

基于EVSC无监督特征选择与MIMO-BP神经网络预测射电望远镜背架温度场分布*

张世交^{1,2} 许谦^{1,3,4,5†} 王惠^{1,2} 薛飞^{1,2} 曹晓曼¹

(1 中国科学院新疆天文台 乌鲁木齐 830011)

(2 中国科学院大学 北京 100049)

(3 中国科学院射电天文重点实验室 乌鲁木齐 830011)

(4 新疆射电天体物理实验室 乌鲁木齐 830011)

(5 陕西省天线与控制技术重点实验室 西安 710065)

摘要 背架受非均匀温度影响是造成射电望远镜天线主反射面精度下降的重要因素之一. 工作于野外的天线由于背架拓扑结构复杂导致杆件间相互存在遮挡、热传导、热辐射等, 使得背架结构温度场难以通过热力学仿真来准确获取与预测. 通过在南山26 m射电望远镜天线背架上布设测温传感器, 得到天线背架温度数据集, 利用3种不同的无监督特征选择方法从66个测温点选出16个温度敏感点, 再将3组不同的温度敏感点集作为输入, 使用多输入多输出的BP (Back Propagation)神经网络模型训练输出对应的66个测温点的预测温度值, 通过插值算法实现背架全域连续点的温度预测. 经对比分析得出采用基于特征值敏感准则无监督特征选择方法选取测温敏感点效果最佳, 结合BP神经网络与Barnes插值算法实现了仅用16个实测温度点预测南山26 m射电望远镜天线背架全域连续点的温度场分布, 预测均方根误差约为0.707 °C. 研究成果为大口径射电望远镜天线背架结构温度采集点的布置、温度场的获取及预测提供一种可选方法.

关键词 望远镜, 仪器: 背架, 方法: 无监督特征选择, 方法: 神经网络

中图分类号: P111; **文献标识码:** A

1 引言

反射面精度和指向精度是反映射电望远镜天线性能的两个重要指标, 天线背架结构受非均匀温度影响造成的变化是影响反射面精度的重要因素. 目前, 对于射电望远镜热分析的研究国内外早已开展了一系列相关工作, 现有研究多为热力学仿真和实测分析两种方式, 如Nikolic等^[1]在100 m美国绿

岸望远镜(Green Bank Telescope, GBT)上使用了全息测量技术证明了在白天热变形影响通常超过重力变形. Greve等^[2]在30 m口径射电望远镜天线上布设了156个温度传感器以获取真实热状态, 利用实测温度数据分析了天线热力学特性, 并利用结构有限元方法分析计算了由温度梯度带来的误差. 易乐天等^[3]使用有限元热力学建模仿真分析表明日照下的南山26 m射电望远镜(Nanshan 26 m Ra-

2023-11-20收到原稿, 2024-03-07收到修改稿

*国家自然科学基金项目(12273102)、国家重点研发计划(2021YFC2203601)、中国科学院青年创新促进会(Y202019)、中国科学院天文台站设备更新及重大仪器设备运行专项、中国科学院科研仪器设备研制项目(PTYQ2022YZZD01)、陕西省天线与控制技术重点实验室开放基金项目资助

†xuqian@xao.ac.cn

dio Telescope, NSRT) 背架结构温度呈近似线性分布. 李干等^[4]利用全站仪测量了上海65 m射电望远镜(Shanghai 65 m Tianma Radio Telescope, TM-RT) 背架上选定点由热变形导致的位移误差, 再根据背架热变形规律分析得出日照温度变化对面形精度的影响. Fu等^[5]使用红外热成像仪和Pt100温度传感器结合距离视角矫正公式来实现(TMRT) 背架温度的精确测量.

结合相关领域现有研究进展可知, 使用数值仿真方法由于无法设置实时的天线工况参数, 仅能通过设置极端工况下的边界条件来得到天线在极端工况的性能表现. 而对于使用实测手段获取望远镜温度数据的方法, 测温点的最优数量还需要进一步研究, 另外由于天线结构复杂使得接触式温度传感器安装布设与后期维护难度大; 使用非接触式温度传感器测量范围有所局限, 还无法实现对结构的完全测量. 目前仍没有一种高效可行的方法来实现望远镜背架温度分布数据的获取.

本研究提出了一种基于无监督特征选择方法并结合神经网络模型实现望远镜背架温度分布预测的方法, 通过数据驱动的方式建立相应的预测模型来替代复杂的数学物理方程求解, 进而实现预测结构件的温度场分布. 利用NSRT望远镜背架实测温度数据, 使用3种不同的无监督特征选择方法找出3组敏感测温点集, 以不同敏感测温点集为输入建立相应的MIMO-BP (Multiple Input and Multiple Output - Back Propagation)神经网络模型, 再利用插值算法最终实现实时预测背架整体温度场分布. 该方法为望远镜背架温度采集点的布置提供了理论支撑; 在保持测量精度的情况下, 为实现用较少实测温度点预测背架全域连续点的温度场分布提供了可行方案.

2 数据的获取与处理

通过在26 m NSRT背架上布设基于光纤布拉格光栅(Fibber Bragg Grating, FBG)温度传感器来获取实测温度数据并在其周边布设多参数传感器来采集多种环境数据, 用以建立基于数据驱动的神经网络预测模型. 采集时间段为2021年11月15日至2022年7月19日, 采集频率为10 s/次, 采集内容有

环境温度、环境湿度、大气压力、风向、风速、望远镜的方位俯仰角度、太阳相对于NSRT的方位俯仰角度以及NSRT背架上66个点的实测温度数值. 图1表示天线背架结构上66个温度传感器安装位置示意图, 其中66个测温传感器位置分布俯视图如图1 (a)所示, A-P表示布设在26 m NSRT天线背架上16片主辐射梁的16个测量通道, 呈中心对称分布, 因为主辐射梁是天线背架的核心承力构件, 所以重点测量主辐射梁的温度变化有利于分析背架整体热变形情况, 在每根主辐射梁上传感器的安装位置均集中在连接杆中部, 以杆件中间节点温度代表整个杆件平均温度. 图1 (b)表示单根辐射梁的横截面侧视图, 圆点为测温传感器安装点位, 由图可知, 所有测温传感器均布设在下弦梁等分点处. 现场安装布设测温传感器如图2所示, 图2 (a)为蜘蛛吊车载人至射电望远镜背架下弦梁处布设测温传感器, 背架杆件上布设测温传感器全局图如图2 (b)所示, 使用防潮防水隔热耐磨损的灰色聚四氟乙烯薄膜胶带固定光纤线路和测温传感器, 局部细节图如图2 (c)所示. 图3为NSRT高频仓内温度采集设备示意图, 图3 (a)中各温度传感器所采集的布拉格波长信息由光纤线路传输至高频仓内, FBG光纤光栅测温系统数据处理设备整体如图3 (b)所示.

在测温传感器类型选择上, 综合考虑了测量精度、电磁兼容性、使用寿命和设备安装与后期维护难度等方面, 选择使用FBG温度传感器来获取实际背架温度. FBG温度传感器测量原理^[6]是通过测量布拉格波长的漂移实现对被测点的温度检测, 布拉格波长 λ_B 定义式为(1)式:

$$\lambda_B = 2N\Lambda, \quad (1)$$

式中, N 为激光在光纤内传播的有效折射率; Λ 为布拉格光栅的周期, 反射波长 λ_B 会受到光栅区域的物理或机械特性的变化影响, 其中, 温度的变化会导致 N 的改变; 对于非约束光纤, Λ 会受到热膨胀和热收缩的影响, 如(2)式所示, 描述温度对 λ_B 的影响:

$$\Delta\lambda_B = \lambda_B (\gamma + \zeta) \Delta T, \quad (2)$$

式中, $\Delta\lambda_B$ 为布拉格波长变化量, γ 和 ζ 分别表示热膨胀系数和热光系数, ΔT 表示温度变化量.




图 1 温度传感器布设位置图. (a)俯视图, (b)横截面视图.

Fig.1 Diagram of temperature sensors deployment position. (a) Top view, (b) cross-sectional view.




图 2 温度传感器布设现场. (a)吊车载人安装传感器, (b)传感器布设全局图, (c)传感器布设细节图.

Fig.2 Diagram of temperature sensors field installation. (a) Manned crane for laying sensors, (b) sensors layout global diagram, (c) sensors layout detail diagram.

3 基于UFS的温度敏感点的选择

为了实现在不降低测量精度的条件下, 使用较少的温度传感器来进行预测, 对66个测温点进行敏感测温点的选取是十分有必要的, 而使用无监督特征选择方法可以达到预期效果. 特征选择可分为有监督和无监督两类, 当数据的类别信息已知时应用有监督特征选择方法, 而数据类别信息未知时应用无监督特征选择方法, 实际不同的背架测温点对应着不同的温度变化敏感强度, 因此, 应采用无监

督特征选择方法(Unsupervised Feature Selection, UFS)进行特征的筛选.

在UFS方法理论研究领域中, Solorio-Fernández等^[7]全面详细地介绍了各种UFS方法, 并对其进行了结构化分类和优缺点对比. 徐峻岭等^[8]提出了一种基于互信息的无监督特征选择方法, 使用了无监督最小冗余最大相关来评价特征的重要性, 在理论上证明了基于互信息的无监督特征选择方法的有效性; 丁雪梅等^[9]提出了一种新型的基于改进ReliefF (该算法通过样本间的差异性常用于多类样

本分类问题)的无监督特征选择方法UFS-IR (Un-supervised Feature Selection based on Improved ReliefF), 通过改进抽样策略避免了ReliefF类算法在小类样本抽样概率低、无法删除冗余特征的缺陷, 实现了有效缩减数据维度的同时保证特征子集的最大相关最小冗余性. 本研究采用3种无监督

特征选择方法实现16个测温敏感点的获取, 随后通过模型预测结果来分析得出最优的UFS方法, 3种UFS方法分别是基于特征值敏感准则(Eigenvalue Sensitive Criterion, EVSC)、基于拉普拉斯得分法(Laplacian Score, LS)以及基于谱分解(Spectral Feature Selection method, SPEC).




图3 光纤光栅测温系统数据处理设备. (a)温度传感器采集设备, (b)温度采集设备全局图.

Fig. 3 Diagram of fiber grating temperature measurement system data processing equipment. (a) Temperature sensor acquisition device, (b) global view of the temperature collection device.

EVSC方法^[10]是利用相似度矩阵和协方差矩阵之间的关联性来进行特征选择, 选用的相似度测量方法是常见的高斯核函数:

$$S_{EVSC(i,j)} = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / 2\delta^2), \quad (3)$$

其中, $S_{EVSC(i,j)}$ 表示特征 i 与特征 j 的相似度, $\mathbf{x}_i$ 和 $\mathbf{x}_j$ 分别是数据集中特征 i 与特征 j 所对应的数据样本, δ 是高斯核的宽度参数, 而最后使用EVSC准则来评估每个特征重要性的计算公式为:

$$\text{Score}_{EVSC(i)} = \frac{\sum_n |\mathbf{v}_{n(i)}| \lambda_{n(i)}}{\sum_n \lambda_{n(i)}}, \quad (4)$$

其中, $\text{Score}_{EVSC(i)}$ 表示使用EVSC方法计算出特征 i 的重要性评分, $\mathbf{v}_{n(i)}$ 是特征 i 的特征向量, $\lambda_{n(i)}$ 是

$\mathbf{v}_{n(i)}$ 的特征值, n 表示数据集中共有 n 个特征. 特征的重要性评分越高, 意味着该特征越重要. 因此, 选择重要性评分最高的特征子集作为最终的特征选择结果.

Laplacian Score^[11]主要通过构建无向图模型来了解数据的几何结构, 其基本思想是: 如果一个特征在数据的流形结构上表现得比较均匀, 那么这个特征比较重要. 基本流程如下: (1)利用特征间的相似度来构造关联矩阵 $\mathbf{S}$, 则特征 i 与特征 j 的关联矩阵 $\mathbf{S}_{(i,j)}$ 可以表示为(5)式:

$$\mathbf{S}_{(i,j)} = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / t), \quad (5)$$

其中, t 为定常数, 否则 $\mathbf{S}_{(i,j)} = 0$. (2)定义对角矩阵

并求出拉普拉斯矩阵, 对角矩阵 $\mathbf{D}_{(i,i)}$ 定义为(6)式:

$$\mathbf{D}_{(i,i)} = \sum_{j=1}^n \mathbf{S}_{(i,j)}, \quad (6)$$

然后得到拉普拉斯矩阵 $\mathbf{L} = \mathbf{D} - \mathbf{S}$. (3)计算拉普拉斯得分, 通过(7)式计算出每个特征的拉普拉斯得分:

$$\text{Score}_{\text{LS}(i)} = \frac{\tilde{\mathbf{x}}_i^T \mathbf{L} \tilde{\mathbf{x}}_i}{\tilde{\mathbf{x}}_i^T \mathbf{D} \tilde{\mathbf{x}}_i}, \quad \text{其中 } \tilde{\mathbf{x}}_i = \mathbf{x}_i - \frac{\mathbf{x}_i^T \mathbf{D} \mathbf{E}}{\mathbf{E}^T \mathbf{D} \mathbf{E}} \mathbf{E}, \quad (7)$$

其中, $\text{Score}_{\text{LS}(i)}$ 表示使用拉普拉斯得分法计算出特征*i*的重要性评分, $\mathbf{D}$ 是对角矩阵, $\mathbf{L}$ 是拉普拉斯矩阵, $\mathbf{T}$ 表示转置, $\mathbf{E}$ 为单位矩阵 $\mathbf{E} = [1, \dots, 1]^T$. 从(7)式中可以看出, 一个特征的拉普拉斯得分主要由两部分组成: 分子部分表示这个特征在数据的流形结构上的变化程度, 分母部分表示这个特征在所有样本上的取值的分散程度. 因此, 得分越小的特征意味着它在保持数据的几何结构方面做得更好.

Spectral Feature Selection^[12]既可以用于有监督的特征选择中, 又可以用于无监督的特征选择中, 而在应用于UFS中, 算法大体流程如下. (1)基于输入数据构建特征图: 对于输入数据集, 计算每一对特征之间的相似度即关联矩阵, 对于应用于无监督特征选择场景中的SPEC算法, 本文选用常见的径向基函数高斯核函数来表达关联矩阵 $\mathbf{S}_{(i,j)}$, 具体计算公式同(5)式; (2)计算拉普拉斯矩阵 $\mathbf{L}$: 在获得关联矩阵 $\mathbf{S}_{(i,j)}$ 后, 定义度矩阵 $\mathbf{D}$ 为对角矩阵, 其中第*i*个节点的度为 $\mathbf{D}_{ii}$, 具体计算公式同(6)式, 随后得出拉普拉斯矩阵 $\mathbf{L} = \mathbf{D} - \mathbf{S}$; (3)计算拉普拉斯得分并对特征进行排序. 在计算得分前要求出归一化拉普拉斯矩阵 $\mathbf{L}_{\text{norm}}$:

$$\mathbf{L}_{\text{norm}} = \mathbf{D}^{-\frac{1}{2}} (\mathbf{D} - \mathbf{S}) \mathbf{D}^{-\frac{1}{2}}, \quad (8)$$

得到归一化拉普拉斯矩阵 $\mathbf{L}_{\text{norm}}$ 后对于特征*i*其拉普拉斯得分 $\text{Score}_{\text{SPEC}(i)}$ 计算如下:

$$\text{Score}_{\text{SPEC}(i)} = \hat{\mathbf{H}}_i^T \mathbf{L}_{\text{norm}} \hat{\mathbf{H}}_i, \quad (9)$$

其中, $\hat{\mathbf{H}}_i = \frac{\mathbf{D}_{ii}^{\frac{1}{2}}}{\|\mathbf{D}^{\frac{1}{2}}\|}$, 虽然SPEC的基本思想类似于Laplacian Score, 与数据流形结构一致的特征应该为彼此接近的实例分配相似的值且两者都使用到了拉普拉斯矩阵, 但需要指出的是两者计算得分的方式却有所不同.

表1中表示分别使用EVSC、LS、SPEC这3种无监督特征选择方法对66个测温点进行前16个特征的特征重要性排序, 表1中的第1列与第2列为使用EVSC方法计算出的敏感测温点的传感器编号与对应的特征重要性评分. 图4 (a)为使用EVSC选出的前16个敏感测温点在背架上的位置分布情况. 表中的第3列与第4列为使用LS方法计算出的敏感测温点的传感器编号与对应的特征重要性评分. 图4 (b)为使用LS选出的前16个敏感测温点在背架上的位置分布情况. 表中的第5列与第6列为使用SPEC方法计算出的敏感测温点的传感器编号与特征重要性评分. 图4 (c)为使用SPEC选出的前16个敏感测温点在背架上的位置分布情况.

总的来说, 通过使用EVSC、LS、SPEC这3种无监督特征选择方法实现了从66个测温点中. 选出了3组不同的16个敏感测温点. 实际上这3种UFS方法并没有性能优劣之分, 只是不同的特征选择方法在不同的数据处理场景中的适用性不同. 仅从主观经验分析, 作者认为EVSC方法因其选择位置较为分散推测其结果较好, 但是, 为了更客观准确地验证3种UFS选择结果, 同时为了实现背架温度场的预测, 下面以16个敏感测温点为输入利用多输入多输出的MLP-BP神经网络模型预测66个测温点的温度数值.

表 1 各UFS方法得分结果
Table 1 Results of the UFS methods

Results of EVSC		Results of LS		Results of SPEC	
Index	Score	Index	Score	Index	Score
I6	439.2784514	P2	−4309698.11	I3	71933.33533
I3	124.5710628	O3	−3962016.74	I5	66452.00113
G6	80.57297229	O2	−3324747.21	J4	66345.10519
E2	75.86214345	O5	−2858378.13	J6	66206.18312
O5	70.03045854	N2	−2476909.71	J3	66008.41117
P5	69.79317324	F5	−2196099.97	I4	65832.43683
O6	68.3097417	P1	−1906935.75	I2	65536.05742
D5	67.68975572	F4	−1720000.58	I1	65463.06731
O3	66.14797888	G6	−1657903.68	K5	64803.86955
P6	65.98849135	F2	−1513577.35	J2	64731.03751
P3	64.97825356	F3	−1511204.93	H4	64587.98183
B3	63.49854558	F6	−1346486.11	E2	64209.0074
G5	63.44343847	F1	−1121846.04	J1	63860.48761
D4	63.33725886	O4	−968166.182	H5	63659.32744
K5	63.29073154	G4	−600254.096	K6	63388.19794
N2	63.07514446	M2	−567571.238	E3	63147.70101




图 4 使用UFS方法选择出的敏感测温点集在背架结构上的位置示意图. (a)使用EVSC选择结果, (b)使用LS选择结果, (c)使用SPEC选择结果.
Fig. 4 Diagram of the sensitive temperature measuring points selected by the UFS method on the backup structure. (a) Feature selection result obtained using EVSC, (b) feature selection result obtained using LS, (c) feature selection result obtained using SPEC.

4 基于MIMO-BP神经网络模型实现背架温度预测

望远镜背架温度分布求解与预测的关系式实际上是一组复杂的多元非线性方程组, 很难用传统方法得到其解析解, 而多层人工神经网络^[13]利用大量的数据不断对网络模型进行训练优化, 最终实现求解复杂方程的目的. 图5为本文设计的MIMO神经网络结构, 其中输入层为 $\mathbf{X} = [x_1, x_2, x_3, \dots]$, 输出层为 $\mathbf{Y} = [y_1, y_2, y_3, \dots]$, 除了输入层和输出层外, 中间层包含了2个隐层, 即4层结构, 其中 d_n^f 表示为第 n 个隐层中的第 f 个神经节点.




图5 多输入多输出神经网络结构示意图

Fig. 5 Diagram of multiple input and multiple output neural network architecture

图中每一个圆圈代表一个神经节点, 层与层之间是全连接的, 但同层间的神经元不连接, 也不存在跨层连接, 该结构常称为“多层前馈神经网络”, 在前向传播中每层求得 z_n 的运算如下:

$$z_n = \mathbf{w}_n \mathbf{a}_{n-1} + \mathbf{b}_n, \quad (10)$$

其中, $\mathbf{z}_n = [z_n^1, z_n^2, \dots, z_n^f]^T$, z_n^f 表示节点 d_n^f 所对应的节点值, $\mathbf{a}_{n-1} = [a_{n-1}^1, a_{n-1}^2, \dots, a_{n-1}^f]^T$, a_{n-1}^f 表示为 z_{n-1}^f 所对应的激活值, $\mathbf{a}_0$ 为原始输入 $\mathbf{X}$, $\mathbf{w}_n$ 为第 n 层的权重即连接系数矩阵, $\mathbf{b}_n =$

$[b_n^1, b_n^2, \dots, b_n^f]^T$ 为第 n 层的偏置, 而该层节点值所对应的激活值 $\mathbf{a}_n$ 的运算式:

$$\mathbf{a}_n = g_n(\mathbf{z}_n), \quad (11)$$

其中, $\mathbf{a}_n = [a_n^1, a_n^2, \dots, a_n^f]^T$, a_n^f 为 z_n^f 所对应的激活值, g_n 为第 n 层所选用的激活函数^[14]. 综合考虑到模型输入输出变量与数据集较大, 且温度数值不具有数值突变的特点, 在该模型中选用Tanh函数比较合适.

考虑到网络结构较为复杂, 选择更为高效的训练方法来提高模型训练效率是十分有必要的. BP算法(Error Back Propagation)是比较常用的训练方法, 该算法由前向传播和反向传播两过程组成, 前者求出损失, 后者由损失进行误差回传, 上文中已经阐述了前向传播的算法流程, 从本质上来说, 前向传播是为反向传播做好输入值, 而反向传播是一种高效求梯度的方法. 在前向传播中输出的损失值结果, 由(12)式中的损失函数 E 得到:

$$E = \frac{1}{2} \sum_{p \in n} (t^{(p)} - y^{(p)})^2, \quad (12)$$

其中, p 为当前层下(即 n 层下)的所有可能神经节点, $t^{(p)}$ 为 n 层下所有神经节点对应的真实值, $y^{(p)}$ 为 n 层下所有神经节点的前向传播输出值. 通过上式计算出每个神经元的局部损失进而求导计算出损失梯度, 然后对权重和偏置的参数值进行不断的迭代更新, 公式如下:

$$\begin{cases} \mathbf{w}_n = \mathbf{w}_n - \alpha \frac{\partial E}{\partial \mathbf{w}_n}, \\ \mathbf{b}_n = \mathbf{b}_n - \alpha \frac{\partial E}{\partial \mathbf{b}_n}, \end{cases} \quad (13)$$

其中, α 表示学习率, 根据经验来设定, 取值范围在 $(0, 1]$. 迭代更新后使损失函数 E 不断减小, 最终达到机器学习优化模型的目的.

5 数据结果分析

为了确保模型具有普适性, 在每次训练前抽取80%作为训练集, 10%分别作为验证集和测试集, 使用Python在TensorFlow框架中建立结构为具有2层

隐藏层[50, 96]的MLP-BP网络模型进行训练学习. 而对于模型性能的评估指标有很多种, 本研究结合实际应用场景和数据集特征, 采用 R^2 系数(coefficient of R squared)和RMSE (Root Mean Squared Error)来评价模型整体的泛化能力. 判定系数 R^2 是一种衡量回归模型拟合程度的重要指标, 其数值越接近1表明模型拟合优度越高, 一般来讲, 拟合优度达到0.8以上说明拟合效果优异, 具体计算公式为:

$$R^2 = 1 - \frac{\text{mean}[\sum_{t=1}^m (y_t - \hat{y}_t)^2]}{\text{mean}[\sum_{t=1}^m (y_t - \bar{y}_t)^2]}, \quad (14)$$

其中, mean为取平均运算, t 为当前预测点, $\hat{y}_t$ 为 t 点的预测值集, $\bar{y}_t$ 为 t 点预测值集的平均值, y_t 为 t 点的真实值集, m 为预测点个数. 而均方根误差用来衡量预测值与真实值之间的绝对差异, 值越小说明具有更高的精度, 具体计算公式为:

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_t - \hat{y}_t)^2}. \quad (15)$$

将3组不同的敏感测温点集作为输入进行模型训练得到预测结果与真实值对比, 表2给出了使

用 R^2 系数和RMSE表示预测结果的误差大小.

表 2 模型训练结果
Table 2 Model training results

UFS method	R^2	RMSE/ $^{\circ}\text{C}$
EVSC	0.99001	0.707
LS	0.97651	1.240
SPEC	0.92423	2.284

从表2可知, 使用EVSC方法选择敏感测温点的模型预测效果最好, 判定系数 R^2 最接近1表示输出值由输入值解释程度最强, 且RMSE也是3种方法中最小的. 由于预测数据为温度而RMSE与数据集量纲相同, 也就意味着使用EVSC方法进行模型预测的整体误差约为 0.707°C , 说明了模型训练的效果和对测试集的泛化效果都很好. 考虑到不同位置的测温设备的稳定性准确性不同, 因此对不同位置的测温点误差分析是十分必要的, 图6为使用箱线图分析66个不同位置测温点的RMSE和 R^2 系数, 从而判断出整体数据的偏态和尾重.




图 6 RMSE和 R^2 系数的误差箱线图. (a) RMSE箱线图, (b) R^2 系数箱线图.

Fig. 6 Diagram of RMSE and R^2 boxplot. (a) Diagram of RMSE boxplot, (b) diagram of R^2 boxplot.

其中, 图6 (a)是使用不同UFS方法预测出的66个不同位置点的RMSE值, 图6 (b)则是66个不同位置点的 R^2 系数. 从数据离散度分析箱线图可以看出, 3种方法的RMSE与 R^2 系数分布均较为集中, 但 R^2 系数存在个别离群异常点. 从各组数据整体分布位置分析, 不论RMSE还是 R^2 系数的误差范围分布规律均为EVSC方法最小, LS方法居中, SPEC方法最大.

为了验证在各种极端工况下使用EVSC方法模型预测精度的稳定性, 即量化评价其鲁棒性能, 本研究针对NSRT工作环境分出8类极端工况^[15-16]分别为: 相对强风(风速大于 $4 \text{ m} \cdot \text{s}^{-1}$) 与无风、高温(室外温度 25°C 以上)与低温(零下 15°C 以下)、雨雪与晴天、强日照与黑夜. 需要说明的是NSRT台址全年风力强度多在 $3 \text{ m} \cdot \text{s}^{-1}$ 内, 因此将风速大于 $4 \text{ m} \cdot \text{s}^{-1}$ 的少数偶然时段定为相对强风工况, 而在实测时段(2021年11月15日至2022年7月19日)内的最低温度为 -19.7°C , 最高温度为 28.1°C , 因此将温度 25°C 以上的时段实测数据定为高温工况数据集, 将零下 15°C 以下的时段实测数据定为低温工况数据集. 将测试数据集分类后各自进行预测, 表3给出了各种工况下的预测精度.

表 3 各极端工况预测精度结果

Table 3 Prediction accuracy of several extreme working conditions

Name of working condition	R^2	RMSE/ $^\circ\text{C}$
Relative strong wind	0.98397	0.816
Windless environment	0.99193	0.668
High temperature environment	0.99002	0.763
Low temperature environment	0.98598	0.642
Rainy and snowy	0.99344	0.576
Sunny and cloudless	0.99502	0.673
Strong sunshine environment	0.99213	0.857
Cloudless night environment	0.99299	0.565

从表3可知, 模型应对各种极端工况的预测效

果良好, 在强风和强日照条件下的预测效果相对较差, 强风工况因整体背架位姿与受风角度复杂多样导致背架结构温度场风冷散热情况不同, 而强日照则由于背架被太阳照射的方位俯仰角度与区域不同导致了温度场变化情况复杂多变, 进而均表现出较差的预测效果. 但是, 整体分析表3中的结果可得各工况的预测误差数值相近且均在 1°C 以内, 预测精度较为可观, 至此论证了使用EVSC方法通过MIMO-BP模型进行预测在复杂极端的工况下鲁棒性强, 预测结果表现良好.

为了实现从离散点的温度预测到背架上连续位置点的温度预测, 参考了王从思等^[17]关于利用插值算法重构温度场的研究, 使用Barnes插值算法^[18-19]实现背架整体温度场的获取与预测. 该算法因其计算量小且稳定性高已广泛应用于大气与海洋科学相关领域, 分别对实测66个敏感测温点数据和66个预测温度点数据进行插值运算进而算出RMSE, 用以评估背架上连续位置点温度预测的误差精度. 表4为各方法对背架结构连续域温度场的预测精度误差结果, 从表4中数据可得温度场由MIMO-BP模型预测到Barnes插值其预测误差经多次传递而不断增大, 但使用EVSC方法结合模型预测和插值算法实现连续域温度场的预测精度仍优于其他方法, 其预测精度约为 1.912°C . 为了从空间位置上更具体直观地分析该算法在背架结构温度场连续域的插值预测精度, 图7依次为EVSC、LS和SPEC这3种UFS方法预测的背架整体温度的RMSE热力图, 红色越深代表预测的温度误差越高, 蓝色越深代表预测的温度误差越低.

表 4 连续域温度场插值精度

Table 4 Interpolation accuracy of continuous temperature field

UFS method	RMSE/ $^\circ\text{C}$
EVSC	1.912
LS	3.935
SPEC	5.163




图 7 RMSE空间热力图

Fig. 7 Spatial thermal maps of RMSE

从图7中可以得出, EVSC的预测误差优于LS, 而LS优于SPEC, 这与前文结果一致. 此外, 通过神经网络预测66个测温敏感点后再经过插值算法实现背架全域连续点的温度预测, 因此误差经过多次传递与叠加后需要重新统计与评估. 而从图7和表4中可以得出, 使用EVSC特征选择方法结合MLP-BP神经网络模型与Barnes插值算法实现背架全域连续点温度预测的误差均在 2°C 以内, 分布较为集中且无突变异常点. 至此, 本文使用了多种验证分析方法和评价指标从整体到局部全方位地证明了使用EVSC选择敏感测温点是最适用本场景的无监督特征选择方法. 同时, 结合EVSC特征选择方法与MLP-BP神经网络加以Barnes插值实现了利用更少的实测温度点来预测背架全域连续点的温度分布.

6 结论

本研究基于多种无监督特征选择方法实现了从66个测温点中选取16个敏感测温点, 通过对比分析得出使用EVSC无监督特征选择方法选取敏感测温点效果最佳, 并验证了其在多种极端工况下预测精度的鲁棒性, 整体预测效果表现良好误差约为 0.707°C . 但由于NSRT野外工况环境复杂多变, 尤其在强风与强日照的工况下的背架结构温度场预测精度相对较差, 因此针对极端工况下的天线背架结构温度场预测领域, 有待后续深入开展相关工作. 最终, 本文使用EVSC特征选择方法并结

合MIMO-BP神经网络模型与Barnes插值算法实现了背架全域连续点温度预测, 预测精度约为 1.912°C , 该方法对射电望远镜背架上测温传感器位置布置工作提供了理论参考. 通过MLP-BP神经网络结合Barnes插值算法实现了望远镜背架整体的温度场分布从离散到连续的预测, 为天线结构部件的温度实测与预测提供了一种可选方案.

参考文献

- [1] Nikolic B, Prestage R M, Balser D S, et al. A&A, 2007, 465: 685
- [2] Greve A, Bremer M, Penalver J, et al. IEEE Transactions on Antennas and Propagation, 2005, 53: 851
- [3] 易乐天, 许谦, 王娜, 等. 天文学报, 2022, 63: 43
- [4] 李干, 李宗春, 牟爱国, 等. 天文学报, 2013, 54: 189
- [5] Fu L, Tang J, Zhao R, et al. Experimental Astronomy, 2023, 56: 223
- [6] Hirayama N, Sano Y. ISA Transactions, 2000, 39: 169
- [7] Solorio-Fernández S, Carrasco-Ochoa J A, Martínez-Trinidad J F. Artificial Intelligence Review, 2020, 53: 907
- [8] 徐峻岭, 周毓明, 陈林, 等. 计算机研究与发展, 2012, 49: 372
- [9] 丁雪梅, 王汉军, 王韶光, 等. 计算机系统应用, 2018, 27: 149
- [10] Jiang Y, Ren J. ICML'11: Proceedings of the 28th International Conference on Machine Learning. Wisconsin: Omnipress, 2011: 89
- [11] He X, Cai D, Niyogi P. Laplacian Score for Feature Selection. Advances in Neural Information Processing Systems 18. Proceedings of the 2005 Conference. Massachusetts: MIT Press, 2005: 507
- [12] Zhao Z, Liu H. ICML'07: Proceedings of the 24th International Conference on Machine Learning. New York: Association for Computing Machinery, 2007: 1151

- [13] Dreiseitl S, Ohno-Machado L. *Journal of Biomedical Informatics*, 2002, 35: 352
- [14] Sharma S, Athaiya A. *IJEAST*, 2017, 6: 310
- [15] Baars JW, Greve A, Hein H, et al. *Proceedings of the IEEE*, 1994, 82: 687
- [16] 张宇. *科技风*, 2016, 18: 11
- [17] 王从思, 王娜, 连培园, 等. 高频段大型反射面天线热变形补偿技术. 北京: 科学出版社, 2018: 77
- [18] Barnes S L. *Journal of Applied Meteorology and Climatology*, 1964, 3: 396
- [19] Askelson M A, Aubagnac J P, Straka J M. *Monthly Weather Review*, 2000, 128: 3050

Predicting the Temperature Field Distribution of Radio Telescope Back-Up Structure on EVSC Unsupervised Feature Selection and MIMO-BP Neural Network

ZHANG Shi-jiao^{1,2} XU Qian^{1,3,4,5} WANG Hui^{1,2} XUE Fei^{1,2} CAO Xiao-man¹

(1 *Xinjiang Astronomical Observatory, Chinese Academy of Sciences, Urumqi 830011*)

(2 *University of Chinese Academy of Sciences, Beijing 100049*)

(3 *Key Laboratory of Radio Astronomy, Chinese Academy of Sciences, Urumqi 830011*)

(4 *Key Laboratory of Xinjiang Radio Astrophysics, Urumqi 830011*)

(5 *Shaanxi Key Laboratory of Antenna and Control Technology, Xi'an 710065*)

ABSTRACT The influence of non-uniform temperature on the back-up structure (BUS) is one of the important factors that causes the accuracy of the main reflector of the radio telescope antenna to decrease. Due to the complex topological structure of the BUS, there are shielding, heat conduction and heat radiation among the rods, which makes the temperature field of the BUS difficult to be accurately obtained and predicted by thermodynamic simulation. In this study, temperature sensors were installed on the BUS of Nanshan 26-meter radio telescope (NSRT) to obtain the BUS temperature data set. Three different unsupervised feature selection (UFS) methods were used to select 16 temperature sensitive points from 66 temperature measurement points, and then these three different sets of temperature sensitive points were used as inputs. MIMO-BP (Multiple Input and Multiple Output - Back Propagation) neural network model is used to train the predicted temperature values of 66 points corresponding to the output, and then the temperature prediction of global continuous points on the BUS is realized by interpolation algorithm. Through calculation and comparative analysis, it is concluded that the unsupervised feature selection method based on eigenvalue sensitive criterion (EVSC) has the best effect on selecting temperature sensitive points. Combined with the BP neural network and Barnes interpolation algorithm, only 16 measured temperature points are used to predict the temperature field distribution of global continuous points on the NSRT's BUS. The root-mean-square error (RMSE) of the predicted value is about 0.707 °C. The research result provides an alternative method for the arrangement of temperature collection points and the acquisition and prediction of temperature field in the BUS of large aperture radio telescope.

Key words telescope, instrumentation: backup structure, methods: UFS (unsupervised feature selection), methods: neural network