

图1 多分辨率卷积神经网络框架

Fig.1 The framework of multi-resolution convolutional neural network

1.1 基础卷积神经网络架构

随着深度学习技术的快速发展,目前卷积神经网络已在图像分类和目标检测上取得了巨大的成功,有代表性的典型网络包括 AlexNet、VGGNet 和 ResNet 等^[12].综合考虑神经网络的识别性能和计算代价后,笔者选择使用 BN_Inception 作为基础框架实现所提出的火焰检测方法.

BN_Inception 架构中 inception 模块融合不同尺度特征^[17],采用不同大小的卷积核(比如 1、3、5)对感受野提取特征,设定卷积步长 $\text{stride} = 1$,只需分别设定 $\text{padding} = 0、1、2$,就可以得到相同维度的特征直接拼接在一起,使之更适合复杂场景识别任务.Inception 模块还采用 1×1 卷积核进行降维,参数数量大大减少.将稀疏矩阵聚类为密集的子矩阵,既保持了网络结构的稀疏性,又能利用密集矩阵的高计算性能^[16].

在 BN_Inception 架构中,批量归一化 BN 层可以加速网络收敛,提高网络性能.在卷积神经网络的训练过程中,BN 层保证每次迭代时,网络每层的输入数据都满足正态分布,它通过学到的重构参数 $\gamma、\beta$ 对数据缩放平移,恢复出原始的每层学到的特征.BN 层使激活输入值落在对 Sigmoid 敏感的区域,避免梯度消失问题,参数调整率变大,收敛加快.

1.2 多分辨率卷积神经网络架构

对于复杂场景下的火焰检测,考虑到场景特征的多尺度特性,笔者提出多分辨率的卷积神经

网络架构,同时关注场景的背景环境、局部目标、整体布局等特征^[17].

多分辨率的卷积神经网络由粗分辨率和细分辨率卷积神经网络两部分构成.两种不同分辨率的卷积神经网络使用不同分辨率的训练数据作为输入,使用基础架构 BN_Inception 训练网络模型,然后进行复杂场景下的火焰检测.

1.2.1 粗分辨率卷积神经网络

粗分辨率的卷积神经网络处理图像大小是 224×224 ,共 13 层.它以粗略的视角观察图像关注场景的整体布局信息,容易遗漏局部细节,而一些小目标往往是场景分类的重要线索.一个强大的场景分类神经网络需要学习场景多层次的视觉概念,因此笔者还要令神经网络更精细地学习场景的视觉信息.

1.2.2 细分辨率卷积神经网络

细分辨率的卷积神经网络处理图像大小是 336×336 ,鉴于输入图像更大,综合考虑模型的速度和容量后,相比于粗分辨率的卷积神经网络,笔者新增加了 3 个卷积层.在细分辨率下,卷积神经网络可以更精细地学习场景,能精准地捕捉到场景中有意义的局部细节信息.

由于输入图像的分辨率不同,卷积神经网络在每层对原始图像都有大小不同的感受野,这种设计使得网络能够学习复杂场景的多尺度信息.两个不同分辨率的卷积神经网络彼此互补,对分类的概率取算术平均值作为场景的最终判断结果.

1.3 多分辨率的神经网络训练

1.3.1 数据处理

笔者通过现场拍照或是互联网共收集了1 173张各种复杂场景下的火焰图片.将收集的火焰图片按2:1:1的比例,分为训练数据集、验证数据集和测试数据集^[18].模型训练使用caffe深度学习框架,将图片处理为分辨率为 224×224 , 336×336 的lmd6格式数据供训练使用.

1.3.2 训练网络

笔者对两种不同分辨率的卷积神经网络进行并行独立训练,并使用随机批量梯度下降算法优化神经网络权重.为了实现数据增广,笔者将 $N \times N$ 的输入图像按 $[N, 0.875N, 0.75N, 0.625N, 0.5N]$ 的比例随机裁剪后输入神经网络.训练阶段,在计算好总的数量后,设定总迭代次数为20万次,用训练2 000次就测试1次的策略,将学习率初始化为0.001,每训练5万次学习率衰减10倍.测试精度与迭代次数曲线如图2所示,其中,横轴表示迭代次数,纵轴表示测试精度.找出最优模型作为复杂场景下火焰检测的预测模型,取精度最高的模型用于复杂场景下的火焰检测.




图2 测试精度曲线图

Fig.2 Test accuracy graph

1.4 类激活映射方法

卷积神经网络通过多个卷积层提取图像的特征,从低层的位置信息逐渐到学习高层的语义信息,高层特征做加权操作后送给输出层(softmax层),得出最终分类的预测结果^[18].笔者根据卷积神经网络的这种连接结构使用类激活映射方法推导出卷积层到输出层的特征图权重,证明图像判别力强的局部区域对于最终分类结果具有重要意义.

在网络结构中,笔者使用全局平均池化层替换全连接层,保持了卷积对于场景激活区域的定位能力.对任意输入图像,使用训练好的模型检测完成后,提取输出层权重作为神经元最终做决定的依

据.把这些权重作为最后一个卷积层特征图的权重,计算出特征图的加权和,高亮显示出火焰场景中最具判别力的区域,图3为图1中火焰图像的灰度图,图中高亮区域(黄色部分)代表响应度最高的地方,即火焰目标,绿色区域表示响应度次之,蓝色区域响应度最低.将灰度图处理后与原图叠加生成热力图,图4为火焰图像的热力图,图中的高亮部分(红色区域)代表响应最高的火焰目标,绿色区域响应度次之,蓝色区域响应度最低.在热力图上使用阈值分割技术生成包围框定位出火焰在场景中的位置.在实现了火焰场景判别的情况下,笔者利用类激活映射方法,在只有图像标签的弱监督数据集上定位火焰在场景中的位置.




图3 火焰图像灰度图

Fig.3 Grayscale map of fire image




图4 火焰图像热力图

Fig.4 Heatmap of fire image

1.5 自学习的目标检测

笔者利用类激活映射方法,进一步在海量的场景数据上自动生成包围框,作为火焰检测的训练数据,指导神经网络完成目标检测任务.不仅省去了昂贵的人工标注成本,而且使火焰检测的定位精度也得到进一步提升.

2 实验对比

2.1 基于BP神经网络的火焰检测

BP神经网络是反向传输的一种神经网络,作为对比试验,笔者实现了使用BP神经网络对火焰进行检测.以火焰的圆形度、尖角数和面积变化率作为BP神经网络的输入信号,对火焰信息进行全方面的描述^[19-20].经过训练的BP神经网络输出该图片含有火焰目标的概率值.

2.2 基于多分辨率卷积神经网络的火焰检测

基于 BP 神经网络的火焰检测算法基于多特征融合思想^[21]利用火焰目标提取一些物理特征(颜色、圆形成度、尖角数和面积变化率)经过量化后作为神经网络的输入,BP 神经网络的输出层将输出该图像是火焰图像的概率,并将满足火焰特征的像素在图像中对火焰目标进行定位.笔者提出的火焰检测算法采用多分辨率卷积网络作为基础框架,在充分获取火焰多层次特征的基础上,使用类激活映射方法对火焰目标进行准确定位.这两种算法在笔者构造的涵盖各种复杂场景的火焰数据集上进行测试,并从检测正确率、定位覆盖率和处理速度等方面进行分析对比,结果如表 1 所示.

表 1 两种算法检测结果对比

Tab.1 Comparison of detection results of two algorithms

算法	检测正确率/ %	定位覆盖率/ %	处理速度/ fps
BP 网络	67.5	52.7	5
笔者算法	95.8	86.3	8

表 1 中的正确率是指在涵盖各种复杂场景的 1 173 张火焰图像数据集上实验,能够正确识别火焰在整个数据集所占的百分比.笔者定义目标的定位框与真值的 IOU^[4]值大于 50%的图像在整个数据集所占的百分比.定位覆盖率是能够正确识别火焰目标并且准确定位出火焰目标范围在整个数据集中所占的百分比.

由表 1 可知,由于 BP 神经网络的训练数据过多地依赖于传统的火焰图像特征,因此,会发生错检和漏检的情况.而笔者所提方法将火焰检测的正确率提高了 28.3%,其中所采用的弱监督定位方法,可以极大地提高对火焰目标的定位和框选覆盖准确率.另外,笔者提出的网络框架采用批量归一化的处理方法,极大地提高了对图像的处理速度,部分结果如图 5 所示.

其中,图(a)为基于 BP 神经网络的火焰检测算法对“晚霞”的检测结果,结果显示将晚霞误识别为火焰,但是笔者所提出的算法不会发生类似的错检情况(如图(b)).图(c)为基于 BP 神经网络火焰检测算法对含有火焰目标的图像发生了漏检的情况,笔者所提出的基于多分辨率的火焰检测算法检测结果如图(d)所示:检测出火焰目标,并用红色包围框对火焰目标进行定位,“fire”代表检测结果为火焰,检出概率为“0.99”;笔者使用类激活映射的方法可以在很大的程度上提高火




图 5 对比试验的部分实验结果展示

Fig.5 Demonstration of some experimental results of comparative experiments

焰目标的定位覆盖率,如图(e)、图(f)所示,图(e)为基于 BP 神经网络的火焰检测算法检测结果,该算法存在对火焰目标定位覆盖率不完全的问题.图(f)为笔者所提出算法的检测结果,可正确检测出“fire”目标,概率为 0.74,与图(e)相比,定位覆盖率更为完整.

3 结论

笔者通过使用基于多分辨率卷积神经网络的火焰检测算法,实现了在复杂场景下的火焰检测,并在实际场景中得到了有效的应用.在复杂场景中,相比于传统的 BP 神经网络,笔者提出的算法互补学习了火焰的多尺度视觉特征,同时关注场景的背景环境、局部目标、整体布局等特征.实验结果表明笔者提出的算法在检测精度和检测速率上都得到了显著的提升,对于场景分类和未来的场景理解都具有重要实际意义.

参考文献:

- [1] 杜静,严云洋,高尚兵,等.时空视觉选择性注意机制的视频火焰检测[J].计算机辅助设计与图形学学报,2014,26(3):479-485.
- [2] ZHANG K, SONG H, ZHANG L. Active contours driven by local image fitting energy[J]. Pattern Recognition, 2010, 43(4): 1199-1206.

- [3] JIANG B, LU Y, LI X, et al. Towards a solid solution of real-time fire and flame detection[J]. *Multimedia Tools & Applications*, 2015, 74(3):689-705.
- [4] 靳琪琳,段锁林. 基于神经网络与加权融合的火灾火焰识别研究[J]. *计算机工程与应用*, 2013, 49(13):156-159.
- [5] 邵婧,王冠香,郭蔚. 基于视频动态纹理的火灾检测[J]. *中国图象图形学报*, 2013, 18(6):38-44.
- [6] 邵良杉,郭雅婵. 基于 Codebook 的视频火焰识别算法[J]. *计算机应用*, 2015, 35(5):1483-1487.
- [7] 严云洋,杜静,高尚兵,等. 融合多特征的视频火焰检测[J]. *计算机辅助设计与图形学学报*, 2015, 27(3):433-440.
- [8] 杨文柱,刘晴,王思乐,等. 基于深度卷积神经网络的羽绒图像识别[J]. *郑州大学学报(工学版)*, 2018, 39(2):11-17.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]// *International Conference on Neural Information Processing Systems*. Curran Associates Inc. 2012:1097-1105.
- [10] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2015:1-9.
- [11] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. *Pattern Recognition*, 2014, 47(5):1409-1421.
- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]// *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016:770-778.
- [13] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Re-thinking the inception architecture for computer vision [C]// *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016:2818-2826.
- [14] ZHANG Y, WEI X S, WU J, et al. Weakly supervised fine-grained categorization with part-based image representation[J]. *IEEE Transactions on Image Processing*, 2016, 25(4):1713-1725.
- [15] WANG Z, WANG L, WANG Y, et al. Weakly supervised patchNets: describing and aggregating local patches for scene recognition.[J]. *IEEE Transactions on Image Processing*, 2017, 26(4):2028-2041.
- [16] ZHOU B, KHOSLA A, LAPEDRIZA A, et al. Learning deep features for discriminative localization [C]// *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016:2921-2929.
- [17] ZHOU B, LAPEDRIZA A, KHOSLA A, et al. Places: a 10 million image database for scene recognition.[J]. *IEEE Trans Pattern Anal Mach Intell*, 2018, (99):1-12.
- [18] MAHENDRAN A, VEDALDI A. Understanding deep image representations by inverting them [C]// *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2015:5188-5196.
- [19] 刘芳. 面向视频的火焰检测与跟踪算法研究[D]. 南昌:南昌航空大学信息工程学院, 2018.
- [20] 梅建军,张为. 基于 ViBe 与机器学习的早期火灾检测算法[J]. *光学学报*, 2018, 38(7):60-67.
- [21] 张震,刘博,李龙. 一种多特征提取及融合的虹膜识别方法[J]. *郑州大学学报(工学版)*, 2017, 38(1):63-67.

Fire Detection Based on Multi-resolution Convolution Neural Network

HUANG Wenfeng¹, XU Shanshan², SUN Yi², ZHOU Bing²

(1.Henan Provincial Institute of Scientific & Technical Information, Zhengzhou 450003, China; 2.School of Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: A fire detection algorithm based on multi-resolution convolutional neural network was proposed to achieve the objective of fire detection in real scenes. This algorithm leveraged the BN_Inception network as the basic network structure. Different coarse and fine resolution neural networks were used to learn the multi-scale visual features of the fire in complex scenes complementarily, while paying attention to the background environment, local targets and overall layout of the scene. The method was evaluated in fire dataset covers most real scenes. The experiment showed that the proposed method could achieve better detection results than other methods, which could be effectively applied in the real world.

Key words: multi-resolution convolutional neural network; fire detection; deep learning; weak supervised learning

文章编号:1671-6833(2019)05-0084-07

基于BP-RBF神经网络的组合模型预测港口物流需求研究

蔡婉贞¹, 黄 翰²

(1.汕头职业技术学院 经济管理系,广东 汕头 515078; 2.华南理工大学 软件学院,广东 广州 510006)

摘 要: 为了准确、高效地预测港口物流需求量,提出一种基于BP-RBF神经网络的组合预测模型.考虑到物流需求的非线性变化特点,在建模过程中首先采用BP与RBF两种神经网络方法分别建立单项预测子模型,然后依据各子模型预测结果赋予不同权重进一步构建加权组合预测模型.再以汕头港为例,通过MATLAB软件对港口物流需求量进行仿真预测.结果表明,组合预测模型较单一预测模型具有更高的预测精度,能有效减少出现较大误差的概率,使预测结果更接近于实际情况,可为港口今后物流发展规划提供参考.

关键词: BP神经网络; RBF神经网络; 组合模型; 预测; 港口物流需求

中图分类号: TP183;F552.7

文献标志码: A

doi:10.13705/j.issn.1671-6833.2019.02.025

0 引言

随着粤东沿海产业带建设的快速推进,汕头港口物流将迎来更大的发展机遇和挑战.对港口的物流需求进行精准的预测,将为港口物流产业发展以及物流基础设施规划设计提供可靠的数据支持.目前用于物流需求预测的理论方法可分为定性和定量两大类^[1].定性预测方法主要包括德尔菲法、专家调查法、主观概率法等.定性预测法较灵活,预测简单迅速,但易受主观因素的影响,难以对物流需求作数量上的精确描述.定量预测法则是利用历史数据或因素变量来预测未来物流需求的数学模型.传统港口物流需求定量预测方法主要有回归分析法^[2]、移动平均法^[3]、指数平滑法^[4]等.然而,物流系统是一个非常复杂的非线性系统,物流需求受多种因素共同影响,既存在一定的规律性,又具有很强的随机性,这使得传统的预测模型很难准确反映出各因素之间的复杂映射关系,从而影响预测结果的准确性.基于黑箱理论的人工神经网络是模仿大脑神经网络的结构和功能而建立的一种数学模型,凭借其非线性处理、自适应学习、高容错能力等特性,可以较轻松地实现非线性映射过程,广泛应用于非线性系统以及模型未知系统的预测控制^[5-6].BP神经网络和RBF

神经网络是两种常用的人工神经网络中.两者均属于前向型神经网络,其中BP神经网络是一种按照误差反向传播算法训练的多层神经网络,属于典型的全局逼近网络,该神经网络模型无论在网络理论还是在性能方面均比较成熟,具有较强的非线性映射能力和柔性网络结构^[7-9].BP神经网络也存在收敛速度慢、容易陷入局部极小值的缺点,难以保证学习结果达到均方误差的全局最小.与BP神经网络不同,RBF神经网络是一种局部逼近网络,只要有足够多的隐层神经元,RBF神经网络就能够以任意精度逼近任何连续非线性函数,具有训练速度快,不易陷入局部极小值等优点^[10-11].当算例中样本数据较多时,应用单一神经网络模型进行训练易出现过拟合问题,影响网络预测效果.鉴于港口物流需求量具有明显的不确定性和非线性特征,笔者拟将人工神经网络方法引入到港口物流需求预测中,分别构建BP神经网络和RBF神经网络预测模型.考虑到单一预测方法在实际预测中预测效果并不稳定,得出的预测结果与实际值可能存在较大偏差,为综合利用各神经网络模型的优点提高预测精度,笔者拟将上述单项模型预测结果按照误差平方和最小的原则计算各自的权系数,加权构建组合预测模型,并以汕头港为例进行实证分析.

收稿日期:2018-09-11;修订日期:2018-11-12

基金项目:国家自然科学基金资助项目(61370102)

作者简介:蔡婉贞(1982—),女,广东汕头人,汕头职业技术学院讲师,硕士,主要从事物流管理研究,E-mail:47653812@qq.com.

1 预测方法

1.1 BP神经网络

BP神经网络包括输入层、中间层和输出层。在整个网络中,为实现纵向全连接,横向每层的神经元间无连接,是一种按误差逆传播算法训练的前馈网络。它利用网络的实际输出和期望输出之间的误差最小对网络的多层连接权值和阈值由后向前逐层进行修正,随着这种误差逆向传播修正不断进行,神经网络对输入模式响应的正确率也不断提高。构建BP神经网络模型时,首先给每个连接权值和阈值赋予 $(-1, 1)$ 内的随机值;然后从训练样本中随机选取一组样本输入向量 $\mathbf{P}_k = (p_1, p_2, \dots, p_n)$ 和期望输出向量 $\mathbf{Q}_k = (q_1, q_2, \dots, q_l)$ 提供给网络。接着用输入向量 \mathbf{P}_k 、连接权 v_{ij} 和阈值 θ_j 计算隐层各单元的输入,然后利用该输入通过传递函数 f 计算隐层各单元的输出,

$$O_j = f\left(\sum_{i=1}^n v_{ij} p_i - \theta_j\right), \quad (1)$$

式中: i 为输入层的维数($i=1, 2, \dots, n$)。然后用隐层的输出 O_j 、连接权 w_{ji} 和 ψ_i 阈值计算输出层各单元的输出,然后利用该输出通过传递函数 f 计算输出层的响应,即网络的实际输出,

$$Y_i = f\left(\sum_{j=1}^p w_{ji} O_j - \psi_i\right), \quad (2)$$

式中: j 为隐层的维数, $j=1, 2, \dots, p$ 。

式(1)、式(2)中,传递函数 f 通常选用sigmoid型函数,

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (3)$$

再利用网络期望输出向量 \mathbf{Q}_k 和网络实际输出向量 \mathbf{Y}_i 计算出输出层的校正误差,

$$d_i^k = (q_i^k - Y_i) f'\left(\sum_{j=1}^p w_{ji} O_j - \psi_i\right), \quad (4)$$

式中: f' 为输出层函数的导数。接着利用该误差、连接权 w_{ji} 和隐层各单元的输出计算出隐层的校正误差,

$$e_j^k = \left(\sum_{i=1}^q w_{ji} d_i^k\right) f'\left(\sum_{i=1}^n v_{ij} p_i - \theta_j\right). \quad (5)$$

求得上述校正误差后,再利用该误差沿逆方向逐层修正输出层至隐层、隐层至输入层的连接权值和阈值。其校正量分别为:

$$\Delta w_{ji} = \alpha d_i^k O_j, \quad (6)$$

$$\Delta \psi_i = \alpha d_i^k, \quad (7)$$

式中: $0 < \alpha < 1$ 。

$$\Delta v_{ij} = \beta e_j^k p_i^k, \quad (8)$$

$$\Delta \theta_j = \beta e_j^k, \quad (9)$$

式中: $0 < \beta < 1$ 。

对所有的学习样本均按照上述计算方法对网络进行训练,通过重复执行以上过程,使实际输出不断逼近期望输出,直到网络全局误差函数 E 小于预先设定的极小值或学习次数大于预先设定的数值时,则完成网络的训练和收敛过程。

1.2 RBF神经网络

RBF神经网络属于单隐层的三层前馈网络,该网络输入层仅起到传输信号的作用,神经元的数目为样本中输入向量的维数;隐层是由一组传递函数为径向基函数的神经元构成的非线性映像层,能将低维输入数据映射到高维空间内,使其变得线性可分;输出层则对隐层的输出进行线性加权求和得到网络的最终输出。RBF神经网络最常用的径向基函数是高斯函数,表达式为:

$$g_i(x) = \exp \frac{-\|\mathbf{x} - \mathbf{c}_i\|^2}{2\sigma_i^2}, \quad (10)$$

式中: $g_i(x)$ 为隐层中第 i 个神经元的输出; \mathbf{x} 为 n 维输入向量; \mathbf{c}_i 为高斯函数的中心; σ_i 为高斯函数的方差; $\|\mathbf{x} - \mathbf{c}_i\|$ 为欧式范数。网络的输出为隐层神经元输出的线性加权求和,表达式为:

$$y_i = \sum_{i=1}^k w_{ij} g_i(x). \quad (11)$$

RBF神经网络训练分为无教师式学习与有教师式学习两个阶段。第一阶段为无教师式学习,可用基于K-means聚类方法求取径向基函数的中心 \mathbf{c}_i ,然后计算出方差 σ_i ,

$$\sigma_i = \frac{c_{\max}}{\sqrt{2k}}, \quad (12)$$

式中: c_{\max} 为所选取中心之间的最大距离, $i=1, 2, \dots, k$ 。通过上述学习求解径向基函数的中心和方差后,便进入第二阶段有教师式学习,即求解隐层和输出层之间神经元的连接权 w_{ij} ,可用最小二乘法计算得到,

$$w_{ij} = \exp\left(\frac{k}{c_{\max}^2} \|\mathbf{x} - \mathbf{c}_i\|\right). \quad (13)$$

此处的权为网络可调参数,RBF神经网络通过检查输出误差来调整径向基函数的中心 \mathbf{c}_i 和连接权值 w_{ij} ,据此调整网络内部系数,然后再重新检查网络误差,重复此过程直到网络达到误差要求或者最大隐层神经元数时则完成网络训练。

1.3 组合模型

港口物流需求预测是一个十分复杂的非线性

问题,仅使用单一的预测方法进行预测往往具有片面性,如 BP 神经网络虽然具有良好的曲线拟合能力、抗干扰和学习能力,但该网络采用的是基于梯度下降的训练算法,容易陷入局部最优,应用该网络进行长期预测时,受传递函数的影响,预测精度会随着时间的推移而降低.RBF 神经网络可对非线性连续函数一致逼近且不存在局部极小问题,可并行高速地处理数据.RBF 网络基函数中心是在输入样本集中选取的,有时难以反映系统真正的输入输出关系,且优选过程中有可能出现数据病态问题.如果可以综合利用上述网络模型的输出信息,赋予精度高的输出数据较高权重,精度低的输出数据占较低权重,最后将各网络模型的输出结果进行融合,不仅能够提高港口长期物流需求预测的精度,又能保障预测结果的稳定性.为将上述单项模型预测结果进行最优组合以提高预测效果,本研究采用的是一种“误差平方和最小”的加权组合预测模型,即通过求误差平方和最小值来确定最优权重系数,该方法综合了多种预测方法的优点,只要选择合适的组合权值就能有效提高预测精度.权重系数的大小与各单项预测方法的预测误差有关,误差大的预测方法相应权重小;反之,误差越小的预测方法对应的权重越大.应用 n 种不同的预测模型对同一个预测对象进行预测时,其加权组合模型预测值可表示为,

$$Y_t = \sum_{i=1}^n w_i Y_{it}. \quad (14)$$

式中: Y_t 为 t 时刻组合预测模型的预测值; Y_{it} 为第 i 个预测模型的预测值 ($i=1, 2, \dots, n$); w_i 为第 i 个预测模型的加权系数 ($i=1, 2, \dots, n$); 设某一时段的实际值为 C_t ; 欲使组合模型误差平方和达到最小,可构建以下方程组,

$$\begin{cases} \text{Min} \sum_{t=1}^n (C_t - \sum_{i=1}^n w_i Y_{it})^2 = 1 \\ \sum_{i=1}^n w_i = 1 \end{cases}. \quad (15)$$

通过计算组合模型误差平方和的最小值,求各个预测模型加权系数 w_i 的值.在建模过程中,先通过分别构建 BP 神经网络和 RBF 神经网络预测模型,采用训练效果最佳时的预测结果作为单项模型的最终预测值,将其与实测值一起代入式(15)计算得到各单项模型的加权系数,再将各预测模型的权值代入式(15)中进一步计算得到加权组

合模型的最终预测值,组合模型具体构建流程如图 1 所示.

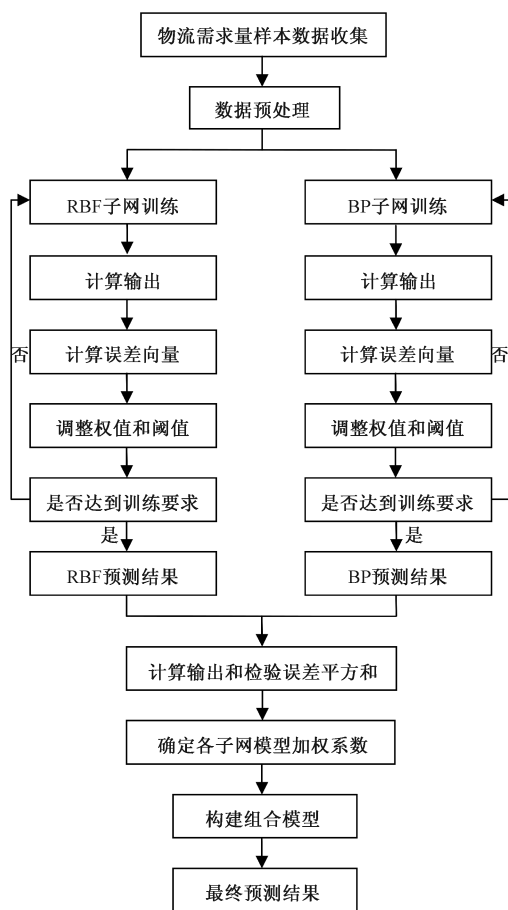


图 1 算法流程图

Fig.1 Algorithm flowchart

2 实证分析

为了测试上述模型对港口物流需求的预测效果,笔者以汕头港为例进行实证分析,样本数据如表 1 所示.实证数据以 2000~2017 年汕头港直接经济腹地三次产业产值、进出口总额、社会消费品零售总额、固定资产投资额作为物流需求的影响因素,港口货物吞吐量作为物流需求指标.2000~2016 年数据来源于广东省统计年鉴,2017 年数据来自汕头港直接经济腹地各市的国民经济和社会发展统计公报.表 1 中,符号 x_1 为第一产业产值,亿元; x_2 为第二产业产值,亿元; x_3 为第三产业产值,亿元; x_4 为进出口总额,亿美元; x_5 为社会消费品零售总额,亿元; x_6 为固定资产投资额,亿元; y 为港口货物吞吐量,万吨.将表 1 中的数据分成训练集和测试集两部分,训练集为 2000~2012 年各项数据,测试集为 2013~2017 年各项数据,训练集用来数据建模,测试集用来对建立的模型