



(21) 申请号 202410494661.8

(22) 申请日 2024.04.24

(65) 同一申请的已公布的文献号

申请公布号 CN 118096085 A

(43) 申请公布日 2024.05.28

(73) 专利权人 山东冠县鑫恒祥面业有限公司

地址 252514 山东省聊城市冠县辛集镇冯杜庄村

(72) 发明人 樊振岗 樊振松 郜洪海 代明飞

(74) 专利代理机构 安徽谷知知识产权代理事务

所(普通合伙) 34286

专利代理师 李航

(51) Int. Cl.

G06Q 10/10 (2023.01)

G06N 3/006 (2023.01)

G06N 3/126 (2023.01)

G06N 3/092 (2023.01)

G06F 18/25 (2023.01)

G16Y 40/35 (2020.01)

(56) 对比文件

CN 116862160 A, 2023.10.10

CN 117789422 A, 2024.03.29

审查员 李孜孜

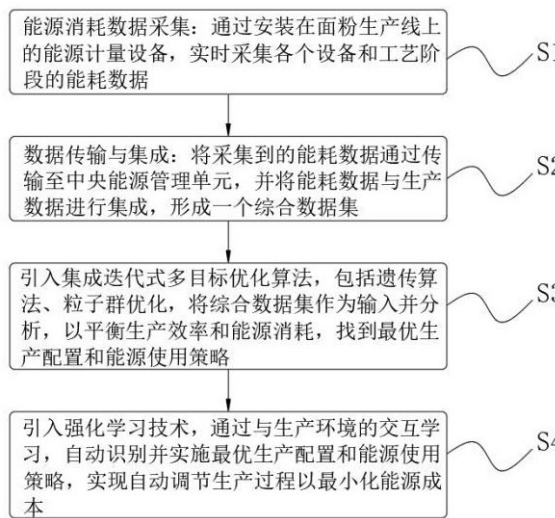
权利要求书3页 说明书11页 附图2页

(54) 发明名称

一种基于物联网的面粉产线设备运维管理方法

(57) 摘要

本发明涉及设备运维管理技术领域,具体涉及一种基于物联网的面粉产线设备运维管理方法,包括以下步骤:通过安装在面粉生产线上的能源计量设备,实时采集各个设备和工艺阶段的能耗数据;将采集到的能耗数据通过传输至中央能源管理单元,并将能耗数据与生产数据进行集成,形成一个综合数据集;引入集成迭代式多目标优化算法,包括遗传算法、粒子群优化,将综合数据集作为输入并分析,以平衡生产效率和能源消耗,找到最优生产配置和能源使用策略;引入强化学习技术,通过与生产环境的交互学习,自动识别并实施最优生产配置和能源使用策略。本发明,能够持续找到能源使用的最优策略,减少无效和过量的能源消耗。



1. 一种基于物联网的面粉产线设备运维管理方法,其特征在于,包括以下步骤:

S1,能源消耗数据采集:通过安装在面粉生产线上的能源计量设备,实时采集各个设备和工艺阶段的能耗数据;

S2,数据传输与集成:将采集到的能耗数据通过传输至中央能源管理单元,并将能耗数据与生产数据进行集成,形成一个综合数据集;

S3,引入集成迭代式多目标优化算法,包括遗传算法、粒子群优化,将综合数据集作为输入并分析,以平衡生产效率和能源消耗,找到最优生产配置和能源使用策略;

S4,引入强化学习技术,通过与生产环境的交互学习,自动识别并实施最优生产配置和能源使用策略,实现自动调节生产过程以最小化能源成本;

所述S1具体包括:

S11:在面粉生产线的关键设备和工艺阶段安装多类型的能源计量设备,包括电能表、燃气流量计和水流量计,用于实时监测和记录各个设备和工艺阶段的电力、燃气和水的消耗量;

S12:配置数据采集单元,用于录入各个计量设备的数据,并将数据标准化处理,形成统一格式的数据流,利用无线网络实时传输标准化的数据流至中央能源管理单元,以供后续的数据分析和优化处理;

所述S2中的生产数据包括原料消耗量、产品产量、设备运行状态和工艺参数,S2具体包括:

S21:对收集到的数据进行预处理,包括数据清洗,数据标准化和数据同步;

S22:在数据预处理后,进行数据融合操作,将能耗数据和生产数据整合到一个统一的数据模型中,通过数据匹配和关联,将能耗数据与相应的生产活动关联起来;

S23:构建综合数据集,使用数据库管理系统或数据分析平台将融合后的数据组织成综合数据集,数据集反映生产活动与能耗之间的关系,在综合数据集中,每个数据记录包含时间戳、能耗指标、生产参数信息;

所述S3中的集成迭代式多目标优化算法具体包括:

S31:初始阶段,使用遗传算法进行全局搜索,遗传算法通过模拟自然选择和遗传机制来探索解空间,寻找优化解集合,遗传算法对解空间进行广泛探索,识别全局最优解的主区域,避免早期就陷入局部最优;

S32:评估与选择,经过多次迭代后的遗传算法优化后,评估当前找到的最优解或解集合的性能,确定遗传算法搜索结果的质量;

S33:细化优化阶段,基于遗传算法找到的最优解或解集合,启用粒子群优化算法进行细化搜索,粒子群优化通过模拟鸟群的社会行为,以快速收敛于解空间中的最优解,在遗传算法确定的主区域内进行局部搜索和优化,以精细化调整和提高解的精确度;

S34:迭代循环,结合遗传算法和粒子群优化的结果,不断迭代优化,在每次迭代中,根据上一次迭代的结果调整遗传算法和粒子群优化的参数,以适应优化过程的动态变化;

S35:通过迭代的方式,不断循环使用遗传算法和粒子群优化,直到满足停止准则,包括达到预定的迭代次数、解的改进量低于阈值或达到预设的性能目标;

S36:最终优化结果:经过多次迭代后,综合遗传算法和粒子群优化的优化过程,最终确定最优化的能源管理策略;

所述使用遗传算法进行全局搜索具体包括：

选择：从当前种群中选择出优质个体，作为下一代的父母，选择过程基于适应度函数，适应度函数评估每个个体的性能，即生产线的能源效率或成本效率的函数，适应度函数表

示为：
$$\text{Fitness} = \alpha \times \frac{\text{产量}}{\text{能耗}} + \beta \times \frac{\text{设备运行效率}}{\text{能耗}}$$
，其中， α 和 β 是权重因子，用于调整产量和设备运行效率对总适应度的影响程度；

交叉：选定父母个体后，通过交叉操作生成后代，通过单点交叉结合父母个体的特征产生新个体；

变异：为了维持种群的多样性并避免过早收敛到局部最优解，对部分个体进行变异操作，随机改变个体的特征；

所述评估与选择具体包括：

在遗传算法的每一代中，均对种群中的个体进行评估，并选择高性能个体进入下一代，评估与选择过程依赖适应度函数，量化每个个体解决问题的能力，基于定义好的适应度函数对每个个体进行评估，高适应度的个体表明其对应的生产配置和能源使用策略更优；

选择过程：根据适应度进行选择，采用轮盘赌选择，使高适应度个体具有高概率被选为下一代的父母；

所述细化优化阶段，粒子群优化算法用于在遗传算法确定的解区域内进行局部搜索，粒子群优化算法处理过程包括：

粒子群中的每个粒子代表一个潜在解，即对应的生产配置和能源使用策略；

每个粒子根据个体经验和集体经验调整其搜索方向和速度，粒子更新计算如下：

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot \text{rand}() \cdot (p_i - x_i(t)) + c_2 \cdot \text{Rand}() \cdot (p_g - x_i(t));$$

$$x_i(t+1) = x_i(t) + v_i(t+1);$$

其中， $v_i(t+1)$ 是粒子 i 在时间 $t+1$ 的速度， $x_i(t)$ 是粒子 i 在时间 t 的位置， p_i 是粒子 i 的个体最佳位置， p_g 是全局最佳位置， w 是惯性权重，控制粒子速度的持续性， c_1 和 c_2 是加速常数，控制粒子向个体最佳和全局最佳移动的速度， $\text{rand}()$ 和 $\text{Rand}()$ 是区间 $[0,1]$ 内的随机数；

所述迭代循环是遗传算法和粒子群优化交替执行的过程，在每次迭代中，遗传算法和粒子群优化的参数根据之前迭代的结果进行调整，参数包括交叉率、变异率和加速常数、惯性权重；

所述最终优化结果综合考虑遗传算法和粒子群优化过程中得到的最佳解，以形成最终的优化策略，最终策略平衡生产效率和能源消耗，确保在满足生产需求的同时实现能源使用的最优化；

所述S4中引入强化学习技术，通过观察生产过程的反馈来不断优化其决策，具体包括：

定义强化学习环境：通过定义状态来表示生产线的当前状况，当前状况包括能耗数据、生产速度、原料使用量、产品质量指标；通过动作集定义可执行的操作，包括调整设备参数、

更改能源输入、修改生产节奏；通过定义奖励，奖励信号基于生产效率和能源消耗的目标，减少能源消耗和提高生产效率时给予正奖励，反之给予负奖励；

选择基于策略的算法PPO来处理连续的状态和动作空间，在复杂生产环境中找到最优策略；

使用集成迭代式多目标优化算法分析得到的最优生产配置和能源使用策略作为强化学习的训练基础，训练过程中，通过尝试不同的动作并观察结果，学习如何调整生产配置以优化能源使用，通过，不断试错学习，更新其策略以最大化长期奖励；

所述PPO算法具体包括：

策略函数：策略函数 $\pi_{\theta}(a|s)$ 表示在给定状态 s 下选择动作 a 的概率，其中 θ 表示策略网络的参数；

优势函数：优势函数 $A(s, a)$ 表示执行动作 a 在状态 s 下比平均情况更好的程度；

目标函数：PPO算法的目标是最大化一个裁剪的目标函数，该目标函数基于概率比率

$$r(\theta) = \frac{\pi_{\theta}(a|s)}{\pi_{\theta_{old}}(a|s)}, \text{其中 } \theta_{old} \text{ 是旧策略的参数, 目标函数定义为:}$$

$L(\theta) = \widehat{\mathbb{E}}[\min(r(\theta)A(s, a), \text{clip}(r(\theta), 1 - \epsilon, 1 + \epsilon)A(s, a))]$, 其中 ϵ 是一个小常数, 取值0.2, 用于限制策略更新的步幅, $r(\theta)$ 为概率比例, clip 为裁剪函数, 用于将 $r(\theta)$ 的值限制在 $[1 - \epsilon, 1 + \epsilon]$ 范围内。

一种基于物联网的面粉产线设备运维管理方法

技术领域

[0001] 本发明涉及设备运维管理技术领域,尤其涉及一种基于物联网的面粉产线设备运维管理方法。

背景技术

[0002] 在面粉生产行业,能源消耗和生产效率的管理是关键的经济和环境因素,传统的面粉生产线依赖于经验和定期的维护计划来管理能源使用和维持生产效率,这种方法不仅效率低下,而且无法实时响应生产过程中的变化,导致能源浪费和生产中断。

[0003] 随着物联网技术的发展,实时数据采集和分析成为可能,为改善生产线的能源管理和效率提供了新的机会,然而,如何有效地整合和利用这些大量的数据来优化生产配置和能源使用策略,仍然是一个挑战。传统的数据处理方法往往无法处理复杂的生产动态和多变的能源需求,且缺乏对生产过程中突发事件的快速响应能力。

[0004] 此外,虽然现有技术中存在一些优化方法,如单一的数学规划或机器学习模型,但 these 方法通常关注于生产过程的某个特定方面,缺乏对生产线整体性能和能源消耗的综合考虑。因此,需要一种能够全面分析并优化面粉生产线中能源和生产效率的方法,这种方法应该能够动态适应生产环境的变化,实现实时、自动化的优化决策。

发明内容

[0005] 基于上述目的,本发明提供了一种基于物联网的面粉产线设备运维管理方法。

[0006] 一种基于物联网的面粉产线设备运维管理方法,包括以下步骤:

[0007] S1,能源消耗数据采集:通过安装在面粉生产线上的能源计量设备,实时采集各个设备和工艺阶段的能耗数据;

[0008] S2,数据传输与集成:将采集到的能耗数据通过传输至中央能源管理单元,并将能耗数据与生产数据进行集成,形成一个综合数据集;

[0009] S3,引入集成迭代式多目标优化算法,包括遗传算法、粒子群优化,将综合数据集作为输入并分析,以平衡生产效率和能源消耗,找到最优生产配置和能源使用策略;

[0010] S4,引入强化学习技术,通过与生产环境的交互学习,自动识别并实施最优生产配置和能源使用策略,实现自动调节生产过程以最小化能源成本。

[0011] 进一步的,所述S1具体包括:

[0012] S11:在面粉生产线的关键设备和工艺阶段安装多类型的能源计量设备,包括电能表、燃气流量计和水流量计,用于实时监测和记录各个设备和工艺阶段的电力、燃气和水的消耗量;

[0013] S12:配置数据采集单元,用于录入各个计量设备的数据,并将数据标准化处理,形成统一格式的数据流,利用无线网络实时传输标准化的数据流至中央能源管理单元,以供后续的数据分析和优化处理。

[0014] 进一步的,所述S2中的生产数据包括原料消耗量、产品产量、设备运行状态和工艺

参数,S2具体包括:

[0015] S21:对收集到的数据进行预处理,包括数据清洗,数据标准化和数据同步;

[0016] S22:在数据预处理后,进行数据融合操作,将能耗数据和生产数据整合到一个统一的数据模型中,通过数据匹配和关联,将能耗数据与相应的生产活动关联起来;

[0017] S23:构建综合数据集,使用数据库管理系统或数据分析平台将融合后的数据组织成综合数据集,数据集反映生产活动与能耗之间的关系,在综合数据集中,每个数据记录包含时间戳、能耗指标、生产参数信息。

[0018] 进一步的,所述S3中的集成迭代式多目标优化算法具体包括:

[0019] S31:初始阶段,使用遗传算法进行全局搜索,遗传算法通过模拟自然选择和遗传机制(如选择、交叉、变异)来探索解空间,寻找优化解集合,遗传算法对解空间进行广泛探索,识别全局最优解的主区域,避免早期就陷入局部最优;

[0020] S32:评估与选择,经过多次迭代后的遗传算法优化后,评估当前找到的最优解或解集合的性能,确定遗传算法搜索结果的质量,如是否已接近全局最优,或者是否存在明显的改进空间;

[0021] S33:细化优化阶段,基于遗传算法找到的最优解或解集合,启用粒子群优化算法进行细化搜索,粒子群优化通过模拟鸟群的社会行为,以快速收敛于解空间中的最优解,在遗传算法确定的主区域内进行局部搜索和优化,以精细化调整和提高解的精确度;

[0022] S34:迭代循环,结合遗传算法和粒子群优化的结果,不断迭代优化,在每次迭代中,根据上一次迭代的结果调整遗传算法和粒子群优化的参数(如交叉率、变异率、学习因子等),以适应优化过程的动态变化;

[0023] S35:通过迭代的方式,不断循环使用遗传算法和粒子群优化,直到满足停止准则,包括达到预定的迭代次数、解的改进量低于阈值或达到预设的性能目标;

[0024] S36:最终优化结果:经过多次迭代后,综合遗传算法和粒子群优化的优化过程,最终确定最优化的能源管理策略,该策略应在全局最优解的基础上经过局部搜索和细化,以确保能源使用的最佳效率和生产过程的最优配置。

[0025] 进一步的,所述使用遗传算法进行全局搜索具体包括:

[0026] 选择:从当前种群中选择出优质个体(解),作为下一代的父母,选择过程基于适应度函数,适应度函数评估每个个体的性能,即生产线的能源效率或成本效率的函数,适应度

函数表示为:
$$\text{Fitness} = \alpha \times \frac{\text{产量}}{\text{能耗}} + \beta \times \frac{\text{设备运行效率}}{\text{能耗}}$$
,其中, α 和 β 是权重因子,用于调整

产量和设备运行效率对总适应度的影响程度;

[0027] 交叉:选定父母个体后,通过交叉操作生成后代,通过单点交叉结合父母个体的特征产生新个体;

[0028] 变异:为了维持种群的多样性并避免过早收敛到局部最优解,对部分个体进行变异操作,随机改变个体的特征。

[0029] 进一步的,所述评估与选择具体包括:

[0030] 在遗传算法的每一代中,均对种群中的个体进行评估,并选择高性能个体进入下一代,评估与选择过程依赖适应度函数,量化每个个体解决问题的能力,基于定义好的适应

度函数对每个个体进行评估,高适应度的个体表明其对应的生产配置和能源使用策略更优;

[0031] 选择过程:根据适应度进行选择,采用轮盘赌选择,使高适应度个体具有高概率被选为下一代的父母。

[0032] 进一步的,所述细化优化阶段,粒子群优化算法用于在遗传算法确定的解区域内进行局部搜索,粒子群优化算法处理过程包括:

[0033] 粒子群中的每个粒子代表一个潜在解,即对应的生产配置和能源使用策略;

[0034] 每个粒子根据个体经验(个体最佳位置)和集体经验(全局最佳位置)调整其搜索方向和速度,粒子更新计算如下:

$$[0035] \quad v_i(t+1) = w \cdot v_i(t) + c_1 \cdot rand() \cdot (p_i - x_i(t)) + c_2 \cdot Rand() \cdot (p_g - x_i(t));$$

$$[0036] \quad x_i(t+1) = x_i(t) + v_i(t+1);$$

[0037] 其中, $v_i(t+1)$ 是粒子*i*在时间*t+1*的速度, $x_i(t)$ 是粒子*i*在时间*t*的位置, p_i 是粒子*i*的个体最佳位置, p_g 是全局最佳位置, w 是惯性权重,控制粒子速度的持续性, c_1 和 c_2 是加速常数,控制粒子向个体最佳和全局最佳移动的速度, $rand()$ 和 $Rand()$ 是区间[0.1]内的随机数。通过这种方式,PSO算法可以有效地在全局最优的附近区域进行细化搜索,找到更优的解。

[0038] 进一步的,所述迭代循环是遗传算法和粒子群优化交替执行的过程,在每次迭代中,遗传算法和粒子群优化的参数根据之前迭代的结果进行调整,参数包括交叉率、变异率(遗传算法参数)和加速常数、惯性权重(粒子群优化参数);

[0039] 所述最终优化结果综合考虑遗传算法和粒子群优化过程中得到的最佳解,以形成最终的优化策略,最终策略平衡生产效率和能源消耗,确保在满足生产需求的同时实现能源使用的最优化。

[0040] 进一步的,所述S4中引入强化学习技术,通过观察生产过程的反馈来不断优化其决策,具体包括:

[0041] 定义强化学习环境:通过定义状态来表示生产线的当前状况,当前状况包括能耗数据、生产速度、原料使用量、产品质量指标;通过动作集定义可执行的操作,包括调整设备参数、更改能源输入、修改生产节奏;通过定义奖励,奖励信号基于生产效率和能源消耗的目标,减少能源消耗和提高生产效率时给予正奖励,反之给予负奖励;

[0042] 选择基于策略的算法PPO来处理连续的状态和动作空间,在复杂生产环境中找到最优策略;

[0043] 使用集成迭代式多目标优化算法分析得到的最优生产配置和能源使用策略作为强化学习的训练基础,训练过程中,通过尝试不同的动作并观察结果(如能源消耗和生产量),学习如何调整生产配置以优化能源使用,通过,不断试错学习,更新其策略以最大化长期奖励。

[0044] 进一步的,所述PPO算法具体包括:

[0045] 策略函数:策略函数 $\pi_{\theta}(a|s)$ 表示在给定状态*s*下选择动作*a*的概率,其中 θ 表示策略网络的参数,在本发明中,状态*s*是当前的生产线状态,包括能耗、生产速率等,动作*a*是调

整设备设置或改变能源使用策略；

[0046] 优势函数：优势函数 $A(s,a)$ 表示执行动作 a 在状态 s 下比平均情况更好的程度，在生产环境中，优势函数可以帮助识别哪些动作会导致比当前策略更好的能源使用效率或生产性能；

[0047] 目标函数：PPO算法的目标是最大化一个裁剪的目标函数，该目标函数基于概率比

$r(\theta) = \frac{\pi_{\theta}(a|s)}{\pi_{\theta_{old}}(a|s)}$ ，其中 θ_{old} 是旧策略的参数，目标函数定义为：

[0048] $L(\theta) = \hat{\mathbb{E}}[\min(r(\theta)A(s,a), \text{clip}(r(\theta), 1 - \epsilon, 1 + \epsilon))A(s,a))]$ ，其中 ϵ 是一个小

常数，取值0.2，用于限制策略更新的步幅， $r(\theta)$ 为概率比例， clip 为裁剪函数，用于将 $r(\theta)$

的值限制在 $[1 - \epsilon, 1 + \epsilon]$ 范围内。

[0049] 本发明的有益效果：

[0050] 本发明，通过引入集成迭代式多目标优化算法，结合遗传算法和粒子群优化，本发明能够全面分析和优化面粉生产线的能源消耗和生产效率，这种方法可以有效地平衡生产效率和能源使用，从而实现能源成本的显著降低，同时保持或提高生产量，通过细化搜索和迭代优化，能够持续找到能源使用的最优策略，减少无效和过量的能源消耗，对企业来说，这意味着成本节约和经济效益的提升。

[0051] 本发明，引入强化学习技术使得本发明能够通过和生产环境的实时交互学习，自动识别并实施最优生产配置和能源使用策略，这种动态适应机制使得生产过程能够根据实时数据和环境变化进行调整，优化策略得以持续更新和改进，确保生产过程始终运行在最佳状态，不仅提高了生产线的灵活性和响应速度，而且通过长期学习积累，系统的决策能力和优化效率将持续提高。

[0052] 本发明，通过集成和分析生产线的实时能耗数据和生产数据，构建了一个综合的数据分析和决策框架，这种数据驱动的方法使得决策过程更加科学和精准，能够基于全面的数据分析为生产管理和能源优化提供强有力的支持，通过不断的数据融合、分析和优化，能够确保每项决策都是基于最新和最全面的信息做出的，大大提高了生产管理的智能化水平和决策的准确性。

附图说明

[0053] 为了更清楚地说明本发明或现有技术中的技术方案，下面将对实施例或现有技术描述中所需要使用的附图作简单地介绍，显而易见地，下面描述中的附图仅仅是本发明，对于本领域普通技术人员来讲，在不付出创造性劳动的前提下，还可以根据这些附图获得其他的附图。

[0054] 图1为本发明实施例的方法流程示意图；

[0055] 图2为本发明实施例的集成迭代式多目标优化算法示意图。

具体实施方式

[0056] 为使本发明的目的、技术方案和优点更加清楚明白，以下结合具体实施例，对本发

明进一步详细说明。

[0057] 需要说明的是,除非另外定义,本发明使用的技术术语或者科学术语应当为本发明所属领域内具有一般技能的人士所理解的通常意义。本发明中使用的“第一”、“第二”以及类似的词语并不表示任何顺序、数量或者重要性,而只是用来区分不同的组成部分。“包括”或者“包含”等类似的词语意指出现该词前面的元件或者物件涵盖出现在该词后面列举的元件或者物件及其等同,而不排除其他元件或者物件。“连接”或者“相连”等类似的词语并非限定于物理的或者机械的连接,而是可以包括电性的连接,不管是直接的还是间接的。“上”、“下”、“左”、“右”等仅用于表示相对位置关系,当被描述对象的绝对位置改变后,则该相对位置关系也可能相应地改变。

[0058] 如图1-图2所示,一种基于物联网的面粉产线设备运维管理方法,包括以下步骤:

[0059] S1,能源消耗数据采集:通过安装在面粉生产线上的能源计量设备,实时采集各个设备和工艺阶段的能耗数据;

[0060] S2,数据传输与集成:将采集到的能耗数据通过传输至中央能源管理单元,并将能耗数据与生产数据进行集成,形成一个综合数据集;

[0061] S3,引入集成迭代式多目标优化算法,包括遗传算法、粒子群优化,将综合数据集作为输入并分析,以平衡生产效率和能源消耗,找到最优生产配置和能源使用策略;

[0062] S4,引入强化学习技术,通过与生产环境的交互学习,自动识别并实施最优生产配置和能源使用策略,实现自动调节生产过程以最小化能源成本。

[0063] S1具体包括:

[0064] S11:在面粉生产线的关键设备和工艺阶段安装多类型的能源计量设备,包括电能表、燃气流量计和水流量计,用于实时监测和记录各个设备和工艺阶段的电力、燃气和水的消耗量;

[0065] S12:配置数据采集单元,用于录入各个计量设备的数据,并将数据标准化处理,形成统一格式的数据流,利用无线网络实时传输标准化的数据流至中央能源管理单元,以供后续的数据分析和优化处理。

[0066] 关键设备和工艺阶段包括:

[0067] 原料接收与储存:

[0068] 关键设备:原料仓、输送系统;

[0069] 工艺阶段:小麦或其他原料的接收、清理、分级和储存。

[0070] 清洗和预处理:

[0071] 关键设备:清洗机、去石机;

[0072] 工艺阶段:对小麦进行清洗、去除杂质和石粒,以及金属异物。

[0073] 研磨:

[0074] 关键设备:磨粉机、筛网机;

[0075] 工艺阶段:将清洁后的小麦研磨成面粉,包括多次研磨和筛分过程,以获取不同精度的面粉。

[0076] 筛分与分级:

[0077] 关键设备:平面筛、圆筒筛、粉碎机;

[0078] 工艺阶段:对研磨后的面粉进行筛分和分级,分离不同大小和质量的面粉。

- [0079] 粉质调整:
- [0080] 关键设备:调质器、搅拌机;
- [0081] 工艺阶段:根据不同的产品需求调整面粉的质量,如湿度、颗粒大小和面筋含量。
- [0082] 成品处理与包装:
- [0083] 关键设备:包装机、称重系统;
- [0084] 工艺阶段:将处理好的面粉进行定量包装、封装和标记,准备出售或存储。
- [0085] S2中的生产数据包括原料消耗量、产品产量、设备运行状态和工艺参数,S2具体包括:
- [0086] S21:对收集到的数据进行预处理,包括数据清洗,数据标准化和数据同步;
- [0087] S22:在数据预处理后,进行数据融合操作,将能耗数据和生产数据整合到一个统一的数据模型中,通过数据匹配和关联,将能耗数据与相应的生产活动关联起来;
- [0088] S23:构建综合数据集,使用数据库管理系统或数据分析平台将融合后的数据组织成综合数据集,数据集反映生产活动与能耗之间的关系,在综合数据集中,每个数据记录包含时间戳、能耗指标、生产参数信息。
- [0089] S3中的集成迭代式多目标优化算法具体包括:
- [0090] S31:初始阶段,使用遗传算法进行全局搜索,遗传算法通过模拟自然选择和遗传机制(如选择、交叉、变异)来探索解空间,寻找优化解集合,遗传算法对解空间进行广泛探索,识别全局最优解的主区域,避免早期就陷入局部最优;
- [0091] S32:评估与选择,经过多次迭代后的遗传算法优化后,评估当前找到的最优解或解集合的性能,确定遗传算法搜索结果的质量,如是否已接近全局最优,或者是否存在明显的改进空间;
- [0092] S33:细化优化阶段,基于遗传算法找到的最优解或解集合,启用粒子群优化算法进行细化搜索,粒子群优化通过模拟鸟群的社会行为,以快速收敛于解空间中的最优解,在遗传算法确定的主区域内进行局部搜索和优化,以精细化调整和提高解的精确度;
- [0093] S34:迭代循环,结合遗传算法和粒子群优化的结果,不断迭代优化,在每次迭代中,根据上一次迭代的结果调整遗传算法和粒子群优化的参数(如交叉率、变异率、学习因子等),以适应优化过程的动态变化;
- [0094] S35:通过迭代的方式,不断循环使用遗传算法和粒子群优化,直到满足停止准则,包括达到预定的迭代次数、解的改进量低于阈值或达到预设的性能目标;
- [0095] S36:最终优化结果:经过多次迭代后,综合遗传算法和粒子群优化的优化过程,最终确定最优化的能源管理策略,该策略应在全局最优解的基础上经过局部搜索和细化,以确保能源使用的最佳效率和生产过程的最优配置。
- [0096] 为了清晰描述集成迭代式多目标优化算法的详细过程,将集成迭代式多目标优化算法的过程分解,并明确输入、输出以及它们如何与能耗数据和生产数据结合使用:
- [0097] 1. 初始阶段:全局搜索(使用遗传算法):
- [0098] 输入数据:综合数据集,包含能耗数据和生产数据。
- [0099] 处理过程:
- [0100] 遗传算法通过模拟自然选择和遗传机制(选择、交叉、变异)探索解空间。
- [0101] 广泛搜索用于识别全局最优解的主区域,避免过早陷入局部最优。

- [0102] 输出数据:一组潜在的优化解,表示为生产配置和能源使用策略的组合。
- [0103] 2. 评估与选择:
- [0104] 输入数据:遗传算法产生的潜在优化解。
- [0105] 处理过程:
- [0106] 评估每个解的性能,基于实际生产和能源消耗指标。
- [0107] 确定解的质量,判断是否接近全局最优或是否有明显的改进空间。
- [0108] 输出数据:筛选后的优化解,即最有可能接近全局最优的解集合。
- [0109] 3. 细化优化阶段:局部搜索(使用粒子群优化):
- [0110] 输入数据:筛选后的优化解集合。
- [0111] 处理过程:
- [0112] 粒子群优化算法在遗传算法确定的主区域内进行局部搜索。
- [0113] 通过模拟鸟群社会行为,粒子群优化快速收敛于最优解。
- [0114] 细化调整解以提高其精确度和性能。
- [0115] 输出数据:更精细化和优化的生产配置和能源使用策略。
- [0116] 4. 迭代循环:
- [0117] 输入数据:粒子群优化的输出。
- [0118] 处理过程:
- [0119] 不断迭代,结合遗传算法和粒子群优化的结果进行优化。
- [0120] 在每次迭代中,调整算法参数(如交叉率、变异率、学习因子)以适应优化过程的需求。
- [0121] 迭代继续,直至满足停止准则(如迭代次数、改进量、性能目标)。
- [0122] 输出数据:迭代优化后的生产配置和能源使用策略。
- [0123] 5. 最终优化结果:
- [0124] 输入数据:迭代过程中不断优化的结果。
- [0125] 处理过程:
- [0126] 综合遗传算法和粒子群优化过程的结果,形成最终的优化策略。
- [0127] 该策略平衡生产效率和能源消耗,实现最佳性能。
- [0128] 输出数据:最终确定的最优化的能源管理策略,它指导实际生产和能源使用,以确保最高效率和成本效益。
- [0129] 通过以上步骤,该优化算法不仅结合了遗传算法和粒子群优化的优势,还明确了每个阶段的输入输出数据,以及如何通过迭代过程不断优化生产配置和能源使用策略,从而实现生产效率和能源消耗之间的最佳平衡。
- [0130] 使用遗传算法进行全局搜索具体包括:
- [0131] 选择:从当前种群中选择出优质个体(解),作为下一代的父母,选择过程基于适应度函数,适应度函数评估每个个体的性能,即生产线的能源效率或成本效率的函数,适应度函数表示为:
$$\text{Fitness} = \alpha \times \frac{\text{产量}}{\text{能耗}} + \beta \times \frac{\text{设备运行效率}}{\text{能耗}}$$
,其中, α 和 β 是权重因子,用于调整产量和设备运行效率对总适应度的影响程度;

[0132] 交叉:选定父母个体后,通过交叉操作生成后代,通过单点交叉结合父母个体的特征产生新个体,单点交叉示例:如果有两个个体A和B,它们的编码(特征表示)可以是能耗参数和生产参数的组合,单点交叉会选择的一个交点,A和B在这个点之前的数据交换,生成两个新的个体;

[0133] 变异:为了维持种群的多样性并避免过早收敛到局部最优解,对部分个体进行变异操作,随机改变个体的特征,变异示例:对于一个个体,可以随机选择其特征中的一个或多个,并随机增加或减少其值(例如,调整能耗参数),以探索解空间的新区域。

[0134] 评估与选择具体包括:

[0135] 在遗传算法的每一代中,均对种群中的个体进行评估,并选择高性能个体进入下一代,评估与选择过程依赖适应度函数,量化每个个体解决问题的能力,基于定义好的适应度函数对每个个体进行评估,高适应度的个体表明其对应的生产配置和能源使用策略更优;

[0136] 选择过程:根据适应度进行选择,采用轮盘赌选择,使高适应度个体具有高概率被选为下一代的父母。

[0137] 轮盘赌选择法是按照个体适应度占总适应度的比例来分配选择概率,每个个体被选择的概率等于其适应度除以总适应度之和。这样,适应度高的个体被选中的机会更大,但适应度低的个体也有机会被选中,保持了种群的多样性。

[0138] 细化优化阶段,粒子群优化算法用于在遗传算法确定的解区域内进行局部搜索,粒子群优化算法处理过程包括:

[0139] 粒子群中的每个粒子代表一个潜在解,即对应的生产配置和能源使用策略;

[0140] 每个粒子根据个体经验(个体最佳位置)和集体经验(全局最佳位置)调整其搜索方向和速度,粒子更新计算如下:

$$[0141] \quad v_i(t+1) = w \cdot v_i(t) + c_1 \cdot \text{rand}() \cdot (p_i - x_i(t)) + c_2 \cdot \text{Rand}() \cdot (p_g - x_i(t));$$

$$[0142] \quad x_i(t+1) = x_i(t) + v_i(t+1);$$

[0143] 其中, $v_i(t+1)$ 是粒子*i*在时间*t+1*的速度, $x_i(t)$ 是粒子*i*在时间*t*的位置, p_i 是粒子*i*的个体最佳位置, p_g 是全局最佳位置, w 是惯性权重,控制粒子速度的持续性, c_1 和 c_2 是加速常数,控制粒子向个体最佳和全局最佳移动的速度, $\text{rand}()$ 和 $\text{Rand}()$ 是区间[0.1]内的随机数。通过这种方式,PSO算法可以有效地在全局最优的附近区域进行细化搜索,找到更优的解

[0144] 迭代循环是遗传算法和粒子群优化交替执行的过程,在每次迭代中,遗传算法和粒子群优化的参数根据之前迭代的结果进行调整,参数包括交叉率、变异率(遗传算法参数)和加速常数、惯性权重(粒子群优化参数);

[0145] 最终优化结果综合考虑遗传算法和粒子群优化过程中得到的最佳解,以形成最终的优化策略,最终策略平衡生产效率和能源消耗,确保在满足生产需求的同时实现能源使用的最优化。最终的优化策略将指导实际的生产和能源管理决策,如调整生产线速度、设备运行模式和能源分配,以实现最优的能源和生产效率。

[0146] 遗传算法(GA)参数调整策略如下:

[0147] 交叉率:交叉率决定了新一代中有多少个体将通过交叉操作产生,如果发现当前

种群的多样性不足,可以提高交叉率,以增加种群的探索能力和多样性。

[0148] 调整策略:如果连续几次迭代后,最优解没有显著改进,可以提高交叉率;如果种群的多样性过高,导致优化方向不明确,则可以适当降低交叉率。

[0149] 变异率:变异率决定了种群中有多少个体会经历变异操作,变异可以引入新的遗传特征,增加种群的多样性。

[0150] 调整策略:如果优化过程陷入局部最优,可以提高变异率,以增加跳出局部最优的可能性;反之,如果种群变化过大,导致搜索过程不稳定,则减少变异率。

[0151] 粒子群优化(PSO)参数调整策略如下:

[0152] 加速常数:加速常数包括个体学习因子(c1)和社会学习因子(c2),分别代表粒子跟随自身经验和群体经验的倾向。

[0153] 调整策略:如果粒子趋向于快速聚集,会导致早熟收敛,这时可以减少c2以增加探索;如果搜索过程过于分散,可以增加c2以加强粒子间的信息共享和合作。

[0154] 惯性权重(w):

[0155] 惯性权重决定了粒子保持当前速度方向的倾向,它平衡了全局探索和局部开发的能力。

[0156] 调整策略:通常采用动态调整方法,如迭代初期设置较高的惯性权重以促进全局探索,随着迭代进展减小惯性权重以加强局部搜索。例如,可以使用线性递减策略,从较高的初始值逐渐降低至较低的终止值。

[0157] 通过这样动态调整GA和PSO的参数,可以在全局搜索和局部搜索之间动态平衡,有效地探索解空间,提高找到全局最优解的概率。这种自适应调整策略有助于优化算法适应不同阶段的搜索需求,从而提高整个优化过程的效率和效果。

[0158] 设面粉生产线有几个关键操作点,需要优化能源消耗和生产效率。目标是减少能源成本,同时保持或提高生产量。

[0159] 步骤1:数据采集与集成:

[0160] 在生产线的关键设备上安装能源计量设备和传感器,实时采集能源消耗数据(如电力、水和燃气消耗)和生产数据(如生产量、设备运行状态)。

[0161] 数据集成后形成一个综合数据集,包含时间戳、能源消耗量、生产量等信息。

[0162] 步骤2:初始阶段 — 使用遗传算法进行全局搜索:

[0163] 初始化遗传算法:随机生成一组初始解,每个解代表一种生产配置和能源使用方案。

[0164] 进行全局搜索:

[0165] 评估每个解的适应度,通过计算每单位产品的能源消耗来衡量。

[0166] 应用遗传操作(选择、交叉、变异)生成新的种群。

[0167] 重复此过程,直到找到一组潜在的优化解集合。

[0168] 步骤3:细化优化 — 使用粒子群优化进行局部搜索

[0169] 以GA的输出作为PSO的输入:选择GA过程中表现最好的解作为PSO的初始粒子位置。

[0170] 进行局部搜索:

[0171] 粒子根据自身的最佳位置和群体的最佳位置更新自己的速度和位置。

- [0172] 每个粒子的新位置代表一个更新的生产能源使用方案。
- [0173] 重复迭代,直到在局部解空间找到更优的解。
- [0174] 步骤4: 迭代优化过程:
- [0175] 交替使用GA和PSO,通过迭代改进解的质量:
- [0176] 根据前一次迭代的结果动态调整GA和PSO的参数,如交叉率、变异率、惯性权重等。
- [0177] 每次迭代后评估当前找到的最优解,检查是否满足停止条件(如迭代次数、改进量等)。
- [0178] 步骤5: 产生最终优化结果:
- [0179] 综合迭代过程中得到的最佳解,形成最终的优化策略,该策略在保证生产效率的同时最小化能源消耗。
- [0180] 实施最终策略,调整生产线的实际运行参数,如调整机器运行速度、更换或调整设备配置、优化能源分配等。
- [0181] 实际应用
- [0182] 通过这个集成迭代式优化过程,发现某些设备在特定时间段内能耗异常高,而通过调整这些设备的运行计划或参数,可以显著减少能源消耗而不影响生产量,或者,可以识别出通过轻微增加某些设备的能耗,可以在总体上提高生产效率和降低成本。
- [0183] S4中引入强化学习技术,通过观察生产过程的反馈来不断优化其决策,具体包括:
- [0184] 定义强化学习环境:通过定义状态来表示生产线的当前状况,当前状况包括能耗数据、生产速度、原料使用量、产品质量指标;通过动作集定义可执行的操作,包括调整设备参数、更改能源输入、修改生产节奏;通过定义奖励,奖励信号基于生产效率和能源消耗的目标,减少能源消耗和提高生产效率时给予正奖励,反之给予负奖励;
- [0185] 选择基于策略的算法PPO(Proximal Policy Optimization)来处理连续的状态和动作空间,在复杂生产环境中找到最优策略;
- [0186] 使用集成迭代式多目标优化算法分析得到的最优生产配置和能源使用策略作为强化学习的训练基础,训练过程中,通过尝试不同的动作并观察结果(如能源消耗和生产量),学习如何调整生产配置以优化能源使用,通过,不断试错学习,更新其策略以最大化长期奖励;
- [0187] 将训练好的强化学习模型部署到生产环境中,实时接收状态数据,并根据模型的策略输出动作来调节生产过程,监控模型的性能和决策效果,确保它能稳定地减少能源成本同时保持或提高生产效率。
- [0188] PPO算法具体包括:
- [0189] 策略函数:策略函数 $\pi_{\theta}(a|s)$ 表示在给定状态 s 下选择动作 a 的概率,其中 θ 表示策略网络的参数,在本发明中,状态 s 是当前的生产线状态,包括能耗、生产速率等,动作 a 是调整设备设置或改变能源使用策略;
- [0190] 优势函数:优势函数 $A(s,a)$ 表示执行动作 a 在状态 s 下比平均情况更好的程度,在生产环境中,优势函数可以帮助识别哪些动作会导致比当前策略更好的能源使用效率或生产性能;
- [0191] 目标函数:PPO算法的目标是最大化一个裁剪的目标函数,该目标函数基于概率比

率 $r(\theta) = \frac{\pi_{\theta}(a|s)}{\pi_{\theta_{old}}(a|s)}$,其中 θ_{old} 是旧策略的参数,目标函数定义为:

[0192] $L(\theta) = \hat{\mathbb{E}}[\min(r(\theta)A(s,a), \text{clip}(r(\theta), 1 - \epsilon, 1 + \epsilon))A(s,a))]$,其中 ϵ 是一个小常数,取值0.2,用于限制策略更新的步幅, $r(\theta)$ 为概率比例, clip 为裁剪函数,用于将 $r(\theta)$ 的值限制在 $[1 - \epsilon, 1 + \epsilon]$ 范围内;

[0193] PPO算法的运算过程如下:

[0194] 策略评估:利用收集到的生产和能源数据,评估当前策略 $\pi_{\theta_{old}}$ 的性能,计算每个状态动作对的优势函数 $A(s,a)$ 。

[0195] 策略改进:通过优化目标函数 $L(\theta)$ 来更新策略参数 θ ,即寻找能够提高预期奖励的策略参数。

[0196] 裁剪更新:通过 $\text{clip}(r(\theta), 1 - \epsilon, 1 + \epsilon)$ 限制策略更新的幅度,防止策略更新过大导致性能急剧下降。

[0197] 在本发明中,应用PPO算法有效地在生产线的操作中进行策略优化,自动调整生产参数和能源使用策略,以实现能源成本的最小化同时保持或提高生产效率。通过不断地交互学习和策略更新,系统能够适应生产环境的变化,持续优化生产过程的能源效率。

[0198] 所属领域的普通技术人员应当理解:以上任何实施例的讨论仅为示例性的,并非旨在暗示本发明的范围被限于这些例子;在本发明的思路下,以上实施例或者不同实施例中的技术特征之间也可以进行组合,步骤可以以任意顺序实现,并存在如上所述的本发明的不同方面的许多其它变化,为了简明它们没有在细节中提供。

[0199] 本发明旨在涵盖落入权利要求的宽泛范围之内的所有这样的替换、修改和变型。因此,凡在本发明的精神和原则之内,所做的任何省略、修改、等同替换、改进等,均应包含在本发明的保护范围之内。

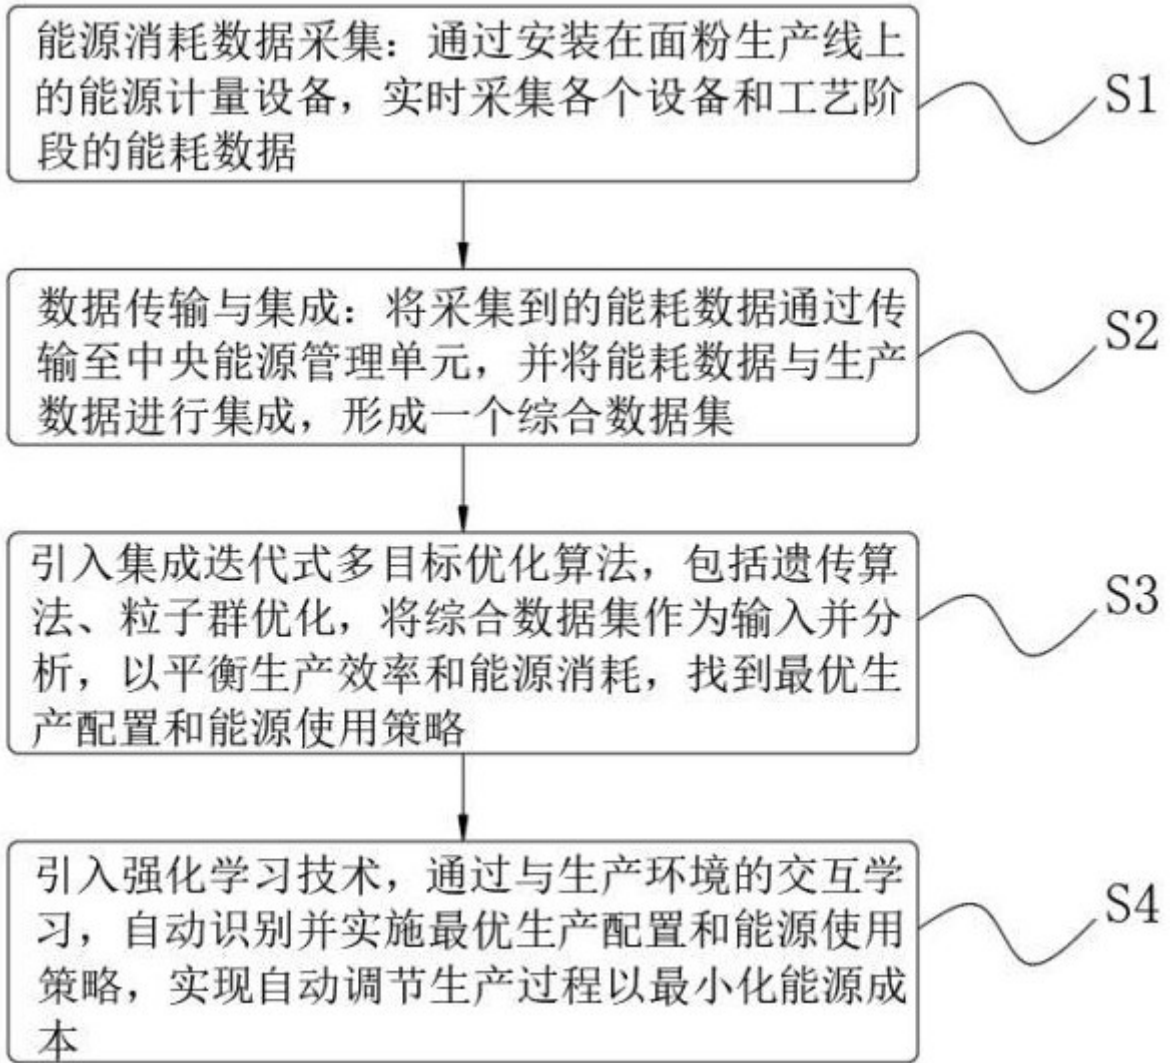


图 1



图 2