

doi:10.3969/j.issn.1000-7695.2024.18.025

基于自适应增强 (AdaBoost) 的 径向基 (RBF) 神经网络改进算法在关键词预测中的应用

陈张一, 朱朝阳, 邹玲, 胡小君

(浙江大学医学院, 浙江杭州 310058)

摘要: 探究学科或领域内研究发展趋势和热点一直以来受到国内外学者们重点关注, 而高频关键词的频次变化分析是其中重要的研究内容。关键词的变化与时间存在强相关性, 但当前仅有少数研究考虑了关键词随时间密切变化的特性。在考虑关键词信息的时间属性基础上, 提出一种基于自适应增强 (AdaBoost) 的径向基 (RBF) 神经网络预测算法 (以下简称“RBF 改进算法”), 对关键词频次进行分析预测。对中国知网 2007—2022 年收录的医学图像期刊论文关键词进行处理, 其中将 2007 年至 2021 年的数据作为实验训练数据, 2022 年数据作为验证数据, 通过案例分析, 对比 RBF 改进算法、反向传播算法和时间序列算法对关键词词频的预测结果。结果发现: 通过 AdaBoost 算法对 RBF 算法进行改进, 能够增强 RBF 神经网络的泛化能力以及对样本的适应性, 同时保留了 RBF 神经网络较好的非线性映射能力这一优点; RBF 改进算法预测结果与实际数据接近, 其预测精度优于 BP 神经网络和时间序列算法, 该算法的预测效果更佳。

关键词: 关键词词频; 预测算法; AdaBoost 算法; RBF 神经网络; 算法应用; 算法优化; 医学图像

中图分类号: G250.2; R319; G301

文献标志码: A

文章编号: 1000-7695 (2024) 18-0224-07

The Application of AdaBoost-Based Radial Basis Function Neural Network Algorithm for Keyword Prediction

Chen Zhangyi, Zhu Chaoyang, Zou Ling, Hu Xiaojun

(School of Medicine, Zhejiang University, Hangzhou 310058, China)

Abstract: Exploring research trends and hot topics within a discipline or field has always attracted significant attention from scholars both domestically and internationally, and analyzing the frequency changes of high-frequency keywords is an important aspect of such research. There is a strong correlation between changes in keywords and time, but currently only a few studies have considered the characteristic of keywords changing closely over time. Considering the time attribute of keywords, an Adaboost-based radial basis function (RBF) neural network forecasting algorithm (hereinafter referred to as "improved RBF algorithm") was proposed and applied to the keyword frequency forecasting and analyzing. The keywords of medical image journal papers indexed in CNKI from 2007 to 2022 were processed, with the data from 2007 to 2021 used as experimental training data and the 2022 data used as validation data. Through case analysis, the prediction results of keyword frequency were compared using the RBF improved algorithm, the backpropagation (BP) algorithm, and auto-regressive moving-average (ARMA) time series analysis algorithm. The results shows that improving the RBF algorithm through the AdaBoost algorithm can not only enhance the generalization ability and adaptability of the RBF neural network to samples, but also retain the good nonlinear mapping ability of the RBF neural network. The prediction results of the improved RBF algorithm were close to the actual data, and its prediction accuracy was better than the BP neural network algorithm and ARMA time series algorithm. Thus the improved RBF algorithm this paper proposed performs better.

Key words: the frequency of keywords; forecasting algorithm; Adaboost algorithm; RBF neural network; algorithm application; algorithm optimization; medical image

收稿日期: 2023-12-19, 修回日期: 2024-03-20

基金项目: 国家自然科学基金面上项目“基于‘非典型信号’的变革性研究特征识别与机理辨析的方法论研究及实证考察”(71974169)

0 引言

在进行科研创作和科技创新的过程中,学习和参考他人的研究成果是很重要的,在其他学者有关成果基础上能够更好地进行科研和技术的再创新。Nicolaisen^[1]、祝娜等^[2]研究表明,通过分析相关文献的引文和关键词等信息可以对相关领域热点的发展趋势进行研究。目前,国内外学者对研究热点的预测分析进行了大量的研究,其中基于关键词的研究热点分析一般通过分析高频关键词的频次变化来探讨研究热点的演进(如周鑫等^[3]、肖明等^[4]的研究)。

现有的热点分析研究中,Ko等^[5]、邱均平等^[6]、巩永强等^[7]、秦长江^[8]、李品等^[9]大多数研究仅对关键词数量变化进行了简单的加总运算,或是通过人工选取阈值来进行。但关键词的变化与时间存在强相关性,上述研究均未充分关注关键词随时间变化的规律特性。仅有少数研究考虑了关键词随时间密切变化的特性,如刘自强等^[10]的研究使用了时间序列法来预测相关热点。随着计算机技术的快速发展,人工智能被广泛运用于各个领域研究,神经网络尤其是人工神经网络(如可见于石乐明等^[11]、Rosenblatt^[12]、金耀初等^[13]、Hopfield^[14]的研究)因其强大的非线性拟合效果得到广泛应用和快速发展。因此本文研究利用神经网络相关模型来预测关键词的变化,以期提高预测准确性。

传统神经网络算法包括反向传播(BP)算法等,其基本的结构由非线性变化单元组成,理论上几乎可以逼近任意函数^[15]。BP算法灵活性很高,且具有很强的非线性映射能力,但由于BP神经网络训练复杂,且存在过拟合、需要反复迭代等特性,训练的结果容易陷入局部最优;而方俊等^[16]、王旭东等^[17]、陈伟等^[18]、李艳君等^[19]的研究表明,属于前向神经网络类型的径向基函数(RBF)神经网络算法可以克服上述算法的缺陷。但由于RBF神经网络算法是一种弱学习算法,为进一步提升预测精度,本研究提出基于自适应增强(AdaBoost)算法的RBF神经网络算法用于研究领域内论文关键词的预测,即使用Adaboost算法对RBF神经网络算法进行改进。AdaBoost算法本质上属于迭代算法,Morra等^[20]、付忠良^[21]、Nishii等^[22]、Collins等^[23]研究均表明,它可以提高弱学习算法的泛化能力以及预测精度,具体做法是针对训练集训练不同的弱学习器,然后将这些弱学习器集合构成强学习器。

1 基于 AdaBoost 的 RBF 神经网络改进算法构建

1.1 RBF 神经网络

人工神经网络可以用输入层、隐含层和输出层

的神经元构成,神经元之间使用连接权值连接,具有很强的自适应学习能力。Moody等^[24]提出了一种前向神经网络,即RBF神经网络,该网络类似于多层前向网络,虽然结构简单,但是在学习速度和泛化能力上都有很大的优势,能够逼近任意非线性函数。因此本研究选择RBF算法作为初始弱学习器。该算法的第一层为输入层 $\{x_1, x_2, \dots, x_m\}$,由信号源节点构成,这些信号源节点仅传递数据信息,不改变数据信息;第二层为隐含层 $\{c_1, c_2, \dots, c_n\}$,该层由若干隐单元组成,每个单元的变换函数均为非线性映射的径向基函数,而隐单元数目需要根据具体问题来确定;第三层为输出层,隐含层的输出经过线性加权后得到最终输出结果 y ,其中隐含层对应的权值为 $\{w_1, w_2, \dots, w_n\}$ 。RBF算法流程见图1。

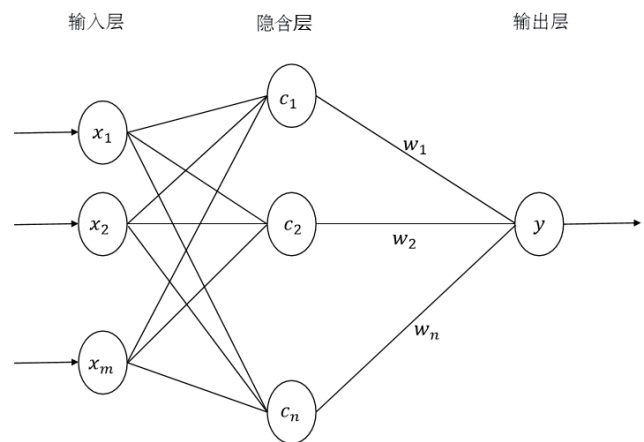


图1 RBF 算法流程

1.2 AdaBoost 算法

AdaBoost算法的核心思想是形成一个强学习器(即强学习算法),针对同一个训练集进行训练,得到若干初始弱分类器,然后集合这些弱分类器来构成强分类器。该算法主要用以解决回归问题和分类问题,且已经被运用到图像目标监测、交通量预测,电力负荷预测等多个领域(分别可见于高琳等^[25]、陈淑燕等^[26]、卢盼成^[27]、钱昆^[28]的研究)。

AdaBoost算法通过迭代运行形成的强学习器大大提高了其泛化能力。该算法通过调整样本和弱学习器的权重,提高难以正确分类的样本权值,基于已分类结果进行更改权值后的样本对下一个弱学习器进行训练。对于学习能力强的学习器,提高其权重,直至达到规定的迭代次数或者预期的误差率时,则强学习器构建完成。在训练初始,给每个样本赋相同权值,在此样本分布下训练得到一个学习器 $g_1(x)$ 。根据训练出的学习器计算训练样本集的误差,并相应调整学习器 $g_1(x)$ 的权值 W_1 和各个训练样本的

权值, 对于误差较小的样本, 则对应降低样本权重, 反之则增加其权重。更新样本权重分布后, 训练得到新一轮的学习器 $g_2(x)$ 以及其对应的权值 W_2 。依此进行 T 次循环, 则可以得到 T 个弱学习器以及这些弱学习器的权重向量 W , 最终的强学习器 $G(x)$ 由上述弱学习器根据权重向量集合起来构成。算法的具体步骤如下:

(1) 初始的弱学习算法为 $g_1(x)$, M 个训练样本组成的训练集为: $\{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ 。

(2) 初始化 M 个样本权值, 设定初始样本权重均匀分布, 则样本权值为 $D_t(i) = 1/M$, 其中 t 代表当前迭代轮数, $t = 1, 2, \dots, T, i = 1, 2, \dots, M$ 。

(3) 根据样本集当前的权重分布, 训练出弱学习器 $g_t(x)$ 和对应的总体错误率 ε_t , $\varepsilon_t = \frac{1}{N} \sum_{i=1}^N \varepsilon_i$, 其中 ε_i 为每个样本对应的误差。

(4) 根据上述错误率更新样本权重, 设定 $\beta_t = \frac{\varepsilon_t}{1-\varepsilon_t}$, 则调整样本权重为 $D_t(i) = D_{t-1}(i)\beta_t^{-\varepsilon_i}$, 该轮弱学习器的权值为 $W_t = \frac{1}{2} \ln(1/\beta_t)$ 。

(5) 若迭代次数未达到设定值 T , 则返回步骤 (3) 进行下一轮的迭代。

(6) 将弱学习器加权组合得到强学习器为 $G(x) = \sum_{t=1}^T W_t g_t(x)$ 。

1.3 基于 AdaBoost 的 RBF 神经网络算法

基于 AdaBoost 的 RBF 神经网络算法 (以下简称“RBF 改进算法”) 流程见图 2。

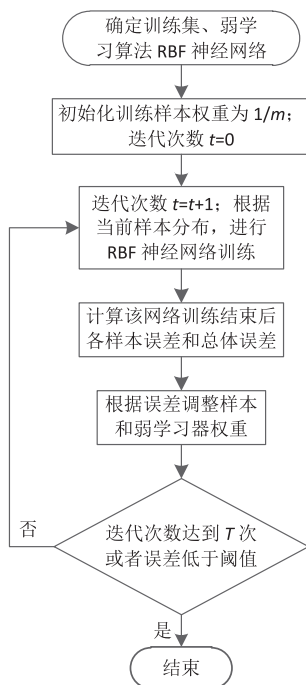


图 2 基于 AdaBoost 的 RBF 神经网络算法流程

该算法最开始使用归一化处理选定的样本集, 并将相同的权值赋给训练集样本。对归一化后的样本, 根据 AdaBoost 算法训练出 T 个弱学习器, 即 RBF 神经网络。根据当前的样本分布, 在训练集中随机选取出样本, 使用这些样本训练得到第 1 个 RBF 网络 M_1 , 该网络学习算法学习目标误差平方和为 $E_{rr_goal} = 10^{-5}$, 学习速率为 0.05, 最大学习次数为 50 000 次。本轮的训练结束后, 分别对所使用样本的预测误差进行计算, 然后根据预测误差对使用样本和神经网络的权重进行调整。重复上述过程, 当训练得到 RBF 神经网络数目达到 T 个, 根据这些网络和对对应权值通过式 (1) 进行关键词预测:

$$G(x) = \sum_{t=1}^T W(t) \cdot M_t(x) \quad (1)$$

2 实证研究

2.1 数据来源和研究方法

近年来, 数字化技术的飞速发展不断助推数字图像处理技术的进步。数字图像处理技术被广泛应用于医学诊断中。医学图像可以呈现出不同的病症, 通过处理画面上相关数据, 可以有效实现精准治疗, 具有重要的研究价值。为保证使用神经网络算法所需的训练数据量, 本研究基于中国知网 (CNKI) 中文学术期刊数据库 2007 年 1 月 1 日至 2022 年 12 月 31 日的数据, 以“医学图像”为主题进行搜索, 共得到学术期刊论文 4 826 篇 (以下简称“样本”)。通过分析 2007—2022 年样本论文关键词的变化趋势, 分析预测医学图像领域的研究热点变化。为验证本文所提算法的有效性, 选取 BP 算法和时间序列 (ARMA) 算法对结果进行分析比较, 并用平均绝对百分比误差 (MAPE) 和均方根误差 (RMSE) 两个指标对算法的有效性进行分析。

2.1.1 发文趋势分析

如图 3 所示, 在 2007—2022 年期间, 发文量最多的为 2008 年的 395 篇, 最少的是 2016 年的 249 篇。可以看出, 有关研究成果短暂出现过高峰, 后热度略有下降并保持平稳发展, 其中 2010—2016 年呈下降趋势, 不过在 2018 年后有所回升, 总体呈波动增长。




图 3 医学图像有关研究发文量年度分布

2.1.2 关键词数据处理

首先提取出样本论文的关键词并对其进行预处理, 先统计每个关键词在每一年出现的频率, 然后统计 2007—2022 年所有关键词的综合词频并进行排名。数据显示, 研究期间样本文献中共获取 7 963 个

关键词, 关键词出现的总累计频次为 19 639 次, 从中选取总频次大于等于 10 次的 207 个关键词用于算法分析(见表 1)。由于样本论文通过检索主题词“医学图像”得到, 所以“医学图像”及其近义词“医学影像”不列入结果中。

表 1 2007—2022 年样本论文的部分高频关键词

| 编号 | 关键词 | 词频 / 次 | 编号 | 关键词 | 词频 / 次 | 编号 | 关键词 | 词频 / 次 |
|----------|--------|--------|----------|----------|--------|----------|--------|--------|
| K_1 | 图像分割 | 439 | K_{21} | 水平集 | 59 | K_{41} | 生成对抗网络 | 36 |
| K_2 | 深度学习 | 257 | K_{22} | 人工智能 | 57 | K_{42} | 超声图像 | 36 |
| K_3 | 医学图像分割 | 249 | K_{23} | CT 图像 | 57 | K_{43} | CT | 36 |
| K_4 | 医学图像处理 | 240 | K_{24} | 分割 | 55 | K_{44} | 分水岭算法 | 36 |
| K_5 | 图像配准 | 219 | K_{25} | 遗传算法 | 54 | K_{45} | 图像压缩 | 33 |
| K_6 | 图像融合 | 204 | K_{26} | 计算机辅助诊断 | 53 | K_{46} | 感兴趣区域 | 33 |
| K_7 | 小波变换 | 195 | K_{27} | 可视化 | 49 | K_{47} | MRI | 33 |
| K_8 | 图像处理 | 187 | K_{28} | 脉冲耦合神经网络 | 48 | K_{48} | 数据挖掘 | 33 |
| K_9 | 三维重建 | 185 | K_{29} | 应用 | 48 | K_{49} | 区域生长 | 32 |
| K_{10} | 互信息 | 155 | K_{30} | 神经网络 | 44 | K_{50} | U-Net | 31 |
| K_{11} | 卷积神经网络 | 130 | K_{31} | 数学形态学 | 44 | K_{51} | 图像检索 | 31 |
| K_{12} | DICOM | 126 | K_{32} | 医学图像检索 | 43 | K_{52} | 面绘制 | 31 |
| K_{13} | 医学图像配准 | 115 | K_{33} | 三维可视化 | 43 | K_{53} | 活动轮廓模型 | 30 |
| K_{14} | 医学图像融合 | 112 | K_{34} | 配准 | 43 | K_{54} | 图像分类 | 29 |
| K_{15} | 边缘检测 | 106 | K_{35} | 注意力机制 | 42 | K_{55} | 迁移学习 | 29 |
| K_{16} | 特征提取 | 96 | K_{36} | 多模态 | 42 | K_{56} | 纹理特征 | 29 |
| K_{17} | PACS | 94 | K_{37} | 医学超声图像 | 41 | K_{57} | 压缩感知 | 29 |
| K_{18} | 图像增强 | 91 | K_{38} | ITK | 40 | K_{58} | 模糊聚类 | 29 |
| K_{19} | VTK | 78 | K_{39} | 支持向量机 | 39 | K_{59} | 医学影像学 | 29 |
| K_{20} | 体绘制 | 61 | K_{40} | 图像去噪 | 38 | K_{60} | 中值滤波 | 29 |

由于如“图像分割”和“医学图像分割”等意思相近的关键词在本研究中实际意义相同, 对于类似关键词频率进行合并统计处理。各高频关键词在各年度出现的频次见表 2。由此可知, 部分关键词在 10 年前尚未出现, 但随着时间推进而出现并逐渐变得热门, 如“深度学习”等; 而也有些关键词 10 年前比较热门, 随着研究的发展, 其出现频次逐步下降甚至有消失的趋势, 如“小波变换”等。这说

明医学图像领域的研究趋势变化较大, 研究内容从“可视化工具包 (VTK)”“互信息”和“小波变换”等的早期图像处理技术逐步转变成为如“深度学习”和“卷积神经网络”等不断发展的新兴技术, 说明随着人工智能的出现和不断发展, 其逐步取代旧有的研究技术, 被越来越广泛地应用在医学图像领域, 因此预测相关关键词趋势有着重要意义。

表 2 部分高频关键词出现频次年度分布

单位：次

| 关键词编号 | 2022 | 2021 | 2020 | 2019 | 2018 | 2016 | 2015 | 2014 | 2013 | 2012 | 2011 | 2010 | 2009 | 2008 | 2007 | 总频次 |
|-----------------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|-----|
| K_1/K_3 | 78 | 35 | 41 | 41 | 38 | 39 | 39 | 38 | 33 | 38 | 50 | 54 | 37 | 50 | 42 | 688 |
| K_4/K_8 | 41 | 32 | 33 | 28 | 23 | 15 | 19 | 22 | 17 | 25 | 20 | 33 | 33 | 34 | 28 | 427 |
| K_5/K_{13} | 8 | 19 | 11 | 14 | 12 | 12 | 23 | 9 | 19 | 18 | 27 | 37 | 32 | 42 | 37 | 334 |
| K_6/K_{14} | 13 | 18 | 19 | 19 | 19 | 18 | 21 | 21 | 25 | 20 | 17 | 17 | 23 | 17 | 23 | 316 |
| K_2 | 71 | 69 | 54 | 41 | 17 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 257 |
| K_7 | 0 | 4 | 2 | 5 | 3 | 11 | 9 | 14 | 16 | 12 | 15 | 22 | 25 | 26 | 26 | 195 |
| K_9 | 5 | 0 | 2 | 5 | 5 | 9 | 11 | 7 | 11 | 14 | 19 | 20 | 18 | 27 | 19 | 185 |
| K_{10} | 1 | 0 | 8 | 3 | 2 | 6 | 7 | 4 | 16 | 9 | 18 | 15 | 12 | 29 | 19 | 155 |
| K_{11} | 28 | 31 | 32 | 24 | 12 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 130 |
| K_{12} | 0 | 1 | 0 | 2 | 3 | 5 | 1 | 5 | 12 | 10 | 15 | 21 | 13 | 18 | 16 | 126 |
| K_{15} | 0 | 2 | 0 | 5 | 7 | 6 | 8 | 8 | 5 | 10 | 12 | 11 | 12 | 12 | 5 | 106 |
| K_{16} | 4 | 5 | 11 | 5 | 4 | 9 | 4 | 7 | 6 | 4 | 3 | 8 | 9 | 8 | 3 | 96 |
| K_{17} | 1 | 0 | 2 | 1 | 3 | 1 | 2 | 2 | 9 | 7 | 7 | 17 | 14 | 17 | 10 | 94 |
| K_{23}/K_{13} | 1 | 7 | 10 | 7 | 4 | 4 | 2 | 6 | 9 | 2 | 12 | 5 | 11 | 3 | 4 | 93 |
| K_{18} | 2 | 3 | 4 | 5 | 7 | 4 | 8 | 8 | 8 | 2 | 9 | 7 | 11 | 4 | 6 | 91 |
| K_{19} | 0 | 0 | 0 | 3 | 3 | 2 | 1 | 3 | 5 | 7 | 12 | 14 | 11 | 6 | 8 | 78 |
| K_{20} | 1 | 0 | 0 | 0 | 1 | 3 | 3 | 2 | 4 | 3 | 10 | 8 | 9 | 6 | 9 | 61 |
| K_{21} | 0 | 4 | 2 | 3 | 5 | 1 | 4 | 5 | 3 | 5 | 6 | 6 | 5 | 6 | 2 | 59 |
| K_{22} | 13 | 16 | 10 | 7 | 8 | 1 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 57 |
| K_{24} | 1 | 8 | 1 | 6 | 2 | 2 | 2 | 2 | 2 | 4 | 3 | 5 | 4 | 8 | 3 | 55 |

2.2 算法处理

基于上文提出的 RBF 改进算法对样本论文的关键词进行分析，并与分别通过传统时间序列法和 BP 神经网络法计算的结果进行对比。选取 2007—2021 年的关键词词频数据为实验训练数据，并以 2022 年关键词词频数据为验证数据，即通过对前 15 年的论文关键词词频变化进行分析预测，与 2022 年的数据进行对比验证，以验证预测方法的有效性。随后

分别运用 BP 算法、ARMA 算法、RBF 改进算法对 2022 年关键词频次进行预测，结果见表 3、图 4 和图 5。

表 3 不同算法下关键词频次预测的误差值

| 算法 | RMSE | MAPE |
|----------|------|-------|
| RBF 改进算法 | 2.12 | 4.93 |
| BP 算法 | 4.25 | 8.73 |
| ARMA 算法 | 5.74 | 11.25 |




图 4 2007—2022 年前 12 名高频关键词在不同算法下的词频预测结果




图5 2022年前12名高频关键词在不同算法下的词频预测结果

2.3 结果分析

(1) 3种算法中，RBF改进算法的MAPE值和RMSE值均最低，BP神经网络算法的MAPE值和RMSE值比RBF改进算法略高，而ARMA算法的MAPE值和RMSE值最高，说明RBF改进算法预测误差值最小，预测精度优于另两种算法，对测试样本具有较好的适应性。AdaBoost算法通过训练若干具有弱学习器特性的RBF网络，组合得到的RBF神经网络从而形成强学习器，该算法进一步增强了RBF神经网络算法的泛化能力，同时保留了RBF神经网络非线性映射能力较强这一优点。

(2) 大部分关键词频次随时间变化而变化，且变化程度较大。部分关键词频次越来越高，成为研究热点，另外一部分关键词频次则越来越低，反映出其研究热度下降。从图4可以看出，不管是词频越来越高还是越来越低的关键词，本研究提出的RBF改进算法对关键词词频的预测结果都比其他两种算法更接近实际频次，反映出更好的预测效果。

(3) 从图5可以看出，RBF改进算法的预测效果较另外两种算法更好，预测值更接近实际频次值。最近的年份频次排名靠前的关键词更能代表当前研究热点，说明用本研究提出的RBF改进算法更适用于关键词频次的预测，有助于更好地分析预测出领域内研究的发展趋势。

3 结论

传统热点分析方法对关键词的处理往往未能充分考虑关键词随时间密切变化的特性，本研究的预测方法充分考虑了该特性，提高了关键词预测的科学性与准确性。本研究对2007—2022年医学图像有关文献的高频关键词进行分析，算例分析结果表明，

运用AdaBoost算法对RBF神经网络进行改进，增强了RBF神经网络的泛化能力，增强了算法对样本的适应性，应用基于AdaBoost的RBF神经网络算法预测关键词频次的效果更佳。另外，结果也表明医学图像领域当前研究趋势是深度学习、图像分割和卷积神经网络等方法，可以给相关研究人员的研究方向提供参考意见。本文方法也存在一定的局限性，因此接下来可以扩大数据源的范围和丰富关键词预测以及相关热点发展趋势的分析方法，提高预测效果并增加分析手段。

参考文献：

- [1] NICOLAISEN J. Citation analysis [J]. Annual Review of Information Science and Technology, 2010, 41(1):609-641.
- [2] 祝娜, 王效岳, 白如江. 科技创新路径识别研究进展: 方法与工具 [J]. 图书情报工作, 2014, 58(13):132-139.
- [3] 周鑫, 陈媛媛. 关键词词频变化视角下学科研究发展趋势分析: 以国内情报学研究为例 [J]. 情报杂志, 2016, 35(5):133-140, 112.
- [4] 肖明, 李国俊, 杨楠. 基于词频分析的国内情报学研究热点: 1998—2007 [J]. 情报杂志, 2009, 28(8):21-25.
- [5] KO N, YOON J, SEO W. Analyzing interdisciplinarity of technology fusion using knowledge flows of patents [J]. Expert Systems with Applications, 2014, 41(4):1955-1963.
- [6] 邱均平, 温芳芳. 近五年来图书情报学研究热点与前沿的可视化分析: 基于13种高影响力外文源刊的计量研究 [J]. 中国图书馆学报, 2011, 37(2):51-60.
- [7] 巩永强, 刘莉. 基于词频分析法的情报学研究热点透析 [J]. 图书馆学研究, 2011(13):9-13.
- [8] 秦长江. 以关键词词频法透视《大学图书馆学报》学术研究特色 [J]. 图书馆论坛, 2014, 34(8):72-76.
- [9] 李品, 周金元. 中国图情领域2005至2009年研究热点透视: 基于国内外期刊发文词频统计的分析 [J]. 国家图书馆学报, 2010, 19(4):36-40.
- [10] 刘自强, 王效岳, 白如江. 基于时间序列模型的研究热点分析预测方法研究 [J]. 情报理论与实践, 2016, 39(5):27-33.

- [11] 石乐明, 周家驹, 刘信安, 等. 神经网络用于化学杂交剂的构效关系研究 [J]. 化学通报, 1992(6):46-48,37.
- [12] ROSENBLATT F. The perceptron: a probabilistic model for information storage and organization in the brain [J]. Psychological Review, 1958,65(6):386-408.
- [13] 金耀初, 蒋静坪. 神经网络在机器人控制中的应用 [J]. 机器人, 1992,14(6):54-58.
- [14] HOPFIELD J J. Neurons with graded response have collective computational properties like those of two-states neurons [J]. Proceedings of the National Academy of Sciences of the United States of America, 1984,81(10):3088-3092.
- [15] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back propagating errors [J]. Nature, 1986,323(6088):533-536.
- [16] 方俊, 赵英良. 基于 RBF 神经网络的一次性口令认证方案 [J]. 计算机工程, 2011,37(9):157-159.
- [17] 王旭东, 邵惠鹤. RBF 神经网络理论及其在控制中的应用 [J]. 信息与控制, 1997,26(4):272-284.
- [18] 陈伟, 冯斌, 孙俊. 基于 QPSO 算法的 RBF 神经网络参数优化仿真研究 [J]. 计算机应用, 2006,26(8):1928-1931.
- [19] 李艳君, 吴铁军, 赵明旺. 一种新的 RBF 神经网络非线性动态系统建模方法 [J]. 系统工程理论与实践, 2001,21(3):64-69.
- [20] MORRA J H, TU Z W, APOSTOLOVA L G, et al. Comparison of AdaBoost and support vector machines for detecting Alzheimer's disease through automated hippocampal segmentation [J]. IEEE Transactions on Medical Imaging, 2010,29(1):30-43.
- [21] 付忠良. 多分类问题代价敏感 AdaBoost 算法 [J]. 自动化学报, 2011,37(8):973-983.
- [22] NISHII R, EGUCHI S. Supervised image classification by contextual AdaBoost based on posteriors in neighborhoods [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005,43(11):2547-2554.
- [23] COLLINS M, SCHAPIRE R E, SINGER Y. Logistic regression, AdaBoost and Bregman distances [J]. Machine Learning, 2002,48:253-285.
- [24] MOODY J, DARKEN C J. Fast learning in networks of locally-tuned processing units [J]. Neural Computation, 1989,1(2):281-294.
- [25] 高琳, 高峰, 管晓宏, 等. 电力系统短期负荷预测的多神经网络 Boosting 集成模型 [J]. 西安交通大学学报, 2004,38(10):1026-1030.
- [26] 陈淑燕, 王炜, 瞿高峰, 等. 交通量预测的神经网络集成方法 [J]. 公路交通科技, 2004,21(12):80-83,92.
- [27] 卢盼成. 基于注意机制与深度学习的无人机视觉目标检测与跟踪 [D]. 南京: 南京航空航天大学, 2021.
- [28] 钱昆. 一种融合显著性的 Adaboost 电视制导图像变尺度目标快速检测方法研究 [J]. 指挥控制与仿真, 2014,36(2):127-130.

作者简介: 陈张一 (1989—), 女, 湖北枣阳人, 助理实验师, 硕士, 主要研究方向为医学信息学; 朱朝阳 (1973—), 男, 浙江宁波人, 助理研究员, 学士, 主要研究方向为生物医学工程、机器学习; 邹玲 (1988—), 女, 安徽六安人, 助理研究员, 博士, 主要研究方向为生物医学传感技术; 胡小君 (1965—), 通信作者, 女, 浙江武义人, 博士生导师, 教授, 博士, 主要研究方向为医药大数据管理、科学计量学。

(责任编辑: 叶伊倩)