

神经网络的压力容器评估系统设计

吕兵, 王华珍, 潘孝铭

(华侨大学 计算机科学与技术学院, 福建 厦门 361021)

摘要: 为解决长周期压力容器设备安全评估的低效率、低可靠性和不能人机交互等问题,利用开源的 R 语言设计复杂的神经网络识别算法,并通过 C#.NET 设计出一套界面友好的压力容器评估系统.实验结果表明:创建的压力容器评估系统嵌入 BP 神经网络算法,能精确刻画压力容器参数与状态之间的复杂非线性关系,评估准确率高;同时,软件系统实现了评估过程的交互性和自动化,具有良好的用户体验和很强的实践性.

关键词: 压力容器;评估;人工神经网络;混合编程

中图分类号: TP 183

文献标志码: A

压力容器广泛应用于石油化工、能源、机械和冶金等领域,其内部或外部承受气体或液体压力,对安全性有较高的要求.如何及时有效地对长周期压力容器设备进行安全评估,保证压力容器设备可靠地使用,已成为工业生产的迫切要求.传统的评估方法通过人工对检测到的参数值,按照阈值水平等规范进行简单运算.其工作量大且需要检验人员专家经验知识指导,受人为因素的影响较大,一般无法综合考虑多种因素之间的相互作用,因此,无法正确刻画压力容器多种因素与安全状态之间的非线性关系.目前,压力容器缺陷的安全评定出现了一些新的技术方法^[1].如基于模糊理论的评定技术^[2]对压力容器结构存在大量的不确定性,采用模糊数学方法进行处理;专家系统技术^[3]基于事例的推理算法归纳出若干条输入因素与输出安全性能之间的规则,从而进行评估;采用概率断裂力学的评定技术^[4]将概率统计理论与确定性断裂力学理论相结合;基于人工神经网络的评定技术^[5-6]利用机器学习(ML)技术从高维、海量的数据中自动地学习到容器参数和安全性之间蕴含的复杂非线性关系,无限逼近地挖掘到输入与输出之间的关系.本文利用机器学习技术设计压力容器安全性智能评估算法,使其高效地刻画出压力容器安全性评估模式;同时研究生产实践中常用的 C#.NET 平台与智能算法编写工具 R 语言的混合编程技术,开发出简单、易用的软件界面.

1 系统总体设计

在实际应用中,比较典型的机器学习算法有人工神经网络(ANN)^[7]、支持向量机(SVM)^[8]、集成学习^[9]等.在智能算法选择方面采用 ANN 算法.在软件系统设计方面,采用 C#.NET 技术构建用户交互界面,并使用 R 语言来编写 ANN 算法程序嵌入其中.在 R 和 C#.NET 的调用连接方面,采用 Stat-ConnDCOM 接口软件来实现二者的混合编程(<http://rcom.univie.ac.at/>).这种 COM(组件对象模型)组件相当于 C#与 R 间交互的媒介或数据转换器,使数据能很好的在 2 种平台之间实现互相通信.

PVES 系统的技术原理,如图 1 所示. PVES 的工作流程为:1) 现场采集数据,构建完整、详实的压力容器数据库,数据库中的数据集在机器学习领域称为样本集,该数据库可实现数据的增加、删除、查询、修改和统计等基本功能;2) 使用 ANN 算法从数据库中的样本集中学习出 ANN 智能评估模型,这一过程实现了评估系统的自学习、自适应;3) 当采集到新的待评估的压力容器的一系列参数,将这些参数值输入到 ANN 模型中,由模型推断出压力容器的安全性(安全或不安全).这一过程实现了系统的自

收稿日期: 2013-09-26

通信作者: 王华珍(1975-),女,讲师,主要从事机器学习、模式识别的研究. E-mail: wanghuazhen@hqu.edu.cn.

基金项目: 福建省自然科学基金资助项目(2012J01274);华侨大学高层次人才科研项目(09BS515)

动、智能评估. 本系统的开发环境包括: .NET 4.0 框架平台; Visual Studio 2010 开发工具; R 3.0.0 软件平台; statconnDCOM 3.5 组件; Microsoft Access 2010 数据库.

2 建模与混合编程相关技术研究

2.1 人工神经网络模型的建立

人工神经网络 ANN 是由大量并行运算的处理单元即神经元互联组成的复杂网络结构, 能够对信息进行分布存储, 以及对输入输出关系进行无限逼近拟合. 迄今为止, 具有代表性的 ANN 网络模型有感知器及多层感知器、BP 网络、RBF 网络、Hopfield 网络、SOM 模型等^[10]. 文中需要对压力容器的安全性(安全或不安全)进行评估, 其本质是分类过程. 在以上 ANN 模型中能够完成分类任务的是多层感知器(MLP)、误差反向传播神经网络(BP)以及径向基函数神经网络(RBF). MLP 是感知器的推广, 解决了感知器不能对线性不可分数据进行识别的问题, 其学习函数常用 SCG 算法^[11].

以 3 层结构 BP 神经网络为例, 论述 ANN 的学习和建模过程. BP 神经网络由输入层、隐含层和输出层组成, 其结构如图 2 所示, 具体的学习和建模流程分为以下 4 个过程.

1) 模式顺传播. 输入模式(数据)由输入层经过隐含层向输出层逐层传播的过程. 输入层只是简单将接收到的输入模式作为输出模式传递给隐含层, 隐含层各个神经元的净输入和输出为

$$b_j^k = f(\sum_{i=1}^n w_{i,j} x_i^k - \theta_j), \quad j = 1, 2, \dots, p. \quad (1)$$

输出层各个神经元的净输入和实际输出计算式为

$$c_t^k = f(\sum_{j=1}^p v_{j,t} b_j^k - \gamma_t), \quad t = 1, 2, \dots, q. \quad (2)$$

式(1)~(2)中: 中间层采用 S 型激活函数, 输出层采用线性激活函数.

2) 误差逆传播. 误差信号(网络的期望输出与实际输出之差)由输出层经隐含层向输入层逐层修正连接权值的过程. 输出层和隐含层的各个神经元的校正误差分别为

$$d_t^k = (y_t^k - c_t^k) f'(\sum_{j=1}^p v_{j,t} b_j^k - \gamma_t), \quad t = 1, 2, \dots, q, \quad (3)$$

$$e_j^k = [\sum_{t=1}^q v_{j,t} d_t^k] f'(\sum_{i=1}^n w_{i,j} x_i^k - \theta_j), \quad j = 1, 2, \dots, p. \quad (4)$$

修正隐含层至输出层的连接权值 V 和输出层神经元的阈值 γ , 即

$$\Delta v_{j,t} = \alpha d_t^k b_j^k, \quad j = 1, 2, \dots, p, \quad t = 1, 2, \dots, q, \quad (5)$$

$$\Delta \gamma_t = \alpha d_t^k, \quad t = 1, 2, \dots, q. \quad (6)$$

修正输入层至隐含层的连接权值 W 和隐含层神经元的阈值 θ , 即

$$\Delta w_{i,j} = \beta e_j^k x_i^k, \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, p, \quad (7)$$

$$\Delta \theta_j = \beta e_j^k, \quad j = 1, 2, \dots, p. \quad (8)$$

3) 记忆训练. 随机一定量的学习模式对提供给网络, 由前两个过程反复交替进行网络训练.

4) 学习收敛. 判断网络全局误差 E 是否满足精度要求, 即 $E \leq \epsilon$.

2.2 R 语言与 C#.NET 混合编程

R 语言是一套完整的数据处理、计算和绘图系统, 是一个自由、免费、开源的软件. 而 C#.NET 是针对 .NET 平台而设计的, 利用 C#.NET 开发的系统软件能有效脱离编程环境运行. 但 .NET 框架平台缺少统计学、机器学习(尤其是人工神经网络)方面的类库. 如果独立开发, 会使软件开发周期加长, 并

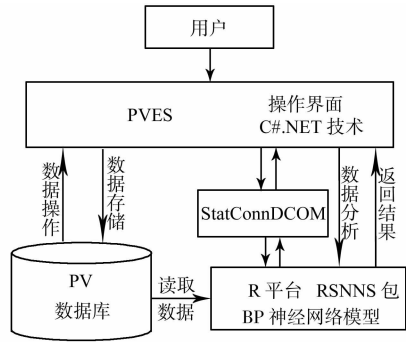


图 1 R 与 C#.NET 混合编程技术图
Fig. 1 Technical chart of R and C#.NET mixed programming

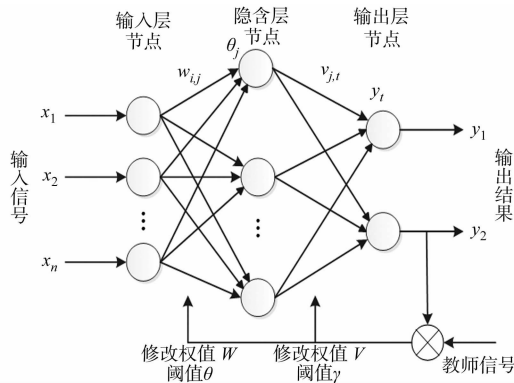


图 2 BP 网络模型的基本结构
Fig. 2 Basic Structure of BP network model

且, NET 在数据分析和作图功能上表现并不突出,无法满足数据挖掘方面的应用.

将 R 与 C#. NET 混合编程协同工作,能够实现优势互补,既可以利用人工神经网络模型对长周期压力容器进行有效地分析建模,又可以利用友好操作界面来提高压力容器安全性评估的实用性. 但是, 由于两者的混合编程受到 R 版本和相应的. NET 动态链接库的支持包 rscproxy 的兼容性等限制,这给混合编程技术研究带来很大的困难. 目前研究 R 和 C#. NET 的混合编程的工作非常少,只有赵毅等^[12]尝试将 R 与. NET 混合编程实现其在重质油数据管理分析中的应用. 文中针对压力容器这个特定领域,开发基于 R 语言环境和 C#. NET 混合编程的智能评估系统,具有理论和实践的迫切性.

3 实验与分析

3.1 数据与实验设置

针对具体项目中的压力容器的常见缺陷,即安全状态进行建模和评定. 这些典型缺陷分为体积型缺陷和面型缺陷,其中面型缺陷又主要分为纵环焊缝裂纹缺陷和接管角焊缝裂纹缺陷两种. 针对这 3 种不同的安全性问题,其所关联的特征集(容器参数等)略有差异. 因此,PVES 系统将针对这医药个缺陷(安全评估)问题分别构建 3 种不同的智能评估模型,即体积型缺陷评估模型,纵环焊缝裂纹评估模型和接管角裂纹评估模型. 这 3 种模型所对应的参数集、样本集情况,如表 1 所示. 其中:安全性能(数据所对应的类别)分为“安全”和“不安全”两类.

表 1 样本集介绍
Tab. 1 Information of sample sets

样本信息		参数(特征)分布情况			特征总数	样本数	类别数
缺陷类型		材料参数	应力参数(模型尺寸)	缺陷参数(缺陷尺寸)			
体积型缺陷		材质	凹坑所在部位计算厚度,平均半径,工作压力	凹坑长轴长度一半,凹坑短轴长度一半,凹坑深度	7	1 458	2
面型缺陷	纵环焊缝裂纹	材质	筒体直径,筒体长度,筒体壁厚,封头壁厚,工作压力	焊缝位置,裂纹短轴长度一半,裂纹长轴长度一半,错边量,角变形	11	13 474	2
	接管角焊缝裂纹	材质	筒体直径,筒体长度,筒体壁厚,接管壁厚,接管内径,工作压力	圆形裂纹半径	8	1 672	2

以上个模型对应的样本集具有多参数、混合特征(即同时存在连续和离散型特征)等特点. 对表 1 中 3 个样本集分别随机选择其中的 70%作为训练集,剩下的 30%作为测试集. 在训练集上采用十重交叉验证对参数进行网格搜索,以得到最优的 ANN 模型.

R 语言的 RSNNS 软件包能够同时实现 MLP,BP 和 RBF 算法并且提供了详细的参数调整方案. 这 3 种算法共同的参数设置是:1) 输入层节点数,其数量等于特征的个数;2) 输出层神经元个数为 2 个,对应最终评估结果为“安全”和“不安全”两种情况. 此外,3 种算法还有各自特定的参数,如 BP 网络的隐含层神经元个数根据经验公式: $h=\sqrt{n+t}+a,1\leq a\leq 10$,其中: h 为隐含层节点数; n 为输入层节点数; t 为输出层节点数. 经过参数优化过程,得到 3 种最优网络模型对应的参数值,如表 2 所示.

表 2 3 种网络模型最优参数
Tab. 2 Optimal parameters of three network models

名称	输入层节点数	隐含层节点数	输出层节点数	迭代次数
		MLP/BP/RBF		MLP/BP/RBF
体积型缺陷	7	10/8/15	2	150/100/100
纵环焊缝裂纹	11	13/14/34	2	240/200/200
接管角焊缝裂纹	8	10/11/15	2	120/100/100

3.2 实验结果

对体积型缺陷样本集、纵环焊缝裂纹样本集和接管角焊缝裂纹样本集分别进行学习建模,每个模型分别采用 3 种 ANN 算法实现,实验重复 20 次,得到 3 种 ANN 算法的平均运行时间(t)和测试集平均预测准确率(η),如表 3 所示(下划线数字为性能最优结果).

表 3 MLP,BP 网络和 RBF 网络性能比较

Tab. 3 Properties comparison of MLP, BP network and RBF network

性能	安全评估模型	MLP 模型	BP 网络	RBF 网络
t/s	体积型缺陷	4.43	3.23	4.29
	纵环焊缝裂纹	29.60	19.97	21.27
	接管角焊缝裂纹	6.74	3.46	4.03
	体积型缺陷	98.80	99.31	95.30
$\eta/\%$	纵环焊缝裂纹	96.76	99.46	90.77
	接管角焊缝裂纹	99.16	99.20	93.10

通过 3 种 ANN 算法的性能比较可知:BP 算法的运行时间最快,其次是 RBF 网络,而 MLP 所需的迭代次数最多,在网络训练中运行时间最长.在测试集的预测准确率上,BP 网络最高,MLP 同样很高,但 RBF 网络预测效果明显要差许多.因此,在具体的 PVES 构建中选择 BP 网络作为内嵌智能算法.

3.3 系统实现

PVES 实现了 3 种不同的安全评估模型,软件界面如图 3 所示.图 3 中,在菜单栏显示了 PVES 的主要功能模块:安全评估模块、材料性能参数数据库模块、分类应力参数数据库模块和缺陷复合参数数据库模块等.其中:后面 3 个模块是压力容器相关参数的数据库管理模块,用于存储和管理压力容器的参数数据,其功能对应于机器学习领域中的训练数据集构建.而安全评估模块是系统的核心模块,主要完成从压力容器训练数据集学习出智能评估模型.安全评估模块上方有体积型缺陷评估、纵环焊缝裂纹评估和接管角裂纹评估 3 个交互界面,每个界面针对特定问题有不同的参数输入和结果输出.这里以体积型缺陷(安全性)评估模型为例,展示其在 PVES 中的使用流程和关键技术的实现.



图 3 PVES 主界面

Fig. 3 Main interface of PVES

在工业环境中实际使用时,用户在界面上输入体积型缺陷辨识模型相应的 7 个特征参数值后,PVES 通过 COM 构件启动和调用 R 程序,R 系统将从数据库中调用历史样本数据集进行特定的 BP 网络模型构建.R 同时绘制其建模过程的拟合错误率曲线图并显示于程序操作界面,随着迭代次数的增加训练误差逐渐减小,最终达到指定的误差下限,表明判别模型构建完成.接下来用户点击“评估”按钮,则用户输入的参数将送入判别模型中推理,PVES 根据 R 的分析结果来给出评估结果,即安全或不安全.用户可将本次评估数据使用“保存”按钮添加至相应数据库,或使用“重置”按钮进行下一轮的数据评估.PVES 对测试数据进行评估的结果,如表 4 所示(限于篇幅,只列出 10 组数据进行对比).

表 4 PVES 评估结果

Tab. 4 Evaluated results of PVES

序号	特征参数集							真实状态	评估结果
	材质	凹坑所在部位 容器计算厚度	平均半径	工作压力	凹坑长轴 长度一半	凹坑短轴 长度一半	凹坑深度		
1	Q235B	6	400	1.30	40	45	3.0	安全	安全
2	Q345R	6	500	1.77	30	90	2.0	安全	安全
3	Q245R	8	400	2.00	50	75	3.0	安全	安全
4	Q235B	6	600	1.57	50	135	1.0	不安全	不安全
5	Q245R	10	1 000	2.00	30	150	2.5	不安全	不安全
6	Q235B	14	1 600	2.00	130	105	0.5	不安全	不安全
7	Q345R	14	1 600	1.77	85	30	3.5	不安全	不安全
8	Q345R	8	900	1.30	50	150	0.5	安全	安全
9	Q235B	10	600	1.57	10	45	0.5	安全	安全
10	Q245R	12	1 300	1.30	70	90	2.5	安全	安全

运行结果表明:PVES 运用 BP 网络模型对压力容器的检测结果和测试样本集的真实类别基本一致,表明 PVES 能够有效地对长周期压力容器进行安全评估.

4 结 束 语

研究智能算法编写工具 R 语言与生产实践中常用的 C#.NET 技术的混合编程技术,构建长周期压力容器智能评估软件系统 PVSE. 该软件系统充分结合了 BP 神经网络智能算法和 C#.NET 软件工程两者强大的功能和优势,使得高端的智能算法能够嵌入到实际的工业流程中. 实验结果表明:采用 BP 神经网络智能算法可以综合考虑压力容器多种因素之间的相互作用,正确刻画压力容器多因素与安全状态之间的非线性关系. 同时,利用界面交互操作使得压力容器评估工作简单易用,具有良好的用户体验. 接下来的工作将考虑综合运用多种评估方法来进行补充、完善和校验长周期压力容器评估系统.

参 考 文 献:

[1] 韩毅,淡勇,李小勇,等. 含缺陷压力容器安全评定的发展历程与趋势[J]. 石油化工设备技术,2012,33(4):47-50, 71.

[2] 龙伟,杜仕冲,余进. 基于含缺陷在役压力容器的模糊评定[J]. 四川大学学报:工程科学版,2007,39(1):166-170.

[3] 戴树和. 化工装置在线检查诊断中的非精确性推理[J]. 化工学报,1994,45(2):141-146.

[4] 陈国华. 含缺陷压力容器失效概率分析方法初步研究[J]. 化工机械,1996,23(4):42-45,63.

[5] 俞树荣,李尔国,贾立. 基于人工神经网络的压力容器初级评定方法[J]. 化工机械,1999,26(3):54-56,64.

[6] 俞树荣,李尔国,贾立. 人工神经网络与失效评定图在压力容器安全评定中的应用[J]. 化工机械,1999,26(5):280-283,301.

[7] HAYKIN S. Neural networks and learning machines[M]. New York:Prentice Hall,2009:122-154.

[8] GUYON I, WESTON J, BARNHILL S, et al. Gene selection for cancer classification using support vector machines [J]. Machine Learning,2002,46(1/2/3):389-422.

[9] DIETTERICH T G. Ensemble methods in machine learning[M]. Springer:Berlin Heidelberg,2000:1-15.

[10] 马锐. 人工神经网络原理[M]. 北京:机械工业出版社,2010:45-49.

[11] MØLLER M F. A scaled conjugate gradient algorithm for fast supervised learning[J]. Neural Networks,1993,6(4):525-533.

[12] 赵毅,史权,赵镇奇,等. R 语言与 .NET 混合编程在重质油数据管理分析中的应用[J]. 计算机与应用化学,2012, 29(4):491-494.

Design of Pressure Vessel Evaluation System Based on Artificial Neural Networks

LYU Bing, WANG Hua-zhen, PAN Xiao-ming

(College of Computer Science and Technology, Huaqiao University, Xiamen 361021, China)

Abstract: To address the problems of low efficiency, low reliability, without human-computer interaction in the safety evaluation of the long-periodic pressure vessel, an intelligent evaluation system based on artificial neural network algorithm is established. In which the open source R language is used to design the complex neural network intelligent algorithm and a user-friendly operating system is developed through C#.NET technology. The experimental results show that the pressure vessel evaluation system embedded BP neural network algorithm can precisely figure out the complex nonlinear relationship between the parameters and the state of pressure vessel by significantly high accuracy. Meanwhile, the software system promotes the interactivity and automation of the evaluation process, which gives good user experience and strong practicality.

Keywords: pressure vessel; evaluation; artificial neural networks; mixed programming