

文章编号: 1004-4353(2017)01-0025-09

一种改进的模拟退火算法优化的支持向量机 在交易信号研判中的应用

黄宏运¹, 吴礼斌^{2*}, 李诗争¹, 朱家明², 黄华继¹

(1. 安徽财经大学 金融学院; 2. 安徽财经大学 统计与应用数学学院: 安徽 蚌埠 233000)

摘要: 针对利用机器学习算法支持向量机来研判交易信号时的参数设置问题,本文首先提出一种改进的模拟退火算法(三交换法)来优化 LIBSVM 工具箱中的惩罚因子“ $-c$ ”和核函数因子“ $-g$ ”的选取,然后建立一个基于历史证券技术指标信息的量化择时模型. 实证研究表明,改进后的 ISA-SVM 算法相比于二交换法和互逆交换法不仅可以更好地收敛于最小能量,而且在实际投资中可以对交易信号进行更准确的预测、实现更为可观的收益回报.

关键词: 模拟退火; 支持向量机; 择时; 三交换; LIBSVM ToolBox

中图分类号: TP183; F830. 91; O29 **文献标识码:** A

Application of an improved SA-SVM algorithm in judgment of transaction signals

HUANG Hongyun¹, WU Libin^{2*}, LI Shizheng¹, ZHU Jiaming², HUANG Huaji¹

(1. *Anhui University of Finance and Economics, School of Finance*; 2. *Anhui University of Finance and Economics, Institute of Statistics and Applied Mathematics*; Bengbu 233000, China)

Abstract: For solving the problem of parameter setting when using the machine learning algorithm Support Vector machine to judge the transaction signal, this paper firstly proposed an improved simulated annealing algorithm (triple exchange method) to optimize the selection of the penalty factor “ $-c$ ” and the kernel function “ $-g$ ” in the LIBSVM Toolbox, then establishing a quantitative timing model based on historical securities technical indicators. The empirical study shows that the improved ISA-SVM algorithm can not only converge to the minimum energy better than the two-exchange method and the inverse exchange method, but also can predict the transaction signal more accurately in the actual investment.

Keywords: simulated annealing; support vector machine; selection time; triple exchange method; LIBSVM Toolbox

近些年,量化投资(Quantitative Investment, QI)^[1]凭借着高额稳定的收益回报而成为众多投资者关注的一颗新星. 量化投资在国外发展的较早,至今已有 40 多年的历史,由于它主要是通过算法来挖掘交易数据背后潜藏的投资机会,可以完全规避传统投资方式中人为主观因素的干扰,因而取得的收益回报一直较为可观,甚至于某些对冲基金在金融危机时期也能取得年化 30% 以上的稳定收益,因而量化投资无疑是当下金融领域的热点话题之一.

收稿日期: 2016 - 10 - 21 *** 通信作者:** 吴礼斌(1964—),男,副教授,研究方向为计量金融与数理统计.

基金项目: 国家自然科学基金资助项目(11601001);安徽高等学校省级自然科学基金资助项目(KJ2013Z001);安徽财经大学校级重点研究项目(ACKY1402ZD)

随着机器学习算法理论的不断发展和完善,其在金融数据挖掘领域的应用也得到了不断地实践.受益于计算机信息技术以及金融市场的领先发展,国外在这方面已经取得了较多的成就,有很多学者都对利用机器学习算法开发量化投资模型作了研究^[2-4],并且大多数先进的金融机构也都部署了机器学习算法在金融工程领域的策略研发^[5].由于国内受到金融市场发展程度的制约,目前还很少有学者在理论方面做出较为深入的研究,尽管有少数学者^[6-9]在这方面作了一些补充,但是他们更侧重于应用层面的探讨,对于具体模型的调参以及算法背后的原理并未作出细致的分析.基于以上背景,本文尝试利用模拟退火算法来优化 SVM 参数,并以纯技术指标信息为输入变量建立量化择时模型.

1 数据来源及相关描述

本文的数据主要来源于万得(Wind)金融资讯终端数据中心提供的自 2012 年 1 月 4 日至 2016 年 6 月 22 日的股票指数,其中数据的格式为 1 050 行乘 20 列,每一行代表个股浦发银行(SH600000)观察日内的 20 技术指标信息,具体包括 5 日、10 日和 20 日 MA,6 日、12 日和 24 日 PSY,6 日、12 日和 24 日 ROC,6 日、12 日和 24 日 ATR,12 日和 24 日 RVI,10 日和 20 日 RSI,6 日和 12 日 ATR,12 日和 24 日 ADTM.

2 SA-SVM 算法在交易信号研判中的应用

2.1 支持向量机原理

支持向量机(Support Vector Machine, SVM)^[10]的基本原理是构建一个分离超平面,以使两类(可以扩展到多类问题)的边界平面距离最大化(如图 1 所示),其本质在数学上可以理解为一个凸二次优化问题^[11]:

假设原始样本集为 $(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_n, y_n)$,其中 y_i 表示第 i 个样本的属性标签,若 x_i 代表正类样本,则 $y_i = 1$,反之,若 x_i 代表负类样本,则 $y_i = -1$.如果存在分离超平面 $w^T x + b = 0$ 将原始样本集准确地化为正负两类(对于在低维空间内线性不可分的数据, SVM 通过核函数将原始数据映射到高维空间以实现线性可分,下文中 $K(x)$ 表示核函数),即满足

$$\begin{cases} w^T K(x_i) + b \geq 1, & y_i = 1; \\ w^T K(x_i) + b \leq -1, & y_i = -1. \end{cases}$$

(1)

式(1)中的 $w^T K(x_i) + b = 1$ 和 $w^T K(x_i) + b = -1$ 即表示正类和负类样本集的平面方程(二维空间中即为直线方程),不难发现这两个平面互为平行,因而对于分离超平面 $w^T x + b = 0$ 的求解可转化为如下规划问题:

$$\begin{aligned} \max_{w, b}: & \left(\frac{2}{\|w\|} \times \min_n (y_i (w^T K(x_i) + b)) \right); \\ \text{s. t. : } & y_i (w^T K(x_i) + b) \geq 1. \end{aligned}$$

(2)

根据式(1)可知: $y_i (w^T K(x_i) + b) \geq 1$,那么 $\min_n y_i (w^T K(x_i) + b) = 1$,为了便于求解 w ,可将式(2)中目标函数项转置,即得到问题(3):

$$\begin{aligned} \min_{w, b}: & \frac{1}{2} \times \|w\|^2; \\ \text{s. t. : } & y_i (w^T K(x_i) + b) \geq 1. \end{aligned}$$

(3)

问题(3)对应的对偶优化问题为:




图 1 边界平面、间隔平面与支持向量

$$\begin{aligned} \max_{\lambda_i}: & \frac{1}{2} \times \|w\|^2 - \sum_{i=1}^n \lambda_i (y_i (w^T K(x_i) + b) - 1); \\ \text{s. t.}: & \lambda_i \geq 0; \sum_{i=1}^n \lambda_i y_i = 0; i = 1, 2, \dots, n. \end{aligned} \quad (4)$$

其中 $\lambda_i (i = 1, 2, \dots, n)$ 表示拉格朗日乘子。

将上述拉格朗日函数分别对 w 和 b 求偏导后得到的一阶驻点判别条件回代入原函数中得到:

$$\begin{aligned} L(w, \lambda_i, b) &= \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \lambda_i (y_i (w^T K(x_i) + b) - 1) = \\ &= \frac{1}{2} w^T w - \sum_{i=1}^n \lambda_i (y_i (w^T K(x_i) + b) - 1) = \\ &= \frac{1}{2} w^T \sum_{i=1}^n \lambda_i y_i K(x_i) - w^T \sum_{i=1}^n \lambda_i y_i K(x_i) - \sum_{i=1}^n \lambda_i y_i b + \sum_{i=1}^n \lambda_i = \\ &= -\frac{1}{2} w^T \sum_{i=1}^n \lambda_i y_i K(x_i) - b \sum_{i=1}^n \lambda_i y_i + \sum_{i=1}^n \lambda_i = -\frac{1}{2} \left(\sum_{i=1}^n \lambda_i y_i K(x_i) \right)^T \times \sum_{i=1}^n \lambda_i y_i K(x_i) + \sum_{i=1}^n \lambda_i = \\ &= -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j K(x_i)^T K(x_j) + \sum_{i=1}^n \lambda_i = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j K(x_i, x_j) + \sum_{i=1}^n \lambda_i, \end{aligned} \quad (5)$$

所以求解 w 和 b 的原问题最终转化为如下二次优化问题:

$$\begin{aligned} \max_{\lambda_i}: & -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j K(x_i, x_j) + \sum_{i=1}^n \lambda_i; \\ \text{s. t.}: & \lambda_i \geq 0; \sum_{i=1}^n \lambda_i y_i = 0; i = 1, 2, \dots, n. \end{aligned} \quad (6)$$

不难发现问题(6)中含有多个 λ_i , 而 SMO(Sequential Minimal Optimization) 算法^[12-13] 是专门用来求解这种优化类问题, 这种算法在迭代的过程中每次只选择调整两个样本点的 λ_i (固定其他样本点的 λ_i)。

设最终得到的 $\partial^* = [\partial_1^*, \partial_2^*, \dots, \partial_n^*]^T$, 进一步可确定分类超平面的法向量和偏置量分别为: $w^* =$

$$\sum_{i=1}^n \partial_i^* x_i y_i, b^* = y_i - \sum_{i=1}^n \partial_i^* y_i x_i^T x_j.$$

如果原始数据线性不可分, 可将原问题转变为如下问题求解:

$$\begin{aligned} \max_{\lambda_i}: & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \delta_i - \sum_{i=1}^n \partial_i (y_i (w^T K(x_i) + b) - 1 + \delta_i) - \sum_{i=1}^n \mu_i \delta_i; \\ \text{s. t.}: & \lambda_i \geq 0; \sum_{i=1}^n \lambda_i y_i = 0; C - \lambda_i - \mu_i = 0; i = 1, 2, \dots, n. \end{aligned} \quad (7)$$

其中 C 称为惩罚因子, 其值越大, 表明对错分样本的惩罚程度越大, 这样可以使得模型获得较小的经验风险^[14] (即模型的样本内预测能力越强), 其值越小, 表明可以容忍错分样本的程度越大, 这样做虽然降低了模型的预测能力, 但使得分类间隔变大, 即模型的泛化能力得到提高, 因而在实际运用中如何设置惩罚因子的大小显得尤为重要。

2.2 模拟退火算法

模拟退火(Simulated Annealing, SA)^[15] 思想最早由 Metropolis 教授于 1953 年提出, 其主要效仿了固体的退火过程, 即首先将固体加热至足够高的温度, 然后再徐徐冷却, 升温时, 固体内部分子随温度升高变为无序状, 对应为一个熵增和内能增的过程, 而在缓慢冷却固体时, 内部分子又逐渐趋于有序, 对应为一个熵减内能减的过程, 从理论上来说, 如果整个冷却过程足够长, 那么冷却中任一温度时固体都能达到热平衡状态, 最后在常温时达到基态, 内能减为最小, 因此算法实际上将优化问题的最优解集类比为退火过程中能量的最低状态, 也就是温度处于最低点时, 概率分布中具有最大概率的状态。

基于上述模拟退火的思想, 模拟退火算法主要实现是在局部搜索的过程中引入了随机扰动的机制,

对于产生的新解,如果好于旧解,则无条件接受或更新,如果差于旧解,则以一定概率接受或更新.模拟退火算法的整体步骤大致如下:

- Step1 设定初始温度 $T=T_0$,通过二进制数串或实数随机产生一个新解 x_0 ,并计算目标函数(或称能量函数)值 $E(x_0)$;
- Step2 令 T 等于冷却进度表中的下一个值 T_i ;
- Step3 对当前解 x_i 进行扰动,产生新解 x_j ,并计算相应的目标函数 $E(x_j)$,得到 $\Delta E=E(x_j)-E(x_i)$;
- Step4 根据 Metropolis 规则来判断是否接受新解,具体为如果 $\Delta E<0$,则旧解 x_i 被替换,新解 x_j 被接受;如果 $\Delta E>0$,则以概率 $\exp(-\Delta E/T_i)$ 接受新解 x_j , T_i 对应为当前温度;
- Step5 在当前温度 T_i 下,重复一个马尔科夫(Markov)链长度的循环扰动;
- Step6 判断温度是否到达终止条件 $T_i<T_{\text{end}}$,如果满足则算法结束,不满足则继续返回 Step2.

从上述算法的整个实现过程可以看出,在算法迭代的初始阶段,对应的温度 T_i 处于较高状态下,负指数函数 $\exp(-\Delta E/T_i)$ 接近于 1,即对于比当前解 x_i 差的新解 x_j 也有较大可能被接受.相比于其他的优化算法,如遗传算法、粒子群算法等,模拟退火算法有更多的机会可以逃离局部最优陷阱,因此本文选取了模拟退火算法.

2.3 改进的模拟退火算法

对于经典的模拟退火算法来说,影响其性能的因素主要包括扰动机制(又称临域控制)和参数控制,其中参数控制主要包括冷却进度表中的初始温度 T_0 、衰减因子 ϑ 和终止温度 T_{end} .对于参数控制目前已经有众多学者进行了研究,具体可参见文献[16]和[17].对于扰动机制,目前最为常用的两种方法为“二交换”和“互逆交换”,其中“二交换”法主要是通过随机调换两个位置上的数值来产生新解,其扰动过程大致如图 2 所示.




图 2 二交换法

扰动后的新解表达式为:

$$\begin{cases} Chrom_new(id1)=Chrom_old(id2), \\ Chrom_new(id2)=Chrom_old(id1). \end{cases}$$

(8)

式(8)中, $Chrom_new$ 和 $Chrom_old$ 分别表示新解和旧解位串,通常初始解由二进制编码或实数编码产生.

“互逆交换”法是指先随机选择一个区域位串($id1$ 至 $id2$),然后通过首尾颠倒这个区域位串内的所有数值来产生新解,其扰动过程大致如图 3 所示.




图 3 互逆交换法

扰动后的新解表达式为:

$$\begin{cases} reverse_old=Chrom_old(id1:id2), \\ reverse_new(i)=reverse_old(id2-id1+2-i), \\ Chrom_new(id1:id2)=reverse_new. \end{cases}$$

(9)

式(9)中, *reverse_old* 表示随机选择的区域位串, *reverse_new* 表示首尾交换后的区域位串.

“二交换”法和“互逆交换”法在对简单问题的解决上可以取得较好的效果,但对于变量维数较多的复杂问题求解则存在不足:“二交换”法的单点交换方式对于旧解的扰动度过小,不易产生明显区别于旧解的新解;“互逆交换”法虽然通过位串变换的方式规避了单点交换的不足,但每次对旧解的扰动均是在同一个位串内进行,如果采取二进制数串对解进行编码,可能会使算法在迭代的后期陷入局部最优解陷阱. 所以本文在这两种方法的基础之上提出一种新的扰动方法,称为“三交换”法,简记为 ISA 算法(Improved Simulated Annealing, ISA),其扰动过程大致如图 4 所示.




图 4 三交换法

扰动后的新解表达式为:

$$\begin{cases} Chrom_new(id1+1:id2-1)=Chrom_old(id3+id1-id2+2:id3), \\ Chrom_new(id3+id1+id2:id3)=Chrom_old(id1+1:id2-1). \end{cases}$$

(10)

本文提出的“三交换”法一方面保留了“互逆交换”法的位串交换方式,另一方面每次对旧解的扰动不再局限于单个区域位串,而是在两个区域位串内进行. 理论上来说,只要解的编码位串足够长,就可以将对旧解的扰动推广到若干个区域位串内进行.

2.4 基于模拟退火算法优化 SVM 的原理

由上文中的理论推导可知,惩罚因子 *C* 是一个关键的超参数,另外在使用高斯核函数的过程中,核函数因子 *g* 也起着重要的作用. 通常使用网格遍历和遗传算法^[18]来对这两个参数寻优,其中网格遍历法是一种人为设置区间的迭代算法,存在较强的主观性,不同的设置方式可能会导致最终的结果差异较大,遗传算法虽然具有良好的非线性寻优能力,但是容易在进化过程中导致早熟停滞问题. 相比较而言,模拟退火算法不仅可以通过 Metropolis 接受解准则来有效地跳出局部最优陷阱,而且它是一种完全依赖于概率的随机搜索方法,所以本文主要利用改进的 ISA 算法来优化 SVM 模型参数的设定.

根据前文内容,模拟退火算法优化 SVM 参数的大致思路如图 5 所示.

2.5 SA 算法优化的 SVM 量化择时模型

2.5.1 模型的建立 在利用机器学习算法建立模型时通常需要确定输入变量和输出变量,目前对于量化择时模型的输入变量选择,常见的有基于历史价量信息和技术指标信息两种,由于本文主要是研究短期的信号预测问题,所以认为选取指标信息作为模型的输入变量更为合理. 输出变量即交易信号主要是通过比较短长期移动平均指数的大小来控制,当短期移动平均指数超过长期移动平均指数时,股价在短期之内呈现出看涨的趋势,即预示着买入信号,标记为 +1,反之,当短期移动平均指数低于长期移动平均指数时,股价在长期之内呈现出看跌的趋势,即预示着卖出的向好,标记为 -1,所以具体的模型表

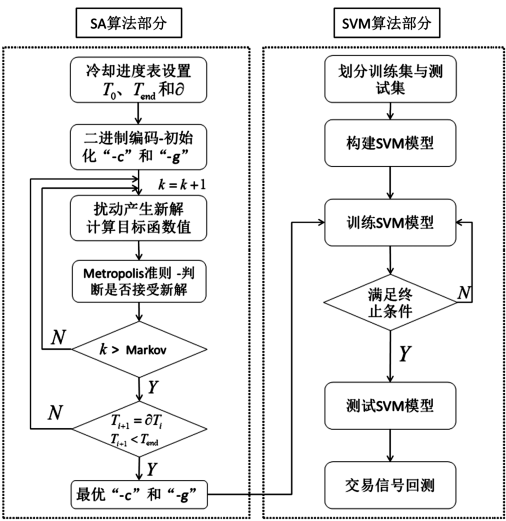


图 5 SA 算法优化 SVM 参数流程图

达式如下:

$$Y(t)=\text{sgn}(\text{movavg}_{\text{long}}(t-1)-\text{movavg}_{\text{short}}(t-1))=H(t-1), \tag{11}$$

上式中: $\text{sgn}(\cdot)$ 表示符号函数; 当短期移动平均指数 $\text{movavg}_{\text{short}}$ 大于长期移动平均指数 $\text{movavg}_{\text{long}}$ 时, Y 为 +1; 当短期移动平均指数 $\text{movavg}_{\text{short}}$ 小于长期移动平均指数 $\text{movavg}_{\text{long}}$ 时, Y 为 -1; $H(\cdot)$ 代表数据说明中的 20 项技术指标因子.

2.5.2 模型的准备 在对模型进行训练之前, 一方面需要对数据进行适当的预处理, 另一方面需要通过 ISA 算法寻优得到一组“-c”和“-g”值, 具体分为以下几个步骤来完成.

Step1 数据变换处理. 由于原始各项技术指标在数量级和量纲方面均存在一定的差异, 所以首先对其进行必要的变换处理. 具体变换的公式如下:

$$x'_{ij} = \begin{cases} b, & x_{ij} > \frac{1}{n} \sum_{i=1}^n x_{ij} + 2 \times \sqrt{\frac{1}{n} (x_{ij} - \frac{1}{n} \sum_{i=1}^n x_{ij})} \quad (j=1, 2, 3, \dots, 20); \\ a, & x_{ij} < \frac{1}{n} \sum_{i=1}^n x_{ij} - 2 \times \sqrt{\frac{1}{n} (x_{ij} - \frac{1}{n} \sum_{i=1}^n x_{ij})} \quad (j=1, 2, 3, \dots, 20); \\ b + (a-b) \times \frac{x_{ij} - x_{ij}^{\min}}{x_{ij}^{\max} - x_{ij}^{\min}}, & \text{其它.} \end{cases} \tag{12}$$

式(12)中, 将小于或大于均值两倍标准差的数据视为异常点, 均归一化到 a, b 端点值上, 其他数据归一化到区间 $[a, b]$ 上, x_{ij} 表示原始数据, x_{ij}^{\min} 和 x_{ij}^{\max} 分别表示原始各列数据的最小值和最大值, 本文具体设置 $a=0, b=1$.

Step2 利用主成分分析(PCA)进行降维处理. 从图 6 可以看出, 归约后的 20 项技术指标因子存在着较高的相关性, 如果直接运用于模型的训练, 不仅会导致变量间严重的多重共线性问题, 而且很可能会导致系统信息冗余, 所以这里利用主成分分析对其进行降维.




图 6 变量之间的相关系数

Step3 划分训练样本与测试样本. 训练样本集主要是用于训练模型, 而测试样本集主要是为了检验模型的样本外预测能力.

Step4 基于模拟退火算法进行寻优. 具体的参数设置为: 初始“ $-c$ ”和“ $-g$ ”值采用二进制数串编码, 每个变量的长度为 20, 冷却进度表中的初始温度 T_0 为 1 000, 终止温度 T_{end} 为 0.001, 衰减系数 θ 为 0.95, 每个温度下的 Markov 链长度为 1 000, 能量函数为模型预测结果与实际结果间的 Hamming 距离, 其表达式为 $E = \text{sum}(y_i \neq o_i) / \text{sum}(o_i)$, 其中 y_i 表示预测结果, o_i 为实际结果, $\text{sum}(\cdot)$ 表示向量元素的个数.

整个迭代过程中, 每个温度下对应的最小能量值与平均能量值变化如图 7 所示. 从图 7 可以看出, 对于“互逆交换”法来说, 在经过一个 Markov 链扰动之后, 其对应的最小能量与平均能量趋于稳定, 其值都显著高于其他两种方法对应的最小能量与平均能量, 即陷入了局部最优陷阱. 从最小能量方面来看, “二交换”法与“三交换”法最终的迭代结果相近, 但是“二交换”法是经过 4 次变换之后才达到最小能量状态, 而“三交换”法仅经过 2 次变换后即趋于稳定. 从平均能量方面来看, 每个温度下“三交换”法的平均能量低于“二交换”法. 所以从总的来看, 改进后的 ISA-SVM 算法不仅可以更快地收敛于最小能量, 而且对于最优解的搜索能力也得到一定程度的提高. 3 种方法确立的“ $-c$ ”和“ $-g$ ”参数值分比见表 1.




图 7 最小能量值与平均能量值变化

表 1 3 种方法确定的“ $-c$ ”和“ $-g$ ”参数值

参数	参数值		
	“二交换”法	“互逆交换”法	“三交换”法
$-c$	87.884 9	46.370 6	63.742 0
$-g$	4.227 2	7.128 9	5.770 8

2.5.3 模型的训练 完成模型的准备工作之后, 即可对模型进行训练. 为了检验模型的预测性能, 本文对 3 种方法预测的买卖信号进行了统计, 具体见表 2.

表 2 3 种方法的预测结果

交易类型	实际结果	“二交换”法		“互逆交换”法		“三交换”法	
		1	-1	1	-1	1	-1
买	1	89.23	10.77	81.51	18.49	96.77	3.23
卖	-1	15.21	84.79	20.89	79.11	4.87	95.13

由表 2 可以看出: 当实际结果为买入信号时, “二交换”法、“互逆交换”法和“三交换”法预测的准确率分别为 89.23%、81.51%、96.77%; 当实际结果为卖出信号时, 3 种方法预测的准确率分别为 84.79%、79.11%、95.13%. 由此说明, “三交换”法的预测准确度高于其他两种方法.

3 种方法预测的 ROC(Receiver Operating Characteristic)曲线如图 8 所示. 从图 8 可以明显看出, 随着假阳率的增加, “三交换”法对应的真阳率增加得最快, 且拐点最接近于 90°, 这进一步验证了“三交换”法的预测性能优于其他两种方法.

2.5.4 策略的回测 量化策略的回测过程主要包括开仓和平仓模块,对于开仓模块来说,需要具体确定的是何时买入以及买入的价格,同样对于平仓模块来说,需要具体确定的是何时卖出以及卖出的价格.在本文中,通过 ISA-SVM 预测的正负 1 信号即代表了买卖的时机,设置市场冲击成本为 0.01.对于开仓模块:如果当日跳空高开(开盘价大于昨日收盘价),则买入价为开盘价-冲击成本,否则,以开盘价买入(80%资金仓位).对于平仓模块:如果当日跳空低开,则卖出价为开盘价+冲击成本.在持仓期间如果买入信号再次得到确认,则追加 50%的可用资金.

根据以上分析,本文中 ISA-SVM 策略的回测结果(初始资本为 500 万)如下:

1) 收益率方面.从图 9 可知,3 种方法对于交易信号的判别均有一定的预测能力,并均能获得一定的超额收益.从时间的角度来看,在回测的初始时期,由于受到资本金的限制,3 种方法对应的累计收益率未呈现出显著的差异,但随着时间的延长,“三交换”法的累计收益率逐渐高于其他两种方法.




图 8 3 种方法预测的 ROC 曲线




图 9 3 种方法的累计净收益率

2) 绩效指标方面.表 3 中的数据是 3 种方法对应策略的相关绩效指标的统计结果.从投资回报角度来看,“三交换”法的收益率最高,但其波动率也最高.从夏普比率与信息比率来看,每承受一单位的系统风险,3 种方法对应的策略都会造成一定的损失,其中“三交换”法在单位跟踪误差方面所能取得的超额收益最高,其次依次为“二交换”法和“互逆交换”法.

表 3 3 种方法对应策略的绩效指标 %

方法类型	有效收益率	年化收益率	夏普比率	信息比率	波动率
“二交换”法	445.52	49.77	-1.438	0.057	1.27
“互逆交换”法	287.86	38.09	-2.378	0.045	0.83
“三交换”法	658.60	62.00	-1.502	0.071	1.35

3) 最大回撤方面.图 10 是 3 种方法对应策略的回撤比例(有效资金的损失).因为“互逆交换”法陷

入局部最优而过早收敛,预测的准确度相对最低(15.58%),所以在此不予考虑.从“二交换”法与“三交换”法的对比来看,整个回测区间内“二交换”法所作出的回撤波动幅度相对较小,最大回撤比例只有 8.15%,而“三交换”法所作出的回撤波动幅度较大,最大回撤比例高达 14.21%,由此说明“三交换”法对应策略的风险要远高于“二交换”法.




图 10 3 种方法的最大回撤

3 结束语

本文通过一种改进的模拟退火算法对 SVM 择时策略模型的“ c ”和“ g ”参数进行优化,结果表明该方法不仅可以更快地收敛于最小能量值,而且对于最优解的搜索能力也得到一定程度的提升.在对交易信号的具体研判过程中,由于 ISA 优化后的 SVM 具有更强的模式识别能力,在大多数情况下都可以准确地把握买与卖的时机,所以取得的收益回报较为可观;但是在某些情况下,由于是完全依赖于历史信息来抉择未来的买与卖,所以研判的交易信号也就与市场走势相悖.

参考文献:

[1] 方浩文. 量化投资发展趋势及其对中国的启示[J]. 管理现代化, 2012(5): 3-5.

[2] 李子睿. 量化投资交易策略研究[D]. 天津: 天津大学, 2013.

[3] 章宏帆. 运用量化投资策略实现超额收益 Alpha 的理论与实践[D]. 浙江大学, 2015.

[4] 王力弘. 浅议量化投资发展趋势及其对中国的启示[J]. 中国投资, 2013(S2): 202.

[5] 王冰, 李想. 浅议量化投资在国内市场的发展[J]. 经济视角(下), 2011(3): 46-47.

[6] 黄恒秋. 基于高频数据的支持向量机量化择时预测模型[J]. 科技经济导刊, 2016, (13): 29.

[7] 苏冰. 基于 PCA-SVM 模型的量化择时研究[D]. 天津财经大学, 2015.

[8] 张伟. 支持向量分类机(SVC)在量化选股中的应用[D]. 山东大学, 2014.

[9] 李艺. 量化交易策略模型应用研究[D]. 云南财经大学, 2014.

[10] Corinna Cortes, Vladimir Vapnik. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.

[11] Olivier Chapelle, Vladimir Vapnik, Olivier Bousquet, et al. Choosing multiple parameters for support vector machines[J]. Machine Learning, 2002, 46(1): 131-159.

[12] 赵长春, 姜晓爱, 金英汉. 非线性回归支持向量 SMO 算法改进[J]. 北京航空航天大学学报, 2014(1): 125-130.

[13] Cao L J, Keerthi S S, Ong Chong-Jin, et al. Parallel sequential minimal optimization for the training of support vector machines[J]. IEEE Transactions on Neural Networks, 2006, 17(4): 1039-1049.

[14] 薛浩然, 张珂珩, 李斌, 等. 基于布谷鸟算法和支持向量机的变压器故障诊断[J]. 电力系统保护与控制, 2015, 43(8): 8-13.

[15] 庞峰. 模拟退火算法的原理及算法在优化问题上的应用[D]. 吉林: 吉林大学, 2006.

[16] 朱颖东, 钟勇. 一种改进的模拟退火算法[J]. 计算机技术与发展, 2009, 19(6): 32-35.

[17] 卢宇婷, 林禹攸, 彭乔姿, 等. 模拟退火算法改进综述及参数探究[J]. 大学数学, 2015, 31(6): 96-103.

[18] 黄宏运, 吴礼斌, 李诗争. GA 优化的 SVM 在量化择时的应用[J]. 南京师范大学(工程技术版), 2017, 17(1): 1-8.