

基于动态记忆反馈的改进 ELM 故障预测方法应用研究

徐 圆, 叶亮亮, 朱群雄

(北京化工大学 信息科学与技术学院, 北京 100029)

摘 要: 随着工业系统复杂性的逐步增加, 对故障预测的实时性和准确性提出了更高的要求. 对此, 提出一种基于动态记忆反馈的改进 ELM 神经网络模型进行故障预测. 此模型在结构上增加了反馈层用于记忆隐含层输出, 并从反馈层记忆的信息中提取数据变化趋势特征, 从而动态更新反馈层的输出权重. 通过对非线性动态系统的下一时刻输出进行预测, 并对预测输出进行诊断, 达到故障预测的目的. 通过人工数据 Sinc 验证和 TE 过程实例应用表明了所提出方法具有预测精度高、动态适应能力强等优点, 对非线性时序系统具有较好的预测能力.

关键词: 极限学习机; 动态递归; 故障预测

中图分类号: TP273

文献标志码: A

Improved dynamic recurrent-based ELM neural network for fault prediction

XU Yuan, YE Liang-liang, ZHU Qun-xiong

(College of Information Science Technology, Beijing University of Chemical Technology, Beijing 100029, China.

Correspondent: XU Yuan, E-mail: xuyuan@mail.buct.edu.cn)

Abstract: With the increase of the complexity of industrial system, the demand of real time of accuracy of fault prediction is higher. Therefore, an improved dynamic recurrent-based extreme learning machine (DR-ELM) neural network is proposed for fault prediction. For the network structure, a feedback layer is added to memorize the hidden output. And the trend characters of data variation is extracted from the feedback information, so as to update the output weight of feedback layer dynamically. Through the prediction of the next-time output for the nonlinear dynamic system, the diagnosis is made for the prediction output, then the fault prediction is realized. A numerical study(Sinc test) and the complicated Tennessee Eastman(TE) benchmark process show the superiority of the proposed approach not only in prediction accuracy but also in dynamic adaptability, and the better prediction ability for non-linear sequential systems.

Keywords: extreme learning machine; dynamic recurrent; fault prediction

0 引 言

如今大型工业系统通常流程复杂、控制环节与控制点多, 而许多重大危险源一旦发生安全事故, 将会造成巨大的生命和财产损失^[1]. 因此, 如何根据系统过去和当前的状态, 预测系统在将来可能发生的故障^[2-4], 即故障预测, 是保障工业系统安全的重要任务之一. 目前, 工业系统对故障预测方法的实时性和准确性的要求逐步增高, 尤其对于非线性动态系统, 要求故障预测模型能够快速准确地对系统运行过程中各变量进行实时地故障预测分析^[5-6], 这也是故障预

测研究的主要问题.

近年来, 系统的故障预测方法主要包括贝叶斯估计方法^[7]、灰色理论^[8]、专家系统技术^[5]、粒子滤波^[9]和神经网络技术^[10-11]等. 人工神经网络因其具有强大的非线性逼近功能, 且建模难度低, 十分适用于复杂过程预测^[11]. 目前, 用于故障预测的神经网络多为静态前馈型神经网络, 如 BP、RBF 和 ELM 等. BP 网络通过对数据进行静态映射来达到预测目的, 训练完成后具有性能稳定的优点, 但同时 BP 网络也有很明显的缺陷, 如网络的训练速度慢、存在局部最

收稿日期: 2014-01-27; 修回日期: 2014-04-21.

基金项目: 国家自然科学基金项目(61104131); 北京市自然科学基金项目(4142039); 北京市青年英才计划项目(BJYC21); 中央高校基本科研业务费项目(ZZ1312).

作者简介: 徐圆(1983—), 女, 副教授, 博士, 从事系统仿真、故障预测等研究; 朱群雄(1960—), 男, 教授, 博士生导师, 从事人工智能、数据挖掘等研究.

优解等; RBF神经网络可将低维空间非线性问题映射到高维空间线性可分, 但其对典型训练样本的提取要求较高, 训练难度大^[12]; ELM神经网络训练速度快, 泛化精度高, 鲁棒性强, 但对于动态系统预测, ELM网络仍然存在预测精度不高的缺点^[11, 13]. 动态递归网络因具备映射动态特征的功能, 能较好地解决静态网络对于动态系统建模存在的问题. 反馈网络是一种动态网络, 主要代表有 Hopfield 网络^[14]、Boltzmann 机和 Elman 网络^[15]等.

本文根据动态网络的递归思想, 提出一种基于动态信息记忆反馈功能的改进 ELM 神经网络模型 (DR-ELM). 在 DR-ELM 网络中, 通过在网络前馈隐含层中增加反馈承接层, 用于记忆历史数据信息并反馈影响下一时刻输入, 使网络具有动态记忆功能; 同时采用滑动窗口技术, 提取历史数据趋势变化特征, 并根据趋势变化特征对反馈承接层的输出权值进行动态调整, 从而实现对非线性动态系统的回归预测. 相对于传统机器学习方法, 该算法具有更快的训练速度, 同时针对实时系统兼具动态调整的能力. 通过对人工数据 Sinc 波形的预测实验和对 TE 过程的故障预测应用, 比较结果表明该方法在预测精度和实时性方面都得到了较大的提高, 较好地解决了复杂动态系统的故障预测问题.

1 DR-ELM 网络

1.1 DR-ELM 网络结构

DR-ELM 网络在 ELM 网络结构的基础上, 通过增加反馈承接层以动态记忆隐含层输出数据, 同时运用滑动窗口采集单位时间数据的变化率, 用以表示数据的趋势特征, 从而形成 DR-ELM 网络结构. 此网络中, 反馈承接层数目表示记忆历史数据规模, 而承接层数目需根据数据的时滞性和网络训练精度进行确定. DR-ELM 网络结构如图 1 所示.

DR-ELM 网络结构中包括输入层、隐含层、反馈承接层和输出层. 假定 DR-ELM 网络的隐含层节点数为 N' , 反馈承接层数为 Q ; 输入数据集为 P , 其中输入数据集 P 包含 k 时刻的输入样本, 单位输入样本包含 n 个属性; 网络的目标输出集为 T , 输出数据集与输入数据集相同, 包含 k 时刻的输出样本, 单位输出样本包含 m 个属性.

DR-ELM 的输入层只对输入样本 P 进行记忆, 因此输入层节点数与输入样本的属性数相同为 n ; 输入层与隐含层之间的连接权值为 A , 隐含层节点偏差为 B . DR-ELM 的隐含层用于激活输入, 其中隐含层的激活函数为 $g(\cdot)$, 隐含层输出为 H , 输入层与隐含层的连接权值为 A , 输入层与隐含层的偏差为 B , 隐含层输出至反馈承接层和输出层. DR-ELM 的反馈承接层对隐含层的输出进行记忆存储, 反馈承接层输出为 H' , 反馈承接层趋势特征因子为 η , 每层反馈承接层与隐含层之间的输出权值为 Wb . DR-ELM 的输出层得到网络的最终计算结果, 其中输出层的输出权值为 β , 将隐含层的输出 H 进行计算即可获得网络输出 T .

DR-ELM 网络训练过程中, 输入层与隐含层的连接权值为 A , 输入层与隐含层的阈值为 b , 承接层与隐含层的连接权值均为随机赋值, 采用广义最小二乘法可得到网络最优输出权值 β ^[16]. 反馈承接层数目表示记忆历史数据信息的程度, 由于权值的大小与所在承接层相关, 离现时较远的的数据对输出影响程度低于当前记忆的历史数据, 因此网络具有遗忘功能, 反馈承接层存储的历史数据经过计算得到反馈承接层输出 H' , 直接反馈至隐含层, 对隐含层的输出 H 进行调整. 网络通过对包含 k 时刻的数据集进行训练后, 权值 A , B , Wb 和 β 将被记忆保留. 反馈承接层根据当前存储的数据, 提取当前的数据趋势变化特征, 根据提取的趋势特征对反馈承接层输出权值进行更新, 从

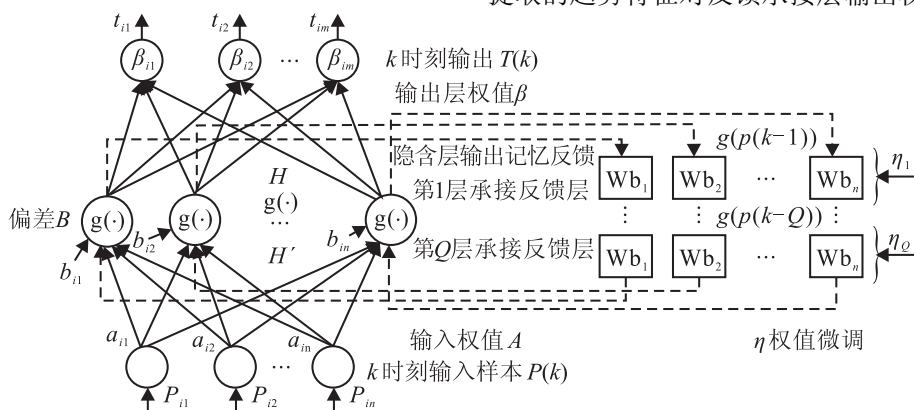


图 1 DR-ELM 结构

而在每一个时刻对隐含层输出进行动态调整。

1.2 DR-ELM 算法

DR-ELM 由输入层、隐含层、反馈承接层和输出层组成, 假设 DR-ELM 网络中样本集 U 包含 k 时刻的学习样本, 网络目标输出为 T . 其中 $T = H\beta$, H 表示隐含层输出矩阵, β 表示输出层权值. 对样本 U 采用 DR-ELM 神经网络建模流程如下.

1) 构造训练样本与泛化样本.

假设输入样本包含 n 个属性、输出样本包含 m 个属性, 网络的样本集、输入样本和期望输出分别为

$$U = \{(P_i, T_i) | i = 1, 2, \dots, k; P_i \in R^n; T_i \in R^m\}, \quad (1)$$

$$P_i = [p_{i1}, p_{i2}, \dots, p_{in}], \quad (2)$$

$$T_i = [t_{i1}, t_{i2}, \dots, t_{im}]. \quad (3)$$

其中: P 为输入样本, T 为期望输出, 由 P 和 T 构成成样本集 U .

假设样本集包含 k 时刻样本, 输入样本 P 和输出样本 T 分别为

$$P = [P_1^T, P_2^T, \dots, P_k^T]_{n \times k}, \quad (4)$$

$$T = [T_1^T, T_2^T, \dots, T_k^T]_{k \times m}. \quad (5)$$

2) 连接权值设置.

假设网络共有 N' 个隐藏结点, 随机设定输入层与隐含层之间的连接权值 A 和偏差 B , 连接权值与偏差可表示为

$$A = [A_1, A_2, \dots, A_n]_{N' \times n}, \quad (6)$$

$$B = [B_1, B_2, \dots, B_n]_{N' \times n}. \quad (7)$$

其中

$$A_i = [a_{i1}, a_{i2}, \dots, a_{iN'}]^T, i \in [1, n]; \quad (8)$$

$$B_i = [b_{i1}, b_{i2}, \dots, b_{iN'}]^T, i \in [1, n]. \quad (9)$$

这里: A_i 为连接第 i 个隐藏层结点的输入权值, B_i 为 i 个隐藏层结点的偏差.

3) 隐含层矩阵.

$g(\cdot)$ 表示隐含层激活函数, 本文选择 Sigmoid 作为隐含层激活函数. 在第 k 时刻样本输入后, 若反馈承接层为 0 层, 则隐含层矩阵 H 与标准 ELM 相同, 即

$$H = \begin{bmatrix} g(A_1 P_1^T b_1) & \cdots & g(A_{N'} P_1^T b_{N'}) \\ \vdots & \ddots & \vdots \\ g(A_1 P_k^T b_1) & \cdots & g(A_{N'} P_k^T b_{N'}) \end{bmatrix}_{k \times N'} \quad (10)$$

4) 反馈承接层权值设置.

在隐含层中增加 Q 层反馈承接层用于记忆隐含层输出, 若现时刻输入为 $P(k)$, 则第 Q 层反馈承接层的记忆样本为 $g(k - Q)$, 设反馈权值为 Wb , 权值随机取 0 至 1 之间取值. 其中第 Q 层反馈输出权值为

$$Wb_Q = [wb_1^q, wb_2^q, \dots, wb_{N'}^q], wb_i \in (0, 1), \quad (11)$$

其中第 Q 层权值为设定权值 wb 的 q 次幂, 使反馈承接层具备遗忘功能.

5) 提取趋势特征因子.

采用滑动窗口进行数据特征提取, 根据单位时间内数据变化率表征数据的趋势变化形式. 第 Q 层趋势特征因子为

$$\eta_Q = [\eta_1^Q, \eta_2^Q, \dots, \eta_{N'}^Q]. \quad (12)$$

运用下式计算得到趋势特征:

$$\eta_{N'}^Q = \frac{g(P_k^T(k - Q + 1)) - g(P_k^T(k - Q))}{c(k - Q + 1) - c(k - Q)}, \quad (13)$$

其中 c 表示单位时间变化.

6) 反馈承接层输出.

将得到的趋势特征因子对承接反馈层输出权值进行调整, 即

$$Wb_Q = Wb'_Q \cdot \eta_Q. \quad (14)$$

由于权值在 0 到 1 之间, 离现时越远的信息, 其 Wb 的值越小, 越能够对离现时较远的信息进行遗忘. 运用下式可得反馈承接层输出权值:

$$H'(k) = \sum_{q=1}^Q (Wb_Q \cdot g(P(k - Q))). \quad (15)$$

7) 隐含层输出调整.

将反馈承接层与当前时刻输入进行线性相加, 即 $H = H(k) + H'(k)$, 修正后的隐含层输出矩阵为

$$H = \begin{bmatrix} g(P_1^T) + H'(1) & \cdots & g(P_1^T) + H'(1) \\ \vdots & \ddots & \vdots \\ g(P_k^T) + H'(k) & \cdots & g(P_k^T) + H'(k) \end{bmatrix}_{k \times N'} \quad (16)$$

8) 输出权值训练.

由前文可知, 在训练过程中, 将随机给隐含层权值 A 、偏差 B 和反馈承接层的输出权值 Wb 赋值, 即 H 和 T 已知, 网络输出权值为

$$\beta = [\beta_1, \beta_2, \dots, \beta_{N'}]^T_{N' \times m}, \beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]. \quad (17)$$

由此, 隐含层神经元与输出层神经元的连接权值可由极小范数最小二乘解得^[12, 16-17], 即

$$\beta = H^+ T. \quad (18)$$

9) 网络模型的回想与泛化.

根据训练网络所获得的权值再次输入样本 U , 计算 DR-ELM 网络的输出 $U_k (k = 1, 2, \dots, k)$, 并进行反归一化, 与期望输出 $T_k (k = 1, 2, \dots, k)$ 进行比较, 计算训练均方误差和训练标准差, 回想过程结束.

选择与训练样本不同的数据集合作为网络的泛化样本, 按时间序列输入到 DR-ELM, 根据记忆的历史值动态调整反馈层权值, 利用泛化样本 U' 计算网络的泛化输出. 将泛化输出与泛化期望输出进行比较, 计算泛化均方误差和泛化标准差, 泛化过程结束.

2 人工数据 Sinc 测试

Sinc 数据在区间范围内会产生波峰波谷, 数据趋势变化大, 有利于验证网络预测性能, 因此为了验证 DR-ELM 网络对于时序模型预测的有效性, 选择人工数据 Sinc 的输出波形进行预测实验. 数据产生方法为: 在区间 $(-10, 10)$ 内以递增方式产生 5000 个训练样本和测试样本; 为了验证模型的鲁棒性, 在所有训练样本上附加取值范围为 $[-0.2, 0.2]$ 的随机噪声, 而测试数据无噪声. 本节针对 ELM 与 DR-ELM 两种模型, 分别验证了隐含层节点数、反馈承接层和趋势特征对模型预测的影响.

2.1 隐含层节点数与相对误差

下面进行隐含层节点数与网络输出相对误差关系的实验. 图 2 显示了 ELM 和 DR-ELM 在节点数分别为 5, 10, 15, 20, 25, 30 条件下, 预测输出的相对误差变化.




图 2 隐含层节点数与输出相对误差关系

由图 2 可知: 通过增加标准 ELM 隐含层节点数, 其输出精度并没有显著提高, 输出相对误差基本稳定在 4% 左右, 提升空间小, 标准 ELM 在隐含层节点数为 5 的效果最好; DR-ELM 网络输出相对误差比 ELM 小, 选择合适的 DR-ELM 网络结构, 其相对误差可提升至 2% 以内, DR-ELM 在隐含层节点数增加至 10 后性能达到最佳. 由此可知, 对于 Sinc 数据增加反馈承接层数能够提高系统预测输出精度.

2.2 反馈层与趋势特征提取的影响

考虑网络结构和精度关系, 选择节点数为 10 进

行模型性能的详细对比, 同时验证趋势特征提取对网络预测的影响. 表 1 记录了标准 ELM 和 DR-ELM 网络性能的比较结果, 每种网络均进行 50 次实验来计算其性能平均值, 采用均方误差 mse 判断网络精度, 通过计算精度的平均标准差 stdev 判断网络的稳定性.

表 1 Sinc 预测精度结果对比

类型(承接层)	趋势特征	训练 mse	训练 stdev	泛化 mse	泛化 stdev
ELM(0)	N	0.092	0.0001	0.0309	0.0024
DR-ELM(1)	N	0.084	0.0001	0.0202	0.0015
DR-ELM(1)	Y	0.0842	0.0001	0.0198	0.0008
DR-ELM(2)	N	0.0804	0.0007	0.0152	0.0017
DR-ELM(2)	Y	0.0811	0.0001	0.0129	0.001
DR-ELM(3)	N	0.0787	0.0015	0.0130	0.0026
DR-ELM(3)	Y	0.0791	0.0001	0.0104	0.0009

由表 1 可知: 在相同隐含层结点的条件下, ELM 训练和泛化精度分别为 0.092 和 0.0309, 训练标准差和泛化标准差分别为 0.0001 和 0.0024, 网络训练精度和稳定性均低于 DR-ELM. 以 1 层 DR-ELM 网络(未提取趋势特征)为例, 其训练精度和泛化精度提升至 0.0840 和 0.0202, 相比于标准 ELM 训练性能提升约 8.7%, 泛化性能提升约 34.6%; 对比 DR-ELM 在不同反馈承接层数下的预测输出可知, 对于 Sinc 数据, 网络在增加反馈承接层后, 其训练和泛化精度都得到提高, 3 层反馈承接层的 DR-ELM 泛化性能从 0.0202 提高至 0.0130, 性能提升约 35.64%; 对比提取趋势特征对 DR-ELM 的影响可以发现, 趋势特征的提取不仅提高了网络的输出精度, 同时增加了网络输出的稳定性, 以 3 层反馈承接层 DR-ELM 实验结果为例, 泛化精度由 0.0130 提升至 0.0104.

图 3 为 Sinc 数据 2350~2550 段标准 ELM 与 DR-ELM 网络输出的对比. 由于在数据趋势变化大的部分, 预测精度效果容易变差, 这里选择数据趋势增减变化较大的 2350~2550 段进行对比.

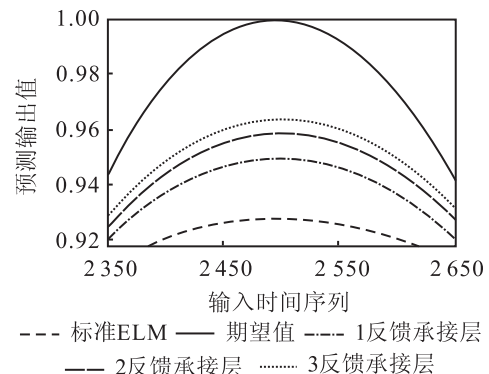


图 3 Sinc 预测输出对比

由图 3 可见, 增加反馈承接层的 DR-ELM 网络输出值更接近于预测真实值. 同时在数据波动的拐点预

测难度较大的情况下,增加记忆层数目可达到增加历史数据对当前时刻预测影响的目的,使DR-ELM在数据趋势变化处的预测值与真实值更接近。

通过对比两个模型的泛化精度和稳定性可发现,通过增加反馈承接层,DR-ELM相对于标准ELM具备对历史数据记忆和对数据趋势变化进行权值调整的能力,因此相对于标准ELM具有更高的泛化精度和稳定性。

3 工程应用

为了验证该神经网络模型的实用性,选择TE过程进行故障预测研究测试。

3.1 TE 过程

TE过程是一个典型的实际工业过程,包括反应器、换热器、企业分离器、汽提塔和压缩机5个单元,

在TE仿真过程中共有12个操作变量和41个测量变量,仿真过程中有20个预先设定好的干扰,其中故障1~故障15为已知故障,故障16~故障20为未知故障。本次实验通过仿真模型48小时的数据进行建模,仿真过程中每30s进行一次采样,在第5小时加入故障,选择故障发生后第1小时的数据作为故障特征数据,同时也作为神经网络的训练样本。通过DR-ELM模型预测系统下一时刻的输出,并将预测输出作为故障判别数据,从而达到故障预测的目的。

3.2 TE过程变量预测

为了提高DR-ELM模型的预测精度,降低DR-ELM网络的训练难度,在获取TE训练数据后,采用模糊聚类方法将53个变量分为18类,模糊聚类结果为:1)物料D阀门,物料C阀门,反应器液位,气提塔温度;2)物料E阀门,产品组分G;3)汽提塔底产品流量阀门,反应器进料总流量,产品组分H;4)气液分离器液位,气提塔液位;5)物料A阀门,气液分离器出口流气提塔出口流量,排空物料组分B,排空气流阀门,反应器给料组分B,反应器给料组分E,排空物料组分E,排空物料组分C,排空物料组分G;6)压缩机阀门,再沸器蒸气阀门,物料A流量,排空物料流量,产品组分D,产品组分E,产品组分F;7)冷凝器冷却水流量控制阀;8)气液分离器底部阀门,反应器冷却水流量控制阀,回流物料流量,反应器给料组分A,排空物料组分A;9)搅拌速度,反应器冷凝液出口温度;10)气液分离器温度,气液分离器液位;11)反应器温度;12)压缩机功率;13)物料D流量;14)气提塔压力;15)反应器压力;16)气液分离器压力;17)物料E流量;18)排空物料组D,物料C流量,反应器给

料组分D,排空物料组分F,排空物料组分G,反应器给料组分F,排空物料组分H,气提塔蒸气流量。

首先,对比不同网络结构对于TE过程的预测输出精度,输入节点数和输出节点数由训练泛化样本决定。考虑网络结构与输出精度关系,本文选择在隐含层结点数均为20的条件下进行TE过程预测,选择第1,10和11类变量进行测试来对比ELM与DR-ELM的优劣性,如表2~表4所示。

表2 第1类样本预测结果对比

参数	标准ELM	DR-ELM		
		1承接层	2承接层	3承接层
平均训练时间/s	0.0306	0.1204	0.1435	0.1438
平均泛化时间/s	0.0730	0.4193	0.4814	0.5323
平均训练精度	0.0365	0.0352	0.0358	0.0357
训练精度标准差	0.0002	0.0002	0.0004	0.0003
平均泛化精度	0.0374	0.0344	0.0347	0.0342
泛化精度标准差	0.0024	0.0006	0.0007	0.0008

表3 第10类样本预测结果对比

参数	标准ELM	DR-ELM		
		1承接层	2承接层	3承接层
平均训练时间/s	0.0412	0.1304	0.1641	0.1964
平均泛化时间/s	0.0743	0.4118	0.4602	0.4989
平均训练精度	0.0252	0.0246	0.0246	0.0239
训练精度标准差	0.0002	0.0001	0.0001	0.0002
平均泛化精度	0.0821	0.0266	0.0250	0.0251
泛化精度标准差	0.0278	0.0020	0.0008	0.0007

表4 第11类样本预测结果对比

参数	标准ELM	DR-ELM		
		1承接层	2承接层	3承接层
平均训练时间/s	0.0434	0.1299	0.1355	0.1167
平均泛化时间/s	0.0724	0.5863	0.6521	0.2877
平均训练精度	0.0302	0.0277	0.0279	0.0270
训练精度标准差	0.0001	0.0002	0.0003	0.0002
平均泛化精度	0.2055	0.0685	0.0475	0.0447
泛化精度标准差	0.0812	0.0260	0.0041	0.0039

由表2~表4可以看出,DR-ELM网络的泛化精度和稳定性相对于标准ELM都有显著提高。以第11类为例,对比ELM与一层反馈承接层DR-ELM,DR-ELM的泛化精度提高66.67%左右,稳定性提高67.98%左右;同时对比承接层数目对于不同变量预测效果,增加承接层数后基本可以提高网络泛化精度,如第1类在3层承接层条件下精度最高达到0.0342,但稳定性有所降低,由0.0006增至0.0008;第10类在3层承接层精度对比2层承接层提高6%左

右,提高不明显;第11类在3层承接层条件下预测精度最好,泛化精度达到0.0447。

通过以上实验说明了DR-ELM网络反馈承接层数目的确定,需要根据数据时滞性特征进行调整。由于工业数据的前一时刻数据对当前时刻数据的影响最大,记忆过多历史数据也有可能致预测精度降低,因此网络结构选择需要结合数据特征进行调整。

考虑网络结构及训练时间的关系,本次实验采用1层承接反馈层的DR-ELM神经网络对TE过程所有变量进行预测,在对18类53个变量分别进行50次的预测实验后,将其平均相对误差与平均标准差进行对比,如表5所示。

表5 18类变量数值预测效果比较

序号	相对误差/%/平均标准差/(E-04)			
	ELM		DR-ELM	
	训练阶段	泛化阶段	训练阶段	泛化阶段
1	0.14 / 2	0.14 / 24	0.13 / 5	0.13 / 11
2	0.18 / 2	0.19 / 10	0.17 / 1	0.18 / 1
3	0.21 / 1	0.23 / 10	0.21 / 2	0.22 / 7
4	0.94 / 3	1.52 / 1116	0.92 / 7	1.11 / 156
5	1.22 / 16	2.84 / 42	0.97 / 2	2.32 / 10
6	6.52 / 50	9.2 / 1749	6.06 / 3	5.34 / 878
7	5.37 / 1	5.74 / 90	5.2 / 1	5.52 / 87
8	0.35 / 5	0.35 / 7	0.35 / 1	0.35 / 3
9	0.02 / 1	0.03 / 595	0.01 / 1	0.02 / 4
10	0.48 / 2	0.6 / 278	0.46 / 5	0.49 / 52
11	0.01 / 1	0.01 / 812	0.01 / 2	0.01 / 318
12	0.09 / 3	0.16 / 274	0.09 / 2	0.08 / 269
13	0.22 / 1	0.22 / 36	0.21 / 1	0.21 / 23
14	0.02 / 4	6.56 / 2562	0.02 / 3	2.8 / 899
15	0.02 / 2	4.86 / 7746	0.02 / 2	0.42 / 1013
16	0.03 / 2	10.85 / 1361	0.02 / 3	1.14 / 456
17	0.22 / 1	0.23 / 56	0.21 / 2	0.22 / 42
18	5.54 / 695	1.95 / 1726	1.1 / 23	1.2 / 2015

由表3可知,1层反馈承接层DR-ELM的整体预测效果优于标准ELM的预测输出,变量预测的相对误差和标准差都得到提升,其中第6,7,14,16类变量的标准ELM预测效果较不好,相对误差均超过5%,而DR-ELM网络预测输出效果提高明显,将相对误差减少至5%以内。

3.3 TE过程故障预测

将预测的输出数据分别输入DR-ELM和ELM进行故障预测,图4显示了故障预测的结果,通过预测成功率判断预测效果的优劣性。ELM和DR-ELM的输入结点数为53,输出节点数为21,隐含层结点数为100,选择8种工况,即正常、故障1(A/C物料进

料比例扰动)、故障4(反应器冷却水入口温度)、故障5(冷凝器冷却水入口温度)、故障7(组分C压力下降扰动)、故障12(冷凝器冷却水入口温度)、故障16(未知)和故障17(未知)进行预测比较。由图4可见,DR-ELM预测输出对于故障的预测成功率优于标准ELM预测输出。




图4 故障预测结果比较

实验过程中,DR-ELM模型对TE输入的实时数据进行故障预测,实时对可能发生的故障进行预测。由图4可知,在TE过程故障预测过程中,其精度和稳定性优于标准ELM网络。对比正常工况预测可知,DR-ELM的误报率比ELM低,同时对于故障1、故障4、故障5、故障7的预测,DR-ELM的成功率基本达到90%以上,均优于ELM的预测成功率;而对于故障12、故障16和未知故障17,DR-ELM的成功率虽未到达90%以上,但其预测精度仍优于标准ELM故障预测成功率。

综上实验表明,将本文所提出的DR-ELM网络用于复杂过程工业故障预测可更加有效地优化模型的预测能力,从而提高故障预测的成功率。

4 结 论

故障预测可在故障未发生之前进行预测并及时处理,一般故障预测方法实现难度大,预测精度低,而静态神经网络对于动态系统的故障预测存在无法实时反馈动态性能、预测误差大等问题。对此,本文提出了一种基于动态信息记忆反馈的DR-ELM神经网络用于故障预测。DR-ELM通过反馈承接层动态存储系统历史数据;通过滑动窗口技术提取历史数据的变化特征;通过反馈承接层的动态反馈,调整隐含层的输出,从而提高了模型的预测精度。

仿真研究表明,DR-ELM和ELM的训练泛化速度相当,预测精度和稳定性均优于ELM,较好地适应了工业数据时变特性。将所提出的DR-ELM用于复杂过程工业故障预测,可有效优化模型的预测能力,从而减少故障发生率。

参考文献(References)

- [1] 吉世明. 基于半定量SDG模型的化工过程故障诊断[D].

- 广州: 华南理工大学化学与化工学院, 2012.
- (Ji S M. Based on semi-quantitative SDG model chemical process fault diagnosis[D]. Guangzhou: Chemistry and Chemical Engineering College, South China University of Technology, 2012.)
- [2] 彭宇, 刘大同, 彭喜元. 故障预测与健康管理系统综述[J]. 电子测量与仪器学报, 2010, 24(1): 1-9.
(Peng Y, Liu D T, Peng X Y. A review: Prognostics and health management[J]. J of Electronic Measurement and Instrument, 2010, 24(1): 1-9.)
- [3] Yan A, Wang W, Zhang C, et al. A fault prediction method that uses improved case-based reasoning to continuously predict the status of a shaft furnace[J]. Information Sciences, 2014(259): 269-281.
- [4] Zhou Z, Hu C, Fan H, et al. Fault prediction of the nonlinear systems with uncertainty[J]. Simulation Modelling Practice and Theory, 2008, 16(6): 690-703.
- [5] 艾红, 周东华. 动态系统的故障预测方法[J]. 华中科技大学学报: 自然科学版, 2009, 37(1): 222-225.
(Ai H, Zhou D H. Fault prediction approach for dynamic system[J]. J of Huazhong University of Science & Technology: Natural Science Edition, 2009, 37 (1): 222-225.)
- [6] Zhou Z, Hu C, Fan H, et al. Fault prediction of the nonlinear systems with uncertainty[J]. Simulation Modelling Practice and Theory, 2008, 16(6): 690-703.
- [7] 胡昌华, 张琪, 乔玉坤. 强跟踪粒子滤波算法及其在故障预报中的应用[J]. 自动化学报, 2008, 34(12): 1522-1528.
(Hu C H, Zhang Q, Qiao Y K. A strong tracking particle filter with application to fault prediction[J]. Acta Automatica Sinica, 2008, 34 (12): 1522-1528.)
- [8] 赵辉, 任秀峰, 王红君, 等. 基于灰色理论和神经网络的拉坯阻力状态预测模型研究[J]. 计算机测量与控制, 2012, 20(3): 602-605.
(Zhao H, Ren X F, Wang H J, et al. Research mould friction status prediction model based on grey theory and neural network theory [J]. Computer Measurement & Control, 2012, 20(3): 602-605.)
- [9] 沙成满, 韩合新, 杨冬梅. 基于小波去噪的改进灰色自适应变形预测[J]. 东北大学学报: 自然科学版, 2011, 32(8): 1195-1197.
(Sha C M, Han H X, Yang D M. Deformation forecast using improved self-adaptive grey model based on wavelet denoising[J]. J of Northeastern University: Natural Science Edition, 2011, 32 (8): 1195-1197.)
- [10] Zhang Y, Zhang P. Optimization of nonlinear process based on sequential extreme learning machine[J]. Chemical Engineering Science, 2011, 66(20): 4702-4710.
- [11] 彭荻, 贺彦林, 徐圆, 等. 基于数据特征提取的AANN-ELM研究及化工应用[J]. 化工学报, 2012, 63(9): 2920-2925.
(Peng D, He Y L, Xu Y, et al. Research and chemical application of data feature extraction based AANN-ELM neural network[J]. J of Chemical Industry and Engineering, 2012, 63(9): 2920-2925.)
- [12] 徐圆, 冯晶, 朱群雄. 基于可拓理论的RBF神经网络研究及其应用[J]. 控制与决策, 2011, 26(11): 1721-1725.
(Xu Y, Feng J, Zhu Q X. Research and application of extension theory-based radial basis function neural network[J]. Control and Decision, 2011, 26 (11): 1721-1725.)
- [13] 邓万宇, 郑庆华, 陈琳, 等. 神经网络极速学习方法研究[J]. 计算机学报, 2010, 33(2): 279-287.
(Deng W Y, Zheng Q H, Chen L, et al. Research on extreme learning of neural networks[J]. Chinese J of Computers, 2010, 33(2): 279-287.)
- [14] 李明爱, 阮晓钢. 基于连续Hopfield网络的多变量时变系统最优控制[J]. 控制与决策, 2005, 20(9): 1038-1044.
(Li M A, Ruan X G. Continuous Hopfield neural network based optimal control for multivariable time-varying systems[J]. Control and Decision, 2005, 20(9): 1038-1044.)
- [15] 王章利, 谭永红. 基于改进动态递归神经网络的发酵过程pH值辨识[J]. 控制工程, 2009, 16(2): 84-86.
(Wang Z L, Tan Y H. pH modeling of fermentation process based on improved dynamic recurrent neural networks[J]. Control Engineering of China, 2009, 16(2): 84-86.)
- [16] 高慧慧, 贺彦林, 彭荻, 等. 基于数据属性划分的递阶ELM研究及化工应用[J]. 化工学报, 2013, 64(12): 4348-4353.
(Gao H H, He Y L, Peng D, et al. Research and chemical application of data attributes decomposition based hierarchical ELM Neural network[J]. J of Chemical Industry and Engineering, 2013, 64 (12): 4348-4353.)

(责任编辑: 滕蓉)