

超短期热负荷预测在发电机组厂级供热调度的应用

齐结红¹, 钱虹^{2,3}, 吴文军¹

(1. 上海电力大学电气工程学院, 上海 200090; 2. 上海电力大学自动化学院, 上海 200090;
3. 上海市电站自动化技术重点实验室, 上海 200090)

摘要: 对于火力发电厂的综合能源应用, 存在供热蒸汽调度控制和管道延迟导致的供热蒸汽不能及时满足供热用户需求的问题。根据所延时的时间长度提出采用对供热用户需求的预测值取代实时供热需求值作为供热调度的约束条件, 基于 Informer 建立一个热负荷多步时序预测模型。构建的 Informer 模型采用的概率稀疏自注意力机制能够有效获取热负荷时序数据中的信息, 并建立热负荷与相关气象因素之间的非线性关系, 进而提高热负荷预测精确度。通过实际现场数据验证表明, 建立的基于 Informer 的热负荷多步时序预测模型能够与未来一段时间内的热负荷有很强的拟合度, 并满足实际调度控制延迟对热负荷的需求。

关键词: 套索回归; Informer; 热负荷流量预测; 供热调度

Application of ultra-short-term heat load forecasting in power plant level heat supply dispatching

QI Jiehong¹, QIAN Hong^{2,3}, WU Wenjun¹

(1. School of Electric Power Engineering, Shanghai University of Electric Power, Shanghai 200090, China;
2. School of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;
3. Shanghai Key Laboratory of Power Station Automation Technology, Shanghai 200090, China)

Abstract: For comprehensive energy application by thermal power plants, the heating steam caused by the heating steam dispatching control and pipeline delay does not meet, in timely fashion, the needs of heating users. From the length of time delay, it is proposed to replace the real-time heating demand with the predicted value of heating user demand as the constraint condition of heating dispatch. Based on Informer, a multi-step time series prediction model of heat load is established. The prob-sparse self-attention mechanism adopted in the Informer model can effectively obtain the information in the heat load time series data, and establish the nonlinear relationship between heat load and related meteorological factors, thus improving the accuracy of heat load prediction. The verification of actual field data shows that the multi-step time series prediction model of heat load based on Informer established in this paper can have a strong fit with the heat load in a future period of time, and meet the demand of actual scheduling control delay for heat load.

This work is supported by the National Natural Science Foundation of Shanghai (No. 19ZR1420700).

Key words: LASSO regression; Informer; heat load flow prediction; heat supply dispatching

0 引言

电厂在面对多元供能的市场竞争下对发电机组进行抽汽供热改造, 在满足供电的同时实现对用户的供热。为了提高电厂供热的经济性需要实现热负荷经济调度, 以热负荷的流量需求建立调度决策,

基金项目: 上海市自然科学基金项目资助(19ZR1420700); 上海市2019年度“科技创新行动计划”高新技术领域项目资助(195111037)

热负荷的流量需求可以来自于热负荷流量的超短期预测。因此, 对超短期热负荷流量进行预测有利于热负荷准确的厂级调度。由于供热抽汽侧到用户侧存在一定长度的供热管道, 如果根据当前热负荷需求值进行调度控制, 会产生一定的滞后效果, 且滞后效果与供热管道长度存在一定的关系。因此, 需要提前预测热负荷的流量需求并进行提前调度, 进而消除滞后效果带来的不利影响, 且预测时间长度与供热管道存在一定的关系。

国内外很多学者对热负荷预测进行了一定的研

究, 其研究方法随着机器学习的发展由传统预测方法^[1]转变为人工智能预测方法^[2-5]。热负荷传统预测方法原理相对简单, 但在遇到非线性问题时无法进行处理, 会导致在预测时产生较大的误差^[6]。人工智能方法有人工神经网络算法^[7-10]、支持向量回归算法^[11-15]等。这类方法能够挖掘变量与变量之间的非线性关系, 在预测性能方面优于传统预测方法, 已成为热负荷预测领域的研究热点, 国内外学者对这类方法进行了一定的研究。卷积神经网络(convolutional neural network, CNN)^[16-17]挖掘数据特征能力强, 但是对于输入数据的顺序不敏感, 在预测中难以学习时序数据之间的关系。长短期记忆神经网络(long short-term memory, LSTM)^[18-21]通过在隐含层中添加 3 个门机制, 进而能有效地挖掘时间序列中蕴藏的时序关系, 但在输入序列过长时会出现重要数据信息丢失的情况。对 Transformer^[22]进行有效的改进得到 Informer^[23]。Transformer 最初是运用于机器翻译任务, 其对输入的序列信息进行处理时采用了自注意力机制(self-attention mechanism), 自注意力机制能够着重注意具有强关联的局部信息, 并能够有效避免信息的递归传递。Informer 专门设计用来处理时序预测问题, 对 Transformer 中原有的自注意力机制实现了概率稀疏化, 降低了运算复杂性, 并有效增强了时间序列预测的准确性。

本文提出将 Informer 运用于热负荷时序预测问题, 将过去一段热负荷数据和相关气象数据输入 Informer 模型, 实现对未来一段热负荷的多步预测。Informer 模型对输入数据的每个顺序区域都进行了编号以保留数据间重要的位置顺序信息。Informer 预测模型获得热负荷序列的长期依赖信息, 并对热负荷影响因素之间的非线性关系进行建模, 进而提

高热负荷预测精确度。将采用 Informer 模型预测出的热负荷进行调度, 满足实际调度控制延迟对热负荷的需要。

1 基于管道延迟下负荷预测时间长度的确认

由于蒸汽经供热管道传输至用户端时会存在延迟现象, 供热延迟会导致供热不能及时满足热负荷需求, 用户体验感差。因此可以通过对热负荷进行提前预测, 当前调度时采用下一时刻的热负荷值, 用于消除延迟。为了使预测热负荷消除传输过程中延迟的影响, 要使预测周期与延迟时间保持一致。假设供热管道延迟时间为 τ , 则预测周期和调度周期也为 τ 。

某电厂经过供热抽汽改造后可以同时向用户供电和供热, 其工作流程如图 1 所示。图 1 为供热抽汽改造机组工作流程, 机组锅炉的燃料量是根据自动发电控制(automatic generation control, AGC)指令确定, 将燃料输送至锅炉充分燃烧产生大量热量, 给水在锅炉中被加热成过热蒸汽, 然后被输送至汽轮机进行工作。一些蒸汽将从几个汽轮机抽汽点被抽入回热系统, 以加热给水, 从而提高机组的经济性。汽轮机高压缸(HP)排放点的蒸汽一部分进入锅炉的再热系统, 另一部分输送至供热集箱用来给用户供热。锅炉再热系统的蒸汽一部分进入中压缸(IP)内工作, 另一部分蒸汽输送至供热集箱用来给用户供热。部分中压排汽在低压缸(LP)中工作后进入冷凝器进行冷凝热交换, 然后进入回热系统。图 1 中 K1 表示冷再供热抽汽阀门, 从此阀门抽出蒸汽已经在高压缸做功结束; K2 表示热再供热抽汽阀门, 从此阀门抽出蒸汽是经过锅炉再热的蒸汽。

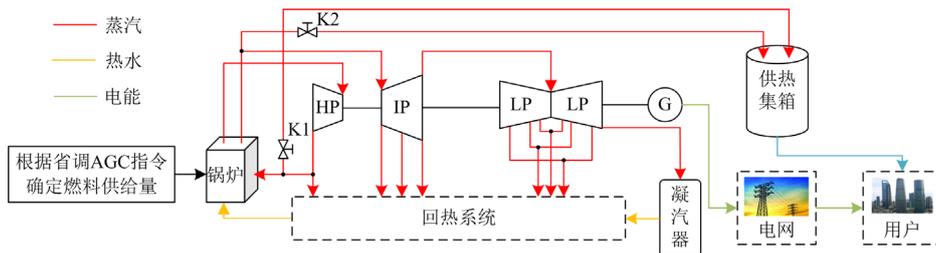


图 1 供热抽汽改造机组工作流程

Fig. 1 Work flow of the unit after heat supply and steam extraction transformation

一般在进行厂级热负荷调度时没有考虑供热延迟的影响, 即供热平衡约束方程为

$$\begin{cases} D_{\text{lengchou}}(t)(h_1 - h_2) + D_{\text{rechou}}(t)(h_2 - h_3) = Q(t) \\ Q(t) = D(t)h_3 \end{cases} \quad (1)$$

式中: $D_{\text{lengchou}}(t)$ 表示在 t 时段机组热再供热抽汽流量, t/h; $D_{\text{rechou}}(t)$ 表示机组在 t 时段冷再供热抽汽流量, t/h; h_1 表示机组冷再供热抽汽流量焓值, kJ/kg; h_2 表示机组热再供热抽汽流量焓值, kJ/kg;

h_2 表示凝汽器补水焓值, kJ/kg; $Q(t)$ 表示在 t 时段用户供热管道热负荷, GJ/h; $D(t)$ 表示热负荷所需流量值, t/h; h_3 表示热负荷流量焓值, kJ/kg。

本文考虑供热延迟的影响进行超短期热负荷流量预测, 预测时间间隔与供热延迟时间保持一致, 在进行厂级热负荷调度时供热平衡约束方程改为

$$\begin{cases} D_{\text{lengchou}}(t)(h_1 - h_2) + D_{\text{rechou}}(t)(h_2 - h_3) = Q(t + \tau) \\ Q(t + \tau) = D(t + \tau)h_3 \end{cases} \quad (2)$$

在超短期热负荷流量预测的基础上根据式(2)采用改进粒子群算法对机组的冷再供热和热再供热进行经济分配, 本文以单台机组为例研究其供热延迟问题, 具体厂级热负荷调度参考文献[24]。

2 热负荷预测模型

为了提高热负荷流量预测的精度, 本文采用套索(least absolute shrinkage and selection operator, LASSO)回归模型分析气象因素与热负荷流量之间的影响关系, 然后将气象因素和历史热负荷流量数据输入 Informer 预测模型对热负荷进行预测。

2.1 热负荷影响因素分析

气象因素是影响热负荷流量的众多影响因素中最为显著且直接的一个因素, 因此本文主要分析气象因素对热负荷流量的影响。气象因素主要包括干球温度、相对湿度、风速、单位面积太阳辐射量和降雨量等, 这些因素的变化规律比较难掌握, 但这些因素均在不同程度上影响热负荷的大小。

LASSO 回归模型适用于线性情况和非线性情况, 在建立在广义线性模型时, 对于连续或离散的因变量均能够处理。该方法主要步骤如下所述。

1) 确定 LASSO 回归的目标函数

$$J(\beta) = \sum_{i=1}^n (y_i - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda \sum_{j=1}^p |\beta_j| = \text{ESS}(\beta) + \lambda l_1(\beta) \quad (3)$$

式中: n 表示数据的样本量; p 表示热负荷流量影响因素的个数; y_i 表示热负荷流量 y 中第 i 个值; x_{ij} 表示第 i 个影响因素对应的第 j 个变量; β_j 表示每个热负荷流量影响因素的回归系数; $\text{ESS}(\beta)$ 为误差平方和; $\lambda l_1(\beta)$ 代表惩罚项; λ 表示惩罚系数。

2) 基于电厂历史数据集, 使用交叉验证法确定 λ 值。

3) 使用坐标轴下降法和次梯度法分别对 $\text{ESS}(\beta)$ 与 $\lambda l_1(\beta)$ 求 β_j 的偏导数与次导数。

4) 将 $\text{ESS}(\beta)$ 与 $\lambda l_1(\beta)$ 的偏导数相结合并且令

其为 0 来求解最终的 LASSO 回归系数, 该系数值依赖于 λ 值。

根据 10 重交叉验证所求得的 λ 值为 0.000 104 7, 最大迭代次数为 10 000, LASSO 回归模型各输入变量对应系数如图 2 所示。从图 2 中可以看到, 各输入参数对应的系数有正有负。干球温度、太阳辐射和相对湿度的系数小于 0, 表示这 3 个变量与热负荷呈负相关; 室外风速的系数大于 0, 表示这个变量与热负荷呈正相关。模型的输入变量加入干球温度、相对湿度、室外风速和太阳辐射量, 能提高预测精度和减少预测成本。

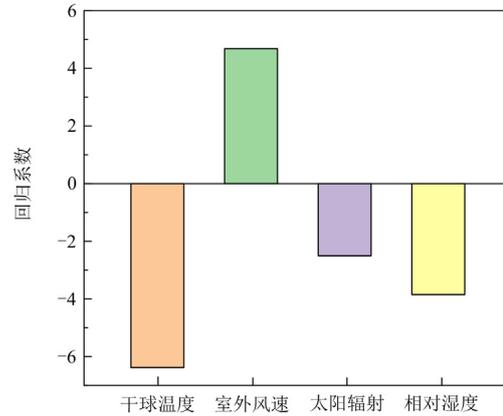


图 2 LASSO 回归模型各输入变量对应系数

Fig. 2 Corresponding coefficients of each input variable in LASSO regression model

2.2 Informer 模型

Informer 预测问题定义如下。

在预设的变量数目下, 对这些变量进行滚动预测。设在时间 t 输入有 $\mathcal{X}' = \{\mathbf{x}'_1, \dots, \mathbf{x}'_{L_x} \mid \mathbf{x}'_i \in \mathbb{R}^{d_x}\}$, 其中 L_x 是输入序列长度, d_x 是输入序列维度, 本文 d_x 取 5, 包含热负荷数据、太阳辐射量、干球温度、相对湿度和室外风速; 输出是与输入的多维变量对应的预测序列 $\mathcal{Y}' = \{\mathbf{y}'_1, \dots, \mathbf{y}'_{L_y} \mid \mathbf{y}'_i \in \mathbb{R}^{d_y}\}$, L_y 是输出序列长度, d_y 是输出序列维度。

Informer 模型采用编码解码结构。输入 \mathcal{X}' 至编码器中得到隐藏状态输出 \mathcal{H}' , 之后将 $\mathcal{H}' = \{h'_1, \dots, h'_{L_h}\}$ 输入解码器进行解码得到最终的输出 \mathcal{Y}' 。推理涉及一个名为“动态解码”的分步过程, 其中解码器从先前的状态 h 计算新的隐藏状态 h'_{k+1} 和第 k 步骤的其他必要输出, 然后预测第 $k+1$ 序列 y'_{k+1} 。

2.2.1 Informer 模型的输入

Informer 预测模型的输入为多维时间序列数据 $\mathcal{X}' = \{\mathbf{x}'_1, \dots, \mathbf{x}'_{L_x}\}$, 由于时序数据是整体输入到

Informer 模型, 这导致了时序数据失去了在时间上的位置信息。为了消除这一影响, Informer 模型在数据输入之前对时序数据进行位置编码, 具体公式如式(4)和式(5)所示。

$$PE_{(pos,2j)} = \sin \frac{P_{os}}{(2L_x)^{2j/d_{model}}} \quad (4)$$

$$PE_{(pos,2j+1)} = \cos \frac{P_{os}}{(2L_x)^{2j/d_{model}}} \quad (5)$$

式中: p_{os} 代表时序数据的位置; $j=1,2,\dots,d_{model}/2$ 代表维度。通过式(4)和式(5)得到的一组位置编码将会嵌入到时序数据之中。Informer 模型除了会对输入数据嵌入位置顺序信息外, 也会对时序数据的时间信息进行嵌入, 例如将时序数据的月份、年份与时刻信息进行编码, 时序数据通过位置信息嵌入以及时间信息嵌入后, 输入到 Informer 模型的编码器与解码器之中。

2.2.2 稀疏自注意力机制(Prob-sparse self-attention mechanism)

传统自注意力机制是通过计算 Query 与 Key 之间的相似度来分配权重系数, Query 与 Key 的特征矩阵 \mathbf{Q} 与 \mathbf{V} 之间是通过缩放点积来得到注意力矩阵, 如式(6)所示。

$$Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax} \left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}} \right) \mathbf{V} \quad (6)$$

式中: $\mathbf{Q} \in R^{L_Q \times d}$, $\mathbf{K} \in R^{L_K \times d}$, $\mathbf{V} \in R^{L_V \times d}$ 为输入特征变量线性变换得到的 3 个同尺寸特征矩阵, L_Q 、 L_K 、 L_V 分别为特征矩阵 \mathbf{Q} 、 \mathbf{K} 和 \mathbf{V} 的长度; d 为输入维度; Softmax 为激活函数。为了进一步讨论自注意力机制, 让 \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 第 i 行分别为 \mathbf{q}_i 、 \mathbf{k}_i 、 \mathbf{v}_i 。第 i 行 Query 的注意力系数被定义为概率形式的内核平滑器。

$$Attention(\mathbf{q}_i, \mathbf{K}, \mathbf{V}) = \sum_j \frac{k(\mathbf{q}_i, \mathbf{k}_j)}{\sum_t k(\mathbf{q}_i, \mathbf{k}_t)} \mathbf{v}_j = E_{p(\mathbf{k}_j | \mathbf{q}_i)}[\mathbf{v}_j] \quad (7)$$

式中: $p(\mathbf{k}_j | \mathbf{q}_i) = k(\mathbf{q}_i, \mathbf{k}_j) / \sum_t k(\mathbf{q}_i, \mathbf{k}_t)$, $k(\mathbf{q}_i, \mathbf{k}_j)$ 是非对称指数 $\exp(\mathbf{q}_i \mathbf{k}_j^T / \sqrt{d})$ 。自注意力机制根据计算概率 $p(\mathbf{k}_j | \mathbf{q}_i)$ 来得到输出, 这需要二次时间复杂度的点积计算, 并且计算时需要 $O(L_K L_Q)$ 的空间复杂度。这阻碍了模型的长时序预测性能。为了克服上述缺点, 传统自注意力机制的概率分布存在稀疏性, 自注意力分数形成一个长尾分布, 即少数点积对主要的 attention 贡献大, 其他的可以忽略不计。

第 i 行 Query 对所有 Key 的注意力定义为概率 $p(\mathbf{k}_j | \mathbf{q}_i)$ 。占主导地位的点对应的注意力分数概率分布不是均匀分布。如果 $p(\mathbf{k}_j | \mathbf{q}_i)$ 接近均匀分布, $q(\mathbf{k}_j | \mathbf{q}_i) = 1/L_K$, self-attention 变成了 \mathbf{V} 的总和, 这样就丧失了自注意力机制的意义。因此, 分布 p 和 q 之间的相似性可以用来区分重要性较高的 Query。于是可通过 Kullback-Leibler 散度来衡量相似度, 如式(8)所示。

$$M(\mathbf{q}_i, \mathbf{K}) = \ln \sum_{j=1}^{L_K} e^{\frac{\mathbf{q}_i \mathbf{k}_j^T}{\sqrt{d}}} - \frac{1}{L_K} \sum_{j=1}^{L_K} \frac{\mathbf{q}_i \mathbf{k}_j^T}{\sqrt{d}} \quad (8)$$

式中: 第一项是所有 Key 上 \mathbf{q}_i 的 Log-Sum-Exp(LSE), 第二项是它们的算术平均值。如果第 i 行 Query 获得较大的 $M(\mathbf{q}_i, \mathbf{K})$, 则该点积对 attention 有较大的贡献度。通过允许每个 Key 只关注重要性较高的 Query 来实现稀疏自注意力机制。

$$Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax} \left(\frac{\overline{\mathbf{Q}\mathbf{K}^T}}{\sqrt{d}} \right) \mathbf{V} \quad (9)$$

通过重要性度量后, 选择得到稀疏性 Query 矩阵 $\overline{\mathbf{Q}}$, 通过选择稀疏的 Query 矩阵之后点积计算的复杂度降低为 $O(\ln L_Q)$, 有效降低了模型的计算复杂度。

2.2.3 编码过程

编码器的输入是带有位置嵌入与时间嵌入的多维时序数据 $\mathbf{X}_{encoder}^t = [\mathbf{X}_1^t, \mathbf{X}_2^t, \dots, \mathbf{X}_{L_x}^t]$ 。编码器由多头稀疏自注意力机制模块与“蒸馏”机制模块叠加构成, 图 3 为编码器结构。编码器首先通过稀疏自注意力机制提取时序数据中的长期依赖关系。为了减小编码器运算使用的内存, 使用注意力蒸馏机制使得单个层级特征在时间维度减半, 从而允许编码器处理更长的序列。注意力蒸馏主要是通过 1 维卷积神经网络将特征维度压缩并且提取出主要信息, 从 j 到 $j+1$ 层的蒸馏如式(10)所示。

$$\mathbf{X}_{j+1}^t = \text{Max Pool}(\text{ELU}(\text{Conv1d}([\mathbf{X}_j^t]_{\text{ATTENTION}}))) \quad (10)$$

式中: $[\mathbf{X}_j^t]_{\text{ATTENTION}}$ 代表了多头稀疏自注意力机制中的计算; Conv1d 代表了时间序列上的一维卷积操作; ELU 为激活函数。然后使用最大池化层将 \mathbf{X}^t 下采样到 1/2 维。自注意力块的维度也减少到前一个的 1/2。最终编码器将会输出一个维度较低的特征映射。

2.2.4 解码过程

解码器的结构与编码器类似, 但是在时序数据输入上有所不同。解码器在训练时为了避免得到将

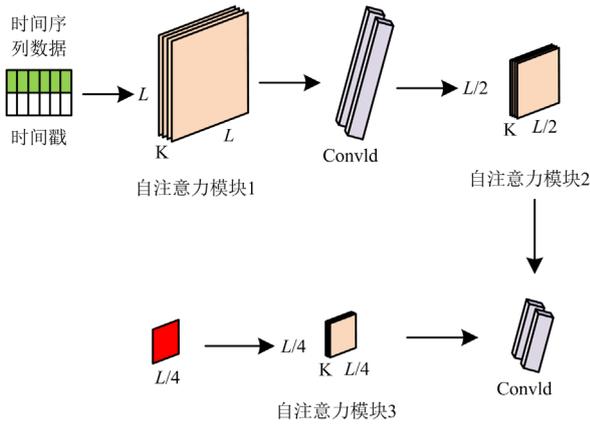


图3 编码器结构

Fig. 3 Encoder structure

要预测的序列信息, 在预测序列段使用 0 来填充, 输入向量如式(11)所示。

$$\mathbf{X}'_{\text{decoder}} = \text{Concat}(\mathbf{X}'_{\text{token}}, \mathbf{0}') \quad (11)$$

输入的时序数据先通过带掩码(Masked)的多头 Prob-sparse 自注意力机制模块计算后与编码器输出的特征映射进行稀疏自注意力操作, 运算结果进入到全连接层, 得到热负荷预测结果 $[Y_{t+1}, Y_{t+2}, \dots, Y_{t+n}]$ 。预测结果计算损失函数后通过梯度下降对模型进行优化。

图4为 Informer 整体框架图, Informer 模型中采用编码解码模型, 来对输入的多维数据进行预测, 在编码器中使用蒸馏机制, 来对长时间序列的特征进行提取并降维。在解码器中, 使用多头自注意力机制来对长时间序列的依赖性进行处理, 最终输出预测结果。

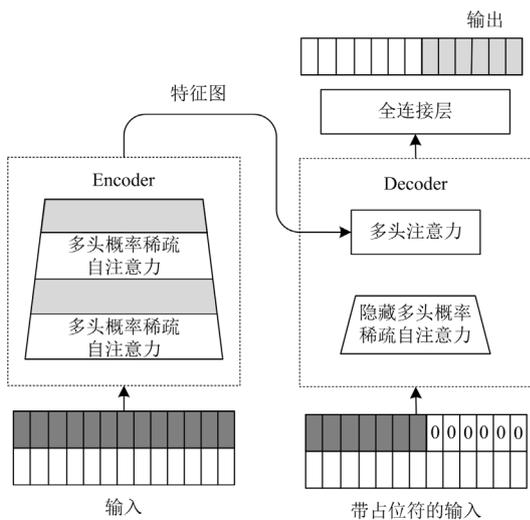


图4 Informer 整体框架图

Fig. 4 Informer overall framework diagram

为了消除数据量纲的影响, 将数据进行归一化处理, 如式(12)所示。

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (12)$$

式中: X' 表示归一化之后的数据; X 表示原始数据; X_{\max} 与 X_{\min} 分别为数据的最大值与最小值。

为了评估超短期热负荷预测模型的精度, 本文选用平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE)作为超短期热负荷模型的衡量指标, 计算公式分别为

$$M_{\text{AE}} = \frac{1}{n} \sum_{i=1}^n |y'_i - y_i| \quad (13)$$

$$R_{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (14)$$

式中: y_i 表示实际的热负荷值; y'_i 表示预测的热负荷值; n 表示热负荷流量预测样本的数量; M_{AE} 可以反映超短期热负荷预测误差的真实情况; R_{MSE} 作为超短期热负荷预测误差分析综合指标, 反映热负荷预测的精度, 其值越小说明热负荷流量预测的精度越高。

3 仿真结果与分析

本文通过多学科仿真平台(multi-subject simulation platform, MSP)建立对外供热系统动态模型来得到管道供热延迟时间 τ ; 然后采用 python 语言进行本次预测算法的编程, 形成热负荷时序预测算法; 最后根据热负荷的预测值进行提前预测调度。

3.1 确定预测时间长度

采用 MSP 建立对外供热系统动态模型如图 5 所示。电厂机组的冷再供热与热再供热经过供热集箱然后通过供热蒸汽管道向热用户供热, 冷再供热和热再供热抽汽流量根据热负荷的需求变化。

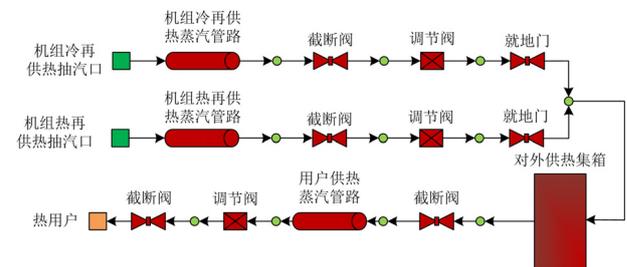


图5 对外供热系统动态模型

Fig. 5 Dynamic model of external heating system

根据热负荷的需求控制调节阀的开度, 改变调节阀的开度并观测热用户侧的流量变化来确定供热

延迟时间 τ 。本文选取 50 个热负荷数据来观测热负荷供热延迟的时间。表 1 是部分不同热负荷所需流量的供热延迟时间。

表 1 部分不同热负荷所需流量的供热延迟时间

Table 1 Partial heating delay time for flow required by different heat loads

热负荷所需流量/(t/h)	25	35	45	55	65
延迟时间/s	65.5	63.8	62.7	61.8	60.2
热负荷所需流量/(t/h)	75	85	95	105	115
延迟时间/s	59.8	59.4	58.8	58.5	58.1

从表 1 中可以看出，随着热负荷的增加，供热延迟时间会有下降的趋势。本文 τ 取 50 个热负荷供热延迟时间的平均值，即 $\tau = 60$ s。

3.2 负荷预测用于热调度验证

本文采用 python 语言进行本次预测算法的编程，形成热负荷时序预测算法，实验环境为 python 3.7, pytorch 1.6 框架。本文实验选取某电厂历史运行的热负荷和相关气象数据，分别包括干球温度、相对湿度、室外风速和太阳辐射量等信息。热负荷流量数据每 1 min 采集一次，气象数据每 30 min 采集一次，假设 30 min 内气象数据不发生变化。将热负荷数据、太阳辐射量、干球温度、相对湿度和室外风速作为 Informer 模型的输入。将 2019—2021 年的热负荷所需流量数据中的 1 261 440 组数据作为训练集，315 360 组数据作为测试集，对 2022 年 1 月的热负荷数据进行预测。

为验证所构建的 Informer 预测模型的预测优势，选取多层感知器(multi-layer perceptron, MLP)、CNN、LSTM 3 种常用的神经网络预测模型作为对照实验组。根据不同模型的特性设置超参数，并根据模型训练和验证结果的情况进行调节，最终采用 4 种模型的超参数如表 2 所示。

图 6 是不同模型下热负荷所需流量预测结果对比。从图 6 中可以看出，Informer 模型预测结果与实际热负荷所需流量值相比偏差较小，在实际所需流量值变化时预测值能够较好地跟随且误差小。相较于 Informer 模型而言，MLP 模型、CNN 模型和 LSTM 模型的预测值在实际值出现变动时无法较好地跟随，误差较大。在进行长时间序列预测时，Informer 模型能够很好地获取输入与输出之间的关系，使其在进行热负荷预测时获得较高的预测精度。

为了从整体上比较 4 个热负荷流量预测模型的精确度，不同模型热负荷流量的预测结果误差对比见表 3。从表 3 中可以看出，Informer 模型的 RMSE 比 MLP 模型、CNN 模型和 LSTM 模型分别低 25.48%、24.97%和 21.81%；Informer 模型的 MAE

比 MLP 模型、CNN 模型和 LSTM 模型分别低 37.06%、40.38%和 29.01%。Informer 模型对热负荷流量预测的效果最好，其中 MLP 模型、LSTM 模型和 CNN 模型方法由于其自身结构的约束，导致热负荷流量预测精度较低。

表 2 模型超参数

Table 2 Hyperparameters of models

超参数	MLP	CNN	LSTM	Informer
输入序列长度	60	60	60	60
预测序列长度	24	24	24	24
编码器堆叠	—	—	—	3,2,1
堆叠层数	3	3	3	—
隐藏层数量	64	32	32	—
批尺寸	128	128	128	128
丢弃率(dropout)	0.01	0.01	0.01	0.01
优化器	Adam	Adam	Adam	Adam
训练周期(epoch)	20	20	20	20
初始化学学习率	1×10^{-4}	1×10^{-4}	1×10^{-4}	1×10^{-4}
激活函数	gelu	gelu	gelu	gelu
损失函数	均方差(MSE)	均方差(MSE)	均方差(MSE)	均方差(MSE)

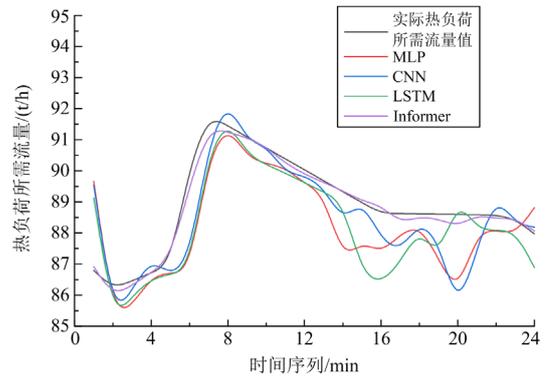


图 6 不同模型下热负荷所需流量预测结果对比

Fig. 6 Comparison of prediction results of flow required by heat load under different models

表 3 不同模型热负荷流量的预测结果误差对比

Table 3 Comparison of prediction error of heat load flow of different models

模型	MLP	CNN	LSTM	Informer
RMSE/(t/h)	1.193	1.185	1.221	0.889
MAE/(t/h)	0.618	0.652	0.698	0.389
计算时间/s	56	49	48	41

为了验证在进行厂级热负荷调度时采用提前预测值来消除供热延迟的合理性及有效性，本文选取该电厂某一特征日中某 24 min 内的热负荷所需流量预测值进行厂级调度，以 24 min 为调度周期，

1 min 为调度时段。图 7 是基于预测调度与传统调度的热负荷实现结果比较。从图 7 中可以看出, 传统调度在调度时会产生延迟, 不能第一时间满足热负荷的需求, 而采用预测调度能消除供热传输过程中的延迟, 使热用户使用感更好。

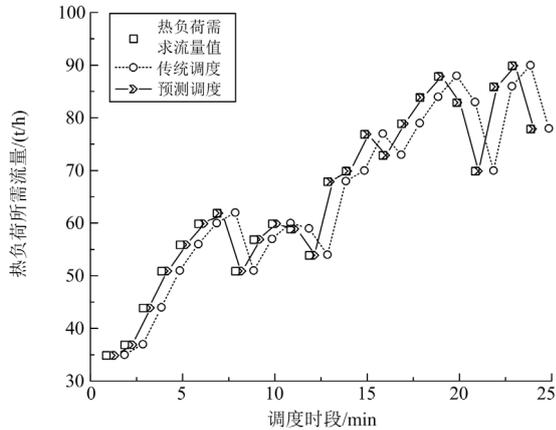


图 7 基于预测调度与传统调度的热负荷实现结果比较
Fig. 7 Comparison of heat load realization results between prediction based scheduling and traditional scheduling

4 结论

本文提出一种基于 Informer 的热负荷多步时序预测模型以提高超短期热负荷的预测精度, 解决了电厂供热改造机组在供热时由于调度控制和管道延迟导致的供热蒸汽不能及时满足供热用户需求的问题, 将 Informer 模型预测的热负荷运用于厂级多机组的热负荷优化调度的热负荷需求, 满足实际调度延迟对蒸汽量的需要, 以减少供热控制延迟的影响。此外, 实验结果表明, Informer 模型相较于 MLP、CNN、LSTM 模型在预测热负荷流量上具有最高的预测精度, 且泛化能力强, 可有效应用于综合能源优化调度, 如多机组、多热网系统的及时响应调度中。

参考文献

[1] 郭占伍. 考虑气象因素的电采暖负荷预测研究[J]. 电测与仪表, 2022, 59(2): 154-158.
GUO Zhanwu. Study on forecasting method of electric heating load considering meteorological factors[J]. Electrical Measurement & Instrumentation, 2022, 59(2): 154-158.

[2] 张月宇, 李德成, 方大俊, 等. 基于 EEMD-LSTM 模型的集中供热系统热负荷预测方法研究[J]. 能源工程, 2022, 42(1): 1-6.
ZHANG Yueyu, LI Decheng, FANG Dajun, et al. Study on heat load forecasting method of central heating system based on EEMD-LSTM mode[J]. Energy Engineering, 2022, 42(1): 1-6.

[3] 赵安军, 席江涛, 荆竞, 等. 基于 CNN 的高层住宅建筑群热负荷混合预测模型[J/OL]. 控制工程: 1-10 [2022-05-27]. DOI: 10.14107/j.cnki.kzgc.20210644.
ZHAO Anjun, XI Jiangtao, XING Jing, et al. Hybrid prediction model of heat load of high-rise residential complex based on CNN[J/OL]. Control Engineering of China: 1-10[2022-05-27]. DOI:10.14107/j.cnki.kzgc.20210644.

[4] 吴建中. 欧洲综合能源系统发展的驱动与现状[J]. 电力系统自动化, 2016, 40(5): 1-7.
WU Jianzhong. Drivers and state of-the art of integrated energy systems in Europe[J]. Automation of Electric Power Systems, 2016, 40(5): 1-7.

[5] 李香龙, 张宝群, 马龙飞, 等. 基于隐含数据信息挖掘的贝叶斯电采暖负荷预测[J]. 电测与仪表, 2018, 55(24): 88-93.
LI Xianglong, ZHANG Baoqun, MA Longfei, et al. Bayes heating load forecasting based on implicit data message mining[J]. Electrical Measurement & Instrumentation, 2018, 55(24): 88-93.

[6] 景胜蓝, 王飞, 雷勇刚. 热负荷预测方法研究综述[J]. 建筑热能通风空调, 2015, 34(4): 31-35.
JING Shenglan, WANG Fei, LEI Yonggang. Review on heating load prediction method[J]. Building Energy & Environment, 2015, 34(4): 31-35.

[7] 李伟, 钱华东, 徐强, 等. 基于线性回归的热负荷预测在热电联产机组中的应用[J]. 仪器仪表用户, 2018, 25(8): 59-62, 9.
LI Wei, QIAN Huaqiang, XU Qiang, et al. Application of heat load forecasting based on linear regression in cogeneration unit[J]. Instrumentation, 2018, 25(8): 59-62, 9.

[8] DING Y, ZHANG Q, YUAN T, et al. Model input selection for building heating load prediction: a case study for an office building in Tianjin[J]. Energy and Buildings, 2018, 159: 254-270.

[9] 李思琦, 蒋志坚. 基于改进 BP 神经网络的热负荷预测模型[J]. 软件导刊, 2019, 18(7): 41-44, 48.
LI Siqi, JIANG Zhijian. Forecasting model of heating load based on improved BP neural network[J]. Software Guide, 2019, 18(7): 41-44, 48.

[10] 王新雨, 于丹, 刘益民, 等. MIV-PSO-BP 神经网络用户热负荷预测[J]. 煤气与热力, 2022, 42(2): 1-3, 10.
WANG Xinyu, YU Dan, LIU Yimin, et al. Prediction of user heat load with MIV-PSO-BP neural network[J]. Gas & Heat, 2022, 42(2): 1-3, 10.

[11] 张佼, 田琦, 王美萍, 等. 基于遗传算法优化支持向量回归机参数的热负荷预测[J]. 暖通空调, 2017, 47(2): 104-108, 25.

- ZHANG Jiao, TIAN Qi, WANG Meiping, et al. Heating load prediction based on support vector regression machine with parameters optimized by genetic algorithm[J]. Heating, Ventilating and Air Conditioning, 2017, 47(2): 104-108, 25.
- [12] 薛普宁, 周志刚, 蒋毅, 等. 基于机器学习的供热系统热负荷多步递归预测[J]. 煤气与热力, 2019, 39(7): 20-26.
- XUE Puning, ZHOU Zhigang, JIANG Yi, et al. Multi-step ahead recursive prediction of heat at load of heating system based on machine learning[J]. Gas & Heat, 2019, 39(7): 20-26.
- [13] PROTIC M, SHAMSHIRBAND S, PETKOVIC D, et al. Forecasting of consumers heat load in district heating systems using the support vector machine with a discrete wavelet transform[J]. Energy, 2015, 87: 343-351.
- [14] SHAMSHIRBAND S, PETKOVIC D, ENAYATIFA R, et al. Heat load prediction in district heating systems with adaptive neurofuzzy method[J]. Renewable and Sustainable Energy Reviews, 2015, 48: 760-767.
- [15] GEYSEN D, DE SOMER O, JOHANSSON C, et al. Operational thermal load forecasting in district heating networks using machine learning and expert advice[J]. Energy and Buildings, 2018, 162: 144-153.
- [16] 夏睿, 高云鹏, 朱彦卿, 等. 基于 SE-CNN 模型的窃电检测方法研究[J]. 电力系统保护与控制, 2022, 50(20): 117-126.
- XIA Rui, GAO Yunpeng, ZHU Yanqing, et al. A detection method of electricity theft behavior based on an SE-CNN model[J]. Power System Protection and Control, 2022, 50(20): 117-126.
- [17] 杨威, 蒲彩霞, 杨坤, 等. 基于 CNN-GRU 组合神经网络的变压器短期故障预测方法[J]. 电力系统保护与控制, 2022, 50(6): 107-116.
- YANG Wei, PU Caixia, YANG Kun, et al. Short-term fault prediction method for a transformer based on a CNN-GRU combined neural network[J]. Power System Protection and Control, 2022, 50(6): 107-116.
- [18] 王俊, 李霞, 周昔东, 等. 基于 VMD 和 LSTM 的超短期风速预测[J]. 电力系统保护与控制, 2020, 48(11): 45-52.
- WANG Jun, LI Xia, ZHOU Xidong, et al. Ultra-short-term wind speed prediction based on VMD-LSTM[J]. Power System Protection and Control, 2020, 48(11): 45-52.
- [19] 李楠, 朱媛, 崔莹. 考虑代价敏感的 AC-LSTM 暂态稳定评估[J]. 电力系统保护与控制, 2022, 50(22): 160-169.
- LI Nan, ZHU Yuan, CUI Ying. AC-LSTM transient stability assessment considering cost-sensitivity[J]. Power System Protection and Control, 2022, 50(22): 160-169.
- [20] 吉兴全, 曾若梅, 张玉敏, 等. 基于注意力机制的 CNN-LSTM 短期电价预测[J]. 电力系统保护与控制, 2022, 50(17): 125-132.
- JI Xingquan, ZENG Ruomei, ZHANG Yumin, et al. CNN-LSTM short-term electricity price prediction based on an attention mechanism[J]. Power System Protection and Control, 2022, 50(17): 125-132.
- [21] 胡威, 张新燕, 李振恩, 等. 基于优化的 VMD-mRMR-LSTM 模型的短期负荷预测[J]. 电力系统保护与控制, 2022, 50(1): 88-97.
- HU Wei, ZHANG Xinyan, LI Zhen'en, et al. Short-term load forecasting based on an optimized VMD-mRMR-LSTM model[J]. Power System Protection and Control, 2022, 50(1): 88-97.
- [22] ZHOU H, ZHANG S, PENG J, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[C] // Proceedings of AAAI, 2021.
- [23] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C] // Advances in Neural Information Processing Systems, 2017: 5998-6008.
- [24] 齐结红, 潘宇, 钱虹, 等. 自动发电控制优先的厂级多机组供热经济优化调度研究[J]. 热力发电, 2022, 51(9): 63-71.
- QI Jiehong, PAN Yu, QIAN Hong, et al. AGC priority plant level multi-unit heating economic optimal dispatching[J]. Thermal Power Generation, 2022, 51(9): 63-71.

收稿日期: 2022-11-29; 修回日期: 2022-12-29

作者简介:

齐结红(1998—), 女, 通信作者, 硕士研究生, 研究方向为电力系统运行与优化研究和大数据预测; E-mail: 2213374580@qq.com

钱虹(1967—), 女, 博士, 教授, 研究方向为故障诊断、过程控制等。E-mail: qianhong.sh@163.com

(编辑 魏小丽)