

红外云图的台风内核风速建模的 RBFNN 和 PDE 方法

钱金芳¹, 张长江¹, 杨波¹, 马雷鸣²

(1. 浙江师范大学 数理与信息工程学院, 浙江 金华 321004; 2. 上海市浦东新区气象局, 上海 200135)

摘要: 目前反演台风内核风场时多采用线性回归方法进行建模, 针对基于线性回归法的台风内核风速拟合效果较差的缺点, 提出一种基于径向基函数神经网络(RBFNN)和偏微分方程(PDE)结合的红外卫星云图有眼台风内核风速和云图灰度建模方法。首先采用基于测地活动轮廓模型的 PDE 提取有眼台风的眼壁, 获得台风眼壁空间位置和亮度数据; 然后结合台风年鉴给出的台风近中心最大风速数据基于 RBFNN 进行有眼台风内核风速和云图灰度建模。实验结果表明: 该算法改善了台风内核风速拟合效果, 算法性能优于传统的线性回归法。

关键词: 建模; 偏微分方程; 径向基函数神经网络; 台风云图

中图分类号: TN219 **文献标志码:** A **文章编号:** 1007-2276(2015)02-0438-07

Typhoon inner core wind speed modeling method by RBFNN and PDE based on infrared cloud image

Qian Jinfang¹, Zhang Changjiang¹, Yang Bo¹, Ma Leiming²

(1. College of Mathematics, Physics and Information Engineering, Zhejiang Normal University, Jinhua 321004, China;

2. Pudong New Area, Shanghai Meteorological Bureau, Shanghai 200135, China)

Abstract: At present, linear regression model is often used to estimate typhoon inner core wind field. But the fitting effect of typhoon inner core wind speed based on linear regression was bad. Based on infrared satellite cloud image, radial basis function neural network (RBFNN) and partial differential equation(PDE) were used to build a model between typhoon inner core speed and cloud image's gray value. Firstly, typhoon's eye wall was extracted by using PDE which based on geodesic active contour model from the infrared satellite cloud image and the eye wall's space position and brightness are obtained. Then the maximum wind speed near typhoon center which was recorded by typhoon yearbook was used to build a model between typhoon inner core's speed and cloud image's gray value by RBFNN. The experimental results show that the proposed algorithm improves the fitting effect of typhoon inner core's wind speed, and the overall performance of the proposed algorithm is better than tradition method of linear regression.

Key words: model; partial differential equations; radial basis function neural network; typhoon cloud image

收稿日期: 2014-06-05; 修订日期: 2014-07-15

基金项目: 国家 973 计划(2009CB421500); 国家自然科学基金(40805048, 11026226, 41475059);

浙江省自然科学基金(LY13D050001); 浙江省科技厅公益性技术应用研究计划(2012C23027);

浙江师范大学计算机科学与技术省级重中之重学科开放基金(ZC323014072)

作者简介: 钱金芳(1989-), 女, 硕士生, 主要从事图像处理及应用方面的研究。Email: qjf15067063893@163.com

导师简介: 张长江(1974-), 男, 教授, 硕士生导师, 主要从事图像处理、模式识别、机器学习方面的研究。Email: zcj74922@zjnu.edu.cn

0 引言

台风是一种强热带气旋,台风来临时经常会伴随风暴潮、狂风和暴雨给沿海城市造成严重损失。我国是全球范围内受台风灾害影响严重的国家之一,提高台风的监测预报精度是有效地降低台风带来的经济损失的关键所在。台风强度是影响台风预报精度的一个重要指标,因此众多国内外学者展开对台风强度估计方面的研究。

侦查飞机不仅能够有效估计台风强度而且还能刻画台风整体结构,但是鉴于其昂贵的设备和侦查人员的安全考虑,因此鲜有利用侦查飞机进行强度估计的研究。陆基多普勒雷达能够对台风强度准确地估计,但是其有效监测范围仅仅是台风邻近登陆时有效,且在海面上较为准确,当台风登陆后其预报精度将会降低。与之相对的卫星资料虽然精度没有陆基多普勒雷达资料高,但是由于其覆盖面广且应用简单而被学者们广泛用于台风强度估计。最早利用卫星资料进行强度估计且作为早期的主要业务预报方法是 Dvorak 技术^[1]。考虑到 Dvorak 技术预报的主观性较大,Velden 等在 1998 年开发了一种由静止气象卫星的数字红外云图客观估计热带气旋强度的方法。王瑾等在 2005 年利用静止气象卫星红外展宽信息开发研究适用于西北太平洋上热带气旋强度的客观估计方法^[2]。2007 年,Kossin 等提出了一种基于红外卫星云图借助于线性回归法反演二维内核表面风场的方法^[3]。鲁小琴等利用日本 MTSAT 红外亮温资料,从热带气旋云图中提取对流较旺盛、云顶较高的深对流信息,用提取的对流核亮温极值、对流核数量、对流核距热带气旋中心距离等信息建立热带气旋强度估计模型^[4]。Gholamreza 通过对历史卫星资料的分析,提出一种新的方法,该方法类似于卫星图像的功能衍生物,需要从中心位置提取方位亮温资料,再利用 K 类均值算法进行强度估计^[5]。Miguel 通过对热带气旋进行偏差角计算,获得偏差角方差,再利用 sigmoid 曲线进行热带气旋强度估计^[6]。虽然线性回归法算法在很多情况下简单有效,但是其拟合误差通常较大,因此本文对红外云图灰度特征和最大风速进行了分析,利用径向基函数神经网络算法代替线性回归法的方法,建立有眼台风内核风速和红

外云图灰度的模型,以提高其建模精度,更加准确地刻画台风内核风场,为后续台风内核风场反演奠定基础。

1 基于 PDE 的有眼台风眼区提取

1.1 分割方法介绍

台风中心位置的确定对于台风灾害监测具有重要的意义,但在实际工作中,台风中心位置作为台风重要特征主要依靠人工方式进行确定^[7],因此,如何利用卫星云图,自动、准确地分割眼壁并在此基础上自动定位台风中心显得至关重要。基于卫星云图的台风眼壁分割属于图像分割范畴,常见的图像分割有:基于边缘检测的图像分割方法;基于灰度特征的阈值分割方法;基于区域的分割方法;基于分水岭的图像分割方法。

台风眼壁分割应该注意以下两个方面:一方面台风眼区轮廓是一条不规则曲线,常规图像分割方法不能直接有效用于台风眼壁分割;另一方面风速拟合要求台风眼区曲线必须是连续且封闭的。基于偏微分方程的图像分割方法恰好能够兼顾上述两个方面的要求,因此文中采用基于偏微分方程(PDE)图像分割方法。偏微分方程图像分割的基本原理是:将图像分割问题转化为一个偏微分方程,则该方程的解就是图像分割问题处理的结果。可见,为了达到期望的图像分割结果,选择一个合理的偏微分方程是该方法的关键。常见的偏微分方程是建立一个“能量”泛函,通过变分法,得到的 Euler-Lagrange 方程就是笔者需要的偏微分方程。因此图像分割问题就转化为寻找一个偏微分方程再对其进行求解。

1.2 GAC 模型简介

1988 年,Kass, Witkin 和 Terzopoulos 从全新角度出发,直接用连续曲线模型来定位图像边缘,提出了 Snakes 活动轮廓模型(参数模型)^[8],该模型在图像某个区域的附近定义一条带能量的初始化演化曲线(显示表达),在自身内力和图像信息产生的外力的作用下不断地运动,最后收敛于目标物体的边缘。该模型首次引进了变分法,其局部极值组成可供高层视觉处理的图像分割结果,这样在寻找显著图像特征时,即可通过将图像特征推向一个适当的局部极值点来与模型进行交互。1988 年,R. Osher 和 J.A.

Sethian 提出水平集方法 (Level Set Method)^[9], 使得活动轮廓模型进一步完善。与参数模型不同, 水平集方法并不跟踪不同时刻曲线运动情况, 而是在固定坐标系中更新不同时刻下的水平集函数来模拟曲线的演化。该方法大大拓宽了 Snakes 模型的应用范围, 活动轮廓模型的理论得到了很大的发展。1997 年, V. Caselles, R. Kimmel 和 G. Sapiro 三人在 Snakes 的基础上结合水平集方法共同研究提出了测地线活动轮廓模型(Geodesic Active Contour, GAC)^[10]。GAC 模型不仅克服了 Snakes 模型的很多固有缺陷, 并且具有水平集函数模拟曲线演化的特点, 因此该方法的提出所产生的影响是巨大的, 引发了图像分割技术的新革命, 对于图像处理技术的进步具有重大推动作用。

1.3 基于 GAC 模型的 PDE 图像分割方法数值简介

根据文中 1.2 小节所述, 活动轮廓模型是测地线活动轮廓模型的基础。由 Kass 提出的活动轮廓模型, 其主要思想是将图像分割问题转化为最小化一个封闭曲线 $C(p)$ 的“能量”泛函:

$$E[C(p)] = \alpha \int_0^1 |C'(p)|^2 dp + \beta \int_0^1 |C''(p)|^2 dp - \lambda \int_0^1 |\nabla I[C(p)]| dp \quad (1)$$

式中: p 为封闭曲线 C 的位置参数; α, β, λ 为权重因子, 用于调整能量得比重; I 为正值常量, 为一给定的图像。其中, 前两项控制曲线轮廓的平滑性(内力), 第三项驱使曲线向轮廓收敛(外力)。那么, 最小化公式(1)就需要要最小化前两项和最大化第三项。由参考文献[10], 可知当 $\beta=0$ 时, 曲线平滑仍然可以实现, 即公式(1)为:

$$E[C(p)] = \alpha \int_0^1 |C'(p)|^2 dp + \lambda \int_0^1 |\nabla I[C(p)]| dp \quad (2)$$

公式(2)可以通过以下方式概括边缘检测部分来进行推广:

定义一个严格渐减函数 $g(r), g: [0, +\infty], r \in \mathbf{R}^+$, 当 $r \rightarrow \infty$ 时, $g(r) \rightarrow 0$, 因此公式(2)第二项的 $|\nabla I|$ 可以被 $g(|\nabla I|)^2$ 代替, 得到一个一般形式的能量函数:

$$E[C(p)] = \alpha \int_0^1 |C'(p)|^2 dp + \lambda \int_0^1 g(|\nabla I[C(p)]|)^2 dp \quad (3)$$

式中: α, λ 的物理意义与公式(1)的相同, 观察公式(3),

发现 $E[C(p)]$ 主要与曲线的位置参数 p 的变化有关。参数 p 的随意性大大影响了 E 的结果, 为了避免这种情况, 将活动轮廓模型改为使用无自由参数 p 的测地活动轮廓模型。同时为使 $E[C(p)]$ 最小, 需要曲线通过边缘函数 $g(|\nabla I|)$ 的局部最小值, 这个思想类似于光学中费马定理, 则最小化封闭曲线 $C(p)$ 能量泛函式为:

$$L_R(C) = \int_0^{L(C)} g(|\nabla I[C(p)]|) ds, L(C) := \int_0^1 |C'(q)| dq = \int ds \quad (4)$$

式中: $L(C)$ 为封闭曲线 C 的欧几里得弧长; $L_R(C)$ 为经过加权后的弧长; ds 为欧几里得度量。根据最陡梯度法, 要最小化公式(4), 引入时间变量 t , 并且遵循曲线演化方程:

$$\frac{\partial C}{\partial t} = g(I) \kappa \vec{N} - (\nabla g \cdot \vec{N}) \vec{N} \quad (5)$$

式中: 前一项中 $\kappa \vec{N}$ 表示的是平均曲率运动; κ 为欧几里得曲率; \vec{N} 为曲线的单位法向量; ∇g 为边缘函数 $g(|\nabla I|)$ 的梯度。但是公式(5)存在一个明显的缺陷, 即它只适合分割凸的对象, 而不适合用来分割凹形对象。于是, 将公式(5)改进如下:

$$\frac{\partial C}{\partial t} = g(I)(c + \kappa) \vec{N} - (\nabla g \cdot \vec{N}) \vec{N} \quad (6)$$

式中: 参数 c 为一可调参数, 通常与演化的速度有关, κ 与公式(5)中的 κ 具有一样的物理意义。公式(6)即为广义的 GAC 模型。

在使用数值方案之前, 要得到边缘函数 $g(|\nabla I|)$, 因此需要计算出图像的灰度梯度。计算梯度的过程对噪声非常敏感。采用高斯去除噪声的干扰公式如下:

$$I_\sigma(x, y) = I(x, y) * G_\sigma(x, y) \quad (7)$$

式中: $I(x, y)$ 为源图像; σ 为高斯方差; $G_\sigma(x, y)$ 为高斯平滑函数; $I_\sigma(x, y)$ 为经高斯平滑后的目标图像。

令边缘函数为:

$$g(r) = \frac{1}{1 + (r/M)^p}, p = 1, 2 \quad (8)$$

式中: M 为待选的常数, 决定边缘函数 $g(I)$ 的下降速度。用图像中的各个像素的梯度大小代替 $g(r)$ 中的 r 得到:

$$g(x, y) = g(|\nabla I_\sigma|) \quad (9)$$

采用水平集的数值方法实现图像分割操作。假设曲线 C 的水平集函数为 u , 即 u 是曲线 C 的一个隐式表达式。对于平面曲线演化的一般方程式为:

$$\frac{\partial \mathbf{C}}{\partial t} = \delta \vec{\mathbf{N}} \quad (10)$$

式中: δ 为曲线 \mathbf{C} 的曲率; $\vec{\mathbf{N}}$ 为曲线的单位法向量, 则曲线演化水平集方法的基本方程式:

$$\frac{\partial \mathbf{C}}{\partial t} = \delta |\nabla \mathbf{u}| \quad (11)$$

对比公式(6)和公式(10)可知, $\delta = \mathbf{g}(\mathbf{l})(\mathbf{c} + \kappa) - (\nabla \mathbf{g} \cdot \vec{\mathbf{N}})$, 且 $\kappa = \text{div} \left(\frac{\nabla \mathbf{u}}{|\nabla \mathbf{u}|} \right)$ 代入公式(11):

$$\begin{aligned} \frac{\partial \mathbf{u}}{\partial t} = \delta |\nabla \mathbf{u}| &= \left[\mathbf{g}(\mathbf{l})(\mathbf{c} + \kappa) + \nabla \mathbf{g} \cdot \frac{\nabla \mathbf{u}}{|\nabla \mathbf{u}|} \right] |\nabla \mathbf{u}| = \\ &= \mathbf{g}(\mathbf{l}) \mathbf{c} |\nabla \mathbf{u}| + \mathbf{g}(\mathbf{l}) \kappa |\nabla \mathbf{u}| + \nabla \mathbf{g} \cdot \frac{\nabla \mathbf{u}}{|\nabla \mathbf{u}|} |\nabla \mathbf{u}| = \\ &= \mathbf{c} \mathbf{g}(\mathbf{l}) |\nabla \mathbf{u}| + \text{div} \left(\mathbf{g}(\mathbf{l}) \frac{\nabla \mathbf{u}}{|\nabla \mathbf{u}|} \right) |\nabla \mathbf{u}| \quad (12) \end{aligned}$$

由公式(5)可知, 基于基本 GAC 模型的曲线 \mathbf{C} 的隐函数 \mathbf{u} 的水平集方法为:

$$\frac{\partial \mathbf{u}}{\partial t} = \text{div} \left(\mathbf{g}(\mathbf{l}) \frac{\nabla \mathbf{u}}{|\nabla \mathbf{u}|} \right) |\nabla \mathbf{u}| \quad (13)$$

由于图像以离散的形式存储, 而偏微分方程描述的是连续的形式, 因此在对公式(12)和(13)作数值计算前, 采用“半点离散化”方案离散化这两式中的散度算子 $\text{div}()$, 由

$$\text{div} \left(\frac{\nabla \mathbf{u}}{|\nabla \mathbf{u}|} \right) = \frac{\partial}{\partial x} \left(\mathbf{g}(\mathbf{l}) \frac{\nabla u_x}{|\nabla \mathbf{u}|} \right) + \frac{\partial}{\partial y} \left(\mathbf{g}(\mathbf{l}) \frac{\nabla u_y}{|\nabla \mathbf{u}|} \right) \quad (14)$$

可得:

$$\begin{aligned} \text{div} \left(\mathbf{g}(\mathbf{l}) \frac{\nabla \mathbf{u}}{|\nabla \mathbf{u}|} \right) &\approx \mathbf{g}(\mathbf{l})_{i,j+1/2} \left(\frac{u_x}{|\nabla \mathbf{u}|} \right)_{i,j+1/2} - \\ &= \mathbf{g}(\mathbf{l})_{i,j-1/2} \left(\frac{u_x}{|\nabla \mathbf{u}|} \right)_{i,j-1/2} + \mathbf{g}(\mathbf{l})_{i+1/2,j} \left(\frac{u_y}{|\nabla \mathbf{u}|} \right)_{i+1/2,j} - \\ &= \mathbf{g}(\mathbf{l})_{i+1/2,j} \left(\frac{u_y}{|\nabla \mathbf{u}|} \right)_{i-1/2,j} \quad (15) \end{aligned}$$

公式(15)中的每一项, 可用 \mathbf{u} 和 $\mathbf{g}(\mathbf{l})$ 在整点的值作近似表达, 现以第一项为例:

$$\begin{aligned} (\nabla \mathbf{u})_{i,j+1/2} &= ((u_x)_{i,j+1/2}, (u_y)_{i,j+1/2}) \\ (u_x)_{i,j+1/2} &= u_{i,j+1} - u_{ij} \\ (u_y)_{i,j+1/2} &= (u_{i+1,j+1/2} - u_{i-1,j-1/2}) / 2 + (u_{i+1,j+1} - u_{i-1,j+1} - u_{i-1,j}) / 4 \quad (16) \end{aligned}$$

所以:

$$\begin{aligned} \left(\frac{u_x}{|\nabla \mathbf{u}|} \right)_{i,j+1/2} &= \frac{(u_x)_{i,j+1/2}}{\sqrt{(u_x)_{i,j+1/2}^2 + (u_y)_{i,j+1/2}^2}} = \\ &= \frac{(u_{i,j+1} - u_{ij})}{\sqrt{[(u_{i,j+1} - u_{ij})^2 + (u_{i+1,j+1} + u_{i+1,j} - u_{i-1,j+1} - u_{i-1,j})^2 / 16]^{1/2}}} = \\ &= \frac{C_{1,ij} (u_{i,j+1} - u_{ij})}{C_{1,ij} (u_{i,j+1} - u_{ij})} \quad (17) \end{aligned}$$

其中

$$C_{1,ij} = \frac{1}{[(u_{i,j+1} - u_{ij})^2 + (u_{i+1,j+1} + u_{i+1,j} - u_{i-1,j+1} - u_{i-1,j})^2 / 16]^{1/2}} \quad (18)$$

用相邻两“整点”的平均值近似地表示 $\mathbf{g}(\mathbf{l})$ 在“半点”的值:

$$\mathbf{g}(\mathbf{l})_{i+1/2,j} = \mathbf{g}(\mathbf{l})_{1,ij} = (\mathbf{g}(\mathbf{l})_{i+1,j} + \mathbf{g}(\mathbf{l})_{i,j}) / 2 \quad (19)$$

对其他三项作类似的处理, 便可知:

$$\begin{aligned} s_{ij} = \text{div} \left(\mathbf{g}(\mathbf{l}) \frac{\nabla \mathbf{u}}{|\nabla \mathbf{u}|} \right)_{ij} &\approx C_{1,ij} \mathbf{g}(\mathbf{l})_{1,ij} (u_{i,j+1} - u_{ij}) - \\ &= C_{2,ij} \mathbf{g}(\mathbf{l})_{2,ij} (u_{i,j} - u_{i,j-1}) + C_{3,ij} \mathbf{g}(\mathbf{l})_{3,ij} (u_{i+1,j} - u_{i,j}) - \\ &= C_{4,ij} \mathbf{g}(\mathbf{l})_{4,ij} (u_{i,j} - u_{i-1,j}) \quad (20) \end{aligned}$$

最后采用一种双曲型方程的迎风差分方法, 对离散化的公式(12)的偏微分方程进行数值计算。因为公式(12)的第一项系数 $\mathbf{c} \mathbf{g}(\mathbf{l})$ 总取正值, 故该项的迎风方案为:

$$Q_{1,ij} = \mathbf{c} \mathbf{g}(\mathbf{l}) \nabla_{ij}^{(-)} \quad (21)$$

公式(12)的第二项系数 $s_{ij} = \text{div} \left(\mathbf{g}(\mathbf{l}) \frac{\nabla \mathbf{u}}{|\nabla \mathbf{u}|} \right)_{ij}$ 可能为正值, 也可能为负, 故该项的迎风方案为:

$$Q_{2,ij} = \max(s_{ij}, 0) \nabla_{ij}^{(-)} + \min(s_{ij}, 0) \nabla_{ij}^{+} \quad (22)$$

得到显示方案:

$$\begin{aligned} u_{ij}^{n+1} &= u_{ij}^n + \Delta t (Q_{1,ij} + Q_{2,ij}) = u_{ij}^n + \Delta t (\mathbf{c} \mathbf{g}(\mathbf{l}) \nabla_{ij}^{(-)} + \\ &= \max(s_{ij}, 0) \nabla_{ij}^{(-)} + \min(s_{ij}, 0) \nabla_{ij}^{+}) \quad (23) \end{aligned}$$

2 基于 RBFNN 的台风内核风速和云图灰度模型的建立

2.1 近中心最大风速与云图灰度的关系

台风风速最大的地方在其眼壁附近, 眼部内几乎无风无雨, 即眼壁上 是风雨变化最剧烈的地方。通过观察卫星云图, 笔者发现在台风眼壁附近的灰度变化较为明显。在台风眼部内灰度值较小, 而眼部外面灰度值较大, 那么在两者的交界处即热带气旋眼壁上, 灰度变化最剧烈。因此采用拟合算法来构造最大风速和眼壁上灰度的关系。首先利用第 1 节中的基于 GAC 模型的偏微分方程法对台风眼分割得到眼壁处的灰度信息。由于台风年鉴数据每隔 6 h 才进行一次最大风速的记录, 因此文中将分割出来的眼壁上的所有点的灰度值取其平均值作为与最大风速建模的特征值, 如公式(24)所示:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (24)$$

式中： \bar{X} 为平均灰度； X_i 为第 i 个像素的灰度值； n 为整个眼壁处的像素个数。有眼台风内核风速和云图灰度建模算法流程图如图 1 所示。

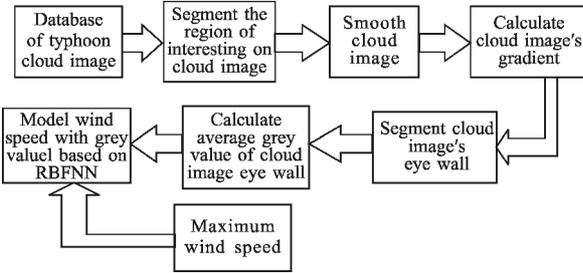


图 1 建模算法流程图

Fig.1 Modeling algorithm flow chart

2.2 径向基函数神经网络基本原理

1985 年 Powell 提出径向基函数 (Radial Basis Function, RBF) 方法, 1988 年 Moody 和 Darken 提出了一种神经网络结构, 即 RBF 神经网络。Broomhead 和 Lowe 在 1988 年发表的论文《Multivariable function interpolation and adaptive networks》中初步探讨了 RBF 用于神经网络设计与应用与传统插值领域的不同特点, 进而提出了一种三层结构的 RBFNN, 其结构如图 2 所示。

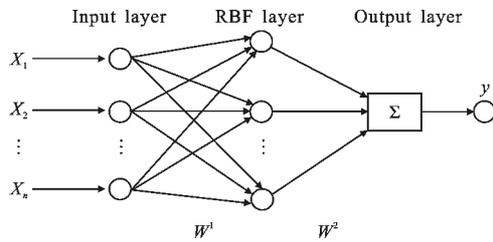


图 2 径向基函数神经网络结构图

Fig.2 Structure chart of radial basis function neural network

设 RBFNN 结构如下: 第一层为输入层其神经元节点数 n , 第二层为隐含层在 RBFNN 中即为径向基层其神经元节点数 r , 第三层为输出层神经元节点数 m 。设径向基层神经元 j 与输入层神经元 i 之间的连接权为 w_{ij} , 即:

$$w_j = (w_{j1}, w_{j2}, \dots, w_{jn})^T \quad j=1, 2, \dots, r \quad (25)$$

则连接权矩阵为:

$$W^j = (w_1, w_2, \dots, w_r)^T \quad (26)$$

高斯函数作为 RBFNN 中的径向基函数, 因此 RBFNN 的激活函数可以表示为:

$$R(x_p - c_i) = \exp\left(-\frac{1}{2\sigma^2} \|x - c_i\|^2\right) \quad (i=1, 2, \dots, m) \quad (27)$$

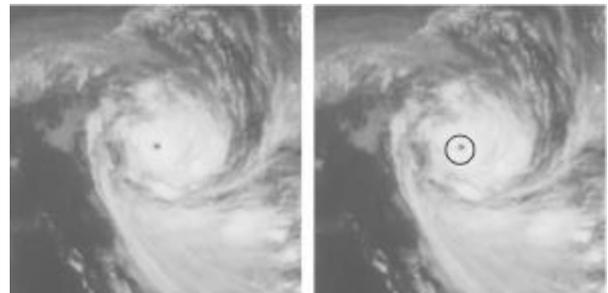
式中: x 为 n 维输入向量; c_i 为第 i 个基函数的中心, 与 x 具有相同维数的向量; σ_i 为第 i 个感知的变量 (可以自由选择参数), 它决定了该基函数围绕中心点的宽度; m 为单元个数。 $\|x - c_i\|$ 是向量 $x - c_i$ 的范数, 它通常表示 x 与 c_i 之间的距离。由图 2 所示的 RBFNN 结构可以得到网络的输出为:

$$F(x) = \sum_{i=1}^N w_i R(x_p - c_i) \quad i=1, 2, \dots, N \quad (28)$$

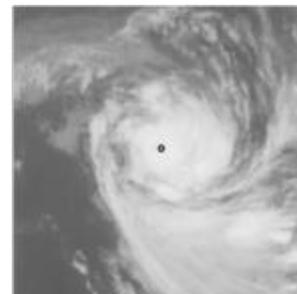
3 实验结果

3.1 分割眼壁结果及其分析

文中采用国内风云二号 C 卫星拍摄的静止红外卫星云图作为实验数据, 由于原始云图的大小为 $2\ 288 \times 2\ 288$ pixel, 笔者截取包含台风主体云系的 300×300 pixel 大小云图作为分析对象。文中主要以具有清晰台风眼拍摄时间为 2007 年 9 月 17 日 20 时 (世界时间) 的韦帕云图, 第 0713 号台风为例, 通过 GAC 模型的 PDE 方法来分割台风眼, 如图 3(a) 所示, 图 3(b) 为分割台风眼壁初始化轮廓范围, 图 3(c) 为分割后得到的台风眼壁。表 1 为分割后得到的眼壁上各点坐标值及其灰度值。



(a) 原图 (b) 初始化原图
(a) Original image (b) Initialize the original image



(c) 分割眼壁后云图
(c) Cloud image after segmenting eye wall

图 3 台风眼壁分割效果图

Fig.3 Segmentation for typhoon eye wall

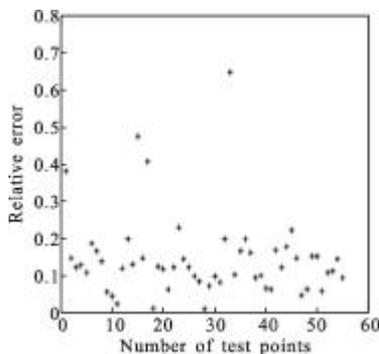
表 1 眼壁各点坐标值及其灰度值

Tab.1 Each point's coordinate and gray value in the eye wall

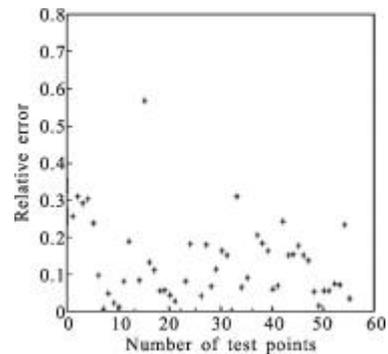
Ordinate	Abscissa	Grey value	Ordinate	Abscissa	Grey value
145	151	193	148	155	189
145	152	202	149	149	194
146	150	177	149	155	192
146	153	172	150	150	190
146	154	190	150	154	197
147	149	190	151	151	202
147	155	196	151	152	199
148	149	190	151	153	204

3.2 台风内核风速和云图灰度建模结果及其分析

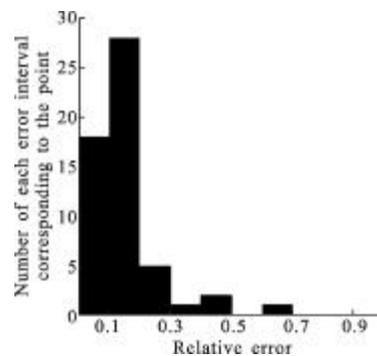
即使每个台风从形成到消散都会被记录, 但是年鉴数据为间隔 6h 进行一次采集, 因此有对应时刻的台风云图很少, 所以笔者选取 55 幅能够对应最大风速的云图作为实验数据。该实验主要利用径向基函数神经网络建立台风眼壁平均灰度和近中心最大风速之间的关系模型, 输入变量为眼壁的平均灰度, 输出变量为近中心最大风速, 实验结果的相对误差散点图和柱状图如图 4 (a)~(d)所示, 性能指标如表 2 所示。下面通过算法的相对误差散点图和柱状图来比较使用 RBFNN 作为拟合方法和使用其他拟合方法(线性回归法)的性能。其中径向基函数神经网络的径向基函数为高斯函数, 取均方误差为 0, 径向基函数的扩展速度为 0.79, 神经元的最大数目为 23, 两次显示之间所添加的神经元数目为 5。



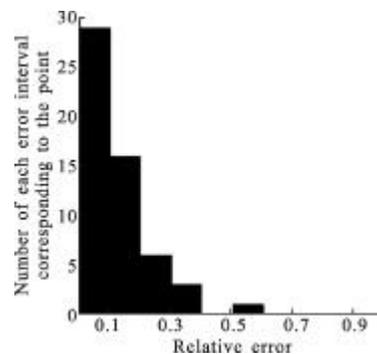
(a) 线性回归法的相对误差散点图
(a) Scattering plot of relative error by Linear Regression



(b) 径向基函数神经网络的相对误差散点图
(b) Scattering plot of relative error by RBFNN



(c) 线性回归法的相对误差柱状图
(c) Histogram of relative error by Linear regression



(d) 径向基函数神经网络的相对误差柱状图
(d) Histogram of relative error by RBFNN

图 4 相对误差散点图和柱状图

Fig.4 Scattering plot and histogram of relative error

表 2 各拟合算法的相对误差

Tab.2 Relative error of each fitting algorithm

Fitting method	Linear regress	RBFNN
Relative error	0.145 2	0.123 1

图 4(a)~(b)误差散点图和柱状图中的纵坐标表示实际风速与预测风速之间的相对误差, 横坐标表

示测试点数。从图 4 (c)~(d)可以看出,线性回归法的拟合相对误差主要集中在 0.1~0.2 之间,而径向基函数神经网络拟合相对误差主要集中在 0~0.1 之间,而且从图 4 (a)~(b)可以看出线性回归法的拟合和径向基函数神经网络的相对误差都存在个别点误差较大的情况,如线性回归法拟合的相对误差最大点为 0.649 0,径向基函数神经网络拟合误差中的最大相对误差为 0.570 0。另外,由表 2 中可以观察得到径向基函数神经网络的相对误差比线性回归法小,综合而言,径向基函数神经网络拟合效果优于线性回归法。由于文中样本数据必须满足以下条件:数据必须来源于有眼台风的红外云图,气象中心发布的台风年鉴上有与云图灰度相对应的近中心最大风速值。从历年情况来看,满足以上条件的样本数据较少,因此造成了一定的建模误差。为此,文中后续工作将考虑采用针对小样本数据具有一定优势的支持向量机、相关向量机等机器学习方法建立模型,以期提高建模精度。

4 结 论

文中根据台风眼区提取的要求,综合分析各类图像分割方法,采用基于测地活动轮廓模型的偏微分方程法提取台风眼区。实验结果表明该方法提取的眼壁准确性高,曲线光滑,为后续台风内核风速和云图灰度建模奠定了良好的基础。相比于国外购买昂贵的设备获取台风风场信息和目前普遍采用线性回归法的拟合效果,该模型只需利用卫星提供的台风云图和中国气象局上海台风研究所提供的年鉴数据,就可以得到较小的风速-灰度拟合误差。文中提出的方法对后续反演有眼台风内核风场具有重要的价值,下一步的工作拟将在此基础上反演台风二维表面风场。

参考文献:

- [1] Dvorak V F. Tropical cyclone intensity analysis and forecasting from satellite imagery [J]. *Monthly Weather Review*, 1975, 103(5): 420-430.
- [2] Wang Jin, Jiang Jixi. An objective technique for estimating tropical cyclone intensity from geostationary meteorological satellite observation [J]. *Journal of Applied Meteorological Science*, 2005, 16(3): 283-292. (in Chinese)
王瑾, 江吉喜. 热带气旋强度的卫星探测客观估计方法研究[J]. *应用气象学报*, 2005, 16(13): 283-292.
- [3] Kossin J P, Knaff J A, Berger H I, et al. Estimating hurricane wind structure in the absence of aircraft reconnaissance [J]. *Weather and Forecasting*, 2007, 22: 89-101.
- [4] Lu Xiaoqin, Lei Xiaotu, Yu Hui, et al. An objective TC intensity estimation method based on satellite data [J]. *Journal of Applied Meteorological Science*, 2014, 25 (1): 52-58. (in Chinese)
- [5] Gholamreza F, Abdollah H. Objective tropical cyclone intensity estimation using analogs of spatial features in satellite data [J]. *Weather and Forecasting*, 2013, 28 (6): 1446-1459.
- [6] Miguel F P, Elizabeth A R, Tyo J S. Estimating tropical cyclone intensity from infrared image data [J]. *Weather and Forecasting*, 2011, 26: 690-698.
- [7] Cheng Xi, Li Yan, Mao Kefeng, et al. Infrared cloud image typhoon center automatic position based on nonlinear optimal objective function [J]. *Journal of Tropical Meteorology*, 2013, 29(1): 155-160. (in Chinese)
陈希, 李妍, 毛科峰, 等. 基于非线性最优目标函数的红外云图台风中心自动定位 [J]. *热带气象学报*, 2013, 29(1): 155-160.
- [8] Kass M, Witriw A, Terzopoulos D. Snakes: active contour models[C]//In the first International Conference on Computer Vision, 1998, 1: 321-369.
- [9] Osher S, Sethian J. Fronts propagating with curvature-dependent speed: Algorithms based on Hamilton-Jacobi formulations [J]. *Journal of Computational Physics*, 1988, 79: 12-49.
- [10] Caselles V, Kimmel R, Sapiro G. Geodesic active contour [J]. *The International Journal of Computer Vision*, 1997, 22(1): 61-79.