

# 基于 GWO-SVM 模型的股票市场风险预警研究

张鹤立<sup>1</sup>, 淳伟德<sup>1</sup>, 淳正杰<sup>2</sup>, 蒲俊充<sup>1</sup>

(1. 成都理工大学 管理科学学院, 四川 成都 610059; 2. 成都理工大学 商学院, 四川 成都 610059)

**摘要:** 鉴于预警股票市场风险的重要性, 为提高我国股票市场风险的预警能力, 针对传统支持向量机(SVM)参数选择困难和预测精度不高等问题, 基于灰狼优化算法(GWO)提出灰狼算法支持向量机(GWO-SVM)股票市场风险预警模型, 并利用平均绝对误差(MAE)和均方误差(MSE)检验了有效性。研究表明, 与SVM、GS-SVM、GA-SVM、PSO-SVM相比, GWO-SVM模型对日收益率预测的MAE平均降低了4%, MSE平均降低了5%, 能有效提高股票市场风险的预测精度和效率。通过原始-预测数据的对比, GWO-SVM能较为准确地预测出股票指数的波动情况, 为我国股票市场风险预测提供了新的思路。

**关键词:** 股票市场风险; 灰狼优化算法; 支持向量机; 风险预警

**中图分类号:** F832.5 **文章标识码:** A **文章编号:** 1007-3221(2023)04-0192-06 **doi:** 10.12005/orms.2023.0134

## Study of the Stock Market Risk Warning Based on GWO-SVM

ZHANG Heli<sup>1</sup>, CHUN Weide<sup>1</sup>, CHUN Zhengjie<sup>2</sup>, PU Junchong<sup>1</sup>

(1. School of Management Science, Chengdu University of Technology, Chengdu 610059, China; 2. School of Business, Chengdu University of Technology, Chengdu 610059, China)

**Abstract:** With the advancement of China's reform and opening up in the 1980s, the emergence of joint-stock companies has led to widespread attention on the construction of the stock market. As more and more joint-stock companies appeared and stocks were issued, the stock exchange emerged to deepen the reform and opening up of the financial industry. During the period from 1990 to 1991, the Shanghai Stock Exchange and the Shenzhen Stock Exchange were established, which opened the construction of China's stock market. Although the Chinese stock market started later, it has been continuously improved through the advancement of reform. As an important component of the financial market, the stock market not only plays a crucial role for investors and listed companies but also stabilizes the national financial order and improves the ability to withstand risks. Throughout history, many financial crises have been caused by stock market crashes, such as the Great Crash of 1929 in the US, the 1990 Japanese stock market collapse, the 2015 Chinese stock market plunge, and the global stock market crash in 2020 caused by the COVID-19 pandemic. Studies have also shown that the stock market is the largest risk output and receiver, and a stock market crash can cause panic among investors, lead to financial crises for listed companies, and even affect the overall operation of the socio-economy. Therefore, it is essential to be able to alert and improve the ability to withstand risks for investors, listed companies, and the government.

In the big data era, traditional linear prediction methods such as data simplification, composite index method, and financial stress index method are no longer accurate in describing financial market risks. The emergence of new intelligent machine learning algorithms such as Decision Trees (DT), Logistic Regression (LR), Random Forests (RF), Artificial Neural Networks (ANN), Copula, and Support Vector Machine (SVM) have greatly addressed the problems of the big data era. As a machine learning method, SVM is frequently used for data analysis and regression problems due to its strong non-linear fitting ability, simple learning rules, easy implementation by computers, and the ability to achieve optimal decisions using a small number of support vectors. It effectively solves the complexity of indicators in the era of big data. However, traditional SVM is

收稿日期: 2021-04-07

基金项目: 国家社会科学基金资助项目(17BJY188)

作者简介: 张鹤立(1995-), 男, 四川广安人, 博士研究生, 研究方向: 金融工程与风险管理; 淳伟德(1963-), 男, 四川广元人, 教授, 博士生导师, 研究方向: 公司金融与金融风险管理; 淳正杰(1989-), 男, 四川广元人, 讲师, 博士, 研究方向: 金融工程与风险管理; 蒲俊充(1995-), 男, 四川南充人, 博士研究生, 研究方向: 金融工程与风险管理。

sensitive to missing data, and the selection of penalty coefficient  $C$  and kernel function parameter  $g$  is subjective and empirical, which can consume a large amount of memory and time in the case of large samples. From existing research, SVM has been widely used in company financial risk warning and financial market warning, and has achieved certain research results. However, it has been less applied in stock market risk warning. The key to preventing risks lies in constructing a reasonable early warning model, so the adaptability of the SVM model to stock market prediction is a subject that needs further research.

Given the importance of risk warning for the stock market, this article proposes a Grey Wolf Optimizer Support Vector Machine (GWO-SVM) stock market risk warning model to improve China's stock market risk warning ability. This is in response to traditional SVM problems, such as difficulties in parameter selection and low prediction accuracy. The effectiveness of the model was tested using the Mean Absolute Error (MAE) and Mean Squared Error (MSE). The Grey Wolf Optimization algorithm is an intelligent optimization algorithm proposed by scholars from Griffith University in Australia in 2014. Inspired by the hunting behavior of grey wolves, this algorithm is a type of optimization search method that has strong convergence performance, fewer parameters, and is easy to implement. It can significantly improve the efficiency and prediction accuracy of SVM. Our paper focuses on the daily returns and volatility of eight major stock market indices in China. Daily returns can comprehensively reflect the price changes and trends of stocks, while volatility can effectively measure market sentiment and help managers judge the macro trend of the market. Moreover, these eight indices have a broad coverage and can basically represent the operation of the entire stock market. They are often used as benchmark indices to measure the overall market risk. Therefore, daily rate of return and volatility are selected as the research objects, with data collected from CSMAR and RESSET databases. The research results show that compared to SVM, GS-SVM, GA-SVM, and PSO-SVM, GWO-SVM has an average runtime efficiency that is 330% longer than the other three optimization algorithms. Meanwhile, the GWO-SVM model has an average decrease of 4% in MAE and 5% in MSE in predicting daily returns, and it also shows a highly fitting trend in predicting daily volatility. Therefore, the model can effectively improve the accuracy and efficiency of predicting stock market risks. By comparing the original and predicted data, GWO-SVM can accurately predict the fluctuation of the stock index, providing new ideas for stock market risk prediction in China. Future research will focus on characterizing risk indices and further optimizing the model to better analyze and predict stock market risks.

**Key words:** stock market risk; grey wolf optimization algorithm; support vector machine; risk warning

## 0 引言

众所周知,股票市场是金融市场的重要组成部分,一旦股票市场爆发风险,会对金融系统、经济社会造成巨大的伤害。股票市场风险,是一种不可分散风险。回顾历史,无论是 1929 年美国股市大崩盘,还是 1990 年日本股市腰斩,或者是 2015 年中国股市的“千股跌停、千股停牌”异象,都将股票市场风险的破坏力表现的淋漓尽致,对经济社会造成的伤害至今让人心有余悸<sup>[1]</sup>。同样的,2020 年在全球爆发的新冠疫情,我国 A 股市场在春节后的首个交易日超 3000 只股票跌停,沪指收和深成指暴跌,在一定程度上引起了投资者的恐慌情绪。在我国,不仅将守住不发生系统性金融风险作为三大攻坚战之一,更将其列为金融工作的根本任务,而股票市场风险是金融风险的重要组成部分,其一旦爆发就会牵连其他市场,所以防范股市风险是政府高度关注的事宜。

在系统性风险发生的情况下,股票市场是风险

的主要输出方,所以一般情况下风险是从股市传播到其他金融市场的,产生一种非对称传染效应<sup>[2]</sup>。鉴于防范爆发股市风险的关键是建立可靠的预警系统,所以一直以来金融风险预警就是学术界研究的热点。在传统的有效市场假说下,股票市场收益率服从正态分布,通过金融时间序列对未来进行预测几乎是不可能的。现代金融市场是一个非线性、高维度和嘈杂的动态系统<sup>[3]</sup>,我国股票市场属于新兴市场,价值投资者少、投机氛围强,股价波动大、换手率远高,所以这种市场的非有效性使收益率与波动率具有一定的可预测性。在此基础上,选择合理的预测方法显得更为重要。

支持向量机 (Support Vector Machine, SVM) 利用内积核函数代替向高维空间的非线性映射,用少量的支持向量来实现最优决策,有很强的非线性拟合能力,学习规则简单,便于计算机实现,有效的解决了大数据时代的指标复杂性。赵海月和杨万寿<sup>[4]</sup>通过 Copula-SVM 模型,对股票市场上证综指、深证成指及沪深 300 的风险因子进行测算;赵丹丹和丁建臣<sup>[5]</sup>利用 SVM 对我国银行市场风险进

行了预警,发现其具有较高的准确率。但是,传统 SVM 对缺失数据敏感,惩罚系数  $C$  和核函数参数  $g$  选取具有经验性和主观性,在大样本的情况下耗费大量内存和时间。针对 SVM 的一些缺陷,国内外学者提出了一些优化方法。淳伟德等<sup>[6]</sup>将金融压力指数与 SVM 相结合,有效的监测了金融市场风险。林宇等<sup>[7]</sup>利用 ODR-ADASYN-SVM 模型,提高了 SVM 对非均衡样本学习能力。MIN 等<sup>[8]</sup>通过网格搜索来优化参数选择构造了 GS-SVM 模型,提高了传统 SVM 的预测性能。总的来看,SVM 在公司财务风险预警和金融市场预警等方面已经被广泛利用且有了一定的研究成果,但却较少应用在股票市场风险预警上,而对于风险的防范关键就在于构建合理的预警模型,所以 SVM 模型对股票市场预测的适应性是一个待研究的课题。

因为 SVM 模型的预测性能与参数的选择密切相关,针对参数选择的难题,本文引入灰狼优化算法 (Grey Wolf Optimizer, GWO) 来搜索最优参数,提出 GWO-SVM 模型,将其嵌入股票市场风险预测框架。选取八个大盘指数的日收益率为研究对象,利用均方误差 (Mean Square Error, MSE) 和平均绝对误差 (Mean Absolute Error, MAE) 来验证本文所建模型的有效性,接着选取四个具有代表性的日波动率指标,通过其原始预测数据的趋势图来进一步验证模型的准确性,最后针对研究结果得出结论和启示。

## 1 GWO-SVM 构建

为构建我国股票市场风险预警模型,选取支持向量机作为主要预警工具,通过非线性映射函数  $\varphi(x)$  将风险指标时间序列数据映射到高维空间,寻找支持向量形成最大间隔超平面在高维空间进行线性回归,其回归函数和目标函数如下:

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

根据风险最小化原则构建目标函数,其中  $C$  为惩罚因子,  $\xi_i$  和  $\xi_i^*$  表示松弛因子,  $\|\omega\|$  是与  $f(x)$  相关的项,  $\varepsilon$  为不敏感损失函数:

$$\min J = \frac{1}{2} \|\omega\| + C \sum_{i=1}^n (\xi_i^* + \xi_i)$$

$$\text{s. t. } \begin{cases} y_i - \omega \cdot \varphi(x) - b \leq \varepsilon + \xi_i \\ \omega \cdot \varphi(x) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i = 0, 1, 2, \dots, n \end{cases} \quad (2)$$

在 SVM 的构建过程中,惩罚因子  $C$  和核函数

参数  $g$  的选择至关重要。为解决 SVM 中最优参数选择问题并提高模型的预测能力,本文基于灰狼优化算法提出了 GWO-SVM 股票市场风险预警模型。灰狼隶属于群居生活的犬科动物,其种群严格遵守着一个社会支配等级关系,最高层是头狼  $\alpha$ , 然后依次是  $\beta$ 、 $\delta$ 、 $\varepsilon$ 。GWO 优化模拟了灰狼捕猎的过程,主要包括包围、捕猎和攻击猎物三个步骤。

包围猎物就是当灰狼搜索猎物时逐渐地接近并包围它,该行为的数学模型如下,式中:  $t$  为当前迭代次数;  $A$  和  $C$  是协同系数向量;  $X_p$  表示猎物的位置向量,即全局最优解;  $X(t)$  表示当前灰狼的位置向量;在整个迭代过程中  $a$  由 2 线性降到 0;  $r_1$  和  $r_2$  是  $[0, 1]$  中的随机向量。

$$D = |C \cdot X_p(t) - X(t)| \quad (3)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (4)$$

$$A = 2a \cdot r_1 - a \quad (5)$$

$$C = 2r_2 \quad (6)$$

猎捕过程就是识别最优解位置的过程,但是很多问题的解空间特征是未知的,灰狼无法确定其精确位置。为了模拟灰狼的搜索行为,假设  $\alpha$ 、 $\beta$ 、 $\delta$  具有较强识别潜在猎物位置的能力。因此,在每次迭代过程中需要根据  $\alpha$ 、 $\beta$ 、 $\delta$  的位置信息来更新其它搜索代理(包括  $\omega$ ) 的位置。该行为的数学模型可表示如下

$$D_\alpha = |C_1 \times X_\alpha|, D_\beta = |C_2 \times X_\beta|, D_\delta = |C_3 \times X_\delta| \quad (7)$$

$$X_1 = X_\alpha - A_1 \cdot D_\alpha, X_2 = X_\beta - A_2 \cdot D_\beta, X_3 = X_\delta - A_3 \cdot D_\delta \quad (8)$$

$$X_{(t+1)} = \frac{(X_1 + X_2 + X_3)}{3} \quad (9)$$

式中:  $X_\alpha$ 、 $X_\beta$ 、 $X_\delta$  分别表示当前种群中  $\alpha$ 、 $\beta$ 、 $\delta$  的位置向量;  $X$  表示灰狼的位置向量;  $D_\alpha$ 、 $D_\beta$ 、 $D_\delta$  分别表示当前候选灰狼与最优三条狼之间的距离;当  $|A| > 1$  时,灰狼之间尽量分散在各区域并搜寻猎物;当  $|A| < 1$  时,灰狼将集中搜索某个或某些区域的猎物。 $C$  是在区间范围  $[0, 2]$  上的随机值构成的向量,此系数为猎物提供了随机权重。

## 2 实证分析

本文选取上证综指、上证 50、上证 100、上证 150、沪深 300、中证 100、中证 200、中证 500 共计八个指数的日收益率和日波动率作为研究对象。收益率能综合反映股票的价格变动和走势情况,波动率能有效衡量市场情绪和帮助管理者判断市场的宏观走势,且这八个指数涵盖面很广,基本上能代

表着整个股票市场的运行情况,常作为大盘指数来衡量整个市场的风险。数据区间为 2010 年 1 月 4 日至 2020 年 12 月 31 日,每个指数的日收益率和日波动率数据样本量为 2674。考虑到若能用较少的数据量来进行预测的同时还能保持预测效果的准确性,则更能提高模型的鲁棒性与泛化能力,经过分析研究后将各个指标的前 1290 作为训练集,后 1384 作为测试集。采用 MSE 和 MAE 两个指标来验证本文所建股票市场风险预测模型的有效性。

## 2.1 数据预处理和基准模型

因为 SVM 模型对  $[0,1]$  范围内的数据更加灵敏,为了提高训练效率,在训练之前对数据进行归一化处理,方法如下,式中为原始样本数据,  $x_{\max}$  和  $x_{\min}$  分别表示样本数据的最大值和最小值,  $y_{\max}$  和  $y_{\min}$  分别为 1 和 -1。

$$y = \frac{(y_{\max} - y_{\min}) \times (x - x_{\min})}{x_{\max} - x_{\min}} + y_{\min} \quad (10)$$

为验证文章所建模型的有效性和准确性,使用传统 SVM 模型,交叉验证和网格搜索优化的 GS-SVM 模型,遗传算法优化的 GA-SVM 模型,粒子群优化的 PSO-SVM 模型与本文的 GWO-SVM 模型进行比较。根据 BRUNNERMEIE M<sup>[9]</sup>,徐达宇和丁帅<sup>[10]</sup>,孙嘉楠和齐丽<sup>[11]</sup>的研究,设定模型 GA-SVM 的最大进化代数 100,最大种群数 20,交叉概率 0.4; PSO-SVM 的,  $c_1 = c_2 = 1.5$ ,最大进化代数 100,最大种群数 20; GWO-SVM 的狼群数量为 20,最大迭代次数为 20。SVM 参数  $C$  和  $g$  的范围都为  $[0.01,100]$ 。

## 2.2 实证结果与分析

表 1 是各个优化算法对不同指数日收益率计

表 1 基准模型最优参数取值

	GS-SVM		GA-SVM		PSO-SVM		GWO-SVM	
	$C$	$g$	$C$	$g$	$C$	$g$	$C$	$g$
上证综指	0.0168	27.8576	2.1429	0.1005	7.0983	0.1003	0.0109	56.1185
上证 50	0.1088	9.1896	0.3131	5.7348	0.1000	11.1953	97.5126	0.4463
上证 100	0.0359	3.0314	0.1382	0.8345	0.1000	1.0479	0.0164	1.2275
上证 150	0.0118	5.2780	0.1008	7.5440	0.1000	1.2275	0.0199	3.9781
沪深 300	0.0118	27.8576	0.1885	3.9744	0.1000	8.6411	26.3808	0.0118
中证 100	0.1088	9.1896	0.1141	6.7509	0.1000	10.1361	3.7097	0.0916
中证 200	0.0118	9.1896	0.1102	1.1813	0.1000	1.0479	0.5952	0.0105
中证 500	0.0359	1.7411	3.6564	0.2996	0.1000	2.3150	0.2074	0.0100

表 2 运行时间 (s)

	SVM	GS-SVM	GA-SVM	PSO-SVM	GWO-SVM
上证综指	0.6	219	116	389	39
上证 50	0.4	188	121	303	43
上证 100	0.6	327	212	552	68
上证 150	0.5	324	278	724	63
沪深 300	0.6	298	283	425	87
中证 100	0.4	198	94	393	55
中证 200	0.6	207	101	356	49
中证 500	0.3	212	95	432	43

算出的最优  $C$  和  $g$  值。可以看出,很多情况下的  $C$  和  $g$  的取值都是一大一小,原因是因为在 SVM 模型中,惩罚系数  $C$  影响的是超平面间隔大小和分类的准确度,而  $C$  值过大或过小都会影响模型的泛化能力;核函数系数  $g$  决定了支持向量的个数和数据映射到高维空间的分布,影响模型的训练和预测效率。所以当  $C$  值较大时,模型可能过拟合,故  $g$  值会减小从而形成一种平滑效应来提高模型的训练和预测结果;而当  $C$  值较小时,模型则需要较大的  $g$  值来获取更多的支持向量,避免模型欠拟合从而降低其泛化能力。

表 2 给出了各个模型针对不同指数日收益率预测的运行时间。因传统 SVM 模型不需要优化参数等过程,所以需要的时间最短。在优化参数了的四种模型中,PSO-SVM 模型的运行时间最长,其次是 GS-SVM 和 GA-SVM,时间最短的是 GWO-SVM。PSO-SVM 因为粒子群中的所有粒子需要根据自己找到的当前个体极值,并和整个粒子群共享的当前全局最优解才能调整自己的速度和位置,所以在一定程度上增长了训练时间,也有可能是对股票市场大盘指数不敏感导致的。

表 3 给出了各个模型针对不同指数日收益率预测的 MAE 和 MSE,可以发现所有 SVM 模型对指数的预测都有较好的结果,说明 SVM 模型对于股票市场风险的预测是有效的,且进行优化过后的模型,在预测准确性上比原始的 SVM 模型上有了一定的提高。从误差大小来看,GWO-SVM 的误差值都较小,对于其他 4 个模型获得了更好的预测结果。

表3 模型误差结果

	SVM		GSSVM		GA-SVM		PSO-SVM		GWO-SVM	
	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE
上证综指	0.0097	0.0425	0.0094	0.0400	0.0094	0.0404	0.0095	0.0406	0.0094	0.0389
上证50	0.0100	0.0431	0.0101	0.0428	0.0100	0.0412	0.0101	0.0430	0.0098	0.0412
上证100	0.0123	0.0653	0.0127	0.0626	0.0121	0.0644	0.0120	0.0630	0.0119	0.0620
上证150	0.0134	0.0734	0.0129	0.0707	0.0129	0.0707	0.0129	0.0708	0.0129	0.0706
沪深300	0.0104	0.0461	0.0102	0.0439	0.0101	0.0434	0.0104	0.0441	0.0101	0.0434
中证100	0.0100	0.0425	0.0100	0.0420	0.0098	0.0409	0.0101	0.0421	0.0098	0.0401
中证200	0.0120	0.0605	0.0117	0.0581	0.0118	0.0590	0.0117	0.0586	0.0117	0.0577
中证500	0.0128	0.0668	0.0125	0.0643	0.0125	0.0650	0.0125	0.0645	0.0124	0.0633

综上,虽然 SVM 模型只需要很短的运行时间,但是其误差相对较大,而 GWO-SVM 模型不仅运行时间较短且 MAE 和 MSE 都小,所以 GWO-SVM 具有优秀的预测效率和能力。

与日收益率不同,日波动率更多的体现了股票市场的整体波动趋势和宏观环境,波动率越大说明市场变化越快,从而导致风险加剧。为进一步验证模型在风险预测的效果,使用上证综指、中证100、沪深300和中证100这四个有代表性指数的日波动率来研究 GWO-SVM 模型在原始—预测数据上的准确性。从图1~图4可以看出,模型对日波动率的预测趋势和实际趋势是一致的,具有很好的预测性能。

为更深入分析新冠疫情以来对股票市场的影

响,图5~图8选取了[1100,1384]区间的日波动率原始预测图来说明,对应时间从2019年11月1日到2020年12月31日。可以看出在2020年春节前,各指数保持着相对平稳的波动态势,而在春节之后的第一个交易日,各个指数开始剧烈波动,基本上都达到了0.04,经过严格的防疫措施和全国人民长达数月的共同努力后,股市在图中1280左右也就是2020年7月开始趋于稳定。在系统性风险发生的情况下,股票市场是风险的主要输出方,所以针对股票市场的预警十分重要且必要,而日波动率在很大程度上能够反映股票市场风险程度,相比于其他模型,GWO-SVM 模型在预测精度和预测效率方面都展现出了其有效性。

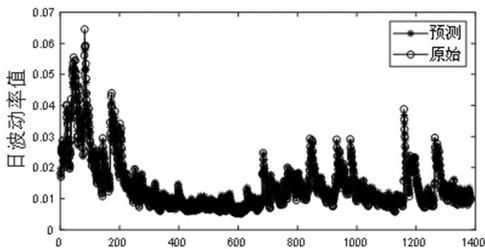


图1 上证综指日波动率原始—预测图

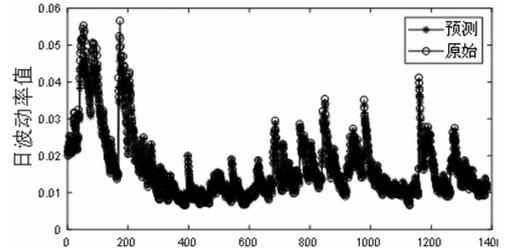


图2 上证100日波动率原始—预测图

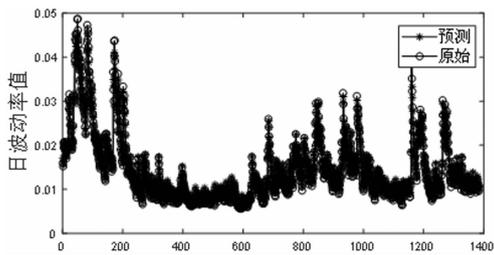


图3 沪深300日波动率原始—预测图

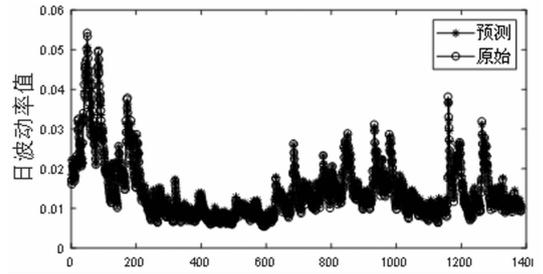


图4 中证100日波动率原始—预测图

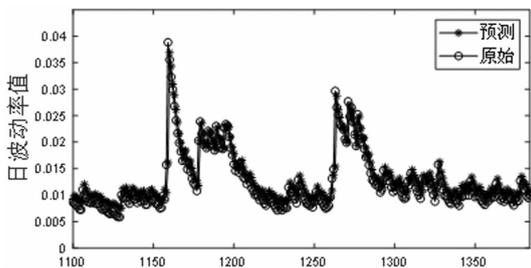


图5 上证综指[1100,1384]原始—预测图

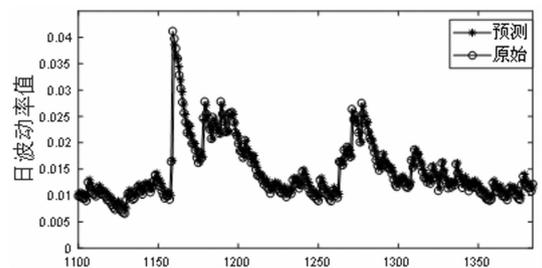


图6 上证100[1100,1384]原始—预测图

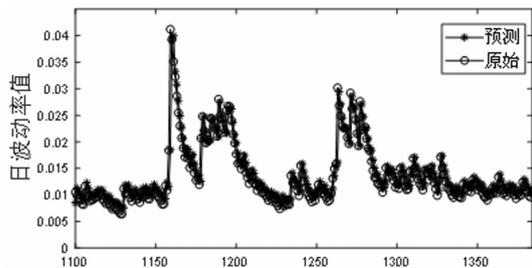


图7 沪深300[1100,1384]原始—预测图

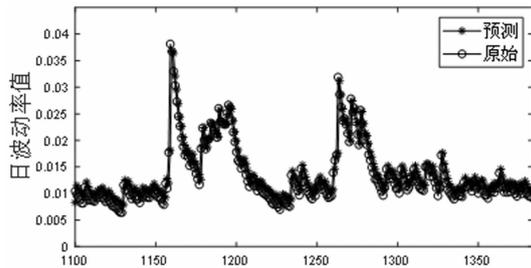


图8 中证100[1100,1384]原始—预测图

### 3 结论与启示

为防范系统性金融风险的发生,提高股票市场的预测精度,同时针对传统支持向量机(SVM)参数选择困难和预测精度不高等问题,本文提出一种基于灰狼算法优化支持向量机的风险预测模型,同时建立了传统SVM、GS-SVM、GA-SVM、PSO-SVM四种基准模型,用模型对八个主要指数的日收益率和波动率预测效果进行测试,利用均方误差和平均绝对误差两个指标来验证所建模型的有效性,最后选取四个具有代表性指标的日波动率来验证模型的准确性。实证结果表明,在运行时间上,传统SVM运行时间最快,但是精度不高。GWO-SVM运行时间效率比其他三种优化算法SVM平均提高了330%,很大程度提高了效率。相对于其他四个模型,GWO-SVM模型预测日收益率的MAE平均降低了4%,MSE平均降低了5%,同时模型对日波动率的预测也呈现高度拟合的状态。综上,GWO-SVM模型的运行稳定性更强,相比于其他算法收敛速度更快,效率更高,且预测趋势与实际吻合,有效提高了预测精度和效率。

我国股市属于新兴市场,政策和制度相比国外股票市场还不是很成熟,存在市场规模较小、盈利能力偏低、政策机制不完善等不足;同时我国股市散户居多,承担了市场的大部分风险。股票市场一旦发生风险,会导致整个金融市场的系统性风险而产生金融危机甚至经济危机,所以需要完善的预警机制来增强市场的稳定。GWO-SVM风险预警模型可以通过对大盘指数的预测,为股票市场风险预测提供了一种新的方法和途径;同时为金融从业人员提供新思路,更好的对我国金融业发展做出合理

建议;也能让投资者了解近期的波动趋势,降低投资者的风险;还能为政府提供预测数据,从而对市场进行干预和制定应对政策,保持我国经济发展持续向好的发展态势。

### 参考文献:

- [1] 李延双,庄新田,张伟平. 股指极端波动下中国股市复杂网络结构及中心性分析[J]. 运筹与管理,2020(7): 131-143.
- [2] 杨子暉,陈里璇,陈雨恬. 经济政策不确定性与系统性金融风险的跨市场传染——基于非线性网络关联的研究[J]. 经济研究,2020(1):65-81.
- [3] CAVALCANTE R C, BRASILEIRO R C, SOUZA V L F, et al. Computational intelligence and financial markets: A survey and future directions[J]. Expert Systems with Applications, 2016: 194-211.
- [4] 赵海月,杨万寿. 基于Copula-SVM非均衡数据的金融风险识别与测算[J]. 统计与决策,2019,35(21): 156-159.
- [5] 赵丹丹,丁建臣. 中国银行业系统性风险预警研究——基于SVM模型的建模分析[J]. 国际商务(对外经济贸易大学学报),2019(4):100-113.
- [6] 淳伟德,肖杨. 供给侧结构性改革期间系统性金融风险的SVM预警研究[J]. 预测,2018(5):36-42.
- [7] 林宇,黄迅,淳伟德,等. 基于ODR-ADASYN-SVM的极端金融风险预警研究[J]. 管理科学学报,2016,19(5):87-101.
- [8] MIN J H, LEE Y C. Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters[J]. Expert Systems with Application, 2005, 28(4): 603-614.
- [9] ADRIA T, BRUNNERMEIE M. CoVaR[J]. American Economic Review, 2016, 106(7): 1705-1741.
- [10] 徐达宇,丁帅. 改进GWO优化的SVM云计算资源负载短期预测研究[J]. 计算机工程与应用,2017(7): 68-73.
- [11] 孙嘉楠,齐丽. 基于GWO-SVM的财务困境预测模型研究[J]. 微型电脑应用,2019,35(4):95-98.