

基于数据子空间 PLS 建模技术的热轧轧制力优化设定

洪悦^{a,b}, 唐立新^{a,c}, 张颜颜^{a,c}

(东北大学 a. 物流优化与控制研究所, b. 流程工业综合自动化国家重点实验室, c. 辽宁省制造系统与物流优化重点实验室, 沈阳 110004)

摘要: 针对机理模型难以刻画的热轧精轧生产过程, 采用基于数据子空间的偏最小二乘方法建立热轧轧制力数据模型, 并构建轧制力优化模型, 利用改进的粒子群优化算法对优化模型计算求解. 结果表明, 使用数据驱动方法建立的轧制力数据模型能够揭示精轧过程轧制力的机理规律, 可以替代机理模型在实际系统中的应用. 通过对整体优化模型的求解, 可以提高热轧精轧产品的质量, 降低能源消耗, 表明基于数据驱动的建模和优化方法在实际生产中具有较大的应用价值.

关键词: 数据驱动; 偏最小二乘; 数据子空间; 轧制力; 热轧

中图分类号: TP273

文献标志码: A

Optimization of rolling force of hot rolling by using data subspace PLS modeling technique

HONG Yue^{a,b}, TANG Li-xin^{a,c}, ZHANG Yan-yan^{a,c}

(a. Institute of Logistics, b. State Key Laboratory of Synthetical Automation for Process Industries, c. Liaoning Key Laboratory of Manufacturing Systems and Logistics, Northeastern University, Shenyang 110004, China. Correspondent: TANG Li-xin, E-mail: lxtang@tli.neu.edu.cn)

Abstract: For the problem that the physics model is difficult to describe complex finishing mill process for hot rolling production, the rolling force data model of hot rolling is build by using the data subspace-based partial least squares method. Then it is used as part of the rolling force optimization model, and the modified particle swarm optimization intelligent optimization algorithm solves the problem. By the computational analysis, the rolling force data model established by the data-driven approach is able to reveal the physics laws of the rolling force, which can be used in the actual system instead of the physics model. By solving the overall optimization model, the quality of the hot rolling finishing products is improved and energy consumption is reduced. The data-driven based modeling and optimization method has great value in the actual production process.

Key words: data driven; partial least squares; data subspace; rolling force; hot rolling

0 引言

钢铁行业作为国民经济的基础产业, 在国家建设、社会发展等方面发挥着重要作用, 而热轧工序在钢铁企业的整个流程中处于重要地位. 热轧是在再结晶温度以上将连铸板坯或初轧板坯轧制成带钢的过程, 其生产线主要由加热炉、高压水除鳞装置、定宽压力机、粗轧机、精轧机、层流冷却装置、卷曲机等组成. 连铸板坯从板坯库运送至热轧线后, 所有的连铸板坯均进入到加热炉中进行加热. 在达到生产所需的温度后, 离开加热炉, 经过高压水除去表面鳞皮、定

宽压力机侧压, 并依次通过两台粗轧机进行多道次的可逆轧制, 轧制成厚度约为 50 mm 的中间板坯, 通过 7 机架的精轧机组, 最终轧制成厚度约为 1 mm 的带钢. 经过层流冷却装置, 将带钢温度冷却至可以卷曲的温度, 再由卷取机卷成钢卷. 在热轧工艺流程中, 精轧过程是核心, 精轧机组的控制精度和稳定性对最终带钢产品的质量起着至关重要的作用, 最终影响到企业的整体效益^[1]. 用来衡量热轧带钢的厚度精度指标与精轧机组的轧制力设定精度有直接关系, 研究如何科学地对精轧机组进行轧制力优化设定, 对热

收稿日期: 2013-07-15; 修回日期: 2013-09-27.

基金项目: 国家自然科学基金项目(71302161); 国家 111 计划项目(B08015).

作者简介: 洪悦(1980—), 男, 博士生, 从事冷热轧生产过程操作优化与预测控制的研究; 唐立新(1966—), 男, 教授, 博士生导师, 从事数学规划与最优化、工业集成自动化过程优化与控制等研究.

轧实际生产具有极大的现实意义. 因此, 根据板坯的厚度、宽度、钢种、轧辊辊径、电机容量限制条件、轧制负荷限度等因素科学合理地热轧精轧机组进行轧制力分配, 可以降低热连轧生产过程中的能耗, 改善最终成品质量, 提高设备的有效利用. 因为热轧的轧制力与速度、厚度、温度等诸多轧制过程变量有关, 这些变量通常是非线性的, 并且相互之间存在耦合关系, 所以热轧轧制力优化设定的计算非常复杂.

目前, 在热轧实际生产过程中应用的轧制力设定方法主要是通过研究热轧轧制的机理, 利用其物理化学变化规律和各种守恒方程推导出数学关系式进行设定计算. 李海军等^[2]从轧制机理角度考虑了应力状态和残余应变的影响, 建立了轧制力预测模型. 刘文仲等^[3]通过将轧制力进行分解, 利用轧制原理建立了轧制力模型. 然而, 这些模型的建立均受一定条件的限制, 往往不能揭示内在的变化规律, 因此与实际的轧制效果有较大的差距. 基于这些缺点, 研究人员将智能计算和统计方法应用于热轧建模, 弥补纯机理模型的不足. Lee 等^[4]将神经网络应用于厚板轧机, 改善了轧制力预测能力. Son 等^[5]利用在线自学习神经网络预测热轧的轧制力. 近年来, 随着数据驱动建模技术的发展, 研究人员将其大量应用于工业过程建模, 模型的精度大幅提高. 刘强等^[6]针对复杂工业过程中大量数据的特性, 综述了基于数据驱动方法的优势特点. Wang 等^[7]总结了数据驱动方法在故障诊断和容错控制中的应用状况. Kadlec 等^[8]总结了过程工业中通常使用的数据驱动建模技术. 侯忠生等^[9]从控制理论、实际应用角度说明了数据驱动控制理论和方法的适用条件. Tang 等^[10]利用在线主元分析方法进行过程建模.

复杂工艺过程的机理模型难以获得, 而且即使存在机理模型也很难准确地刻画工艺过程, 因此本文提出一种新的基于数据驱动的建模方法——基于数据子空间的偏最小二乘(PLS)方法. 该方法利用大量的历史生产数据, 通过对其进行分析, 从而辨识出规律信息, 揭示生产过程的输入输出关系, 实现热轧轧制力的建模. 利用改进的粒子群优化算法(MPSO), 在热轧轧制力的数据驱动模型基础上, 以质量、经济为目标, 对轧制力进行优化设定计算. 通过应用验证, 表明了基于数据驱动的轧制力优化模型和算法在实际热轧系统中具有良好的应用效果.

1 基于数据驱动模型的轧制力优化策略

针对热轧轧制力优化设定问题, 提出基于数据驱动模型的热轧轧制力优化策略. 该策略建立基于数据的优化模型并求解, 其核心是利用数据驱动方法建立轧制力数据模型, 在该轧制力模型的基础上, 选择目

标建立优化模型, 并将轧制力数据模型作为约束条件之一, 使用MPSO方法进行计算求解, 具体流程如图1所示. 首先收集热轧生产系统的历史和实时生产数据, 将其存入数据库; 然后对这些生产数据进行预处理, 取出90%的数据, 利用基于数据子空间的PLS方法进行建模, 回归出轧制力模型, 利用其余10%的数据进行模型精度校验; 最后采用MPSO智能优化算法在轧制力模型的基础上进行轧制力优化计算和生产过程控制, 同时更新生产数据库.

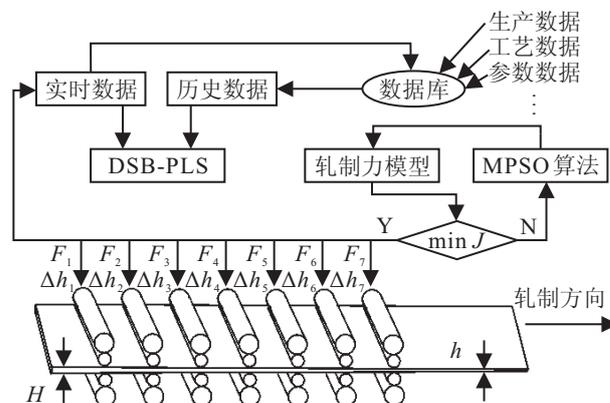


图1 基于数据驱动模型的轧制力优化设定策略

2 热轧轧制力的数据驱动模型

热轧轧制过程是极其复杂的物理化学变化过程, 涉及因素很多, 各个变量之间存在耦合关系, 且呈现出非线性特点, 难以确定出精确的轧制力机理模型. 由于自动化技术和计算机技术在热轧生产线的广泛应用, 热轧生产数据的获取变得非常容易. 这些生产数据中包含了大量热轧系统的运行机理知识和运行规律^[11], 因此, 利用基于数据驱动的方法, 从海量的生产数据中回归并辨识出热轧轧制力模型是一种有效的方法.

2.1 数据的预处理

在建立数据驱动模型前, 要对所有数据进行预处理, 去除不准确的数据^[12]. 令

$$X \in \mathbf{Z}^{M' \times d}.$$

其中: $\mathbf{Z}^{M' \times d}$ 为原始的历史数据空间, X 为空间中的数据向量, d 为数据向量的维数, M' 为原始的数据向量个数. 针对数据向量的每一维度, 将原始数据按照其数值的大小进行升序排列. 找出前5%的数据和后5%的数据, 将这些数据向量从 \mathbf{Z} 中删除, 最终得到 $X \in \Omega$, Ω 为处理后的有效数据集, 利用这些数据进行建模.

2.2 数据子空间划分

对于数据空间 Ω , 其维度为 d , 数据的个数为 M , 每个数据对象表示为 $X_i (0 \leq i \leq M)$ 或 $x_{ij} (0 \leq i \leq M, 0 \leq j \leq d)$. 为了建立精确的数据模型, 需要将相

似的数据划分在同一个数据子空间内, 因此采取一种基于自适应变深度的划分方法. 在对数据空间 Ω 中的数据进行子空间划分时, 将整个空间划分为若干个连续的 d 维超立方体, 这样在回归建模时无需在整个数据空间中进行, 只在各自的子空间中完成即可. 子空间划分的步骤如下.

Step 1: 确定子空间的个数. 假设按照每一维度将 Ω 划分成 q^j ($0 \leq j \leq d$) 个子集, X_i 每一维度的最大值和最小值分别为 X_{\max}^j 和 X_{\min}^j ($0 \leq j \leq d$), 划分空间的原则是尽量用较少数量的子空间将所有数据划分开, 使相似的数据在同一子空间之内, 则有 $2 \leq q^j \leq \text{Min}(M, X_{\max}^j - X_{\min}^j)$, 子空间的个数为 $q^1 q^2 \cdots q^j$. 在整个子空间的划分过程中, 整数 q^j 由 2 增加到 $\text{Min}(M, X_{\max}^j - X_{\min}^j)$.

Step 2: 确定超立方体的边界. 用 LU_{jt} 和 LD_{jt} 分别表示第 j 维度上第 t ($2 \leq t \leq q^j$) 个子空间的上边界和下边界, 有

$$LU_{jt} = \left\lfloor \frac{(X_{\max}^j - X_{\min}^j)(t+1)}{q^j} \right\rfloor,$$

$$LD_{jt} = \left\lfloor \frac{(X_{\max}^j - X_{\min}^j)t}{q^j} \right\rfloor.$$

Step 3: 自适应改变空间深度. 由最少的空间个数开始子空间划分, 计算划分后每个子空间中数据点的数量 P_i ($i = 1, 2, \dots, q^1 q^2 \cdots q^j$). 统计 $P_i = 0$ 的数量, 当其小于给定值 ε 时, 表明子空间划分得不够细致, 应该增加空间划分的深度, 因此增加 q^j 的数值继续深入划分空间, 直到空间的数量达到 ε 时停止.

Step 4: 子空间的合并. 划分空间后, 如果部分空间中只有一个数据, 则计算该数据与其相邻空间内数据的欧式距离的均值, 并将该数据空间与均值最小的数据空间合并, 最终确定 q 个子空间.

2.3 基于数据子空间的 PLS

针对已划分的 q 个子空间, 使用 PLS 回归方法建立数据模型. 该方法是一种集典型相关分析、主成分分析和多元回归功能为一体的建模方法, 由 Wold 等^[13-14]于 1983 年提出. PLS 回归方法能够对数据信息进行分解和筛选, 并提取出描述性因子, 建立自变量的潜变量与因变量的潜变量的回归模型, 从而得到自变量与因变量之间的关系模型. 针对海量数据的建模, Wold 等^[15]于 1996 年提出了递阶偏最小二乘回归, 该方法将自变量集合划分成若干子集合, 然后针对每个子集合建立因变量的偏最小二乘回归模型, 再将子集合中提取的主成分作为自变量和最终的因变量建立整体的回归模型. 在整个回归建模过程中使用 2 次偏最小二乘回归, 并且分成 2 级模型进行回归. 本文提出的基于数据子空间的 PLS 方法, 与该方法有相似

之处, 均是用于处理海量数据的建模. 但是, 基于数据子空间的 PLS 方法使用空间划分技术将整体数据空间分割成子空间, 然后在每个子空间中利用 PLS 方法进行回归建模, 只需进行一次偏最小二乘回归.

基于数据子空间的 PLS 方法的具体步骤如下. 在 q 个子空间中, 依次使用非线性迭代偏最小二乘 (NIPALS) 方法进行回归建模.

Step 1: 设第 t 个子空间中包含数据点的数目为 P_t , 根据数据的实际意义定义输入和输出数据的边界 s , 当 $j \leq s$ 时, x_{ij} 为输入数据, 即自变量, 令自变量矩阵为 X^t ; 当 $j > s$ 时, x_{ij} 为输出数据, 即因变量, 令因变量矩阵为 Y^t . 计算 X^t 的得分向量 t 、载荷向量 p' 、 Y^t 的得分向量 u 和载荷向量 q' .

Step 2: 计算 X^t 和 Y^t 矩阵的残差分别为

$$E = X^t - tp', \quad F = Y^t - uq'.$$

Step 3: 计算预测误差平方和 S_{Press} , 当其小于预期精度时, 继续选择主元进行迭代计算; 当其大于预期精度时, 表明已经得到了最佳的主元数目, 可以得到 X^t 和 Y^t 矩阵的关系表达式, 从而得到该子空间上的回归模型 $Y^t = F_t(X^t)$.

Step 4: 继续计算下一子空间的回归模型, 并得到所有子空间的回归模型.

将上述建模方法应用于热轧实际生产数据, 计算出热轧制力数据驱动模型.

3 基于 MPSO 算法的轧制力优化计算

3.1 建立基于数据驱动的轧制力优化模型

热轧精轧过程的核心工作是分配各机架的压下量和轧制力, 确定各机架的出口厚度, 最终轧制出所需的产品. 然而, 各机架压下量的设定值均在一定的范围内, 可以有多种设定方式, 不同的设定方式会导致不同的轧制能耗和产品质量, 因此要寻找在轧制能耗低、产品质量好的前提下的最优设定值. 以各机架的压下量 Δh_i 为决策变量, 以能耗最低和板形良好为目标, 建立轧制力优化模型, 优化目标函数为

$$J = \delta_1 \sum_{i=1}^n (HP_i - \alpha HP'_i) + \delta_2 \sum_{i=1}^n (F_i - F'_{\text{opti}})^2.$$

其中: n 为机架的组数, δ_1 为电机功率因素的权重系数, δ_2 为板形因素的权重系数, HP_i 为第 i 组机架主电机的轧制功率, α 为主电机的负荷系数, HP'_i 为第 i 组机架主电机的额定功率, F_i 为第 i 组机架的轧制力, F'_{opti} 为满足板形要求的第 i 组机架的最优轧制力^[16].

根据热轧的生产特性, 确定如下的约束条件:

1) 电机能力约束. 保证主电机在正式生产过程中不过载, 因此轧制力、轧制功率不超过主电机允许的

最大值,即

$$0 \leq F_i \leq F_{i \max}, 0 \leq HP_i \leq HP'_i,$$

其中 $F_{i \max}$ 为第 i 组机架允许的最大轧制力。

2) 工艺条件约束. 为了保证带钢的板形质量好, 带钢在通过每组机架时不能发生较大的形变, 则压下量和压下率必须在一定范围之内, 即

$$\Delta h_{\min i} \leq \Delta h_i \leq \Delta h_{\max i},$$

$$\varepsilon_{\min i} \leq \varepsilon_i \leq \varepsilon_{\max i}.$$

其中: ε_i 为第 i 组机架的压下率, $\Delta h_{\min i}$ 和 $\Delta h_{\max i}$ 分别为第 i 组机架允许的压下量最小值和最大值, $\varepsilon_{\min i}$ 和 $\varepsilon_{\max i}$ 分别为第 i 组机架允许的压下率最小值和最大值。

3) 轧制力与压下量的关系. 利用上述数据驱动方法获得该模型, 即

$$F_i = f^{DD}(\Delta h_i).$$

因此, 优化问题就是要寻找一组最优的各机架压下量 Δh_i , 使得

$$\min J;$$

$$\text{s.t. } 0 \leq F_i \leq F_{i \max},$$

$$0 \leq HP_i \leq HP'_i,$$

$$\Delta h_{\min i} \leq \Delta h_i \leq \Delta h_{\max i},$$

$$\varepsilon_{\min i} \leq \varepsilon_i \leq \varepsilon_{\max i},$$

$$F_i = f^{DD}(\Delta h_i).$$

3.2 改进的 PSO 优化算法

PSO 算法是一种基于种群的进化算法, 最早由 Kenney 等^[11]于 1995 年提出. PSO 算法在开始执行时需要构建种群, 种群中的粒子代表优化问题的一个解, 每个粒子均具有位置和速度属性, 通过位置和速度的更新, 实现粒子在解空间中的搜索和飞翔, 并依据自身的历史信息 and 整个群体的社会信息, 促使粒子群向全局最优解靠近. 在热轧轧制力优化问题中, 粒子种群为 N_p , 粒子的位置为 P_{ik} , 它代表压下量, 粒子的速度为 V_{ik} , $P_{\text{best}_{ik-1}}$ 为第 k 次迭代时第 i 个粒子找到的历史最好解, $G_{\text{best}_{ik-1}}$ 为第 k 次迭代时所有粒子找到的历史最好解. 在 PSO 算法迭代过程中, 使用下列公式^[18]进行更新:

$$v_{ik} = c_0 v_{ik-1} + c_1 \text{rand}_1 (P_{\text{best}_{ik-1}} - p_{ik-1}) +$$

$$c_2 \text{rand}_2 (G_{\text{best}_{ik-1}} - p_{ik-1}),$$

$$p_{ik} = p_{ik-1} + v_{ik}.$$

智能优化算法在迭代搜索过程中, 既要有较好的分散性, 也要有较好的搜索深度, 这样才能具有良好的性能, 搜索到全局最优解. 基本的 PSO 算法具有较快的收敛速度, 但也极易陷入局部最优, 因此需要对

基本的 PSO 算法进行改进. 针对极易陷入局部最优的缺点, 提出多种群和扰动策略, 极大程度地增加算法的分散性, 同时增加了局部搜索策略, 便于搜索到质量更好的解.

本文提出的改进 PSO 算法步骤如下.

Step 1: 设置基本参数, 包括种群规模、惯性权重、最大位置、最大速度、最大迭代次数等.

Step 2: 随机产生初始种群, 迭代次数 $k = 1$.

Step 3: 计算种群 S 中每个粒子的适应度值 J , 记录每个粒子的个体最好位置和全局最好位置, 并找出最优粒子.

Step 4: 判断是否达到终止条件, 如果达到, 则输出最优解, 否则执行 Step 5.

Step 5: 将种群 S 中的粒子平均分成两个子种群 S_1 和 S_2 , 子种群 S_1 汇集质量较好的一半粒子, 子种群 S_2 汇集质量较差的一半粒子. 利用上述速度和位置更新公式, 分别对每个子种群中的所有粒子执行更新操作. 在更新时, 子种群 S_1 中的粒子使用整个种群的历史最好解作为全局最优位置; 子种群 S_2 中的粒子使用本种群的历史最好解作为全局最优位置.

Step 6: 增加扰动策略, 算法每迭代 50 次, 便在于子种群 S_1 的粒子位置更新公式中加入高斯噪声干扰.

Step 7: 对最优个体按照其负梯度方向进行局部搜索, 并替换种群中相应的粒子, 使用下述公式实现:

$$s_{k-1} = -\nabla J(p_{ik-1}),$$

$$\hat{s}_{k-1} = \frac{s_{k-1}}{\|s_{k-1}\|},$$

$$p_{ik} = p_{ik-1} + \rho_{ik-1} \hat{s}_{k-1}.$$

其中: s_{k-1} 为粒子在 p_{ik-1} 位置的搜索方向, \hat{s}_{k-1} 为粒子搜索方向的单位向量, ρ_{ik-1} 为搜索步长.

Step 8: 判断新的最优个体是否满足约束条件, 如果满足, 则执行 Step 9, 否则执行 Step 5.

Step 9: 更新迭代次数 $k = k + 1$, 转至 Step 3.

4 应用分析

4.1 热轧轧制力建模

以国内某钢铁企业的 7 机架热轧系统为例, 验证上述数据驱动建模方法. 本文选择实际生产数据 110 组, 在此基础上随机产生 60 组数据, 剔除异常数据 25 组, 最后选择 145 组数据. 使用其中的 120 组数据构成训练数据集, 另外 25 组作为测试数据集. 以第 1 机架 F1 的轧制力为例, 实验结果如图 2 所示.

由图 2 可见, 实线为系统正常生产时的实际轧制力数值曲线, 虚线为利用基于数据驱动模型计算出的轧制力曲线, 这两条曲线基本吻合, 而且与实际的生产数据相比, 利用基于数据驱动模型计算出的轧

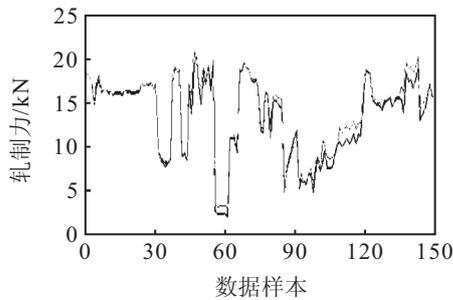


图2 实际的F1轧制力数据与模型计算结果比较

制力数据的平均偏差在5%以内, 具有较高的精度. 利用基于数据驱动的方法建立的轧制力模型, 可以对生产不同产品时的轧制力数值进行预测并设定.

4.2 热轧轧制力优化

热轧精轧机组生产信息如下: 钢种为 SPHC, 成品宽度为 1010 mm, 来料厚度为 35.2 mm, 成品厚度为 3.1 mm, 入口温度为 1055°, 出口温度为 821°, 凸度为 0.019 mm. 热轧精轧机组的技术参数: 工作辊直径为 380 mm, 最大允许轧制力为 35 000 kN, 电机额定功率为 8 000 kW, 电机转速为 1 650 rpm. 改进 PSO 算法的基本参数设置如下: 种群规模为 40, 最大允许位置为 40 000, 最大允许速度为 10, 最大迭代次数为 5 000, 偏差值为 0.02, 惯性权重为 0.9, 加速因子为 1.494 45.

图3显示了改进 PSO 算法的全局最好粒子的进

化过程. 由图3可见, 该算法的收敛速度较快, 在迭代计算 500 次时, 其结果非常接近于最终的优化结果, 在迭代计算 3 500 次后, 改进的算法已经收敛到最优目标. 因此, 该算法在极短的时间内即可搜索到满意的结果.

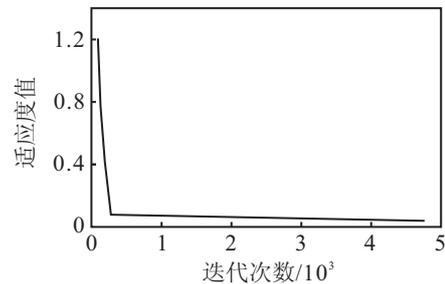


图3 改进 PSO 算法的进化效果

表1列出了经过 100 次重复计算求得的平均最优结果和现场实际系统的数据. 由表1可见, 当现场系统运行时, 7 个机架的电机总功率为 19 335 kW; 通过改进 PSO 优化算法计算出的电机总功率为 19 011 kW. 与现场实际系统数据相比, 经过优化计算的电机总功率减少了 324 kW, 减少能耗可达 1.6%. 经实验分析比较, 本文提出的基于数据驱动的优化模型和算法能够准确地利用数据进行高精度建模, 并在此数据模型的基础上优化计算, 在保证质量的前提下, 能够降低系统能耗, 可应用于生产实际系统.

表1 现场实际数据与优化计算结果的比较

参数	机架							
	1	2	3	4	5	6	7	
实际数据	入口厚度/mm	35.2	23.1	15.9	10.4	7.12	5.5	4.2
	出口厚度/mm	23.1	15.9	10.4	7.12	5.5	4.2	3.1
	轧制力/kN	18 087	13 766	13 630	11 764	9 987	9 414	7 948
	电机功率/kW	3 832	3 109	2 971	2 698	2 402	2 392	1 931
	总功率/kW	19 335						
优化计算结果	入口厚度/mm	35.2	24.2	15.3	9.9	7.8	5.8	4.3
	出口厚度/mm	24.2	15.3	9.9	7.8	5.8	4.3	3.1
	轧制力/kN	16 133	13 958	13 474	11 592	10 420	9 605	8 114
	电机功率/kW	3 418	3 152	2 966	2 649	2 506	2 398	1 922
	总功率/kW	19 011						

5 结 论

本文基于数据空间划分技术, 将数据子空间与 PLS 结合在一起, 建立起精度较高的轧制力数据驱动模型. 以节能降耗和板形良好为目标, 利用多种群和局部搜索改进的 PSO 智能优化算法, 在轧制力数据模型基础上, 优化了热轧精轧机组的轧制力设定. 通过应用分析, 表明了所提出建模和优化方法具有良好的性能, 通过与人工操作相比, 表明了该方法的有效性, 并且可以应用于实际热轧系统, 解决机理模型建模难、不准确和参数优化设定等问题.

参考文献(References)

[1] 孙一康. 带钢热连轧的模型与控制[M]. 北京: 冶金工业出版社, 2002: 105.
(Sun Y K. Hot strip continuous mill model and control[M]. Beijing: Metallurgical Industry Press, 2002: 105.)

[2] 李海军, 徐建忠, 王国栋. 热轧带钢精轧过程高精度轧制力预测模型[J]. 东北大学学报: 自然科学版, 2009, 30(5): 669-672.
(Li H J, Xu J Z, Wang G D. High-precision rolling force prediction model for hot strip continuous rolling process[J]. J of Northeastern University: Natural Science, 2009, 30(5):

- 669-672.)
- [3] 刘文仲, 吕志民. 热连轧带钢压力数学模型及其建模方法研究[J]. 钢铁, 2002, 37(5): 34-37.
(Liu W Z, Lv Z M. Study of rolling force model on hot strip mill[J]. Iron and Steel, 2002, 37(5): 34-37.)
- [4] Lee D M, Choi S G. Application of on-line adaptable neural network for rolling force set-up of a plate mill[J]. Engineering Applications of Artificial Intelligence, 2004, 17(5): 557-565.
- [5] Son J S, Lee D M, Kim I S, et al. A study on online learning neural network for prediction for rolling force in hot rolling mill[J]. J of Materials Processing Technology, 2005, 1(164/165): 1612-1617.
- [6] 刘强, 柴天佑, 秦泗钊, 等. 基于数据和知识的工业过程监视及故障诊断综述[J]. 控制与决策, 2010, 25(6): 801-807.
(Liu Q, Chai T Y, Qin S J, et al. Progress of data-driven and knowledge-driven process monitoring and fault diagnosis for industry process[J]. Control and Decision, 2010, 25(6): 801-807.)
- [7] Wang H, Chai T Y, Ding J L, et al. Data driven fault diagnosis and fault tolerant control: Some advances and possible new directions[J]. Acta Automatica Sinica, 2009, 35(6): 739-747.
- [8] Kadleca P, Gabrys B, Strandtb S. Data-driven soft sensors in the process industry[J]. Computers and Chemical Engineering, 2009, 33(4): 795-814.
- [9] 侯忠生, 许建新. 数据驱动控制理论及方法的回顾和展望[J]. 自动化学报, 2009, 35(6): 650-667.
(Hou Z S, Xu J X. On data-driven control theory: The state of the art and perspective[J]. Acta Automatica Sinica, 2009, 35(6): 650-667.)
- [10] Tang J, Yu W, Chai T Y, et al. On-line principal component analysis with application to process modeling[J]. Neurocomputing, 2012, 82(1): 167-178.
- [11] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-9.
(Li H, Xiao D Y. Survey on data driven fault diagnosis methods[J]. Control and Decision, 2011, 26(1): 1-9.)
- [12] Nelson R C, Taylor A, MacGregor F. Missing data methods in PCA and PLS: Score calculations with incomplete observations[J]. Chemometrics and Intelligent Laboratory Systems, 1996, 35(1): 45-65.
- [13] Wold S, SjEostrEom M, Eriksson L. PLS-Regression: A basic tool of chemometrics[J]. Chemometrics and Intelligent Laboratory Systems, 2001, 58(2): 109-130.
- [14] Kettaneha N, Berglundb A, Wold S. PCA and PLS with very large data sets[J]. Computational Statistics & Data Analysis, 2005, 48(1): 69-85.
- [15] Wold S, Wold K, Tjessem K. Hierarchical multiblock PLS and PC models for easier model interpretation and as an alternative to variable selection[J]. J of Chemometrics, 1996, 10(5/6): 463-482.
- [16] 刘战英. 轧制变形规程优化设计[M]. 北京: 冶金工业出版社, 1996: 188.
(Liu Z Y. Optimization design of rolling deformation schedule[M]. Beijing: Metallurgical Industry Press, 1996: 188.)
- [17] Kennedy J, Eberhart R. Particle swarm optimization[C]. Proc of IEEE Int Conf on Neural Networks. Piscataway: IEEE, 1995, 4: 1942-1948.
- [18] Shi Y, Eberhart R. A modified particle swarm optimizer[C]. Proc of IEEE Int Conf on Evolutionary Computation. New York: IEEE, 1998: 69-73.

(责任编辑: 郑晓蕾)