



(12) 发明专利申请

(10) 申请公布号 CN 115169649 A

(43) 申请公布日 2022. 10. 11

(21) 申请号 202210692707.8

G06N 20/10 (2019.01)

(22) 申请日 2022.06.17

G06N 20/20 (2019.01)

(71) 申请人 武汉理工大学

地址 430070 湖北省武汉市洪山区珞狮路
122号

(72) 发明人 李宁 吴亚辉 刘鼎 王李管

王其洲 贾明滔 叶海旺 曹权薪

(74) 专利代理机构 武汉科皓知识产权代理事务

所(特殊普通合伙) 42222

专利代理师 石超群

(51) Int. Cl.

G06Q 10/04 (2012.01)

G06Q 50/02 (2012.01)

G06Q 50/30 (2012.01)

G06N 5/00 (2006.01)

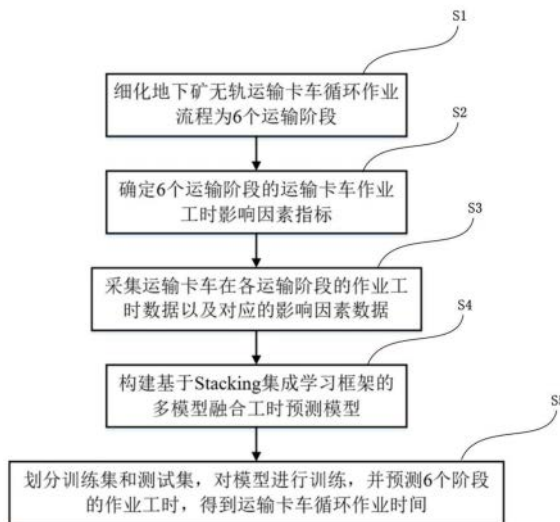
权利要求书2页 说明书7页 附图4页

(54) 发明名称

地下矿山卡车运输循环作业工时集成预测方法

(57) 摘要

本发明提供一种地下矿山卡车运输循环作业工时集成预测方法,包括以下步骤:S1、将无轨运输卡车循环作业过程细化为6个阶段;S2、构建不同运输阶段下的作业工时影响因素指标体系;S3、采集不同运输阶段的卡车作业工时数据及影响因素指标数据;S4、基于Stacking集成学习框架,构建多模型融合的Stacking集成学习工时预测模型;S5、将采集到的作业工时数据以及对应的工时影响因素数据划分为训练集和测试集,以影响因素指标为输入、作业工时为输出,进行训练和测试,得到6个阶段对应的预测模型;通过待预测参数对6个阶段的作业工时分别进行预测,从而得到无轨运输卡车循环作业工时预测值,更符合矿山实际运输情况,提高作业工时预测精度。



1. 一种地下矿山卡车运输循环作业工时集成预测方法,其特征在于,该预测方法包括以下步骤:

S1、针对地下矿无轨运输流程,根据运输卡车状态以及运行环境将无轨运输卡车循环作业过程细化为6个阶段;

S2、分析影响卡车作业时间的因素,构建不同运输阶段下的作业工时影响因素指标体系;

S3、采集不同运输阶段的卡车作业工时数据,并采集对应作业工时影响因素指标数据;

S4、基于Stacking集成学习框架,构建多模型融合的Stacking集成学习工时预测模型;

S5、将所述步骤S3中采集到的作业工时数据以及对应的工时影响因素数据划分为训练集和测试集,以影响因素指标为输入、作业工时为输出,对所述6个阶段对应的模型进行训练和测试,分别得到6个阶段对应的预测模型;通过待预测参数对6个阶段的作业工时分别进行预测,从而得到无轨运输循环作业工时预测值。

2. 根据权利要求1所述的地下矿山卡车运输循环作业工时集成预测方法,其特征在于:

在所述步骤S1中,将卡车从装矿点行驶至卸矿点、再由卸矿点返回至装矿点作为一个循环作业过程,该过程包括3个路段:地下平巷路段、斜坡道路段以及地表路段,根据运输卡车在每个路段上的工作状态将循环作业过程拆分为6个阶段:重车平巷运行阶段、重车斜坡道上行阶段、重车地表运行阶段、空车地表返回阶段、空车斜坡道下行阶段、空车平巷返回阶段。

3. 根据权利要求1所述的地下矿山卡车运输循环作业工时集成预测方法,其特征在于:

在所述步骤S2中,基于实际矿山无轨运输情况,结合每个运输阶段的特点,选取影响运输卡车作业工时的影响因素,对选取的影响因素进行皮尔逊相关性分析,最终得到每个阶段的若干个相互独立的影响因素指标。

4. 根据权利要求3所述的地下矿山卡车运输循环作业工时集成预测方法,其特征在于:

在确定每个运输阶段的影响因素的过程中,根据矿山实际运输情况,在斜坡道路段,基于上下行车辆需要错车的情况,将下行空车错车红灯等待时间作为空车斜坡道下行阶段中影响作业工时的重要因素。

5. 根据权利要求4所述的地下矿山卡车运输循环作业工时集成预测方法,其特征在于:

在所述步骤S3中,通过计算运输卡车发生错车的概率将下行空车错车红灯等待时间分配至每一辆卡车的作业工时中,包括以下过程:

假设路线上正在运行的卡车数量为 N ,平巷路段长度为 L_1 ,斜坡道路段长度为 L_2 ,地表路段长度为 L_3 ,则卡车在斜坡道上需要错车等待的概率 P 为:
$$P = \frac{1}{4} C_N^2 \left(\frac{L_2 \rho_2}{L_1 \rho_1 + L_2 \rho_2 + L_3 \rho_3} \right)^2$$
,式

中, ρ_1 、 ρ_2 、 ρ_3 为卡车在3个路段上的时间系数,表示卡车在对应路段上行驶的难易程度; C_N^2 表示 N 辆车中两辆车相遇的组合数;则分配至每辆卡车行程时间当中的红灯等待时间为: $t_w = T_w \times P$,式中, T_w 为斜坡道下行阶段错车时规定的红灯等待时间。

6. 根据权利要求1所述的地下矿山卡车运输循环作业工时集成预测方法,其特征在于:

在所述步骤S3中,所述作业工时影响因素指标数据包括路面粗糙度指标,并且采用路面图像灰度处理方式计算地下矿无轨运输各路段路面粗糙度。

7. 根据权利要求6所述的地下矿山卡车运输循环作业工时集成预测方法,其特征在於:所述路面图像灰度处理的过程包括以下步骤:

S31、等间隔选取测量路段五个测点,于测点正上方两米且垂直于路面架设照相机,拍摄路面图像;

S32、对获得的路面图像进行灰度处理,得到图像的每个像素点的灰度值;

S33、设每张图像的像素为 $N \times M$, p_{ij} ($i=1, 2, \dots, N; j=1, 2, \dots, M$) 为每个像素点的灰度数据, p_{\max} 为各像素点灰度数据的最大值,则每张图像路面粗糙度 R 的计算公式为:

$$R = \frac{\sum_{j=1}^M \sum_{i=1}^N (p_{\max} - p_{ij})}{N \times M};$$

S34、将五个测点对应的图像路面粗糙度取平均即为测量路段的路面粗糙度,计算公式为: $R_L = \frac{R_1 + R_2 + R_3 + R_4 + R_5}{5}$, 其中 R_L 为测量路段的路面粗糙度, R_1, R_2, R_3, R_4, R_5 为五个测点的路面粗糙度。

8. 根据权利要求1所述的地下矿山卡车运输循环作业工时集成预测方法,其特征在於:在所述步骤S4中,构建多模型融合的Stacking集成学习工时预测模型的过程包括:

S41、基于Stacking集成学习框架,选取随机森林RF、轻量级梯度提升机LightGBM、最小二乘支持向量机LSSVM作为Stacking集成学习框架中的基模型,各基模型的预测结果作为元模型的输入;

S42、选取稳定性和精度均较好的极端梯度提升树XGBoost作为Stacking集成学习框架中的元模型,元模型的输出为最终的预测结果。

9. 根据权利要求4所述的地下矿山卡车运输循环作业工时集成预测方法,其特征在於:

在步骤S5中,以工时影响因素为输入参数,作业工时为输出参数,使用Python构建循环结构,对各单模型的超参数进行迭代,以平均绝对误差MAE作为预测结果的评价指标,寻求各模型的最优超参数。

10. 根据权利要求9所述的地下矿山卡车运输循环作业工时集成预测方法,其特征在於:

在所述步骤S5中,所述无轨运输循环作业工时预测值的过程为:

设6个运输阶段的预测值分别为 $t_1, t_2, t_3, t_4, t_5, t_6$,则无轨运输循环作业工时预测值为: $T_P = \sum_{i=1}^6 t_i + t_w$, 其中, t_w 为分配至每辆卡车行程时间当中的红灯等待时间。

地下矿山卡车运输循环作业工时集成预测方法

技术领域

[0001] 本发明属于采矿装备作业工时预测技术领域,具体涉及一种地下矿山卡车运输循环作业工时集成预测方法。

背景技术

[0002] 矿产资源是人类社会发展的重要物质基础和保障,根据埋藏深度的不同,获取矿产资源的方式主要包括露天开采和地下开采两种。从全球范围来看,地下开采方式仍然占据矿床开发利用的主导地位,随着矿产资源需求量的不断增加,地下矿山的开采规模也不断增大,大量机械化设备的应用已成为全球地下矿山生产建设的必然趋势。构建矿山运输设备实时精准调度系统是实现多装备连续、高效运输作业过程的关键,但目前的地下矿山车辆调度方法都没有考虑到运输设备行程时间对调度准确性的影响,在实际运用过程中容易出现调度计划超前或者滞后的问题。因此,地下矿山卡车行程时间预测是构建实时精准调度系统的必然要求。

[0003] 目前对于矿山运输设备的作业时间预测的研究相对较少,大量的文献主要是针对城市道路和高速公路交通系统当中的车辆行程时间预测进行研究。按照预测模型划分,交通领域的行程时间预测方法可分为时间序列预测模型、交通参数预测模型以及影响因素预测模型。地下矿山道路存在车流密度小,时空关联性不强等问题,且运输卡车的行程时间受环境和人员影响较大,容易产生波动,基于时间序列或交通参数的预测方法不完全适用地下矿车辆行程时间的预测,而基于行程时间影响因素的预测模型更贴近矿山实际。

发明内容

[0004] 本发明的目的在于针对现有技术的不足之处,提供一种地下矿山卡车运输循环作业工时集成预测方法,根据卡车的位置和状态将卡车作业循环过程细化为6个阶段,结合每个阶段的特点,确定各阶段的行程时间影响因素指标,对6个阶段的卡车运行时间分别进行预测,更符合矿山实际运输情况,提高作业工时预测精度。

[0005] 为解决上述技术问题,本发明采用如下技术方案:

[0006] 一种地下矿山卡车运输循环作业工时集成预测方法,该预测方法包括以下步骤:

[0007] S1、针对地下矿无轨运输流程,根据运输卡车状态以及运行环境将无轨运输卡车循环作业过程细化为6个阶段;

[0008] S2、分析影响卡车作业时间的因素,构建不同运输阶段下的作业工时影响因素指标体系;

[0009] S3、采集不同运输阶段的卡车作业工时数据,并采集对应作业工时影响因素指标数据;

[0010] S4、基于Stacking集成学习框架,构建多模型融合的Stacking集成学习工时预测模型;

[0011] S5、将所述步骤S3中采集到的作业工时数据以及对应的工时影响因素数据划分为

训练集和测试集,以影响因素指标为输入、作业工时为输出,对所述6个阶段对应的模型进行训练和测试,分别得到6个阶段对应的预测模型;通过待预测参数对6个阶段的作业工时分别进行预测,从而得到无轨运输循环作业工时预测值。

[0012] 较佳地,在所述步骤S1中,将卡车从装矿点行驶至卸矿点、再由卸矿点返回至装矿点作为一个循环作业过程,该过程包括3个路段:地下平巷路段、斜坡道路段以及地表路段,根据运输卡车在每个路段上的工作状态将循环作业过程拆分为6个阶段:重车平巷运行阶段、重车斜坡道上行阶段、重车地表运行阶段、空车地表返回阶段、空车斜坡道下行阶段、空车平巷返回阶段。

[0013] 较佳地,在所述步骤S2中,基于实际矿山无轨运输情况,结合每个运输阶段的特点,选取影响运输卡车作业工时的影响因素,对选取的影响因素进行皮尔逊相关性分析,最终得到每个阶段的若干个相互独立的影响因素指标。

[0014] 较佳地,在确定每个运输阶段的影响因素的过程中,根据矿山实际运输情况,在斜坡道路段,基于上下行车辆需要错车的情况,将下行空车错车红灯等待时间作为空车斜坡道下行阶段中影响作业工时的重要因素。

[0015] 较佳地,在所述步骤S3中,通过计算运输卡车发生错车的概率将下行空车错车红灯等待时间分配至每一辆卡车的作业工时中,包括以下过程:

[0016] 假设路线上正在运行的卡车数量为 N ,平巷路段长度为 L_1 ,斜坡道路段长度为 L_2 ,地表路段长度为 L_3 ,则卡车在斜坡道上需要错车等待的概率 P 为:

$$P = \frac{1}{4} C_N^2 \left(\frac{L_2 \rho_2}{L_1 \rho_1 + L_2 \rho_2 + L_3 \rho_3} \right)^2, \text{ 式中, } \rho_1, \rho_2, \rho_3 \text{ 为卡车在3个路段上的时间系数,表示卡车在对}$$

应路段上行驶的难易程度; C_N^2 表示 N 辆车中两辆车相遇的组合数;则分配至每辆卡车行程时间当中的红灯等待时间为: $t_w = T_w \times P$, 式中, T_w 为斜坡道下行阶段错车时规定的红灯等待时间。

[0017] 较佳地,在所述步骤S3中,所述作业工时影响因素指标数据包括路面粗糙度指标,并且采用路面图像灰度处理方式计算地下矿无轨运输各路段路面粗糙度。

[0018] 较佳地,所述路面图像灰度处理的过程包括以下步骤:

[0019] S31、等间隔选取测量路段五个测点,于测点正上方两米且垂直于路面架设照相机,拍摄路面图像;

[0020] S32、对获得的路面图像进行灰度处理,得到图像的每个像素点的灰度值;

[0021] S33、设每张图像的像素为 $N \times M$, p_{ij} ($i=1, 2, \dots, N; j=1, 2, \dots, M$) 为每个像素点的灰度数据, p_{\max} 为各像素点灰度数据的最大值,则每张图像路面粗糙度 R 的计算公式为:

$$R = \frac{\sum_{j=1}^M \sum_{i=1}^N (p_{\max} - p_{ij})}{N \times M};$$

[0022] S34、将五个测点对应的图像路面粗糙度取平均即为测量路段的路面粗糙度,计算公式为: $R_L = \frac{R_1 + R_2 + R_3 + R_4 + R_5}{5}$, 其中 R_L 为测量路段的路面粗糙度, R_1, R_2, R_3, R_4, R_5 为五个测点的路面粗糙度。

[0023] 较佳地,在所述步骤S4中,构建多模型融合的Stacking集成学习工时预测模型的过程包括:

[0024] S41、基于Stacking集成学习框架,选取随机森林RF、轻量级梯度提升机LightGBM、最小二乘支持向量机LSSVM作为Stacking集成学习框架中的基模型,各基模型的预测结果作为元模型的输入;

[0025] S42、选取稳定性和精度均较好的极端梯度提升树XGBoost作为Stacking集成学习框架中的元模型,元模型的输出为最终的预测结果。

[0026] 较佳地,在步骤S5中,以工时影响因素为输入参数,作业工时为输出参数,使用Python构建循环结构,对各单模型的超参数进行迭代,以平均绝对误差MAE作为预测结果的评价指标,寻求各模型的最优超参数。

[0027] 较佳地,在所述步骤S5中,所述无轨运输循环作业工时预测值的过程为:

[0028] 设6个运输阶段的预测值分别为 t_1 、 t_2 、 t_3 、 t_4 、 t_5 、 t_6 ,则无轨运输循环作业工时预测值为: $T_P = \sum_{i=1}^6 t_i + t_w$,其中, t_w 为分配至每辆卡车行程时间当中的红灯等待时间。

[0029] 与现有技术相比,本发明的有益效果为:

[0030] (1) 本发明根据卡车的位置和状态将卡车作业循环过程细化为6个阶段,结合每个阶段的特点,确定各阶段的行程时间影响因素指标,对6个阶段的卡车运行时间分别进行预测,更符合矿山实际运输情况。

[0031] (2) 本发明在斜坡道下行阶段,考虑了下行运输卡车错车红灯等待时间,通过计算出出现错车情况的概率将红灯等待时间平均分配值每一辆车的运行时间中,贴近矿山生产实际,能更准确地反映矿山卡车实际运输情况。

[0032] (3) 基于Stacking学习框架,以泛化能力最好的XGBoost作为元模型,以RF、LightGBM、LSSVM3个模型作为Stacking集成学习框架中的基模型,构建多模型融合的运输作业工时集成预测模型,更能适应地下矿山无轨运输道路特点,适应运输卡车在不同运输阶段的工时预测。

附图说明

[0033] 图1为本发明的实施例中地下矿山卡车运输循环作业工时集成预测方法的流程图。

[0034] 图2为本发明的实施例中各运输阶段工时影响因素指标汇总表示意图。

[0035] 图3为本发明的实施例中各基模型超参数对预测效果的影响示意图。

[0036] 图4为本发明的实施例中各模型的最优超参数表示意图。

[0037] 图5为本发明的实施例中测试样本作业工时预测值与真实值对照曲线示意图。

[0038] 图6为本发明的实施例中测试样本各评价指标参数表示意图。

具体实施方式

[0039] 下面结合附图所示的实施例对本发明作进一步说明。

[0040] 如附图1所示,本实施例公开了一种地下矿山卡车运输循环作业工时集成预测方法,该预测方法包括以下步骤:

[0041] 步骤S1、针对地下矿无轨运输流程,根据运输卡车状态以及运行环境将无轨运输卡车循环作业过程细化为6个阶段。

[0042] 在步骤S1中,将卡车从装矿点行驶至卸矿点、再由卸矿点返回至装矿点作为一个循环作业过程,该过程包括3个路段:地下平巷路段、斜坡道路段以及地表路段,根据运输卡车在每个路段上的工作状态将循环作业过程拆分为6个阶段:重车平巷运行阶段、重车斜坡道上行阶段、重车地表运行阶段、空车地表返回阶段、空车斜坡道下行阶段、空车平巷返回阶段。

[0043] 步骤S2、分析影响卡车作业时间的因素,构建不同运输阶段下的作业工时影响因素指标体系。

[0044] 在步骤S2中,基于实际矿山无轨运输情况,结合每个运输阶段的特点,选取影响运输卡车作业工时的影响因素,对选取的影响因素进行皮尔逊相关性分析,最终得到每个阶段的若干个相互独立的影响因素指标。

[0045] 在另一实施方式中,在步骤S2确定每个运输阶段的影响因素的过程中,根据矿山实际运输情况,在斜坡道路段,基于上下行车辆需要错车的情况,矿山专门设有交通信号装置。该情况下应遵循空车让重车、下坡车让上坡车的原则,且错车需要在错车硐室进行。因此,将下行空车错车红灯等待时间作为空车斜坡道下行阶段中影响作业工时的重要因素。

[0046] S3、采集不同运输阶段的卡车作业工时数据,并采集对应作业工时影响因素指标数据。

[0047] 在步骤S3中,作业工时影响因素指标包括定量指标和定性指标,定量指标可通过相关仪器测量或相关资料查阅得到。

[0048] 如,卡车的载重量可由地磅称重系统实时测量获取。卡车行驶速度,可由测试时刻卡车驾驶室显示面板记录得到。斜坡道坡度,由坡度计测量得到。巷道氧气浓度,由井下氧气检测仪检测记录得到。卡车司机工龄、卡车使用年龄、转弯次数、避让行人次数等,均可查阅矿山相关资料获取。

[0049] 对于司机技能等级,根据中国国家职业资格证书制度,对于卡车驾驶员一共设置了初级工、中级工、高级工、技师四个级别,可用数字1、2、3、4表示,通过查阅矿山卡车驾驶员职业资格证书即可获得对应数据。雨雪天气指标,将天气划分为无降雨、少量降雨、大量降雨3个等级,由数字0、1、2表示,通过查阅当日中国气象局监测数据得到。

[0050] 另外,针对步骤S2中确定的重要因素指标下行空车错车红灯等待时间,可以通过计算运输卡车发生错车的概率将下行空车错车红灯等待时间分配至每一辆卡车的作业工时中,具体包括以下过程:

[0051] 假设路线上正在运行的卡车数量为N,平巷路段长度为 L_1 ,斜坡道路段长度为 L_2 ,地表路段长度为 L_3 ,则卡车在斜坡道上需要错车等待的概率P为:

$$P = \frac{1}{4} C_N^2 \left(\frac{L_2 \rho_2}{L_1 \rho_1 + L_2 \rho_2 + L_3 \rho_3} \right)^2, \text{ 式中, } \rho_1, \rho_2, \rho_3 \text{ 为卡车在3个路段上的时间系数,表示卡车在对}$$

应路段上行驶的难易程度; C_N^2 表示N辆车中两辆车相遇的组合数;则分配至每辆卡车行程时间当中的红灯等待时间为: $t_w = T_w \times P$,式中, T_w 为斜坡道下行阶段错车时规定的红灯等待时间。

[0052] 在另一实施方式中,在步骤S3中,作业工时影响因素指标数据还可以包括路面粗糙度指标,并且采用路面图像灰度处理方式计算地下矿无轨运输各路段路面粗糙度。

[0053] 具体地,路面图像灰度处理的过程包括以下步骤:

[0054] S31、等间隔选取测量路段五个测点,于测点正上方两米且垂直于路面架设照相机,拍摄路面图像。

[0055] S32、对获得的路面图像进行灰度处理,得到图像的每个像素点的灰度值。

[0056] S33、设每张图像的像素为 $N \times M$, p_{ij} ($i=1,2,\dots,N$; $j=1,2,\dots,M$) 为每个像素点的灰度数据, p_{\max} 为各像素点灰度数据的最大值,则每张图像路面粗糙度 R 的计算公式为:

$$R = \frac{\sum_{j=1}^M \sum_{i=1}^N (p_{\max} - p_{ij})}{N \times M}。$$

[0057] S34、将五个测点对应的图像路面粗糙度取平均即为测量路段的路面粗糙度,计算公式为: $R_L = \frac{R_1 + R_2 + R_3 + R_4 + R_5}{5}$, 其中 R_L 为测量路段的路面粗糙度, R_1, R_2, R_3, R_4, R_5 为五个

测点的路面粗糙度。

[0058] S4、基于Stacking集成学习框架,构建多模型融合的Stacking集成学习工时预测模型。

[0059] 在步骤S4中,构建多模型融合的Stacking集成学习工时预测模型的过程包括:

[0060] S41、基于Stacking集成学习框架,选取随机森林RF、轻量级梯度提升机LightGBM、最小二乘支持向量机LSSVM作为Stacking集成学习框架中的基模型,各基模型的预测结果作为元模型的输入;

[0061] S42、选取稳定性和精度均较好的极端梯度提升树XGBoost作为Stacking集成学习框架中的元模型,元模型的输出为最终的预测结果。

[0062] S5、将步骤S3中采集到的作业工时数据以及对应的工时影响因素数据划分为训练集和测试集,以影响因素指标为输入、作业工时为输出,对6个阶段对应的模型进行训练和测试,分别得到6个阶段对应的预测模型;通过待预测参数对6个阶段的作业工时分别进行预测,从而得到无轨运输循环作业工时预测值。

[0063] 在步骤S5中,以工时影响因素为输入参数,作业工时为输出参数,使用Python构建循环结构,对各单模型的超参数进行迭代,以平均绝对误差MAE作为预测结果的评价指标,寻求各模型的最优超参数。

[0064] 另外,在步骤S5中,将6个运输阶段的预测值相加得到循环作业工时预测值,则无轨运输循环作业工时预测值的过程为:

[0065] 设6个运输阶段的预测值分别为 $t_1, t_2, t_3, t_4, t_5, t_6$, 则无轨运输循环作业工时预测值为: $T_P = \sum_{i=1}^6 t_i + t_w$, 其中, t_w 为分配至每辆卡车行程时间当中的红灯等待时间。

[0066] 基于本实施例的预测方法,根据卡车的位置和状态将卡车作业循环过程细化为6个阶段,多方面确定各阶段的行程时间影响因素指标,对6个阶段的卡车运行时间分别进行预测,更符合矿山实际运输情况。而且,在斜坡道下行阶段,考虑了下行运输卡车错车红灯等待时间,通过计算出现错车情况的概率将红灯等待时间平均分配值每一辆车的运行时间

中,贴近矿山生产实际,能更准确地反映矿山卡车实际运输情况。另外,基于Stacking学习框架,以泛化能力最好的XGBoost作为元模型,以RF、LightGBM、LSSVM3个模型作为Stacking集成学习框架中的基模型,构建多模型融合的运输作业工时集成预测模型,更能适应地下矿山无轨运输道路特点,适应运输卡车在不同运输阶段的工时预测。

[0067] 以下,选取国内某地下矿山正在进行无轨运输作业的路段作为实验路段,以对本实施例的预测方法进行验证。

[0068] 步骤S1、该实验路段的地下矿无轨运输过程中,卡车从装矿点行驶至卸矿点,再由卸矿点返回至装矿点为一个循环作业过程。过程中主要经历3个路段:地下平巷路段、斜坡道路段以及地表路段。根据运输卡车在每个路段上的工作状态(重车行驶、空车行驶)将循环作业过程拆分为6个阶段:重车平巷运行阶段、重车斜坡道上行阶段、重车地表运行阶段、空车地表返回阶段、空车斜坡道下行阶段、空车平巷返回阶段。

[0069] 步骤S2、通过对矿山无轨运输情况的调查以及询问相关管理人员,从多个角度分析影响运输卡车作业工时的影响因素,初步选取各运输阶段的影响因素,对初选的影响因素进行皮尔逊相关性分析,最终得到每个阶段的若干个相互独立的影响因素指标。6个运输阶段的影响因素指标具体见图2。

[0070] 步骤S3、跟踪该地下矿山实验路段无轨运输循环作业流程,按照划分的6个运输阶段连续采集运输卡车作业工时数据,并采集对应作业工时影响因素指标数据,其中每个运输阶段的样本数据均采集200组。

[0071] 对于错车红灯等待时间,通过计算运输卡车发生错车的概率,将错车红灯等待时间分配至每一辆卡车的作业工时当中。假设路线上正在运行的卡车数量为 N ,平巷路段长度为 L_1 ,斜坡道路段长度为 L_2 ,地表路段长度为 L_3 ,则卡车在斜坡道上需要错车等待的概率 P

为:
$$P = \frac{1}{4} C_N^2 \left(\frac{L_2 \rho_2}{L_1 \rho_1 + L_2 \rho_2 + L_3 \rho_3} \right)^2$$
, 式中: ρ_1 、 ρ_2 、 ρ_3 为卡车在3个路段上的时间系数,表示卡车

在对应路段上行驶的难易程度; C_N^2 表示 N 辆车中两辆车相遇的组合数。则分配至每辆卡车行程时间当中的红灯等待时间为: $t_w = T_w \times P$, 式中, T_w 为斜坡道下行阶段错车时规定的红灯等待时间。查阅矿山资料可知,在实验路段上运行的卡车数量为5,2822中段平巷长度约为3800米,斜坡道长度约为3600米,地表路段长度约为3000米, ρ_1 、 ρ_2 、 ρ_3 分别取1、1.2、0.8,统计 T_w 值约为120秒。则由上述公式计算得到 t_w 为40.46秒。

[0072] 步骤S4、基于Stacking集成学习框架,选取RF(随机森林)、LightGBM(轻量级梯度提升机)、LSSVM(最小二乘支持向量机)作为Stacking集成学习框架中的基模型,各基模型的初级预测值作为元模型的输入;选取稳定性和精度均较好的XGBoost(极端梯度提升树)代替常规的线性回归算法作为Stacking集成学习框架中的元模型,元模型的输出为最终的预测结果。

[0073] 步骤S5、地下矿运输卡车作业流程分为地下平巷路段、地下斜坡道路段以及地表路段3个路段,其中地下斜坡道路段运输环境比其他两个路段更加复杂,考虑的影响因素更多,因此选取更具有代表性和全面性的斜坡道样本数据作为训练样本,以工时影响因素为输入参数,作业工时为输出参数,使用Python构建循环结构,对各单模型的超参数进行迭代,以平均绝对误差(MAE)作为预测结果的评价指标,寻求各模型的最优超参数,最终得到

各基模型超参数对预测效果的影响见图3所示,各模型的最优超参数见图4所示。

[0074] 将各模型的最优超参数代入融合模型,并将步骤S3采集的作业工时数据以及对应的工时影响因素数据划分为训练集和测试集,其中训练集为160组,测试集为40组。以影响因素指标为输入,作业工时为输出,对模型进行训练和测试,分别预测6个运输阶段的作业工时,最终将6个阶段预测工时相加得到无轨运输循环作业工时预测值,选择平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)、以及决定系数(R²)作为测试样本的评价指标对模型的精度进行评价。

[0075] 设6个运输阶段的预测值分别为 t_1 、 t_2 、 t_3 、 t_4 、 t_5 、 t_6 ,则运输卡车循环作业工时为:

$T_P = \sum_{i=1}^6 t_i + t_w$,其中, t_w 为分配至每辆卡车行程时间当中的红灯等待时间,由步骤S3公式计算为40.46秒。

[0076] 将各阶段预测值以及 t_w 相加得到运输卡车作业循环时间预测值 T_P ,图5所示为预测值与真实值对照,预测样本的平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)以及决定系数(R²)指标见图6所示。由图5和图6可知,预测值和真实值拟合程度高,R²达到了0.9762,平均绝对误差为146.74秒。

[0077] 通过上述实验,结果表明本发明提出的一种地下矿运输作业工时集成预测模型及方法具有较强的实用性,在误差允许范围内,能够满足矿山智能调度系统的数据要求。

[0078] 本发明的保护范围不限于上述的实施例,显然,本领域的技术人员可以对本发明进行各种改动和变形而不脱离本发明的范围和精神。倘若这些改动和变形属于本发明权利要求及其等同技术的范围,则本发明的意图也包含这些改动和变形在内。

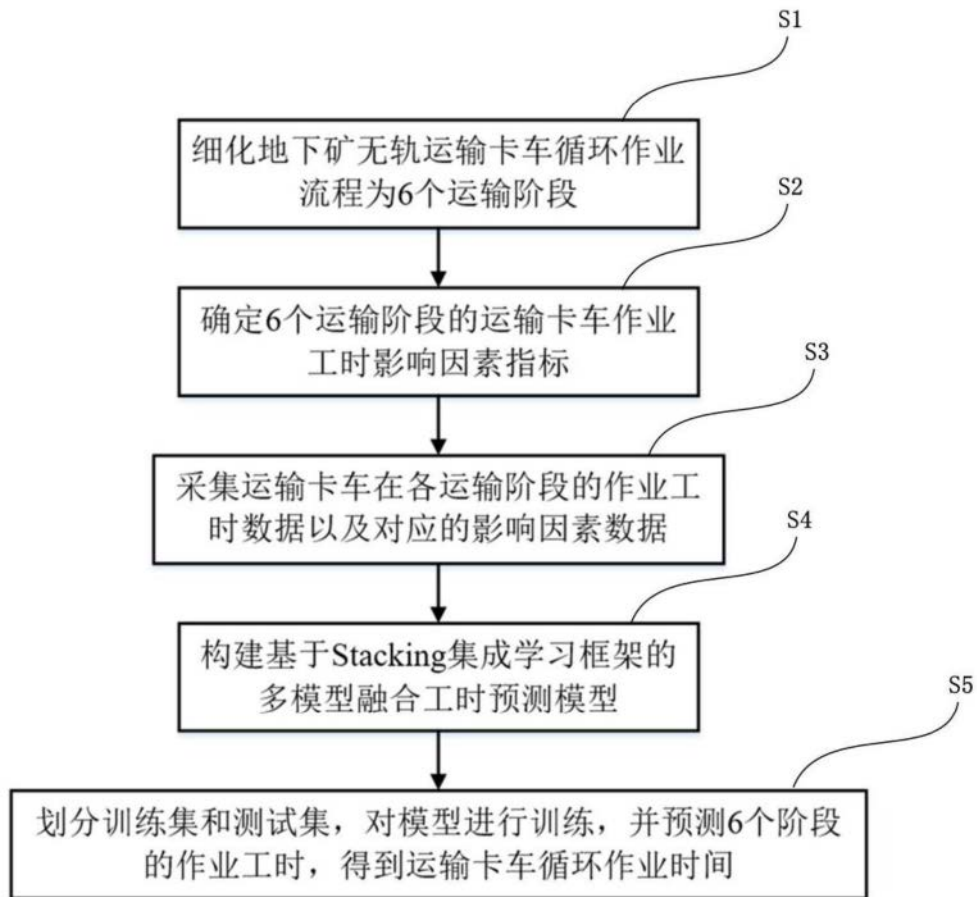



图1


运输阶段		重车平巷运行阶段	重车斜坡道上行阶段	重车地表运行阶段	空车地表返回阶段	空车斜坡道下行阶段	空车平巷返回阶段
操作人员指标	司机技能等级	A1	B1	C1	D1	E1	F1
	卡车司机工龄	A2	B2	C2	D2	E2	F2
运输卡车指标	卡车载重量	A3	B3	C3	D3	E3	F3
	卡车行驶速度	A4	B4	C4	D4	E4	F4
	卡车使用年龄	A5	B5	C5	D5	E5	F5
	轮胎磨损程度	-	B6	-	-	E6	-
运行环境指标	转弯次数	A6	-	C6	D6	-	F6
	斜坡道坡度	-	B7	-	-	E7	-
	路面粗糙度	A7	B8	C7	D7	E8	F7
	氧气浓度	A8	B9	-	-	E9	F8
	避让行人次数	A9	-	C8	D8	-	F9
	雨雪天气	-	-	C9	D9	-	-
其他	斜坡道红灯	-	-	-	-	E10	-

注：“A、B、C、D、E、F”表示6个运输阶段的影响因素代号；“-”表示该运输阶段不考虑对应的影响因素


图2




(a) XGBoost 超参数 N_estimators 和 learning_rate 对预测效果的影响



(b) RF 超参数 N_estimators 和 MAX_Depth 对预测效果的影响



(c) LightGBM 超参数 N_estimators 和 learning_rate 对预测效果的影响



(d) LSSVM 超参数 gamma 和 C 对预测效果的影响

注: N_estimators: 弱学习器数量; learning_rate: 学习率; MAX_Depth: 决策树的最大深度; gamma: 核函数参数; C: 惩罚系数。

图3

模型	超参数	最优值
XGBoost	N_estimators	45
	learning_rate	0.14
RF	N_estimators	28
	MAX_Depth	14
LightGBM	N_estimators	21
	learning_rate	0.25
LSSVM	gamma	0.25
	C	803

图4




图5

评价指标	MAE (S)	RMSE	MAPE(%)	R ²
指标值	146.74	177.11	1.85	0.9762

图6