

# 基于 MSTSO 算法的冷水机组负荷分配模型研究

王华秋, 李乐天

(重庆理工大学 两江人工智能学院, 重庆 401135)

**摘要:** 为降低空调系统的运行能耗, 优化冷水机组的负荷分配, 提出了一种多策略改进的金枪鱼优化算法 (MSTSO), 引入黄金正弦觅食机制和非线性惯性权重来加强算法对最优解的全局定位能力; 通过蜜獾随机搜索策略赋予算法更强的性能以跳出局部最优; 利用双向长短期记忆网络 (BiLSTM) 搭建能效预测模型并对各机组的能效比 (COP) 进行预测, 同时使用 MSTSO 算法对网络的初始参数进行寻优从而获得最佳训练效果; 提出 BiLSTM-MSTSO 负荷分配模型, 对多台冷水机组的部分负荷率 (PLR) 进行合理分配与优化; 实验结果表明, 优化后的 BiLSTM 预测模型拥有更高的预测精度, MSTSO 算法相较其他智能优化算法可以减少更多的能耗并最大化提升冷水机组的运行效率; 因此 BiLSTM-MSTSO 智能模型适用于多冷水机组的能耗预测与优化。

**关键词:** 多冷水机组; 负荷分配; 金枪鱼优化算法; 双向长短期记忆网络; 能耗优化

## Study on Load Distribution Model of Chillers Based on MSTSO Algorithm

WANG Huaqiu, LI Letian

(School of Liangjiang Artificial Intelligence, Chongqing University of Technology, Chongqing 401135, China)

**Abstract:** To reduce the operating energy consumption of air-conditioning systems and optimize the load distribution of chillers, a multi-strategy improved tuna swarm optimization algorithm (MSTSO) is proposed. A golden sine foraging mechanism and non-linear inertia weights are introduced to enhance the algorithm's ability to locate the optimal solution globally. A honey badger random search strategy is used to help the algorithm stronger performance to jump out of the local optimum. A bi-directional long short-term memory (BiLSTM) network is used to build an energy efficiency prediction model and predict the coefficient of performance (COP) of each chiller, while the MSTSO algorithm is used to optimize the initial parameters of the network to obtain the best training results. A BiLSTM-MSTSO energy consumption optimization model is proposed to reasonably allocate and optimize the part load ratio (PLR) of multi-chillers. The experimental results show that the optimized BiLSTM prediction model has higher prediction accuracy, and compared with other intelligent optimization algorithms, the MSTSO algorithm can reduce the energy consumption and maximize the operating efficiency of chillers. Therefore, the BiLSTM-MSTSO intelligent model can be used to predict and optimize the energy consumption of multi-chillers.

**Keywords:** multi-chillers; load distribution; tuna swarm optimization algorithm; bi-directional long short-term memory network; energy consumption optimization

## 0 引言

目前, 建筑业占全球能源消耗总量的 1/3 以上, 约占直接和间接二氧化碳排放总量的 40%<sup>[1]</sup>。随着全球经济的发展和人类对高品质建筑空间及健康生活的需求增加, 建筑能耗也呈现出不断增加的趋势<sup>[2]</sup>。作为建筑中的主要能源消耗者, 暖通空调 (HVAC) 系统消耗了约 25%~40% 的总能源使用量, 尤其是暖通空调系统中的冷水机组消耗了最多的能源, 以满足夏季的冷却需求<sup>[3-4]</sup>。显然, 优化冷水机组的部分负荷率和开关状态不仅对创造舒适健康的室内环境, 而且对降低能耗具有重要意义。因而, 最优冷水机组负荷 (OCL) 问题已成为节能领域的一个研究热点。

由于在多冷水机组系统中, 各台冷水机组之间存在一

定的性能差异, 为更精准更贴合实际地解决 OCL 问题, 对冷水机组进行能效关系建模成为了重中之重。空调系统的建模类型主要分为机理模型和黑盒模型<sup>[5]</sup>。随着当今数据采集能力的不断进步, 大批次暖通空调设备的运行数据得以获取, 因而基于神经网络和数据挖掘的黑盒模型成为了主流的预测模型。魏峥等<sup>[6]</sup>使用了包括随机森林等多种机器学习算法进行冷水机组能耗建模, 通过与回归分析方法对比, 发现机器学习算法拥有较高的灵活性和预测精度。高扬等<sup>[7]</sup>基于前向神经网络, 用较小的代价精准预测了建筑的热环境变化规律。Fan 等<sup>[8]</sup>利用深度学习算法对短期建筑冷负荷进行了预测, 更方便高效地解决了实际问题。王香兰等<sup>[9]</sup>使用 Apriori 频繁项集算法挖掘冷水机组运行参数

收稿日期: 2023-03-13; 修回日期: 2023-04-13。

基金项目: 国家科技部重点研发计划项目 (2018YFB1700803); 重庆市科委一般自然基金项目 (cstc2019jcyj-msxmX0500)。

作者简介: 王华秋 (1975-), 男, 博士, 教授。

引用格式: 王华秋, 李乐天. 基于 MSTSO 算法的冷水机组负荷分配模型研究[J]. 计算机测量与控制, 2024, 32(1): 201-208, 216.

和最小运行能耗之间的关联规则，取得了良好的节能效果。以上文献大都以能耗为目标进行建模，而非以能效比为目标进行预测模型的搭建。

在冷水机组的能效关系模型建立之后，需要解决不同运行工况下的 OCL 问题。随着对智能优化算法的研究不断深入，更多类型的智能优化算法被应用于 OCL 问题的解决中。Lee 等人<sup>[10]</sup>使用微分进化 (DE) 算法来解决 OCL 问题以降低能耗，结果表明，DE 算法可以像 PSO 一样找到最优解并获得更好的平均解。Sulaiman 等人<sup>[11]</sup>应用差分搜索 (DS) 算法来优化制冷机负荷以实现能量转换。Sohrabi 等人<sup>[12]</sup>利用交换市场算法 (EM) 在满足冷却需求的同时最小化了冷却器的功耗，结果表明 EM 算法可以解决大型多冷却器系统中的 OCL 问题。这些智能优化算法对 OCL 问题的解决有显著的提升但同时也存在收敛速度慢，易陷入局部最优等不足。

综上所述，本文提出一种多策略改进的金枪鱼优化算法 (MSTSO, multi-strategy improved tuna swarm optimization algorithm)，并利用该算法优化 BiLSTM 网络的初始参数，进而构建冷水机组能效预测模型。而后，在预测模型的基础上利用 MSTSO 进行冷水机组负荷的智能分配从而完成 BiLSTM-MSTSO 负荷分配模型的搭建，最终获取各台冷水机组的最佳运行负荷并达到减少能耗的目的。

### 1 研究对象

多冷水机组系统通常是将两个或者更多的主机用并联的方式加以连结，并连接至共同的分布系统中，这种设计方式具有良好的操作适应性、更可靠的容量供给以及更少的设备故障和维修。图 1 是解耦的多机组系统结构图，每台机器在运行的过程中独立运行，互不影响，共同支撑整个系统的冷量需求。

#### 1.1 冷水机组的优化参数

当各台冷水机组并联运行的时候，单个机组并不都处于满负荷的运行状态，此时将单个机组的运行负荷与其额定负荷的比值定义为该机组的部分负荷率 (PLR)，如式 (1) 所示：

$$PLR_{\sigma-i} = \frac{CL_{p-i}}{CL_{r-i}} \quad (1)$$

式中， $PLR_{\sigma-i}$  为第  $i$  台机组的部分负荷率； $CL_{p-i}$  为第  $i$  台机组实际运行时的负荷，kW； $CL_{r-i}$  为第  $i$  台机组的额定负荷，kW。

在满足负荷需求的条件下，最佳的工作情况发生在能效比 (COP) 最高时，如式 (2) 所示：

$$COP_i = \frac{CL_{p-i}}{P_{\sigma-i}} \quad (2)$$

式中， $COP_i$  为第  $i$  台机组的能效比； $P_{\sigma-i}$  为第  $i$  台机组的能耗，kW。

#### 1.2 能效影响因素分析

为更好地搭建冷水机组能效预测模型，需要准确地获得模型的输入参数和输出参数，而模型的输出参数为冷水

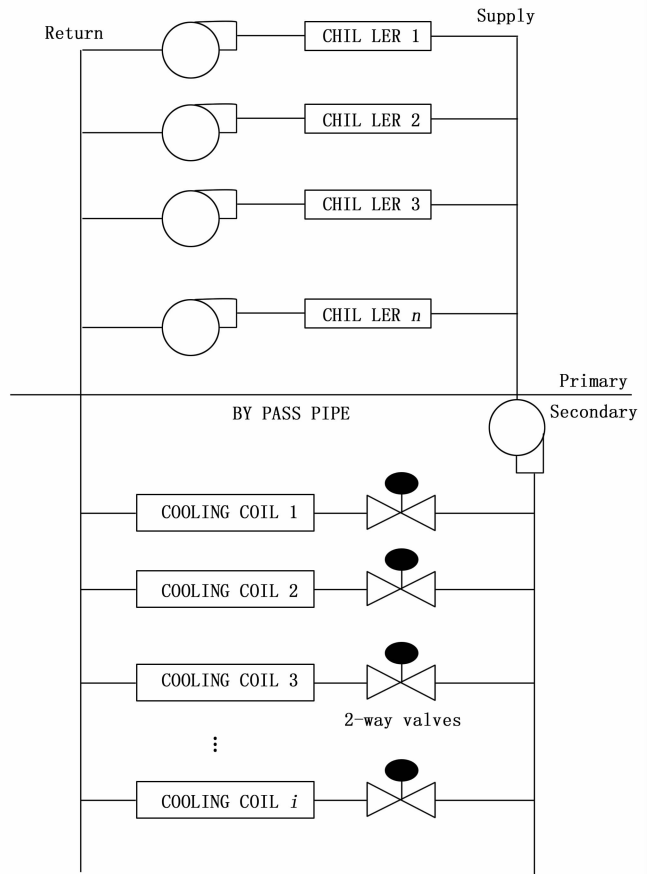


图 1 解耦的多机组结构图

机组的 COP 值。中央空调系统较为复杂，各参数之间相互影响，PLR 和 COP 的单一回归曲线并不能完全代表冷水机组的运行条件，其运行还会受到冷冻水进出水温度、冷却水进出水温度、冷冻水流量及冷却水流量等其他因素的影响<sup>[13]</sup>。因此本文采用 Pearson 相关系数对重要参数进行相关性分析，表达式如下所示：

$$\rho(X, Y) = \frac{cov(X, Y)}{\sigma_X \sigma_Y} \quad (3)$$

式中， $cov(X, Y)$  为变量之间的协方差， $\sigma_X$  和  $\sigma_Y$  分别为  $X$  和  $Y$  的标准差。 $\rho$  的取值范围为  $(-1, 1)$ ，当其绝对值越接近于 1，则两个参数相关性越大，反之若绝对值越接近于 0，则两参数之间相关性越小。计算结果如表 1 所示。

表 1 能效影响因素分析

影响因素	Pearson 相关系数
冷冻水出水温度/°C	0.859 4
冷冻水进水温度/°C	0.3657
冷却水进水温度/°C	0.586 5
冷却水出水温度/°C	0.802 9
冷冻水流量/(m <sup>3</sup> /h)	0.2413
冷却水流量/(m <sup>3</sup> /h)	0.761 5
冷水机组负荷率	0.806 2

由表 1 可以看出, 冷冻水出水温度、冷却水进水温度、冷却水出水温度、冷却水流量以及冷水机组负荷率与 COP 值有较大的相关性, 因此将以上 5 个因素作为冷水机组能效预测模型的输入, COP 值作为模型的输出。

## 2 多策略改进金枪鱼优化算法

### 2.1 金枪鱼优化算法

金枪鱼算法 (TSO, tuna swarm optimization)<sup>[14]</sup> 是一种新的基于群的元启发式算法, 其受启发于金枪鱼群体的合作觅食行为, 合作觅食包含两个部分, 分别是螺旋觅食和抛物线觅食。

#### 2.1.1 螺旋觅食

金枪鱼群通过形成紧密的螺旋来追逐猎物, 除此之外, 成群的金枪鱼还会进行信息的交互。由于每一条金枪鱼都会紧随前一条金枪鱼, 相邻的金枪鱼之间得以共享信息。基于上述原理, 螺旋觅食策略的数学公式如下:

$$X_i^{t+1} = \begin{cases} \alpha_1 \cdot (X_{best}^t + \beta \cdot |X_{best}^t - X_i^t|) + \alpha_2 \cdot X_i^t, i = 1 \\ \alpha_1 \cdot (X_{best}^t + \beta \cdot |X_{best}^t - X_i^t|) + \alpha_2 \cdot X_{i-1}^t, i = 2, 3, \dots, NP \end{cases} \quad (4)$$

$$\alpha_1 = a + (1 - a) \cdot \frac{t}{t_{max}} \quad (5)$$

$$\alpha_2 = (1 - a) - (1 - a) \cdot \frac{t}{t_{max}} \quad (6)$$

$$\beta = e^{bl} \cdot \cos(2\pi b) \quad (7)$$

$$l = e^{3\cos((t_{max}+1/t)-1)\pi} \quad (8)$$

$X_i^{t+1}$  是第  $t+1$  次迭代的第  $i$  个个体,  $X_{best}^t$  是当前最佳个体 (食物),  $\alpha_1$  和  $\alpha_2$  为两个控制移动趋势的权重系数,  $a$  是一个常数,  $t$  表示当前迭代次数,  $t_{max}$  表示最大迭代次数,  $b$  是均匀分布在 0 到 1 之间的随机数。

若最佳个体无法找到食物, 选择在搜索空间内随机生成一个坐标作为螺旋觅食的参照点。具体的数学模型描述如下:

$$X_i^{t+1} = \begin{cases} \alpha_1 \cdot (X_{rand}^t + \beta \cdot |X_{rand}^t - X_i^t|) + \alpha_2 \cdot X_i^t, i = 1 \\ \alpha_1 \cdot (X_{rand}^t + \beta \cdot |X_{rand}^t - X_i^t|) + \alpha_2 \cdot X_{i-1}^t, i = 2, 3, \dots, NP \end{cases} \quad (9)$$

其中:  $X_{rand}^t$  是搜索空间中随机生成的参考点。启发式算法通常在早期阶段进行广泛的全局搜索, 然后在后期阶段进行精确的局部开发。

#### 2.1.2 抛物线觅食

除了形成螺旋线进行觅食, 金枪鱼还会将食物作为参照点形成抛物线进行合作觅食。具体的数学模型描述如下:

$$X_i^{t+1} = \begin{cases} X_{best}^t + rand \cdot (X_{best}^t - X_i^t) + TF \cdot p^2 \cdot (X_{best}^t - X_i^t), rand < 0.5 \\ TF \cdot p^2 \cdot X_i^t, rand \geq 0.5 \end{cases} \quad (10)$$

$$p = (1 - \frac{t}{t_{max}})^c \quad (11)$$

其中:  $TF$  是一个值为 1 或 -1 的随机数。

### 2.2 金枪鱼优化算法的改进策略

针对标准金枪鱼优化算法易早熟收敛、定位能力有限、收敛速度慢等问题。本文结合多种改进策略, 提出一种多策略融合改进的金枪鱼优化算法 (MSTSO), 具体过程如下。

#### 2.2.1 黄金正弦觅食机制和非线性惯性权重

黄金正弦算法 (Golden-SA, Golden Sine Algorithm)<sup>[15]</sup> 是近年来提出的一种新型元启发式优化算法, 其灵感来源于数学中的正弦函数。本文将黄金正弦算法作为局部算子引入至金枪鱼群的螺旋觅食阶段中, 协助其进行位置的更新, 从而获得更快的寻优速度和更强的局部搜索能力。同时 Golden-SA 算法中的黄金分割系数  $x_1$  和  $x_2$  平衡了算法的搜索和开发能力, 使得金枪鱼群的搜索范围进一步缩小, 从而可以更迅速地定位种群最优个体。具体的位置更新公式如下所示:

$$X_i^{t+1} = \alpha_1 \cdot (|\sin(r_1)| \cdot X_{rand}^t + r_2 \cdot \sin(r_1) \cdot \beta \cdot |x_1 \cdot X_{rand}^t - x_2 \cdot X_i^t|) + \alpha_2 \cdot X_{i-1}^t \quad (12)$$

$$X_i^{t+1} = \alpha_1 \cdot (|\sin(r_1)| \cdot X_{best}^t + r_2 \cdot \sin(r_1) \cdot \beta \cdot |x_1 \cdot X_{best}^t - x_2 \cdot X_i^t|) + \alpha_2 \cdot X_{i-1}^t \quad (13)$$

式中,  $r_1$  为  $[0, 2\pi]$  范围内的随机数;  $r_2$  为  $[0, \pi]$  范围内的随机数;  $x_1 = -\pi * (1 - \tau) + \pi * \tau, x_2 = -\pi * \tau + \pi * (1 - \tau)$ , 其中  $\tau = \frac{(\sqrt{5}-1)}{2}$ 。

标准 TSO 依靠式 (10) 来更新金枪鱼群抛物线觅食的位置, 但是在整个寻优过程中忽视了猎物对于金枪鱼群位置更新的吸引力也是具有多样性的。因此, 本文引入了惯性权重使最优解具有更强的吸引力, 从而提高算法的寻优能力。具体改进公式如下:

$$\omega(t) = \frac{2}{\pi} \arcsin(\frac{t}{t_{max}}) \quad (14)$$

$$X_i^{t+1} = \begin{cases} X_{best}^t + rand \cdot (X_{best}^t - X_i^t) + TF \cdot p^2 \cdot (1 - \omega)(X_{best}^t - X_i^t), rand < 0.5 \\ TF \cdot p^2 \cdot (1 - \omega)X_i^t, rand \geq 0.5 \end{cases} \quad (15)$$

金枪鱼群在以抛物线轨迹寻找猎物时需要较大的惯性权重, 即增加最优解对金枪鱼群的吸引力方便其被更快地找到, 从而增加算法的全局搜索能力。

#### 2.2.2 蜜獾随机搜索策略

蜜獾算法 (HBA, honey badger algorithm)<sup>[16]</sup> 主要模仿了蜜獾的觅食行为。蜜獾一方面会利用嗅觉接近猎物, 围绕猎物移动并最终选择合适的时机挖掘和捕捉猎物, 该觅食模式称为挖掘模式; 另一方面, 蜜獾还会在蜂巢向导鸟的指引下直接定位蜂巢, 此觅食模式称为蜂蜜模式。两种模式均采用随机扰动标志  $F$  来更广泛地对整个空间进行搜索。

根据 TSO 算法可知, 在金枪鱼螺旋觅食的中后期, 金枪鱼只会在较小的局部范围内搜寻食物, 而此特性会导致其忽略周围更优的猎物, 从而使整个寻优过程陷入局部最

优陷阱。因此本文引入了蜜獾算法中的随机扰动标志  $F$  来进行位置更新以跳出局部最优，改进后的位置更新方式如式 (16) 所示：

$$X_i^{t+1} = X_i^t + F \cdot r_3 \cdot \alpha_3 \cdot (X_{i_{best}}^t - X_i^t) \quad (16)$$

$$F = \begin{cases} 1 & r_4 \leq 0.5 \\ -1 & r_4 > 0.5 \end{cases} \quad (17)$$

$$\alpha_3 = C \times \exp\left(\frac{-t}{t_{max}}\right) \quad (18)$$

式 (16) 中， $F$  即为随机扰动标志，帮助金枪鱼群找到更优的猎物位置，其公式如式 (17) 所示，其中  $r_4$  为  $[0, 1]$  范围内的随机数； $r_3$  为  $[0, 1]$  范围内的随机数； $\alpha_3$  为密度因子，控制时变随机化以确保种群从勘探到开发的平稳过渡，公式如式 (18) 所示，其中  $C$  为大于等于 1 的常数。

MSTSO 算法流程图如图 2 所示。

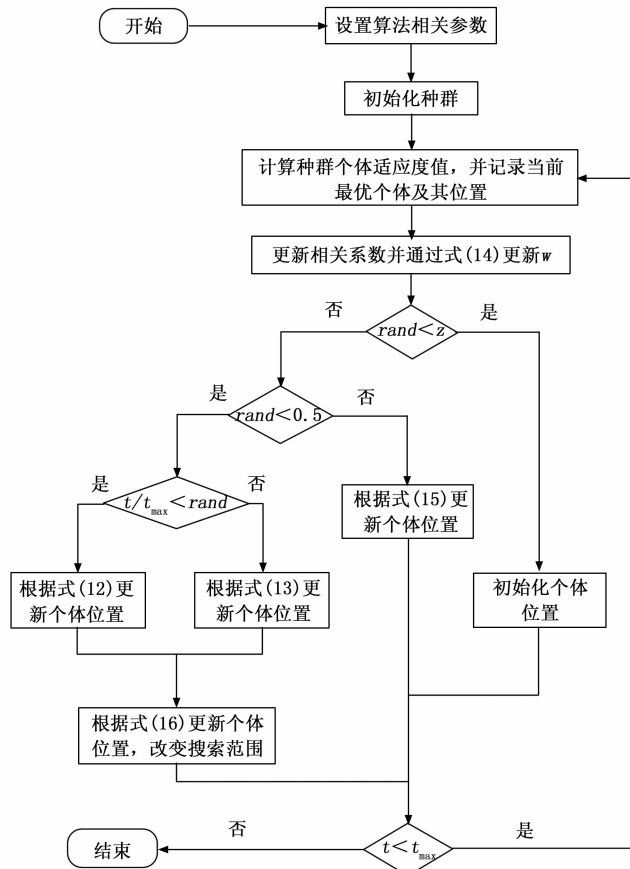


图 2 算法流程图

### 3 冷水机组能效预测模型

#### 3.1 BiLSTM 神经网络

LSTM 为 RNN 的一种变体，一定程度上解决了传统神经网络训练过程中出现的梯度消失问题<sup>[17]</sup>。LSTM 主要由输入门、遗忘门以及输出门这 3 种门控单元组成并通过特有的细胞状态将重要的信息传递下去。图 3 为 LSTM 内部结构图。

遗忘门用于决定信息的取舍，将前一个隐藏状态的信息和当前输入的信息一同传入遗忘门的控制层 Sigmoid 中并

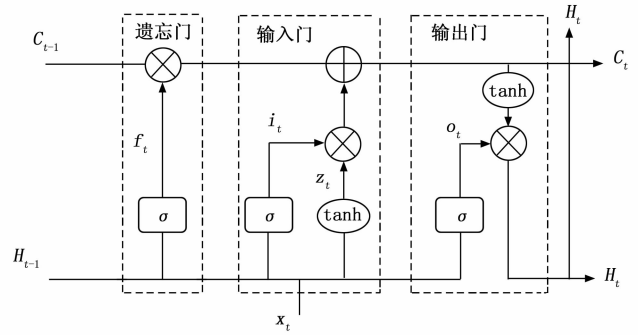


图 3 LSTM 结构图

进行信息的过滤，即式 (19)。

$$f_t = \sigma(W_f x_t + W_f H_{t-1} + b_f) \quad (19)$$

式中， $\sigma$  为 sigmoid 函数， $W$  和  $b$  分别为对应公式的权重和偏置项。

输入门用于更新细胞状态，sigmoid 层选择更新哪些信息，而 tanh 函数负责创造一个新的候选值向量，如式 (20) 和式 (21)。

$$i_t = \sigma(W_i x_t + W_i H_{t-1} + b_i) \quad (20)$$

$$z_t = \tanh(W_z x_t + W_z H_{t-1} + b_z) \quad (21)$$

式中， $\tanh$  为双曲正切函数。

LSTM 细胞状态的更新公式如式 (22)。

$$C_t = f_t \times C_{t-1} + i_t \times z_t \quad (22)$$

输出门用来确定下一个隐藏状态的值，其值由 tanh 的输出与 sigmoid 的输出相乘获得并传入下一个时间步长当中。此过程计算公式如下所示：

$$o_t = \sigma(W_o x_t + W_o H_{t-1} + b_o) \quad (23)$$

$$H_t = o_t \times \tanh(C_t) \quad (24)$$

LSTM 采用单向结构传递信息，因此仅能通过过去的信息去获得预测值，但在实际应用中当前的信息也和未来的信息高度相关。BiLSTM 由前向 LSTM 和后向 LSTM 两部分构成，既可以挖掘历史的信息也可以对未来的信息进行预测，从而大大提升了网络的预测精度并对输入的数据信息进行充分的学习。图 4 为 BiLSTM 结构图。

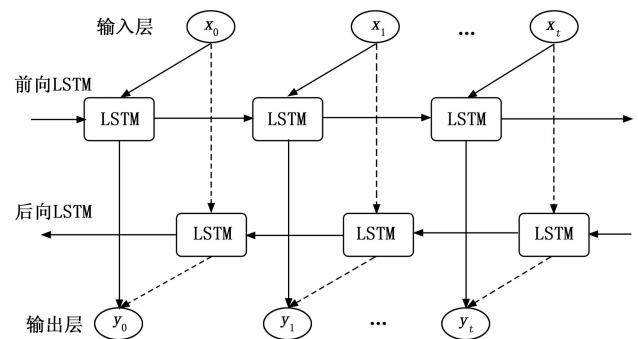


图 4 BiLSTM 结构图

#### 3.2 MSTSO 优化的 BiLSTM

本文将 MSTSO 算法与 BiLSTM 进行有机的结合，其既能维持 BiLSTM 本身优秀的训练性能和预测精度，又可

以自适应地调节网络的关键初始参数。MSTSO 优化的 BiLSTM 模型流程图如图 5 所示。

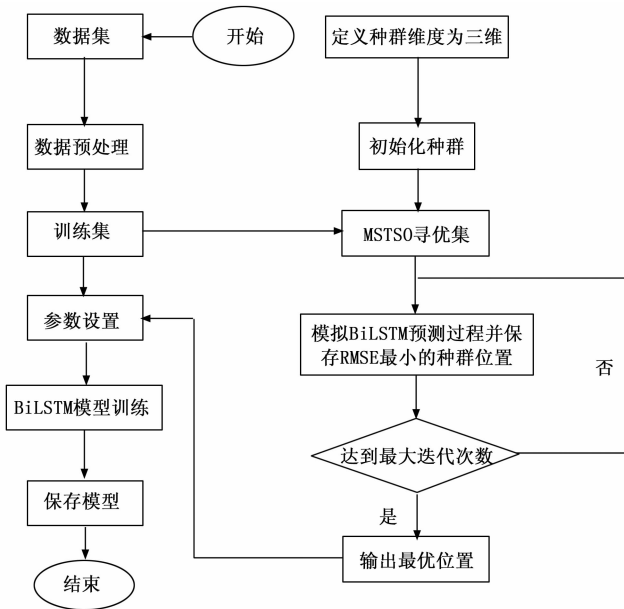


图 5 能效预测模型流程图

MSTSO-BiLSTM 的网络初始参数寻优过程如下:

- 1) 将网络训练的训练集作为 MSTSO 寻优集。
- 2) 初始化 MSTSO 算法并生成初始种群, 将算法维度设为三维, 分别是初始学习率、隐藏层节点数以及 L2 正则化系数。

3) 在每一轮迭代中利用 MSTSO 寻优集去模拟 BiLSTM 预测过程, 以均方根误差 (RMSE) 作为寻优目标函数并将预测误差最小的解进行保存。

4) 当 MSTSO 迭代结束, 输出种群的历史最优解并从中获取最佳初始学习率、最佳隐藏层节点数以及最佳 L2 正则化系数, 为后续 BiLSTM 模型的训练做准备。

## 4 冷水机组负荷分配模型

### 4.1 能耗优化目标函数

降低冷水机组运行时的能耗是 OCL 问题的解决目标。因此在不同工况下使得多台机组的能耗总和达到最小便是优化策略的最终目标。本文优化问题的目标函数为:

$$J = \min \sum_{i=1}^n P_{\sigma-i} = \sum_{i=1}^n \frac{PLR_{\sigma-i} CL_{r-i}}{COP_i} \quad (25)$$

在实际的工程应用中, 冷水机组的运行需要满足相应的约束条件, 因而本文所解决的问题为带约束的优化问题。约束条件如下所示:

$$0.3 \leq PLR_{\sigma-i} \leq 1 \quad (26)$$

$$CL_{rd} = \sum_{i=1}^n PLR_{\sigma-i} CL_{r-i} \quad (27)$$

式中,  $CL_{rd}$  为所研究对象在实际应用场景中所需要的冷量, kW。

为了处理不等式约束, 即式 (26), 当搜索结果不在限

制范围内时, 算法设计为选择边界值。而对于等式约束, 即式 (27), 使用惩罚函数。惩罚函数在求和不匹配时生效并嵌入目标函数中, 如式 (28) 所示。

$$J = (J) + PF * abs \left[ \sum_{i=1}^n (PLR_{\sigma-i} CL_{r-i}) - CL_{rd} \right] \quad (28)$$

式中,  $PF$  为惩罚因子。

### 4.2 基于 BiLSTM-MSTSO 的负荷分配

本文首先构建了基于 BiLSTM 的能效预测模型, 在此基础上继续采用 MSTSO 算法进行冷水机组的负荷优化与分配。负荷分配模型的具体步骤如下:

- 1) 获取系统运行所需要的冷负荷并确定优化参数的数值范围。
- 2) 采集运行参数, 其中冷冻水出水温度、冷却进水温度、冷却水出水温度以及冷却水流量已知, 冷水机组负荷率 (PLR) 为主要优化参数。
- 3) 训练并保存能耗预测模型并用其计算各台机组的 COP 值。
- 4) 初始化 MSTSO 算法相关参数, 结合能耗优化目标函数计算个体适应度值并进行多次迭代比较, 保存历史最优值及其个体位置。

5) 获取运行参数, 判断是否有机组存在喘振隐患, 若是则确定机组启停情况并返回步骤 1) 继续执行, 否则输出运行参数作为优化后的负荷数据。

基于 BiLSTM-MSTSO 的负荷分配模型的整体流程如图 6 所示。

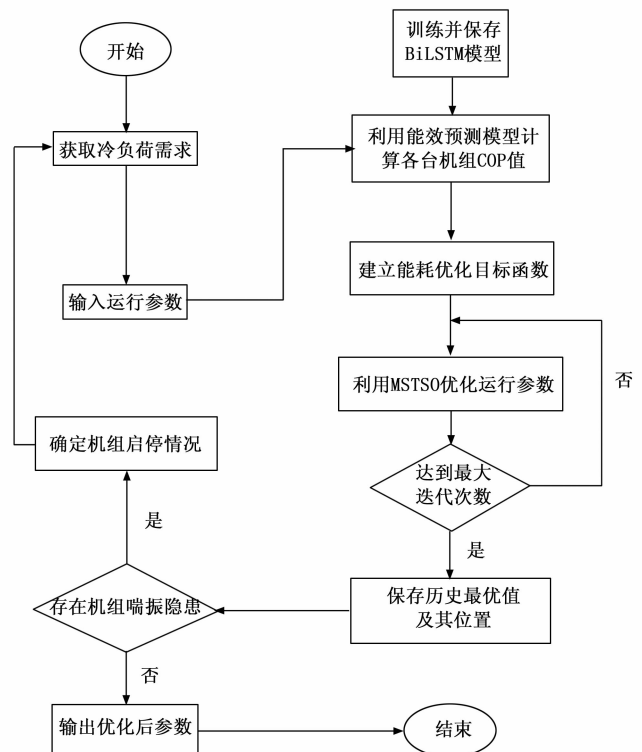


图 6 负荷分配模型流程图

### 5 实验结果与分析

本文数据来源于某卷烟厂车间的空调系统，共 4 800 组，按照 7: 3 的比例划分为训练集和测试集，其中包含冷冻水出水温度、冷却水进水温度、冷却水出水温度、冷却水流量、冷水机组负荷率与能效比 COP。

#### 5.1 优化算法性能验证

为了验证本文提出的 MSTSO 算法在求解最优问题上的鲁棒性和有效性，将 MSTSO 算法与粒子群优化算法 (PSO)<sup>[18]</sup>、蝴蝶优化算法 (BOA)<sup>[19]</sup>、鲸鱼优化算法 (WOA)<sup>[20]</sup> 以及标准 TSO 算法应用在 3 个典型的标准测试函数中进行 100 次独立实验以求解最优值，其中  $F_1-F_2$  为单峰函数， $F_3$  为多峰函数。各测试函数具体信息如表 2 所示，其最优值均为 0。为使对比实验规范化，将各算法种群大小  $NP$  设为 200，最大迭代次数  $t_{max}$  设为 1 000。主要参数如表 3 所示。

表 2 标准测试函数

测试函数	维度	搜索空间
$F_1(x) = \sum_{i=1}^N x_i^2$	30	$[-100,100]$
$F_2(x) = \max\{ x_i , 1 \leq i \leq N\}$	30	$[-100,100]$
$F_3(x) = \frac{1}{4\,000} \sum_{i=1}^N x_i^2 - \prod_{i=1}^N \cos(\frac{x_i}{\sqrt{i}}) + 1$	30	$[-600,600]$

表 3 算法参数设置

算法	主要参数
PSO	$W=0.9, c_1=2, c_2=2$
BOA	$p=0.8, e=0.1, a=0.01$
WOA	$b=0.1$
TSO	$a=0.7, z=0.05$ BH
MSTSO	$a=0.7, z=0.05, C=2$

在 100 次独立实验之后，将寻优结果的平均值 (mean)、最小值 (min)、标准差 (std) 作为性能评价指标，其结果如表 4 所示。同时，为更加直观地体现算法的性能，每种算法的适应度变化曲线如图 7 所示。为使迭代曲线展现地

更加清晰，对迭代图进行了等比例的缩放调整，实际的迭代次数为 500 次。

表 4 标准测试函数结果对比

函数	算法	mean	min	std
$F_1$	PSO	21.281 4	0.933 29	10.298 3
	BOA	1.86E-07	7.51E-08	4.19E-08
	WOA	1.11E-103	3.10E-114	1.08E-102
	TSO	1.22E-254	2.99E-289	0
	MSTSO	0	0	0
$F_2$	PSO	2.749 9	0.742	0.859 9
	BOA	6.22E-05	4.13E-05	8.43E-06
	WOA	1.70E+01	5.27E-14	2.47E+01
	TSO	8.46E-128	1.23E-146	4.01E-127
	MSTSO	0	0	0
$F_3$	PSO	1.173 8	1.030 4	0.090 9
	BOA	4.99E-08	1.42E-08	2.07E-08
	WOA	0.001 0	0	0.005 3
	TSO	0	0	0
	MSTSO	0	0	0

从表 4 中可以看出，针对函数  $F_1$  和  $F_2$ ，MSTSO 相较于其他 4 种算法拥有更高的寻优精度，各项评价指标均达到了测试函数的理论最优值，由此体现改进后的算法拥有更好的全局寻优能力，能更加精准地定位最优解的位置。而在  $F_3$  中，MSTSO 与 TSO 均拥有更好的算法性能，但通过图 7 不难发现，MSTSO 拥有更快的寻优速度，可以率先完成算法的收敛。

从图 7 中可以看出，MSTSO 拥有更优的收敛速度和寻优精度。在 3 个测试函数中，其他对比算法均陷入了局部最优陷阱，迭代曲线发生了停滞，由此可见 MSTSO 拥有更强的跳出局部最优的能力。

综上分析，跟其他 4 种算法相比，MSTSO 拥有明显的优势，具有更好的寻优精度、收敛速度、跳出局部最优的能力及鲁棒性。MSTSO 在原算法的基础上进行了有效的改进。

#### 5.2 预测模型性能对比

本文以机组 1 的数据为例进行模型性能测试并选用均方根误差 (RMSE)、平均相对误差 (MAPE) 作为网络模




图 7 标准测试函数适应度变化曲线

型的评价指标, 具体公式如下:

$$RMSE = \sqrt{\sum_{i=1}^N (X_{\text{model},i} - X_{\text{real},i})^2 / N} \quad (29)$$

$$MAPE = \frac{100\%}{N} \left( \sum_{i=1}^N |(X_{\text{model},i} - X_{\text{real},i}) / X_{\text{real},i}| \right) \quad (30)$$

式中,  $X_{\text{model},i}$  为第  $i$  组样本的模型预测值,  $X_{\text{real},i}$  为第  $i$  组样本的实际测量值,  $N$  为样本总数。RMSE 值和 MAPE 值越小, 则模型的预测效果就越精准。

同时为更直观地展现 MSTSO-BiLSTM 的网络性能, 将原始 BiLSTM、BiGRU<sup>[21]</sup> 以及时间卷积网络 TCN<sup>[22]</sup> 与其进行对比。其中, MSTSO-BiLSTM 的相关初始参数由优化算法寻优所得; BiLSTM 及 BiGRU 的初始学习率均为 0.05, 隐藏层节点数均为 10; TCN 的初始学习率与空间丢失因子均为 0.05。4 种网络均进行 500 轮次训练, 其测试集对比结果如表 5 所示。

表 5 测试集性能对比

模型	RMSE	MAPE
TCN	0.054 2	0.713%
BiGRU	0.057 0	0.726%
BiLSTM	0.062 1	0.751%
MSTSO-BiLSTM	0.041 4	0.644%

从表 5 中可以看出, 相较于其他 3 种网络, MSTSO-

BiLSTM 拥有最优的预测精度。对比原始 BiLSTM, MSTSO-BiLSTM 的初始参数由优化算法经过多次迭代比较所得, 更容易达到模型的最佳训练状态, 从而提升模型训练的整体稳定性。BiGRU 虽可以有效抑制梯度消失或爆炸, 但因缺少超参数的自动寻优而无法降低人为因素对网络的干扰。TCN 为一种卷积模型, 相较于 MSTSO-BiLSTM 有更复杂的网络结构, 但后续的负荷分配模型需要在迭代中多次调用能效预测模型, 其时间成本大幅增加从而降低了解决问题的时效性和灵活性。

### 5.3 负荷分配结果对比及分析

本文研究对象为四台冷水机组, 其中机组 1 和机组 2 的容量均为 2 150 RT, 机组 3 和机组 4 的容量均为 3210RT。同时本文在六种工况下进行冷水机组负荷分配, 分别为系统冷负荷 (CL) 需求的 90%、80%、70%、60%、50% 及 40%。为进行模型性能对比, 本文还采用鲸鱼算法 (WOA) 和哈里斯鹰算法 (HHO)<sup>[23]</sup> 搭建冷水机组负荷分配模型。为更具体地展现启停优化策略及冷水机组运行效率的提升, 表 6 为启停优化前的冷水机组负荷分配结果, 后续分析均以采用 MSTSO 算法的工况为例。

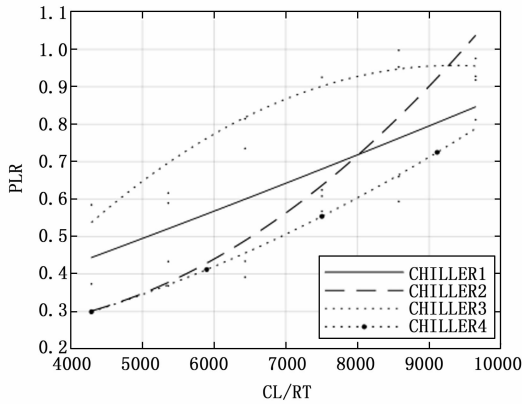
表 6 展示了在六种工况下 3 种算法的详细结果。从中不难看出, 采用 MSTSO 算法的负荷分配结果优于 WOA 以及 HHO。与 WOA 算法相比, MSTSO 算法的最优能耗分别减少了 1.97% (9 648 RT)、3.12% (8 576 RT)、2.10%

表 6 冷水机组负荷分配结果

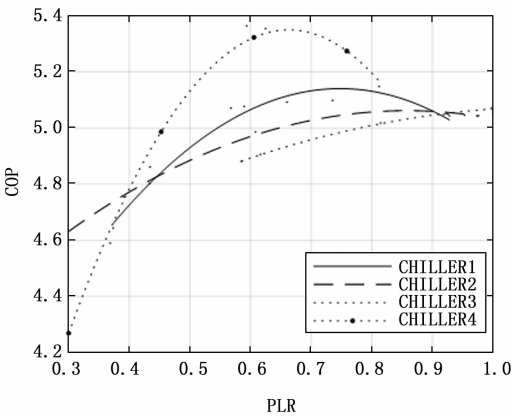
CL/RT	chiller <sub>i</sub>	PLR	WOA/COP	P/kW	PLR	HHO/COP	P/kW	PLR	MSTSO/COP	P/kW
9 648 (90%)	1	0.985 6	5.021	1 940.1	0.640 0	5.088	1 926.3	0.928 1	5.044	1 901.8
	2	0.894 9	5.053		0.861 4	5.056		0.975 8	5.044	
	3	0.746 1	4.995		1.000 0	5.071		0.918 4	5.048	
	4	0.999 9	4.889		1.000 0	4.889		0.812 0	5.148	
8 576 (80%)	1	0.688 8	5.096	1 725.4	0.4745	4.871	1 720.1	0.660 2	5.092	1 671.6
	2	0.332 0	4.681		0.770 8	5.060		0.952 9	5.046	
	3	0.988 0	5.068		0.874 0	5.035		0.997 5	5.070	
	4	1.000 0	4.889		0.963 6	4.941		0.593 8	5.364	
7 504 (70%)	1	0.474 0	4.870	1 497.1	0.364 4	4.626	1 496	0.567 7	5.071	1 465.7
	2	0.964 0	5.045		0.839 5	5.058		0.608 1	4.986	
	3	0.906 1	5.045		0.717 7	4.984		0.925 5	5.050	
	4	0.468 5	5.008		0.813 7	5.146		0.624 6	5.354	
6 432 (60%)	1	0.752 4	5.095	1 311.5	0.914 7	5.049	1 307	0.735 3	5.098	295.2
	2	0.300 0	4.641		0.367 6	4.725		0.391 7	4.754	
	3	0.998 9	5.071		0.714 3	4.994		0.814 7	5.018	
	4	0.300 0	4.325		0.403 5	4.733		0.434 2	4.861	
5 360 (50%)	1	0.719 1	5.100	1 122.0	0.417 8	4.741	1 118.3	0.589 5	5.077	1 104.6
	2	0.526 0	4.904		0.377 1	4.737		0.433 3	4.802	
	3	0.535 8	4.705		0.837 3	5.024		0.616 3	4.906	
	4	0.300 0	4.325		0.300 0	4.325		0.368 4	4.590	
4 288 (40%)	1	0.549 9	5.054	951.3	0.666 4	5.093	950.5	0.373 5	4.644	919.1
	2	0.548 6	4.928		0.311 2	4.655		0.300 0	4.641	
	3	0.300 0	3.772		0.381 0	4.039		0.584 8	4.881	
	4	0.300 0	4.325		0.300 0	4.325		0.300 0	4.325	

(7 504 RT)、1.24% (6 432 RT)、1.55% (5 360 RT)、3.38% (4 288 RT)。与 HHO 算法相比, MSTSO 算法的最优能耗分别减少了 1.27% (9 648 RT)、2.82% (8 576 RT)、2.03% (7 504 RT)、0.90% (6 432 RT)、1.23% (5 360 RT)、3.30% (4 288 RT)。

进一步研究表 6 中 MSTSO 算法的优化结果, 发现各机组的部分负荷率和本文冷负荷需求呈现一种正相关的联系性, 机组的 COP 值也会随着负荷率的变化而产生变化, 变化关系如图 8 所示。



(a)CL-PLR关系图



(b)PLR-COP关系图

图 8 机组数据关系

从表 6 中可知, 当  $CL=4\ 288\ RT$  时, 机组 2 和机组 4 的负荷率仅为 0.30, 因而容易发生机组喘振现象且此时两台机组的 COP 值偏低。因此在冷负荷需求较小的时候开启所有的机组会造成额外的能耗, 应选择合适的启停策略对冷水机组的负荷分配进行进一步优化。表 7 是当  $CL=4\ 288\ RT$  时利用 MSTSO 对机组进行启停优化后的结果。

表 7 机组运行数据

chiller	PLR	COP	P/kW
1	0.681 2	5.095	848.0
2	0	/	
3	0.879 6	5.054	
4	0	/	

由表 7 可知, 在  $CL=4\ 288\ RT$  时, MSTSO 将负荷需求分配到机组 1 和机组 3 上。此启停策略的系统总能耗为 848 kW, 且开启机组的 COP 值均在 5 以上。结合图 8 可知, 开启机组运行时的 COP 值正好在各自最佳 COP 值附近。跟四台机组全开的情况相比, 启停优化后的机组可较之前节能 7.74% 左右, 策略效果显著。

## 6 结束语

1) 在算法改进方面, 引入多策略金枪鱼算法。相较于标准 TSO, 其先融合黄金正弦算法来缩小种群的搜索空间, 提升寻优精度; 接着引入非线性惯性权重, 增强领导者的吸引力, 加快算法收敛速度; 最后采用蜜獾随机搜索策略对种群位置进行不断更新, 使算法跳出局部最优, 平衡了局部和全局的搜索能力。通过使用标准测试函数进行测试, 发现其收敛速度和精度均有一定的提升。

2) 在冷水机组能效预测方面, 使用 MSTSO 对原始 BiLSTM 进行优化, 通过不断地迭代寻优获得最佳的初始超参数, 使得预测模型的精度提升, 从而更准确地反映冷水机组相关参数之间的联系。

3) 在冷水机组负荷分配方面, 以能效预测模型为基础, 提出一种基于 MSTSO 算法的冷水机组负荷分配模型。通过 MSTSO 算法对冷水机组的负荷进行合理分配并对机组的启停策略进行调整, 最终降低整个系统的运行能耗并提升各台机组的运行效率。

### 参考文献:

- [1] WANG Z Y, LIU J, ZHANG Y X, et al. Practical issues in implementing machine-learning models for building energy efficiency: Moving beyond obstacles [J]. Renewable and Sustainable Energy Reviews, 2021, 143: 110929.
- [2] LEI L, CHEN W, WU B, et al. A building energy consumption prediction model based on rough set theory and deep learning algorithms [J]. Energy & Buildings, 2021, 240: 110886.
- [3] GARCIA SANZ CALCEDO J, DE SOUSA NEVES N, ALMEIDA FERNANDES J P. Measurement of embodied carbon and energy of HVAC facilities in healthcare centers [J]. Journal of Cleaner Production, 2021, 289: 125151.
- [4] SHI H S, CHEN Q. Building energy management decision-making in the real world: A comparative study of HVAC cooling strategies [J]. Journal of Building Engineering, 2020, 33: 101869.
- [5] SHAHNAZARI H, MHASKAR P, HOUSE J M, et al. Modeling and fault diagnosis design for HVAC systems using recurrent neural networks [J]. Computers & Chemical Engineering, 2019, 126: 189-203.
- [6] 魏 峥, 王碧玲. 基于机器学习的冷水机组能耗模型辨识方法研究 [J]. 建筑科学, 2018, 34 (6): 115-122.
- [7] 高 扬, 陈 坦, 胡海涛. 基于神经网络的建筑节能预测方法 [J]. 制冷与空调, 2017, 31 (1): 9-13.

(下转第 216 页)