**, 671-680. <https://doi.org/10.1126/science.220.4598.671>
  - [16] Gilles, J. (2013) Empirical Wavelet Transform. *IEEE Transactions on Signal Processing*, **61**, 3999-4010. <https://doi.org/10.1109/tsp.2013.2265222>
  - [17] Dka Solar Centre. <https://dkasolarcentre.com.au/source/yulara/yulara-3-roof-sails-in-the-desert>
  - [18] Australian Government Bureau of Meteorology. <http://www.bom.gov.au/>