

# 系统性风险视角下的中国企业动态财务困境预警：基于AdaBoost CSSVM-TW模型

邹承益, 王文胜\*

杭州电子科技大学经济学院, 浙江 杭州

收稿日期: 2025年8月4日; 录用日期: 2025年8月24日; 发布日期: 2025年9月8日

## 摘要

为了解决由于数据不平衡、信息不充分和概念漂移等原因导致的中国外贸企业财务困境预测准确率低的问题。本文利用2010年至2022年中国A股上市外贸企业系统性风险指标和财务指标的年度数据, 构建了时间加权结合AdaBoost成本敏感支持向量机模型, 用于动态预测企业财务困境。实证研究结果表明, 系统性风险指标具有独立于传统财务指标的预测潜力, 因此可作为中国外贸企业的非财务动态预警指标, 从而提高各种比较模型的预测准确性。结合系统性风险指标的时间加权与AdaBoost成本敏感支持向量机模型, 有效解决了数据不平衡、信息稀缺和概念漂移带来的挑战, 显著提高了在2015年中国股灾、中美贸易摩擦和COVID-19疫情下动态预测中国外贸企业财务困境的准确性, 可作为中国外贸企业高效的风险动态预警工具。

## 关键词

系统性风险, 动态财务困境预警, 概念漂移, 不平衡数据, AdaBoost CSSVM-TW模型

# Dynamic Financial Distress Early Warning for China's Enterprises from a Systemic Risk Perspective: Based on the AdaBoost CSSVM-TW Model

Chengyi Zou, Wensheng Wang\*

School of Economics, Hangzhou Dianzi University, Hangzhou Zhejiang

Received: Aug. 4<sup>th</sup>, 2025; accepted: Aug. 24<sup>th</sup>, 2025; published: Sep. 8<sup>th</sup>, 2025

\*通讯作者。

文章引用: 邹承益, 王文胜. 系统性风险视角下的中国企业动态财务困境预警: 基于 AdaBoost CSSVM-TW 模型[J]. 统计学与应用, 2025, 14(9): 41-53. DOI: 10.12677/sa.2025.149255

## Abstract

To tackle the problem of low accuracy in predicting financial distress in China's foreign trade enterprises, attributable to data imbalance, insufficient information and concept drift, this paper utilizes annual data on systemic risk indicators and financial metrics of China's foreign trade enterprises listed on the China's A-share market between 2010 and 2022 to construct the time weighting combined with AdaBoost cost sensitive support vector machine model for dynamic corporate financial distress prediction. Empirical findings indicate that systemic risk indicators possess predictive potential independent of traditional financial metrics. This makes them valuable as non-financial, dynamic early warning indicator for China's foreign trade enterprises, thereby enhancing the predictive accuracy of various comparative models. The time weighting combined with AdaBoost cost sensitive support vector machine model incorporating systemic risk indicators effectively addresses challenges arising from data imbalance, information scarcity and concept drift, significantly improving the accuracy of dynamic predicting financial distress in China's foreign trade enterprises under the 2015 Chinese stock market crash, the Sino-US trade friction and the COVID-19 epidemic, which can be used as an efficient risk dynamic early warning tool for China's foreign trade enterprises.

## Keywords

Systemic Risk, Dynamic Financial Distress Early Warning, Concept Drift, Imbalanced Data, AdaBoost CSSVM-TW Model

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

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



Open Access

## 1. 引言

当前, 中国正处于以国内大循环为主体、国内国际双循环相互促进的关键时期。在去杠杆、经济增长放缓、2015年股市震荡、中美贸易摩擦及新冠肺炎疫情等一系列事件的叠加冲击下, 中国外贸企业越来越多地暴露于系统性风险之中[1][2]。订单萎缩、资金结构不合理等内外部因素导致财务困境时有发生。财务困境不仅会导致企业经营受挫, 也会通过贸易链条、商业信用渠道和情绪溢出等多种途径迅速将风险传染至其他行业, 引发更大范围的系统性风险[3]。因此, 构建结合系统性风险因素的前沿机器学习技术, 优化中国外贸企业的财务困境预警模型尤为重要。

企业财务困境预警本质上是一个二分类问题, 通常以企业是否被特殊处理(Special Treatment, ST)作为判别依据。Beaver [4]率先提出单变量统计方法, 分析了29项财务比率对企业陷入财务困境前1至5年的预测能力。Altman [5]构建了多变量的Z-score模型, 取得了较高的预测准确率。逻辑回归[6]、决策树[7]、神经网络[8]和支持向量机[9]等人工智能模型同样被广泛应用于财务预警问题中。

然而, 在财务困境预警领域中通常面临类别不平衡的问题, 即财务健康的企业数量远多于陷入困境的企业。代价敏感学习通过引入差异化的分类错误代价机制, 对少数类样本赋予更高的错分代价, 对多数类样本赋予较低代价, 从而提升了对少数类样本的关注度, 使模型目标从最大化分类准确率转向为最小化整体错分代价[10]。此外, 传统的财务困境预警研究大多基于静态数据的静态模型, 忽视了财务数据随时间演变而产生的概念漂移问题。因为数据分布会随着时间变化, 导致原有模型不再适用于新数据,

预测准确率下降。Sun [11]提出 adaptive and dynamic ensemble of support vector machine (ADE-SVM)模型, 该模型通过动态地扩充数据集, 并集成多个 SVM 基分类器来提升模型适应性。在此基础上, Sun [12]进一步引入时间权重概念, 根据样本的时间先后赋予不同权重, 并结合 AdaBoost 框架改进了样本权重更新机制, 提出了 AdaBoost SVM internally integrated with time weighting (ADASVM-TW)模型, 以实现动态预警。

早期的财务预警研究主要基于公司的财务表现, 但随着对企业财务危机成因研究的日益完善, 发现系统性风险也是导致企业财务危机的重要因素[13]。当金融市场受到风险冲击时, 银行新增贷款规模通常会出现大幅减少[14], 这会对部分企业的流动性与偿债能力产生负面影响, 从而增加企业陷入财务困境的概率。系统性风险冲击可能会抑制居民消费[15], 从需求端对企业的财务状况造成冲击。

本文试图在现有研究的基础上[16], 引入系统性风险指标, 构建时间加权结合 AdaBoost 成本敏感支持向量机模型(AdaBoost CSSVM-TW), 用于动态预测企业财务困境。首先, 采用 XGBoost 模型和 SHapley Additive exPlanations (SHAP)方法分析系统性风险和中国外贸企业财务困境之间的关系, 从而探索系统性风险指标作为外贸企业财务困境预警中非财务指标的潜力。随后, 利用本文构建的 AdaBoost CSSVM-TW 模型, 从动态视角分析引入系统性风险因素后, 预警模型在识别潜在财务困境方面的预测分类性能。通过与 Sun [12]使用的 ADASVM-TW 模型相比, 引入系统性风险的 AdaBoost CSSVM-TW 模型对中国外贸企业财务困境的动态预测效果更好。进一步地, 在考虑由系统性风险导致的 2015 年中国股灾, 中美贸易战和新冠疫情极端事件对中国外贸企业财务困境影响时, 通过对比极端事件发生与否的预测准确率, 融入系统性风险的 AdaBoost CSSVM-TW 模型的动态预警效率显著提高。这表明该模型能够较好地捕捉到系统性风险对财务困境的显著影响。

## 2. 模型设定与方法说明

### 2.1. 模型设定

#### 2.1.1. 成本敏感支持向量机(Cost Sensitive Support Vector Machine)

在分类问题中, 传统的支持向量机(SVM)算法假设所有类别的分类错误代价是相等的。其基本思想为: 设训练样本集  $D = \{(X_i, Y_i)\}, i = 1, 2, \dots, n$ , 若样本集  $D$  线性可分, 则 SVM 需要找到一个最优超平面  $\omega^T x + b = 0$  将两类样本分开, 当样本集线性不可分时, 则需引入松弛变量  $\xi_i > 0$  和惩罚因子  $C$ , 目标函数为:

$$\min(\omega, \xi) = \frac{\|\omega\|^2}{2} + C \left( \sum_{i=1}^n \xi_i \right) \quad (1)$$

$$y_i (\omega^T x_i + b) \geq 1 - \xi_i \quad (2)$$

$$\xi_i \geq 0, \quad i = 1, 2, \dots, n \quad (3)$$

成本敏感支持向量机(CSSVM)通过引入不同类别的错分类代价, 使模型能够更加重视少数类样本的分类准确率, 从而在优化过程中调整分类超平面的位置, 以减少少数类样本的误判, 此时, 目标函数由式(1)变为:

$$\min(\omega, \xi) = \frac{\|\omega\|^2}{2} + C \left( C_+ \sum_{i \in n_+} \xi_i + C_- \sum_{j \in n_-} \xi_j \right) \quad (4)$$

$$C_+ = \frac{n}{n_+} \quad C_- = \frac{n}{n_-} \quad (5)$$

其中,  $n_+$  和  $n_-$  分别代表少数类和多数类样本数量,  $C_+$  代表少数类样本被误分为多数类样本的错分代价,

$C_-$  代表多数类样本被误分为少数类样本的错分代价。

### 2.1.2. ADASVM-TW 模型

ADASVM-TW 模型以 SVM 作为基分类器, 并在 AdaBoost 的框架中引入时间权重机制, 在综合考虑样本时效性和前一轮基分类器分类结果的基础上, 动态调整样本权重, 解决了概念漂移带来的影响。时间权重函数如式(6)所示。其中,  $t$  表示样本的时间年龄, 随样本由新到旧依次增大;  $\lambda$  为样本时间权重的惩罚系数, 取值为 $[0, 0.99]$ 。

$$\omega_t = \exp(-\lambda t), \quad t = 0, 1, 2, \dots, n-1 \quad (6)$$

ADASVM-TW 模型在集成分类器迭代训练过程中对样本加权机制进行了优化, 其样本权重函数如式(7)至式(10)所示。

$$\omega_1^i = \frac{1}{m}, \quad i = 1, 2, \dots, m \quad (7)$$

$$\omega_{u+1}^i = \omega_u^i \exp(-\alpha_u l_u^i \exp(\lambda t^i l_u^i)), \quad i = 1, 2, \dots, m; u = 1, 2, \dots, U-1 \quad (8)$$

$$l_u^i = \begin{cases} 1, & \text{if } f_u(x^i) = y^i \\ -1, & \text{if } f_u(x^i) \neq y^i \end{cases} \quad (9)$$

$$\alpha_u = 0.5 \ln \left( \frac{1 - e_u}{e_u} \right) \quad (10)$$

其中,  $U$  代表 ADASVM-TW 算法中的迭代总次数,  $m$  表示样本总数。  $\omega_{u+1}^i$  和  $\omega_u^i$  分别表示第  $u+1$  次和第  $u$  次迭代的第  $i$  个样本的权重。  $l_u^i$  用于控制样本权重值改变方向, 分类正确的赋值为 1, 分类错误的赋值为 -1, 此外,  $\alpha_u$  为由  $u$  基分类器的错误率  $e_u$  确定的权重因子, 它也是 AdaBoost 集合的  $u$  基分类器的投票权重。

### 2.1.3. ADA-CSSVM-TW 模型

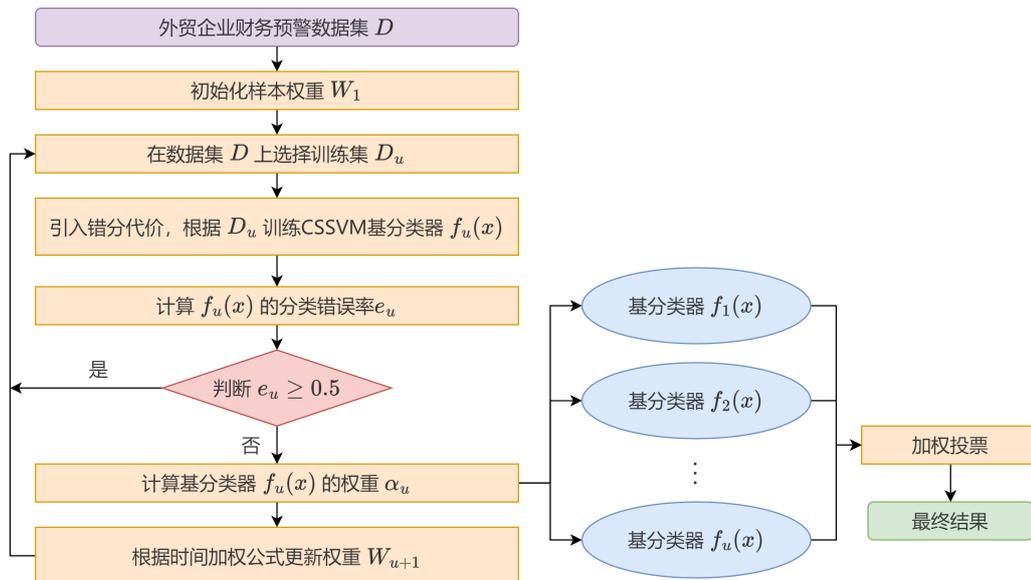


Figure 1. Flow diagram of the ADA-CSSVM-TW algorithm  
图 1. ADA-CSSVM-TW 算法的流程图

ADASVM-TW 模型虽在动态预警方面表现出较高的有效性,但未关注财务领域中普遍存在的数据分布不平衡问题。因此,本文通过引入错分代价构建代价敏感支持向量机(CSSVM),并将其作为 ADASVM-TW 模型的基分类器,得到的 ADA-CSSVM-TW 模型能够在兼顾动态预警性能的同时,更有效地处理数据不平衡问题。其算法的流程如图 1 所示。

## 2.2. 模型评估指标

在不平衡的数据集中,由于类别数量的显著差异,传统的评估指标,如准确性,可能会偏向于大多数类别,这可能会产生误导性的结果。所以,为了更好地评估模型在不平衡数据集的场景下的分类性能,本文使用了少数类样本分类准确率(TPR)评价模型对少数类样本的预测分类能力,以及 AUC 值、F 值和 G 值作为衡量分类器优劣的一个通用性能指标,这些指标是根据混淆矩阵(表 1)计算的。

Table 1. Confusion matrix

表 1. 混淆矩阵

	预测值 = 1	预测值 = 0
真实值 = 1	TP	FN
真实值 = 0	FP	TN

## 3. 研究设计和实证分析

### 3.1. 样本选择和数据来源

本文以 2010 至 2022 年间我国 A 股上市的外贸企业为研究对象,将“外贸企业”定义为财务报表中存在海外业务收入的企业,数据来源于同花顺 iFind 数据库的上市企业基本信息。国内研究通常将财务困境界定为企业被特殊处理(ST),其认定标准为企业连续两年经营亏损,虽然该标准在反映企业潜在的流动性风险或资产质量恶化方面可能存在一定滞后性,但在实践中仍具有较强的识别效力。因此,本研究基于企业 t-2 年的系统性风险指标和财务指标年度数据,预测企业在 t 年是否会被特殊处理(ST)。最终获得 3014 个企业样本,其中被特殊处理的企业样本有 58 个,正常企业样本 2956 个,样本不平衡比例约为 1:51。

在获得总体样本集后,对其进行预处理操作,主要包括:一是对离群值进行双侧 5% 缩尾处理;二是利用各个指标的中值填充其缺失值。

### 3.2. 指标选择与特征筛选

#### 3.2.1. 指标选择

Table 2. Initial financial indicator system

表 2. 初始财务指标体系

一级指标	二级指标
偿债能力	资产负债率( $X_7$ ), 现金流动负债比率( $X_8$ ), 现金流量与负债比率( $X_9$ ), 流动比率( $X_{10}$ ), 速动比率( $X_{11}$ ), 现金比率( $X_{12}$ ), 产权比率( $X_{13}$ ), 权益乘数( $X_{14}$ ), 营运资金与借款比( $X_{15}$ ), 现金流利息保障倍数( $X_{16}$ ), 长期借款与总资产比( $X_{17}$ )
盈利能力	营业毛利率( $X_{18}$ ), 营业净利率( $X_{19}$ ), 净资产收益率( $X_{20}$ ), 资产报酬率( $X_{21}$ ), 总资产净利润率( $X_{22}$ )
经营能力	总资产周转率( $X_{23}$ ), 应收账款周转率( $X_{24}$ ), 应付账款周转率( $X_{25}$ ), 存货周转率( $X_{26}$ ), 股东权益周转率( $X_{27}$ ), 流动资产周转率( $X_{28}$ ), 营运资金周转率( $X_{29}$ ), 非流动资产周转率( $X_{30}$ )

续表

发展能力	资本积累率( $X_{31}$ ), 总资产增长率( $X_{32}$ ), 净利润增长率( $X_{33}$ ), 所有者权益增长率( $X_{34}$ ), 管理费用增长率( $X_{35}$ ), 净资产收益率增长率( $X_{36}$ )
现金流水平	净利润现金净含量( $X_{37}$ ), 现金适合比率( $X_{38}$ ), 营业利润现金净含量( $X_{39}$ ), 全部现金回收率( $X_{40}$ )
风险水平	财务杠杆系数( $X_{41}$ ), 经营杠杆系数( $X_{42}$ ), 综合杠杆系数( $X_{43}$ )

在系统性风险指标方面, 共选择了 6 个初始指标, 分别表示如下: 在险价值(VaR)为  $X_1$ , 条件在险价值(CoVaR)为  $X_2$ , 条件在险价值的变化( $\Delta$ CoVaR)为  $X_3$ , 预期损失(ES)为  $X_4$ , 边际预期损失(MES)为  $X_5$ , 贝塔系数为  $X_6$ 。在财务指标方面, 我们从偿债能力、盈利能力、经营能力、发展能力、现金流水平和风险水平六个方面共选择了 37 个初始指标, 详见表 2。

### 3.2.2. 特征筛选

本文选取的 43 个指标作为模型的初始特征集, 但过多指标会不可避免地产生多重共线性问题, 因此须对初始特征进行筛选。本文将具有财务危机的 ST 企业分类为“1”, 将健康的非 ST 企业分类为“0”, 以获得两组样本。随后, 对两个样本组进行了双重显著性检验, 即双样本 Kolmogorov-Smirnov (K-S)检验和 Mann-Whitney U (MW-U)检验。初始指标的双重显著性检验结果见表 3 和表 4。

Table 3. K-S test results

表 3. K-S 检验结果

指标	显著性	指标	显著性	指标	显著性	指标	显著性
$X_1$	0.000	$X_{13}$	0.000	$X_{25}$	0.000	$X_{37}$	0.000
$X_2$	0.000	$X_{14}$	0.000	$X_{26}$	0.002	$X_{38}$	0.000
$X_3$	0.000	$X_{15}$	0.000	$X_{27}$	0.000	$X_{39}$	0.000
$X_4$	0.000	$X_{16}$	0.000	$X_{28}$	0.000	$X_{40}$	0.000
$X_5$	0.000	$X_{17}$	0.000	$X_{29}$	0.000	$X_{41}$	0.000
$X_6$	0.000	$X_{18}$	0.000	$X_{30}$	0.000	$X_{42}$	0.000
$X_7$	0.000	$X_{19}$	0.000	$X_{31}$	0.000	$X_{43}$	0.000
$X_8$	0.000	$X_{20}$	0.000	$X_{32}$	0.000		
$X_9$	0.000	$X_{21}$	0.000	$X_{33}$	0.000		
$X_{10}$	0.000	$X_{22}$	0.000	$X_{34}$	0.000		
$X_{11}$	0.000	$X_{23}$	0.000	$X_{35}$	0.000		
$X_{12}$	0.000	$X_{24}$	0.000	$X_{36}$	0.000		

Table 4. MW-U test results

表 4. MW-U 检验结果

指标	显著性	指标	显著性	指标	显著性	指标	显著性
$X_1$	0.000	$X_{13}$	0.000	$X_{25}$	0.008	$X_{37}$	0.000
$X_2$	0.000	$X_{14}$	0.000	$X_{26}$	0.114	$X_{38}$	0.000
$X_3$	0.000	$X_{15}$	0.000	$X_{27}$	0.002	$X_{39}$	0.000
$X_4$	0.000	$X_{16}$	0.000	$X_{28}$	0.000	$X_{40}$	0.000

续表

$X_5$	0.000	$X_{17}$	0.000	$X_{29}$	0.000	$X_{41}$	0.000
$X_6$	0.000	$X_{18}$	0.000	$X_{30}$	0.000	$X_{42}$	0.000
$X_7$	0.000	$X_{19}$	0.000	$X_{31}$	0.000	$X_{43}$	0.000
$X_8$	0.000	$X_{20}$	0.000	$X_{32}$	0.000		
$X_9$	0.000	$X_{21}$	0.000	$X_{33}$	0.000		
$X_{10}$	0.000	$X_{22}$	0.000	$X_{34}$	0.000		
$X_{11}$	0.000	$X_{23}$	0.000	$X_{35}$	0.000		
$X_{12}$	0.000	$X_{24}$	0.000	$X_{36}$	0.000		

为了保证指标选择的严格性, 只有当指标在 K-S 检验和 MW-U 检验中均不显著时( $P \geq 0.05$ ), 才剔除指标。根据双重显著性检验结果, 所有指标均保留。

### 3.3. 因子分析和 SHAP 方法分析因子重要性

本研究采用因子分析(FA)分别从初始系统风险指标和财务指标中提取公共因子。对于系统风险指标, Kaiser-Meyer-Olkin (KMO)统计量的值为 0.703, 巴特利特球度检验表明 P 值为 0。因此本文选择了两个因子 SystemicRisk1 和 SystemicRisk2, 它们共同贡献的累积方差为 83.392%。对于财务指标, KMO 统计量的值为 0.756, 而巴特利特球度检验表明 P 值为 0。总共选择了 13 个因子: Accounting1、Accounting2、...、Accounting13, 共同贡献的累积方差为 81.075%。

图 2 显示了我国系统性风险 SystemicRisk1 和 SystemicRisk2 的年平均值。近 10 年来, 2015 年、2018 年和 2020 年的 systemicRisk1 和 systemicRisk2 的年均值均为正, 说明这些年的系统性风险较高。这一结果证实了杨子晖[13]的结论。

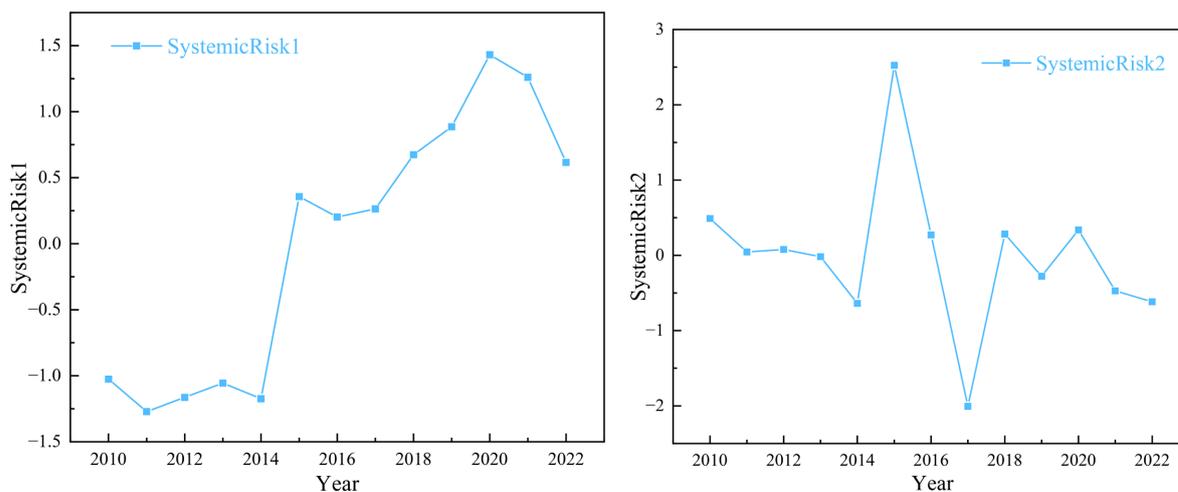


Figure 2. Annual average of SystemicRisk1 and SystemicRisk2

图 2. SystemicRisk1 和 SystemicRisk2 的年平均值

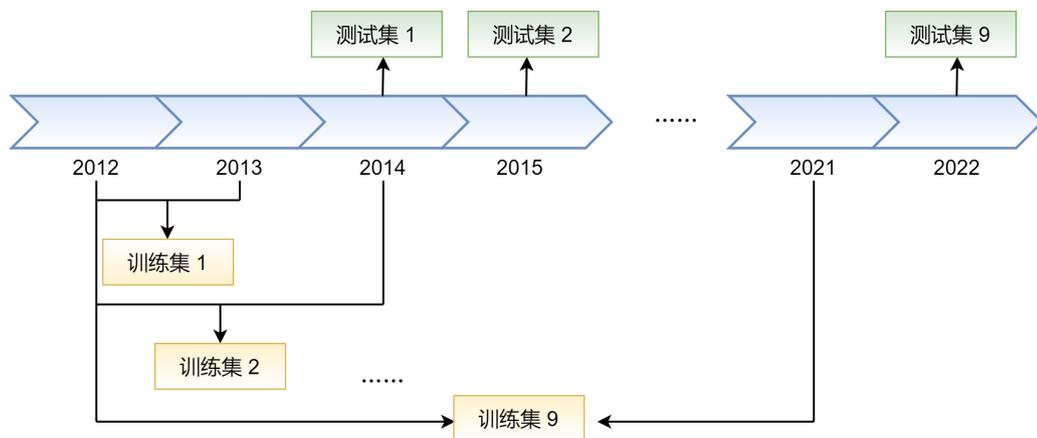
SHapley Additive exPlanations (SHAP)解释方法能够对指标的重要性进行评价, 本研究构建了基于可解释机器学习模型 XGBoost-SHAP 分析了系统性风险和财务指标在预测企业财务危机中的相对重要性, 结果如表 5 所示, 2 个系统性风险指标因子 SystemicRisk1 和 SystemicRisk2 的相对重要性的值分别为 8.04%

(排名第 7)和 3.16% (排名第 10), 这说明系统性风险指标具有独立于财务信息的预测能力, 能够成为预测企业财务危机的有效先行指标。与此同时, 财务指标因子 Accounting10、Accounting9、Accounting11、Accounting3、Accounting5 和 Accounting12 的重要性排序均位于前 6 位, 再次表明企业财务信息是我国企业财务危机预警体系中不可或缺的组成部分。

**Table 5.** Analysis of the relative importance of predictors of corporate financial distress  
**表 5.** 企业财务危机预测变量的相对重要性分析

	相对重要性	相对重要性排序
SystemicRisk1	8.04%	7
SystemicRisk2	3.16%	10
Accounting1	3.25%	9
Accounting2	1.45%	13
Accounting3	9.26%	4
Accounting4	1.26%	14
Accounting5	8.77%	5
Accounting6	1.63%	12
Accounting7	1.82%	11
Accounting8	4.49%	8
Accounting9	13.70%	2
Accounting10	23.43%	1
Accounting11	10.08%	3
Accounting12	8.56%	6
Accounting13	1.10%	15

### 3.4. 动态数据集构建



**Figure 3.** Principle of dynamic datasets  
**图 3.** 动态数据集原理

为实现模型的动态预警, 本文构建了动态数据集。其基本原理为: 随着时间的推移, 以年度为单位不断调整训练集与测试集的构成, 在测试集向前滚动的同时, 训练集也随之扩充历史数据。具体的构建过程如图 3 所示。

### 3.5. 模型分析

针对上述提出的 ADA-CSSVM-TW 模型, 为了评估引入系统性风险指标前后的预测性能, 本文以 ADASVM-TW 模型作为对比模型进行分析研究。两个模型在各个年份的分类性能如表 6 所示, 加粗的数字是两个模型中的最大值。在纳入系统性风险指标后, 两个模型在 9 个预测年份的评价指标上都有显著的提高, 具体来说, 在九个预测年份中, AUC 和 G 值表现出大约 0.3%到 4%的增量, 而 TPR 和 F 值表现出大约 1%到 8%的增量。这表明当加入系统性风险指标时, 预警模型的预测准确性得到显著提升, 更有助于外贸企业提前发现潜在的财务风险。平均来看, AUC 和 G 值的均值表现出大约 1.4%到 2.2%的增量, TPR 和 F 值的均值表现出大约 2.9%到 4%的增量, 说明加入系统性风险指标对模型的预测效果有进一步的提升, 系统性风险指标的引入能为外贸企业财务危机预警模型提供更好的支撑。

**Table 6.** Model prediction results with systemic risk indicators

**表 6.** 加入系统性风险指标的模型预测结果

指标	模型	2014	2015	2016	2017	2018	2019	2020	2021	2022	均值
TPR	ADA-CSSVM-TW	0.8783	0.8412	0.8133	0.9583	0.7818	0.7037	0.8380	0.7167	0.7455	0.8085
	ADASVM-TW	0.7723	0.6831	0.7607	0.7824	0.5273	0.5767	0.6013	0.5188	0.5802	0.6448
AUC	ADA-CSSVM-TW	0.8931	0.8517	0.7902	0.9437	0.7174	0.8306	0.8445	0.7818	0.8199	0.8303
	ADASVM-TW	0.8021	0.7652	0.7356	0.7765	0.6867	0.7869	0.7561	0.8187	0.7044	0.7591
F 值	ADA-CSSVM-TW	0.6598	0.7571	0.6087	0.8127	0.6444	0.6909	0.7619	0.6478	0.6613	0.6938
	ADASVM-TW	0.6914	0.6000	0.5202	0.7028	0.6780	0.5923	0.4828	0.5266	0.4941	0.5876
G 值	ADA-CSSVM-TW	0.8823	0.8612	0.7814	0.9367	0.7370	0.8410	0.8487	0.7764	0.7965	0.8290
	ADASVM-TW	0.7825	0.7448	0.7503	0.7551	0.6318	0.7830	0.6926	0.8189	0.7396	0.7443
$\Delta$ TPR	ADA-CSSVM-TW	0.0208	0.0389	0.0185	0.0441	0.0370	0.0292	0.0583	0.0454	0.0488	0.0379
	ADASVM-TW	0.0281	0.0256	0.0142	0.0459	0.0263	0.0397	0.0765	0.0288	0.0372	0.0358
$\Delta$ AUC	ADA-CSSVM-TW	0.0057	0.0194	0.0098	0.0271	0.0171	0.0221	0.0396	0.0349	0.0157	0.0213
	ADASVM-TW	0.0086	0.0168	0.0112	0.0037	0.0103	0.0221	0.0339	0.0275	0.0129	0.0163
$\Delta$ F 值	ADA-CSSVM-TW	0.0112	0.0537	0.0262	0.0291	0.0235	0.0347	0.0498	0.0190	0.0189	0.0296
	ADASVM-TW	0.0196	0.0426	0.0195	0.0457	0.0214	0.0546	0.0297	0.0235	0.0213	0.0309
$\Delta$ G 值	ADA-CSSVM-TW	0.0101	0.0291	0.0112	0.0252	0.0130	0.0259	0.0359	0.0277	0.0137	0.0213
	ADASVM-TW	0.0075	0.0128	0.0109	0.0036	0.0172	0.0157	0.0304	0.0221	0.0120	0.0147

注:  $\Delta$ TPR、 $\Delta$ AUC、 $\Delta$ F 值和  $\Delta$ G 值分别表示加入系统性风险指标和未加入系统性风险指标的模型比较时 TPR、AUC、F 值和 G 值的增量。

由系统性风险引发的 2015 年股灾、2018 年中美贸易战和 2020 年新冠疫情爆发对外贸企业的财务状

况造成了较大的不确定性和冲击。因此我们针对这些极端事件发生两年后(即 2017 年、2020 年和 2022 年)的外贸企业财务困境的预测效果进行分析,从表 6 可以看出,引入系统性风险后的两模型在 2017 年 TPR 值分别比未引入时提高了 4.41% 和 4.59%, 同样地, 结合系统性风险指标后, 2020 年的 TPR 值分别提高 5.83% 和 7.65%, 2022 年的 TPR 值分别提高 4.88% 和 3.72%。这表明, 在极端事件中, 引入系统性风险指标的预警模型有助于更有效地识别风险企业, 从而能够提高外贸行业的财务危机预警效率。进一步分析, 将系统性风险纳入非极端事件年份的预警模型中, TPR 值的平均提升幅度分别为 3.16% 和 2.71%, 与 2017 年、2020 年、2022 年相比, 增幅相对较小。这表明随着系统性风险水平的提高, 融合系统性风险的模型在预测两年后外贸企业财务困境的效率变得更加明显。

此外, 将两个模型 2014~2022 年评价指标的均值绘制成柱状图, 如图 4 所示, 在纳入系统性风险指标后, ADA-CSSVM-TW 模型在 TPR 值上的平均得分达到 80.85%, 相比 ADASVM-TW 模型的 64.48% 提升了 25% 左右, 显著增强了对高风险企业的识别能力。除 TPR 外, 该模型在综合指标 AUC、G 值和 F 值上也整体优于 ADASVM-TW 模型, 验证了其在分类性能方面的优势。值得注意的是, ADASVM-TW 模型并未关注数据不平衡的问题, 模型在构建过程中受到多数类样本的较大影响, 即非 ST 公司的高分类准确率掩盖了 ST 公司低分类准确率的影响, 所以即使 ST 公司的分类准确率不高(64.48%), G 值和 AUC 值仍然能够表现良好。而在实际的财务预警问题中, ST 企业被误判可能带来更大的经济损失, 因此模型对 ST 企业的识别能力应被优先考虑。综上, 纳入系统性风险指标的 ADA-CSSVM-TW 模型在处理动态不平衡财务预警问题上性能更佳。

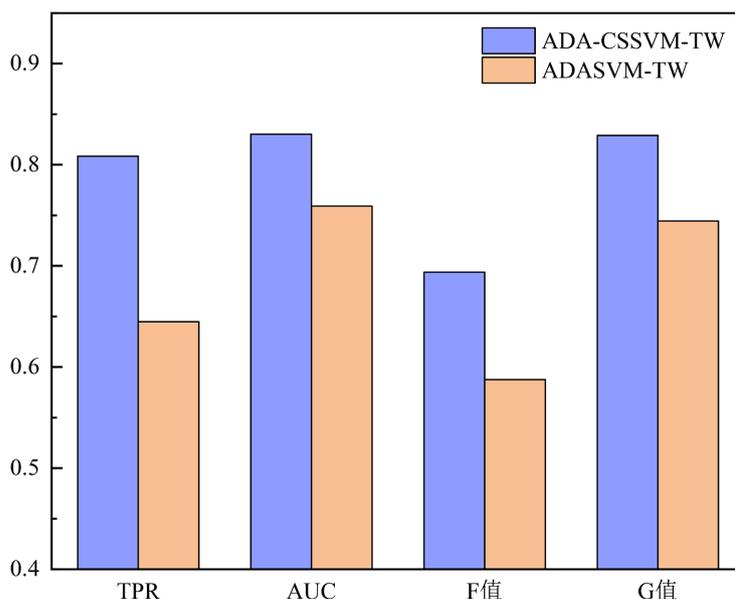


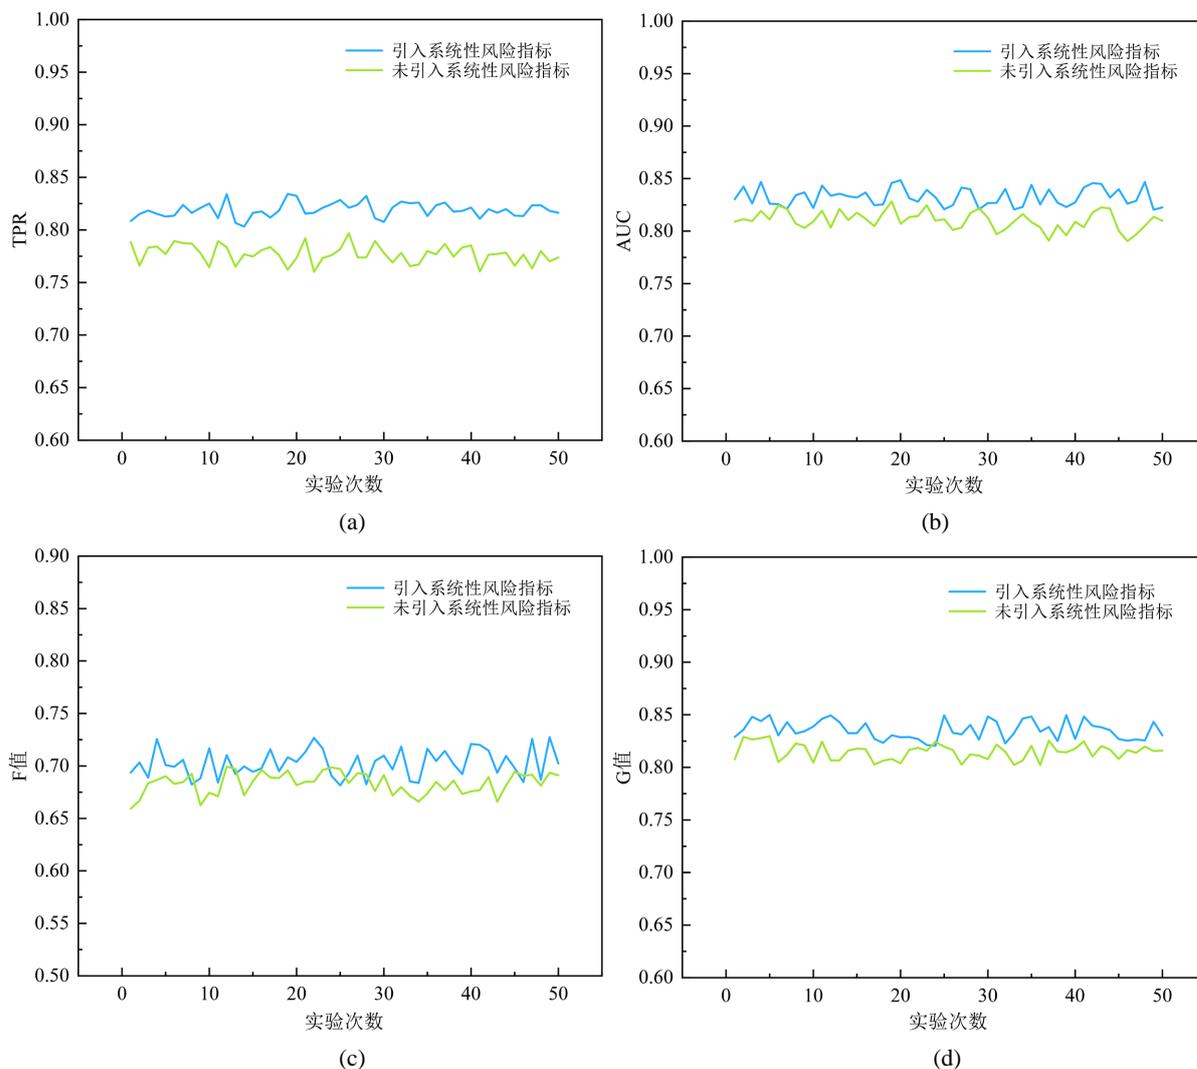
Figure 4. Comparison of the mean evaluation indicators

图 4. 评价指标均值对比

### 3.6. 稳定性分析

为了更直观地展示引入系统性风险指标对效果提升的稳健性, 本文绘制了 ADA-CSSVM-TW 模型在所有测试年份中进行 50 次重复实验的各项指标均值折线图(如图 5 所示), 图中的横轴表示实验次数, 纵轴表示评价指标的结果, 可以看出, 引入系统性风险指标的模型在整体分类准确性和稳定性方面均优于未引入该指标的模型。该结果进一步说明, 系统性风险指标在提升财务困境预测效果方面具有显著作用,

再次验证了其在预警模型构建中的重要价值。



**Figure 5.** Mean line chart of each index of 50 replicates. (a) Mean TPR for 50 replicates; (b) AUC mean for 50 replicates; (c) Mean TPR for 50 replicates; (d) AUC mean for 50 replicates

**图 5.** 50 次重复实验的各项指标均值折线图。(a) 50 次重复实验的 TPR 均值；(b) 50 次重复实验的 AUC 均值；(c) 50 次重复实验的 TPR 均值；(d) 50 次重复实验的 AUC 均值

#### 4. 结论与启示

本文尝试从系统性风险这一视角出发，在一般财务指标的基础上融合系统性风险指标构成外贸企业财务危机预警指标体系。结合可解释机器学习模型 XGBoost-SHAP 分析导致企业财务危机的影响因素，并构建 ADA-CSSVM-TW 动态预警模型，深入探究系统性风险对中国外贸企业财务危机预警的影响。以我国外贸企业 2010~2022 年的数据为样本进行实证研究，本文得出的主要结论如下：

第一、本文研究表明，系统性风险指标在财务危机预警中起着重要作用。通过实证分析发现，2 个系统性风险指标因子 SystemicRisk1 和 SystemicRisk2 在 XGBoost 模型的 SHAP 分析方法下的相对重要性的值分别为 8.04% 和 3.16%，表明系统性风险可以作为中国外贸企业有效的非财务预警指标。

第二、引入系统性风险指标的 ADA-CSSVM-TW 模型在各年份上的 TPR、AUC、F 值和 G 值等评价

指标上均有显著提升。尤其是在 2015 年股灾、2018 年中美贸易战和 2020 年新冠疫情等由系统性风险引发的极端事件中, 该模型展现出更高效的实时预测性能。

第三、构建的 ADA-CSSVM-TW 模型通过引入代价敏感学习和时间加权机制, 在综合考虑样本时效性和前一轮基分类器分类结果的基础上, 动态调整样本权重, 有效解决了数据不平衡与概念漂移所带来的影响, 从而实现企业财务困境的动态预警。

基于以上结论, 本文得出以下两点启示:

第一、鉴于系统性风险指标对中国外贸企业财务危机的显著预测能力, 建议监管机构和企业可以将系统性风险指标纳入财务预警框架, 完善财务风险控制长效机制。中国企业应优先考虑对系统性风险指标进行持续监测和评估, 以增强其在应对经济不确定性的抵御能力。

第二、ADA-CSSVM-TW 模型在纳入系统性风险指标后, 其出色的实时预测准确率表明其有潜力成为高效的动态预警工具。因此, 相关部门可考虑采用该模型作为实时风险评估工具的一部分。该模型不仅提高了对高风险企业的识别率, 还为将系统性风险指标纳入决策过程提供了一个稳健的框架, 能够确保更有效的风险管理, 推动企业健康、可持续发展。

## 基金项目

教育部人文社会科学研究规划基金项目(24YJA910006)。

## 参考文献

- [1] Zhang, P., Yin, S. and Sha, Y. (2023) Global Systemic Risk Dynamic Network Connectedness during the COVID-19: Evidence from Nonlinear Granger Causality. *Journal of International Financial Markets, Institutions and Money*, **85**, Article ID: 101783. <https://doi.org/10.1016/j.intfin.2023.101783>
- [2] Che, Y., Yuan, M., Zhang, Y. and Zhao, L. (2024) Cross-Border E-Commerce and China's Exports during the COVID-19 Pandemic. *China & World Economy*, **32**, 215-242. <https://doi.org/10.1111/cwe.12537>
- [3] Li, Y., Chen, S., Goodell, J.W., Yue, D. and Liu, X. (2023) Sectoral Spillovers and Systemic Risks: Evidence from China. *Finance Research Letters*, **55**, Article ID: 104018. <https://doi.org/10.1016/j.frl.2023.104018>
- [4] Beaver, W.H. (1966) Financial Ratios as Predictors of Failure. *Journal of Accounting Research*, **4**, 71-111. <https://doi.org/10.2307/2490171>
- [5] Altman, E.I. (1968) Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, **23**, 589-609. <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>
- [6] 方匡南, 范新妍, 马双鸽. 基于网络结构 Logistic 模型的企业信用风险预警[J]. 统计研究, 2016, 33(4): 50-55.
- [7] Kim, S.Y. and Upneja, A. (2014) Predicting Restaurant Financial Distress Using Decision Tree and Adaboosted Decision Tree Models. *Economic Modelling*, **36**, 354-362. <https://doi.org/10.1016/j.econmod.2013.10.005>
- [8] 关欣, 王征. 基于 Logistic 回归和 BP 神经网络的财务预警模型比较[J]. 统计与决策, 2016(17): 179-181.
- [9] Mselmi, N., Lahiani, A. and Hamza, T. (2017) Financial Distress Prediction: The Case of French Small and Medium-Sized Firms. *International Review of Financial Analysis*, **50**, 67-80. <https://doi.org/10.1016/j.irfa.2017.02.004>
- [10] 李艳霞, 柴毅, 胡友强, 等. 不平衡数据分类方法综述[J]. 控制与决策, 2019, 34(4): 673-688.
- [11] Sun, J., Li, H. and Adeli, H. (2013) Concept Drift-Oriented Adaptive and Dynamic Support Vector Machine Ensemble with Time Window in Corporate Financial Risk Prediction. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, **43**, 801-813. <https://doi.org/10.1109/tsmca.2012.2224338>
- [12] Sun, J., Fujita, H., Chen, P. and Li, H. (2017) Dynamic Financial Distress Prediction with Concept Drift Based on Time Weighting Combined with Adaboost Support Vector Machine Ensemble. *Knowledge-Based Systems*, **120**, 4-14. <https://doi.org/10.1016/j.knosys.2016.12.019>
- [13] 杨子晖, 张平淼, 林师涵. 系统性风险与企业财务危机预警——基于前沿机器学习的新视角[J]. 金融研究, 2020, 506(8): 152-170.
- [14] Ivashina, V. and Scharfstein, D. (2010) Bank Lending during the Financial Crisis of 2008. *Journal of Financial Economics*, **97**, 319-338. <https://doi.org/10.1016/j.jfineco.2009.12.001>

- [15] Allen, L., Bali, T.G. and Tang, Y. (2012) Does Systemic Risk in the Financial Sector Predict Future Economic Downturns? *Review of Financial Studies*, **25**, 3000-3036. <https://doi.org/10.1093/rfs/hhs094>
- [16] 任婷婷, 鲁统宇, 崔俊. 基于改进 AdaBoost 算法的动态不平衡财务预警模型[J]. 数量经济技术经济研究, 2021, 38(11): 182-197.