

自然循环流动不稳定性的多目标优化 极限学习机预测方法*

陈涵瀛 高璞珍[†] 谭思超 付学宽

(哈尔滨工程大学, 核安全与仿真技术国防重点学科实验室, 哈尔滨 150001)

(2014年4月28日收到; 2014年6月9日收到修改稿)

极限学习机是近年来提出的一种前向单隐层神经网络训练算法, 具有训练速度快、不会陷入局部最优等优点, 但其性能会受到随机选取的输入权值和阈值的影响. 针对这一问题, 提出一种基于多目标优化的改进极限学习机, 将训练误差和输出层权值的均方最小化同时作为优化目标, 采用带精英策略的快速非支配排序遗传算法对极限学习机的输入层到隐层的权值和阈值进行优化. 将该算法应用于摇摆工况下自然循环系统不规则复合型流量脉动的多步滚动预测, 分析了训练误差和输出层权值对不同步长预测效果的影响. 仿真结果表明, 优化极限学习机预测误差可以用较小的网络规模获得很好的泛化能力. 为流动不稳定性的实时预测提供了一种准确度较高的途径, 其预测结果可以作为核动力系统操作员的参考.

关键词: 流动不稳定性, 极限学习机, 多目标优化, 非支配排序遗传算法

PACS: 05.45.Pq, 05.45.Tp, 47.52.+j

DOI: 10.7498/aps.63.200505

1 引言

极限学习机是Huang等^[1,2]近年提出的一种单隐层神经网络学习算法. 极限学习机随机选取输入权值和隐层阈值, 然后通过求解隐层输出矩阵的Moore-Penrose广义逆来获得输出层的权值. 由于极限学习机仅进行一次计算就可完成网络的训练, 因此需要的训练时间远远短于梯度下降算法. 同时极限学习机不会受到梯度下降算法中训练步长、训练率等参数设定的影响, 也不存在局部最优解等问题.

极限学习机所具有的诸多优点使它获得了学者的广泛关注, 已提出了多种极限学习机的改进模型. 如优化剪枝极限学习机^[3,4]、误差最小化极限学习机^[5]、小波极限学习机^[6-8]、复合混沌优化的极限学习机^[9]等. 这些改进模型的优化方向多为通过减少极限学习机的节点个数或改变传递函数

以增强模型的适应性和泛化能力.

虽然极限学习机具有很多优点, 但是其从输入层到隐层节点的参数是随机选择的, 这一过程会对算法的性能带来影响^[10]. 为此Zhu等^[11]首先提出采用进化算法对极限学习机的节点参数选取进行优化的思想. 但目前根据这一思路提出的极限学习机优化模型多为单目标优化, 并且单纯考虑降低极限学习机的训练误差并不意味着会降低极限学习机的预测误差. 本文将训练误差和输出层权值的均方根值同时作为隐层参数的优化目标函数, 提出一种基于非支配排序遗传算法(NSGA-II)的多目标优化极限学习机. 带精英策略的快速NSGA-II为Deb等^[12]在2002年提出的多目标优化算法, 在电信^[13]、石油^[14]、航天^[15]等领域有成功的应用.

自然循环系统是由上升段与下降段中不同温度的流体产生的密度差提供循环动力的系统, 在核动力系统失去循环动力时依然能为核反应堆堆芯

* 黑龙江省留学归国人员基金(批准号: LC2011C18)、黑龙江省青年学术骨干支持计划(批准号: 1254G017)和哈尔滨工程大学核安全与仿真技术国防重点学科实验室基金(批准号: HEUFN1305)资助的课题.

[†] 通讯作者. E-mail: gaopuzhen@sina.com

提供冷却,对核动力系统安全具有重要意义.在船用核动力系统中,受海洋摇摆条件影响,流体处于附加外力场的作用下,自然循环动力系统容易出现复杂的流动不稳定性^[16].流动不稳定性会给核动力系统带来诸多问题:持续的流动振荡可能会造成不利的设备机械振动;流动振荡在水冷反应堆中会影响中子动力学过程,从而带来严重的系统控制问题;流动不稳定性还会影响局部的换热并在堆芯引发沸腾危机,严重时导致反应堆堆芯烧毁.因此研究海洋条件下的自然循环流动不稳定性的预测,对于提高核动力系统的安全性是十分必要的.本文将提出的多目标优化极限学习机算法应用于流动不稳定性预测问题上,为摇摆工况下自然循环流动不稳定性提供了一种新的全局预测途径.

2 实验系统与数据处理

为了研究海洋条件下船舶的横摇对自然循环系统热工水力特性的影响,利用哈尔滨工程大学摇摆实验台进行了自然循环实验.实验装置由加热段、冷凝器、稳压器、预热器、连接管和流量、压力、温度的测量仪表等组成.图1为实验回路示意图.上升段中的流体受到加热段加热,下降段中的流体为冷凝器冷凝之后的流体,由此在上升段和下降段形成密度差,从而形成自然循环的驱动压头,回路中没有泵提供的额外的动力.实验过程中,电机驱动的曲柄摇杆机构使整个实验台以一定角度和周期做简谐摇摆运动,以模拟海洋条件下船体的横摇,实验装置的详细布置和运行参数详见文献^[17].

摇摆工况下自然循环不稳定性实验显示,随着加热功率的增加,加热段的流动形式由单相流动逐渐转变为单相与汽液两相共存的流动,最终加热段内以汽液两相流动为主导.而流动不稳定性的形式则由单相正弦波动转变为摇摆主导的波谷型脉动,再转变为两相自然循环系统的密度波型不稳定性主导的复合型脉动^[18].在流量波动的主导因素由波谷型脉动向密度波不稳定性过渡的工况中,在摇摆引起的波谷型脉动和两相自然循环系统所固有的密度波不稳定性共同作用下,会出现无明显周期的不规则复合型脉动^[19].这种脉动与文献^[20]中两种周期性作用力引起的混沌系统相类似,具有分叉特性且混沌特性较强^[21],可能对海洋条件下自然循环系统的安全性产生较大影响,进行预测的

必要性最大,因此本文将作为预测研究的对象.本文选用的流量时间序列为实验回路中下降段的体积流量,图2为测得的3组不规则复合型脉动流量曲线,测量数据经过了小波降噪.3组实验数据采样时间间隔均为0.1 s,其工况参数和使用小数据量法计算得到的Lyapunov指数列于表1,3组时间序列的Lyapunov指数均大于0,证明了其具有混沌特性.对3组实验时间序列进行相空间重构得到的混沌吸引子结构如图3.




图1 摇摆实验台回路示意图




图2 不规则脉动流量时间序列曲线 (a) 数据组1; (b) 数据组2; (c) 数据组3

表1 实验数据参数

数据组	加热功率/kW	入口欠热度/(°)	摇摆周期/s	摇摆角度/(°)	Lyapunov 指数
1	3	40	10	15	0.1637
2	10	70	10	10	0.1288
3	6	40	7.5	10	0.1602

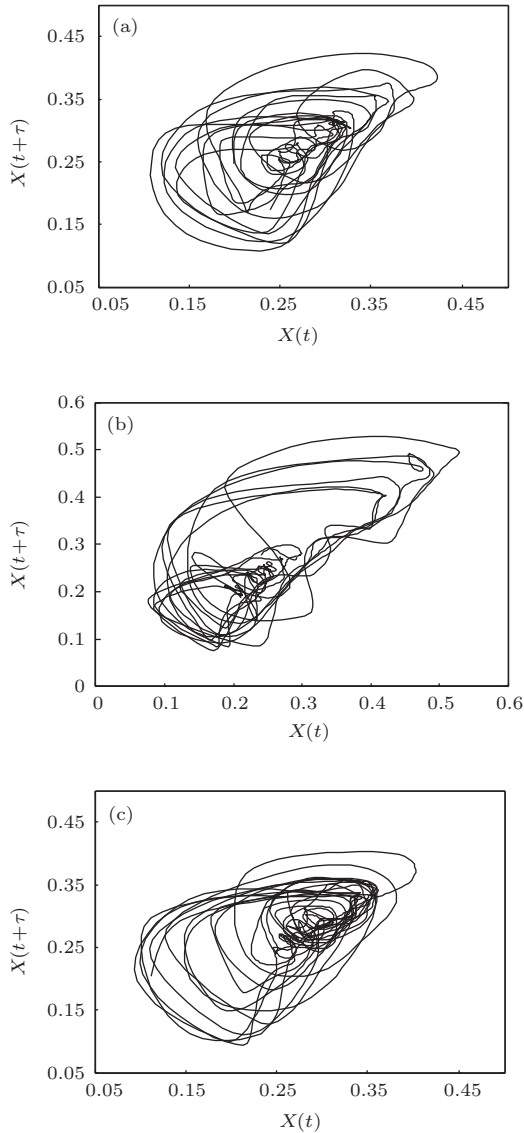


图3 流量时间序列吸引子结构 (a) 数据组 1; (b) 数据组 2; (c) 数据组 3

3 多目标优化极限学习机

3.1 极限学习机

极限学习机本质上是一种单隐层前向神经网络的训练算法。设有 Q 组训练样本 $(\mathbf{x}_i, \mathbf{t}_i)$ ($i = 1, 2, \dots, Q$), 输入向量 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]'$, 输出向量 $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{iM}]'$, 可以证明有 $K(K <$

$Q)$ 个隐层节点的单隐层神经网络可以通过增加隐层节点数零误差逼近训练样本, 即有

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T}, \tag{1}$$

其中 $\mathbf{H} = \{h_{ij}\} (i = 1, 2, \dots, Q; j = 1, 2, \dots, K)$ 是隐层输出矩阵, 设激活函数为 $g(x)$, $h_{ik} = g(\mathbf{w}'_k \cdot \mathbf{x}_i + b_k)$, \mathbf{w}_k 是从输入层到第 k 个隐层节点的权值向量, b_k 为第 k 个隐层节点的阈值. $\boldsymbol{\beta} = \{\beta_{kj}\} (k = 1, 2, \dots, K; j = 1, 2, \dots, M)$ 为从隐层到输出层的权值矩阵, 其中 β_{kj} 为从隐层第 k 个节点到输出层第 j 个节点的权值. $\mathbf{T} = [t_1, t_2, \dots, t_Q]'$ 是神经网络的输出矩阵.

极限学习机首先随机定义单隐层神经网络输入权值和隐层阈值, 然后用最小二乘法求解 (1) 式从而得到输出层的权值, 其解为

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^\dagger \mathbf{T}, \tag{2}$$

其中 \mathbf{H}^\dagger 是矩阵 \mathbf{H} 的 Moore-Penrose 广义逆. 从极限学习机的计算过程可以看出, 它不需要反复修正节点权值和阈值, 一次顺序计算就可以完成整个网络的训练, 因此它的训练速度远优于需要反复修改各节点参数的梯度下降算法.

3.2 NSGA-II 算法

NSGA-II 算法由 NSGA 算法 [22] 改进而来, 是一种典型的多目标进化算法. 该算法在每一代首先对亲代种群 P 进行遗传操作, 得到子代种群 Q , 然后将子代种群与亲代种群合并, 进行非支配排序和拥挤距离排序, 形成新的亲代种群. 其具体过程 [12] 描述如下.

1) 随机产生初始种群 P_0 , 然后对种群进行非支配排序, 每个个体被赋予秩; 再对初始种群执行锦标赛选择、交叉和变异操作, 得到子代种群 Q_0 , 记代数 $t = 0$.

2) 形成新的群体 $R_t = P_t \cup Q_t$, 对种群 R_t 进行非支配排序, 得到非支配前端 F_1, F_2, \dots .

3) 对所有的非支配前端进行拥挤距离比较, 选择其中最好的 N 个个体形成新种群 P_{t+1} .

4) 对种群 P_{t+1} 进行复制、交叉和变异, 形成种群 Q_{t+1} .

5) 如果终止条件成立, 则得到问题的 Pareto 最优解集; 否则, 代数 $t = t + 1$, 转到 2).

非支配排序和拥挤排序的流程如图 4 所示.

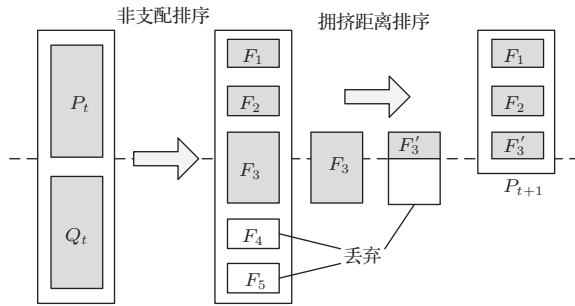


图 4 NSGA-II 流程示意图

3.3 多目标优化极限学习机

极限学习机随机选取输入权值和隐层阈值, 只进行一次运算就得到神经网络模型, 这使极限学习机具有了训练速度快和不容易过训练等显著优点, 但是其随机选择参数的过程会使极限学习机的性能不稳定. 为此 Zhu 等^[11] 提出采用进化算法对极限学习机的节点参数选取进行优化. 极限学习机的训练误差可以作为优化极限学习机的目标函数, 但是降低训练误差虽然提高了模型对训练样本的拟合精度, 却并不一定能增强泛化能力和降低预测误差. Bartlett^[23] 从数学上证明了输出层权值的大小对人工神经网络具有显著影响, 节点参数较小的人工神经网络具有较强的泛化能力, 这一结论对于模式识别问题和函数回归问题都是适用的. 因此本文将训练误差和输出层权值的均方值作为优化的两个目标函数对极限学习机进行多目标优化, 得到这一问题的 Pareto 最优解集, 并从中选择适当的样本完成预测, 从而优化极限学习机对不规则复合型流动不稳定的预测能力, 具体的计算流程如图 5 所示.

4 对流动不稳定性的预测

4.1 仿真实验与结果分析

将实验得到的 3 组流量时间序列进行相空间重构, 选取每组的前 1000 个数据向量作为极限学习机的训练样本, 激活函数选用反双曲正弦函数.

随机生成 1000 组输入权值和隐层节点阈值作为 NSGA-II 多目标优化的初始样本, 权值和阈值的取值范围为 $[-1, 1]$, 经过 200 步进化得到 Pareto 最优解集.

对 3 组数据进行仿真获得 Pareto 最优解集后, 为了获得最终的预测结果, 必须从中选取泛化能力最好的样本. 将 3 组 Pareto 最优解集中的非支配解按照训练误差由小到大、输出层节点权值由大到小的顺序排序, 并分别进行预测验证. Pareto 最优解集形成的 Pareto 前沿和仿真得到非支配解对应的预测误差列于图 6. 图 6 中的 Pareto 前沿可以分为两部分: 位于图 6 左侧的一支训练误差接近最优值, 而输出层节点权值相差较大; 位于图 6 底部的一支输出层节点权值接近最优值, 而训练误差相差较大. 两支 Pareto 最优解在左下角交汇处形成一个较明显的拐角.

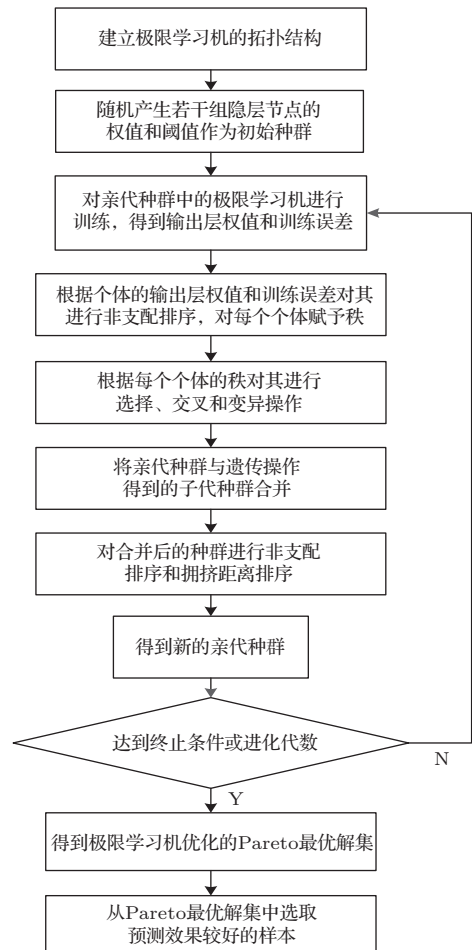


图 5 多目标优化极限学习机流程

文献^[23] 提出神经网络的节点权值大小对神经网络的泛化能力有重要影响, 并从数学上证明了

具有较小的训练样本误差和节点权值数量级的神经网络有较强的泛化能力, 而这一结论在权值衰减法和提前终止法等提高神经网络泛化能力的方法中得到了证实. 同时, 文献 [24] 也指出, 在函数拟合问题中, 有着接近最小训练误差的神经网络的预测误差上限会随着节点权值量级的增大而增大. 分析本文的仿真结果发现, Pareto 最优解左侧一支的样本的训练误差均已接近最优值, 而其中输出层节点权值较低的非支配解的预测结果好于输出层节点权值较高的非支配解, 这与文献 [24] 中得到的结果一致. 此外在图 6 所示的 Pareto 前沿上拐点处的样本同时具有较小的训练样本误差和节点权值, 图 6 中的预测误差也证实此处样本的预测误差最小, 即泛化能力最好, 因此选为预测使用的样本.

采用第 2 组数据中 Pareto 前沿拐点处的样本 (序号 65) 和拐点左侧、右侧的样本 (序号 45、序号 78) 的参数, 进行不同提前步数的预测流量曲线与实验流量曲线的对比, 结果列于图 7. 结果也证明拐点处的样本所对应的极限学习机预测效果较好.

4.2 预测误差比较

采用 BP 神经网络 (BP-NN)、支持向量机 (SVM)、极限学习机 (ELM)、遗传算法单目标优化的极限学习机 (GA-ELM) 和优化剪枝极限学习机 (OP-ELM) 对 3 组数据进行预测仿真, 并将预测误差与本文提出的多目标优化极限学习机 (MO-ELM) 的预测误差相比较, 结果列于表 2.

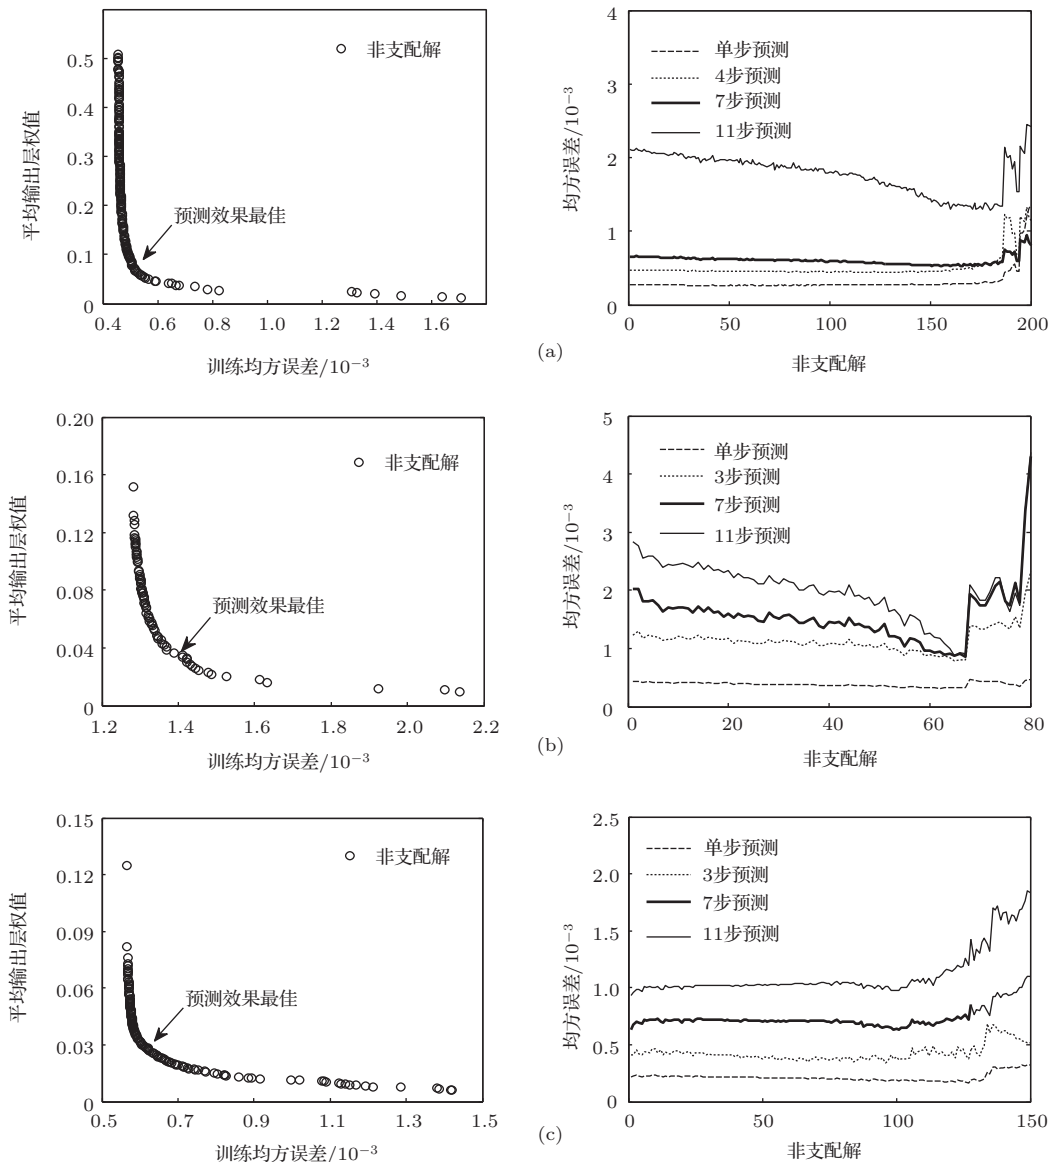


图 6 Pareto 最优解集与预测误差 (a) 数据组 1; (b) 数据组 2; (c) 数据组 3

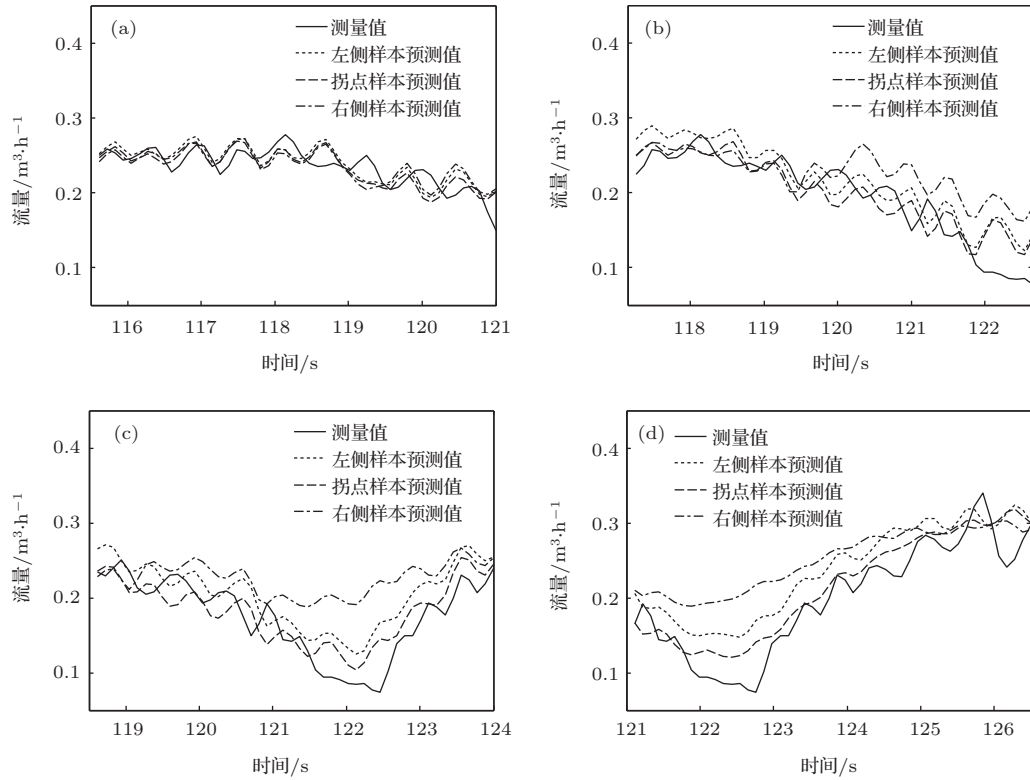


图7 流量预测结果对比 (a) 单步预测; (b) 4步预测; (c) 7步预测; (d) 11步预测

表2 不同预测方法的预测效果比较

数据组	算法	单步预测均方误差	4步预测均方误差	7步预测均方误差	11步预测均方误差	最佳隐层节点数
		$/10^{-3}$ (提前 0.55 s)	$/10^{-3}$ (提前 2.2 s)	$/10^{-3}$ (提前 3.85 s)	$/10^{-3}$ (提前 6.05 s)	
1	BP-NN	0.2759	0.6650	0.1298	1.952	3
	SVM	0.1897	0.6006	0.1015	1.830	—
	ELM	0.3250	0.6776	0.7076	2.141	15
	GA-ELM	0.2668	0.4875	0.5933	1.920	8
	OP-ELM	0.2162	0.3307	1.285	2.037	15
	MO-ELM	0.2779	0.4500	0.5430	1.296	7
2	BP-NN	0.3896	1.706	2.312	3.191	5
	SVM	0.2892	1.167	3.387	4.278	—
	ELM	0.5672	1.763	2.172	2.265	21
	GA-ELM	0.4337	1.375	2.667	3.966	10
	OP-ELM	0.3934	1.283	1.563	0.178	18
	MO-ELM	0.3226	0.8117	0.8655	0.9181	10
3	BP-NN	0.3941	2.105	2.530	3.830	6
	SVM	0.3509	2.823	3.978	4.691	—
	ELM	0.3329	0.6244	0.8479	1.060	24
	GA-ELM	0.3302	0.5822	0.7609	0.9721	9
	OP-ELM	0.2792	0.8030	1.275	1.406	20
	MO-ELM	0.1905	0.3831	0.6370	0.9521	9

实验结果表明,多目标优化极限学习机的预测误差低于其他几种模型,特别是在较长提前步数的预测中优势更为明显.另外,极限学习机的缺点之一是需要较多的隐层节点,因而网络规模较大;而多目标优化极限学习机比未经优化的极限学习机所需的隐层节点数更少,网络规模更为紧凑,具有更强的适应性.在实际的在线预测中,由于极限学习机训练速度较快,当工况发生变化使当前预测模型效果变差时,可以迅速重新进行学习并恢复预测效果,具有较强的灵活性.因此多目标优化极限学习机是十分有前途的流动不稳定性在线预测方法.

5 结 论

针对极限学习机的预测性能受到随机确定的隐层节点参数影响这一特点,将降低训练误差和输出层权值同时作为优化目标,提出了一种应用NSGA-II算法的多目标优化极限学习机模型.将该模型应用于摇摆工况下自然循环不规则复合型流量不稳定脉动的预测中,得到了隐层参数的Pareto最优解集,并讨论了Pareto最优解集中预测效果最优样本所在的位置.仿真结果表明,多目标优化极限学习机的预测效果优于目前常用的BP神经网络、支持向量机和极限学习机等预测方法,为流动不稳定性的非线性实时预测提供了一种效果较好且具有全局预测能力的途径.

参考文献

- [1] Huang G B, Zhu Q Y, Siew C K 2004 *Proceedings of the International Joint Conference on Neural Networks* Budapest, Hungary, July 25–29, 2004 p985
- [2] Li M B, Huang G B, Saratchandran P, Sundararajan N 2005 *Neurocomputing* **68** 306

- [3] Rong H J, Ong Y S, Tan A H, Zhu Z 2008 *Neurocomputing* **72** 359
- [4] Miche Y, van Heeswijk M, Bas P, Simula O, Lendasse A 2011 *Neurocomputing* **74** 2413
- [5] Feng G, Huang G B, Lin Q, Gay R 2009 *IEEE Trans. Neural Networ.* **20** 1352
- [6] Cao J, Lin Z, Huang G B 2010 *Neurocomputing* **73** 1405
- [7] Cao J, Lin Z, Huang G B 2011 *Neural Process. Lett.* **33** 251
- [8] Javed K, Gouriveau R, Zerhouni N 2014 *Neurocomputing* **123** 299
- [9] Gao G Y, Jiang G P 2012 *Acta Phys. Sin.* **61** 040506 (in Chinese) [高光勇, 蒋国平 2012 物理学报 **61** 040506]
- [10] Bhat A U, Merchant S S, Bhagwat S S 2008 *Ind. Eeg. Chem. Res.* **47** 920
- [11] Zhu Q Y, Qin A K, Suganthan P N, Huang G B 2005 *Pattern Rrcogn.* **38** 1759
- [12] Deb K, Pratap A, Agarwal S, Meyarivan T 2002 *IEEE Trans. Evolut. Comput.* **6** 182
- [13] Huang B, Buckley B, Kechadi T M 2010 *Expert Syst. Appl.* **37** 3638
- [14] Ak R, Li Y, Vitelli V, Zio E, Droguett E L, Jacinto C M C 2013 *Expert Syst. Appl.* **40** 1205
- [15] He B Y, Li H Y, Zhang B 2013 *Acta Phys. Sin.* **62** 190505 (in Chinese) [贺波勇, 李海阳, 张波 2013 物理学报 **62** 190505]
- [16] Tan S C, Su G H, Gao P Z 2009 *Ann. Nucl. Eng.* **36** 103
- [17] Tan S C, Su G H, Gao P Z 2009 *Appl. Therm. Eng.* **29** 3160
- [18] Tan S C, Pang F G 2005 *Nucl. Power Engineer.* **26** 140 (in Chinese) [谭思超, 庞凤阁 2005 核动力工程 **26** 140]
- [19] Tan S C, Gao P Z, Su G H 2008 *Atom. Energy Sci. Technol.* **42** 1007 (in Chinese) [谭思超, 高璞珍, 苏光辉 2008 原子能科学技术 **42** 1007]
- [20] Jiang H, Li T, Zeng X L, Zhang L P 2014 *Chin. Phys. B* **23** 010501
- [21] Zhang W, Tan S, Gao P, Wang Z, Zhang L, Zhang H 2014 *Ann. Nucl. Energy* **65** 1
- [22] Srinivas N, Deb K 1994 *Evolutionary Comput.* **2** 221
- [23] Bartlett P L 1998 *IEEE Trans. Inform. Theory* **44** 525
- [24] Lee W S, Bartlett P L, Williamson R C 1996 *IEEE Trans. Inform. Theory* **42** 2118

Prediction method of flow instability based on multi-objective optimized extreme learning machine*

Chen Han-Ying Gao Pu-Zhen[†] Tan Si-Chao Fu Xue-Kuan

(Fundamental Science on Nuclear Safety and Simulation Technology Laboratory, Harbin Engineering University,
Harbin 150001, China)

(Received 28 April 2014; revised manuscript received 9 June 2014)

Abstract

Extreme learning machine (ELM) is a recently proposed learning algorithm for single-hidden-layer feedforward neural networks, which has a fast learning speed while avoiding the problem of local optimal solution. However, the performance of ELM may be affected due to the random determination of the input weights and hidden biases. In this paper, a multi-objective optimized extreme learning machine (MO-ELM) is proposed to solve this problem. The algorithm uses the no-dominated sorting genetic algorithm II algorithm to select input weights and hidden biases. Both the learning errors and the mean square value of output weights are used as optimization objects. The MO-ELM algorithm is used in the multi-step forecast of irregular complex flow oscillations of natural circulation system in rolling motion, and the influences of learning errors and output weights on forecast results are analyzed. Experimental results show that MO-ELM can achieve good generalization performance with much more compact networks and provide a relatively accurate forecast method of flow rate, and the forecast results can be used as reference to nuclear power system operators.

Keywords: flow instability, extreme learning machine, multi-objective optimization, no-dominated sorting genetic algorithm II

PACS: 05.45.Pq, 05.45.Tp, 47.52.+j

DOI: [10.7498/aps.63.200505](https://doi.org/10.7498/aps.63.200505)

* Project supported by the Scientific Research Foundation of Heilongjiang Province for Returned Overseas Chinese Scholars, China (Grant No. LC2011C18), the Foundation for Young Key Scholars of Higher Education Institution of Heilongjiang Province, China (Grant No. 1254G017), and the Foundation of Fundamental Science on Nuclear Safety and Simulation Technology Laboratory, China (Grant No. HEUFN1305).

[†] Corresponding author. E-mail: gaopuzhen@sina.com