

基于SVM的老年痴呆症智能诊断研究

张会敏, 胡 太

(南京师范大学计算机科学与技术学院, 江苏 南京 210023)

[摘要] 为了验证支持向量机(SVM)更适用于基于血常规数据的老年痴呆症的预测诊断,通过仿真实验,将BP神经网络、RBF神经网络、SVM支持向量机分别应用于老年痴呆症的预测诊断,建立3种算法对应的诊断模型,并对3种模型的预测结果进行分析比较,仿真实验在Matlab软件平台上进行。结果表明,与BP、RBF神经网络方法相比,SVM模型预测准确度高,建模时间短,整体性能好,更适用于基于血常规数据的老年痴呆症预测诊断,实际应用时可以此结论作为理论指导。

[关键词] 支持向量机, BP神经网络, RBF神经网络, 老年痴呆症预测, 数据挖掘

[中图分类号] TP18 **[文献标志码]** A **[文章编号]** 1672-1292(2016)02-0086-07

A Study on Intelligent Diagnosis of Senile Dementia Based on SVM

Zhang Huimin, Hu Tai

(School of Computer Science and Technology, Nanjing Normal University, Nanjing 210023, China)

Abstract: In order to verify that the support vector machine(SVM) is more suitable for predicting diagnosis based on the data of blood routine examination of Alzheimer's disease, through the simulation experiment, BP neural network, RBF neural network, SVM support vector machine(SVM) are applied to predict the diagnosis of Alzheimer's disease. Three diagnostic models are established, and the prediction results of the three models are analyzed and compared. The simulation experiments are carried out on the platform of Matlab software, the results show that compared with BP, RBF neural network method, SVM model with high predictive accuracy, short modeling time, good overall performance is more suitable for prediction diagnosis based on the data of blood routine examination of Alzheimer's disease. This conclusion can be used as a theoretical guide in the practical application.

Key words: support vector machine, BP neural network, RBF neural network, dementia disease prediction, data mining

21世纪,我国迅速进入了老龄化社会,老年疾病突发,其中老年痴呆症^[1]患者数量急剧增长。针对老年痴呆症的诊断方法主要包括两类:一类是传统描述性测试的方法,如MoCA量表、NIHSS量表、CDR量表等;另一类是现代影像技术,如CT、核磁共振成像(MRI)等。但这两种诊断方法多存在不足^[2],传统量表方法干扰因素多、难以定性,现代影像技术价格高、非大众化,鉴于以上状况,需要提出更为有效的智能化的老年痴呆症诊断方法。

近年来,医疗改革使医院管理走上信息化的道路,医院的电子病历取代了传统的纸质病历,存储了大量的病人医疗诊断数据,从这些大量的数据中挖掘出潜在的有用信息,为疾病的诊疗提供有效的临床决策支持,成为近年来医疗信息挖掘的热点^[2]。目前,人工神经网络和支持向量机等算法在医学领域开始获得广泛的应用^[3-4],许多学者利用患者脑图像特征数据在这一领域进行研究,建立了诸如单一或多模态的分类模型^[5-6],这些模型取得了很好的分类诊断效果。但是MRI数据量相对较少。本文则致力于利用更为常见的血常规数据进行预测诊断,将BP神经网络、RBF神经网络、SVM支持向量机分别应用于老年痴呆症的预测诊断,在Matlab软件平台上建立上述3种预测诊断模型并进行仿真实验测试,然后对3种模型的预测结果准确度、运行时间等性能进行分析比较,找出一种更有效的老年痴呆症智能预测诊断方法。

收稿日期:2016-03-25.

基金项目:2013年国家级大学生创新训练项目(201310368027)、2013年省级大学生创新训练项目(AH201310368027)。

通讯联系人:张会敏,硕士研究生,研究方向:数据库与数据挖掘。E-mail:1403451539@qq.com

1 BP神经网络与RBF神经网络

1.1 BP神经网络

BP(back propagation, BP)神经网络是一种采用误差反向传播学习算法训练的多层感知机模,能在不确定映射关系的情况下,进行大量输入-输出模式的学习和存储. BP网络的拓扑结构由输入层、隐含层和输出层组成,层间神经元采用全连接的方式,而层内神经元之间无连接,如图1所示.

BP神经网络算法步骤如下^[7-8]:

Step 1 网络权值和阈值初始化,根据系统输入输出序列 (\mathbf{x}, \mathbf{y}) 确定输入层节点数 n 、隐含层节点数 l 和输出层节点数 m ,初始化输入层、隐含层和输出层神经元之间的连接权值 w_{ij} 和 w_{jk} ,初始化隐含层阈值 \mathbf{a} 、输出层阈值 \mathbf{b} 、给定学习速率 η 和神经元激励函数 f ;

Step 2 计算隐含层输出,根据输入向量 \mathbf{x} ,输入层与隐含层之间连接权值 w_{ij} 以及隐含层的阈值 \mathbf{a} ,计算隐含层输出值 \mathbf{h} :

$$h_j = f\left(\sum_{i=1}^n w_{ij} x_i - a_j\right) \quad (j = 1, 2, \dots, l), \quad (1)$$

式中, l 为隐含层节点数; f 为隐含层激励函数; x_i 为 \mathbf{x} 的第 i 个分量; h_j 为 \mathbf{h} 的第 j 个分量; a_j 为 \mathbf{a} 的第 j 个分量; w_{ij} 为输入层第 i 个节点与隐含层第 j 个节点的连接权值;

Step 3 计算输出层输出,根据隐含层输出 \mathbf{h} ,连接权值 w_{jk} 和阈值 \mathbf{b} ,计算BP网络预测输出 \mathbf{o} :

$$o_k = \sum_{j=1}^l h_j w_{jk} - b_k \quad (k = 1, 2, \dots, m), \quad (2)$$

式中, b_k 为 \mathbf{b} 的第 k 个分量, o_k 为 \mathbf{o} 的第 k 个分量;

Step 4 计算各隐含层和输出层误差,根据网络预测输出 \mathbf{o} 和期望输出 \mathbf{y} ,计算网络预测误差 \mathbf{e} :

$$e_k = y_k - o_k \quad (k = 1, 2, \dots, m), \quad (3)$$

式中, e_k 为 \mathbf{e} 的第 k 个分量;

Step 5 更新各层之间连接权值,根据网络预测误差 \mathbf{e} 更新网络层之间连接的权值 w_{ij} 和 w_{jk} :

$$w_{ij} = w_{ij} + \eta h_j (1 - h_j) x_i \sum_{k=1}^m w_{jk} e_k, \quad (4)$$

$$w_{jk} = w_{jk} + \eta h_j e_k, \quad (5)$$

式中, η 为学习速率;

Step 6 更新各层神经元阈值,根据网络预测误差 \mathbf{e} 更新网络神经元节点阈值 \mathbf{a} 和 \mathbf{b} :

$$a_j = a_j + \eta h_j (1 - h_j) \sum_{k=1}^m w_{jk} e_k \quad (j = 1, 2, \dots, l), \quad (6)$$

$$b_k = b_k + e_k \quad (k = 1, 2, \dots, m); \quad (7)$$

Step 7 检查判断算法是否满足迭代终止条件:最大迭代次数或网络最小误差,若满足终止条件则迭代结束,若不满足,则返回Step 2.

1.2 RBF神经网络

RBF(radial basis function, RBF)神经网络采用的激活函数是径向基函数,其取值仅仅依赖于距离原点的距离,一般采用欧氏距离. 该网络从输入层到输出层的变换是非线性的,而隐含层到输出层的变换却是线性的,因此该网络模型的学习速度较快,且能避免出现局部极小现象,逼近任意非线性函数,可发现样本数据内难以解析的规律性,因此具有最佳逼近以及全局最优的特点,非常适用于解决一些分类问




图1 三层BP神经网络拓扑结构

Fig.1 Three layer BP neural network topology

题. RBF神经网络的拓扑结构包括输入层、隐含层和输出层3层,如图2所示.

RBF网络算法有3个主要的参数需要求解^[7]:基函数的中心、方差以及隐含层到输出层的权值. 高斯函数是应用广泛的径向基函数,此时RBF网络的激活函数可用下式表示:

$$R(\mathbf{x}_p - \mathbf{c}_i) = \exp\left\{-\frac{1}{2\sigma^2}\|\mathbf{x}_p - \mathbf{c}_i\|^2\right\}, \quad (8)$$

式中, \mathbf{c}_i 为高斯函数的中心; σ 为函数的方差; $\|\mathbf{x}_p - \mathbf{c}_i\|$ 为欧式范数.

RBF网络的输出公式为:

$$y_j = \sum_{i=1}^l w_{ij} \exp\left\{-\frac{1}{2\sigma^2}\|\mathbf{x}_p - \mathbf{c}_i\|^2\right\}, \quad (9)$$

式中, \mathbf{x}_p 表示第 p 个输入样本; \mathbf{c}_i 为网络隐含层神经元的数据中心; w_{ij} 为隐含层至输出层连接的权值; $i=1, 2, \dots, l$ 表示隐含层的节点数; y_j 为与输入样本对应的第 j 个输出神经元的实际输出值.

RBF神经网络算法步骤(基于K-均值聚类方法求基函数中心)^[7-9]如下:

Step 1 初始化网络,随机选取 h 个训练样本作为网络的聚类中心 $\mathbf{c}_i (i=1, 2, \dots, h)$;

Step 2 根据 \mathbf{x}_p 与聚类中心 \mathbf{c}_i 间的欧氏距离,采用最近邻原则,将输入样本 \mathbf{x}_p 分配到各个聚类域 $\phi_p (p=1, 2, \dots, P)$ 中;

Step 3 计算各个聚类域 ϕ_p 中训练样本的平均值,作为新的聚类中心 \mathbf{c}_i ,若 \mathbf{c}_i 未发生变化,则所得的 \mathbf{c}_i 即为RBF神经网络最终的基函数中心,否则返回Step 1;

Step 4 求解方差 σ_i :

$$\sigma_i = \frac{c_{\max}}{\sqrt{2h}} \quad (i=1, 2, \dots, h), \quad (10)$$

式中, c_{\max} 为聚类中心之间的最大距离;

Step 5 用最小二乘法计算隐含层到输出节点的连接权值:

$$w = \exp\left\{\frac{h}{c_{\max}^2} \|\mathbf{x}_p - \mathbf{c}_i\|^2\right\} \quad (p=1, 2, \dots, P; i=1, 2, \dots, h). \quad (11)$$

2 支持向量机

支持向量机(support vector machine, SVM)由Cortse和Vapnik于1995年首先提出,是根据统计学习理论中结构风险最小化的归纳原则提出的一种解决非线性、小样本及高维模式识别问题的机器学习方法,能够在有限的样本信息基础上寻求学习能力与模型复杂性的最佳折中,使其获得较好的泛化能力.

支持向量机的基本思想^[10]可用如图3所示的二维情况来说明. 图中圆点和方形点分别代表两类样本, H 为分类线, H_1 、 H_2 是平行于 H 且分别过两类样本离 H 最近的直线, H_1 与 H_2 之间的距离称为分类间隔(Margin),支持向量机学习的目标是构造一个可以将数据最大限度正确分类的超平面,使得分类间隔最大.

对于训练样本集 $\{(\mathbf{x}_i, y_i) | \mathbf{x}_i \in \mathbf{R}^n, y_i \in \mathbf{R}, i=1, 2, \dots, l\}$, 其 \mathbf{x}_i 表示样本属性值向量, y_i 表示类别值,且 $y_i \in \{1, -1\}$, 假设超平面方程为 $\mathbf{w} \cdot \mathbf{x} + b = 0$, 则 $\text{Margin} = 2/\|\mathbf{w}\|$, 由此,最大间隔目标可以转化为:

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l \xi_i, \quad (12)$$

$$\text{s.t. } y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i=1, 2, \dots, l.$$

式中, C 为惩罚因子,表示对错误分类的惩罚大小, C 越大惩罚力度越大; ξ_i 为松弛变量.




图2 RBF神经网络拓扑结构

Fig.2 RBF neural network topology




图3 最优超平面示意图

Fig.3 Schematic diagram of optimal hyper plane

利用 Lagrange 优化算法将上述问题转化为相应的对偶问题:

$$\begin{aligned} \max_{w,b} \quad & \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j x_i x_j K(x_i, x_j), \\ \text{s.t.} \quad & \sum_{i=1}^l y_i \alpha_i = 0, \quad 0 < \alpha_i < C, \quad i = 1, 2, \dots, l. \end{aligned} \quad (13)$$

式中, $K(x_i, x_j)$ 表示核函数, 用于将非线性训练样本映射到一个高维的线性空间中去, 从而使非线性问题转化为高维线性问题, 常用核函数包括:

线性核函数:

$$K(x_i, x_j) = x_i^T x_j; \quad (14)$$

多项式核函数:

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^p, \quad \gamma > 0; \quad (15)$$

径向基核函数:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \quad \gamma > 0; \quad (16)$$

Sigmoid 核函数:

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r); \quad (17)$$

式中, γ 与 r 为核参数.

最终得到的最优分类函数为:

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^l y_i \alpha_i^* K(x_i, x) + b^* \right\}. \quad (18)$$

3 仿真实验

为了验证 SVM 支持向量机比 BP、RBF 神经网络更适用于老年痴呆症的预测诊断, 在 Matlab R2010a 环境下, 利用神经网络工具箱和 LIBSVM 工具箱建立 3 种预测诊断模型^[3, 11-13]: (1) BP 神经网络的老年痴呆症诊断预测模型; (2) RBF 神经网络的老年痴呆症诊断预测模型; (3) SVM 支持向量机的老年痴呆症诊断预测模型, 以收集的电子病历数据中患者血常规生理指标作为模型输入, 分类诊断结果作为输出 (对诊断结果进行编码, 用“-1”表示诊断结果为非老年痴呆症, 用“1”表示诊断结果为老年痴呆症).

实验样本为 141 例从某大型医院电子病历系统中收集的患者血常规数据 (其中, 老年痴呆症患者样本 86 例, 非老年痴呆症患者样本 55 例), 每一例样本数据中都包含了患者 29 项血常规生理指标, 将这 141 例样本中的 90 例作为 3 种模型的训练数据本 (其中, 老年痴呆症患者数据 54 例, 非老年痴呆症患者数据 36 例), 另外的 51 例样本则作为模型的测试数据 (其中, 老年痴呆症患者数据 32 例, 非老年痴呆症患者数据 19 例).

首先, 利用 Matlab 神经网络工具箱中的 newff() 函数建立 29-15-1 的 3 层 BP 网络老年痴呆症诊断预测模型^[3]: (1) 取血常规中 29 项生理指标为初始输入变量, 即输入层为 29 个神经元; (2) 选取隐含层神经元数, 采用综合比较法确定隐含层为 15 个神经元; (3) 输出层用 1 个神经元输出老年痴呆症的诊断结果. 实验中隐含层与输出层的传递函数分别设置为 tansig 和 purelin, 训练函数设置为 trainlm. 模型的最大迭代次数设置为 1 000, 最小误差设置为 0.001, 学习率设置为 0.1, 其余参数采用默认值. 利用训练数据对 BP 网络进行模型学习, 用测试数据对学习获得的模型进行测试, 并记录预测效果. BP 模型分类测试结果如图 4 所示.

其次, 利用 newrb() 函数建立 RBF 神经网络网络老年痴呆症诊断预测模型^[11]. 实验中通过调整最大误差样

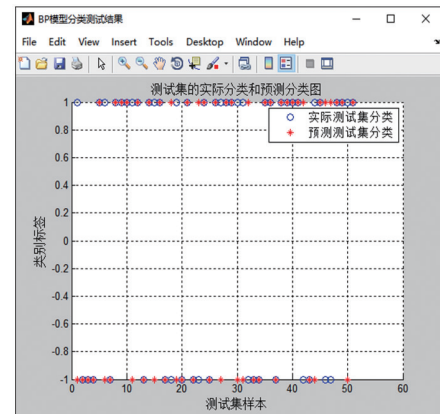


图4 BP模型分类测试结果

Fig.4 BP model classification test results

本,不断增加该 RBF 网络模型的神经元个数,直到误差达到规定的误差性能,神经元个数达到最大.训练精度同样设置为 0.001,径向基函数的扩展速度设置为 1.0,最大神经元的个数设置为 Q ,两次显示之间添加神经元的个数设置为 25. 同样对 RBF 网络进行训练学习和测试,并记录测试结果,RBF 模型的分测试结果如图 5 所示.

最后,利用 LIBSVM 支持向量机工具箱中 svmtrain()函数建立 SVM 支持向量机的老年痴呆症诊断预测模型,本文中参数“-s”设为 0(即 SVM 类型为 C-SVC),参数“-t”设置为 2(即核函数设置为径向基函数),其他参数采用默认值,然后通过 svmpredict()函数利用测试数据对模型进行测试,记录测试结果,如图 6 所示.

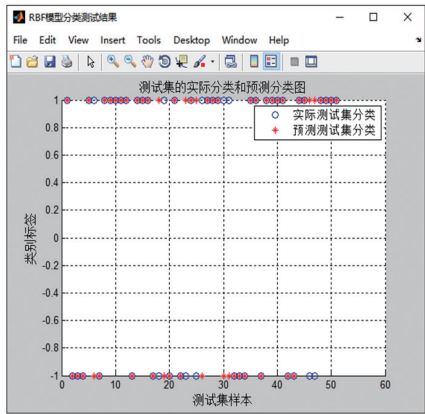


图5 RBF 模型分类测试结果

Fig.5 RBF model classification test results

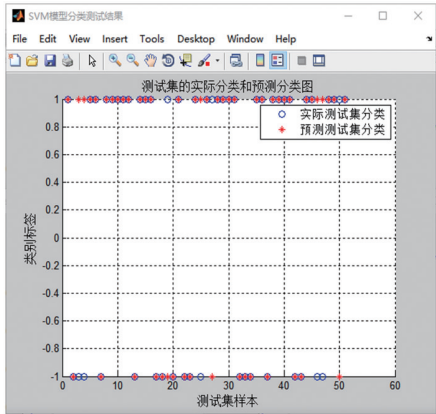


图6 SVM 模型分类测试结果

Fig.6 SVM model classification test results

表 1 给出了 3 种模型对老年痴呆症及非老年痴呆症预测诊断的结果,通过观察比较可以看出,RBF 网络模型预测结果较 BP 网络模型更准确.其中老年痴呆症的确诊率由 68.750 0%上升为 84.375 0%,非老年痴呆症的确诊率由 68.421 1%上升为 73.684 2%,分类准确率由 68.627 5%上升为 80.392 2%.且 RBF 网络模型建立时间更短,由 2.371 2 s 下降为 1.965 6 s.而 SVM 模型与 RBF 网络模型相比,预测结果更为准确,老年痴呆症的确诊率由 84.375 0%上升至 90.625 0%,非老年痴呆症的确诊率同为 73.684 2%,从而使得整体分类准确率由 80.392 2%上升至 84.313 7%.同时,还可看到 SVM 模型建立时间仅仅为 0.015 6 s,不足 RBF 模型建立时间的百分之一.就整体而言,SVM 模型较 BP、RBF 网络模型对老年痴呆症的预测诊断准确率更高,建模速度更快,更适用于基于血常规数据的老年痴呆症的智能预测诊断.

表 1 BP、RBF 及 SVM 3 种模型预测结果比较

Table 1 Comparison of three models prediction results of BP, RBF and SVM

诊断结果		确诊数	误诊数	确诊率/%	误诊率/%	分类准确率/%	建模时间/s
BP 模型	老年痴呆症	22	10	68.750 0	31.250 0	68.627 5	2.371 2
	非老年痴呆症	13	6	68.421 1	31.578 9		
RBF 模型	老年痴呆症	27	5	84.375 0	15.625 0	80.392 2	1.965 6
	非老年痴呆症	14	5	73.684 2	26.315 8		
SVM 模型	老年痴呆症	29	3	90.625 0	9.375 0	84.313 7	0.015 6
	非老年痴呆症	14	5	73.684 2	26.315 8		

图 7 给出了 3 种模型测试结果的 ROC 图,其中实线线条表示老年痴呆病例的 ROC 曲线,虚线线条表示非老年痴呆病例的 ROC 曲线.其中,图 7(a)实线曲线与虚线曲线重合.通过计算 ROC 曲线下的面积(AUC)进行比较,易看出对于老年痴呆病例,SVM 模型的 AUC 面积最大,约 0.8;RBF 模型次之,约为 0.75;BP 模型最小,约为 0.7.而对于非老年痴呆病例,SVM 模型与 RBF 模型的 AUC 面积相近,约为 0.75;BP 模型的最小,约为 0.7.综合考虑老年痴呆与非老年痴呆病例的两种 ROC 曲线,可看出 SVM 模型的 AUC 面积和最大,RBF 模型次之,BP 模型最小.并且,SVM 模型的 ROC 曲线相对靠近左上角.因此,对于基于血常规数据的老年痴呆症数据,ROC 曲线也同样表明 SVM 模型预测诊断效果更好,准确率更高.




图7 3种模型测试分类结果的ROC曲线

Fig.7 ROC curves of the test results of the three models

4 结语

为了验证 SVM 支持向量机算法更适用于基于血常规数据的老年痴呆症预测诊断,将 SVM 模型与 BP 神经网络、RBF 神经网络模型预测结果的确诊率、误诊率、分类准确率以及建模时间分别进行比较,结果表明,SVM 模型分类准确率更高,确诊率更高,误诊率更低,建模时间更短。因而,在基于血常规数据的老年痴呆症预测诊断中,SVM 算法的性能优于 BP 神经网络、RBF 神经网络算法,在实际应用中应优先考虑 SVM 支持向量机算法。本文的结论可以为基于支持向量机的老年痴呆症智能预测诊断研究提供理论准备。

从医院电子病历系统中收集的数据具有高度的可靠性。特别地,血常规是一种较为普遍的化学检验,利用血常规数据作为疾病诊断指标具有方便可行性、经济实用性优势。由于本次实验中老年痴呆症数据量较少,导致模型的预测准确率普遍较低,后期可通过增加数据量来提高模型的准确率。

[参考文献](References)

- [1] 贾伟华,马颖,陈若陵,等. 中国部分城乡社区老年痴呆症患病率及其影响因素研究[J]. 安徽医科大学学报,2012,47(8): 944-947.
JIA W H, MA Y, CHEN R L, et al. The prevalence of Alzheimer's disease and its influencing factors in some urban and rural communities in China[J]. J Anhui Med Univ, 2012, 47(8): 944-947. (in Chinese)
- [2] 吴信东,叶明全,胡东辉,等. 普适医疗信息管理与服务的关键技术与挑战[J]. 计算机学报,2012,35(5): 1-19.
WU X D, YE M Q, HU D H, et al. The key techniques and challenges of pervasive healthcare information management and service[J]. Chinese journal of computers, 2012, 35(5): 1-19. (in Chinese)
- [3] 张会敏,叶明全,孟婷玮,等. 遗传算法优化 BP 神经网络的老年痴呆症智能诊断[J]. 中国数字医学,2014,9(7): 81-84.

- ZHANG H M, YE M Q, MENG T W, et al. Genetic algorithm-based optimized BP neural network for intelligent diagnostics of dementia disease[J]. Chinese digital medicine, 2014, 9(7): 81-84. (in Chinese)
- [4] 郝涛, 张智. 基于 BP 神经网络的原发性肝癌 CT 图像纹理分析[J]. 中国数字医学, 2013, 8(8): 73-76.
HAO T, ZHANG Z. Texture analysis of CT images of primary liver cancer based on BP neural network[J]. Chinese digital medicine, 2013, 8(8): 73-76. (in Chinese)
- [5] JIE B, ZHANG D, BO C, et al. Manifold regularized multitask feature learning for multimodality disease classification[J]. Human brain mapping, 2015, 36(2): 489-507.
- [6] MANHUA L, DAOQIANG Z, DINGGANG S. Ensemble sparse classification of Alzheimer's disease[J]. Neuroimage, 2012, 60(2): 1106-1116.
- [7] 韩敏. 人工神经网络基础[M]. 大连: 大连理工大学出版社, 2014.
HAN M. Artificial neural network[M]. Dalian: Dalian University of Technology Press, 2014. (in Chinese)
- [8] 马锐. 人工神经网络原理[M]. 北京: 机械工业出版社, 2010.
MA R. The principle of artificial neural network[M]. Beijing: China Machine Press, 2010. (in Chinese)
- [9] 刘冰, 郭海霞. MATLAB 神经网络超级学习手册[M]. 北京: 人民邮电出版社, 2014.
LIU B, GUO H X. MATLAB neural network super learning handbook[M]. Beijing: The Posts and Telecommunications Press, 2014. (in Chinese)
- [10] 徐璘, 王忆勤, 邓峰, 等. 基于 SVM 的中医心系证候分类研究[J]. 世界科学技术: 中医药现代化, 2010, 12(5): 713-717.
XU J, WANG Y Q, DENG F, et al. The heart of TCM syndrome classification research based on SVM[J]. World science and technology: modernization of traditional Chinese medicine, 2010, 12(5): 713-717. (in Chinese)
- [11] 张会敏, 叶明全, 罗永钱, 等. 基于 RBF 神经网络的老年痴呆症智能诊断研究[J]. 中国数字医学, 2015, 10(6): 38-41.
ZHANG H M, YE M Q, LUO Y Q, et al. A study on intelligent diagnosis of senile dementia based on RBF neural network[J]. Chinese digital medicine, 2015, 10(6): 38-41. (in Chinese)
- [12] 陈守平, 董瑞, 罗晓莉. MATLAB 神经网络 30 个案例分析[M]. 北京: 北京航空航天大学出版社, 2010.
CHEN S P, DONG R, LUO X L. 30 case analysis of MATLAB neural network[M]. Beijing: Beihang University Press, 2010. (in Chinese)
- [13] 钟志芳. MATLAB 神经网络设计与应用[M]. 北京: 清华大学出版社, 2013.
ZHONG Z F. Design and application of MATLAB neural network[M]. Beijing: Tsinghua University Press, 2013. (in Chinese)

[责任编辑: 严海琳]