文章编号:1000-8608(2013)01-0127-05

基于极限学习机的氧化镁熔池尺寸软测量研究

李 铁, 王 振, 王宁会*

(大连理工大学 电气工程学院, 辽宁 大连 116024)

摘要:在电弧炉中建立大小合适的氧化镁熔池是制备氧化镁单晶的基础.为了实现对氧化 镁熔池大小的控制,通过对电弧炉传热理论的分析,找出影响氧化镁熔池尺寸的主要因素,采 用极限学习机对氧化镁熔池进行软测量研究,并通过与使用支持向量机的软测量模型进行比 较检测了该模型的学习能力和泛化性能.实验结果表明,应用极限学习机极大地提高了前向 神经网络的学习速度,同时具有较好的预测结果,有助于提高氧化镁熔池的控制精度.

关键词:氧化镁单晶;氧化镁熔池;极限学习机;软测量 中图分类号:TF806.6 文献标志码:A

0 引 言

制备氧化镁单晶时,电熔镁炉内熔池尺寸对杂 质的排除、氧化镁单晶的生长和产率等都有非常重 要的影响.熔池太大,会导致电弧炉外壳温度过高, 容易引发电弧炉熔毁;另一方面会在熔池内引入更 多的杂质,延长精炼的时间,浪费能源.熔池过小, 会影响单晶的产量,造成高纯氧化镁粉的浪费.

氧化镁的熔炼由于具有熔体高温性、炉体密闭性、原料高纯性和试验成本高等特点,给熔池大小的测量带来了困难.近年来,已有学者对熔池的形成进行了研究,并取得了一些成果.王丰华等^[1]、Wang等^[2]、张磊等^[3]采用有限元法对熔池的直径及深度与电流大小之间的关系进行了研究.但是,由于实际生产中工艺和设备都较为复杂,各个参数变化剧烈,实验测量研究十分繁难,成本也高,而且许多重要的内部参数不可能测得,采用有限元的分析方式不能定量地指导实际生产.

软测量技术在工业过程中主要应用于实时估 计、故障冗余、智能校正和多路复用等方面.其根 据容易测量的过程变量(如压力、温度等)与难以 直接测量的待测过程变量(如产品分布、物料成 分)之间的数学关系,采用各种计算方法去用软件 实现对待测变量的测量或估计.

极限学习机是近几年发展起来的一种针对单

隐藏层前向神经网络的新算法^[4]. 与传统的梯度 学习算法(如 BP 算法)和 SVM 相比,极限学习机 的学习速度更快,同时避免了基于梯度下降学习 算法的缺陷,如局部极小、迭代次数过多、性能指 标以及学习率确定难等.

本文在研究氧化镁熔池形成过程中物理化学 反应过程及传热过程的基础上,构建基于极限学 习机的软测量模型,对氧化镁熔炉的尺寸进行估 计,并与采用支持向量机的软测量模型预测的结 果进行比较,以提高氧化镁熔池的实时控制精度.

1 极限学习机算法简述

假设学习样本 (x_i, t_i) 的数量为 N,其中 $x_i =$ $(x_{i1} \quad x_{i2} \quad \cdots \quad x_{in})^{T} \in \mathbf{R}^{n}, t_i = (t_{i1} \quad t_{i2} \quad \cdots \quad x_{im})^{T} \in \mathbf{R}^{m},$ 隐藏层的节点数为 \tilde{N} ,隐藏层的激活 函数为 g(x),则单隐藏层前向神经网络结构模型 可以表示为

$$\sum_{i=1}^{\tilde{N}} \boldsymbol{\beta}_{i} g_{i}(\boldsymbol{x}_{j}) = \sum_{i=1}^{\tilde{N}} \boldsymbol{\beta}_{i} g(\boldsymbol{w}_{i} \cdot \boldsymbol{x}_{j} + b_{i}) = t_{j};$$

$$i = 1, 2, \dots, N$$
(1)

其中 $\mathbf{w}_i = (w_{i1} \quad w_{i2} \quad \cdots \quad w_{in})^{\mathrm{T}}$ 是输入节点与第 *i*个隐藏层节点之间的连接权值向量, $\boldsymbol{\beta}_i = (\beta_{i1} \quad \beta_{i2} \quad \cdots \quad \beta_{in})^{\mathrm{T}}$ 是第*i*个隐藏层节点与输出节点之 间的连接权值向量, b_i 是第*i*个隐藏层节点的阈值.

收稿日期: 2012-04-05; 修回日期: 2012-11-06.

基金项目:"八六三"国家高技术研究发展计划资助项目(2008AA03A325).

作者简介: 李 铁(1974-),男,博士生,E-mail:listeel@yeah.net; 王宁会*(1954-),男,教授,博士生导师,E-mail:ninghuiw@263.net.

(2)

式(1) 可以简记为

$$H\beta = T$$

H称为神经网络的隐藏层输出矩阵,**H**的第i列表示当输入变量为 x_1, x_2, \dots, x_N 时第i个隐藏层节点的输出.

对于上述的单隐藏层前向神经网络,极限学 习机的算法用以下4步实现:

(1)随机选取输入连接权值和阈值 w_i、b_i, i =
 ~
 1...., N.

(2) 计算网络隐藏层输出矩阵 H.

(3) 计算隐藏层输出矩阵 H 的广义逆 H⁺.

(4) 计算输出权值 $\boldsymbol{\beta} = \mathbf{H}^{\dagger}\mathbf{T}$,其中 $\mathbf{T} = (t_1 \quad t_2 \quad \cdots \quad t_N)^{\mathrm{T}}$.

2 电弧炉传热理论及熔池软测量所 需参数计算

氧化镁熔池形成的过程是一个高温物理化学 反应过程,本文以辽宁中大超导公司氧化镁单晶 制备的过程为研究对象,从能量平衡的角度出发 来进行电弧炉传热分析及相关参数计算.

2.1 相变控制方程

氧化镁粉的熔化是一个相变的过程,在相变 分析过程中,其控制方程为^[5-7]

 $\rho c_{p} \frac{\partial T}{\partial t} = \frac{\partial}{\partial x} \left[\lambda \frac{\partial T}{\partial x} \right] + \frac{\partial}{\partial y} \left[\lambda \frac{\partial T}{\partial y} \right] + \frac{\partial}{\partial z} \left[\lambda \frac{\partial T}{\partial z} \right] + \dot{Q}$ (3)

式中: ρ,λ,c_p 分别为氧化镁的密度、导热系数和定 压比热容;Q为热源,包括通过电极注入的电能、 从电弧炉表面以对流或者辐射等方式散失的能 量,以及氧化镁熔化所需的相变热;T为温度;t为 时间;x,y,z分别为坐标系的坐标.

2.2 电极输入能量

制备氧化镁单晶的过程中,形成熔池所需的 能量由电极输入功率 P_t 决定:

$$P_{t} = \sqrt{3} \eta VI \cos \varphi$$
(4)
式中:V、I分别为电弧炉的线电压、线电流; cos φ
是功率因数; η 是考虑导线、电极等电能损耗之后
的电能效率.

2.3 炉壁、电极、熔池表面散热

电弧炉由于辐射和对流产生的热流密度分别 为^[8]

$$\mathbf{Q}_{\rm rad} = \sum_{j} q_{j\rm rad} \mathbf{A}_{j\rm e} = \sigma_{j} \mathbf{A}_{j\rm e} \, \boldsymbol{\varepsilon}_{j} \, (\, \mathbf{T}_{j}^{4} - \mathbf{T}_{\rm aj}^{4}) \quad (5)$$

 $Q_{cov} = \sum_{j} q_{jcov} A_{je} = h_{j} A_{je} (T_{j} - T_{aj}) \quad (6)$ 式中: *j* 分别代表炉壁、电极、熔池表面等和外界 进行热交换的部分, ε_{j} 是表面吸收率, σ_{j} 是 Stefan-Boltzmann常数, *h* 是表面传热系数, A_{je} 是

2.4 氧化镁相变热

对应的散热面积.

氧化镁粉的熔化是一个相变的过程,相变分 析必须考虑材料的相变热,相变热是在相变过程 中吸收或者释放的热量,通过定义材料的焓特性 来计算.

$$H_{1}(T) = H_{T}^{\ominus} - H_{298}^{\ominus} = \int_{298}^{3098} C_{p,m} dT + \Delta H_{m} + \int_{3098}^{T} C_{p,m} dT$$
(7)

$$H_{s}(T) = H_{T}^{\ominus} - H_{298}^{\ominus} = \int_{298}^{T} C_{p,m} dT \quad (8)$$

式中: $C_{p,m}$ 为摩尔定压比热容,T为温度,H_s为氧 化镁固体状态下的摩尔焓, ΔH_m 为熔化焓和转变 焓之和,H_l为氧化镁熔液的摩尔焓.

2.5 电弧炉能量方程

总的电弧炉内氧化镁粉能量的变化如图 1 所示.

由传热理论可知影响氧化镁熔池大小的主要 因素包括:电极输入的电能、炉壁散热、电极散热 和熔池表面的热损失、氧化镁相变热^[9].

$$W = \int (P_{t} - Q_{rad} - Q_{cov}) dt \qquad (9)$$





Fig. 1 The heat loss diagram of the electric arc furnace and electrodes

3 熔池软测量模型构建

3.1 模型构建

如图 2、3 中所示, 深色部分是氧化镁熔池, 氧化镁熔池的体积可以用 R_{max}、R_{min}、h 三个量来 表示.其中 R_{max}表示熔池表面的最大半径, R_{min} 表 示熔池表面的最小半径, h 表示熔池的深度.根据 上文中对电弧炉的传热分析, 取影响熔池大小的 因素: 电弧炉输入能量 W, 炉壁热量损失 Q_{wall}, 熔 池表面热量损失 Q_{suf},电极能量损失 Q_{ele},电极在 熔池中的高度 *l* 作为神经网络的输入,将 R_{max}、 R_{min}、*h* 三个量作为神经网络的输出,软测量模型 可以描述为

 $(R_{max}, R_{min}, h) = f(W, Q_{wall}, Q_{suf}, Q_{ele}, l)$ (10) 其中 R_{max}, R_{min}, h 为软测量模型的输出,即熔池尺 寸的估计值.建立熔池尺寸的软测量模型就是建 立式(10)所示的非线性关系模型,以实现熔池尺 寸的在线预估.





图 3 熔池纵向剖面 Fig. 3 Longitudinal cross-section of melt pool

3.2 参数选择

软测量模型采用单隐藏层前向神经网络结构.在确保样本数据质量和分布均衡的情况下,样本数据的规模决定了神经网络训练结果的精度^[10].样本数据量越大,精度越高.本文实验数据取自辽宁中大超导有限公司2006~2008年间制备氧化镁单晶的生产数据,共200组.其中160组数据作为学习样本,用来建立氧化镁熔池的软测量模型;40组作为测试样本,对模型的预估速度及泛化性能进行测试.数据中电极输入的电能、散失的热能以及电弧炉电极的熔池中的高度等数据由现场的各传感器采集后,经 NI 数据采集卡输入到监控平台 LabView 中进行计算得到. 熔池的尺寸在氧化镁单晶制备结束后通过测量得到.

为了对比,在仿真实验中,本文分别基于极限 学习机以及支持向量机进行氧化镁熔池的软测量 建模.对于支持向量机,通过反复试验,以均方差 以及相关系数为标准,最终选取高斯核函数、惩 罚系数 $C=151, \gamma=0.003$,误差控制参数 $\epsilon=0.2$ 作为支持向量机的训练参数,建立软测量模型.

对于极限学习机, Huang 等在文献[4]中提 到,其初始节点参数可以随机选取,影响极限学习 机预测精度的主要因素是隐藏层节点数及激励函 数.为了得到合适的参数,分别选取不同的激励函 数(Sine 函数、Sigmoidal 函数、Radial basis 函 数),并逐渐增加隐藏层节点数,来分析激励函数以 及隐藏层节点数对熔池大小预测精度的影响.参数 选择分析结果参见图 4. 从中可以看到, 当 3 种激励 函数的隐藏层节点数超过 120 时,其对应的预测正 确率开始趋于平稳;当隐藏层节点数在 200 左右 时,分类的正确率达到最高且不再上升.因此,极限 学习机的预测正确率会随隐藏层节点数的增加而 单调增加,正确率达到一定程度时便趋于平稳.综 合计算时间,在本文中,网络的隐藏层节点数取 160,输入权值和阈值随机选取,激励函数采用 Sigmoidal 函数,使用 MATLAB 软件建立模型.



图 4 隐藏层节点数对极限学习机性能影响

Fig. 4 The effect of the number of hidden node on the ELM performance

3.3 实验及结果

将测试样本输入模型,使用极限学习机所得到 的预测值与实际测量值进行对比,结果如图 5 所 示.使用支持向量机所得到的测试样本输入模型所 得的预测值与实际测量值对比结果如图 6 所示.

将建模时间、运算时间、平均训练误差、平均泛 化误差作为性能评价标准,极限学习机和支持向量 机对氧化镁熔池尺寸的最终测试结果对比参见表 1.表1中,误差为样本平均绝对误差,按式(11)计 算;运算时间是指将测试样本中的数据输入已建立 的模型,预测一次氧化镁熔池尺寸所需的时间.

$$e = \frac{1}{N} \sum_{i=1}^{N} |y_i - \hat{y}_i|$$
(11)





Fig. 5 The predicting sizes of the melt pool by ELM



Fig. 6 The predicting sizes of the melt pool by SVM

表 1	极限学	习机与	支持向	量机结果对比
	1/21/2 4	v 1/4 v	×~ 11 C1	I / 0 / 1 / 1 / 1 / 0

Tab. 1 The comparison of performance of SVM and ELM

建模方法	建模时间/s	运算时间/s -	平均训练误差			平均泛化误差		
			$R_{\rm max}$	R_{\min}	h	$R_{ m max}$	R_{\min}	h
ELM	25.245	0.089 5	0.019 0	0.006 0	0.014 6	0.020 5	0.006 6	0.015 9
SVM	1 002.979	0.402 3	0.007 4	0.003 9	0.012 5	0.008 3	0.004 4	0.013 2

式中:N为样本个数(学习样本或测试样本),y_i、ŷ_i 分别表示氧化镁熔池的实际测量值及模型预测值.

从表1可以看出,在学习速度上,由于极限学 习机不需要调整网络的输入权值以及隐藏层节点 的阈值,其建模仅耗时25.245 s;而支持向量机由 于选用径向基函数作为核函数,在建模的过程中 需要调整参数,从而浪费了时间,训练过程共耗时 1002.979 s.极限学习机的学习速度是支持向量 机的约40倍,在模型训练所花费的时间上体现出 了明显的优势.在对测试样本进行测试时,极限学 习机的计算速度是支持向量机的4.5倍.由此可 知,在对未知样本进行建模时,极限学习机的学习 速度明显超过支持向量机.

从表1还可以看出,极限学习机在学习性能 上,与支持向量机相比,训练误差及泛化误差略有 上升,两种算法的训练误差相差 0.005 6,泛化误 差仅相差 0.011.但这种程度的差别相对于实际 的氧化镁熔池的尺寸来说可以忽略不计.从图 5 及 6 也可以看到,极限学习机对氧化镁熔池尺寸 的预测能够满足实际生产的控制要求.极限学习 机在几乎不降低模型泛化误差的同时,这么大幅 度地提高模型的计算速度是很有意义的.

4 结 论

为了实现对氧化镁熔池大小的控制,本文针 对制备氧化镁单晶过程中氧化镁熔池尺寸的测量 问题,提出了基于极限学习机的氧化镁熔池尺寸 的软测量方法.结果表明,应用极限学习机在几乎 不降低模型的训练精度和泛化能力的同时,缩短 了建模时间和运算时间,满足了现场高速高精度 的测量要求.文中提及的氧化镁熔池尺寸建模和 测量方法在辽宁中大超导有限公司进行了试运 行,效果良好,能够满足现场控制的要求.同时该 方法也具有一定的通用性,适用于其他过程的软 测量建模和预测.

参考文献:

 [1] 王丰华,金之俭,朱子述.直流电弧炉精炼期内熔池 流场和温度场的数值模拟[J].工业加热,2005, 34(5):4-9.

> WANG Feng-hua, JIN Zhi-jian, ZHU Zi-shu. Numerical simulation of flow fields and temperature fields of molten bath in the refining stage of DC electric arc furnace [J]. **Industrial Heating**, 2005, **34**(5):4-9. (in Chinese)

- [2] WANG Z, WANG N H, LI T. Computational analysis of a twin-electrode DC submerged arc furnace for MgO crystal production [J]. Materials Processing Technology, 2011, 211(3):388-395.
- [3] 张 磊,尧军平,陈炳坤. 电渣熔铸过程电流大小对金属熔池影响的数值模拟研究[J]. 铸造技术, 2007, 28(1):19-22.
 ZHANG Lei, YAO Jun-ping, CHEN Bing-kun. Numerical simulation on the effect electric current on metal molten pool during the ESR [J]. Foundry Technology, 2007, 28(1):19-22. (in Chinese)
- [4] HUANG Guang-bin, ZHU Qin-yu, Siew Cheekheong. Extreme learning machine: Theory and applications [J]. Neurocomputing, 2006, 70(5): 489-501.
- [5] Camdali U, Tunc M. Modeling of electric energy consumption in the AC electric arc furnace [J].International Journal of Energy Research, 2002,

26(3):935-947.

- [6] Logar V, Dovzan D, Skrjanc I. Mathematical modeling and experimental validation of an electric arc furnace
 [J]. ISIJ International, 2011, 51(3):382-391.
- [7] 佟玉鹏,张 雄,张化光.交流三相电熔镁炉的最佳运行分析[J].控制工程,2007,14(2):202-211.
 TONG Yu-peng, ZHANG Xiong, ZHANG Huaguang. Analysis of optimal operation about purifying magnesium oxide with three-phase AC electric smelting furnace [J]. Control Engineering of China, 2007, 14(2):202-211. (in Chinese)
- [8] 吴永建,张 晶,张 莉,等. 电熔镁炉电极调节系 统的混合建模[J]. 仪器仪表学报, 2009, **30**(6): 13-19.

WU Yong-jian, ZHANG Jing, ZHANG Li, *et al.* Hybrid modeling for electrode regulating system of electrical smelting furnace for magnesia [J]. **Chinese Journal of Scientific Instrument**, 2009, **30**(6):13-19. (in Chinese)

- [9] TIAN Hui-xin, MAO Zhi-zhong. An ensemble ELM based on modified AdaBoost. RT algorithm for predicting the temperature of molten steel in ladle furnace [J]. IEEE Transactions on Automation Science and Engineering, 2000, 7(1):73-80.
- [10] 肖 冬,王继春,潘孝礼,等. 基于改进 PCA-ELM 方法的穿孔机导盘转速测量[J]. 控制理论与应用, 2010, **27**(1):19-24.

XIAO Dong, WANG Ji-chun, PAN Xiao-li, *et al.* Modeling and control of guide-disk speed of rotary piercer [J]. **Control Theory & Applications**, 2010, **27**(1):19-24. (in Chinese)

Research on soft sensing of size of MgO melt pool applied with extreme learning machine

LI Tie, WANG Zhen, WANG Ning-hui*

(School of Electrical Engineering, Dalian University of Technology, Dalian 116024, China)

Abstract: The size of the MgO melt pool in the electric arc furnace is important to grow high-purity MgO single crystals. In order to control the size of the MgO melt pool precisely, a soft-sensor based on extreme learning machine (ELM) is proposed according to the analysis of the heat transfer theory of the electric arc furnace. The learning capability and generalization performance of the model are examined by comparison to the model based on the support vector machine (SVM). The comparative results show that ELM has similar control accuracy compared with SVM, but it has obvious advantages in learning speed for feedforward neural network.

Key words: MgO single crystal; MgO melt pool; extreme learning machine; soft sensing