

刘悦,崔丹丹. 基于结构自组织 ELM 的铝热连轧轧制力预测[J]. 湖南科技大学学报(自然科学版), 2020, 35(1): 77-82. doi:10.13582/j.cnki.1672-9102.2020.01.011

Liu Y, Cui D D. Aluminum Hot Rolling Force Prediction Based on Structural Self Organizing ELM [J]. Journal of Hunan University of Science and Technology(Natural Science Edition), 2020, 35(1): 77-82. doi:10.13582/j.cnki.1672-9102.2020.01.011

基于结构自组织 ELM 的铝热连轧轧制力预测

刘悦, 崔丹丹*

(开封大学 信息工程学院, 河南 开封 475000)

摘要: 轧制力在铝热连轧中起着重要作用, 针对热轧过程中的非线性、参数强耦合性等因素使得其难以建模的问题. 本文提出一种具有拓扑结构自组织的极限学习机(Topology Self-Organizing Extreme learning machine, TSO-ELM)算法, 解决了 ELM 的结构设计问题, 实现了结构和参数的自组织. 根据现场数据, 使用 TSO-ELM 算法进行铝热连轧轧制力预测, 结果表明该算法与人工蜂群算法优化反向传播神经网络(Artificial bee colony algorithm optimized Back-propagation neural network, ABC-BP)和增强型增量极限学习机(Enhanced random search based incremental extreme learning machine, EI-ELM)算法对比, 其训练速度和精度都得到了一定的提高.

关键词: 轧制力预测; 极限学习机; 结构自组织; 自适应算法

中图分类号: TP273 文献标志码: A 文章编号: 1672-9102(2020)01-0077-06

Aluminum Hot Rolling Force Prediction Based on Structural Self Organizing ELM

Liu Yue, Cui Dandan

(College of Information Engineering, Kaifeng University, Kaifeng 475000, China)

Abstract: In the hot rolling of aluminum, Rolling force plays an important role. In order to improve the model due to factors such as nonlinearity and strong coupling of parameters during hot rolling. This paper proposes a topology self-organizing extreme learning machine algorithm, which solves the structural design problem of extreme learning machine and realizes the self-organization of structure and parameters. According to the field data, the TSO-ELM algorithm is used to predict the rolling force of aluminum hot rolling. The results show that the algorithm compared with artificial bee colony algorithm optimized back-propagation neural network and enhanced random search based incremental extreme learning machine, the training speed and accuracy have been improved greatly.

Keywords: Rolling force prediction; Extreme learning machine; Structure self organization

轧制力是铝热连轧过程控制的关键参数, 它计算的精度直接影响带材的厚度精度、形状质量、轧制稳定性. 然而, 热轧过程具有非线性特性, 而且存在热、机械、材料等现象之间的紧密结合, 使得对该过程难以建模和解决^[1]. 所以, 采用传统的数学模型预测轧制力并不理想, 从而影响产品质量.

收稿日期: 2018-06-28

基金项目: 国家自然科学基金资助项目(61702185); 河南省高等学校青年骨干教师培养计划项目资助(2017GGJS270); 河南省高等学校重点科研项目计划(19B520014)

*通信作者, E-mail: 852278078@qq.com

Sims 提出压力分布,滚动力和滚动力矩的解析表达式^[2].Ford 使用极限分析技术对 Orowan 模型进行了改进,并将结果与 Sims 的进行比较^[3].近年来,神经网络一直备受关注,因为它适用于高度非线性和复杂数据的问题^[4-5].Lee 提出了一种使用神经网络长期学习法,提高轧机轧制力预测精度^[6].Bagheripour 提出了一种人工神经网络模型,解决了在热连轧过程中对轧制力和轧制力矩准确预测^[7].赵志伟等人提出一种使用 ABC-BP 的初始权值、阈值和网络结构的轧制力预报方法^[8].

由于上述提到的智能算法的训练时间较长,在一定程度上影响了整体的训练性能.ELM 理论的提出解决了传统神经网络由于迭代训练所产生的局部最优和训练时间长等问题,Huang G-B 提出 EI-ELM^[9],使极限学习机的隐含层数从 1 逐个增加,直到达到最大节点数或目标误差.Jun Y 等人提出一种增强型在线序列极限学习机^[10],通过卡尔曼滤波原理对网络参数调整,但调整过程中会导致一些合适的节点的消除,从而使网络增长不顺畅.B Jing 等人提出一种使用基于误差分布的 ELM 分割模型利用历史功率输出数据预测超短期光伏发电功率的方法与自回归-移动平均(ARMA)时间序列模型和 BPAQ3 神经网络相比,ELM 在各个时段都具有较好的预测精度^[11].

现有的 ELM 网络结构优化大部分受 RBF 神经网络与支持向量机等神经网络结构优化算法启发,采用传统的增长型结构优化方法会导致网络冗余,使网络中残余对预测结果“无用”或者“反作用”的节点,采用枝剪型结构优化方法会使一些作用较大的节点无法充分发挥其作用^[12].本文提出一种拓扑结构自组织的极限学习机算法,并利用模型自适应算法提高模型精度,实现在线轧制力预测.

1 极限学习机

ELM 理论是新加坡南阳理工大学黄广斌教授于 2004 年提出,它不需要通过学习调整权值和阈值等参数,故训练速度快;二是随机输入权重和阈值,应利用最小二乘法原理计算出网络的输出权重,这样就解决了神经网络由于迭代而产生的问题,该算法比起传统神经网络,训练时间快且精确^[13].

ELM 网络结构如图 1 所示,若存在输入/输出样本 (X_j, t_j) ,有 n 个输入, $X_j = [x_{j1}, x_{j2}, \dots, x_{jn}]^T \in \mathbf{R}^n$, m 个输出, $t_j = [t_{j1}, t_{j2}, \dots, t_{jm}]^T \in \mathbf{R}^m$. L 个隐层节点的 ELM 网络表达式:

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i \cdot \mathbf{X}_j + \mathbf{b}_i) = o_j, \quad j = 1, 2, \dots, N. \quad (1)$$

式中: $g(x)$ 为 ELM 网络激活函数; i 为隐层节点数; j 为样本数; $\mathbf{W}_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 为输入权重; β_i 为输出权重.ELM 网络是利用最小二乘法使单层网络的输出得到的误差最小,可以表示为

$$\sum_{j=1}^N \|o_j - t_j\| = 0. \quad (2)$$

由 $\mathbf{W}_i, \mathbf{b}_i$ 和 β_i 可得

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i \cdot \mathbf{X}_j + \mathbf{b}_i) = t_j, \quad j = 1, 2, \dots, N \text{ 或 } \mathbf{H}\boldsymbol{\beta} = \mathbf{T}. \quad (3)$$

式中: \mathbf{H} 为隐含层的输出矩阵; $\boldsymbol{\beta}$ 为输出层权重; \mathbf{T} 为数据实测值.根据式(2)建立的误差损失函数表达式:

$$E = \|\mathbf{H}(\mathbf{W}_i, \mathbf{b}_i)\boldsymbol{\beta} - \mathbf{T}\| = \sum_{j=1}^N \left(\sum_{i=1}^L \beta_i g(\mathbf{W}_i \cdot \mathbf{X}_j + \mathbf{b}_i) - t_j \right)^2. \quad (4)$$

ELM 算法,输入权重 \mathbf{W}_i 和隐层阈值 \mathbf{b}_i 是随机的,输出权重 $\boldsymbol{\beta}$ 是由期望值与隐含层输出的关系确定的,其表达式为

$$\boldsymbol{\beta} = \mathbf{H}^{-1}\mathbf{T}. \quad (5)$$

从式(5)可以看出,具有唯一解^[14].

2 TSO-ELM 的轧制力预测

在极限学习机的生产数据预测过程中,初始的参数需要手动设置且并不能满足现实条件对预测结果的要求,由于极限学习机的初始参数为随机给出,其结构大小对预测效果影响较大^[15].并且,不同算法的




图 1 ELM 网络结构

优化策略会使最终得到的结构千差万别.

2.1 TSO-ELM 结构设计

利用隐层输出对预测值的贡献程度,分析隐含层神经元的输出加权值对神经网络输出的影响,以此判断合并和分裂 ELM 网络隐含层中的神经元,示意图如图 2 所示.




图 2 节点合并分裂

学习阶段,根据隐层输出对预测值的贡献值大小来决定该隐层分裂或合并,同时调整网络结构参数,突出网络的时效性,保证了其稳定性和精度.

其中, \tilde{N} 个隐层节点的贡献度值(Contribution Value, CV)的定义 V 如式(6).

$$V_i = \frac{\beta_i \theta_i}{\sum_{i=1}^{\tilde{N}} \beta_i \theta_i}, i = 1, 2, \dots, \tilde{N} \tag{6}$$

式中: θ_i 为第 i 个隐含层节点的输出; β_i 为第 i 个隐含层节点的输出权重; V_i 为第 i 个隐含层节点的贡献度值.

定义 $V_{\max} = 2V_{av}$, 其中, V_{av} 为贡献度平均值.若当前隐层有 $V_i > V_{\max}$, 则对该隐层分裂 1 次, 设输入权重 W_i , 阈值 b_i , 输出权重 β_i , 其设置为

$$\begin{aligned} W_{N+1} &= \lambda W_i; \\ W_i &= (1 - \lambda) W_i. \end{aligned} \tag{7}$$

式中: $\lambda = [0.3, 0.5]$, 当 $V_i < V_{\min}$ 时, $V_{\min} = \min\{0.05, 1/\tilde{N}\}$, 令该节点与欧氏距离最短的隐层节点 t 合并, 即删除此参数, 并按式(8)进行设置.

$$\beta_i = \beta_i + \frac{\beta_i \theta_i}{\theta_i}. \tag{8}$$

式中: β_i 为第 t 个隐层节点的输出权重; θ_i 为第 t 个隐层节点的输出.

本文采用的 TSO-ELM 针对现场数据优化网络结构,通过计算每个隐含层对预测输出的贡献值,判断是否分裂合并该隐含层节点,以删除冗余节点和增强有效节点.最后并配合指数平滑法进行模型自适应,能够改善因为实测数据偏差而导致的轧制力模型预测误差,TSO-ELM 算法流程如图 3 所示.

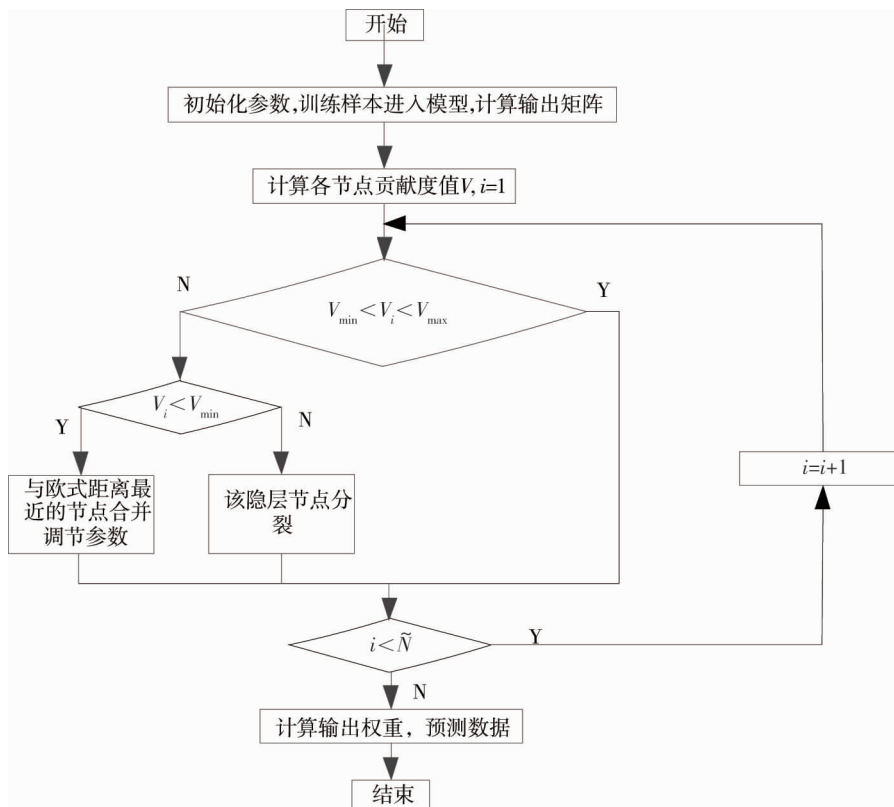


图 3 TSO-ELM 算法

ELM 自组织算法的具体步骤:

步骤 1:初始化算法,ELM 进入初始训练阶段.

步骤 2:训练样本进入模型,根据初始参数使用原始 ELM 算法求出网络输出权重.

步骤 3:计算隐层节点对网络输出的贡献度值 V_i , 如果大于设定上边界值 V_{\max} , 则该隐层分裂,对第 i 个以及新产生的节点按式(6)进行调整.

步骤 4:若 $V_i < V_{\max}$, 则将第 i 个节点删除,并找到其欧氏距离最短的隐层合并,对新的节点按式(7)调整.

步骤 5:调整结束后重新计算输出权重,进入预测阶段,得出预测结果.

2.2 模型自适应算法

在轧制力预报过程中,预测的结果与变形抗力的精度有直接关联,采用数学公式计算会有一些的偏差而导致预测结果有误差^[16].本文采用自适应算法去改善上述问题,该算法是利用 ELM 的预测值与实际值之间的差,对采集的数据进行自适应调整.

本文采用的是乘法自适应,即 $y = \eta \text{ELM}(u_m, T_f, H, h_0, h_1)$, 对 ELM 预测出的值再经过自适应算法与自适应项相乘.这样,通过选出误差最小时的自适应平滑系数,就可以取得比较好的效果.

3 仿真实验

3.1 轧制力模型参数设置

轧制力模型: H 为材料厚度, h_0 为入口厚度, h_1 为出口厚度, τ_f 为入口张力, τ_b 为出口张力, V_0 为轧辊线速度, B 为轧件宽度, T 为入口温度.由上述参数构成 TSO-ELM 网络模型的输入,以轧制力 P 作为输出.为了更了解该 TSO-ELM 轧制力模型,其所需参数: X 为输入样本, t 为输出样本, O 为网络输出, W 为输入权重, β 为输出权重, V 为隐含层贡献度, V_{\min} 为贡献度下限, V_{\max} 为贡献度上限, V_{av} 为所有隐含层平均值, θ 为隐含层输出.

本文以某铝合金厂“1+4”铝热连轧现场的第二机架采集 2 500 组数据为例,以 1 000 组作为训练样本,500 组作为测试样本,表 1 为铝合金轧制过程选出的 10 组数据.

表 1 部分轧制力数据

轧件宽度/mm	前张力/kN	后张力/kN	入口温度/°C	入口厚度/mm	出口厚度/mm	来料厚度/mm	轧辊速度/(m/s)	轧制力/kN
1 658.820	99.057 04	92.854 47	413	19.400 30	11.352 42	33	0.453 030 4	1 086.793
16 859.646	118.576 20	114.858 20	413	19.407 14	11.335 87	33	0.509 424 7	1 071.784
1 658.228	122.234 10	103.277 30	413	19.407 71	11.334 11	33	0.528 509 0	1 091.75
1 656.187	101.497 70	103.664 10	413	19.394 21	11.344 63	33	0.581 529 7	1 093.959
1 657.220	106.449 60	110.935 70	413	19.394 41	11.335 51	33	0.583 250 7	1 098.44
1 364.205	110.886 40	115.940 00	430	20.261 26	11.573 97	34	0.504 199 1	1 052.94
1 363.505	109.997 60	113.840 60	430	20.268 22	11.582 84	34	0.508 648 4	1 054.492
1 363.480	101.466 10	102.273 70	430	20.269 16	11.587 93	34	0.522 707 8	1 072.417
1 655.709	100.695 70	97.294 26	445	19.389 47	11.325 35	32	0.545 898 9	1 052.845
1 654.916	105.217 30	93.223 85	445	19.387 31	11.321 73	32	0.543 311 4	1 067.385

3.2 仿真结果分析

为了便于观察,取前 300 条数据进行拟合,如图 4 所示,可以看出,具有参数和结构自组织的 TSO-ELM 算法,可以根据数据特点调整其网络结构,并用于铝热连轧轧制力预测,将预测值与实际值进行对比,可见该算法的预测效果良好.使用 TSO-ELM 算法与传统 ELM 对热轧轧制力预测结果进行比较,通过结构自组织策略对网络结构进行优化,可以通过增加隐层节点提高 TSO-ELM 算法预测精度,而同时合并了其无用节点使结构更加紧凑,由图 5 所示,相对传统 ELM 预测精度有很大提高.




图 4 TSO-ELM 轧制力预测拟合值




图 5 TSO-ELM 与 ELM 轧制力预测对比

利用 ABC 算法优化反馈神经网络结构,以预测误差作为适应度,将优化好的网络使用原始 BP 神经网络算法学习内部参数.使用双隐层的 ABC-BP 与 TOS-ELM 进行轧制力预测对比,后者预测结果绝大多数数据在 5% 误差范围以内,明显优于前者.EI-ELM 算法为结构增长型的 ELM 算法网络,初始仅含一个隐节点,每次随之增加 k 个备用节点,通过选取 k 个节点中预测误差最小的节点作为增加的隐层节点,一直达到最大隐节点个数或者期望误差.如图 6 表示的是 EI-ELM 算法与 TSO-ELM 对比图,由于其 EI-ELM 算法只能增加隐层节点数,会导致结构的冗余,从而使一些数据的预测变差,从图 7 中可以看出,EI-ELM 结构中 80% 的数据在 $\pm 5\%$ 误差线内,虽然效果优于 ABC-BP 结构预测结果,但是稍差于 TSO-ELM 算法.

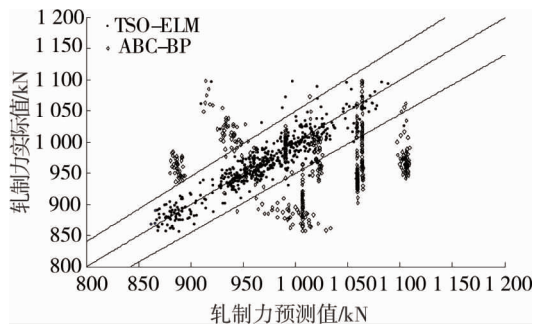


图 6 TSO-ELM 与 ABC-BP 轧制力预测对比

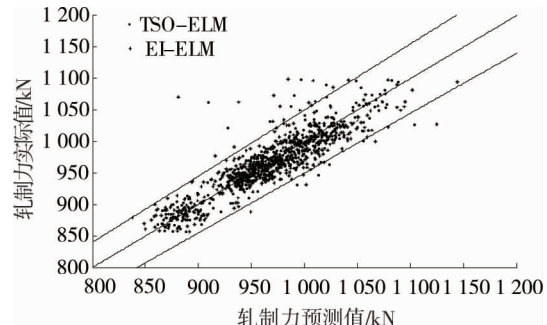


图 7 TSO-ELM 与 EI-ELM 轧制力预测对比

由上述误差散点的对比可以看出,TSO-ELM 的轧制力预测效果优于其他 3 种算法.为了更加客观地比较各个算法的结构紧凑性、训练速度和预测精度,选出隐含层、训练时间、均方误差、最大相对误差、平均绝对百分误差这 5 种评价指标进行对比,实验表明,TSO-ELM 算法的隐含层分裂、合并结构调整策略并配合基于 ELM 原始算法,能在保证预测精度的前提下,训练速度更快,得出更加紧凑的网络结构即较少的隐含层节点数,如表 2 所示.

表 2 算法对比

算法	隐含层	训练时间/s	均方误差/kN	相对最大误差	平均绝对百分误差
TSO-ELM	23	0.265	463.388	0.144	1.449
ELM	23	0.141	800.595	0.189	2.045
EI-ELM	30	0.394	543.578	0.175	1.646
ABC-BP	(18,1)	0.656	8 560.000	4.865	8.464

4 结论

1) 目前主流的结构优化方法旨在实现一个比较紧凑且误差比较小的网络,但是许多控制系统的多变性使网络的优化很难满足.在铝热连轧过程中,为能够得到更好的轧制力预测结果,本文提出 TSO-ELM 算法,通过计算每个隐层节点对网络输出的贡献度来判断对应节点合并和分裂,避免增长和枝剪型结构优化算法导致个别节点稀疏或冗余的问题.

2) 使用 TSO-ELM 算法铝热连轧制力预报并与 ELM,ABC-BP 和 EI-ELM 算法进行对比,该算法

在轧制过程中具有较快的训练速度、并提高了轧制力预测精度。

参考文献:

- [1] Bland D R, Ford H. The Calculation of Roll Force and Torque in Cold Strip Rolling with Tensions[J]. Proceedings of the Institution of Mechanical Engineers, 1948, 159(1): 144-163.
- [2] Sims R B. The Calculation of Roll Force and Torque in Hot Rolling Mills[J]. ARCHIVE Proceedings of the Institution of Mechanical Engineers, 1954, 168(1): 191-200.
- [3] Alexander J M, Ford H. Simplified hot-rolling calculations[J]. Journal of the Institute of Metals, 1963, 93(4): 397-404.
- [4] 韩红桂, 乔俊飞, 薄迎春. 基于信息强度的 RBF 神经网络结构设计研究[J]. 自动化学报, 2012, (7): 1083-1090.
- [5] 付天亮, 王昭东, 王国栋, 等. 修正遗传神经网络预测中厚板轧机轧制力[J]. 东北大学学报(自然科学版), 2008 (10): 1438-1442.
- [6] Lee D M, Choi S G. Application of on-line adaptable Neural Network for the rolling force set-up of a plate mill[J]. Engineering Applications of Artificial Intelligence, 2004, 17(5): 557-565.
- [7] Bagheripoor M, Bisadi H. Application of artificial neural networks for the prediction of roll force and roll torque in hot strip rolling process[J]. Applied Mathematical Modelling, 2013, 37(7): 4593-4607.
- [8] Zhao Z, Yang J, Che H, et al. Application of artificial bee colony algorithm to select architecture of a optimal neural network for the prediction of rolling force in hot strip rolling process[J]. Journal of Chemical and Pharmaceutical Research, 2013, 5 (9): 563-570.
- [9] Huang G B, Chen L. Enhanced random search based incremental extreme learning machine[J]. Neurocomputing, 2008, 71 (16/18): 3460-3468.
- [10] Jun Y, Er M J. An Enhanced Online Sequential Extreme Learning Machine Algorithm[C]//2008 Chinese Control And Decision Conference. IEEE, 2008: 2902-2907.
- [11] Jing B, Qian Z, Pei Y, et al. Ultra short-term PV power forecasting based on ELM segmentation model[J]. The Journal of Engineering, 2017, 2017(13): 2564-2568.
- [12] Lan Y, Soh Y C, Huang G B. Ensemble of online sequential extreme learning machine[J]. Neurocomputing, 2017, 72(13): 3391-3395.
- [13] Geng Z, Qin L, Han Y, et al. Energy saving and prediction modeling of petrochemical industries: A novel ELM based on FAHP[J]. Energy, 2017, 122: 350-362.
- [14] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1/3): 489-501.
- [15] Zhang S, Liu Z, Xiao W. A Hierarchical Extreme Learning Machine Algorithm for Advertisement Click-Through Rate Prediction[J]. IEEE Access, 2018, 6: 50641-50647.
- [16] 陈树宗, 彭文, 姬亚锋, 等. 基于目标函数的冷连轧轧制力模型参数自适应[J]. 东北大学学报(自然科学版), 2013, (8): 1128-1131.