



研究与开发

# 基于 DC-Bi-LSTM 网络集成算法的数据中心能效优化研究

欧阳述嘉<sup>1</sup>, 贾涛<sup>1</sup>, 张亚雄<sup>2</sup>, 陈学真<sup>2</sup>, 李云爽<sup>2</sup>

(1. 国家电网有限公司信息通信中心 (大数据中心), 北京 100761;

2. 北京中电飞华通信有限公司, 北京 100036)

**摘要:** 随着云计算与大数据技术的普及, 数据中心能耗问题日益凸显, 如何通过智能算法实现能效优化成为绿色计算领域的关键课题。传统机器学习模型难以有效捕捉数据中心能耗数据的时序依赖性与多维度耦合特征, 导致能效优化精度不足。为此, 提出一种基于空洞卷积优化的双向长短期记忆 (dilated convolution optimized bi-directional long short-term memory, DC-Bi-LSTM) 网络集成算法, 通过融合双向循环神经网络的时序特征双向捕捉能力与集成学习的误差修正机制, 构建高精度的能耗预测与能效优化模型。实验结果表明, 相较于目前最优的预测方法, 新算法在平均绝对误差 (mean absolute error, MAE) 上降低了 0.22, 在平均绝对百分比误差 (mean absolute percentage error, MAPE) 上降低了 0.43%, 在均方根误差 (root mean squared error, RMSE) 上降低了 0.23, DC-Bi-LSTM 网络集成算法能够有效克服预测中的数据噪声和不确定性干扰, 提高了数据中心能效预测的效果。

**关键词:** 数据中心; DC-Bi-LSTM; 能效预测

**中图分类号:** TN911.73; TP308

**文献标志码:** A

**doi:** 10.11959/j.issn.1000-0801.2025239

## Research on energy efficiency optimization of data centers based on DC-Bi-LSTM network integration algorithm

OUYANG Shujia<sup>1</sup>, JIA Tao<sup>1</sup>, ZHANG Yaxiong<sup>2</sup>, CHEN Xuezhen<sup>2</sup>, LI Yunshuang<sup>2</sup>

1. State Grid Corporation of China Information and Communication Center (Big Data Center), Beijing 100761, China

2. Beijing Zhongdian Feihua Communication Co., Ltd., Beijing 100036, China

**Abstract:** With the popularization of cloud computing and big data technology, the energy consumption problem of data centers has become increasingly prominent. How to achieve energy efficiency optimization through intelligent algorithms has become a key issue in the field of green computing. Traditional machine learning models are difficult to effectively capture the temporal dependencies and multidimensional coupling characteristics of energy consumption data in data centers, resulting in insufficient accuracy in energy efficiency optimization. To this end, an ensemble algorithm based on dilated convolution optimized bi-directional long short-term memory (DC-Bi-LSTM) network was proposed, which combined the bi-directional capture ability of recurrent neural networks with the error correction mechanism of ensemble learning to construct high-precision energy consumption prediction and energy efficiency op-



timization models. The experimental results show that compared to the current best prediction methods, the DC-Bi-LSTM network integrated algorithm reduces mean absolute error (MAE) by 0.22, mean absolute percentage error (MAPE) by 0.43%, and root mean squared error (RMSE) by 0.23. It can effectively overcome the interference of data noise and uncertainty in prediction and improve the effectiveness from data center energy efficiency prediction.

**Key words:** data center, DC-Bi-LSTM, energy efficiency predict

## 0 引言

在21世纪的信息时代,数据中心已成为全球数字经济的核心组成部分,承担着处理、存储和分发庞大数据的重任。随着互联网服务、云计算和物联网应用的快速增长,数据中心的规模和数量呈指数级增长。电能使用效率(power usage effectiveness, PUE)是数据中心总设备能耗与信息技术(information technology, IT)设备总能耗的比值,作为衡量数据中心能耗效率的核心指标,该值越小越好<sup>[1]</sup>。目前,我国数据中心PUE值普遍为1.5~2.0,距离国际先进水平(1.0~1.5)仍有较大差距。伴随“双碳”战略实施、能耗双控趋严,数据中心产业结构和能源结构升级(如数据中心PUE极致化、加快存量改造、提升绿电综合供给能力)、重点满足能耗强度要求成为发展关键,数据中心低碳转型成为未来长期刚需。未来,推广更加先进的电力、制冷等节能技术,加快推动数据中心嵌入绿色能源系统,借助绿电交易、直供等方式高效优化能源结构,呈现更大潜力空间<sup>[2]</sup>。

传统的数据中心能效评价以PUE值为主,虽然PUE简单、直观,但其仅关注总能耗与IT设备能耗的比值,忽略了能源再利用、碳排放等因素,难以全面反映数据中心的可持续性。数据中心的最终目标是为IT设备提供可靠、高效的工作环境,故应将IT设备的性能指标纳入评价体系<sup>[3]</sup>。文献[4]提出将数据中心空调效能(包括制冷能耗、送风能耗等)、IT设备效能(设备入口温度、设备温度分布)等指标纳入数据中心能效评价。为了更好地预测数据中心能效,文献[5]提出采用神经网络

模型优化数据中心能效的方法进行改进,增加了特征维数,提高了预测精度,但优化的数据仅限于数据中心制冷设备,未考虑IT设备的影响。文献[6]考虑了数据中心IT设备和空调设备的能耗特性与换热耦合关系,以及IT设备的时段间启停待机关系和爬坡约束,建立了基于多时段设备耦合的数据中心能效优化模型,但实验数据仅停留在仿真数据,并没有参考数据中心的实际数据。针对传统模型在处理高维非线性数据时预测精度不足的问题,文献[7]提出了一种基于Transformer的电动汽车充电站能耗预测方法,显著提升了模型在复杂时序数据中的特征提取与预测能力。文献[8]提出一种基于深度学习的数据中心负载能耗预测模型,该模型基于历史负载数据,并结合数据中心的环境参数,利用长短期记忆(long short-term memory, LSTM)神经网络进行预测。随着数据中心的不断扩大,能耗数据也越来越复杂,传统的单一深度学习算法已无法支撑预测效果,因此,组合算法成为研究的热点。基于空洞卷积优化的双向长短期记忆(dilated convolution optimized bi-directional long short-term memory, DC-Bi-LSTM)网络组合算法的独特优势在于,深度卷积的局部特征高效提取与双向LSTM的全局时序依赖建模的完美互补,而其必要性则源于单一模型在高维时序数据处理中“局部细节丢失”“长依赖建模困难”“计算效率低下”等固有局限。这种组合架构不仅提升了模型的特征表达能力,更在实际工程中实现了性能与效率的平衡,成为处理复杂时序数据的主流方案之一。

本文聚焦数据中心的能效问题,首先针对数

据中心结构建立了仿真模型，根据流体动力学的基本定律和  $k-\epsilon$  湍流模型对数据中心的温度场、流速场等参数进行了热力学仿真，对比了实际参数和仿真参数，为了更好地对未来数据中心能耗进行优化和预测，提出了 DC-Bi-LSTM 集成算法，构建数据中心能效预测模型，对数据中心相关能效参数进行优化，旨在达到节能减排、高效利用的目的。

## 1 数据中心建模及仿真分析

### 1.1 数据中心概况

本文以国家电网某数据中心为研究对象，其主要应用于需要大规模数据处理、存储和传输的组织和机构，为企业提供数据存储服务、数据处理服务、数据传输服务、主机托管服务、系统维护与管理服务，以及增值服务。数据中心配置有服务器与存储设备、网络设备、电力供应系统、冷却与空调系统、安全监控系统、布线系统，以及机架和机柜。数据中心研究对象面积为  $405 \text{ m}^2$ ，其中空调占  $70 \text{ m}^2$ ，IT 设备占  $335 \text{ m}^2$ 。数据中心高  $4 \text{ m}$ 、宽  $9 \text{ m}$ 、长  $15 \text{ m}$ 。该数据中心共有 4 列机柜，可布置 28 个机柜，数据中心研究对象机房概况如图 1 所示。




图1 数据中心研究对象机房概况

### 1.2 数据中心热仿真流程设计

数据中心内传热流动过程遵循质量守恒、动量守恒与能量守恒三大基本守恒定律。在数值传热学领域，这些守恒定律的偏微分方程统称控制

方程。控制方程的核心思想是，利用有限数量的离散点来表示连续的物理量场（如温度场、速度场和压力场），并据此构建这些离散点上变量之间的代数方程（也称离散方程）。通过解算这些代数方程，能够近似得到相关物理量的值。数值模拟流程如图 2 所示。

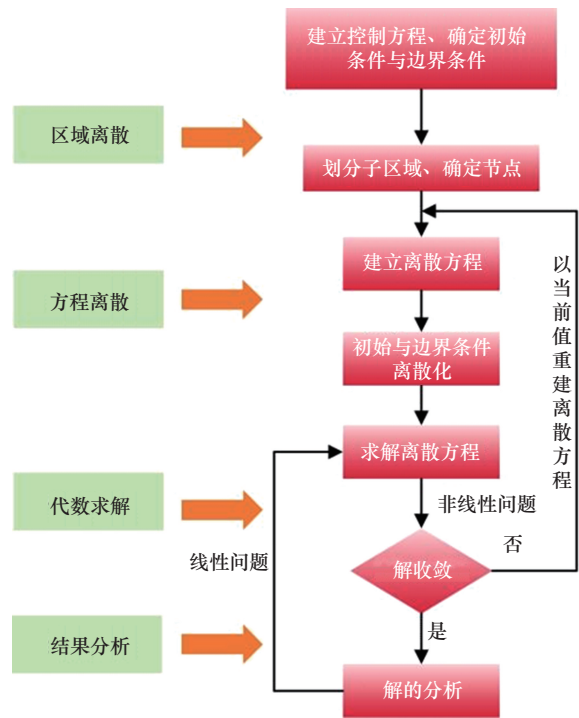


图2 数值模拟流程

数据中心环境遵循流体动力学的基本定律，尤其是当流体处于湍流状态时，必须纳入湍流输运方程，包括湍动能  $k$  方程和湍流耗散率  $\epsilon$  方程。因此，在数据中心的空气流动与换热过程中，所涉及的控制方程包括质量守恒方程、动量守恒方程、能量守恒方程、 $k$  方程以及  $\epsilon$  方程<sup>[9]</sup>。

假设数据中心的墙壁及门窗气密性良好，则满足质量守恒定律，如下所示：

$$\frac{\partial \rho}{\partial t} + \frac{\partial(\rho u)}{\partial x} + \frac{\partial(\rho v)}{\partial y} + \frac{\partial(\rho w)}{\partial z} = 0 \quad (1)$$

其中， $\mathbf{u}$  为速度矢量， $u$ 、 $v$ 、 $w$  为速度矢量分别在  $x$ 、 $y$ 、 $z$  方向上的速度分量，单位为  $\text{m/s}$ ； $\rho$  为密度，单位为  $\text{kg/m}^3$ ； $t$  为时间，单位为  $\text{s}$ 。



数据中心气体的流动遵循动量守恒定律, 在  $x$ 、 $y$ 、 $z$  这 3 个方向的动量守恒方程如下所示:

$$\frac{\partial(\rho u)}{\partial t} + \text{div}(\rho uu) = -\frac{\partial p}{\partial x} + \frac{\partial \tau_{xx}}{\partial x} + \frac{\partial \tau_{yx}}{\partial y} + \frac{\partial \tau_{zx}}{\partial z} + F_x \quad (2)$$

$$\frac{\partial(\rho v)}{\partial t} + \text{div}(\rho vu) = -\frac{\partial p}{\partial y} + \frac{\partial \tau_{xy}}{\partial x} + \frac{\partial \tau_{yy}}{\partial y} + \frac{\partial \tau_{zy}}{\partial z} + F_y \quad (3)$$

$$\frac{\partial(\rho w)}{\partial t} + \text{div}(\rho wu) = -\frac{\partial p}{\partial z} + \frac{\partial \tau_{xz}}{\partial x} + \frac{\partial \tau_{yz}}{\partial y} + \frac{\partial \tau_{zz}}{\partial z} + F_z \quad (4)$$

其中,  $p$  为流体微元体上的压力, 单位为 Pa;  $F_n$  为微元体上的力, 单位为 N;  $\tau_{mn}$  为因分子黏性作用而产生的作用在微元体上的黏性应力, 单位为  $\text{N/m}^2$ ;  $\text{div}$  为散度。

热交换的流动系统也必须满足能量守恒定律, 如下所示:

$$\frac{\partial(\rho T)}{\partial t} + \text{div}(\rho u T) = \text{div}\left(\frac{\kappa}{c_p} \text{grad} T\right) + s_T \quad (5)$$

其中,  $c_p$  为比热容, 单位为  $\text{J}/(\text{kg}\cdot\text{K})$ ;  $T$  为温度, 单位为 K;  $\kappa$  为流体的传热系数, 单位为  $\text{W}/(\text{m}^2\cdot\text{K})$ ;  $s_T$  为黏性耗散项, 表示流体内部热源, 单位为  $\text{m}^2/\text{s}$ 。

在数据中心的气流流动分析中, 假设符合 Boussinesq 假设, 归类为大空间空气流动。因此, 适宜选用适用于高雷诺数的湍流模型——标准  $k$ - $\epsilon$  模型<sup>[10]</sup>。此模型涵盖了湍流脉动动能  $k$  方程和流动耗散率  $\epsilon$  方程。利用这两个方程, 可以表达湍流流动速度, 其表达式依赖于湍流脉动动能  $k$  和流动耗散率  $\epsilon$ <sup>[11]</sup>。本文选用高雷诺数的  $k$ - $\epsilon$  湍流模型进行计算, 如下所示:

$$k = \frac{1}{2}(\overline{u^2} + \overline{v^2} + \overline{w^2}) \quad (6)$$

$$\epsilon = \frac{\mu}{\rho} \left( \frac{\partial \overline{u_1'}}{\partial x_k} \right) \left( \frac{\partial \overline{u_1'}}{\partial x_k} \right) \quad (7)$$


其中,  $k$  为单位质量湍流脉动动能,  $\epsilon$  为流动耗散率。流动黏度  $\mu_t$  可以用  $k$  和  $\epsilon$  表示, 即:

$$\mu_t = C_\mu \rho k^2 / \epsilon \quad (8)$$


其中,  $C_\mu$  为经验常数。

### 1.3 仿真结果与分析

本文选取一个特定时刻的机房参数来进行热环境模拟。数据中心流体仿真结果如图 3 所示, 机房内冷通道的温度在  $19\sim 23^\circ\text{C}$ , 而热通道的温度则在  $24\sim 30^\circ\text{C}$  波动。这些结果与实际测量的机房热环境数据相符。



(a) 流线速度



(b) 流线温度

图3 数据中心流体仿真结果

为了验证模拟的精确性, 本文选取了一些具有代表性的测点进行比较。数据中心温度场与速度场仿真如图 4 所示, 图 4 展示了距地面 1 m、1.5 m 和 2 m 处的温度场和速度场数据。仿真数据与实测数据对比见表 1。

由表 1 可知, 在  $h=2\text{ m}$  处出风温度的实测值高于模拟值, 这是因为在数据中心机房的冷通道中, 机房内的机柜等设备对气流组织有一定影响, 在进行热流模拟时, 对这些设备进行了简化

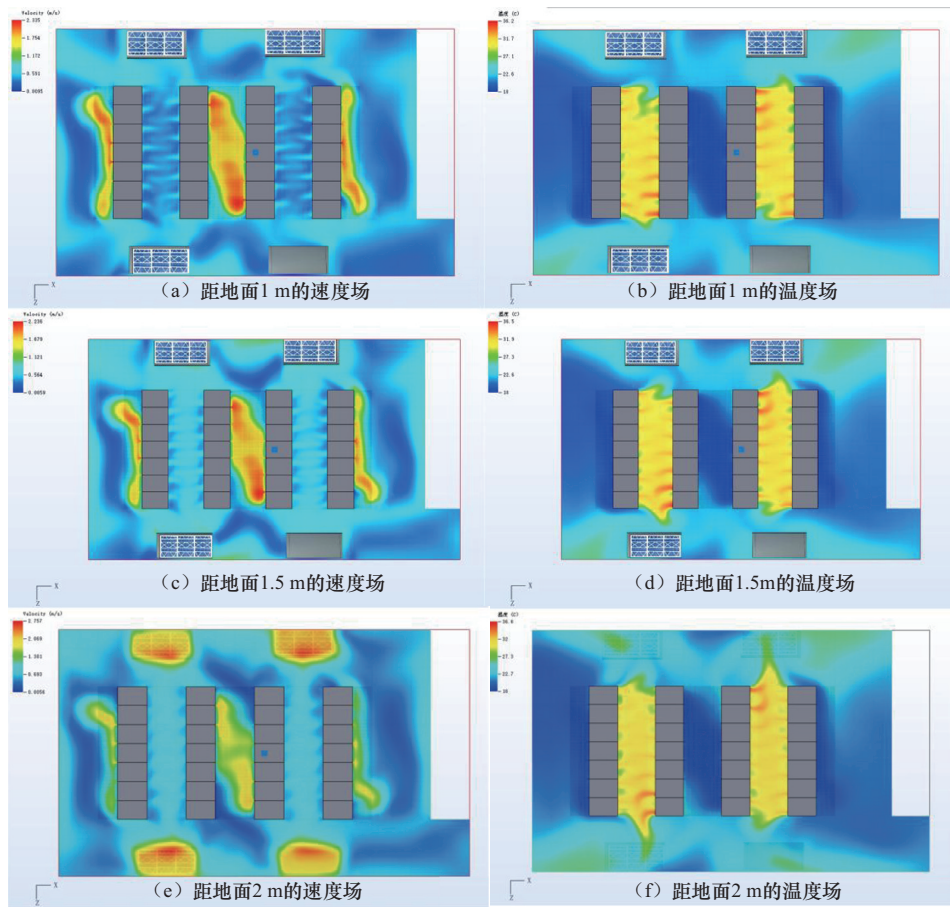


图4 数据中心温度场与速度场仿真

表1 仿真数据与实测数据对比

测点	1 m 处出风温度/°C	1.5 m 处出风温度/°C	2 m 处出风温度/°C	A 柜温度/°C	D 柜温度/°C	G 柜温度/°C
模拟值 1-1	19.2	19.3	19.3	22.3	23.5	19.6
实测值 1-1	19.1	19.1	19.5	23.1	23.2	20.1
模拟值 1-2	19.3	19.4	19.7	22.5	24.1	19.9
实测值 1-2	19.3	19.5	19.8	23.2	24.3	20.1
模拟值 1-3	19.5	19.6	20.0	23.1	24.6	23.2
实测值 1-3	19.4	19.7	19.9	23.8	25.1	23.4
模拟值 1-4	20.1	20.2	20.3	24.9	23.5	23.5
实测值 1-4	20.0	20.1	20.5	25.1	23.8	23.7

处理，减少了对送风冷气流的干扰，使得模拟时的冷气流可以直接到达机柜的顶端，这就导致在机柜处，实际风速比模拟值小，进而使实测温度略高于模拟值。此外，由于此时机柜的进风温度尚未与机柜内设备发生换热，因此，进风温度的实测值与模拟值没有较大差异。在机柜温度的测量中，实际数据与模拟数据之间的误差率为

8.97%，整体的平均误差率为3.74%。总体而言，超过85.4%的模拟结果与实测结果之间的误差均保持在5%以内，而整体误差始终未超过10%。这表明热环境分布的模拟与实际情况具有较高的一致性。因此，从工程应用的角度来看，该模型被证明是有效的，并能准确地反映数据中心内宏观区域的气体热分布情况。准确的仿真数据为后



续数据中心能效的预测提供了海量的数据基础。

### 2 DC-Bi-LSTM网络集成算法模型

数据中心能效预测本质上是一个多输入单输出的预测问题，本文假设 $D_t$ 表示时间 $t$ 的数据中心能效，其中 $\{t|t=1,2,3,\dots,T\}$ ，则其数学模型可以表示为：

$$D_t=f(d_t^1,d_t^2,d_t^3,\dots,d_t^n)+\epsilon_t \quad (9)$$

其中， $f$ 表示预测模型包括多种参数， $d_t^1,d_t^2,d_t^3,\dots,d_t^n$ 表示影响数据中心PUE的各类因素， $\epsilon_t$ 为波动项。数据中心能效预测的研究目标就可以表示为：通过收集影响数据中心能效的各类因素数据，对模型进行参数估计，使其能够准确预测数据中心的能效 $D_{t+1}$ 。

#### 2.1 DC-Bi-LSTM预测模型

基于DC-Bi-LSTM网络集成算法的数据中心

能耗预测流程如图5所示。本文以数据中心能效和与影响数据中心能效的各类因素（如机柜温度、数据中心流速场、数据中心温度场等）作为预测方法的输入<sup>[12]</sup>。首先，对数据进行预测处理，减少历史数据中噪声的干扰，并进行数据归一化；其次，采用提出的混合集成学习策略，利用多组DC-Bi-LSTM模块进行训练，再通过集成剪枝的顺序训练组合生成最终的预测模型；最后，利用训练好的模型预测数据中心能效在未来的变化情况，从而优化数据中心的组织架构，实现节能降耗的目标。

#### 2.2 DC-Bi-LSTM数据中心能效预测网络

为了更准确地预测数据中心能效的变化情况，本文以现有的Bi-LSTM网络为基础，引入具有较大感受野的空洞卷积进行改进，设计了DC-Bi-LSTM网络。DC-Bi-LSTM网络结构如图6所示。

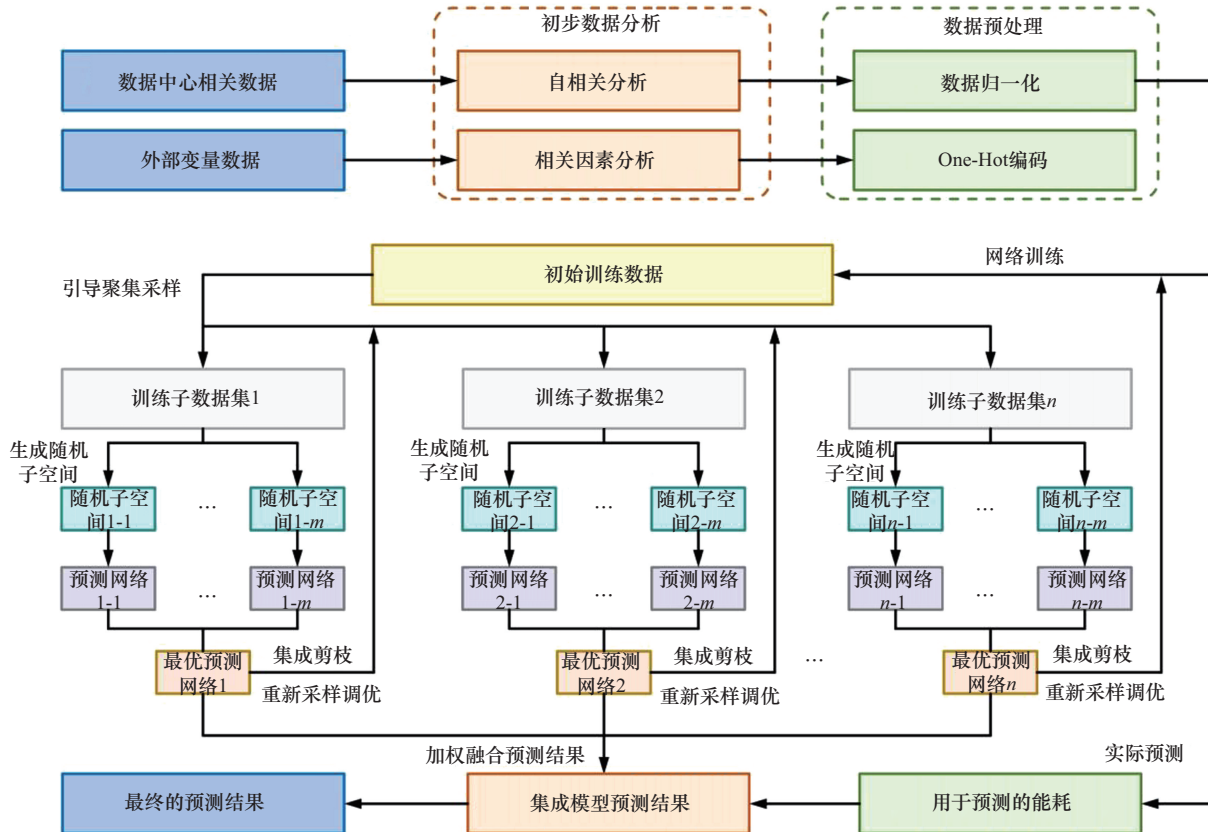


图5 基于DC-Bi-LSTM网络集成算法的数据中心能耗预测流程

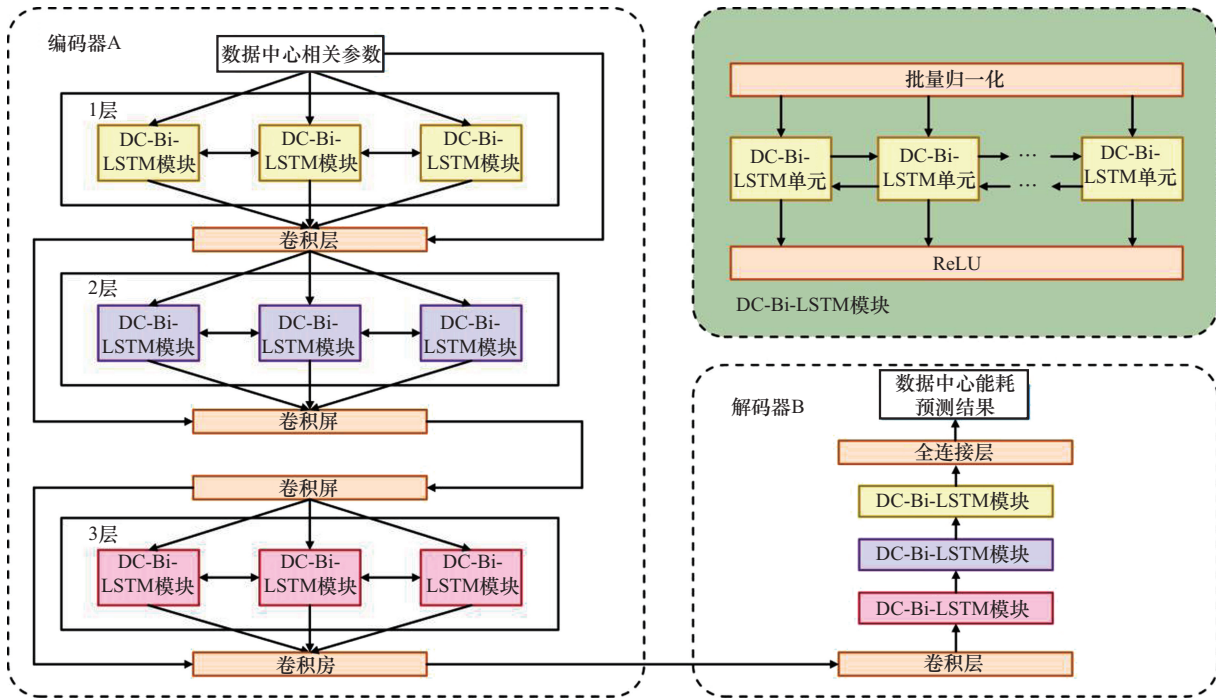


图6 DC-Bi-LSTM网络结构

从全局的角度来看，DC-Bi-LSTM网络基于编码器-解码器架构，其基本组成为DC-Bi-LSTM模块，每层都包括相同扩张率的空洞卷积模块，但每层的扩张率不同。将网络中的各层紧密连接，以最大限度提高各层之间的信息传输，使网络能够更好地学习历史数据中的潜在联系。其中的特征编码器A包含 $N$ 个DC-Bi-LSTM模块，并在每个相邻的DC-Bi-LSTM模块间引入了残差连接操作，除将本层输出的特征向量进行融合外，还融合了前一层输出的特征向量。根据实际实验中观察到的效果，本文将模型编码器中DC-Bi-LSTM模块的数量设置为6，即 $N=6$ 。解码器B则由3个DC-Bi-LSTM层和1个全连接层组成<sup>[13]</sup>。

在现有的数据中心能效预测模型中，虽然利用LSTM网络充分学习了数据中心能耗的隐藏特征，并采用传统的卷积操作从空间角度进行了特征提取，且取得了一定的效果，但是传统卷积的感受野较小，LSTM网络仅能关注正向的时间序列特征，导致无法很好地学习隐藏特征，进而无法有效提高预测的准确度。

为了克服这一问题，本文以双向LSTM网络为基础引入了空洞卷积，并将模型中的空洞卷积扩张率设置为不同的参数，利用其感受野较大的优点，从空间维度出发，充分学习多尺度隐藏特征，挖掘不同数据之间存在的依赖关系<sup>[14]</sup>。本文设计的DC-Bi-LSTM模块由批量归一化层，DC-Bi-LSTM层和ReLU激活函数层组成，其中批量归一化层用于减轻模型的过拟合现象，DC-Bi-LSTM层用于学习特征中隐藏的空间依赖关系。普通卷积和空洞卷积的感受野对比如图7所示。

从图7可以看出，与传统的卷积操作相比，空洞卷积通过在卷积核之间添加固定间隔的零值（即空洞）来增加卷积核的有效感受野。假设输入的特征图为 $F_{in}$ ，卷积核为 $K$ ，则其具体计算公式为：

$$F_{out}[i,j] = \sum_{m=0}^{M-1} \sum_{n=1}^{N-1} F_{in}[i+r \cdot m, j+r \cdot n] \times K[m,n] \tag{10}$$

其中， $F_{out}$ 表示输出的特征图， $F_{out}[i,j]$ 表示输出特征向量中 $i,j$ 位置的特征值， $r$ 表示空洞率， $M$

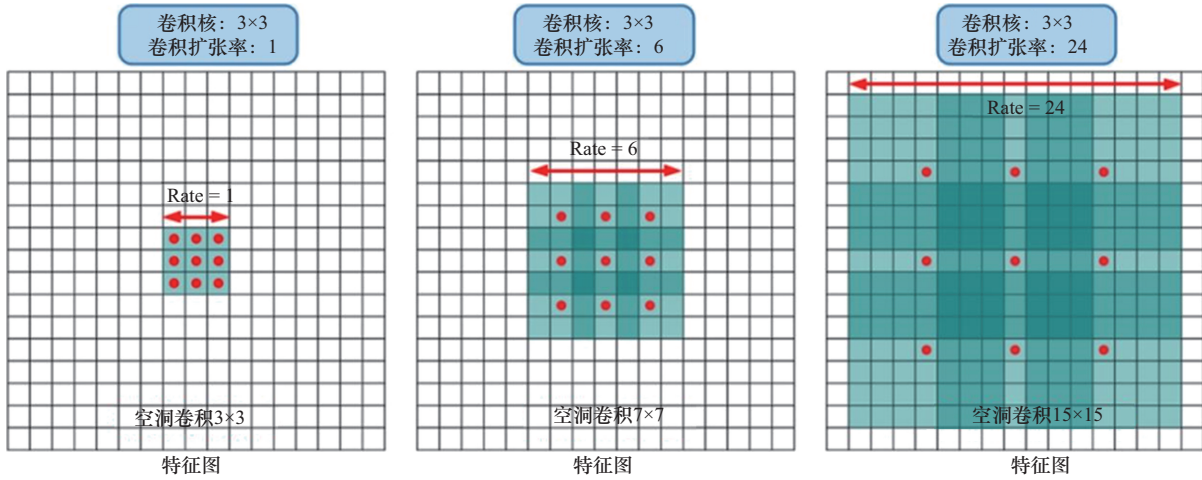


图7 普通卷积和空洞卷积的感受野对比

和  $N$  分别为卷积核的高度和宽度。空洞率用于确定特征图中的采样间隔，直接影响空洞卷积的感受野大小。总体来说，与传统的卷积相比，空洞卷积能够在保持参数量较少的情况下，学习到更多的上下文信息，挖掘数据中心特征在空间上的依赖关系，提高预测准确度。为了能够从正向和反向两个角度（即过去和未来）来综合数据中心能效中的隐藏关联，本文使用双向 LSTM 网络从时间角度挖掘特征<sup>[15]</sup>。相较于传统的单向 LSTM 网络，双向 LSTM 网络相当于包括了 2 个独立的 LSTM 网络，分别用于正向传播和反向传播，具体的学习过程如下所示：

$$\begin{aligned} \vec{h}_t &= \text{LSTM}(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t &= \text{LSTM}(x_t, \overleftarrow{h}_{t+1}) \\ h_t &= f(\vec{h}_t, \overleftarrow{h}_t) \end{aligned} \quad (11)$$

其中， $\vec{h}_t$  和  $\overleftarrow{h}_t$  分别表示正向 LSTM 和反向 LSTM 在时间  $t$  的隐藏状态， $f()$  表示特征融合操作。双向 LSTM 网络能够充分挖掘其中隐藏的长距离依赖关系，提高预测的准确度。

### 2.3 混集成学习策略

在训练阶段，本文首先采用引导聚集方法和随机子空间方法扩充训练数据，并从这些数据中随机选取部分数据进行训练。这样做的目的是增

强基础网络训练过程的多样性，同时还可以降低计算成本、提高训练速度。具体来说，通过迭代  $N_B$  次引导聚集方法，获得  $N_B$  组的训练子数据集，保证每个子数据集的数据量与原始训练数据集相同，再从每个训练子数据集中随机选择  $N_R$  组  $d$  维数据作为最终的训练数据集，这样就可生成  $N_B \times N_R$  组的训练数据，分别用于独立地训练预测网络  $\text{ProNet}_{b \times r}$ ，其中  $b \in N_B$ ， $r \in N_R$ 。最后，根据前一轮训练后得到的预测误差，利用提升（Boosting）方法引导训练数据重新采样，以提高模型的训练效果。第  $n$  次训练的子数据可以表示为：

$$D_{b \times r}^n = \left\{ (x_i, y_i) \mid (x_i, y_i) \in D, \frac{1}{n} \sum_{j=1}^n \tau_j (\rho_j^{(x_i)} - \bar{\rho}_j) > \beta \right\} \quad (12)$$

$$\tau_j = \ln \frac{1 - \bar{\rho}_j}{\bar{\rho}_j} \quad (13)$$

$$\bar{\rho}_j = \frac{1}{T} \sum_{i=1}^T \rho_j^{(x_i)} \quad (14)$$

$$\rho_j^{(x_i)} = \frac{|\text{ProNet}_{b \times r}(x_i) - y_i|}{y_i} \quad (15)$$

其中， $D$  表示整个训练数据集， $D_{b \times r}^n$  表示第  $n$  次训练中通过的  $b \times r$  训练子集， $\tau_j$  表示预测网络  $\text{ProNet}_{b \times r}$  的聚合系数，由其预测效果的百分比误差  $\bar{\rho}_j$  计算得到。当数据  $(x_i, y_i)$  预测得到的误差

$\rho_j^{(x_i)}$  经过计算后超过阈值  $\beta$  时, 就会将其添加到训练数据集中, 继续监督网络的优化。

经过多轮训练, 利用不同的训练子数据能够生成多个相互独立的预测模型, 经过集成剪枝后, 每一轮训练都可以保留一个误差最小的最优预测网络。

$$\text{ProNet}_n^* = \underset{(x,y) \in V}{\operatorname{argmin}}_{\text{ProNet}_{b \times r}} \sum L(y, \text{ProNet}_{b \times r}(x)) \quad (16)$$

其中,  $\text{ProNet}_n^*$  表示本轮选出的误差最小的最优预测网络,  $V$  表示验证数据集。在获取所有的最优预测网络后, 将它们的预测输出进行加权组合, 其中权重为各预测网络对应的聚合系数。利用这些权重系数, 即可预测出数据中心最终的能效值。

### 2.4 损失函数

在数据中心能效预测网络的训练过程中, 使用 Huber 损失函数进行引导, 其计算式如下所示:

$$L = \begin{cases} \frac{1}{2}(y - \hat{y})^2, & |y - \hat{y}| \leq \delta \\ \delta|y - \hat{y}| - \frac{1}{2}\delta^2, & |y - \hat{y}| > \delta \end{cases} \quad (17)$$

其中,  $\delta$  表示损失的调节参数, 当预测误差小于等于  $\delta$  时采用平方误差计算损失值, 当预测误差大于  $\delta$  时采用线性误差计算损失值,  $y$  和  $\hat{y}$  分别表

示真实的数据中心能效和预测的数据中心能效。Huber 损失函数在整体上的形状更为平滑, 能够更好地适应具有异常值的数据, 并提高模型的鲁棒性和稳定性。

## 3 实验结果与分析

### 3.1 实验平台

在需求预测网络的训练过程中, 本文采用了 PyTorch 框架进行编程实现和训练, 利用随机梯度下降 (stochastic gradient descent, SGD) 优化器进行网络的优化, 学习率设置为  $1 \times 10^{-4}$ , 全部的实验均在配置为 Intel (R) i7-9700 CPU 和 NVIDIA GeForce 2080Ti 显卡的工作站上进行。为了能够准确全面地评价各个预测方法的表现, 本文选择了平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE) 以及均方根误差 (root mean squared error, RMSE) 作为评价指标。数据中心能效影响因素包括 IT 设备功耗、IT 设备漏电功耗、空调设备冷负荷、空调的性能系数、IT 设备数量、空调设备数量和运行时间。DC-Bi-LSTM 预测模型步骤及评价指标如图 8 所示。

### 3.2 实验结果

为了验证提出的 DC-Bi-LSTM 网络集成算法的数据中心能效预测网络的有效性, 本文采用了

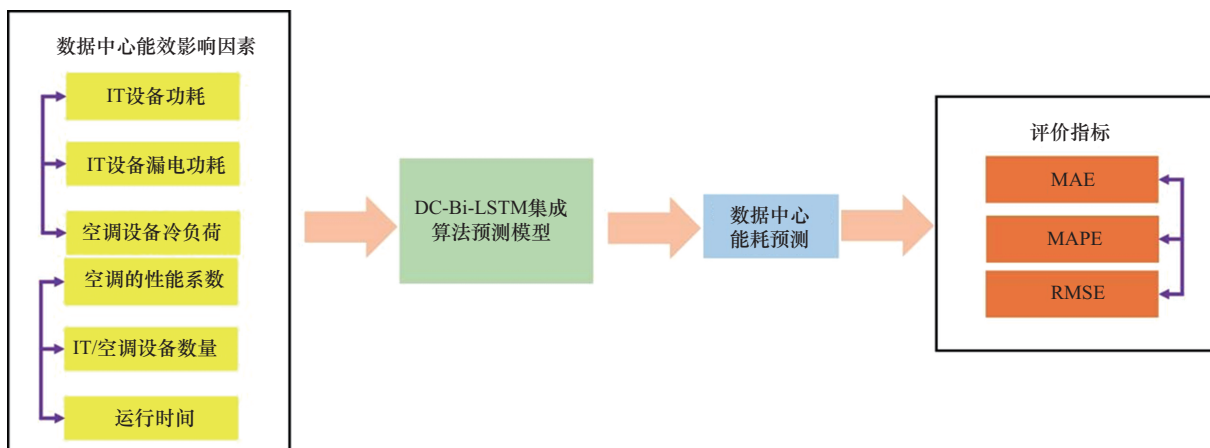


图8 DC-Bi-LSTM 预测模型步骤及评价指标



仿真数据+实测数据和实测数据两种不同的方法进行实验对比。为了排除其他干扰因素，在实验过程中，所有的预测方法均采用相同的训练策略和训练数据。其中，实验组采用70%的仿真数据作为训练数据，30%的实测数据作为测试数据，对照组全部由实测数据组成，其中70%为训练数据，30%为测试数据。不同方法对数据中心能效预测的结果对比见表2。

表2 不同方法对数据中心能效预测的结果对比

方法	MAE	MAPE	RMSE	预测误差
LSTM <sup>[7]</sup>	4.62	4.84%	4.57	9.32%
CNN-LSTM <sup>[7]</sup>	4.48	4.68%	4.31	7.54%
Bi-LSTM <sup>[8]</sup>	4.28	4.49%	4.25	5.41%
A-LSTM <sup>[9]</sup>	4.15	4.36%	4.02	3.29%
DRCNN <sup>[12]</sup>	3.87	4.29%	3.96	2.54%
DC-Bi-LSTM (本文网络)	3.65	3.86%	3.73	1.03%

从表2可知，本文提出的预测网络取得了最优的预测效果，即MAE为3.65、MAPE为3.86%、RMSE为3.73。相较于目前最优的预测方法(DRCNN)，DC-Bi-LSTM网络在MAE上降低了0.22，在MAPE上降低了0.0043，在RMSE上降低了0.23。这表明，本文设计的网络能够有效抑制短期预测中的数据噪声和不确定性干扰，从而提升数据中心预测的准确性。

为了更好地验证本文的仿真模型，本文设计了对比实验。实验组与对照组结果对比见表3。本文分别采集数据中心3月、6月、9月、12月的实测数据进行对比。实验结果表明，采用70%仿真数据+30%实测数据的实验组预测结果要明显优于采用100%实测数据的对照组预测结果，这说明在进行数据中心能效预测和改造过程中，可以先建立仿真模型，对数据中心的能效进行预测，这样的操作大幅提高了建设效率，节约了时间和经济成本。

表3 实验组与对照组结果对比

组别	MAE	MAPE	RMSE
实验组(3月)(70%仿真数据+30%实测数据)	4.27	4.47%	4.52
对照组(3月)(100%实测数据)	4.58	4.92%	4.79
实验组(6月)(70%仿真数据+30%实测数据)	3.17	3.25%	3.34
对照组(6月)(100%实测数据)	3.48	3.52%	3.61
实验组(9月)(70%仿真数据+30%实测数据)	2.93	2.95%	2.12
对照组(9月)(100%实测数据)	3.21	3.43%	2.73
实验组(12月)(70%仿真数据+30%实测数据)	3.01	3.11%	3.57
对照组(12月)(100%实测数据)	3.51	3.62%	3.84

## 4 结束语

本文提出的DC-Bi-LSTM网络集成算法在数据中心能效优化中展现出显著优势。实验结果表明，该算法通过Bi-LSTM网络与集成学习的结合，有效解决了传统模型对能耗数据时序特征捕捉不充分、多维度参数耦合关系处理不足的问题。在能耗预测环节，DC-Bi-LSTM集成模型较单一LSTM模型平均预测误差降低0.0829，较Bi-LSTM模型降低0.0438，验证了双向时序特征提取与集成策略对预测精度的提升作用。DC-Bi-LSTM集成算法为数据中心能效优化提供了兼具预测精度与工程实用性的解决方案，其技术路径对融合时序分析与智能决策的绿色计算研究具有参考意义。未来可进一步结合强化学习实现动态优化策略迭代，或引入边缘计算架构提升实时响应能力，推动数据中心能效管理向智能化、自适应方向发展。

## 参考文献:

- [1] 周峰,王芮敏,马国远,等.我国数据中心碳中和路径情景分析[J].制冷学报,2025,46(1):79-85.  
ZHOU F, WANG R M, MA G Y, et al. Scenario analysis of data centers in China under carbon neutrality target[J]. Journal of Refrigeration, 2025, 46(1): 79-85.
- [2] 陈心拓,周黎旸,张程宾,等.绿色高效数据中心散热冷却

- 技术研究现状及发展趋势[J]. 中国工程科学, 2022, 24(4): 94-104.
- CHEN X T, ZHOU L Y, ZHANG C B, et al. Research status and future development of cooling technologies for green and energy-efficient data centers[J]. Strategic Study of CAE, 2022, 24(4): 94-104.
- [3] 王博, 郭焱华, 邵双全, 等. 数据中心冷却系统相关能效评价指标综述[J]. 制冷学报, 2023, 44(2): 18-27.
- WANG B, GUO Y H, SHAO S Q, et al. Review of energy efficiency evaluation indexes related to data center cooling systems[J]. Journal of Refrigeration, 2023, 44(2): 18-27.
- [4] 魏东, 贾宇辰, 韩少然. 数据中心制冷系统强化学习控制[J]. 计算机工程与科学, 2025, 47(3): 422-433.
- WEI D, JIA Y C, HAN S R. Reinforcement learning control for data center refrigeration systems[J]. Computer Engineering & Science, 2025, 47(3): 422-433.
- [5] 李庆华, 冉泳屹, 刘启晨, 等. 数据中心冷热电联产系统的前摄式智能节能优化算法[J]. 智能系统学报, 2025, 20(1): 139-149.
- LI Q H, RAN Y Y, LIU Q C, et al. Proactive intelligent energy-saving optimization algorithm for data center CCHP system[J]. CAAI Transactions on Intelligent Systems, 2025, 20(1): 139-149.
- [6] 张宇, 李敏霞, 李君, 等. 面向数据中心液冷装置余热回收的卡诺电池储能系统可行性分析[J]. 储能科学与技术, 2024, 13(11): 3921-3929.
- ZHANG Y, LI M X, LI J, et al. Feasibility analysis of a Carnot battery energy storage system for waste heat recovery of liquid cooling units in data centers[J]. Energy Storage Science and Technology, 2024, 13(11): 3921-3929.
- [7] 袁溪, 张邵欣, 张超, 等. 基于 Transformer 的电动汽车充电站能耗预测研究[J]. 计算机技术与发展, 2025, 35(2): 213-220.
- YUAN X, ZHANG S X, ZHANG C, et al. Research on electric vehicle charging station energy consumption prediction based on Transformer[J]. Computer Technology and Development, 2025, 35(2): 213-220.
- [8] 刘芊, 周泉, 叶晓江. 基于深度学习的数据中心负载能耗预测模型研究[J]. 节能, 2024, 43(11): 98-100.
- LIU Q, ZHOU Q, YE X J. Research on data center load energy consumption forecasting models based on deep learning[J]. Energy Conservation, 2024, 43(11): 98-100.
- [9] 张婉婷, 郑晓耘, 王鹏飞, 等. 联合冷却系统的分布式绿色数据中心能量管理[J]. 东华大学学报(自然科学版), 2024, 50(3): 163-171.
- ZHANG W T, ZHENG X Y, WANG P F, et al. Distributed green data center energy management with combined cooling system[J]. Journal of Donghua University (Natural Science Edition), 2024, 50(3): 163-171.
- [10] 王辉东, 高晋坤, 黄佳斌, 等. 考虑数据中心负载灵活性的电力系统运行可靠性评估方法[J]. 电力系统保护与控制, 2023, 51(21): 96-105.
- WANG H D, GAO J K, HUANG J B, et al. Power system operational reliability evaluation method considering data center load flexibility[J]. Power System Protection and Control, 2023, 51(21): 96-105.
- [11] 王丽莉, 赵飞龙. 基于风电升压站的低 PUE 数据中心实现[J]. 电子测量技术, 2023, 46(18): 16-22.
- WANG L L, ZHAO F L. Implementation of low PUE data center based on offshore substation[J]. Electronic Measurement Technology, 2023, 46(18): 16-22.
- [12] 高胜强, 张琳, 王海鹏, 等. 计及 CCM 和改进 GRA 的 PSO-BiLSTM 光伏出力预测模型[J]. 电源技术, 2025, 49(4): 869-882.
- GAO S Q, ZHANG L, WANG H P, et al. PSO-BiLSTM PV output prediction model with CCM and improved GRA[J]. Chinese Journal of Power Sources, 2025, 49(4): 869-882.
- [13] 胡平生, 吴泉军. 基于变分模态分解和 BiLSTM-ATT 的锂电池健康状态估计模型[J]. 科学技术与工程, 2025, 25(11): 4598-4604.
- HU P S, WU Q J. Estimation model for state of health of lithium-ion battery based on VMD and BiLSTM-ATT[J]. Science Technology and Engineering, 2025, 25(11): 4598-4604.
- [14] 程光, 李沛霖. 基于 MSE 改进 BiLSTM 网络算法的工业互联网异常流量时空融合检测[J]. 吉林大学学报(工学版), 2025, 55(4): 1406-1411.
- CHENG G, LI P L. Spatio temporal fusion detection of abnormal traffic in industrial Internet based on MSE improved BiLSTM network algorithm[J]. Journal of Jilin University (Engineering and Technology Edition), 2025, 55(4): 1406-1411.
- [15] 高芷蓉, 杨杉, 喻希, 等. 基于 CNN-BiLSTM-Attention 的电力系统虚假数据注入攻击检测[J]. 智慧电力, 2025, 53(4): 103-111.
- GAO Z R, YANG S, YU X, et al. False data injection attack detection in power systems based on CNN-BiLSTM-Attention[J]. Smart Power, 2025, 53(4): 103-111.

## [作者简介]



欧阳述嘉 (1968-), 男, 国家电网有限公司信息通信中心(大数据中心)分公司高级工程师, 主要研究方向为大数据、数据中心、人工智能技术。



**贾涛**（1988-），男，国家电网有限公司信息通信中心（大数据中心）高级工程师，主要研究方向为数据中心基础设施运维管理。



**陈学真**（1993-），女，北京中电飞华通信有限公司工程师、数据中心智能运维工程师，主要研究方向为数据中心基础设施监控、管理、维护、优化、故障处理等。



**张亚雄**（1991-），男，北京中电飞华通信有限公司工程师，主要研究方向为数据中心电算协同技术、数据中心人工智能节能技术。



**李云爽**（1989-），女，北京中电飞华通信有限公司工程师、数据中心能效运维工程师，主要研究方向为数据中心能效统计、分析、节能优化和实施等。