

GA-BP算法与SVM在呼吸运动估计中的效果比较

米雅婷¹, 葛中芹¹, 张婕¹, 黄晓林¹, 陈颖¹, 蔡晶², 储开岳², 金建华², 葛云¹

1. 南京大学电子科学与工程学院, 江苏 南京 210023; 2. 南通市肿瘤医院放疗科, 江苏 南通 226361

【摘要】目的:比较遗传算法优化的误差反向传播算法(GA-BP)和支持向量机(SVM)对于呼吸运动估计的效果,为临床放疗中的呼吸运动估计提供参考。**方法:**在MATLAB平台下分别采用GA-BP算法和SVM对德国吕贝克大学机器人与认知系统研究所公开的两组可免费下载的实验数据进行计算,并对两种算法的估计精度和实时性进行比较分析。**结果:**在GA-BP算法中,测试数据中90%的估计结果均方根误差小于1.09 mm;在SVM中,90%的估计结果均方根误差小于1.72 mm。两种算法单次估计的时间都小于0.3 ms,均满足临床使用需求。**结论:**在呼吸运动估计中,两种算法均能满足临床实时性需求,且GA-BP算法估计结果的均方根误差小于SVM。

【关键词】误差反向传播算法;支持向量机;呼吸运动;均方根误差

【中图分类号】R33.3

【文献标志码】A

【文章编号】1005-202X(2017)03-0287-04

Comparison between GA-BP algorithm and SVM in respiratory motion estimation

MI Yating¹, GE Zhongqin¹, ZHANG Jie¹, HUANG Xiaolin¹, CHEN Ying¹, CAI Jing², CHU Kaiyue², JIN Jianhua², GE Yun¹

1. School of Electronic Science and Engineering, Nanjing University, Nanjing 210023, China; 2. Department of Radiotherapy, Nantong Tumor Hospital, Nantong 226361, China

Abstract: Objective To compare the effects of genetic back propagation (GA-BP) algorithm and support vector machine (SVM) on the respiratory motion estimation (RME), and to provide a reference for RME in clinical radiotherapy. **Methods** Two groups of free downloadable experimental data, which were given by Institute for Robotics and Cognitive Systems, University of Lubeck, Germany, were calculated by GA-BP algorithm and SVM under the MATLAB platform, respectively. The real-time performance and accuracy of the two algorithms were compared and analyzed. **Results** For 90% of the estimation results in the test data, the root mean square error was less than 1.09 mm in GA-BP algorithm and less than 1.72 mm in SVM. Both the time for the single estimation of GA-BP algorithm and SVM were less than 0.3 ms, meeting the requirement of clinical application. **Conclusion** In RME, both GA-BP algorithm and SVM can meet the clinical real-time requirements, and the root mean square error of GA-BP algorithm was less than that of SVM.

Keywords: back propagation; support vector machine; respiratory motion; root mean square error

前言

统计数据表明,约70%的肿瘤患者需接受不同程度的放射治疗,放疗已成为肿瘤重要的治疗手段。在放疗过程中,人体自身的呼吸运动会引起肿瘤靶

区的偏移,影响肿瘤放疗的效果^[1-2]。在目前的临床治疗中,降低呼吸运动对肿瘤放疗影响的办法主要有靶区外扩法、屏气法、加压法、呼吸门控法、四维放疗以及实时跟踪技术等^[3-4]。实时跟踪技术分为直接跟踪和间接跟踪两种,直接跟踪需要在病人体内植入金粒子,会对病人造成创伤;间接跟踪中可行性最高、使用最多的是通过建立体内-体外数据的关联模型对呼吸运动进行估计。建立关联模型的常用方法有子序列匹配、局部退化、线性预测、组合多项式、卡尔曼滤波等^[5],目前在临床中使用最广泛的Cyberknife^[6](Accuray,美国)同步动态呼吸追踪技术就是基于组合多项式原理建立的关联模型。该系统可以在患者

【收稿日期】2016-11-19

【基金项目】江苏省政策引导类计划(BY2015069-06);江苏省重点研发计划(SBE2016733);江苏省普通高校研究生科研创新计划(KYLX16_0058)

【作者简介】米雅婷,硕士,研究方向:医学信号分析,E-mail: miyating_nju@163.com

【通信作者】葛中芹,工程师,研究方向:信号和信息处理,E-mail: gxlin_2000@163.com;蔡晶,硕士,主任医师,从事放射物理工作,E-mail: cj7227@sina.com

自由呼吸下追踪肿瘤运动,但是基于组合多项式建立的关联模型算法可靠性有待提高^[7]。考虑到呼吸运动本身的非线性和复杂性,机器学习的方法可能可以在这个领域中更好地发挥优势,遗传算法优化的误差反向传播算法(GA-BP)与支持向量机(Support Vector Machine, SVM)是机器学习中两种最为广泛使用的成熟算法^[8]。因此本文将对基于这两种算法建立的不同呼吸运动估计模型进行比较,希望能够为临床选择合适的方案提供参考。

1 GA-BP 算法模型与SVM模型

1.1 GA-BP 算法模型

误差反向传播算法(Back Propagation, BP)由信息的前向传播和误差的反向传播两个部分组成^[9]。假设BP网络的输入层为 $X=[x_1, x_2, \dots, x_m]$, 隐含层为 $B=[b_1, b_2, \dots, b_l]$, 输出层为 $Y=[y_1, y_2, \dots, y_n]$ 。若输入层第 i 个神经元与隐含层第 h 个神经元之间的连接权值为 v_{ih} , 隐含层第 h 个神经元与输出层第 j 个神经元的连接权值为 ω_{hj} , 隐含层第 h 个神经元的阈值为 γ_h , 输出层第 j 个神经元的阈值为 θ_j , f_1 表示隐含层激活函数, f_2 表示输出层激活函数。那么, 隐含层第 h 个神经元接收到的输入为: $\alpha_h = \sum_{i=1}^m v_{ih} x_i$, 经过激活函数 f_1 之后得到该隐含层神经元的输出为:

$$b_h = f_1(\alpha_h - \gamma_h) = f_1\left(\sum_{i=1}^m v_{ih} x_i - \gamma_h\right) \quad (1)$$

输出层第 j 个神经元接收到的输入为: $\beta_j = \sum_{h=1}^l \omega_{hj} b_h$, 经过激活函数 f_2 之后得到该输出层神经元的输出为:

$$y_j = f_2(\beta_j - \theta_j) = f_2\left(\sum_{h=1}^l \omega_{hj} b_h - \theta_j\right) \quad (2)$$

误差反向传播是指将输出层神经元的实际输出 y_j 与期望输出 \widehat{y}_j 之间的均方误差:

$$\text{MSE} = \frac{\sum_{j=1}^n (y_j - \widehat{y}_j)^2}{n} \quad (3)$$

按照与原来正向网络相似的传递规则逐层反向传播,将误差分摊到网络中的每一个神经元,然后根据梯度下降法修正原来网络中的权值和阈值。BP算法容易陷入局部最优,利用遗传算法(Genetic Algorithm, GA)的全局搜索能力能够很好地优化BP算法,从而得到性能更佳的GA-BP网络^[10]。GA算法优化BP网络的步骤包括编码、初始种群生产、适应度评估、选择、交叉和变异^[11]。

1.2 SVM模型

SVM是以统计学习的VC维(Vapnik-Chervonenkis Dimension)理论和结构风险最小原理为基础建立的,它可以根据有限的样本信息在模型的复杂度和学习能力之间寻求最佳折中,得到泛化能力最好的模型^[12]。

假设给定训练样本 $D = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_m, y_m)\}$, $y_i \in \{-1, 1\}$, 希望得到形如 $\mathbf{w}^T \mathbf{x} + b = 0$ 的划分超平面将样本中不同类别的样本分开,其中 \mathbf{w} 是法向量, b 为位移项。在训练样本时,距离超平面 (\mathbf{w}, b) 最近且可以使超平面正确分类的样本点称之为“支持向量(Support Vector)”,两个异类支持向量到超平面的距离之和为:

$$\gamma = \frac{2}{\|\mathbf{w}\|} \quad (4)$$

它被称之为“间隔”。为了得到最佳的分类模型,需找到具有“最大间隔”的划分超平面,也就是找到使 γ 最大的参数 \mathbf{w} 和 b , 即

$$\begin{aligned} \min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{s.t. } y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1, i = 1, 2, \dots, m \end{aligned} \quad (5)$$

这就是SVM问题的基本型。

用SVM的思想解决回归问题称为支持向量机回归。假设给定训练样本 $D = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_m, y_m)\}$, $y_i \in \mathbb{R}$, 希望得到 $f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b$ 形式的回归模型,使得 $f(\mathbf{x})$ 与 y 尽可能接近, $f(\mathbf{x})$ 与 y 之间的最大允许偏差为 ϵ , 其中 \mathbf{w} 和 b 是待确定的模型参数。那么此回归问题可表示为:

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m l_{\epsilon}(f(\mathbf{x}_i) - y_i) \quad (6)$$

其中, C 是正则化常数, l_{ϵ} 是 ϵ -不敏感损失函数。

$$l_{\epsilon}(z) = \begin{cases} 0, & \text{if } |z| \leq \epsilon \\ |z| - \epsilon, & \text{otherwise} \end{cases} \quad (7)$$

引入松弛变量 ξ_i 和 $\widehat{\xi}_i$, 可将式(6)重写为:

$$\min_{\mathbf{w}, b, \xi_i, \widehat{\xi}_i} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m (\xi_i + \widehat{\xi}_i) \quad (8)$$

$$\text{s.t. } f(\mathbf{x}_i) - y_i \leq \epsilon + \xi_i,$$

$$y_i - f(\mathbf{x}_i) \leq \epsilon + \widehat{\xi}_i,$$

$$\xi_i \geq 0, \widehat{\xi}_i \geq 0, i = 1, 2, \dots, m$$

引入拉格朗日乘子,得到对偶问题后,可将式(8)表示为:

$$f(\mathbf{x}) = \sum_{i=1}^m (\widehat{\alpha}_i - \alpha_i) \kappa(\mathbf{x}, \mathbf{x}_i) + b \quad (9)$$

其中, $\widehat{\alpha}_i$ 、 α_i 为拉格朗日算子, $\kappa(\mathbf{x}, \mathbf{x}_i)$ 为核函数。核函数的类型很多,在SVM模型中具体该选用什么样

的核函数目前尚且缺乏统一的理论指导^[13], 经过实验比较, 本文选择的核函数是径向基函数。

1.3 估计效果评价指标

本文从估计结果的精度和实时性两个方面来评价估计算法的性能, 并选择均方根误差(RMSE)作为精度的评价指标, 单次估计时间(T)作为实时性的指标。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

(10)

其中, N 为测试集样本的个数, y_i 为测试集样本的真实值, \hat{y}_i 为测试集样本的估计值。

$$T = \frac{\text{time}}{N}$$

(11)

其中, time 为估计所有测试集数据所需的总时间。

2 实验及结果

2.1 实验设计

根据数据特点, 本文采用隐含层神经元个数为4的3层GA-BP算法, 与核函数为径向基函数的SVM。并采用德国吕贝克大学机器人与认知系统研究所提供的两组可免费下载的数据作为实验数据, 在MATLAB软件平台上对这两种算法估计呼吸运动的性能进行计算比较。

第一组数据中, 记录了7名志愿者的呼吸运动数据。实验组通过4D超声和模板匹配法追踪志愿者的肝脏血管分叉点运动, 以此作为体内目标运动数据; 同时, 利用光学追踪志愿者体表固定的1个LED运动, 以此作为体外运动数据。将上述体内外运动数据相关联, 共获得7组实验数据。


第二组数据中, 记录了以1头猪为对象的呼吸运动数据, 该数据采集共执行两次。在每次数据采集时, 实验组采用双平面X射线法对猪的肝部体内植入的6个金粒子进行追踪, 获得体内运动数据; 同时, 通过对猪体表固定的4个LED进行光学追踪得到体外运动数据。以单个金粒子的运动作为体内目标运动数据, 以单个LED的运动作为体外运动数据分别关联, 获得48组实验数据。

为了简化结果评估过程并保证处理数据不失真, 在建立关联模型前, 分别取体内和体外运动数据的第一主成分作为关联对象^[14], 即将三维空间中的运动数据简化为一维数据处理。在第一组数据中, 7名志愿者的数据采集总时长均超过5.0 min, 实验中选取约前5.0 min数据作为训练集, 其余数据作为测试集; 第二组以猪为实验对象的数据中, 第一次采集的数据总时长约为8.0 min, 第二次采集的数据总时长约为2.0 min。为了降低其他因素的干扰, 在本文中仅取两组采集数据的前2.0 min参与实验, 并取约

前1.5 min数据作为训练集, 其余数据作为测试集。

2.2 实验结果

GA-BP和SVM两种算法对实验样本的呼吸数估计结果如图1和图2所示。图1是分别采用GA-BP和SVM两种算法估计实验样本呼吸运动所产生的RMSE累积频率直方图, 图2用线箱图绘制了两种算法对上述55组实验数据进行单次估计的时间分布图。从图1可以发现, 在对实验样本呼吸运动的估计中, GA-BP算法估计结果的RMSE普遍小于SVM。在GA-BP算法中, 90%的实验数据RMSE小于1.09 mm; 在SVM估计结果中, 80%的实验数据的RMSE小于1.16 mm, 90%的实验数据的RMSE小于1.72 mm。图2表明, SVM在呼吸运动估计中的实时性略优于GA-BP算法, 但两种算法的单次估计时间都稳定在0.3 ms以内, 均能够满足临床使用要求。



GA-BP: Genetic back propagation; SVM: Support vector machine; RMSE: Root mean square error

图1 两种算法(GA-BP和SVM)的运动估计误差累积直方图
Fig.1 Cumulative histogram of respiration motion estimation error of GA-BP algorithm and SVM


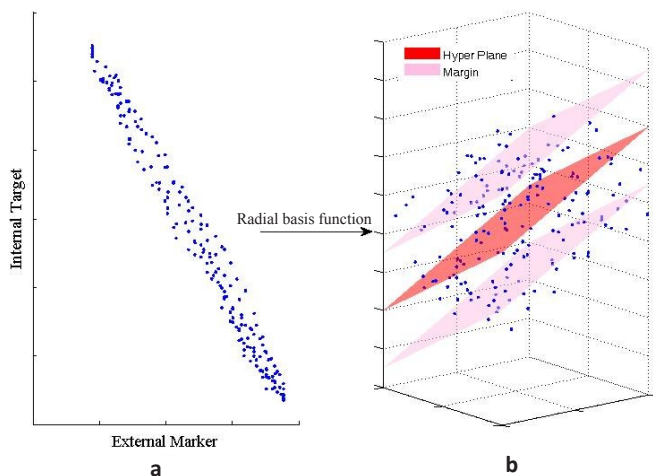


图2 单次呼吸运动估计时间分布图
Fig.2 Time distribution of single respiration motion estimation

3 讨论

本文在MATLAB平台上分别采用GA-BP算法和SVM对55组样本数据的呼吸运动进行估计。估计结果显示,GA-BP算法估计结果的RMSE小于SVM的估计结果,但实时性略逊于SVM,这可能与非线性SVM回归的算法本质有关^[15]。非线性SVM回归的基本思想是通过一个非线性映射将原始数据映射到高维特征空间,并在这个空间进行线性回归^[16]。如图3所示,当原始数据(图3a)被映射到高维空间后(图3b)的线性规律并不明显时,则不能找到一个很好的超平面进行划分,致使SVM的非线性回归结果的准确性受到了影响。此外,SVM避开了从归纳到演绎的拟合过程,提高了从训练样本到估计样本的“转导推理”效率,简化了通常的分类和回归等问题^[17]。因此,在预测实时性方面比GA-BP算法更具优势。



*For the intuitive expression of the author's point of view, and limited by the higher dimensional space rendering difficulties, the figure in the high-dimensional space with three-dimensional space is only indicative, and is not made with the real data.

图3 样本从低维空间到高维空间的映射

Fig.3 Mapping of sample from low-dimensional space to high-dimensional space

4 结论

本文分别采用GA-BP算法和SVM对实验样本的呼吸运动进行估计,同时以精度和实时性两个指标对两种方法进行了比较,分析了GA-BP算法和SVM在呼吸运动估计中的性能差异。结果显示,两种算法进行呼吸估计的实时性都能满足临床需求,同时GA-BP算法的估计精度优于SVM,是处理呼吸估计问题一个较优的选择。

【参考文献】

[1] HAMY V, DIKAIOS N, PUNWANI S, et al. Respiratory motion

correction in dynamic MRI using robust data decomposition registration-application to DCE-MRI[J]. Med Imag Anal, 2014, 18 (2): 301-313.

- [2] JANG S S, HUH G J, PARK S Y, et al. The impact of respiratory gating on lung dosimetry in stereotactic body radiotherapy for lung cancer[J]. Phys Med, 2014, 30(6): 682-689.
- [3] 曾学富, 郎锦义. 呼吸运动对肝癌放疗靶区的影响[J]. 西南军医, 2011, 13(5): 886-889.
ZENG X F, LANG J Y. Influence of respiratory motion on liver cancer radiotherapy target [J]. Journal of Military Surgeon in Southwest China, 2011, 13(5): 886-889.
- [4] MURPHY M J. Tracking organs in real time [J]. Semin Radiat Oncol, 2004, 14(1): 91-100.
- [5] POELS K, DHONT J, VERELLEN D, et al. A comparison of two clinical correlation models used for real-time tumor tracking of semi-periodic motion: a focus on geometrical accuracy in lung and liver cancer patients[J]. Radiother Oncol, 2015, 115(3): 419-424.
- [6] KILBY W, DOOLEY J R, KUDUVALLI G, et al. The CyberKnife robotic radiosurgery system in 2010[J]. Technol Cancer Res Treat, 2010, 9(5): 433-452.
- [7] YAMAZAKI H, DEMIZU Y, OKIMOTO T, et al. Comparison of re-irradiation outcomes for charged particle radiotherapy and robotic stereotactic radiotherapy using CyberKnife for recurrent head and neck cancers: a multi-institutional matched-cohort analysis[J]. Anticancer Res, 2016, 36(10): 5507-5514.
- [8] SEREGNI M, PELLA A, RIBOLDI M, et al. Real-time tumor tracking with an artificial neural networks-based method: a feasibility study[J]. Phys Med, 2013, 29(1): 48-59.
- [9] HECHT-NIELSEN R. Theory of the backpropagation neural network[C]//International Joint Conference on Neural Networks. IEEE, 1989: 593-605.
- [10] HUANG H X, LI J C, XIAO C L. A proposed iteration optimization approach integrating backpropagation neural network with genetic algorithm[J]. Expert Syst Appl, 2015, 42(1): 146-155.
- [11] 李伟超, 宋大猛, 陈斌. 基于遗传算法的人工神经网络[J]. 计算机工程与设计, 2006, 27(2): 316-318.
LI W C, SONG D M, CHEN B. Artificial neural network based on genetic algorithm[J]. Computer Engineering and Design, 2006, 27 (2): 316-318.
- [12] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 121-133.
ZHOU Z H. Machine learning [M]. Beijing: Tsinghua University Press, 2016: 121-133.
- [13] HUSSAIN M, WAJID S K, ELZAART A, et al. A comparison of SVM kernel functions for breast cancer detection [C]. Singapore: 10th International Conference on Computer Graphics, Imaging and Visualization, 2011: 145-150.
- [14] KUANG F, ZHANG S, JIN Z, et al. A novel SVM by combining kernel principal component analysis and improved chaotic particle swarm optimization for intrusion detection[J]. Soft Comput, 2015, 19(5): 1187-1199.
- [15] MINIERO G, RURALE A, ADDIS M. The management of respiratory motion in radiation oncology report of AAPM Task Group 76[J]. Med Phys, 2006, 33(10): 3874-3900.
- [16] 王定成. 支持向量机回归理论与控制的综述[J]. 模式识别与人工智能, 2003, 16(2): 192-196.
WANG D C. Review of support vector machines [J]. Pattern Recognition and Artificial Intelligence, 2003, 16(2): 192-196.
- [17] ZHONG H, MIAO C, SHEN Z, et al. Comparing the learning effectiveness of BP, ELM, I-ELM, and SVM for corporate credit ratings[J]. Neurocomputing, 2014, 128(5): 285-295.

(编辑:陈丽霞)