



基于Copula函数的热轧支持辊健康状态预测模型

李天伦 何安瑞 邵健 付文鹏 强毅 谢向群

Copula-based model for hot-rolling back-up roll health prediction

LI Tian-lun, HE An-ru, SHAO Jian, FU Wen-peng, QIANG Yi, XIE Xiang-qun

引用本文:

李天伦, 何安瑞, 邵健, 付文鹏, 强毅, 谢向群. 基于Copula函数的热轧支持辊健康状态预测模型[J]. *工程科学学报*, 2020, 42(6): 787–795. doi: 10.13374/j.issn2095–9389.2019.08.26.001

LI Tian-lun, HE An-ru, SHAO Jian, FU Wen-peng, QIANG Yi, XIE Xiang-qun. Copula-based model for hot-rolling back-up roll health prediction[J]. *Chinese Journal of Engineering*, 2020, 42(6): 787–795. doi: 10.13374/j.issn2095–9389.2019.08.26.001

在线阅读 View online: <https://doi.org/10.13374/j.issn2095–9389.2019.08.26.001>

您可能感兴趣的其他文章

Articles you may be interested in

热轧金属横向流动规律及其对板形的影响

Transverse flow law of metals and its effect on the shape of a steel strip

工程科学学报. 2017, 39(12): 1859 <https://doi.org/10.13374/j.issn2095–9389.2017.12.012>

数据驱动的卷取温度模型参数即时自适应设定算法

Data-driven adaptive setting algorithm for coiling temperature model parameter

工程科学学报. 优先发表 <https://doi.org/10.13374/j.issn2095–9389.2019.06.12.002>

轧辊偏移条件下六辊轧机的板形调控特性

Shape-control characteristics of six-high mill with roll offset

工程科学学报. 2017, 39(8): 1188 <https://doi.org/10.13374/j.issn2095–9389.2017.08.008>

基于云理论的隧道结构健康诊断方法

Health diagnosis method of shield tunnel structure based on cloud theory

工程科学学报. 2017, 39(5): 794 <https://doi.org/10.13374/j.issn2095–9389.2017.05.019>

精密轧机的辊型电磁调控工艺参数

Roll profile electromagnetic control process parameters in precision rolling mill

工程科学学报. 2017, 39(12): 1874 <https://doi.org/10.13374/j.issn2095–9389.2017.12.014>

基于 Copula 函数的热轧支持辊健康状态预测模型

李天伦¹⁾, 何安瑞¹⁾, 邵 健^{1)✉}, 付文鹏²⁾, 强 毅³⁾, 谢向群²⁾

1) 北京科技大学工程技术研究院, 北京 100083 2) 上海梅山钢铁股份有限公司热轧厂, 南京 210039 3) 机械科学研究总院, 北京 100044
✉通信作者, E-mail: jianshao@ustb.edu.cn

摘 要 热轧支持辊的健康状态在带钢板形质量和轧制稳定性控制中起着关键作用, 非线性、强耦合、少样本等特点使得热轧支持辊健康状态的预测复杂, 目前各大钢厂仍以定期维护和事后维修为主. 本文提出了一种支持辊虚拟健康指数的构建方法以及基于 Copula 函数的复杂工况健康状态预测模型. 首先结合支持辊弯窜辊数据表征支持辊健康状态, 再使用 K-means 聚类方法对支持辊工况进行划分, 将各工况下过程数据分别构建 Copula 预测模型, 最后根据实际轧制计划的排布顺序融合各工况模型的预测结果. 提出的基于 Copula 函数的预测模型在某钢厂 1780 热连轧产线得到应用, 结果表明, 该模型能够准确有效的按照轧制计划实现支持辊的健康状态预测, 以更科学的策略指导支持辊更换维护.

关键词 支持辊; 健康状态预测; Copula 函数; 数据驱动; 板形

分类号 TG333.7

Copula-based model for hot-rolling back-up roll health prediction

LI Tian-lun¹⁾, HE An-rui¹⁾, SHAO Jian^{1)✉}, FU Wen-peng²⁾, QIANG Yi³⁾, XIE Xiang-qun²⁾

1) Institute of Engineering Technology, University of Science and Technology Beijing, Beijing 100083, China

2) Hot Rolling Plant, Meishan Iron & Steel Co. Ltd., Nanjing 210039, China

3) China Academy of Machinery Science and Technology, Beijing 100044, China

✉ Corresponding author, E-mail: jianshao@ustb.edu.cn

ABSTRACT The health condition of hot-rolling back-up rolls plays a key role in controlling the strip profile quality and rolling stability. The characteristics of nonlinearity, strong coupling, and the use of limited samples complicate the prediction of the back-up roll health state. The current back-up roll replacement strategy of each steel mill is generally determined according to a certain rolling time or rolling kilometer, and such a maintenance mode is based on experience. In actual experience, due to different strip specifications in each rolling cycle, the degrees of wear on the back-up rolls are different. Regular maintenance methods may easily lead to excessive wear of the back-up rolls and reduce the quality of the strip shape at the end of the unit, or premature roll replacement wastes the back-up roll performance. This paper proposed a construction method for the back-up roll virtual health index and a Copula function-based model for predicting the health condition of complex working conditions. The health condition of a pair of back-up rolls was characterized by combining roll bending and shifting data, and the back-up roll condition was divided by the K-means clustering method. The Copula prediction model was constructed using the process data under each working condition, and finally, according to the actual rolling schedule, the arrangement order combines the prediction results of the working conditions. The production performance data of a 1780-mm hot rolling line were used to verify the results. The results show that the proposed Copula-based prediction model can accurately and effectively predict the health condition of the back-up roll according to the rolling schedule; thus, it can serve as the basis of a more scientific strategy to guide the replacement and maintenance of the back-up roll.

KEY WORDS back-up roll; health prognostics; Copula function; data-driven; profile and flatness

收稿日期: 2019-08-26

基金项目: 国家自然科学基金资助项目 (51674028); 创新方法专项资助项目 (2016IM010300)

支持辊作为热轧机的重要损耗备件, 因其制造周期长、服役周期长、使用成本高、异常失效后损失大等特点, 在各大钢厂属重点管理产品^[1]。支持辊的工作环境非常恶劣, 在热轧过程中, 轧辊磨损和热凸度使其在长期服役中出现轴向不均匀磨损, 磨损导致的辊形变化使辊间接触压力的分布随之变化, 进而改变承载辊缝的形状, 对带钢的板形及其控制性能造成影响^[2]。当支持辊磨损程度较为严重, 即板形控制能力无法满足下游产线要求时, 需要对支持辊进行更换。目前各大钢厂多按照轧制吨位数确定其维护时机, 例如文献 [3] 指出支持辊 F1 ~ F6 机架的换辊周期为 20 万吨、F7 机架的换辊周期为 10 万吨; 文献 [4] 提出了 F1 ~ F4 机架每 15 万吨、F5 ~ F7 机架每 7 万吨更换支持辊的维护制度。不同产线间换辊制度的差异一般与其轧辊材质、产品结构、工艺制度等有关。上述换辊模式属于典型的定期维护, 容易存在设备的不及时维护或过度维护, 对热轧最终产品的板形质量造成影响, 同时增加了企业的生产成本。

由于轧制过程中支持辊的磨损机理复杂, 不同品种的带钢在热轧过程中对其影响也不尽相同, 难以直观发现支持辊的失效或故障状态并对其表征。此外, 支持辊的换辊周期较长, 剔除异常数据后并不能获得足够的样本数据集, 也对支持辊健康状态的预测造成了一定困难。为了实现复杂工业系统从状态监控到健康管理的转变, 美国军方最先提出了故障预测与健康管理工作 (Prognostics and health management, PHM), 使其节省了 30% 的维修费用^[5-6]。我国在军工、航天等领域也进行了 PHM 技术的应用探索^[7-9]。工程应用方面, 依据机理模型从振动信号中分析发现故障特征的方法在轴承^[10-12]、行星齿轮箱^[13-14]等旋转机械设备的故障诊断中取得了良好的效果。近年来随着信息技术的发展, 基于数据驱动的使用寿命预测方法逐渐成为研究热点并取得了一定成果。人工神经网络^[15-16]、支持向量机^[17-19]、贝叶斯回归模型^[20-21]、相似性^[22]等方法在 PHM 领域均取得了一些成果, 但从文献中可以看出, 目前研究重点在于如何通过算法实现高精度寿命预测, 所用的数据源通常比较理想、规整, 较少考虑到设备所处的外部环境特点, 特别是输入的不确定性、多维度、少样本对预测结果的影响。本文使用数据驱动建模的方法, 依据轧制周期中弯辊工艺的使用特性建立参数表征支持辊健康状态, 之后考虑轧制过程的复杂性对工况进行聚类划分, 再在各工况下

对支持辊健康状态进行基于 Copula 函数的数据建模并融合预测结果, 达到对复杂工况下支持辊健康状态预测的目的, 最后使用某钢厂 1780 热连轧产线支持辊数据进行实验验证。

1 支持辊健康状态建模

1.1 VHI 的构建方法

在热轧过程中, 没有信号能够直接反应支持辊的健康损耗, 可考虑使用多个数据信号组合传递信息来表征支持辊的寿命退化特征, 即虚拟健康指数 (Virtual health index, VHI)。随着涡流、超声、磁粉等无损探伤手段在轧辊下机检测中得到普及应用, 由轧辊疲劳或裂纹累计导致的轧辊剥落、爆辊等失效事故有效减少^[23], 目前热轧环节的支持辊换辊时机主要由板形质量决定, 因此考虑从轧机对板形的控制能力角度间接构建 VHI。通常, 热轧机的板形调控手段主要有弯辊、窜辊两种, 支持辊使用后期二者均处于极限位置的概率增大, 甚至长期保持在极限位置, 导致板形控制能力丧失。综合生产过程中弯窜辊的数值变化构建轧机支持辊的 VHI, 以此表征带钢板形的剩余控制能力, 即可描述支持辊的健康状态。

以某 1780 热连轧产线为案例, F1 ~ F7 机架工作辊均使用连续可变凸度 (Continuous variable crown, CVC) 辊形。设轧辊轴向窜动的行程范围 $s \in [-s_m, s_m]$, 及相应的辊缝凸度范围 $C_w \in [C_1, C_2]$, 则利用辊缝凸度与轧辊轴向窜动量的线性关系, 可求得任意窜辊量的辊缝凸度:

$$C = \frac{C_2 - C_1}{2s_m} \cdot s + C_0 \quad (1)$$

式中, C_0 为不窜辊即 $s=0$ 时的辊缝凸度。

通过二维变厚度有限元方法离线计算, 然后经多元非线性回归得到的承载辊缝及弯辊力系数计算模型的表达式如下^[24]:

$$C_m = k_p P + k_f F_w + k_{wC} C_{wC} + k_{wE} C_{wE} + k_{BC} C_{BC} + k_{BE} C_{BE} + k_{CWR} C_{CWR} + C_{con} \quad (2)$$

式中, k_p 为轧制力影响系数; P 为轧制力设定值; k_f 为弯辊力影响系数; F_w 为弯辊力设定值; k_{wC} 为工作辊中部辊形影响系数; C_{wC} 为工作辊中部辊形特征值; k_{wE} 为工作辊边部辊形影响系数; C_{wE} 为工作辊边部辊形特征值; k_{BC} 为支持辊中部辊形影响系数; C_{BC} 为支持辊中部辊形特征值; k_{BE} 为支持辊边部辊形影响系数; C_{BE} 为支持辊边部辊形特征值; k_{CWR} 为工作辊初始辊形影响系数; C_{CWR} 为工作辊初始辊形特征值; C_{con} 为常数项, 其值与机架间

凸度分配策略及自学习有关。其中弯辊力与工作辊辊形对板形机械凸度的影响互为可逆,即存在成对出现的 F_W 、 C_{CWR} 数值,保持式中其他系数不变,则可以求得单位弯辊力与窜辊数值的换算关系为:

$$\Delta s = K_s \Delta F_W, K_s = -\frac{4k_f s_m}{k_{CWR}(C_2 - C_1)} \quad (3)$$

式中: ΔF_W 为工作辊为调整板形所增加的弯辊力数值, kN; Δs 为由工作辊弯辊值变化对应换算的等效窜辊值, mm。将弯窜辊的作用综合在一起,即可使用一个变量描述支持辊的健康状态,即 VHI, 如式(4)所示:

$$VHI = \frac{S_{RBF} + S_{RSH}}{2S_m} = \frac{[K(d_{RBF0} - d_{RBF})] + (S_{RSH} + S_m)}{2S_m} \quad (4)$$

式中: S_{RBF} 和 S_{RSH} 分别为弯辊和窜辊对板形的作用值; d_{RBF0} 和 d_{RBF} 分别为弯辊力的平衡值与实际值, kN; S_{RSH} 为窜辊值, mm; $[K(d_{RBF0} - d_{RBF})]$ 为弯辊力偏移量的等效窜辊。理论初始状态下设定弯辊力为 d_{RBF0} , 窜辊处于 $-S_m$ 的极限位置, 代入公式 $VHI=0$, 随着轧制计划的推进工作辊逐渐正窜, VHI 数值随之增长; 当设定弯辊力 d_{RBF0} , 窜辊处于 S_m 极限位置时辊系的控制能力到达极限, 不能继续对板形进行有效调控, 此时 $VHI=1$, 定义为支持辊理论失效点。实际生产中由于设定弯辊力过大或过小, 极限状态下会使 VHI 的数值超出理论范围, 此时取理论上下限值处理, 转化后的 VHI 范围区间为 $[0,1]$, 适合用于支持辊健康状态的表征。

在实际生产中, 更换支持辊对生产效率影响较大, 考虑和上下游检修的生产匹配, 支持辊的更换通常以批量更换为主, 一般当 F7 机架支持辊失效时则更换全部机架或下游 F5 ~ F7 机架的支持辊, 因此上述处理方法计算产生的 F7 机架 VHI 可以较为准确的描述支持辊生命周期内的退化特征, 满足后续预测模型的要求。

使用某钢厂 1780 热连轧产线的支持辊数据, 在连续 8 个月的时间内收集到 F7 机架有效数据 5 组, 具体情况如表 1 所示, 按照 4 组训练集 1 组测试集的比例划分数据, 进行交叉验证完成建模过程。将支持辊完整轧制单元的弯窜辊数据带入公式计算, 由于 F7 机架对带钢热轧出口板形起决定性作用, 其 VHI 数据表现出明显的随轧制计划推进而上升的带状分布趋势(以 1#数据为例), 如图 1 所示。

表 1 某钢厂 1780 热连轧产线 F7 机架支持辊使用情况统计

Table 1 Statistics on the use of F7 back-up roll in a 1780 hot rolling line

Data number	Total number of rolled strips	Total rolling weight/t	Total rolling length /km
1#	15016	336000	12015
2#	16024	356000	13216
3#	17654	388900	15015
4#	14168	308000	12282
5#	16291	362300	13596




图 1 F7 机架 VHI 数据(1#)表现出随轧制计划推进而上升的趋势

Fig.1 Rising trend of F7 stand VHI data (1#) with the rolling schedule

1.2 VHI 带状分布区间工况剥离

图 1 所构建的 VHI 数据虽然具有单调趋势, 但其上升趋势呈带状分布且范围宽泛, 若将该数据直接用于后续预测步骤, 数据的不确定性会对最终的预测结果带来较大误差。轧制过程中弯窜辊的设定值主要受带钢规格及变形抗力等因素影响, VHI 数据的带状分布也由二者的差异导致。因此, 使用 K-means 聚类方法对 VHI 数据进行预处理, 选择带钢的变形抗力和宽厚比两维数据作为聚类算法的输入, 将带钢按照变形抗力大小分为 3 个不同强度类别, 按照带钢厚度差异分为 3 个不同规格类别, 即在变形抗力、宽厚比两个维度上的数据各分为 3 档, 由此确定聚类数为 9。对轧制条件不同的数据划分不同的工况, 在不损失数据信息的情况下降低数据噪音。

K-means 聚类的运算结果如图 2 所示, 其中横坐标为带钢变形抗力, 纵坐标为宽厚比。将聚类结果中的每一个簇视作一种工况, 据此对 F7 机架的原始 VHI 数据进行拆分, 得到某轧制计划内单一工况下的支持辊健康状态衰减趋势, 以 1#数据-工况 1 为例, 该工况代表变形抗力较大而宽厚比处于较低档位的带钢样本, 如图 3 所示。可见工况剥离后 VHI 数据的带状区间宽度从 0.5 下降至 0.3 左右, 集中效果明显, 由于轧辊磨损对轧制过程中弯窜辊的设定值也有影响, 带状区间无法完全消除。




图 2 K-means 聚类结果示意图

Fig.2 K-means clustering results




图 3 原始数据统一聚类后 1#数据-工况 1 效果图

Fig.3 Working condition 1 of 1# data after clustering

支持辊的 VHI 应是单调递增的, 虽然对 F7 机架的 VHI 数据进行了工况剥离处理, 但仍存在较大的数据波动, 因此需要对各工况的 VHI 数据进行降噪和单调处理, 使其满足支持辊健康状态单调的物理意义, 以便顺利进行算法后续步骤. 实际情况下支持辊的磨损情况会随轧制计划的推进逐渐劣化, 支持辊磨损的累积以及磨损不均使其健康状态的衰减速率逐渐增加, 因此选用指数函数 $y = ke^{ax}$ 的形式对 VHI 数据进行拟合, 得到的单工况理想化训练集 VHI 曲线如图 4 所示(以工况 1 为例).

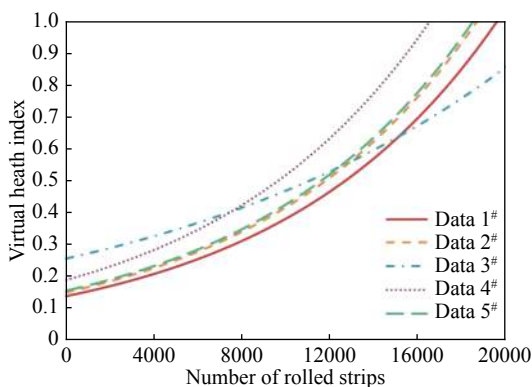


图 4 工况 1 支持辊 VHI 数据拟合降噪后结果示意图

Fig.4 Result of noise reduction after fitting VHI data of working condition 1

2 基于 Copula 函数的数据建模方法

大多数数据驱动的预测方法均需要基于某些函

数关系的假设, 例如回归方法中函数表达式的结构, 神经网络中节点数与激活函数的设置等. 支持辊寿命预测问题中数据高维、不确定性等特点使得算法难以找到合适的函数关系, 加之支持辊服役周期较长, 难以获得大量的运行-失效数据, 为支持辊健康状态的准确预测带来了困难. 将 Copula 函数的性质运用于数据预测中, 可以建立数据集在不同时刻间的分布关系, 消除了剩余使用寿命与表征信号之间函数关系的假设, 建立一个通用的统计关系取而代之, 同时统计模型可以按照分布规律产生大量数据样本, 使得预测算法只由可用的训练数据集驱动.

2.1 Copula 函数在数据预测中的应用

Copula 函数描述变量间的相关性, 其理论核心为 Sklar 定理, 可以表述为^[25]: $F(x_1, x_2, \dots, x_n) = C(F_1(x_1), F_2(x_2), \dots, F_n(x_n))$, 其中 $F_1(x_1), F_2(x_2), \dots, F_n(x_n)$ 为分散的 n 个边缘分布函数, 使用某一类型的 Copula 函数 $C(u_1, u_2, \dots, u_n)$ 连接形成他们的联合分布函数 $F(x_1, x_2, \dots, x_n)$. 若将某变量不同时刻数值的分布看作边缘分布, 通过 Copula 函数的连接则可以研究某变量在时间序列上不同时刻间的联系与变化关系, 利用这一特性即可将 Copula 函数运用到数据预测中. 此外, 由于 Copula 函数是以概率分布的形式描述边缘分布之间的关系, 只要能够求得预测数据的分布情况即可使用 Copula 预测方法完成预测, 可见基于 Copula 函数的预测方法可以满足对于预测结果的概率分布输出要求, 且对数据集体量的需求较小, 比较适合用于少样本下的寿命预测.

2.2 使用 Copula 函数进行预测的建模步骤

基于 Copula 函数的健康状态预测需要在已知某时刻真实健康状态分布的情况下来确定之后可能达到失效状态的时间点. 在支持辊健康状态预测的研究中, 需要将 VHI 指数离散成一定数量的退化等级, 之后建立某一等级 T_n 与最终失效等级 T_{end} 支持辊健康状态之间的相关关系. 其建模过程如图 5 所示, 具体实施步骤在下一章以实例形式给出.

3 单工况 Copula 模型的建立过程

3.1 VHI 曲线的离散化处理

一个测试单元的支持辊 VHI 会在不同时刻表现出不同的健康状态, 在已知工况数据下按一定间隔确定若干时刻, 划分为退化等级 T_i , 其中 i 的范围从 1 到 j , j 为模型划分的退化等级数量, 即可描

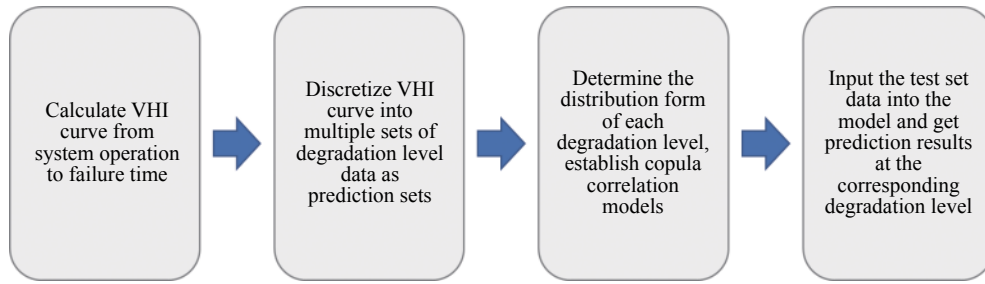


图5 使用 Copula 函数预测支持辊健康状态的建模流程图

Fig.5 Flow chart for predicting the health of back-up roll using Copula function

述支持辊在不同时刻下 VHI 的分布情况。本研究将各工况测试数据集中 VHI 的最小值作为建模起点，以支持辊失效标志即 VHI 值达到 1 时作为建模终点，在建模区间内等距划分 50 个健康状态退化等级，每个退化等级 T_i 分别与失效退化等级 T_{50} 建立联合分布模型，得到 50 组不同类型 Copula 函数构成的 $T_i - T_{50}$ 数据模型，每个模型中均包含 4 组训练集数据及按 Copula 函数分布得到的补充数据，退化等级的划分示意图如图 6 所示。其中左侧表示数据集 VHI 值分别到达退化等级 T_i 、 T_{50} 时的轧制块数值，到达 T_i 的轧制块数记为 $t_{i-1}, t_{i-2}, t_{i-3}, t_{i-4}$ ，到达 T_{50} 的轧制块数记为 $t_{50-1}, t_{50-2}, t_{50-3}, t_{50-4}$ ，纵坐标均为退化等级对应的 VHI 值，右侧四个圆圈为训练集数据点，大面积实点为由 Copula 模型计算扩充而来的训练数据集；横坐标为数据点在 T_i 等级时已经轧制的块数值，纵坐标为其在 T_{50} 等级时轧制达到的块数值。

3.2 最佳 Copula 函数类型的确定

在利用 Copula 理论对多元分布函数进行建模时，不同类型的 Copula 函数有着各自的适用范围，一般可以通过联合分布数据集与各类 Copula 函数的分布形式对比来匹配合适的参数。但对于数据量稀少的情况，无法通过观察得到准确的联合分布形式，使用极大似然估计方法在 Gumbel、Frank、

Clayton 3 种常见类型中选择确定各个 $T_n - T_{50}$ 数据模型匹配的 Copula 函数类型。

对于本案例使用的数据，需要将某一时刻 T_n 与失效等级 T_{50} 间的支持辊轧制块数进行 Copula 建模，认为各失效等级下的数据均符合正态分布，考虑联合分布函数 C 和各变量边缘分布 F_n 都是连续的情形，其似然函数可以写作：

$$L(\theta) = C(F_n(x_n), F_{50}(x_{50})) \prod_n F_n(x_n; \theta) \quad (5)$$

将某时刻支持辊达到轧制块数的概率分布 u 与最终时刻支持辊达到轧制块数的概率分布 v 带入到 3 种不同 Copula 函数的概率密度函数中，利用极大似然方法分别求得每种 Copula 函数对应的最大似然估计值 $\hat{\theta}_{\text{Gumbel}}$ 、 $\hat{\theta}_{\text{Frank}}$ 、 $\hat{\theta}_{\text{Clayton}}$ ，之后得以选出三者中最优的 Copula 类型用作当前时刻的退化等级建模。图 7 为 3 种不同类型函数扩充得到的 Copula 模型典型样本，可见扩充数据的分布形式（头部发散、两端发散、尾部发散）差别明显，随退化等级的推进数据分布逐渐收敛，说明使用极大似然估计确定最优 Copula 类型的方法是可行的。

3.3 提高模型适应性的平移处理

由于退化等级的划分层数有限，加之训练集数据量不足，某些退化等级对应的 Copula 相关性




图6 对单工况训练集数据划分退化等级示意图

Fig.6 Data degradation level for single-working-condition training set




图 7 处于不同退化等级下的分布模型适用于不同类型的 Copula 函数描述。(a) $T_{12}-T_{50}$, Gumbel; (b) $T_{26}-T_{50}$, Frank; (c) $T_{46}-T_{50}$, Clayton

Fig.7 Distribution models at different degradation levels fit for different types of Copula function descriptions: (a) $T_{12}-T_{50}$, Gumbel; (b) $T_{26}-T_{50}$, Frank; (c) $T_{46}-T_{50}$, Clayton

模型可能无法完全代表特定时间内测试集数据样本的分布形式。发生这种情况时,测试数据集可能达到某一退化等级的时刻过早(模型数据集左侧)或过晚(模型数据集右侧),如图 8(a)所示,导致式(5)计算条件概率密度函数时无法取到对应的数值。

这一问题可以将 Copula 模型进行变换得以解决,如图 8(b)所示。若测试集相对于训练集数据更早到达退化等级,将 Copula 模型的中心向左平移,这样就可以利用 Copula 相关性模型得到测试集达到该等级剩余健康寿命的条件概率密度函数。然而为了获得等效的条件概率密度函数,若由于测试集到达退化等级的时间与训练集差别较大,求得的失效时间应该相应的进行增(对应模型向右平移)减(对应模型向左平移),作为退化速率的补偿。

3.4 预测结果的获取

对热轧支持辊的健康状态进行预测时,预测曲线会经过若干个退化等级,每个退化等级对应的 $T_i - T_{50}$ 模型均会给出支持辊最终失效时间的预测区间与概率分布,最终的预测结果需要结合每个模型给出。理论上如果 VHI 达到所有退化等级 T_1, \dots, T_j 的概率密度函数均是可用的,那么就可以使用 Copula 函数将 VHI 先后到达任意两个退化等

级 T_i 和 $T_N (N > i)$ 的二元概率密度函数构建出来,使用式(6)可以近似支持辊最终失效时间 T_{50} 的条件概率密度函数。其中 β 为归一化参数,使得概率密度函数在整个域上的积分等于 1。

$$f(T_{50} | T_1 = a_1, T_2 = a_2, \dots, T_j = a_j) \cong \beta \prod_{i=1}^j f(T_{50} | T_i = a_i) \quad (6)$$

单工况 Copula 模型的预测结果如图 9 所示,其中横坐标表示支持辊已轧块数,纵坐标为预测得到的支持辊在当前工况健康状态下的剩余可轧块数,阴影部分代表预测值的置信区间,阴影中间的实线为预测点对应的预测值。

4 复杂工况下预测结果的融合

4.1 单工况预测结果的转化

单工况数据集在完成 Copula 预测前后,描述支持辊健康状态的尺度发生了改变。Copula 模型的原始输入为 VHI 随轧制块数的变化关系,如图 4 所示;而 Copula 最终输出的是时间序列内每一时刻已轧块数与预测剩余轧制块数之间的数据对应关系。这一过程中 y 轴的数据意义,即设备健康评价尺度发生了变化,对于单工况 Copula 模型无碍,

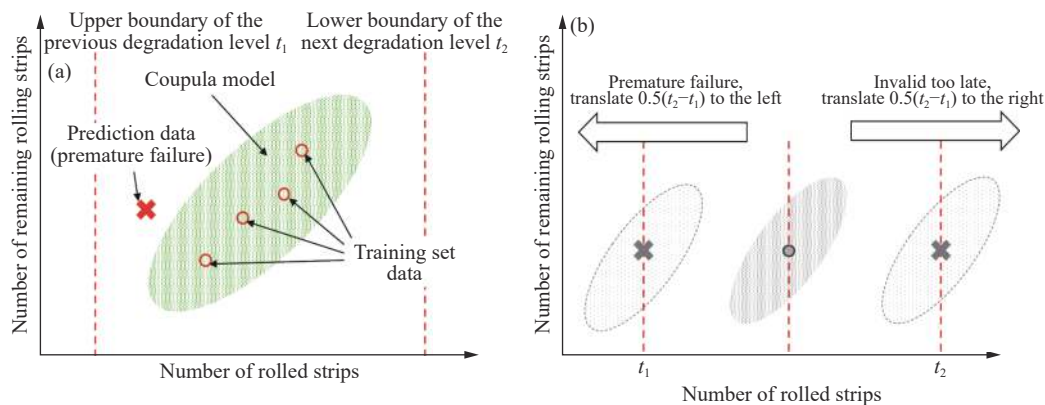


图 8 提高模型适应性的平移处理。(a)过早失效时 Copula 模型无法预测;(b) Copula 模型平移

Fig.8 Translation processing to improve model adaptability: (a) Copula model is unpredictable at premature failure; (b) translation of copula model




图9 单工况 VHI 预测结果

Fig.9 Single-condition VHI prediction result

但若联合多个 Copula 模型进行动态预测, 需要保留 VHI 作为中间参数, 用于不同工况间的等效换算, 以及设备真实寿命极限的评估。

基于以上考虑, 希望将各工况单独的预测结果统一还原为 VHI 尺度, 以便各工况预测结果的相互融合, 同时避免一次人为干预。图 9 中的横纵坐标分别为每一个预测点的已轧制块数与剩余轧制块数, 理论上二者之和为一定值, 由此可以给出 VHI 转化公式如下: 其中 x 为预测点已轧制带钢块数, y 为预测点剩余带钢轧制块数, Δy_{0m} 为第 m 个训练集数据的 VHI 分布范围, 公式等号左边为预测点转换求得的 VHI 数值。

$$VHI = \left(1 - \frac{y}{x+y}\right) \times \Delta y_{0m}, m = 1, 2, 3, 4 \quad (7)$$

将各工况 Copula 模型的预测结果代入式(7)中, 得到单工况预测结果的 VHI 尺度描述如图 10 所示, 其中阴影部分代表 VHI 预测值的最大最小值范围, 阴影中间的实线为预测点对应的预测值, 可见描述尺度的变化并未对预测结果的趋势造成任何改变。




图10 经过 VHI 变尺度处理的单工况预测结果

Fig.10 Single-condition VHI prediction result after scale conversion

4.2 复杂工况预测结果融合

解决各工况预测结果的评价尺度问题后, 即可按照测试数据集的轧制计划融合各工况的单独预测结果。考虑轧件在轧制周期不同阶段对支持辊健康程度的影响差异, 利用各预测点邻域范围内的 VHI 数据计算支持辊短期健康退化率描绘其衰减路径, 具体流程如下:

第一步: 将各工况模型预测结果全部转换为 VHI 尺度, 并按照先前聚类结果划分测试数据集内各个样本的工况, 完成准备工作;

第二步: 按轧制计划序列进行预测结果融合, 选择测试集数据点对应工况对应位置邻域内的数据按一次拟合方式计算短期健康退化率, 求得该点退化率后描绘单位步长(单块带钢)的融合退化曲线; 其中融合预测结果的起点由测试集轧制计划第一块带钢的设定参数计算 VHI 值得来, 当预测数据点处于轧制单元头尾位置时邻域范围不变;

第三步: 往复进行第二步工作, 完成测试集全长的退化曲线, 由于测试集数据点在轧制周期内位置不同, 相同工况各点的健康状态退化率也会存在差异;

第四步: 待融合预测曲线描绘一定长度后, 其预测结果趋于稳定准确, 分析预测性能衰减曲线, 可以为生产计划排布、检修时机安排等提供参考。

4.3 现场生产数据验证

将数据集数据按照交叉验证方法轮流作测试集, 按照上述过程融合得到复杂工况预测结果共 5 组, 如图 11 所示。最终结果与构建的 VHI 曲线形貌相似, 当预测 VHI 到达 0.7 时, 对应的轧制块数范围在 13233 ~ 15253 块之间, 可见轧制计划的不同对支持辊的寿命衰减影响明显, 每块带钢由于所属工况及在生产计划中位置不同, 对支持辊健康状态的消耗是不同的。测试集所使用的数据来自现场生产实况, 最后一块带钢下线时支持辊的 VHI 并未达到理论极限值, 这是由于现行维护策略综合考虑现场检修时机和后续轧制计划安排的情况下支持辊未充分使用, 导致 VHI 在实际应用中不能达到理论极限。

对预测模型的计算结果进行评价, 考虑到实际 VHI 数值的带状特性, 取最后一个工作辊换辊周期, 根据弯窜辊数据计算每块带钢轧制后支持辊的实际 VHI, 并求平均值作为实际下机 VHI。模型预测 VHI 取轧制计划最后一块带钢下机时的模型融合预测结果。对比 5 组融合预测结果的对比情况如表 2 所示, 可见预测误差均在 10% 以内, 效果理想。

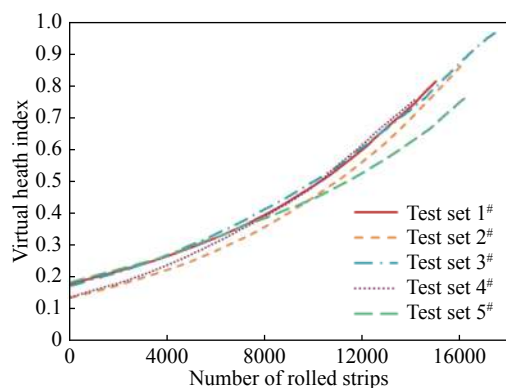


图 11 融合预测结果示意图

Fig.11 Fusion prediction result diagram

表 2 复杂工况下 Copula 模型融合预测结果

Table 2 Copula model fusion prediction results under complex conditions

Test set number	Actual number of rolled strips	Actual VHI	Predict VHI	Model error/%
5 [#]	16291	0.726	0.769	5.85
4 [#]	14168	0.831	0.758	-8.74
3 [#]	17654	0.909	0.976	7.34
2 [#]	16024	0.825	0.862	4.42
1 [#]	15016	0.891	0.815	-8.54

融合结果误差的产生原因除模型预测误差外,还与 VHI 数据的带状分布特征有关。若将该模型应用至现场生产,可以在支持辊使用末期预测多种轧制计划下的剩余 VHI,考虑轧辊磨损对弯窜辊设定值的影响,选择合适的排布方案将支持辊使用至预测 VHI 接近 0.9 时再安排换辊,最大化利用其健康寿命,以此有效提升支持辊健康状态下的轧制块数,节省停机时间,说明支持辊 Copula 模型对支持辊换辊时机的安排具有积极意义。

5 结论

(1) 考虑支持辊濒临失效时板形调控手段到达极限的特点,使用某钢厂 F7 机架弯窜辊数据构建虚拟健康指标表征支持辊的健康状态,并将带钢的宽厚比和变形抗力两维数据带入 K-means 聚类算法,完成了轧制工况的划分,经过工况划分的训练集数据带状分布特征明显减小;

(2) 由于支持辊的换辊周期较长,训练集能够使用的数据条目较少,传统的数据预测方法如神经网络等并不适用于这类情况。利用 Copula 函数的特性将其应用于数据预测中,利用少量数据集找到其符合的分布形式,使得数据量得以扩充,能够顺利完成单工况下支持辊剩余健康状态的预

测,证明基于 Copula 函数的预测方法在训练数据集稀少的情况下具有优势;

(3) 结合各单独工况下支持辊剩余健康状态的预测结果及现场生产轧制计划,将复杂工况混合轧制情况下支持辊剩余健康状态的预测结果融合,并在最后利用预测结果提出了最大化利用支持辊健康寿命的换辊策略,证明了预测模型的适用性和准确性,该流程同样适用于钢铁生产领域中其他关键设备的寿命预测问题。

参 考 文 献

- [1] Shen Y M. Introduction of application technology of backup roll in Baosteel. *Steel Roll*, 2004, 21(1): 55
(沈一鸣. 宝钢支撑辊的使用技术. *轧钢*, 2004, 21(1): 55)
- [2] He A R, Zhang Q D, Cao J G, et al. Effect of back-up roll profile in hot wide strip mill on the strip profile and flatness. *J Univ Sci Technol Beijing*, 1999, 21(6): 565
(何安瑞, 张清东, 曹建国, 等. 宽带钢热轧支撑辊辊形变化对板形的影响. *北京科技大学学报*, 1999, 21(6): 565)
- [3] Li Z W, Gao S H, Han L W, et al. Chenggang Company 1780 save backup roll roll change time // *Proceedings of the 10th CSM Steel Congress & the 6th Baosteel Biennial Academic Conference*. Shanghai, 2015: 623
(李子文, 高少华, 韩立伟, 等. 承钢 1780 节约支撑辊换辊时间 // 第十届中国钢铁年会暨第六届宝钢学术年会论文集. 上海, 2015: 623)
- [4] Shi Z Y, Jing T, Dong B Q, et al. Application optimization of BUR according to the mill features // *2011 CSM Annual Meeting Proceedings*. Beijing, 2011: 2882
(史志勇, 荆涛, 董宝权, 等. 结合热轧机组特点合理使用支撑辊 // 第八届中国钢铁年会论文集. 北京, 2011: 2882)
- [5] Alford L D. The problem with aviation COTS. *IEEE Aerosp Electron Syst Mag*, 2001, 16(2): 33
- [6] Gartner D L, Dibbert S E. Application of integrated diagnostic process to non-avionics systems // *2001 IEEE Autotestcon Proceedings. IEEE Systems Readiness Technology Conference*. Valley Forge, 2001: 229
- [7] Peng Y, Liu D T, Peng X Y. A review: prognostics and health management. *J Electron Meas Instrum*, 2010, 24(1): 1
(彭宇, 刘大同, 彭喜元. 故障预测与健康管理系统综述. *电子测量与仪器学报*, 2010, 24(1): 1)
- [8] Ma S S, Xu A H, Zhang Q X, et al. The security monitoring and health management system for UAV. *Aviat Mainten Eng*, 2009(4): 63
(马飒飒, 许爱华, 张群兴, 等. 无人机安全监控与健康管理系统研究. *航空维修与工程*, 2009(4): 63)
- [9] Yang L F, Wang L, Feng J C. Maintenance support of missile based on PHM technology. *J Naval Aeron Astron Univ*, 2010, 25(4): 447

- (杨立峰, 王亮, 冯佳晨. 基于PHM技术的导弹维修保障. *海军航空工程学院学报*, 2010, 25(4): 447)
- [10] Zhang D, Feng Z P. Fault diagnosis of rolling bearings based on variational mode decomposition and calculus enhanced energy operator. *Chin J Eng*, 2016, 38(9): 1327
(张东, 冯志鹏. 基于变分模式分解和微积分增强能量算子的滚动轴承故障诊断. *工程科学学报*, 2016, 38(9): 1327)
- [11] Liu Y B, Zhou Y K, Feng Z P. Application of morphological component analysis for rolling element bearing fault diagnosis. *Chin J Eng*, 2017, 39(6): 909
(刘永兵, 周亚凯, 冯志鹏. 形态分量分析在滚动轴承故障诊断中的应用. *工程科学学报*, 2017, 39(6): 909)
- [12] Zhang J L, Yang J H, Tang C Q, et al. Bearing fault diagnosis by stochastic resonance method in periodical potential system. *Chin J Eng*, 2018, 40(8): 989
(张景玲, 杨建华, 唐超权, 等. 基于周期势系统随机共振的轴承故障诊断. *工程科学学报*, 2018, 40(8): 989)
- [13] Zhao C, Feng Z P. Localized fault identification of planetary gearboxes based on multiple-domain manifold. *Chin J Eng*, 2017, 39(5): 769
(赵川, 冯志鹏. 基于多域流形的行星齿轮箱局部故障识别. *工程科学学报*, 2017, 39(5): 769)
- [14] Zhang D, Feng Z P. Application of iterative generalized short-time Fourier transform to fault diagnosis of planetary gearboxes. *Chin J Eng*, 2017, 39(4): 604
(张东, 冯志鹏. 迭代广义短时Fourier变换在行星齿轮箱故障诊断中的应用. *工程科学学报*, 2017, 39(4): 604)
- [15] Gugulothu N, Tv V, Malhotra P, et al. Predicting remaining useful life using time series embeddings based on recurrent neural networks // *ACM SIGKDD Workshop on Machine Learning for Prognostics and Health Management*. Halifax, 2017
- [16] Guo L, Li N P, Jia F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings. *Neurocomputing*, 2017, 240: 98
- [17] Huang H Z, Wang H K, Li Y F, et al. Support vector machine based estimation of remaining useful life: current research status and future trends. *J Mech Sci Technol*, 2015, 29(1): 151
- [18] Liu J, Zio E. SVM hyperparameters tuning for recursive multi-step-ahead prediction. *Neural Comput Appl*, 2017, 38: 3749
- [19] Gao M Z, Xu A Q, Xu Q. Online condition prediction of electronic equipment based on relevance vector machine with adaptive Kernel learning. *J Ordnance Equip Eng*, 2017, 38(11): 108
(高明哲, 许爱强, 许晴. 基于aRVM的电子设备状态在线预测方法. *兵器装备工程学报*, 2017, 38(11): 108)
- [20] Zermani S, Dezan C, Chenini H, et al. FPGA implementation of Bayesian network inference for an embedded diagnosis // *2015 IEEE Conference on Prognostics and Health Management*. Austin, 2015: 1
- [21] Zermani S, Dezan C, Euler R, et al. Bayesian network-based framework for the design of reconfigurable health management monitors // *2015 NASA/ESA Conference on Adaptive Hardware and Systems*. Montreal, 2015: 1
- [22] Wang T Y, Yu J B, Siegel D, et al. A similarity-based prognostics approach for remaining useful life estimation of engineered systems // *International Conference on Prognostics and Health Management*. Denver, 2008: 1
- [23] Zhu Y P. Generalization and application of NDT technology in roller testing. *Mech Electr Eng Technol*, 2016, 45(5): 121
(朱扬普. 无损检测技术在轧辊检测中的推广及应用. *机电工程技术*, 2016, 45(5): 121)
- [24] He A R, Shao J, Sun W Q. *Theory and Practice of Shape Control*. Beijing: Metallurgical Industry Press, 2016
(何安瑞, 邵键, 孙文权. 板形控制理论与实践. 北京: 冶金工业出版社, 2016)
- [25] Nelsen R B. An Introduction to Copulas. *Technometrics*, 2000, 42(3): 317