

DOI: 10.13382/j.jemi.B2003255

改进灰狼算法优化支持向量机的网络流量预测*

杨晓敏

(运城学院 数学与信息技术学院 运城 044000)

摘要:高精度网络流量预测是现代网络智能管理的基础,针对支持向量机在网络流量预测建模过程中的参数优化难题,以改善网络流量预测结果为目标,提出了改进灰狼算法优化支持向量机的网络流量预测模型。首先收集网络流量历史数据,并对数据进行相空间重构、归一化等预处理,然后引入改进灰狼算法快速搜索到全局最优支持向量机的相关参数,并根据最优参数对预处理后的网络流量历史数据进行学习,建立能够挖掘网络流量历史数据包含变化规律的预测模型,最后与其他算法优化支持向量机的网络流量预测模型进行了对比分析。结果显示,改进灰狼算法优化支持向量机的网络流量预测精度超过 90%,远高于对比模型,且预测建模过程的建模时间少于对比模型,可以满足网络流量管理的高精度和实时性的要求。

关键词: 现代网络;改进灰狼算法;相空间重构;历史样本数据;支持向量机;全局最优参数

中图分类号: TP273 **文献标识码:** A **国家标准学科分类代码:** 510.50

Improved gray wolf algorithm to optimize support vector machine for network traffic prediction

Yang Xiaomin

(Maths & Information Technology School, Yuncheng University, Yuncheng 044000, China)

Abstract: High precision network traffic prediction is the basis of modern network intelligent management. Targeting at the problem of parameter optimization of SVM in the process of network traffic prediction modeling to improve the network traffic prediction results, this paper proposes the network traffic prediction model of SVM optimized by Improved Gray Wolf algorithm. Firstly, collect the historical data of network traffic, and preprocess the data with phase space reconstruction and normalization, then introduce the improved gray wolf algorithm to quickly search the relevant parameters of the global optimal support vector machine, and learn the historical data of network traffic after preprocessing according to the optimal parameters, and establish a prediction model that can mine the history data of network traffic including the law of change after that, the network traffic prediction model of SVM optimized by other algorithms is compared and analyzed. The results show that the prediction accuracy of the improved gray wolf algorithm optimized support vector machine is more than 90%, much higher than the compared model, and the training time of the prediction modeling process is less than the compared model, which can meet the requirements of high accuracy and real-time network traffic management.

Keywords: modern network; improved gray wolf algorithm; phase space reconstruction; historical sample data; support vector machine; global optimal parameters

0 引言

随着网络技术的不断普及,网络用户数量越来越多,网络规模和应用日益复杂,网络上的业务种类也不断增加,使得网络流量急剧增加,网络阻塞时有发生,网络上

信息丢失和延迟严重,给网络管理带来了挑战^[1-3]。网络流量是一种评价网络管理质量的重要参数,根据历史数据集对网络流量进行建模与预测,可以帮助网络管理员掌握网络流量的变化规律,改善网络服务质量。精确、快速的网络流量预测是降低网络堵塞的重要保障,因此网络流量预测一直是网络领域的一个重要的研究方向^[4-5]。

由于国内外学者的共同努力,当前存在许多网络流量预测模型,这些模型大致可以划分为两类:1) 基于传统统计学理论的线性预测模型,代表的建模方法主要有分数差分自回归滑动平均模型,由于现代网络是一个复杂的非线性系统,网络流量变化趋势具有不确定性,因此线性模型的网络流量预测精度难以得到保证^[6-8];2) 基于现代统计学理论的非线性预测模型,主要建模方法有人工神经网络、支持向量机(SVM),它们具有良好的非线性拟合能力,可以对网络流量变化趋势的非线性和不确定性进行建模,使得网络流量预测结果要好于线性模型^[9-11]。在实际应用中,人工神经网络由于采用经验风险最小化原则的学习原理,收敛速度慢,陷入局部极值的概率相当高,经常获得“过拟合”的网络流量预测结果,降低了网络流量预测精度^[12-14]。支持向量机基于结构风险最小化准则的学习原理,不存在收敛速度慢,陷入局部极值的缺陷,然而其网络流量预测结果受到惩罚因子和核函数核宽的影响大,当前主要采用网格搜索方法、遗传算法(GA)、粒子群优化算法(PSO)对支持向量机参数进行优化,但是这些算法容易陷入局部最优解,无法获得最优的惩罚因子和核函数核宽度^[15-17]。

灰狼算法(grey wolf optimizer, GWO)是一种模拟狼群捕食行为和层级制度特点的新型群智能算法,调整参数少,收敛速度快,针对支持向量机在网络流量预测建模过程中的参数优化难题,以改善网络流量预测结果为目标,提出了改进灰狼算法优化支持向量机的网络流量预测模型,并与其他算法优化支持向量机的网络流量预测模型进行了对比分析。

1 支持向量机和改进灰狼算法

1.1 支持向量机

设训练样本集合为 $T = \{(x_1, y_1), (x_1, y_1), \dots, (x_n, y_n)\}$, n 表示训练样本的数量,支持向量机对训练样本进行学习,建立描述输入变量与输出之间关系的函数,具体如下:

$$f(x_i) = \omega^T \phi(x_i) + b \quad (1)$$

式中: $\phi(x_i)$ 表示映射函数; ω 表示权值向量; b 表示阈值向量。

定义不敏感损失函数为:

$$l_\varepsilon = \begin{cases} 0, & |z| \leq \varepsilon \\ |z| - \varepsilon, & \text{其他} \end{cases} \quad (2)$$

基于不敏感损失函数,那么式(1)可以转化为求解极小化目标函数问题,即:

$$g(x) = \min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n l_\varepsilon(f(x_i) - y_i) \quad (3)$$

式中: C 为惩罚因子。

引入松弛变量,式(3)变为:

$$\min_{\omega, b, \xi_i, \xi_i^*} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (4)$$

s. t.

$$\begin{cases} f(x_i) - y_i \leq \varepsilon + \xi_i \\ y_i - f(x_i) \leq \varepsilon + \xi_i^* \end{cases}$$

对式(4)直接进行求解十分复杂,为了简化其求解过程,引入拉格朗日乘子 α_i, α_i^* , 建立如下的拉格朗日函数:

$$\omega, b, \alpha, \alpha^*, \xi, \xi^* = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i - y_i + f(x_i)) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* - y_i + f(x_i)) \quad (5)$$

联立式(1)和(5),并对 ω, b 以及 ξ, ξ^* 求偏导,得到:

$$\omega = \sum_{i=1}^n (\alpha_i^* - \alpha_i) \phi(x_i) \quad (6)$$

$$0 = \sum_{i=1}^n (\alpha_i^* - \alpha_i) \quad (7)$$

可以得到:

$$W(\alpha, \alpha^*) = \max_{\alpha, \alpha^*} \sum_{i=1}^n y_i (\alpha_i^* - \alpha_i) - \varepsilon (\alpha_i^* + \alpha_i) - \sum_{i=1}^n \sum_{j=1}^n (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) \phi(x_i)^T \phi(x_j) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i - y_i + f(x_i)) \quad (8)$$

引入核函数代替积运算 $\phi(x_i)^T \phi(x_j)$, 可以得到支持向量机的预测决策函数为:

$$f(x) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) k(x, x_i) + b \quad (9)$$

式中: $k(x, x_i)$ 为核函数。

$$k(x, x_i) = \exp(-\|x_i - x\| / 2\sigma^2) \quad (10)$$

1.2 改进灰狼算法

1) GWO 算法

在灰狼群体中,具有严格的社会等级关系,可以划分为 $\alpha, \beta, \delta, \omega$ 4 个等级,如图 1 所示。图 1 中, α 狼为头狼,代表最优解, β 狼为协助者,代表次优解, δ 狼服从 α, β 的命令,代表第 3 优解, ω 狼没有自主决策能力,代表其余候选解。

设灰狼种群共有 N 个个体,第 i 只灰狼的位置为 $X_i = (X_i^{(1)}, X_i^{(2)}, \dots, X_i^{(D)})$, D 表示搜索空的 D 维,狼群主要包括包围行为和捕猎行为。

(1) 包围行为。当灰狼发现猎物,其与猎物之间的距离为 D ,狼群就对猎物进行包围,具体描述方式为:

$$D = |C \cdot X_p(t) - X(t)| \quad (11)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (12)$$

式中: X_p 和 X 分别表示猎物和位置向量; A 和 C 为系数

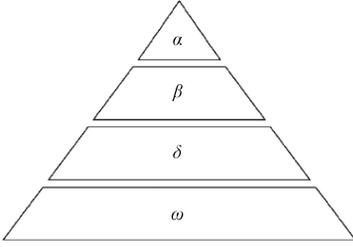


图1 灰狼社会等级划分

Fig.1 Social hierarchy of gray wolf

向量。

$$\begin{cases} \mathbf{A} = 2a(\mathbf{r}_1 - 1) \\ \mathbf{C} = 2\mathbf{r}_2 \end{cases} \quad (13)$$

式中： $\mathbf{r}_1, \mathbf{r}_2$ 为随机向量； a 为收敛因子。

$$a = 2 - 2 \cdot \frac{t}{t_{\max}} \quad (14)$$

式中： t_{\max} 为最大迭代次数。

(2) 捕猎行为。灰狼将猎物包围后，灰狼由 α, β, δ 带领不断靠近猎物， $X_\alpha, X_\beta, X_\delta$ 表示 α, β, δ 相对于猎物的位置， $\mathbf{A}_i, \mathbf{C}_i$ 表示系数向量， α, β, δ 位置更新方式为：

$$\begin{cases} D_\alpha = |C_1 X_\alpha(t) - X(t)| \\ D_\beta = |C_2 X_\beta(t) - X(t)| \\ D_\delta = |C_3 X_\delta(t) - X(t)| \end{cases} \quad (15)$$

$$\begin{cases} X_1(t+1) = X_\alpha(t) - A_1 D_\alpha \\ X_2(t+1) = X_\beta(t) - A_2 D_\beta \\ X_3(t+1) = X_\delta(t) - A_3 D_\delta \end{cases} \quad (16)$$

$$X(t+1) = \frac{X_1(t+1) + X_2(t+1) + X_3(t+1)}{3} \quad (17)$$

2) 灰狼算法的不足及改进

灰狼根据式(16)和(17)不断调整其与猎物的方向和距离，最后 α 所在位置为问题的最优解。在实际应用中，灰狼算法亦存在一定的不足，如：收敛速度较慢，容易陷入局部最优解，难以收敛到全局最优解。为此对灰狼算法进行改进。

(1) 自适应收敛因子。灰狼算法的求解结果与 A 的值相关，而且 A 的取值与收敛因子 a 密切相关。传统灰狼算法的 a 采用线性递减方式，易陷入局部最优解，为此本文利用 Sigmoid 函数的特点，将其引入到收敛因子更新过程中，具体如下：

$$a = a_{\max} - \left[1 + \exp\left(-\frac{t}{t_{\max}}\right) \right]^{-1} \quad (18)$$

式中： t_{\max} 表示迭代最大次数。

从式(18)可知，随着迭代次数的增加， a 值呈非线性减小，可以发现多个潜在最优解。

(2) 灰狼位置更新公式改进。引入惯性权重对灰狼位置进行更新，提高灰狼跳出局部最优值的陷阱，具体如下：

$$X(t+1) = \varphi X(t) - AD \quad (19)$$

式中： φ 为惯性权重。

$$\varphi(t+1) = \varphi_{\max} - (\varphi_{\max} - \varphi_{\min}) \cdot \frac{t}{t_{\max}} \quad (20)$$

1.3 改进灰狼算法的性能测试

为测试改进灰狼算法的性能，选择传统灰狼算法进行对比测试，采用3个标准测试函数作为测试对象，它们具体如下：

$$f_1(x) = \sum_{i=1}^n x_i^2 \quad (21)$$

$$f_2(x) = 1/4 \ 000 \sum_{i=1}^n (x_i)^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1 \quad (22)$$

$$f_3(x) = \sum_{i=1}^{n-1} (100(x_{i+1} - x_i)^2 + (x_i - 1)^2) \quad (23)$$

改进灰狼算法和传统灰狼算法的性能对比结果如图2所示。从图2可以看出，相对于传统灰狼算法，改进灰狼算法的收敛精度上有了很大的提高，收敛速度更快，验证了对传统灰狼算法改进的有效性和优越性。

2 改进灰狼算法优化支持向量机的网络流量预测模型

2.1 相空间重构

网络流量具有一定的混沌变化特性，是一种典型的时间序列数据，因此需要通过引入相空间重构技术得到合适的嵌入维数 m 和延迟变量 τ ，对网络流量时间序列进行重构，提高网络流量预测精度。设网络流量时间序列为： x_1, x_2, \dots, x_n ， n 表示时间序列的长度，那么根据 m 和 τ 可以得到：

$$D_i = [d_i, d_{i+\tau}, \dots, d_{i+(m-1)\tau}] \quad (24)$$

式中： $i = 1, 2, \dots, N - (m - 1) \tau$ 。

当前确定嵌入维数 m 和延迟变量 τ 的方法很多，本文选择 C-C 算法选择 m 和 τ ，取 $m = 1, 2, \dots, k, n = 1, 2, \dots, j, r_i = i \times 0.5\sigma, \sigma$ 表示时间序列的标准差，C-C 算法的参数计算公式为：

$$\bar{S}(t) = \frac{1}{j \times j} \sum_{m=2}^k \sum_{i=1}^j S(m, r_i, t) \quad (25)$$

$$\Delta \bar{S}(t) = \frac{1}{j} \sum_{m=2}^k \Delta S(m, t) \quad (26)$$

$$S_{\text{cor}}(t) = \Delta \bar{S}(t) + |\bar{S}(t)| \quad (27)$$

当 $\Delta \bar{S}(t)$ 达到第一个局部极小值时，其对应的 τ 就是最优延迟时间 τ ，根据 $S_{\text{cor}}(t)$ 的局部极小值得到最佳嵌入窗 τ_w ，然后根据式(28)计算最佳的嵌入维数 m_c 。

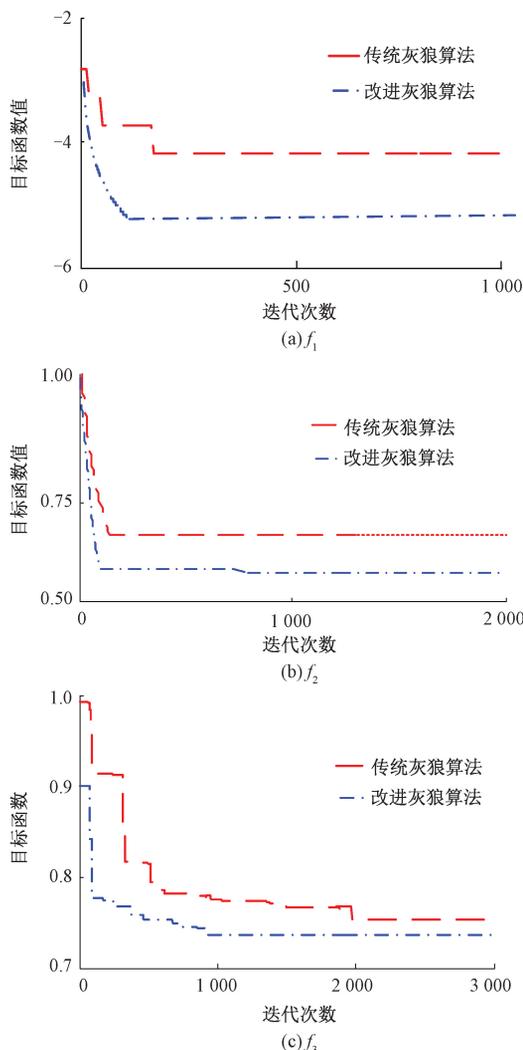


图 2 改进灰狼算法和传统灰狼算法的性能对比
Fig. 2 performance comparison between improved gray wolf algorithm and traditional gray wolf algorithm

$$\tau_w = (m - 1) \tau \tag{28}$$

根据相空间重构,可以得到一个多维的网络流量时间数据,便于后继的支持向量机建模。

2.2 支持向量机参数优化数学模型

在支持向量机的网络流量建模过程中,惩罚参数 C 和核参数至关重要,直接影响到网络流量的预测精度,以提高网络流量预测精度为目标,建立支持向量机的网络流量预测参数优化数学模型,即:

$$\begin{aligned} & \text{Max}_{i=1}^k (G(C_i, \sigma_i)) \\ & \text{s. t.} \\ & \begin{cases} C_i \in \{C_{\max}, C_{\min}\} \\ \sigma_i \in \{\sigma_{\max}, \sigma_{\min}\} \end{cases} \end{aligned} \tag{29}$$

式中: k 表示参数组数。

本文引入改进灰狼算法对式(29)进行求解,找到最

优参数 C, σ 。

2.3 改进灰狼算法优化支持向量机的网络流量预测模型构建

- 1) 收集描述网络流量变化的历史数据,它们根据时间前后组成一维时间序列数据。
- 2) 采用相空间重构技术中的 C-C 算法确定最佳嵌入维数和延迟变量。
- 3) 根据最佳嵌入维数和延迟变量得到一个多维的网络流量时间序列数据。
- 4) 从多维的网络流量时间序列数据中选择部分数据组成训练样本,其它数据为测试样本。
- 5) 初始化狼种群群,确定 C, σ 的取值范围。
- 6) 确定灰狼种群的适应度函数,并将其值作为猎物位置,根据灰狼算法的工作原理,寻找到最优函数值,即猎物的最优位置。
- 7) 根据猎物最优位置得到参数 C, σ 的最优值。
- 8) 根据最优参数 C, σ 对支持向量机进行训练,根据训练精度建立网络流量预测模型。
- 9) 输入测试样本,网络流量预测模型输出测试样本预测值,具体流程如图 3 所示。

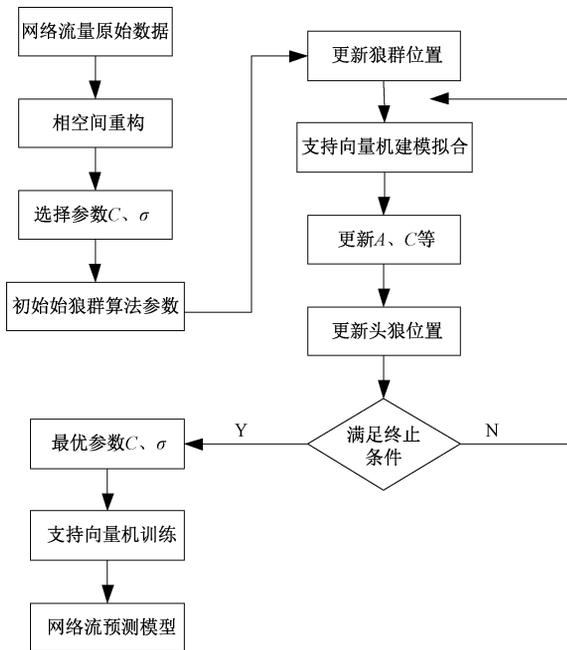


图 3 改进灰狼算法优化支持向量机的网络流量预测流程
Fig. 3 Improved gray wolf algorithm optimizes the network traffic prediction process of SVM

3 网络流预测的实例分析

3.1 实验数据

为了验证改进灰狼算法优化支持向量机的网络流量预测的有效性,选取某服务器的一段时间的网络流量作

为实验对象,如图4所示。为了证明改进灰狼算法优化支持向量机的网络流量预测结果的优越性,选择经典模型:粒子群算法优化支持向量机的网络流量预测模型、遗传算法优化支持向量机的网络流量预测模型进行对比实验。所有模型均选择100个样本作为测试样本,其他样本作为训练样本。网络流量预测建模的仿真软件为MATLAB R2017。

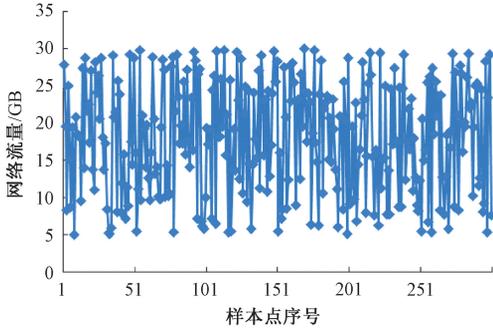


图4 原始网络流量的时间序列

Fig. 4 Time series of original network traffic

采用C-C方法对原始网络流量的时间序列进行相空间重构, $\bar{\Delta S}(t)$ 和 $S_{cor}(t)$ 的变化曲线如图5和6所示。从图5可以看出,当 $\bar{\Delta S}(t) = 3$ 时,得到了第1个局部极小值,那么延迟变量 $\tau = 3$,同时 $S_{cor}(t) = 12$ 时,得到了第一个局部极小值,根据式(28)得到嵌入维数 $m = 7$ 。采用 $\tau = 3$ 和 $m = 7$ 对原始网络流量的时间序列进行重构,用于支持向量机建模。

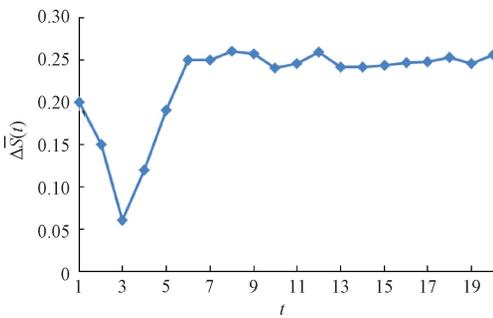


图5 $\bar{\Delta S}(t)$ 的变化曲线

Fig. 5 Change curve of $\bar{\Delta S}(t)$

3.2 支持向量机参数确定

采用粒子群算法、遗传算法和改进灰狼算法优化支持向量机参数 C, σ , 每种算法的种群数量均为20, 迭代次数为500, 找到最优参数的迭代次数如表1所示, 从表1可以看出, 改进灰狼算法的迭代次数要少于粒子群算法和遗传算法, 加快了支持向量机参数寻优的速度。

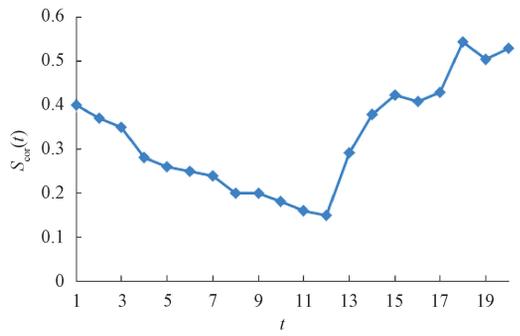


图6 $S_{cor}(t)$ 的变化曲线

Fig. 6 Change curve of $S_{cor}(t)$

表1 不同算法的支持向量机优化参数
Table 1 SVM optimization parameters of different algorithms

算法名称	C	σ	找到最优参数的迭代次数
粒子群算法	100.78	1.972	213
遗传算法	219.52	9.745	227
改进灰狼算法	190.24	4.006	205

3.3 网络流量预测结果对比

每一种模型均进行了5次仿真实验,每一次实验随机选择100个测试样本,3种模型的网络流量预测结果如图7所示,对图7的网络流量预测结果进行对比分析可以发现,遗传算法优化支持向量机的网络流量预测偏差比较大,其次为粒子算法优化支持向量机,网络流量预测效果最优者为改进灰狼算法优化支持向量机,可以较准确地描述网络流量的变化趋势,得到了更高精度的网络流量预测结果,这对于提高网络管理服务质量具有重要的意义,这主要是由于改进灰狼算法找到了更优的支持向量机参数,建立了更加理想的网络流量预测模型,实验结果验证了本文模型的优越性。

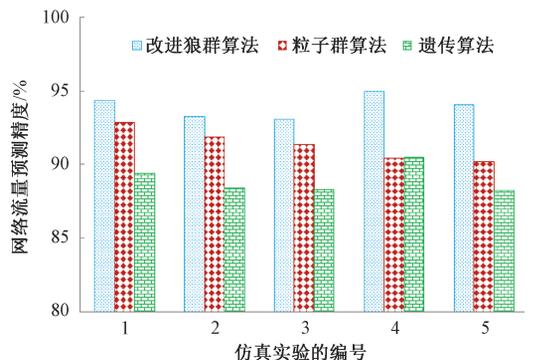


图7 不同模型的网络流量预测结果对比

Fig. 7 comparison of network traffic prediction results of different models

3.4 网络流量建模效率对比

在4核 Intel 2.75 GHz, 32 GB RAM, Win10 的平台上

统计网络流量的训练时间和预测时间,结果如表 2 所示。从表 2 可以看出,改进灰狼算法的网络流量预测时间与粒子群算法、遗传算法相差无几,但是训练时间要明显少于粒子群算法和遗传算法,这表明改进灰狼算法优化支持向量机的网络流量预测复杂性没有增加,提高了网络流量预测建模效率。

表 2 不同模型的训练时间和预测时间

Table 2 training time and prediction time of different models (s)

模型名称	练时间	预测时间
粒子群算法优化支持向量机	30.25	0.167
遗传算法优化支持向量机	47.19	0.180
改进灰狼算法优化支持向量机	28.36	0.166

4 结 论

针对支持向量机在网络流量建模过程中参数优化问题,结合灰狼算法收敛速度快,全局和局部搜索能力强的优点,为了更加准确的对网络流量进行建模和预测,提出了改进灰狼算法优化支持向量机的网络流量预测模型,并通过应用实例得到如下结论。

1) 网络流量的变化是多种因素共同影响的结果,引入相空间重构可以更好的描述原始网络流量数据的变化趋势,同时更加有利于后续支持向量机的学习,可以有效改善网络流量预测结果。

2) 对标准灰狼算法的缺陷进行改进,可以提高灰狼算法的收敛速度,减少了陷入局部极值的概率,寻优耗时短,能够快速,有效的找到支持向量机参数,在提高网络流量预测精度的同时,可以满足网络流量预测的实时性要求。

3) 与其他算法优化的支持向量机相比,改进灰狼算法优化支持向量机的网络流量预测误差更小,网络流量预测误差控制在实际应用的有效区间内,网络流量预测精度提高了约 5%,更加适合网络流量的建模与分析,具有良好的应用前景。

参考文献

[1] 郭丽,刘磊. 基于多层感知器的流量分类方法研究[J]. 电子测量与仪器学报,2019,33(7):56-64.
GUO L, LIU L. Research on refined classification method based on multilayer perceptron [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(7):56-64.

[2] 翟建丽,王映丽. 基于模糊聚类的网络异常流量检测算法研究[J]. 电子测量技术,2019,42(16):172-176.
ZHAI J L, WANG Y L. Research on network anomaly detection algorithm based on fuzzy clustering [J]. Electronic Measurement Technology, 2019, 42(16):

172-176.

[3] 郭佳,余永斌,杨晨阳. 基于全注意力机制的多步网络流量预测[J]. 信号处理,2019,35(5):758-767.
GUO J, YU Y B, YANG CH Y. Multi-step prediction of traffic load with all-attention mechanism [J]. Journal of Signal Processing, 2019, 35(5):758-767.

[4] BUI N, WIDMER J. Data-driven evaluation of anticipatory networking in LTE network [J]. IEEE Trans. Mobile Computer, 2018, 17(10):2252-2265.

[5] LI R, ZHAO Z, ZHENG J, et al. The learning and prediction of application-level traffic data in cellular networks [J]. IEEE Transactions on Wireless Communications, 2017, 16(6):3899-3912.

[6] 李莹琦,黄越,孙晓川. 基于深度置信回声状态网络的网络流量预测模型[J]. 南京邮电大学学报(自然科学版),2018,38(5):85-90.
LI Y Q, HUANG Y, SUN X CH. Network traffic prediction model based on deep belief echo-state network[J]. Journal of Nanjing University of Posts and Telecommunications, 2018,38(5):85-90.

[7] 林志达,吕华辉. 小波系数感知的网络流量预测机制[J]. 太赫兹科学与电子信息学报,2019,17(1):131-135.
LIN ZH D, LV H H. Wavelet coefficient aware network traffic prediction [J]. Journal of Terahertz Science and Electronic Information Technology, 2019, 17(1):131-135.

[8] 李松,周亚同,池越,等. 高斯过程混合模型应用于网络流量预测研究[J]. 计算机工程与应用,2020,56(5):186-193.
LI S, ZHOU Y T, CHI Y, et al. Application of Gaussian process mixture model on network traffic prediction [J]. Computer Engineering and Applications, 2020, 56(5):186-193.

[9] 李校林,吴腾. 基于 PF-LSTM 网络的高效网络流量预测方法 [J]. 计算机应用研究,2019,36(12):3833-3836.
LI X L, WU T. Efficient network traffic prediction method based on PF-LSTM network [J]. Application Research of Computers,2019,36(12):3833-3836.

[10] 任师涛,史志才,吴飞,等. 基于改进 BP 神经网络的路由器流量预测方法[J]. 传感器与微系统,2018,37(8):49-50,54.
REN SH T, SHI ZH C, WU F, et al. Router traffic forecasting method based on improved BP neural network [J]. Transducer and Microsystem Technology, 2018, 37(8):49-50,54.

[11] 林振荣,黎嘉诚,杨冬芹,等. 改进微分进化和小波神经网络的网络流量预测[J]. 计算机工程与设计,

- 2019, 40(12): 3413-3418.
- LIN ZH R, LI J CH, YANG D Q, et al. Network traffic prediction based on wavelet neural network with improved differential evolution algorithm [J]. Computer Engineering and Design, 2019, 40(12): 3413-3418.
- [12] 张沫,郑慧峰,倪豪,等. 基于遗传算法优化支持向量机的超声图像缺陷分类[J]. 计量学报, 2019, 40(5): 887-892.
- ZHANG M, ZHENG H F, NI H, et al. Ultrasonic image defect classification based on support vector machine optimized by genetic algorithm [J]. Acta Metrologica Sinica, 2019, 40(5): 887-892.
- [13] 隋修武,刘乃嘉,乔明敏,等. 基于 PSO-SVM 的仿生肌电假手反馈控制系统设计[J]. 传感技术学报, 2019, 32(12): 1784-1789.
- SUI X W, LIU N J, QIAO M M, et al. Design of Prosthesis Feedback Control System Based on PSO-SVM [J]. Chinese Journal of Sensors and Actuators, 2019, 32(12): 1784-1789.
- [14] 李麟玮,吴益平,苗发盛. 基于灰狼支持向量机的非等时距滑坡位移预测[J]. 浙江大学学报(工学版), 2018, 52(10): 1998-2006.
- LI L W, WU Y P, MIAO F S. Prediction of non-equidistant landslide displacement time series based on grey wolf support vector machine[J]. Journal of Zhejiang University(Engineering Science), 2018, 52(10): 1998-2006.
- [15] 魏臻,陈颖,程磊. 基于 VMD-DE 的混沌网络流量组合预测研究[J]. 合肥工业大学学报(自然科学版), 2019, 42(12): 1625-1629, 1671.
- WEI ZH, CHEN Y, CHENG L. Research on VMD-DE based combined model for chaotic network traffic prediction [J]. Journal of Hefei University of Technology (Natural Science), 2019, 42(12): 1625-1629, 1671.
- [16] SAPANKEVYCH N I, SANKAR R. Time Series Prediction Using Support Vector Machines: A survey [J]. IEEE Computational Intelligence Magazine, 2009, 4(2): 24-38.
- [17] 焦晓璇,景博,李娟,等. 基于 ADEGWO-SVM 的机载燃油泵寿命预测研究[J]. 仪器仪表学报, 2018, 39(8): 43-52.
- JIAO X X, JING B, LI J, et al. Research on life prediction of airborne fuel pump based on ADEGWO-SVM [J]. Chinese Journal of Scientific Instrument, 2018, 39(8): 43-52.

作者简介



杨晓敏, 2009 年于长安大学获得硕士学位, 现运城学院讲师, 主要研究方向为人工智能。

E-mail: yangxiaom2004251@sina.com

Yang Xiaomin received her M. Sc. degree from Chang'an University in 2009.

Now she is lecturer at Yuncheng University. Her main research interest include artificial intelligence.