



(12)发明专利

(10)授权公告号 CN 103593493 B

(45)授权公告日 2017.02.08

(21)申请号 201310259351.X

程科技I辑》.2012,(第6期),B022-41.

(22)申请日 2013.06.26

唐慕.基于OS-ELM-RPLS的间歇过程软测量建模与迭代控制.《中国优秀硕士学位论文全文数据库 工程科技II辑》.2012,(第3期),C028-68.

(65)同一申请的已公布的文献号

申请公布号 CN 103593493 A

唐慕.基于OS-ELM-RPLS的间歇过程软测量建模与迭代控制.《中国优秀硕士学位论文全文数据库 工程科技II辑》.2012,(第3期),C028-68.

(43)申请公布日 2014.02.19

(73)专利权人 东北大学

地址 110819 辽宁省沈阳市和平区文化路3巷11号东北大学135信箱

审查员 薛杰

(72)发明人 肖冬

(51)Int.Cl.

G06F 17/50(2006.01)

(56)对比文件

JP 2012117995 A,2012.06.21,

肖冬.无缝钢管生产过程质量预报及关键参数优化控制.《中国博士学位论文全文数据库 工

权利要求书1页 说明书6页 附图3页

(54)发明名称

一种基于集成梯度数据ELM-PLS方法的减径管质量预报方法

(57)摘要

针对无缝钢管减径生产中衡量减径管管质量好坏的横向和纵向壁厚不均检验滞后和难以建立其机理模型的问题,考虑其时变、非线性、快速间歇、数据梯形分布等的生产特点,提出了基于集成梯度数据ELM-PLS方法的减径管质量预报模型。介绍了集成梯度数据ELM-PLS方法中过程数据时段分解、均值求取、回归模型建立和模型在线预报等内容,并将建立的预报模型用于减径管质量预报中。实验和仿真表明,基于集成梯度数据ELM-PLS预报方法模型有效地提高了减径钢管质量预报精度,为减径钢管生产质量控制提供了模型依据,并且其维护费用低、实时性好、可靠性及精度高。

1. 一种基于集成梯度数据ELM-PLS的减径管质量预报方法，其特征在于：

在对减径过程各时段分析的基础上，确定了建模所需的各时段过程变量，依据变量采集建模数据后，对建模数据进行预处理；对建模数据做批次处理、时段划分、均值处理以及二维展开；在获得的三维数据的基础上，将过程数据按生产操作时段的不同，将其分段处理；先将减径管的生产过程划分为咬钢子时段、稳定轧制子时段和抛钢子时段；然后依据轧辊加入的顺序细划咬钢和抛钢阶段，将咬钢阶段细划成11个子时段，同理将抛钢阶段也细划成11个子时段，确定建模所需的各时段过程变量后，对每个过程变量在该时段取其平均值，对过程变量数据处理后，应用集成梯度数据ELM-PLS方法进行建模；

其中，所述集成梯度数据ELM-PLS方法建模与测试步骤如下：

(1) 利用交叉检验法确定潜变量个数，采用线性PLS方法计算建模样本输入X和输出Y的得分向量矩阵T和U，及负载向量矩阵P和Q；

(2) 设定ELM隐含层节点数和激活函数(如sigmoid函数)，采用ELM建立内部模型T和U之间的非线性模型，可求得 $U = f(T)$ ，式中 $f(\cdot)$ 为ELM表示的非线性函数；

(3) 利用步骤(1)中确定的潜变量个数，对测试样本 X_1, Y_1 进行线性PLS外部模型分解，得到得分向量矩阵 T_1, U_1 和负载向量矩阵 P_1, Q_1 ；

(4) 将 T_1 带入步骤(2)建立的ELM模型中，求得 $\hat{U} = f(T_1)$ ，利用 $\hat{Y} = \hat{U}Q_1^T$ 求得测试样本的预测值；

(5) 步骤(1)~(4)为其中一组模型的建模方法，集成梯度数据ELM-PLS建模方法需利用相同建模数据重复建立10组模型，各模型的区别在于使用不同的ELM输入层到隐层权值，最后使用10组数据的平均值作为最后输出质量。

一种基于集成梯度数据ELM-PLS方法的减径管质量预报方法

技术领域

[0001] 本发明涉及一种减径管质量在线预报方法,实时性好,可靠性和精度高。

背景技术

[0002] 无缝钢管被广泛应用于汽车、航空、石油、化工、建筑、锅炉和军工等各个部门,在国民经济中具有很重要的地位,故被人们称为工业的血管。随着经济的快速发展,无缝钢管的使用领域在不断扩大,对产品质量的要求也越来越高。无缝钢管的生产工序主要有穿孔、轧管和减径。穿孔和轧管时受顶杆刚度的限制,对于直径在70毫米以下的无缝钢管很难在轧管机组上获得。即使是直径大于70毫米的小型热轧无缝钢管也不希望采用小管坯轧管来生产,因为这样将使机组的生产能力大幅度下降。因此,对于小直径钢管应采用减径方式来生产才合理。由于减径工艺的采用,可用大直径管坯穿孔、轧管,而在减径机组上实现较大的减径,得到小直径的长管子。这是增加产量、扩大品种、减小消耗的有效工艺措施。世界各国越来越趋向于在钢管延伸工序上采用生产效率最高的连轧工艺生产单一规格荒管,而在减径工序通过改变工艺,来得到不同规格的成品管。

[0003] 因为张减机是钢管热轧生产的最后一道变形设备,对钢管质量影响很大,壁厚偏差是衡量钢管质量的重要指标。然而钢管减径过程机理模型欠缺,其质量监测需通过技术人员定期抽查来完成,检验结果严重滞后。因此建立具有足够精确性的钢管减径壁厚预测模型,具有重要的理论和经济意义。Macrea等学者建立了减径机的机理模型,对减径过程张力、速度、壁厚等指标进行分析,但机理模型的各种约束较多,适合个别生产机组,模型通用性较差。于辉等学者利用有限元软件模拟了无缝钢管减径生产过程,对减径后钢管的尺寸、壁厚等关键指标进行了预测,用于指导减径生产工艺参数的设定,取得了一定的实际效果。但由于有限元软件的限制,其预测精度并不高,更适合于新规格产品的开发,而不是钢管质量的在线实时控制。

发明内容

[0004] 本发明的目的,是提供一种减径管质量预报方法,能快速准确减径管质量,从而降低废品率,提高生产效益,该方法模型维护费用低,实时性好,精度高。

[0005] 针对管坯穿孔过程的复杂性,可将其分为咬钢、稳定轧制和抛钢三个子时段。本发明人提出了基于集成梯度数据ELM-PLS方法来建立减径管质量预报模型。在每个子时段选取相关过程变量的平均值作为输入变量。该方法避免了传统MPLS方法模型结构复杂、冗余数据多、计算负荷大的缺点,易于实现减径管质量的在线建模与预报。实验表明,基于集成梯度数据ELM-PLS方法模型比传统的MPLS模型具有更高的回归和预报精度,为减径管质量的提高提供了测量依据。

[0006] 在建模前,先对生产时段进行划分

[0007] 钢管减径过程,实质上是空心体无芯棒连续轧制过程。如图1所示,从钢管头部进入第一架到尾部离开最后一架可分为三个阶段。

[0008] (1) 咬钢阶段：从管头进入第1机架到管头进最后1机架为咬钢阶段。如图1所示是从钢管头部进入1号轧机开始，到钢管头部遇到12号轧机为止。钢管头部由A点运动到B点，钢管尾部由A'点运动到B'点。此时管头逐渐通过各机架，其速度随延伸系数的增加而加大。在此阶段，依据钢管的前进步进增加各轧机的影响变量。

[0009] (2) 稳定轧制阶段：从管子头部进入最后1机架到管尾还未离开第1机架，此时整个机组都在轧制一支钢管，轧制负荷及速度都是稳定的，叫稳定阶段。如图1所示是从钢管头部遇到12号轧机开始，到钢管尾部遇到1号轧机为止。钢管头部由C点运动到D点，钢管尾部由C'点运动到D'点。在稳定轧制阶段，各轧机变量对钢管都有影响。

[0010] (3) 抛钢阶段：从管尾离开第1机架到离开最后1机架。如图1所示是从钢管尾部遇到1号轧机开始，到钢管尾部遇到12号轧机为止。钢管头部由E点运动到F点，钢管尾部由C点运动到D点。此阶段同时参与轧制这支钢管的机架数逐渐减少，一直到最后一架进行单机轧制，整支钢管被轧制完毕，然后钢管被抛出机架。在抛钢阶段，依据钢管的前进步进减少各轧机的影响变量。

[0011] 然后对影响毛管质量的因素分析

[0012] (1)荒管加热温度的影响

[0013] 荒管的加热温度的高低会带来金属变形抗力的变化，进而造成轧制力和平均张力系数的变化。荒管的加热温度越高，则金属的变形抗力越低，轧制力越小，钢管的外径波动也就越小。另外，荒管的加热温度是钢管直径的函数，并且二者存在着明显的正相关关系。荒管的加热温度越高，金属受热膨胀后，钢管的热外径越大。

[0014] (2)轧制速度的影响

[0015] 对于轧制速度对荒管减径时金属横向不均匀变形的影响，学者普遍认为是通过摩擦因素来起作用的。当轧制速度越低，摩擦力也越大，因此对减小钢管的壁厚不均也就越有利。

[0016] (3)荒管质量的影响

[0017] 荒管在减径时，由于其内表面没有芯棒支撑，荒管壁厚的控制比较困难，荒管的管壁会随着轧制工艺条件的变化而处于“自由”变化状态。并且，荒管的壁厚不均会“遗传”到减径后的成品钢管上。所以，提高荒管的壁厚均匀性是确保成品钢管壁厚精度的重要条件。

[0018] (4)张力的影响

[0019] 采用张力减径机实施荒管减径时，由于张力的存在，荒管在发生直径减小的同时壁厚减薄，在稳定的张力条件下，金属的横向变形较小，有利于钢管壁厚精度的提高。但因荒管的头部在依次进入各个减径辊机架和荒管的尾端依次离开各个减径辊机架之时，机架之间不能建立起张力，或张力发生波动，因而势必会产生钢管的纵向壁厚不均。

[0020] 质量预报模型输出为减径管质量，衡量减径管质量的量化指标为横纵向壁厚不均。钢管横向壁厚不均是最大壁厚偏差与名义壁厚之比，其计算公式如下式所示。

$$[0021] \Delta S\% = \frac{\delta_{max} - \delta_{min}}{\delta_{nominal}} \times 100 \quad (1)$$

[0022] 式中： $\Delta S\%$ ——相对横向壁厚不均；

[0023] δ_{max} ——钢管的最大壁厚；

[0024] δ_{min} ——钢管的最小壁厚;

[0025] δ_{nom} ——钢管的名义壁厚。

[0026] 钢管纵向壁厚不均的大小由毛管前端壁厚的平均值与后端壁厚的平均值之差来确定,其计算公式如下式所示。

$$[0027] \Delta\delta_{av} = \frac{\sum \delta_{av}}{n} - \frac{\sum \delta_{av}}{n} \quad (2)$$

[0028] 式中: $\sum \delta_{av}$ 和 $\sum \delta_{av}$ 分别是在钢管前端和后端测得的壁厚之和; n 是每端上测量的点数。

[0029] 基于对影响减径管质量因素的上述分析,为实现减径生产的无缝钢管质量的预报,采用下述技术方案:

[0030] 生产数据的梯形预处理

[0031] 本发明在对减径过程各时段分析的基础上,确定了建模所需的各时段过程变量,依据变量采集建模数据后,需要对建模数据进行预处理。对建模数据做批次处理、时段划分、均值处理以及二维展开。在获得的三维数据的基础上,将过程数据按生产操作时段的不同,将其分段处理。本发明先将减径管的生产过程划分为咬钢子时段、稳定轧制子时段和抛钢子时段。然后依据轧辊加入的顺序细划咬钢和抛钢阶段,将咬钢阶段细划成11个子时段,同理将抛钢阶段也细划成11个子时段,确定建模所需的各时段过程变量后,对每个过程变量在该时段取其平均值,实际数据处理如图2所示。

[0032] 加入荒管加热温度 X_1 、质量精度变量 X_2 和 X_3 ,得到最终的输入矩阵

$$[0033] X = [X_{1,1}, X_{1,2}, \bar{X}_{1,3}, \bar{X}_{1,4}, \bar{X}_{1,5}, \bar{X}_{1,6}, \bar{X}_{1,7}, \bar{X}_{1,8}, \bar{X}_{1,9}, \bar{X}_{1,10}, \bar{X}_{1,11}, \bar{X}_{1,12}, \bar{X}_{1,13}, \bar{X}_{1,14}, \bar{X}_{1,15}, \\ X_{2,1}, X_{2,2}, \bar{X}_{2,3}, \bar{X}_{2,4}, \bar{X}_{2,5}, \bar{X}_{2,6}, \bar{X}_{2,7}, \bar{X}_{2,8}, \bar{X}_{2,9}, \bar{X}_{2,10}, \bar{X}_{2,11}, \bar{X}_{2,12}, \bar{X}_{2,13}, \bar{X}_{2,14}, \bar{X}_{2,15}, \\ \bar{X}_{3,1}, \bar{X}_{3,2}, \bar{X}_{3,3}, \bar{X}_{3,4}, \bar{X}_{3,5}, \bar{X}_{3,6}, \bar{X}_{3,7}, \bar{X}_{3,8}, \bar{X}_{3,9}, \bar{X}_{3,10}, \bar{X}_{3,11}, \bar{X}_{3,12}, \bar{X}_{3,13}, \bar{X}_{3,14}, \bar{X}_{3,15}, \\ \bar{X}_{4,1}, \bar{X}_{4,2}, \bar{X}_{4,3}, \bar{X}_{4,4}, \bar{X}_{4,5}, \bar{X}_{4,6}, \bar{X}_{4,7}, \bar{X}_{4,8}, \bar{X}_{4,9}, \bar{X}_{4,10}, \bar{X}_{4,11}, \bar{X}_{4,12}, \bar{X}_{4,13}, \bar{X}_{4,14}, \bar{X}_{4,15}, \\ \bar{X}_{5,1}, \bar{X}_{5,2}, \bar{X}_{5,3}, \bar{X}_{5,4}, \bar{X}_{5,5}, \bar{X}_{5,6}, \bar{X}_{5,7}, \bar{X}_{5,8}, \bar{X}_{5,9}, \bar{X}_{5,10}, \bar{X}_{5,11}, \bar{X}_{5,12}, \bar{X}_{5,13}, \bar{X}_{5,14}, \bar{X}_{5,15}, \\ \bar{X}_{6,1}, \bar{X}_{6,2}, \bar{X}_{6,3}, \bar{X}_{6,4}, \bar{X}_{6,5}, \bar{X}_{6,6}, \bar{X}_{6,7}, \bar{X}_{6,8}, \bar{X}_{6,9}, \bar{X}_{6,10}, \bar{X}_{6,11}, \bar{X}_{6,12}, \bar{X}_{6,13}, \bar{X}_{6,14}, \bar{X}_{6,15}, \\ \bar{X}_{7,1}, \bar{X}_{7,2}, \bar{X}_{7,3}, \bar{X}_{7,4}, \bar{X}_{7,5}, \bar{X}_{7,6}, \bar{X}_{7,7}, \bar{X}_{7,8}, \bar{X}_{7,9}, \bar{X}_{7,10}, \bar{X}_{7,11}, \bar{X}_{7,12}, \bar{X}_{7,13}, \bar{X}_{7,14}, \bar{X}_{7,15}, \\ \bar{X}_{8,1}, \bar{X}_{8,2}, \bar{X}_{8,3}, \bar{X}_{8,4}, \bar{X}_{8,5}, \bar{X}_{8,6}, \bar{X}_{8,7}, \bar{X}_{8,8}, \bar{X}_{8,9}, \bar{X}_{8,10}, \bar{X}_{8,11}, \bar{X}_{8,12}, \bar{X}_{8,13}, \bar{X}_{8,14}, \bar{X}_{8,15}, \\ \bar{X}_{9,1}, \bar{X}_{9,2}, \bar{X}_{9,3}, \bar{X}_{9,4}, \bar{X}_{9,5}, \bar{X}_{9,6}, \bar{X}_{9,7}, \bar{X}_{9,8}, \bar{X}_{9,9}, \bar{X}_{9,10}, \bar{X}_{9,11}, \bar{X}_{9,12}, \bar{X}_{9,13}, \bar{X}_{9,14}, \bar{X}_{9,15}, \\ \bar{X}_{10,1}, \bar{X}_{10,2}, \bar{X}_{10,3}, \bar{X}_{10,4}, \bar{X}_{10,5}, \bar{X}_{10,6}, \bar{X}_{10,7}, \bar{X}_{10,8}, \bar{X}_{10,9}, \bar{X}_{10,10}, \bar{X}_{10,11}, \bar{X}_{10,12}, \bar{X}_{10,13}, \bar{X}_{10,14}, \bar{X}_{10,15}, \\ \bar{X}_{11,1}, \bar{X}_{11,2}, \bar{X}_{11,3}, \bar{X}_{11,4}, \bar{X}_{11,5}, \bar{X}_{11,6}, \bar{X}_{11,7}, \bar{X}_{11,8}, \bar{X}_{11,9}, \bar{X}_{11,10}, \bar{X}_{11,11}, \bar{X}_{11,12}, \bar{X}_{11,13}, \bar{X}_{11,14}, \bar{X}_{11,15}, \\ \bar{X}_{12,1}, \bar{X}_{12,2}, \bar{X}_{12,3}, \bar{X}_{12,4}, \bar{X}_{12,5}, \bar{X}_{12,6}, \bar{X}_{12,7}, \bar{X}_{12,8}, \bar{X}_{12,9}, \bar{X}_{12,10}, \bar{X}_{12,11}, \bar{X}_{12,12}, \bar{X}_{12,13}, \bar{X}_{12,14}, \bar{X}_{12,15}, \\ \bar{X}_{13,1}, \bar{X}_{13,2}, \bar{X}_{13,3}, \bar{X}_{13,4}, \bar{X}_{13,5}, \bar{X}_{13,6}, \bar{X}_{13,7}, \bar{X}_{13,8}, \bar{X}_{13,9}, \bar{X}_{13,10}, \bar{X}_{13,11}, \bar{X}_{13,12}, \bar{X}_{13,13}, \bar{X}_{13,14}, \bar{X}_{13,15}, \\ \bar{X}_{14,1}, \bar{X}_{14,2}, \bar{X}_{14,3}, \bar{X}_{14,4}, \bar{X}_{14,5}, \bar{X}_{14,6}, \bar{X}_{14,7}, \bar{X}_{14,8}, \bar{X}_{14,9}, \bar{X}_{14,10}, \bar{X}_{14,11}, \bar{X}_{14,12}, \bar{X}_{14,13}, \bar{X}_{14,14}, \bar{X}_{14,15}, \\ \bar{X}_{15,1}, \bar{X}_{15,2}, \bar{X}_{15,3}, \bar{X}_{15,4}, \bar{X}_{15,5}, \bar{X}_{15,6}, \bar{X}_{15,7}, \bar{X}_{15,8}, \bar{X}_{15,9}, \bar{X}_{15,10}, \bar{X}_{15,11}, \bar{X}_{15,12}, \bar{X}_{15,13}, \bar{X}_{15,14}, \bar{X}_{15,15}], \quad (3)$$

[0034] 将前述获得三段数据均值从左向右排列既可得到一个具有147个变量均值所构成的一个输入数据矩阵 $X(1 \times 147)$ 。

[0035] 预报模型建立

[0036] 在进行建模的生产数据进行梯度处理后,将PLS、ELM建模方法结合,并采用集成技术进行多模型集成,最后得到集成梯度数据ELM-PLS模型。

[0037] (1) 非线性PLS方法

[0038] 给定两个经标准化的输入输出数据阵 $X \in \mathbb{R}^{n \times p}$ 和 $Y \in \mathbb{R}^{n \times q}$, 非线性PLS的回归模型可以表示为如下形式:

[0039] (a)外部关系模型:

$$\mathbf{X} = \mathbf{TP}^T + \mathbf{E} = \sum_{i=1}^k p_i g_i + \mathbf{E}$$

[0040]

$$\mathbf{Y} = \mathbf{UQ}^T + \mathbf{F} = \sum_{i=1}^k q_i f_i + \mathbf{F} \quad (4)$$

[0041] 其中, k 是保留的特征向量的个数, $\mathbf{t}(\mathbf{x})$ 和 $\mathbf{u}(\mathbf{x})$ 分别为 \mathbf{X} 和 \mathbf{Y} 的得分向量, $\mathbf{p}_i(\mathbf{x})$ 和 $\mathbf{q}_i(\mathbf{x})$ 分别为 \mathbf{X} 和 \mathbf{Y} 的负载向量, $\mathbf{T}(\mathbf{x} \times k)$ 和 $\mathbf{U}(\mathbf{x} \times k)$ 分别为 \mathbf{X} 和 \mathbf{Y} 的得分矩阵, $\mathbf{P}(\mathbf{x} \times k)$ 和 $\mathbf{Q}(\mathbf{x} \times k)$ 分别为 \mathbf{X} 和 \mathbf{Y} 的负载矩阵, \mathbf{E} 和 \mathbf{F} 分别为 \mathbf{X} 和 \mathbf{Y} 的拟合残差矩阵.

[0042] (b)内部关系模型:

$$\mathbf{t}_j = f(t_j) + \epsilon \quad (5)$$

[0044] 其中, $f(\cdot)$ 为非线性函数, ϵ 为参差.

[0045] (2) ELM 算法

[0046] 传统的前馈神经网络(如BP网络)在训练中采用梯度学习算法, 网络中的参数需要迭代更新, 不仅训练时间长, 而且容易导致局部极小和过度训练等问题, 另外其多隐层的结构也导致了样本训练速度慢, 训练误差大. 针对上述问题, HUANG 等人提出了一种单隐层前馈神经网络的新算法---ELM.

[0047] 任意选取 N 个样本 $(\mathbf{x}_i, t_i) \in \mathbb{R}^n \times \mathbb{R}^m$, 这里

[0048] $\mathbf{x} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$ 为输入, $t = [t_1, t_2, \dots, t_N]$ 为目标输出. 如果一个有 N 个隐含层节点的 SLFN 能以零误差来逼近这 N 个样本, 则存在 $\mathbf{a}, \mathbf{c}, \mathbf{b}$, 有

$$f_k(x_j) = \sum_{j=1}^N \mathbf{a}_j G(a_j \mathbf{x}_j + b_j) = t_j, \quad (6)$$

[0050] 式中, \mathbf{a}_j 是输入层到第 j 个隐含层节点的连接权值向量; b_j 是第 j 个隐含层节点的阈值; $a_j \mathbf{x}_j$ 表示向量 \mathbf{a}_j 和 \mathbf{x}_j 的内积. $G(a_j, b_j, x_j)$ 表示第 j 个隐含层节点与输入 \mathbf{x}_j 的关系, 激活函数 $G(\cdot) : \mathbb{R} \rightarrow \mathbb{R}$ (例如S型函数). 式(6)可以简化成:

$$\mathbf{H}\beta = \mathbf{T} \quad (7)$$

[0052] 这里,

$$[0053] \begin{aligned} & \mathbf{H} = \begin{bmatrix} \mathbf{a}_1 & \mathbf{a}_2 & \cdots & \mathbf{a}_N \\ \mathbf{G}(a_1 \mathbf{x}_1 + b_1) & \mathbf{G}(a_2 \mathbf{x}_1 + b_2) & \cdots & \mathbf{G}(a_N \mathbf{x}_1 + b_N) \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{G}(a_1 \mathbf{x}_N + b_1) & \mathbf{G}(a_2 \mathbf{x}_N + b_2) & \cdots & \mathbf{G}(a_N \mathbf{x}_N + b_N) \end{bmatrix}; \quad \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_N \end{bmatrix}; \quad \mathbf{T} = \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_N \end{bmatrix} \end{aligned} \quad (8)$$

[0054] \mathbf{H} 称为神经网络的隐含层输出矩阵, 第 i 列表示与输入 \mathbf{x}_i 相关的第 j 个隐含层节点的输出向量, 第 i 行表示与输入 \mathbf{x}_i 相关的隐含层输出向量. 通常情况下, 隐含层节点数 N 通常比训练样本数 M 小的多, $M \ll N$, 这样隐含层输出矩阵 \mathbf{H} 并非方阵, 从而不存在

$a_i, b_i, \beta_i (i=1, \dots, N)$, 使得 $H\beta = T$. 因此, 需要找到 $\hat{a}_i, \hat{b}_i, \hat{\beta}_i (i=1, \dots, N)$ 使得

$$[0055] \|H(\hat{a}_1, \dots, \hat{a}_N, \hat{b}_1, \dots, \hat{b}_N) \hat{\beta} - T\| = \min_{a_i, b_i, \beta_i} \|H(a_1, \dots, a_N, b_1, \dots, b_N) \beta - T\| \quad (9)$$

[0056] 其等价于最小化代价函数:

$$[0057] E = \sum_{i=1}^N \left(\sum_{j=1}^k (a_j \hat{x}_{ij} + b_j) - t_i \right)^2 \quad (10)$$

[0058] E 为最小化代价函数。研究表明, 隐含层权值和阈值可以随机给出并且不需要调整, 这样式(7)可视为一个线性系统, 由式(9)可看出, 训练一个SLFN等价于求线性系统 $H\beta = T$ 的一个最小二乘解 $\hat{\beta}$, 使

$$[0059] \begin{aligned} & \|H(a_1, \dots, a_N, b_1, \dots, b_N) \beta - T\| \\ & = \min_{a_i, b_i} \|H(a_1, \dots, a_N, b_1, \dots, b_N) \beta - T\| \end{aligned} \quad (11)$$

[0060] 由式(11)得输出权值为:

$$[0061] \hat{\beta} = H^T T \quad (12)$$

[0062] ELM算法可以归纳为下面三个步骤:

[0063] 给出一个训练集 $(x_i, t_i) \in \mathbb{R}^n \times \mathbb{R}, i=1, 2, \dots, N$, 激活函数 $G(x)$ 以及隐含层节点数 N , 则

[0064] (a)随机产生隐含层节点参数 $(a_i, b_i), i=1, 2, \dots, N$;

[0065] (b)计算隐含层输出矩阵 H ;

[0066] (c)计算输出权值 $\hat{\beta}, \hat{\beta} = H^T T$.

[0067] (3)基于集成梯度数据ELM-PLS的建模方法

[0068] 集成梯度数据ELM-PLS建模方法与线性PLS方法不同之处在于建立多个有效模型以提高模型精度, 同时采用ELM建立内部非线性模型。集成梯度数据ELM-PLS方法保留了线性外部模型, 如式(4), 通过PLS提取过程的特征信息, 消除了数据的共线性, 并降低了输入变量的维数, 然后采用ELM建立输入得分向量矩阵 T 和输出得分向量 U 之间的非线性内部模型 $U = f(T)$, 提高内部模型的非线性处理能力。这样, 集成梯度数据ELM-PLS同时具有集成模型、PLS模型和ELM模型的优点, 即集成模型的泛化能力强, PLS模型的鲁棒性、特征提取等特性和ELM模型的快速非线性处理能力。

[0069] 集成梯度数据ELM-PLS方法建模与测试步骤如下:

[0070] (1)利用交叉检验法确定潜变量个数, 采用线性PLS方法计算建模样本输入 X 和输出 Y 的得分向量矩阵 T 和 U , 及负载向量矩阵 P 和 Q 。

[0071] (2)设定ELM隐含层节点数和激活函数(如sigmoid函数), 采用ELM建立内部模型 T 和 U 之间的非线性模型, 可求得 $U = f(T)$, 式中 $f(\cdot)$ 为ELM表示的非线性函数。

[0072] (3)利用步骤(1)中确定的潜变量个数, 对测试样本 X_1, Y_1 进行线性PLS外部模型分解, 得到得分向量矩阵 T_1, U_1 和负载向量矩阵 P_1, Q_1 。

[0073] (4)将 T_1 带入步骤(2)建立的ELM模型中, 求得 $\hat{U} = f(T_1)$ 利用 $\hat{Y} = \hat{U}Q_1$ 求得测试样本的预测值。

[0074] (5)步骤(1)~(4)为其中一组模型的建模方法,集成梯度数据ELM-PLS建模方法需利用相同建模数据重复建立10组模型,各模型的区别在于使用不同的ELM输入层到隐层权值。重复步骤(1)~(4)求得每组模型隐含层至输出层间的权值,确定所有模型参数,最后使用10组数据的平均值作为最后输出质量。

[0075] 减径管质量建模实验

[0076] 取某钢厂无缝钢管减径机组2012年10月的70根减径管生产数据,荒管直径152.5mm,壁厚6mm,减径到直径73.03mm,壁厚5.51mm。共12个机架。将数据分成两组:前45根用来建立质量预报模型,后25根用来测试模型,检验其对减径管质量的预估精度。将45根减径管的生产数据展开,得到二维数据阵 $X(45, 30062)$ 。其中,数据采集周期为20ms,咬钢阶段采集时间为2.5s,稳定轧制阶段采集时间为13s,抛钢阶段采集时间为1.2s。针对上述数据作图2所示的处理得到数据阵 $X(45, 147)$,采用集成梯度数据ELM-PLS方法建立质量预报模型,建模流程如图3所示。利用同样方法采集25根减径管生产数据 $X_{new}(25, 147)$,进行质量预报检验。为了与传统间歇过程质量预报模型相比校,对先前建模的45根减径管生产数据,选取影响减径管质量1至12号减径机电机转速、电流和力矩,荒管加热温度和荒管质量精度误差共39个变量作为输入变量。数据采集周期为20ms,采集时间16.7s。在实验建模中对数据阵 $X(45, 30062)$ 用传统MPLS方法建立质量预报模型。同样方法整理25根减径管生产数据形成检验数据阵 $X_n(25, 30062)$ 进行质量预报检验。图4和图5为两种预报模型的检验数据预报结果。

[0077] 由图4和图5可见,在各段的横向和纵向壁厚误差预测结果中,基于集成梯度数据ELM-PLS方法模型的横向和纵向壁厚误差预报精度为97.4%和95.2%,传统MPLS方法模型预测精度为90.8%和90.3%。由此可见集成梯度数据ELM-PLS方法模型较传统MPLS方法模型有更高的预报精度。

[0078] 本发明的优点在于:

[0079] (1)该方法根据减径过程特性,将过程划分成具有不同变量影响的咬钢子时段、稳定轧制子时段和抛钢子时段三个子时段,并利用各子时段变量均值建立集成梯度数据ELM-PLS方法模型,使得模型精度提高了6.5%。

[0080] (2)该方法克服了传统和改进间歇过程质量预报方法模型结构复杂、计算负荷大的缺点,解决了多时段间歇生产中模型对变量小幅波动不敏感问题,易于实现减径管质量的在线建模与预报。

[0081] 仿真和实验验证了基于集成梯度数据ELM-PLS建模方法在减径管质量预报中的可行性和有效性。

附图说明

[0082] 图1是减径管时间与位移关系图。

[0083] 图2是减径管时间与变量关系图。

[0084] 图3是减径管质量预报模型框图。

[0085] 图4是横向壁厚误差预报比较结果图。

[0086] 图5是纵向壁厚误差预报比较结果图。

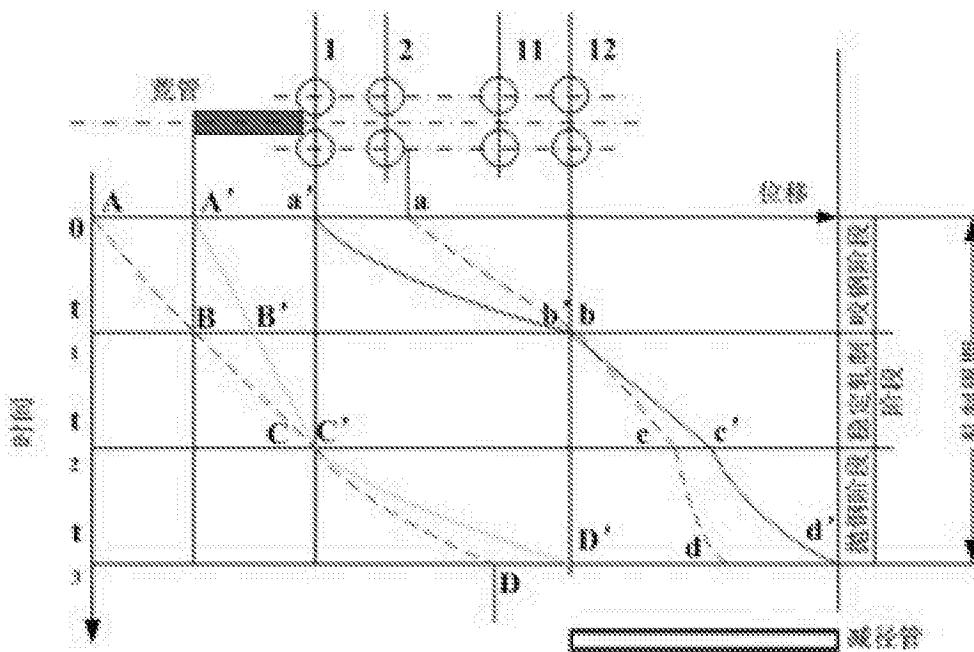


图1

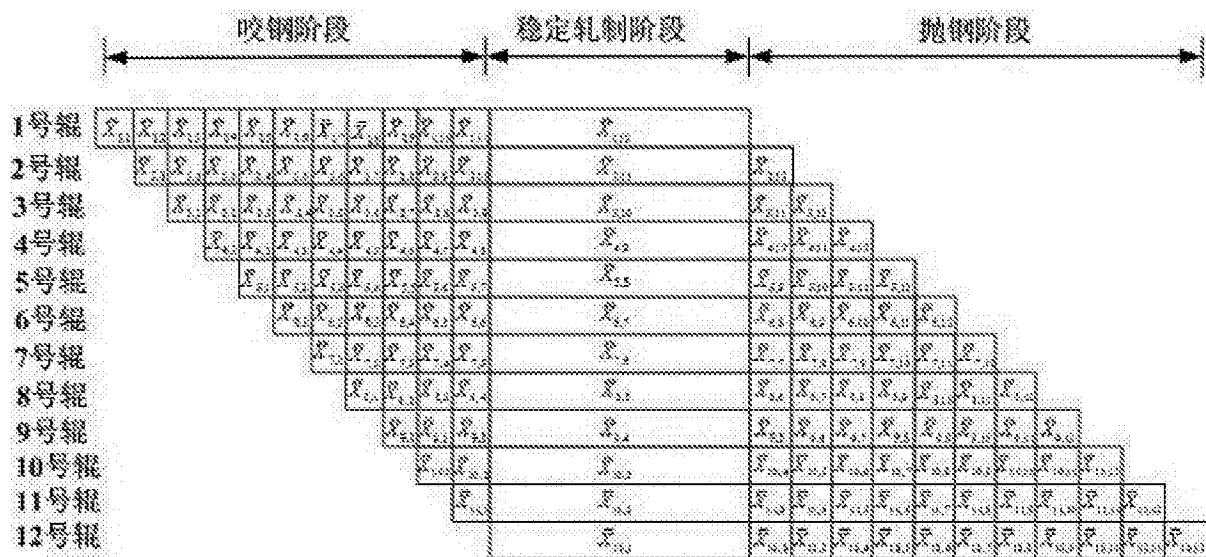


图2

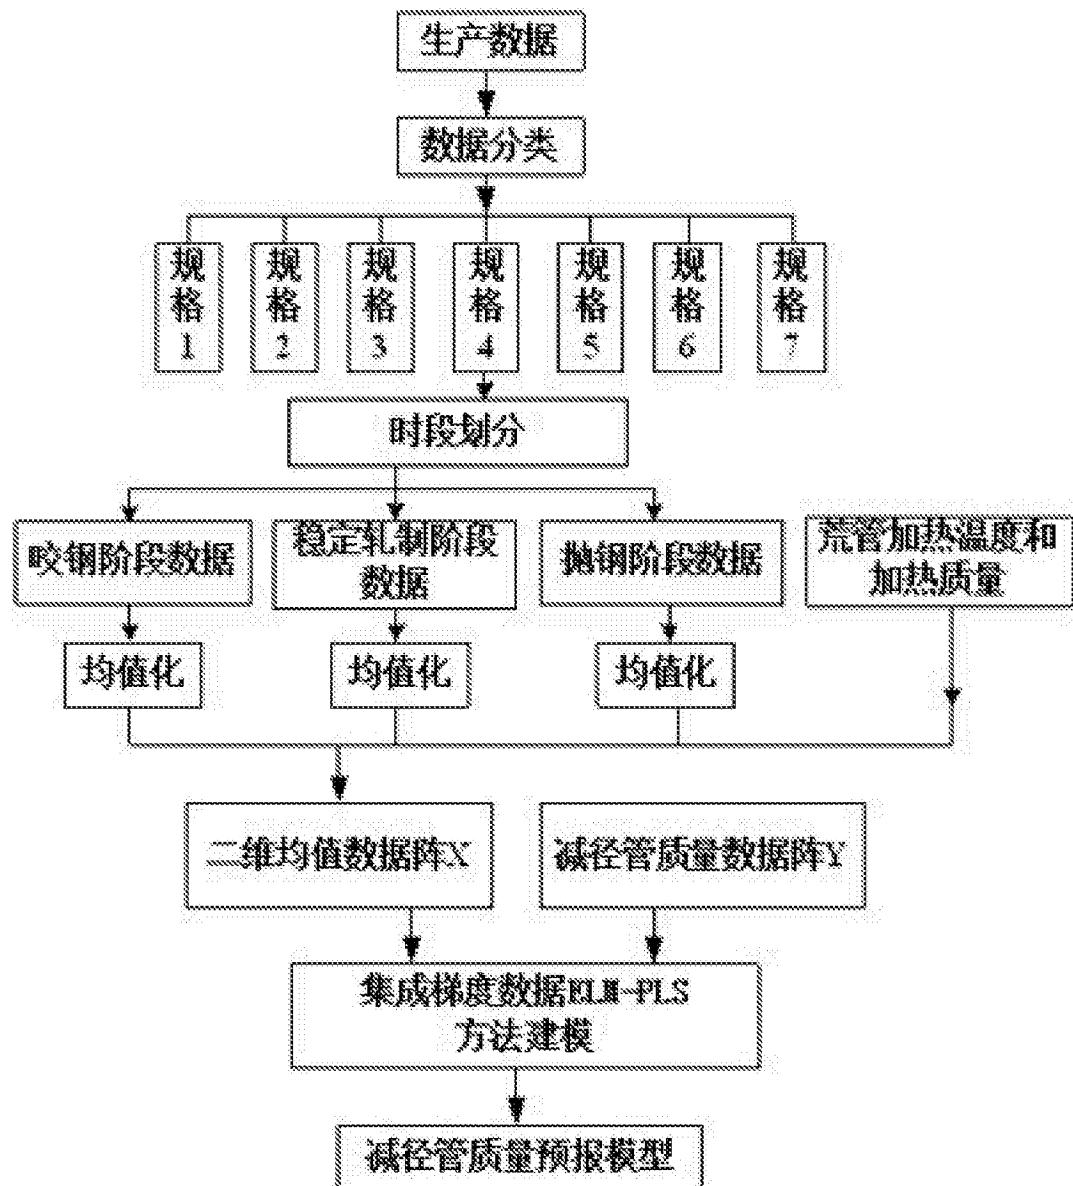


图3

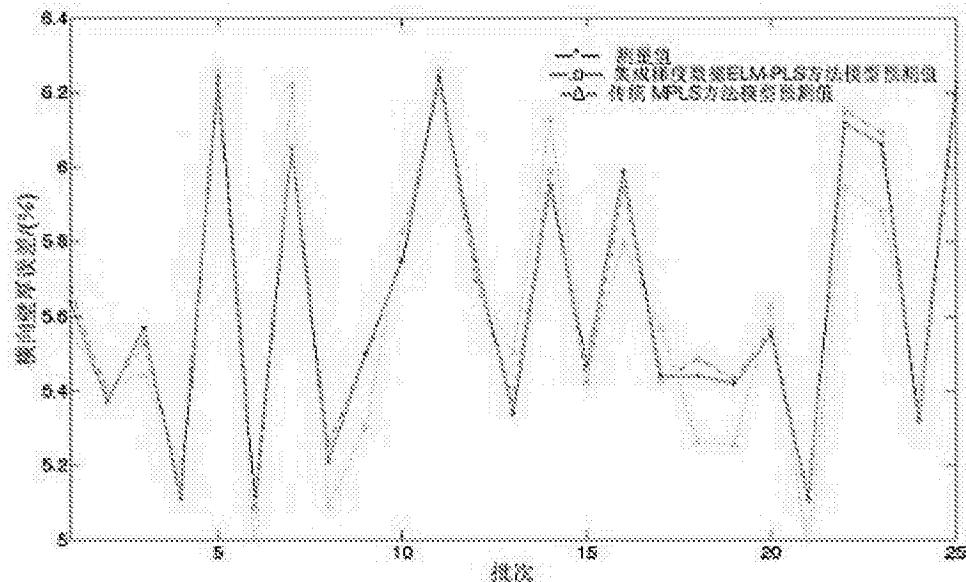


图4

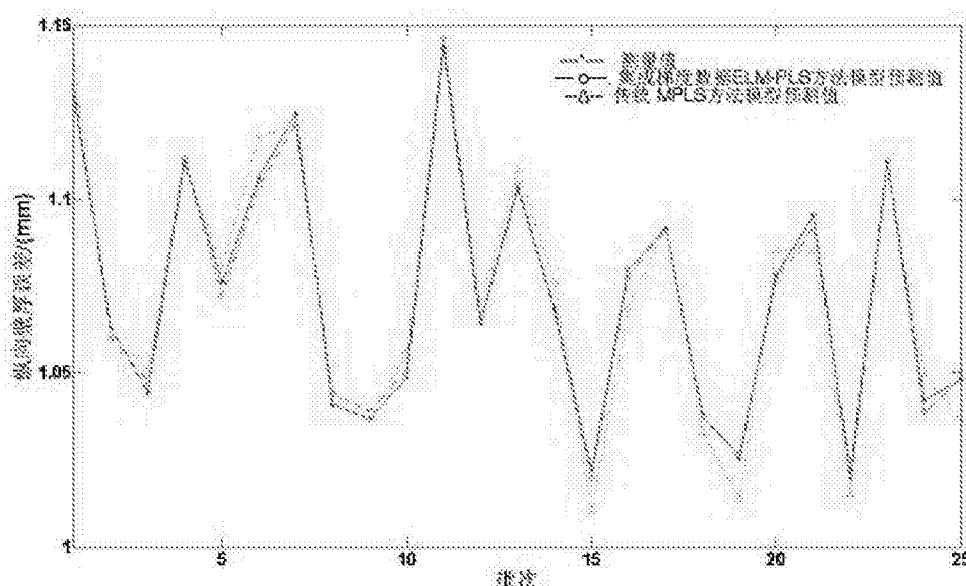


图5