

Optimizing Multi-Factor Stock Selection System Using GBDT-SVM Multi-Level Model

Qingyan Meng

School of Mathematics, South China University of Technology, Guangzhou Guangdong
Email: keanmeng@foxmail.com

Received: Feb. 3rd, 2019; accepted: Feb. 15th, 2019; published: Feb. 22nd, 2019

Abstract

In the field of quantitative investment, the multi-factor model is widely accepted and used by investors in A-share market because of its high stability and high capital capacity. But in recent years, model homogeneity has been getting worse and investment based on multi-factor model can hardly obtain a considerable rate of return. In this work, we presents GBDT-SVM multi-level model based on big factor database, hoping to promote the multi-factor model's ability to acquire excess return in stock investment by optimizing factor selection and factor weight dynamic adjustment using machine learning techniques. Then, we conduct empirical research using China's A-share market data from 2013 to 2017 and compare the model with the classical multi-factor model and its improved version. The research results show that the GBDT-SVM multi-level stock selection model has higher prediction accuracy and gains higher yields and Sharp ratio in historical backtesting.

Keywords

Quantitative Investment, Multi-Factor Model, GBDT, SVM

使用GBDT-SVM多层次模型优化多因子选股系统

孟庆晏

华南理工大学数学学院, 广东 广州
Email: keanmeng@foxmail.com

收稿日期: 2019年2月3日; 录用日期: 2019年2月15日; 发布日期: 2019年2月22日

摘要

在量化投资领域中，多因子选股模型凭借稳定性高、资金容纳量大等优势被A股市场的广大专业投资者接受和使用。但近年来，模型的同质化愈发严重，基于多因子模型的投资难以获取可观的收益率。本文提出了基于大量因子的GBDT-SVM多层次选股模型，希望使用机器学习技术对因子选取和因子权重动态调整方面进行优化，提高多因子模型对股票超额收益的获取能力。之后，使用2013年至2017年中国A股市场数据进行实证研究，并与经典多因子模型和其改进模型进行比较。研究结果表明，GBDT-SVM多层次选股模型具有更高的预测准确性，历史回溯测试中获得了更高的收益率和夏普比。

关键词

量化投资，多因子模型，GBDT，SVM

Copyright © 2019 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

多因子选股模型因为稳定性高、资金容纳量大等优势在A股市场投资中被广泛使用，其基本原理为选取若干可能对股票收益率产生影响的因子，之后对每支股票使用相同的方式对因子权重进行分配，得到每支股票的综合因子值，将综合因子值符合一定条件的股票买入，不符合条件的股票卖出，从而形成投资策略。目前，随着越来越多的机构投资者使用多因子模型以及A股投资市场的风格频繁变化，市场上许多常用的因子已经失效，众多使用多因子模型的资产管理产品近年来业绩表现不佳。因此，如何改进多因子选股模型，如何选择有效的因子、如何对因子权重分配将成为投资者和学者研究的热点问题。

目前多因子模型建模中，选择有效因子大多采用因子测试的方法[1]，通过分析夏普比率、收益率等评价指标，选取在样本空间内表现较好的一批因子，再结合基金经理的经验从中选取若干因子建模，这种方法主观性强，并没有考虑到因子之间的相互作用。因子的权重分配主要采用打分法和回归法：打分法主要包括等权重法和专家打分法，这两种赋权方式没有从数据出发，很难反应因子的质量；回归法建立因子与股票收益率的线性模型，利用回归模型得到各个因子的权重，这种方法在因子较多时，往往很难排除因子间的相互干扰，模型准确度得不到保证。

机器学习方法可以从大样本中寻找可重现的规律，从而使用习得的规律来分类和预测。机器学习算法因为具有非线性、预测准确率高、泛化能力强等特点，而被广泛应用到量化投资各种生活场景中，且取得了一定的成果。陈荣达等(2014年)提出了基于启发式算法的支持向量机选股模型[2]，提高了支持向量机模型的训练精度和效率。He X, Pan J, Jin O等(2014年)使用GBDT解决了LR的特征组合问题[3]，在广告CTR预估中取得了不错的效果。李斌等(2017)建立了基于机器学习和技术指标的量化投资体系从而构建投资组合[4]，得出了收益和风险表现均优于大盘指数的策略。李文星等(2018年)使用半监督K-means核函数聚类方法应用于多因子选股模型中[5]，选出了较优的股票组合。吕凯晨等(2019年)使用多因子打分模型和支持向量机分类算法对沪深300成分股进行精选[6]，得到了远超同期沪深300指数的表现。

从目前的研究现状来看，机器学习方法在量化投资领域特别是多因子选股模型中取得了一定进展。但是，已有的研究主要是使用算法对多因子的权重分配进行改进，将打分法和回归法得到的线性模型优化为非线性模型，但是对于如何获得有效的因子和特征组合等方面的研究较少。随着常用因子的失效，因子的选择和特征提取将直接关系到后续选股模型的分选精度和泛化能力。基于此，在国内外已有研究的基础上，本文旨在完整地优化多因子选股过程，利用 GBDT + SVM 的两阶段综合模型对因子特征提取和因子建模展开研究：首先利用 GBDT 对备选因子库的批量因子进行特征提取并得到新的特征组合；再基于新的特征组合构建 SVM 股票分组模型。最后，利用 A 股市场日行情数据进行实证研究，并与经典多因子模型、支持向量机(SVM)优化的多因子模型等常见模型进行对比分析。

2. 选股模型因子库的建立

有效的因子是影响多因子模型效果的关键要素，为 GBDT-SVM 多层次选股模型选取适当的因子作为原始数据是模型有效性的前提。本文综合分析了各类学术论文和券商研究报告的因子研究成果，使用天软金融数据库和 Wind 金融数据库下载并计算百余个因子，并使用单因子测试的方法选出 43 个因子作为模型初始因子库。

本文建立了相关评价指标来判断因子的有效性，包括因子信息系数 IC、因子信息比 IR、夏普比率和股票组合年化超额收益率，这些指标从被选择股票的收益、波动性等来考察因子的有效性和持续性[7]。单因子测试的具体流程见图 1。

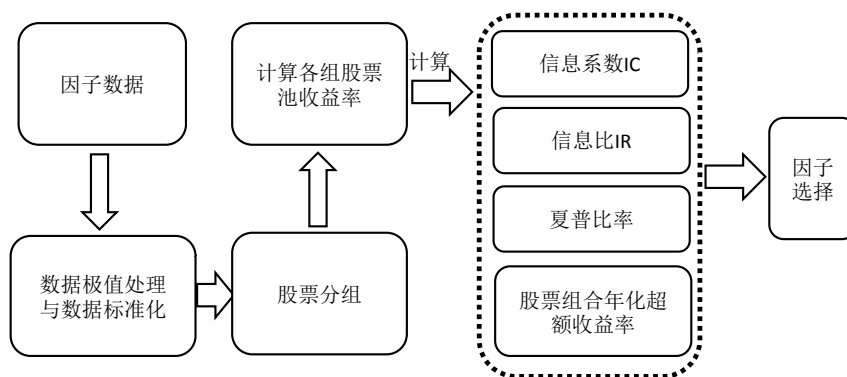


Figure 1. The procedure of single factor test
图 1. 单因子测试流程

信息系数(IC)指每个时间节点所有股票因子的值，与这些股票下个时间段收益率的相关系数。本文以一个月为一个周期，故某月的 IC 为月末每个股票因子值与下个月这些股票的收益率之间的相关系数。本文假设因子值和收益率均服从正态分布，使用皮尔逊相关系数进行计算。记股票在某月末的因子值为 x ，股票的下月收益率为 y ，则该月份 IC 为：

$$IC = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

IC 的取值在-1 与+1 之间，其绝对值越大，表明因子有效性越高，查阅相关文献得出，如果因子的 IC 绝对值大于 2%，则认为该因子有比较好的效果。

信息比率(IR)指因子在历史测试期间投资组合相对于基准指数的平均年化超额收益率与年化平均标

准差的比值，综合衡量了因子的收益与因子收益的稳定性。IR 越大，则表明该因子选取具有 alpha 的股票的能力较强。其计算公式为：

$$IR = \frac{R_{\text{factor}}}{\sigma_{\text{factor}}} \quad (2)$$

其中 R_{factor} 代表样本空间内的年化超额收益率， σ_{factor} 代表因子超额收益的年化标准差，本文基准指数设定为沪深 300 指数。

股票组合年化超额收益率指股票组合在样本期内累计超额收益与测试年数之比，反应因子获取超额正收益的能力。

夏普比率指因子在历史测试期间投资组合相对于无风险资产的平均年化超额收益率与年化平均标准差的比值，综合衡量了因子的收益与收益的稳定性。

本文使用 A 股市场 2005 年至 2012 年的数据进行单因子测试，选取出 IC 绝对值大于 2%，IR 大于 0.5，夏普比率大于 1，组合年化超额收益率大于 15% 的 43 个因子，有关因子说明见表 1。

Table 1. Factor description

表 1. 因子说明表

因子名称	因子描述	说明
Open	日开盘价	
High	日最高价	
Low	日最低价	
Close	日收盘价	
EPSGrowRatio_ttm	每股收益增长率	使用最近 12 个月数据(TTM)
NetEquityReturn_ttm	净资产收益率	使用最近 12 个月数据(TTM)
NetAssetsPS_ttm	每股净资产	使用最近 12 个月数据(TTM)
PriceDelay	价格时滞	
Turnover	市值调整换手率	
Moneyflow1	一个月资金流	
CurrentRatio	流动比率	
DebtEquity	权益负债比率	
QuickRatio	速动比率	
Moneyflow3	10 天资金流	
Buyamt4	散户主动买入金额	挂单额小于 4 万元定义为散户单
Sellamt4	散户主动卖出金额	挂单额小于 4 万元定义为散户单
Amount	日成交额	
Mudl	引力线指标	
Tema10	三重指数移动平均线	
Atr22	月真实波幅	
Vma10	变异平均线	
Acid	收集派发指标	

Continued

Amihud	Amihud 非流动性因子	
Vema10	10 日成交量指数平均线	
Elder90	90 日艾达透视指标	
LnMarketvalue	流通市值对数	
Hsl22	22 日换手率	
Set_Turn30	30 日收益率比换手率	
ROE_12	净资产收益率	使用最近 12 个月数据(TTM)
IVol	特质波动率	使用 5 分钟线数据构造
IDKurt	日内特质峰度	使用 5 分钟线数据构造
MonthDayRatio2	月涨幅与日涨幅之比	
Assets_ttm	总资产周转率	使用最近 12 个月数据(TTM)
Turnover_ratio_ttm	股东权益周转率	使用最近 12 个月数据(TTM)
Growth_ratio_ttm	营业收入增长率	使用最近 12 个月数据(TTM)
Buyamt2	大户主动买入金额	挂单额 20~100 万元定义为大单
Sellamt2	大户主动卖出金额	挂单额 20~100 万元定义为大单
Stm22	22 日动态买卖指标	
Bma60	布林带移动平均	
Weakr10	10 日压力位	
Elder120k	120 日艾达透视指标	
Vema5	5 日成交量指数平均	

多因子建模中可使用的因子较多,人为选取若干因子建模需要丰富的投资经验,同时容易因为市场风格的变化导致因子失效。本文利用 GBDT 在特征工程方面的优势,将整个因子库作为原始数据进行建模,使用 GBDT 模型从 43 个因子中提取有效信息,而不使用人工挑选的方法。

3. GBDT-SVM 多层次选股模型理论

3.1. 使用 GBDT 构造特征组合

梯度提升决策树(GBDT)是一种泛化能力较强的迭代型决策树算法,被广泛应用于搜索排序等场景中。GBDT 的训练过程使用了集成学习的 boosting 思想,多次迭代得到多颗决策树,从而给出预测和分类结果[8]。本文利用 GBDT 对原始因子库构造特征组合来代替主观选取因子的过程,针对每一条样本数据,提取 GBDT 模型的每一棵树作为该样本的一个特征,该特征的具体取值为样本在该决策树中所处的叶子节点的编号[9]。为便于数据对齐与后续模型的使用,本文将各特征值进行独热编码。

本文使用 43 个因子作为原始输入样本,则每个样本可表示为 $x = (x_1, x_2, \dots, x_{43})$,使用原始数据训练后的 GBDT 模型设为 $T = \{T_1, T_2, \dots, T_n\}$,其中 T_i 为第 i 棵决策树, n 为模型中决策树的总数,设 T_i 的叶节点序列为 $l_i = (l_{i1}, l_{i2}, \dots, l_{im})$,其中 $l_{ij} \in \{0, 1\}$ 表示样本是否落入 T_i 的第 j 个叶节点中,落入则 l_{ij} 取 1,否则取 0, m 为该树中叶节点的个数。故对于每个样本,GBDT 构造的特征组合为

$f = (l_1, l_2, \dots, l_m) = (l_{11}, l_{12}, \dots, l_{1m_1}, \dots, l_{i1}, l_{i2}, \dots, l_{im_i}, \dots, l_{n1}, l_{n2}, \dots, l_{nm_n})$ 。由此可以得到因子数据特征提取的过程如图 2 所示。

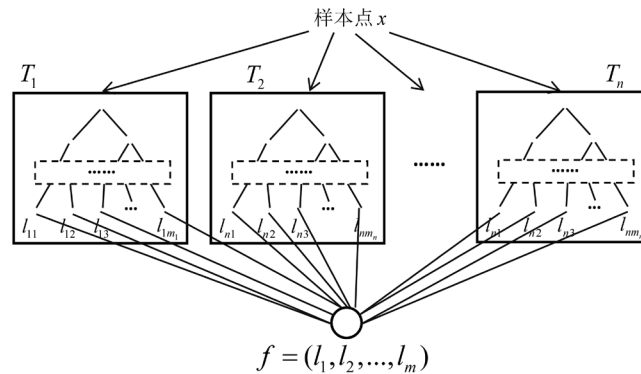


Figure 2. Feature structure using GBDT
图 2. GBDT 特征构造示意图

GBDT 模型中决策树的个数 n 和深度 d 决定特征向量的维度。若特征向量 f 的维度过高，则容易出现过拟合的情况；若维度较低，则提取的特征不能充分涵盖有效信息，导致模型精度较低。本文建模过程中使用带交叉验证的网格搜索方法对 n 和 d 进行了参数优化[10]。

3.2. 基于 SVM 的股票分类模型

支持向量机(SVM)是 1963 年 Vapnik 等人提出的一种机器学习方法[11]，它基于 VC 维理论和结构风险最小化原则，能够较好地处理小样本和非线性问题。本文使用 SVM 模型对股票进行分类，对每只股票下月收益率从大到小排序：取前 40%作为强势股，标记为 1；后 40%作为弱势股，标记为-1；中间 20%的股票排出训练集，相当于噪声数据。故本文使用二分类 SVM 模型进行建模。

假设样本训练集 $S = \{x_i, y_i\}, i = 1, \dots, n$ ， n 为训练样本的总数， x_i 为 GBDT 模型所得的特征向量， y_i 为 x_i 对应的输出值，取值为 1 或者-1。设线性分类器为 $f(x) = \omega x - b = 0$ ，且样本经过非线性函数 $\phi(x)$ 映射到高维空间后线性可分，则模型对应于求解最优化问题[12]：

$$\begin{aligned} \min \quad & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \\ \text{s.t.} \quad & y_i (\omega^\top \phi(x_i) + b) \geq 1 - \xi_i \\ & \xi_i \geq 0, i = 1, 2, \dots, n \end{aligned} \quad (3)$$

其中 C 为惩罚系数， ξ_i 为松弛变量。上述最优化问题的对偶问题为：

$$\begin{aligned} \min \quad & Q(\alpha) = -\sum_{i=1}^n \alpha_i + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j \Phi(x_i)^\top \Phi(x_j) \\ \text{s.t.} \quad & \sum_{i=1}^n \alpha_i y_i = 0 \\ & C \geq \alpha_i \geq 0, i = 1, 2, \dots, n \end{aligned} \quad (4)$$

其中 α_i 为拉格朗日因子， $\Phi(x_i)^\top \Phi(x_j)$ 为对应的核函数，可用 $K(x_i, x_j)$ 表示。根据 Kuhn-Tucker 定理，对偶问题的最优解即为原问题最优解。

参阅以前的研究成果发现，使用径向基函数作为本文多因子 SVM 模型的核函数能取得良好的效果。为了获得效果更优的 SVM 模型，本文需要调节参数惩罚系数 C 和径向基函数参数 γ 。惩罚系数 C 表示对误差的宽容度， C 过大则容易过拟合， C 过小则容易欠拟合， C 过大或过小，均会导致模型泛化能力变差。 γ 隐含地决定了数据映射到新的特征空间后的分布， γ 越大，支持向量越少，支持向量的个数影

响训练的速度和模型的泛化能力。本文使用 S 折交叉验证的方法选取较优的参数 C 和 γ [13]。

构建好 SVM 模型后,将预测数据集带入模型中,选取预测结果为 1 的股票作为需要进行模拟投资的投资组合。

3.3. GBDT-SVM 多层次模型的构建

本文使用 GBDT 构建因子的特征组合,再使用 SVM 对股票进行分类,从而优化经典多因子模型。为了模拟真实的投资过程,本文采用“滚动建模”的方式,模型每次只使用某个时间窗口内的数据进行训练,之后使用该时间窗口后的时间截面数据进行预测,得到该时间截面欲持有的股票。模拟投资完成后,将时间窗口向前移动,对下一个时间窗口和时间截面进行相同的操作[14]。

本文使用月度调换股票的方式,即每月月末确定下个月需要持有的股票。具体方法为使用该月前 12 个月的数据作为时间窗口对 GBDT 和 SVM 模型进行训练,之后将该月的数据带入模型,得到下个月应该持有的股票。滚动建模的过程如图 3 所示,其中每一格代表一个月的股票数据。



Figure 3. Rolling modeling diagram
图 3. 滚动建模示意图

因此,GBDT-SVM 多层次多因子选股模型的构建步骤如下:

步骤 1: 从原始的股票行情数据、财务数据和预期数据等构造出多因子模型的原始因子库。

步骤 2: 使用一个时间窗口的数据作为训练样本,训练 GBDT 模型,得到每只股票的特征组合。

步骤 3: 用步骤 2 得到的新特征组合数据作为训练集训练 SVM 模型,由此生成该时间窗口的 GBDT-SVM 综合模型。

步骤 4: 将预测样本带入训练好的 GBDT-SVM 综合模型,得出对股票下个月是否为强势股的分类,从而根据预测值选出相关股票,进行模拟投资。

步骤 5: 将时间窗口向前移动一个月,重复步骤 2~5,直至到达规定的建模结束日期。

步骤 6: 计算模拟投资的结果,并根据夏普比、年化收益率等指标进行评价,并将该模型与经典多因子模型和只用 SVM 模型优化的多因子模型进行对比。

4. 实证分析

4.1. 数据处理和模型训练

本文使用 2012 年 5 月 31 日至 2017 年 3 月 31 日的股票月末数据进行建模和预测,其中 2012 年 5 月 31 日至 2013 年 5 月 31 日的数据只用于模型的训练,并不得出预测的投资组合。模型使用月度换股的方式,使用股票的日数据会带来数据冗余和计算量的增大等问题,故本文使用的数据为原始数据中每月最后一个交易日的数据。

在对模型进行训练之前,需要对原始因子数据先进行极值处理,再进行标准化处理,以去除各个因子数据极端值的影响和量纲的影响,保证建模效果。

其中极值处理的方法为：对同一日期若干股票的数据序列，先计算数据序列 5%分位数和 95%分位数的值，之后将序列中低于 5%分位数的值均取 5%分位数，将高于 95%分位数的值均取 95%分位数。

标准化处理采用标准差标准化法，对于同一日期若干股票的数据序列 x ，则该方法计算公式为：

$$x_i = \frac{x_i - \bar{x}}{\sigma(x)} \quad (5)$$

其中 x_i 为序列第 i 个数据的值， \bar{x} 为序列的平均值， $\sigma(x)$ 为序列的标准差， x_i 为序列第 i 个数据标准化之后的值。

本文使用滚动建模的方式建立每个交易月对应的模型，之后按照模型的结果建立投资组合，从而可以得到模拟的投资损益情况，所以本文使用模型分类效果和投资组合盈利效果来对模型进行评价。为了方便评估模型分类效果，根据股票分类的实际需要，使用准确率作为模型评价的一个指标。定义模型某个时间窗口模型的准确率为：

$$\text{某时间窗口模型准确率} = \frac{\text{该时间窗口判断为强势股且真实为强势股的数量}}{\text{该时间窗口强势股的数量}}$$

其中强势股的定义见本文第 3 章，模型总的准确率定义为各时间窗口准确率的平均值。同时根据模型所要解决实际问题的特点，在评价体系中加入夏普比率、年化超额收益率、最大回撤率等指标，其中最大回撤率为：

$$\max_i \left(1 - \frac{D_i}{\max_{j < i} D_j} \right) \times 100\% \quad (6)$$

其中 D_i 为策略第 i 日的净值。夏普比率、年化超额收益率的指标定义见本文第 2 章。考虑到模型对股票的持仓周期较长，故计算收益率时不考虑手续费等交易成本以简化计算。

为了衡量 GBDT-SVM 多层次选股模型的优劣，将其与其他模型进行对比。定义 GBDT-SVM 多层次选股模型为模型 A，用等权打分法构建的经典多因子模型为模型 B，仅使用 SVM 进行滚动建模的选股模型为模型 C。

4.2. 结果分析

GBDT-SVM 多层次选股模型(模型 A)所得到的投资净值情况如图 4 所示，该图反映了模型的收益与基准指数沪深 300 指数收益的对比，纵坐标为净值情况，初始值为 1，代表投资的累计收益率。由图可以看出该模型效果显著，投资收益明显大于基准指数的收益。

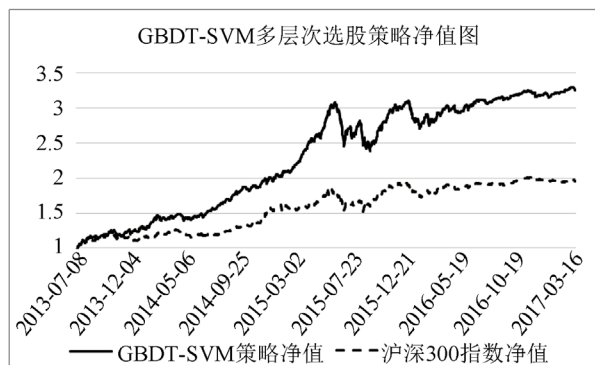


Figure 4. Net value chart of GBDT-SVM multi-level stock selection strategy
图 4. GBDT-SVM 多层次选股策略净值图

对 GBDT-SVM 多层次选股模型(模型 A)、用等权打分法构建的经典多因子模型(模型 B)、仅使用 SVM 进行滚动建模的选股模型(模型 C)进行效果评价, 结果如表 2 所示。

Table 2. Comparison of effects of three models
表 2. 三种模型效果对比

	准确率	夏普比率	年化超额收益率	最大回撤率
模型 A	56.78%	2.30	43.22%	33.25%
模型 B	54.95%	1.82	35.76%	24.53%
模型 C	56.04%	1.98	37.12%	30.29%

由表 2 可以看出, 从模型角度看, 模型 A 预测准确率得到了提高; 从投资角度看, 模型 A 获得了更高的超额收益, 并获得了更高的夏普比例值, 是行之有效的模型, 但应注意最大回撤率的增加会导致策略在某个时间段有亏损更大的可能。综合考虑, GBDT-SVM 多层次选股模型相对于其他两个模型更适合用于投资过程, 对投资决策有明显的现实指导意义。

参考文献

- [1] 赵胜民, 闫红蕾, 张凯. Fama-French 五因子模型比三因子模型更胜一筹吗——来自中国 A 股市场的经验证据[J]. 南开经济研究, 2016(2): 41-59.
- [2] 陈荣达, 虞欢欢. 基于启发式算法的支持向量机选股模型[J]. 系统工程, 2014, 32(2): 40-48.
- [3] He, X.R., et al. (2014) Practical Lessons from Predicting Clicks on Ads at Facebook. *Proceedings of the 8th International Workshop on Data Mining for Online Advertising*, ACM, New York, 24-27 August 2014, 1-9. <https://doi.org/10.1145/2648584.2648589>
- [4] 李斌, 林彦, 唐闻轩. ML-TEA: 一套基于机器学习和技术分析量化投资算法[J]. 系统工程理论与实践, 2017, 37(5): 1089-1100.
- [5] 李文星, 李俊琪. 基于多因子选股的半监督核聚类算法改进研究[J]. 统计与信息论坛, 2018, 33(3): 30-36.
- [6] 吕凯晨, 闫宏飞, 陈翀. 基于沪深 300 成分股的量化投资策略研究[J]. 广西师范大学学报(自然科学版), 2019, 37(1): 1-12.
- [7] 谢合亮, 胡迪. 多因子量化模型在投资组合中的应用——基于 LASSO 与 Elastic Net 的比较研究[J]. 统计与信息论坛, 2017, 32(10): 36-42.
- [8] Friedman, J.H. (2001) Greedy Function Approximation: A Gradient Boosting Machine. *Annals of Statistics*, **29**, 1189-1232. <https://doi.org/10.1214/aos/1013203450>
- [9] 姚旭, 王晓丹, 张玉玺, 等. 特征选择方法综述[J]. 控制与决策, 2012, 27(2): 161-166.
- [10] 黄卿, 谢合亮. 机器学习方法在股指期货预测中的应用研究——基于 BP 神经网络、SVM 和 XGBoost 的比较分析[J]. 数学的实践与认识, 2018, 48(8): 297-307.
- [11] Vapnik, V.N. (1997) The Nature of Statistical Learning Theory. *IEEE Transactions on Neural Networks*, **8**, 1564-1564. <https://doi.org/10.1109/TNN.1997.641482>
- [12] 张奇, 胡蓝艺, 王珏. 基于 Logit 与 SVM 的银行业信用风险预警模型研究[J]. 系统工程理论与实践, 2015, 35(7): 1784-1790.
- [13] Harris, T. (2015) Credit Scoring Using the Clustered Support Vector Machine. *Expert Systems with Applications*, **42**, 741-750. <https://doi.org/10.1016/j.eswa.2014.08.029>
- [14] 干伟明, 张涤新. 基于价值投资的多因子定价模型在中国资本市场的实证研究[J]. 经济经纬, 2018, 35(4): 136-140.

知网检索的两种方式：

1. 打开知网页面 <http://kns.cnki.net/kns/brief/result.aspx?dbPrefix=WWJD>
下拉列表框选择：[ISSN]，输入期刊 ISSN：2325-2251，即可查询
2. 打开知网首页 <http://cnki.net/>
左侧“国际文献总库”进入，输入文章标题，即可查询

投稿请点击：<http://www.hanspub.org/Submission.aspx>

期刊邮箱：sa@hanspub.org