

改进 PSO 的 SVM 回归模型及在气温预测中的应用^①



刘洋¹, 张鸿¹, 徐娟¹, 任余龙², 唐建新³

¹(甘肃省气象信息与技术装备保障中心, 兰州 730020)

²(中国气象局兰州干旱气象研究所 甘肃省防灾减灾重点实验室, 兰州 730020)

³(兰州理工大学计算机与通信学院, 兰州 730050)

通信作者: 张鸿, E-mail: 9463632@qq.com

摘要: 兰州市气温是一个非平稳序列, 具有典型噪声大、不稳定的特征, 气温变化越大, 越不稳定. 为了能够提高支持向量机在气温预测中的预测精度、强化泛化能力和降低参数选择的灵敏度. 本文提出了改进的粒子群算法(improved particle swarm optimization, IPSO) 优化支持向量机(support vector machine, SVM) 的气温预测模型. 首先在粒子群算法(particle swarm optimization, PSO) 中引入了自适应惯性权重以提高 PSO 算法的全局寻优能力和局部开发能力, 其次利用改进的 IPSO 算法优化 SVM 的惩罚因子和核函数参数, 将优化后的模型(IPSO-SVM) 应用于气温预测中. 以兰州地面观测站点实际数据作为样本数据, 运用 Matlab 实验工具进行训练和预测, 实验结果表明, 本文 IPSO-SVM 模型相比于 BP, SVM, GRID-SVM, GWO-SVM, ABC-SVM, ACO-SVM 模型具有更强的泛化能力, 更好的拟合度, 可以更加准确地预测气温的变化, 进一步验证了该模型在气温预测方面的可行性.

关键词: 粒子群算法; 支持向量机; 气温; 优化; 预测

引用格式: 刘洋, 张鸿, 徐娟, 任余龙, 唐建新. 改进 PSO 的 SVM 回归模型及在气温预测中的应用. 计算机系统应用, 2023, 32(9): 203-210. <http://www.c-s-a.org.cn/1003-3254/9225.html>

Improved PSO SVM Regression Model and Its Application in Temperature Prediction

LIU Yang¹, ZHANG Hong¹, XU Juan¹, REN Yu-Long², TANG Jian-Xin³

¹(Gansu Meteorological Information and Equipment Technical Support Center, Lanzhou 730020, China)

²(Key Laboratory of Arid Climatic Change and Reducing Disaster of Gansu Province, Institute of Arid Meteorology, China Meteorological Administration, Lanzhou 730020, China)

³(College of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: The temperature of Lanzhou City is a non-stationary sequence with typical characteristics of loud noise and instability. As the temperature changes greatly, the sequence gets unstable. In order to improve the prediction accuracy, strengthen the generalization ability, and reduce the sensitivity of parameter selection of support vector machine (SVM) in temperature prediction, in this study, the improved particle swarm optimization (IPSO) algorithm is proposed to optimize the temperature prediction model of SVM. Firstly, the adaptive inertia weight is introduced into the particle swarm optimization (PSO) algorithm to improve the global optimization ability and local development ability of the PSO algorithm. Secondly, the improved IPSO is used to optimize the penalty factor and kernel function parameter of the SVM, and the optimized model (IPSO-SVM) is applied to the temperature prediction. The actual data of Lanzhou ground observation station are taken as sample data, and Matlab experimental tools are used for training and prediction. The experimental results show that the IPSO-SVM model in this study has a stronger generalization ability and better fitting

① 基金项目: 国家自然科学基金 (62162040); 国家电网公司总部科技项目 (SGHE000KXJS1700074); 2022 年甘肃省气象信息与技术装备保障中心科技创新基金 (202201)

收稿时间: 2022-12-20; 修改时间: 2023-03-01; 采用时间: 2023-04-07; csa 在线出版时间: 2023-07-14

CNKI 网络首发时间: 2023-07-17

degree than back propagation (BP), SVM, GRID-SVM, GWO-SVM, ABC-SVM, and ACO-SVM. It can predict the change in temperatures more accurately, which further verifies the feasibility of this model in temperature prediction.

Key words: particle swarm optimization (PSO); support vector machine (SVM); temperature; optimization; prediction

天气现象与人们日常生活和各行各业息息相关,气象变化极为不稳定,容易受到各种气象因素的制约和相互影响,这使得天气现象的演化成为一个复杂多变,包含多种无法控制因素的过程,因此能够准确地预测气象要素一直充满着挑战^[1-3].

随着互联网技术、信息化技术以及气象观测技术的迅速发展,气象地面观测站点不断增多,观测频次从逐天逐时转变为逐分钟,同时天气雷达和气象卫星的发射使得高空层面的数据越来越多,气象数据的快速增长使得气象行业累积了海量的数据,气象行业数据多种多样,包括各类结构化、半结构化和非结构化数据,数据量已达到 PB 以上,具有典型的大数据特征^[4].

传统的气象预报模型是在各种基本假设成立的条件下完成的,基本假设决定了预报的准确率,当大量的基本假设不成立时,预测模型的效果将会很差,同时传统预报模型的另外一个缺点就是运算量非常大^[5].随着气象大数据的到来,我们可以利用巨大的气象数据集,分析不同气象要素之间的关联关系,降低预测模型中的基本假设,利用数据驱动模型进行天气现象的预测.目前,该模型已被广泛应用于各类气象要素的预测中^[6,7].

支持向量机 (support vector machine, SVM) 算法是一种通用的机器学习方法,它在小样本数据情况下求解速度快,预测精度高,能够避免过拟合、高维度等问题,由于该算法在非线性和高维度的复杂系统预测中表现出了许多特有的优势,因此被广泛使用,主要用途是分类和回归模型分析.目前,已被应用到人脸识别、邮件分类、故障诊断、各类预测等相关领域^[8-10].支持向量机算法主要是通过核函数进行计算,该算法对核函数和相关参数的初始化设置非常敏感,参数的不同设置会对最终的预测结果产生极大的影响,因此合适的参数选择一直是 SVM 研究的难点.群体智能优化算法在参数寻优方面具有较强的并行处理能力,能够平衡全局与局部搜索,寻优速度快,效果良好^[11].朱晶晶等人^[12]利用 1970-2014 年海南省全部市县的月平均资料,构建了 SVM 回归预测模型,实现了对气温的预测,结果表明 SVM 算法在气温短期预测中具有很好的效

果.杨通晓等人^[13]构建了 SVM 的雷达降水类型识别模型,是 SVM 分类模型的一种应用.在 SVM 中核函数采用径向基函数,同时利用 PSO 对核函数参数进行寻优,结果显示该方法有效地提高了雷达对流天气下降降水类型的识别精度.晋健等人^[14]为提升中长期预报的预测精度,以均方差作为目标函数构建了 FA-SVM 中长期径流预报模型,结果验证了 FA-SVM 模型的预测效果优于基本的 BP 神经网络模型.李纯斌等人^[15]选取了甘肃省作为研究对象,利用 BP 神经网络和 SVM 模型构建了降水量空间插值模型,结果显示 SVM 的插值精度模型明显地高于 BP 神经网络模型.史旭明等人^[16]以桂林市 13 个站点 24 h 降水量为研究对象,建立了改进的单站降水 SVM 回归集合预报模型,与 ECMWF 模式降水预报相比,该模型的预报精度显著提高.目前,利用群体智能算法对 SVM 相关参数进行寻优时,由于群体智能算法自身的缺陷导致 SVM 出现过拟合、泛化能力差、容易陷入局部最优等问题.

针对上述问题,本文从预测模型的参数优化方面进行了研究,提出了一种改进 PSO 算法优化 SVM 的气温预测模型,SVM 中两个参数的设置对预测模型影响很大,由于粒子群算法在后期寻优的过程中种群的多样性降低,容易陷入局部最优等问题,需要对 PSO 算法进行改进,本文采用了自适应的惯性权重,提高了该算法的全局搜索能力和寻优效率,利用改进后的 IPSO 算法对气温预测模型 SVM 进行寻优,实现了模型的优化选择,使得预测精度进一步提高.

1 IPSO-SVM 算法

1.1 支持向量机回归

支持向量机出现在 20 世纪 90 年代,是一种优秀的机器学习方法^[17],其基本思想是支持向量回归 (support vector regression, SVR) 将原始输入数据的空间映射到高维的特征空间上,实现了升维,将原始空间中的非线性回归问题进一步线性化,通过引入非线性的核函数来实现,即定义一个最优线性超平面,把寻找最优超平面的问题转化为一个求解最优解的问题,使得期望值

最小. 因此, 在特征空间中, 只需构造特征空间最优线性回归超平面. 如式 (1) 所示:

$$f(x) = w^T x + u \quad (1)$$

其中, x 表示样本集, w 表示最优超平面的法向量.

为了使得间隔最大化, 通过最小化 $\|w\|^2$ 寻找最优函数 $f(x)$, 对于每个训练数据能够容忍 $f(x)$ 与 y 之间最多有 ε 的误差, 为了能够允许异常值, 仅当 $f(x)$ 与 y 之差的绝对值大于 ε 时才计算损失, 大于 ε 的数据通过敏感损失函数来惩罚, 对每个约束条件加入拉格朗日乘子得到其对偶问题的显式表达, 从而得到不等式约束的优化问题, 该问题的优化需要满足 KKT 条件, 通过计算最佳权重的偏差, 利用方程输出预测值, 其最优化目标函数如式 (2) 和式 (3) 所示^[18,19]:

$$f(x_{\text{new}}) = u + \sum_i^n (a_i - a_i^*) \Phi(x_{\text{new}}, x_i) \quad (2)$$

$$u = y_i + \varepsilon - \sum_{\text{new}=1}^m (a_{\text{new}} - a_{\text{new}}^*) x_{\text{new}}^T x_i \quad (3)$$

式 (2) 中, x_{new} , x_i 表示 x 中的支持向量. n 表示支持向量的总个数, a_i , a_i^* 为拉格朗日乘子, $\Phi(x_{\text{new}}, x_i)$ 表示核函数; 式 (3) 中 y_i 为预测值, ε 为不敏感系数.

1.2 粒子群优化算法

粒子群算法是由 Kennedy 等人在 1995 年提出^[20], 该算法来源于自然界对鸟群捕食行为的模拟, 在问题对应的解空间中有多个不同的食物源, 而最大的食物源只有一个, 最大的食物源可以类比为解空间的全局最优解, 剩余的食物源可以类比为解空间的局部最优解, 鸟群的任务就是找到全局最优解, 在整个群体寻优的过程中, 利用群体中的个体相互传递和共享位置信息实现整个种群向最大食物源不断靠拢, 从而找到全局最优解. 在 PSO 中, 解空间的每一个解向量称为粒子, 每个粒子都具有两个属性, 即位置向量和速度向量, 位置向量用来计算当前粒子所处位置的适应度值, 该适应度值表示当前粒子的位置到全局最优解的距离. 速度向量决定了粒子下次飞行的方向和速度. 在每次寻优的过程中, 种群中的粒子可以根据自身的经验和种群中最优的粒子不断变换自己的飞行方向和速度, 从而使得整个种群向全局最优解靠近.

PSO 算法步骤如下.

(1) 种群初始化. 包括种群的大小, 初始粒子的位置和速度, 并计算每个粒子的适应度值, 确定个体最优粒子和全局最优粒子.

假设在一个 D 维搜索空间中, 有 N 个粒子组成一个群落, 其中第 i 个粒子表示为一个 D 维向量. 如式 (4) 所示:

$$X_i = (x_{i1}, x_{i2}, \dots, x_{iD}), i = 1, 2, \dots, N \quad (4)$$

第 i 个粒子的速度如式 (5) 所示:

$$V_i = (v_{i1}, v_{i2}, \dots, v_{iD}), i = 1, 2, \dots, N \quad (5)$$

同时记录每个粒子的最优解 p_{best} 和整个种群的最优解 g_{best} .

(2) 更新每个粒子自己的速度和位置, 并计算适应度值. 如果每个粒子的适应度值优于历史的适应度值, 更新粒子的位置和适应度值. 如果整个种群中最优适应度值优于当前全局最优适应度值, 更新全局最优粒子的位置和适应度值. 第 i 个粒子的速度和位置更新如式 (6) 和式 (7) 所示:

$$v_{(i+1)d} = wv_{id} + c_1 r_1 (p_{id} - x_{id}) + c_2 r_2 (p_{gd} - x_{id}) \quad (6)$$

$$x_{(i+1)d} = x_{id} + v_{(i+1)d} \quad (7)$$

其中, p_{id} 是个体已知最优解, p_{gd} 是种群已知最优解, w 为惯性权重, c_1 , c_2 为学习因子, r_1 , r_2 是 $[0, 1]$ 范围内的随机数.

(3) 判断算法收敛条件是否满足. 若满足, 则停止迭代, 输出结果; 否则跳转到第 2 步继续执行.

1.3 改进的粒子群优化算法

在 PSO 算法中, 惯性权重因子代表的是粒子继承上一次迭代速度的能力, 惯性因子参数的设置会严重影响 PSO 算法的全局和局部搜索能力. 由于 PSO 算法中惯性因子是固定的, 则会导致其收敛速度慢且容易陷入局部最优. 搜索初期, 需要一个较大的惯性权重因子进行全局寻优. 搜索后期, 需要一个较小的惯性权重因子进行局部搜索能力, 为了更好地平衡算法的全局和局部搜索能力, 本文设置了自适应的惯性权重因子 w , 如式 (8) 所示, 该参数可以随迭代次数的递增而变化, 改进后的算法称为 IPSO.

$$w(t) = (w_{\text{max}} - w_{\text{min}}) / \left(1 + \exp \left(\frac{15t}{T} - 8 \right) \right) + w_{\text{min}} \quad (8)$$

其中, w_{min} 表示初始的惯性权重值, w_{max} 表示最大迭代次数时的惯性权重值, T 表示最大迭代次数, t 代表当前迭代次数.

2 构建 IPSO-SVM 气温预测模型

2.1 数据来源和预处理

在天气预报、气候评估及气象服务等领域, 温压

湿风和能见度是最核心的观测要素,是计算其他相关指标的基础要素,也是社会大众最关注的天气信息;地面自动气象站的观测任务不一,这几个要素是普遍考核要素,各种尺度的天气现象由热力和动力条件配合而发生的,温压湿风可以定量地对热力和动力条件诊断分析,因此本文选取了兰州地面自动站观测数据作为研究样本,采集时间为2019年3月1日00时至2019年4月30日23时,每隔1h采集一次,采集要素为能见度,气压,相对湿度,风速,风向和气温,这些数据来源于甘肃省气象局气象大数据云平台API接口,其原始观测数据如表1所示,表1选取了部分数据。

表1 原始气象数据集

能见度	气压	相对湿度	风速	风向	气温
14721	842.6	28	1	44	19.5
13704	842.2	29	1.2	281	21.7
12949	841.1	39	1.1	328	22.7
13976	839.4	39	1.7	248	25.2
16153	838.1	36	1.7	113	27
⋮	⋮	⋮	⋮	⋮	⋮
16375	836.7	33	2.4	100	28.2

数据预处理主要包括两个方面,即数据清洗和原始数据归一化处理。

(1) 数据清洗。原始数据质量可以很大程度决定模型的预测结果,在保障数据质量的情况下研究预测模型才是有意义的,为了提高数据的质量和可用性,数据清洗是在数据被使用之前必不可少的环节。具体包括重复数据、异常值、空值等。本文编写了Java程序对重复数据进行删除,对原始数据进行异常检测,将检测到的异常值设置成空值,对空值采用领域平均法进行填补,清洗后的样本数据集共有1416条记录,每一条记录包含6个要素特征。

(2) 数据归一化。不同的气象要素有不同的单位,为了消除不同气象要素之间的量级对预测结果造成的影响,使得输入的数据处于同一个区间。本文采用最值归一化的方法对输入数据进行无量纲处理,将数值归一化到区间[0, 1]之间,在完成预测之后将预测值反归一化为原始值^[21]。数据归一化如式(9)所示:

$$\hat{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, i = 1, 2, \dots, n \quad (9)$$

其中, x_{\max} 和 x_{\min} 是清洗后数据集的每个气象要素的最大值和最小值, x_i 为第 i 个输入变量, \hat{x}_i 为归一化之后输出的变量。

2.2 IPSO-SVM 气温预测模型

本文选取了兰州地面自动站观测数据作为研究样本,利用采集的数据对IPSO-SVM气温预测模型进行训练和测试。本文选取样本的80%作为训练集,20%作为测试集。

IPSO-SVM气温预测模型建立主要包括两个方面,一是利用改进的IPSO算法优化SVM模型的惩罚因子 c 和核函数 g ,从而提高SVM模型对历史气温的预测精度;二是对IPSO-SVM气温预测模型预测性能进行评估,利用气温预测值和真实值之间的误差检验该模型的性能。IPSO-SVM气温预测模型步骤如下。

(1) 设定气温数据集并完成数据预处理。将历史气温数据划分为训练集和测试集,完成训练数据和测试数据归一化处理。

(2) 构造气温预测模型适应度函数 $f(c, g)$ 。使用气温真实值和预测值的均方误差 (mean square error, MSE) 作为气温适应度函数的返回值。适应度值大小反映的是气温预测模型的性能,值越小,预测性能越好,气温预测精度越高。

(3) IPSO-SVM算法种群初始化和参数设置。设置种群大小、最大迭代次数、种群维度、学习因子、惯性权重的范围和优化参数的个数。完成粒子位置和速度初始化。

(4) 利用第2步构造的气温适应度函数 $f(c, g)$ 计算种群中每个粒子的适应度值,保存全局最优解的位置和适应度值,以及个体最优解的位置和适应度值。

(5) 更新粒子速度和位置。粒子每次被更新之后,都需要重新计算粒子的适应度值。如果满足条件,则更新粒子全局最优解和个体最优解。

(6) 迭代优化。如果当前的迭代次数未达到设置的最大迭代次数,则继续执行步骤5,反之,则终止迭代,算法停止。

(7) 输出结果。当算法终止之后,IPSO-SVM算法输出参数 c 和 g 的组合最优值。

本文将能见度,气压,相对湿度,风速,风向这5个要素特征作为输入变量,利用最优组合 (c, g) 的SVM模型对气温进行预测,将气温的预测值作为输出变量,输出的气温值需要做反归一化处理。通过气温真实值和预测值之间的误差分析等其他指标评估该预测模型的性能。IPSO-SVM气温预测模型流程如图1所示,其伪代码如算法1。

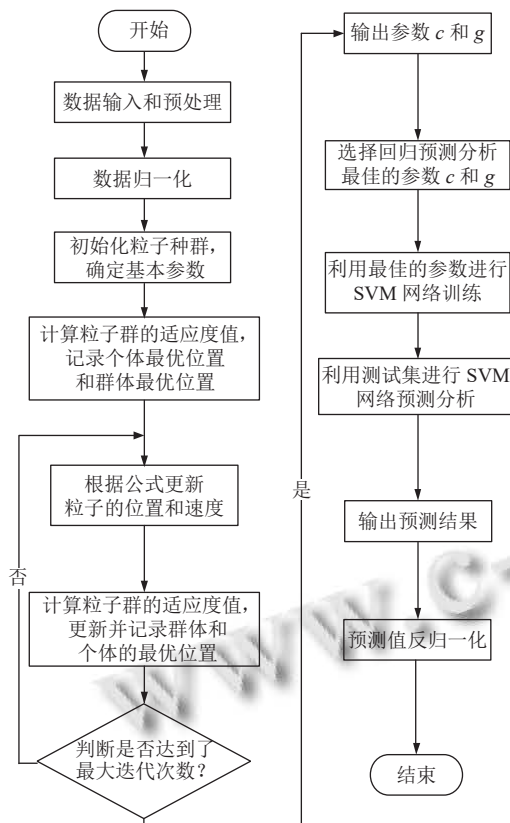


图1 IPSO-SVM 气温预测模型流程图

算法 1. IPSO-SVM 气温预测模型伪代码

```

1. for  $t < T$  do
2. 根据公式更新惯性权重因子
3. for  $i$  属于  $[1:N]$  do
4. 计算粒子的速度  $V_i$ 
5. 判断粒子速度是否越界
6. 更新粒子速度  $V_i$ 
7. 计算粒子的位置  $X_i$ 
8. 判断粒子的位置是否越界
9. 更新粒子的位置  $X_i$ 
10. 计算粒子的适应度值  $fitness(i)$ =均方误差评价函数  $MSE$ 
11. endfor
12. for  $i$  属于  $[1:N]$  do
13. if  $fitness(i) < fitness\_pbest(i)$  then
14.  $pbest(i, :) = init\_pop(i, :)$ 
15.  $fitness\_pbest(i) = fitness(i)$ 
16. endif
17. if  $fitness(i) < fitness\_gbest$  then
18.  $gbest = init\_pop(i, :)$ 
19.  $fitness\_gbest = fitness(i)$ 
20. endif
21. endfor
22. endfor
23. 打印最佳参数结果  $c = gbest(1)$ ,  $g = gbest(2)$ 
24. 输入 5 个要素变量组成的样本数据集

```

25. 利用最优参数 c 和 g 进行 SVM 网络训练和预测分析
26. 输出气温预测值, 进行误差分析和评估预测模型性能

3 实验结果及分析

3.1 实验环境

实验平台采用 Windows 7 操作系统, Intel(R) Core(TM) i7-7700HQ CPU @ 2.80 GHz, 8 核 CPU, 8 GB 内存, 500 GB SSD. 编程环境为 Matlab 2016, 开发工具采用 IntelliJ IDEA, IntelliJ IDEA 主要用于 Java 代码开发.

3.2 参数设置

实验中与 IPSO-SVM 模型对比的算法包括 BP、SVM、GRID-SVM、GWO-SVM、ABC-SVM、ACO-SVM. BP 中输入层神经元个数为 10, 隐含层神经元数为 8, 训练函数采用 traingdx, 学习率为 0.9, 训练次数为 50 000 次; SVM 中核函数采用 RBF, 损失函数 P 值为 0.01; GRID-SVM 中交叉验证的次数设置为 5, 网格大小为 10×10 , 间隔为 0.5, eps 的值为 0.001; 每个优化算法中种群大小 PopSize 设置为 30, 最大迭代次数 Max_iteration 设置为 100, 种群维度设置为 2, 寻优区间为 $[0.01, 100]$, ABC-SVM 中蜜源 (解) 数量设置为 15; ACO-SVM 中信息量权重设置为 2, 启发量权重设置为 2, 信息素挥发因子 $p=0.8$, 区间缩小因子 $r=0.8$; IPSO-SVM 中惯性权重的最大值设置为 $w_{max}=0.9$, 最小值 $w_{min}=0.4$, 加速因子 c_1 和 c_2 均设置为 1.5.

3.3 模型评价指标

为了评估预测模型的性能和精度, 本文选择均方根误差 $RMSE$ 、平均绝对误差 (mean absolute error, MAE) 和平均绝对百分比误差 (mean absolute percentage error, $MAPE$) 作为预测结果的评价指标. 计算公式如式 (10)–式 (12) 所示:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (10)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (11)$$

$$MAPE = \left(\frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \times 100\% \quad (12)$$

其中, N 为数据集的总个数, y_i 为气温实际观测值, \hat{y}_i 为预测气温值. $RMSE$, MAE , $MAPE$ 的值越小, 表明预测模型性能越好.

3.4 优化算法适应度分析

为了验证改进 IPSO 算法的寻优性能, 本文采用标准 PSO 和改进 IPSO 同时对 SVM 参数进行寻优, 其结果如图 2 所示.




图 2 不同算法迭代曲线

从图 2 可知, PSO 算法收敛速度较快, 在迭代的初期就开始收敛, 随着迭代次数的递增, 在第 18 次迭代左右时算法陷入了局部最优; 对于改进的 IPSO 算法, 随着迭代次数的增加, 在逐渐地向最优解靠近, 算法并没有出现早熟的现象, 这说明改进的 IPSO 具有更好局部探索 and 全局寻优能力, 并且收敛精度上要优于标准 PSO 算法.

3.5 IPSO-SVM 模型实验结果及分析


为了验证 IPSO-SVM 预测模型的有效性, 本文选取了 168 组连续样本数据作为模型的输入, 分别利用 SVM 和 IPSO-SVM 模型对预处理好的样本进行训练和测试, 得到如图 3(a) 和图 3(b) 的预测结果.

在图 3(a) 和图 3(b) 中, *代表实际气温值, 用黑色标记; □表示 SVM 算法预测的结果, 用蓝色标记; ○表示 IPSO-SVM 算法预测的结果, 用红色标记. 从图 3(a) 和图 3(b) 可知, 不论是在训练集还是在测试集上, 改进的 IPSO-SVM 模型的拟合效果明显优于 SVM 模型, IPSO-SVM 曲线变化与实际值的曲线变化更加吻合.


为了能够从预测精度方面对比两个模型的性能, 表 2 列出了 SVM 和 IPSO-SVM 的 $RMSE$, MAE , $MAPE$ 的性能指标, 同时为了能够分析每个算法的计算复杂度, 列出了每个算法的平均运行时长.

从表 2 可以看出, IPSO-SVM 气温预测模型的

$RMSE$, MAE , $MAPE$ 的预测指标值远优于 SVM, 与 SVM 预测模型相比, $RMSE$ 值降低了 4.5104, MAE 值降低了 3.9805, $MAPE$ 值降低了 0.2119. 由此可知改进的 IPSO-SVM 气温预测模型精度更高, 误差更小. 虽然 IPSO-SVM 气温预测模型较 SVM 模型的复杂度增加了很多, 但是针对气温预测这个问题, 多出的运行时间对整个预测模型的影响不大, 所以在合理的运行时间内 IPSO-SVM 气温预测模型的精度表现更佳.



(a) 训练集上的预测结果



(b) 测试集上的预测结果


图 3 预测结果

表 2 SVM 模型和 IPSO-SVM 模型的预测误差


预测模型	$RMSE$	MAE	$MAPE$	运行时间 (s)
SVM	5.7636	5.0722	0.2743	16.2385
IPSO-SVM	1.2532	1.0917	0.0624	464.9655

3.6 IPSO-SVM 模型与其他模型比较实验结果及分析

为了进一步验证 IPSO-SVM 模型在气温预测方面的有效性, 本文选取了 BP 神经网络^[22]、GRID-SVM 模型^[23], GWO-SVM 模型^[24]进行了对比, 其训练集和测试集上的拟合曲线如图 4(a) 和图 4(b) 所示.



(a) 其他算法在训练集上的预测结果



(b) 其他算法在测试集上的预测结果

+ IPSO-SVM 算法 × 实际气温数据 △ GWO-SVM 算法
* GRID-SVM 算法 ○ BP 算法

图4 其他算法的预测结果

由图4(a)和图4(b)可知,改进的IPSO-SVM模型在训练集和测试集上的拟合效果是最好的。BP模型在训练和测试的过程中波动比较大,特别是在转折点的预测上,预测值和真实值之间存在较大的误差。GRID-SVM模型在训练过程上的拟合效果要优于其在测试过程中的拟合效果。GWO-SVM模型的预测结果和真实之间的拟合程度与IPSO-SVM相对比较接近,但是在整体的预测过程,IPSO-SVM模型的拟合效果优于GWO-SVM。比如训练过程中,在10~30个数据点时,GWO-SVM预测出的气温值和实际值偏差较大。测试过程中,在70~85个数据点时,GWO-SVM预测出的气温值和实际值偏差也是较大。

为了验证改进IPSO-SVM气温预测模型的精度,将IPSO-SVM模型与其他气温预测模型进行对比,表3列出了BP神经网络、GRID-SVM、GWO-SVM、ABC-SVM^[25]、ACO-SVM^[26]和IPSO-SVM的RMSE,

MAE, MAPE的性能指标。同时为了能够分析每个算法的计算复杂度,列出了每个算法的平均运行时长。

表3 IPSO-SVM气温预测模型和其他预测模型的

预测模型	预测误差			运行时长 (s)
	RMSE	MAE	MAPE	
BP	5.8032	5.1952	0.2717	30.0812
GRID-SVM	5.6706	4.8012	0.2600	1245.4711
GWO-SVM	1.7497	1.4067	0.0804	201.4685
ABC-SVM	1.3156	1.2284	0.0701	547.0286
ACO-SVM	1.6882	1.3902	0.0798	798.4651
IPSO-SVM	1.2532	1.0917	0.0624	464.9655

从表3可以看出,IPSO-SVM气温预测模型的RMSE, MAE, MAPE预测指标值都是最优的,尤其是与BP和GRID-SVM相比,改进的IPSO-SVM预测模型的值远小于这两个算法, RMSE分别降低了4.5500/4.4174, MAE值分别降低了3.7885/3.7095, MAPE分别降低了0.2093/0.1976;同时与GWO-SVM预测模型和ACO-SVM相比, RMSE值降低了0.4965/0.4350, MAE值降低了0.3150/0.1367, MAPE值降低了0.018/0.0174。在所有比对算法中,ABC-SVM预测模型性能仅次于IPSO-SVM模型, RMSE值相差0.0624, MAE值相差0.1367, MAPE值相差0.0077,实验结果表明改进后的算法提高了模型的预测精度。这是因为在IPSO-SVM模型中IPSO算法采用了自适应的惯性权重 w , w 值会随着算法的迭代次数递增而变化,采用自适应的惯性权重使得PSO算法性能有了很大的提升。算法进化初期, w 值较大,种群的多样性好,有利于算法进行全局寻优,随着进化的不断演变,到进化的后期, w 值逐渐减小,有利于进行局部搜索,并且防止算法陷入局部最优,这种自适应的进化机制可以很好地平衡全局和局部寻优能力,加快算法的收敛速度。在算法的计算复杂度方面,运行时间最长的是GRID-SVM模型,这是因为该模型中含有交叉验证的过程,这个比较耗时。IPSO-SVM相对于BP模型和GWO-SVM模型而言运行时间稍长,但是对于气温预测这个问题,本文预测的是每小时的气温,则IPSO-SVM气温预测模型只要在一个小时内能运行出结果就不会影响在实际业务中的应用,所以这个运行时长是在合理的范围内,在合理的时间范围内IPSO-SVM预测模型的预测精度是最优的。

4 结束语

为了解决支持向量机在气温预测方面误差大、参

数选择灵敏等问题,本文提出了一种改进的IPSO优化SVM回归模型,并将该预测模型应用到气温预测研究中.为了提高预测样本数据的质量,首先对数据进行了预处理,删除重复数据、填充缺失数据及数据的归一化和反归一化操作;其次针对基本粒子群算法收敛速度慢,后期容易陷入局部最优的问题,对基本粒子群算法进行了改进并验证了其改进后的性能,改进的算法有效地提高了全局寻优能力、加快了算法的收敛速度;最后选取了兰州站点实际的观测数据,以RMSE、MAE和MAPE为评价指标,分别与BP模型、SVM模型、GRID-SVM模型、ABC-SVM模型、ACO-SVM模型、GWO-SVM模型的气温预测结果进行了对比分析,实验结果表明,IPSO-SVM模型预测精度更高,拟合度更好,验证了该模型在气温预测方面的可行性、有效性及应用价值.

参考文献

- 1 Maqsood I, Khan MR, Abraham A. An ensemble of neural networks for weather forecasting. *Neural Computing & Applications*, 2004, 13(2): 112–122. [doi: 10.1007/s00521-004-0413-4]
- 2 Haidar A, Verma B. Monthly rainfall forecasting using one-dimensional deep convolutional neural network. *IEEE Access*, 2018, 6: 69053–69063. [doi: 10.1109/ACCESS.2018.2880044]
- 3 程文聪, 史小康, 张文军, 等. 基于深度学习的数值模式降水产品降尺度方法. *热带气象学报*, 2020, 36(3): 307–316. [doi: 10.16032/j.issn.1004-4965.2020.029]
- 4 中国气象局. 中国气象大数据 (2018). 北京: 气象出版社, 2018. 3–29.
- 5 单大可. 基于深度学习的气温预测 [硕士学位论文]. 福州: 福建师范大学, 2018.
- 6 Reichstein M, Camps-Valls G, Stevens B, *et al.* Deep learning and process understanding for data-driven Earth system science. *Nature*, 2019, 566(7743): 195–204. [doi: 10.1038/s41586-019-0912-1]
- 7 马景奕, 刘维成, 闫文君. 基于深度学习的气象要素预测方法. *热带气象学报*, 2021, 37(2): 186–193. [doi: 10.16032/j.issn.1004-4965.2021.018]
- 8 郭飞, 谢立勇. 基于气象因素和改进支持向量机的空气质量指数预测. *环境工程*, 2017, 35(10): 151–155. [doi: 10.13205/j.hjgc.201710031]
- 9 宋玉生, 刘光宇, 朱凌, 等. 改进的灰狼优化算法在SVM参数优化中的应用. *传感器与微系统*, 2022, 41(9): 151–155. [doi: 10.13873/J.1000-9787(2022)09-0151-05]
- 10 张淑清, 张桂芬. 基于改进果蝇算法优化SVM的变速箱故障诊断. *组合机床与自动化加工技术*, 2022, (7): 71–74. [doi: 10.13462/j.cnki.mmtamt.2022.07.017]
- 11 李素, 袁志高, 王聪, 等. 群智能算法优化支持向量机参数综述. *智能系统学报*, 2018, 13(1): 70–84. [doi: 10.11992/tis.201707011]
- 12 朱晶晶, 赵小平, 吴胜安, 等. 基于支持向量机的海南气温预测模型研究. *海南大学学报(自然科学版)*, 2016, 34(1): 40–44. [doi: 10.15886/j.cnki.hdxzbkb.2016.0007]
- 13 杨通晓, 岳彩军. 基于支持向量机的双偏振雷达对流降水类型识别方法研究. *暴雨灾害*, 2019, 38(4): 297–302. [doi: 10.3969/j.issn.1004-9045.2019.04.001]
- 14 晋健, 刘育, 王琴慧, 等. 基于小波去噪和FA-SVM的中长期径流预报. *人民长江*, 2020, 51(9): 67–72. [doi: 10.16232/j.cnki.1001-4179.2020.09.013]
- 15 李纯斌, 刘永峰, 吴静, 等. 基于BP神经网络和支持向量机的降水量空间插值对比研究——以甘肃省为例. *草原与草坪*, 2018, 38(4): 12–19. [doi: 10.13817/j.cnki.cyycp.2018.04.002]
- 16 史旭明, 林汉燕, 金龙. 基于支持向量机的桂林短期定量降水预报方法研究. *桂林航天工业学院学报*, 2017, 22(2): 171–175. [doi: 10.3969/j.issn.1009-1033.2017.02.014]
- 17 Vapnik VN. *Statistical Learning Theory*. New York: Wiley Press, 1999.
- 18 陈永义, 熊秋芬. 支持向量机方法应用教程. 北京: 气象出版社, 2011.
- 19 张梁. 基于ARIMA-SVR组合模型的北京市气温预测研究 [硕士学位论文]. 大连: 大连理工大学, 2020.
- 20 Kennedy J, Eberhart R. Particle swarm optimization. *Proceedings of the 1995 International Conference on Neural Networks*. Perth: IEEE, 1995. 1942–1948.
- 21 朱昶胜, 李岁寒. 基于改进果蝇优化算法的随机森林回归模型及其在风速预测中的应用. *兰州理工大学学报*, 2021, 47(4): 83–90. [doi: 10.3969/j.issn.1673-5196.2021.04.013]
- 22 陶晔, 杜景林. 基于随机森林的长短期记忆网络气温预测. *计算机工程与设计*, 2019, 40(3): 737–743. [doi: 10.16208/j.issn1000-7024.2019.03.024]
- 23 张舒雅. 基于网格寻参优化SVM-KNN算法的老人跌倒检测研究 [硕士学位论文]. 武汉: 华中师范大学, 2017.
- 24 何祖杰, 吴新焱, 刘中华. 基于改进灰狼算法优化支持向量机的短期交通流预测. *厦门大学学报(自然科学版)*, 2022, 61(2): 288–297. [doi: 10.6043/j.issn.0438-0479.202104024]
- 25 Karaboga D, Basturk B. A powerful and efficient algorithm for numerical function optimization: Artificial bee colony (ABC) algorithm. *Journal of Global Optimization*, 2007, 39(3): 459–471. [doi: 10.1007/s10898-007-9149-x]
- 26 Dorigo M, Stützle T. The ant colony optimization metaheuristic: Algorithms, applications, and advances. In: Glover F, Kochenberger GA, eds. *Handbook of Metaheuristics*. Boston: Springer, 2001. 250–285. [doi: 10.1007/0-306-48056-5_9]

(校对责编: 孙君艳)