

# 結合台灣經濟新報之永續發展指標 與機器學習之企業財務危機預測模型研究

陳昆皇

李庭安

明志科技大學工業工程與管理系

明志科技大學工業人工智慧學士學位學程

## 摘要

過去企業財務危機研究多以財務報表為主要資訊來源。然而，財務資料僅呈現期末經營結果，所建構之財務危機預測模型往往於財務狀況已明顯惡化時才產生警示，亦容易將短期營運波動誤判為結構性風險。企業危機並非瞬時事件，而是隨時間累積的形成過程，因此若僅依單期財務狀態判斷，難以辨識危機形成初期的風險訊號。為觀察財務危機形成過程中的早期變化，本研究以多期財務資料分析企業財務風險變動，並納入可反映治理與營運異常的非財務資訊。本研究以臺灣永續發展評級之負面事件變數作為事件型風險指標。相較於財務報表反映營運結果與資本結構的期末狀態，負面事件直接呈現治理失序與管理問題，例如違規裁罰、訴訟爭議、違約風險與重大勞資衝突。此類事件多發生於財務惡化之前，並可能透過信用信任下降、融資條件轉差、交易關係收縮與監理成本上升等途徑，逐步轉化為資金壓力與財務結構惡化。當負面事件於多期持續出現或程度加劇時，表示問題具有延續性，並形成可觀測的風險累積軌跡，可補足財報對早期變化反應遲緩的限制。基於此一風險形成機制，本研究建構整合多期財務指標、負面事件訊號與跨期動態特徵的早期預警架構，將企業危機視為時間累積的過程，而非單一年度的狀態判斷。本研究以台灣經濟新報(Taiwan Economic Journal)2016 至 2024 年台灣上市櫃公司為樣本，建立三年期滾動時序特徵，並採用梯度提升決策樹進行分類建模。實證結果顯示，1 年期資料對比 3 年期資料顯著提升樣本外辨識能力，Area Under the Curve(AUC)由 0.8837 提升至 0.9222。特徵重要性分析進一步指出，負面事件變數的預測貢獻高於多數傳統財務比率，且其出現時間早於財務惡化，顯示在危機形成期間，治理與營運異常先由事件訊號被捕捉，財務指標則於後續階段提供危機確認。綜合而言，本研究提出一項「事件訊號提前示警、財務趨勢後續確認」的監測架構，說明企業財務危機具有可觀測的形成歷程，並提供監理機關、投資人與企業風險管理之實證依據。

關鍵詞：企業財務危機、機器學習、ESG (Environmental, Social, and Governance)、Taiwan Economic Journal ESG、早期預警模型

## Abstract

Previous research on corporate financial distress has predominantly relied on financial statements as primary sources of information. However, financial data reflect end-of-period operating outcomes; consequently, prediction models constructed from such data often issue warnings only after financial conditions have substantially deteriorated and may misclassify short-term operational fluctuations as structural risks. Corporate distress is not an instantaneous event but a cumulative process that develops over time. Accordingly, reliance on a single-period financial condition makes it difficult to identify early risk signals during the initial stages of a crisis. To capture early changes in the development of financial distress, this study analyzes multiperiod financial information and incorporates non-financial indicators that reflect governance and operational abnormalities. Specifically, negative event variables from the Taiwan Sustainability Ratings were employed as event-based risk indicators. While financial statements represent the end-of-period status of operating performance and capital structure, negative events directly reveal governance disorder and managerial problems such as regulatory violations and penalties, litigation disputes, default risk, and major labor conflicts. These events typically occur before observable financial deterioration and may gradually translate into financial pressure through multiple channels, including declining creditworthiness, worsening financing conditions, contracting trading relationships, and increased regulatory costs. Ultimately, this leads to liquidity strain and capital structure impairment. When negative events persist across multiple periods or intensify in severity, they indicate the continuity of underlying problems and form an observable trajectory of risk accumulation, thereby compensating for the delayed responsiveness of financial statements to early changes. Based on this risk formation mechanism, this study develops an early warning framework that integrates multiperiod financial indicators, negative-event signals, and intertemporal dynamic features, conceptualizing corporate distress as a time-accumulating process rather than a single-year state assessment. Using data on Taiwanese listed firms from the Taiwan Economic Journal database for 2016–2024, three-year rolling temporal features were constructed, and a gradient-boosting decision tree classifier was applied. The empirical results show that three-year data significantly improve out-of-sample identification performance compared with one-year data, with the Area Under the Curve(AUC) increasing from 0.8837 to 0.9222. Feature importance analysis further indicates that negative event variables contribute more to prediction than most traditional financial ratios and tend to emerge earlier than financial deterioration, suggesting that governance and operational abnormalities are first captured by event signals during crisis formation, whereas financial indicators provide confirmation at later stages. Overall, this study proposes a monitoring framework characterized by “event signals for early warning and financial trends for subsequent confirmation.” The findings demonstrate that corporate financial distress follows an observable developmental trajectory and provides empirical evidence relevant to regulators, investors, and corporate risk management practices.

**Keywords:** corporate financial distress, machine learning, ESG (Environmental, Social, and Governance) , Taiwan Economic Journal ESG, early warning model

## 1. 緒論

企業財務危機預測研究長期以會計財務比率作為主要資訊來源，並多透過單一年度財務報表辨識企業風險 (Altman, 1968)。然而，財務報表反映的是經營績效與融資條件已經變化後的期末結果，當預警訊號出現時，企業狀況通常已進入惡化階段，使風險辨識落後於問題形成。單年度資訊因此較適合確認既有財務困境，而難以捕捉危機早期的累積過程。公司治理與風險管理研究亦指出，企業失敗多源於管理決策偏誤、內部控制弱化與過度風險承擔的長期累積，相關異常往往在財務報表出現明顯變化之前即已存在 (Stulz, 2025)。因此，單期會計資訊雖具辨識能力，但警示時點偏後，限制預警系統的實務效益。

若欲提前辨識風險，評估方式須由觀察單期水準轉為辨識跨期變化。多期財務資料可呈現企業體質隨時間的變動軌跡，有助於區分短期波動與持續性衰退 (Li & Miu, 2010)。然而，即使納入財務趨勢，訊號仍可能偏晚，原因在於企業危機並非由財務惡化開始，而常源於治理失衡與營運異常。違規裁罰、訴訟爭議與其他負面事件，往往在會計績效轉弱前即已發生，並透過監管壓力、聲譽受損與融資條件惡化等途徑逐步轉化為財務壓力 (Broadstock et al., 2021; Friede et al., 2015)。此一時序關係顯示，非財務負面事件先出現，其後財務趨勢惡化，最終才反映於財務報表，因此企業危機屬於可觀察的累積過程，而非單一時點的狀態判斷。

基於上述觀點，本研究將企業危機界定為多來源訊號隨時間累積的動態過程，並建構整合多期財務資訊與臺灣永續發展評級負面事件訊號之預警架構。研究目的不僅在提升分類準確度，更在釐清不同訊號於危機形成中的時序角色：負面事件提供前期風險線索，多期財務趨勢作為後續風險確認，形成先由事件示警、再由財務確認的監測邏輯。本文並以機器學習方法處理多維特徵關係，檢驗在財務指標尚未明顯惡化時，納入事件訊號是否能有效提升高風險企業之辨識能力。

## 2. 文獻探討

本章回顧相關文獻，先整理以財務比率與市場資訊為基礎的傳統危機預測方法及其隱含假設，再說明公司治理與永續風險研究如何修正該假設，指出治理與營運異常往往早於財務績效變化出現。進一步，本章討論事件型資訊與結構化非財務資料在風險觀測上的意義，並說明機器學習方法如何處理多來源與跨期特徵關係，以建立可檢驗危機形成時序的分析基礎。

### 2.1 財務危機預測

企業財務危機預測最早建立於會計資訊分析架構。Beaver (1966) 指出現金流量與負債結構可有效區分存續與破產企業；Altman (1968) 整合多項財務比率提出 Z-score 以衡量破產風險；其後 Ohlson (1980) 與 Zmijewski (1984) 分別以 Logit 與 Probit 模型估計違約機率，降低對統計分配假設的依賴。上述研究隱含共同前提，即企業風險會反映於財務績效惡化，因此可由單一年度財務報表進行辨識。

後續研究納入市場資訊以擴展風險衡量。Merton (1974) 以選擇權定價理論推導違約機率，將企業價值與資本結構納入分析。然而，無論採會計或市場資料，多數模型仍以特定時點的可觀察資訊判斷企業是否處於危機狀態，將企業危機視為狀態辨識問題。此類模型通常於財務狀況已明顯惡化時才辨識風險，其性質較接近事後判別，而非事前預警。隨著計算能力提升，近二十年的研究轉向非線性模型的開發。Qiu et al. (2025) 透過對比傳統模型與 RF/SVM，證實 RF 結合 soft probability 在財務困難預測時準確度超越基準模型，有效捕捉財務變數間的非線性特徵。

除了演算法的改進，研究者開始加入非財務指標來增加預警維度。Wang et al. (2025) 指出，非財務變數在財務困難預測中比傳統財務指標更具關鍵性，能補足財報的滯後性。此外，Zhao et al. (2022) 利用 sentiment tone 分析線上論壇與管理討論，發現負面語氣變化往往比財務數字更早反映

危機訊號，目前的預警架構已演變為整合大數據與人工智慧的多維度評估模式。

## 2.2 非財務風險

公司治理與風險管理研究對上述前提提出修正。相關文獻指出，企業失敗常源於管理決策偏誤、代理問題與內部控制鬆動，且此類問題往往在財務績效惡化之前即已存在 (Stulz,2025)。即使企業仍維持會計獲利，治理缺失與聲譽衝擊仍可能預示後續績效下降 (Broadstock et al.,2021)，長期永續表現亦與企業價值具有穩定關聯 (Friede et al.,2015)。

上述研究顯示企業風險具有時間順序。治理異常首先反映管理品質與內控狀態，其後違規與社會事件透過監管壓力與信任流失轉化為融資壓力，最終才集中呈現在財務報表。因此，財務資訊較可能反映危機的後期結果，而非最早可觀察的風險來源。

## 2.3 公司治理事件

在治理風險具有時間領先性的前提下，如何觀測早期訊號成為關鍵問題。相較於揭露式永續報告，事件型資訊可直接反映企業治理與營運異常。Yousaf.(2024)綜述多國實證研究發現，弱公司治理（如董事會品質與所有權結構）與財務困難風險顯著正相關，且治理弱點常早於危機顯現，因而可作為早期預警的重要線索。違規裁罰、訴訟爭議、重大勞資衝突與違約事件通常早於財務惡化發生，並可能透過監理介入、信用條件轉差與交易關係收縮逐步形成資金壓力。

臺灣永續發展評級將公開資訊與永續揭露資料整理為結構化指標，使原本分散的非財務事件得以被系統性觀測與追蹤。本研究關注的並非評等分數，而是其中的負面事件紀錄，並據此將其視為治理風險的代理變數。當企業於多期內反覆出現負面事件時，代表問題具有延續性，可能構成危機形成初期的可觀察線索。

## 2.4 台灣經濟新報永續發展指標(TESG)

Taiwan Economic Journal Environmental, Social, and Governance(TESEG)指標由台灣經濟新報建置，用以量化企業在環境、社會與公司治理三構面的風險暴露與治理品質。相較於單一揭露資料，TESEG 將公開資訊與永續揭露整合為可比較的結構化資料，使非財務事件得以長期追蹤。

本研究關注的重點不在評等分數本身，而在其中所包含的負面事件訊號。治理缺失、違規裁罰、訴訟爭議與聲譽衝擊通常早於財務惡化出現，並可能透過監理介入、信用條件轉差與交易關係收縮逐步形成資金壓力。負面 ESG 事件不僅損害企業聲譽與市場價值，還會促使企業增加風險行為，以應對長期成長威脅，因此，TESEG 事件紀錄可作為危機形成初期的觀測訊號，本研究據此將其視為治理風險的代理變數，並結合跨期特徵檢驗其預警能力。

## 2.5 機器學習方法於風險預測

隨資料維度與特徵複雜度提高，機器學習方法逐漸應用於財務危機預測。相較於傳統統計模型，機器學習可處理非線性關係與變數交互作用，亦較能因應類別不平衡情境。梯度提升決策樹可於結構化資料中擷取多變數之間的複雜關聯 (Ke et al.,2017)，而特徵貢獻分析方法則可量化各變數對預測結果的邊際影響 (Lundberg & Lee,2017)。因此，機器學習不僅用於提升預測能力，也可比較不同風險訊號的重要性，進而檢驗其在危機形成過程中的相對時序角色。

## 2.6 小結

綜合前述文獻，傳統財務危機預測模型主要依賴單一時間點的會計或市場資訊，較適用於辨識已形成的財務困境；相對地，公司治理與永續風險研究顯示，治理失衡與負面事件通常先於財務惡化出現，並經由信用條件、交易關係與監管壓力逐步轉化為資金壓力，最終反映於財務報表。此一時期關係說明企業危機具有可觀測的累積歷程。基於此，本研究將負面事件視為前期風險線索，多期財務趨勢作為後續風險確認，並透過可處理多維特徵關係

的方法加以檢驗。下一章將依此概念建構研究設計，說明資料來源、變數定義與跨期特徵建立方式，並據以建立預警模型與實證分析流程。

### 3. 研究方法

#### 3.1 資料來源

本研究樣本期間為2016年至2024年，資料取自台灣經濟新報資料庫，涵蓋上市櫃公司之財務報表、營運資訊與永續指標，並包含終止上市公司之完整歷史紀錄。所有變數均由同一資料來源取得，以降低跨資料庫整併所造成之定義差異與資訊不一致問題。

財務危機之操作性定義為因財務困難導致終止上市或停止交易之事件，並排除併購、私有化與轉板等非財務性原因。若公司於某年度後因財務因素停止交易，則將其前一年度之觀測值標記為危機樣本（Y=1），持續正常營運者定義為非危機樣本（Y=0），使模型所使用之資訊均為危機發生前可觀測之市場訊號。

本研究以公司年度為分析單位。對於公司於t年之觀測值，模型僅使用該年度財報公布前可取得之歷史資訊，並預測t+1年是否發生危機，以避免前視偏誤。為辨識企業風險隨時間累積之變化，每一觀測值均蒐集過去三年資料建立滾動特徵，使模型依據跨期變動而非單一年度財務狀態進行判斷。

最終樣本包含190家危機公司與2,181家正常公司，且危機公司僅保留危機發生前之觀測資料。對於公司成立年限不足所造成的歷史資料缺失，本研究不以數值填補，而保留缺失並建立缺失指示變數，使模型得以辨識資訊不足所隱含之風險特徵。

#### 3.2 變數選取與資料架構

本研究變數依其特性分為三大類：TESG 指標、傳統財務變數、公司規模變數。此分類目的在從永續表現、財務健康度與企業規模三個面向全面描述企業特徵。

(1) TESH 指標包含 ESG 原始量化分數與事件雷

達分數兩類變數；TESG 分數(X1)來自環境 E、社會 S、治理 G 三大構面下 16 項議題之量化與揭露指標經產業加權後的結果，更新頻率是半年一次，依賴永續報告書、公開資訊、政府資料等 20 多個來源，主要反映公司制度面、結構面、長期作為；事件雷達轉換計分(X2)出自「ESG 事件資料庫」，是針對 ESG 新聞／裁罰／工安／訴訟等事件，標記其所屬構面與議題，再依「事件強度、事件新穎性、發生頻率、時間權重」等變數做量化。而文獻指出

非財務資訊，特別是 ESG 績效，對企業長期風險與財務穩定性具有顯著的預測能力 (Friede et al., 2015)。本研究將其納入，以補充傳統財務變數無法反映的治理風險或外部負面事件衝擊。

(2) 傳統財務變數傳統財務變數共計 27 項 (X3~X17、X20~X31)，涵蓋以下四個方面：

- 獲利能力 (Profitability)：如 X9 ROE—綜合損益 (權益報酬率)、X10 ROA—綜合損益 (總資產報酬率)、X11 每股盈餘(EPS)、X24 稅前淨利、X28 營業毛利、X29 營業利益率、X30 營業利益、X31 歸屬母公司淨利 (損)。
- 償債能力 (Solvency)：如負 X3 負債比率、X4 流動比率、X5 速動比率、X6 利息保障倍數、X7 有息負債利率、X17 負債總額、X21 非流動負債、X22 流動資產、X23 流動負債。
- 經營能力 (Operating Efficiency)：如 X12 稅後淨利成長率、X13 營收成長率、X14 總資產成長率、X15 淨值成長率、X16 總資產報酬成長率、X20 不動產廠房及設備、X26 營業收入淨額、X27 應收帳款及票據。
- 現金流量 (Cash Flow)：如 X8 現金流量比率、X25 來自營運之現金流量。

這些變數結合多年期趨勢分析，能反映企業財務結構的動態變化 (如負債比率是否逐年惡化)，作為判斷潛在危機的關鍵指標。

(3) 公司規模變數公司規模變數共 2 項，分別為 X18 資產總額與 X19 股東權益總額。此類變數用

以衡量企業規模大小，控制規模效應對財務風險的影響，使模型能更準確地比較不同企業在風險暴露上的差異。

本研究共納入31項指標。各變數定義如表1所示。

表 1 研究因子

變數	說明
X1	ESG 原始量化分數
X2	事件雷達轉換計分
X3	負債比率
X4	流動比率
X5	速動比率
X6	利息保障倍數
X7	有息負債利率
X8	現金流量比率
X9	ROE－綜合損益
X10	ROA－綜合損益
X11	每股盈餘
X12	稅後淨利成長率
X13	營收成長率
X14	總資產成長率
X15	淨值成長率
X16	總資產報酬成長率
X17	負債總額
X18	資產總額
X19	股東權益總額
X20	不動產廠房及設備
X21	非流動負債
X22	流動資產
X23	流動負債
X24	稅前淨利
X25	來自營運之現金流量
X26	營業收入淨額
X27	應收帳款及票據
X28	營業毛利
X29	營業利益率
X30	營業利益
X31	歸屬母公司淨利(損)

為評估不同預警時界下之辨識效果，本研究建構「1年期」與「3年期」兩種特徵維度之資料集。其結構定義如下：

(1) 1年期模型(T-1)：僅納入企業危機發生前一年度之截面資料，定義為  $X_i$  為  $i$  項特徵原始變數 (X1至 X31)。此模型旨在驗證危機爆發前夕，各項財務與非財務指標之即時辨識效能。

(2) 3年期模型(T-1 to T-3)：為捕捉企業危機形成之動態軌跡，本研究將各項指標擴張為具有時間序列特性的落後變數。定義  $X_{i,t}$  為第  $i$  項特徵在危機發生前第  $t$  年之觀測值 ( $t = 1, 2, 3$ )。

在3年期模型中，每一原始變數(如 X1 至 X31)均衍生為三組特徵。例如：

- $X1_{1,t}$ ：代表危機發生前1年之 ESG 原始量化分數。
- $X1_{2,t}$ ：代表危機發生前2年之 ESG 原始量化分數。
- $X1_{3,t}$ ：代表危機發生前3年之 ESG 原始量化分數。

此結構使模型不僅能判斷單一時點之數值水準，更能透過不同年份(如  $X15_{1,t}$  與  $X15_{3,t}$ )的組合，隱含地學習到變數之變動趨勢(如資本侵蝕之速度)。透過此種多維度資料結構，本研究得以進一步比較非財務指標(如事件雷達 X2)在長期預警(T-3)與短期預警(T-1)中的解釋力變化。

### 3.3 模型分析與評估指標

本研究採用多種機器學習演算法進行財務危機預測效能的比較。為確保模型訓練程序的可比性與結果的客觀性，本研究透過 Python 的 PyCaret 自動化機器學習套件統一進行流程管理。確保所有模型在相同的訓練條件與驗證規格下運作，提高模型比較的公平性與結果的可信度，PyCaret 的標準化流程涵蓋：

- (1) 資料切分：將全體樣本依切分為80%訓練集與20%測試集。所有特徵工程與採樣程序均僅在訓練集內執行，避免資訊洩露。
- (2) 特徵篩選：針對資料產生之大量特徵進行篩選，剔除高共線性變數以防止過度擬合。
- (3) 類別不平衡處理：針對訓練集運用合成少數過採樣技術(SMOTE)平衡危機與正常樣本權重，以解決財務危機預測中常見的樣本分佈極度不均問題。
- (4) 決策門檻優化：透過門檻變化圖(Threshold

Plot) 觀察指標趨勢。依據各模型機調整決策閾值至，以產生最大化召回率 (Recall)。

- (5) 交叉驗證：透過 PyCaret 10折重複隨機抽樣以抵銷單次抽樣的偏差，確認模型表現穩定並排除抽樣偏差，最終取平均。
- (6) 超參數調優：透過自動化隨機搜索優化模型內部參數，壓榨演算法性能，確保預測邏輯達到最優化。

為評估模型於高度不平衡樣本下之辨識能力，本研究採用 AUC、Recall、Precision、F1-score 與 Kappa 作為主要評估指標。由於危機樣本遠少於正常樣本，單一正確率易受多數類別主導，無法反映模型對高風險企業的實際辨識能力，因此需以不平衡分類指標進行綜合判斷。

AUC 用以衡量模型整體區辨能力，反映不同分類門檻下區分危機與非危機企業的穩定程度；Recall 表示危機企業被成功辨識的比例，代表預警系統對高風險對象的覆蓋程度；Precision 則衡量預警訊號的可信度，避免大量誤報降低預警的實務價值；F1-score 綜合考量 Recall 與 Precision，使模型在偵測能力與誤警率之間取得平衡；Kappa 則校正樣本比例差異造成的偶然一致性，以檢驗模型辨識能力是否超越隨機判斷。

本研究關注的不僅為整體預測能力，更在檢驗不同資訊來源之預警時序。若 TESG 屬於領先風險訊號，則納入 TESG 的模型應在財務指標尚未明顯惡化時仍維持較高之 AUC 與 Recall，表示模型能於危機形成早期辨識高風險企業；反之，若僅依財務變數，模型表現將主要反映危機後期之狀態辨識。透過比較各指標之變化，可判斷不同訊號在危機形成過程中的相對預警價值。

#### 4. 研究結果

##### 4.1 資料觀測年期影響

為檢驗企業財務危機是否具有時間累積特性，本研究分別以前一年與前三年歷史資料建構預測模型，並以 Light Gradient Boosting Machine(Lightgbm)進行樣本外測試 (分類門檻0.5)。表2顯

示，三年觀測窗口於各項評估指標均優於單一年資料，差異主要反映於整體區辨能力與危機企業之辨識能力。

表 2 一年期與三年期比較(以 LightGBM 為例)

	AUC	Recall	Prec.	F1	Kappa
1年	0.8837	0.7646	0.3533	0.3161	0.3256
3年	0.9222	0.8658	0.4577	0.5204	0.4722

僅使用危機發生前一年資料時，模型之 AUC 與 Recall 較低 (AUC = 0.8837 ; Recall = 0.7646)，顯示單期財務資訊無法充分揭示潛在風險。部分企業於危機發生前一年仍維持帳面穩定，使依賴當期財務水準之模型難以及時辨識其風險，模型判斷因而接近對既有困境的辨識，而非提前預警。

當納入三年跨期資訊後，模型辨識能力明顯提升 (AUC = 0.9222 ; Recall = 0.8658)。此一改善並非來自單一指標水準，而是來自跨期變動所形成的趨勢訊號，使模型得以捕捉企業體質隨時間持續變化的過程，例如負債結構逐步惡化或現金流長期不足。結果顯示，危機並非於發生年度突然出現，而是在更早期間逐步形成。

綜合而言，企業財務危機存在一段可辨識的形成期，且形成過程中會累積可觀測之風險訊號。基於此，後續分析以三年觀測窗口為基準，使模型反映風險形成的時間特性，而非僅依單一年度財務狀態進行判斷。

##### 4.2 機器學習效能比較

在確立三年觀測窗口後，本研究參數設定表 3，並比較 Random Forest Classifier(RF)、Gradient Boosting Classifier(GBC)、Extra Trees Classifier(ET) 與 Light Gradient Boosting Machine(LightGBM)之樣本外表現。表4顯示，各模型之評估指標。

表 3 參數設定

模型：LightGBM	參數名稱	設定值
	boosting_type	'gbdt'
	class_weight	None
	colsample_bytree	1.0
	importance_type	'split'
	learning_rate	0.1
	max_depth	-1
	min_child_samples	20
	min_child_weight	0.001

min_split_gain	0.0
n_estimators	100
n_jobs	-1
num_leaves	31
objective	None
random_state	42
reg_alpha	0.0
reg_lambda	0.0
subsample	1.0
subsample_for_bin	200000
subsample_freq	0

n_jobs	-1
oob_score	False
random_state	42
verbose	0
warm_start	False

表 4 三年期資料下各演算法之效能比較

Model	AUC	Recall	Prec.	F1	Kappa
lightgbm	0.9222	0.8658	0.4577	0.5204	0.4722
rf	0.8626	0.7719	0.2189	0.3411	0.2485
gbc	0.8882	0.5965	0.4096	0.4857	0.4325
et	0.8590	0.7368	0.2308	0.3515	0.2627

從指標數據看，LightGBM 表現最突出。它的 AUC 達到0.9222，代表模型區分「財務危機」與「正常企業」的能力極強。在實務上最重要的召回率（Recall）指標，LightGBM 高達0.8658，意味著模型能精準捕捉到超過86%的潛在危機樣本。對比其他模型：

- rf 與 et：雖然召回率表現尚可，但精確度（Precision）僅有0.21~0.23。這代表這兩個模型過於敏感，會產生過多的誤報，導致銀行浪費大量人力去審核根本沒問題的客戶。
- gbc：雖然精確度與 LightGBM 接近，但召回率僅有0.5965，代表它會漏掉約40%的危機企業，這在風險控管上是無法接受的漏洞。

因此，本研究選擇 LightGBM 作為核心預測模型。它在維持高召回率的同時，還能保有相對較高的精確度（0.4577），在「不漏抓壞帳」與「不誤殺好客戶」之間達到了最好的平衡。

### 4.3 決策門檻

分類模型通常以0.5作為預設判斷門檻，惟在財務危機預警情境中，漏判危機企業所造成的損失往往高於誤判正常企業所需投入之查核成本。因此，本研究將評估目標由整體正確率轉為不對稱成本下的決策規則，並調整分類門檻以提升預警敏感度。

當判斷門檻由0.5下修至0.25後，模型之召回率提升至64.91%，顯示多數潛在危機企業可於危機發生前被辨識；同時精確率維持於48.05%，誤警比例仍在可接受範圍內。結果顯示，在預警應用中，

模型·RF	參數名稱	設定值
	n_estimators	100
	criterion	'gini'
	max_depth	None
	min_samples_split	2
	min_samples_leaf	1
	min_weight_fraction_leaf	0.0
	max_features	'sqrt'
	max_leaf_nodes	None
	min_impurity_decrease	0.0
	bootstrap	True
	oob_score	False
	n_jobs	-1
	random_state	42
	verbose	0
	warm_start	False
class_weight	None	
ccp_alpha	0.0	
max_samples	None	
monotonic_cst	None	

  

模型·GBC	參數名稱	設定值
	loss	'log_loss'
	learning_rate	0.1
	n_estimators	100
	subsample	1.0
	criterion	'friedman mse'
	min_samples_split	2
	min_samples_leaf	1
	min_weight_fraction_leaf	0.0
	max_depth	3
	min_impurity_decrease	0.0
	init	None
	random_state	42
	max_features	None
	verbose	0
	max_leaf_nodes	None
warm_start	False	
validation_fraction	0.1	
n_iter_no_change	None	
tol	0.0001	
ccp_alpha	0.0	

  

模型·ET	參數名稱	設定值
	bootstrap	False
	ccp_alpha	0.0
	class_weight	None
	criterion	'gini'
	max_depth	None
	max_features	'sqrt'
	max_leaf_nodes	None
	max_samples	None
	min_impurity_decrease	0.0
	min_samples_leaf	1
	min_samples_split	2
	min_weight_fraction_leaf	0.0
monotonic_cst	None	
n_estimators	100	

模型的合理運作點並非追求最高整體正確率，而是降低漏判風險，以確保高風險企業能及早被識別。

門檻調整亦改變模型之功能定位。模型不再僅用於事後區分危機與非危機企業，而作為風險篩選機制，其目的在於危機形成期間辨識高風險對象並配置後續查核資源，而非於危機發生後進行確認。此結果說明模型具備預警性質，並使後續分析得以比較不同訊號對早期辨識能力之貢獻。

#### 4.4 關鍵特徵影響力分析

為進一步辨識不同資訊來源在危機形成過程中的角色，本研究檢視 LightGBM 之特徵重要性排序。模型係基於梯度提升決策樹 (Gradient Boosting Decision Tree, GBDT) 框架。其特徵重要性之評估主要依據各特徵在構建決策樹過程中的資訊增益 (Information Gain) 進行加權計算。具體而言，當模型選定某一特徵作為節點進行分割時，會計算該分割對於損失函數 (Loss Function) 的減少量；若某一特徵在模型迭代過程中被頻繁選用，且每次分割皆能顯著提升預測準確度，則該特徵將獲得較高的重要性評分。此一機制確保了最終排序能反映各變數對於辨識企業危機的實質貢獻度，而非僅具備相關性。結果顯示，模型對事件型非財務訊號反應最為明顯，TESG 事件雷達相關特徵多位於排序前段，表示非財務事件在危機辨識中具有實質解釋能力 (圖2)。



圖 1. LightGBM 特徵重要性排行

事件雷達轉換計分事件雷達轉換計分 (X2) 為影響力最高之特徵，其中最近年度值事件雷達轉

換計分前1年 (X2\_1) 排名第一，前2年 (X2\_2、X2\_3) 亦位居前列，顯示負面事件之強度與持續性均具有辨識能力。違規、訴訟、違約與勞資爭議等事件直接反映治理品質與內部控制狀態，並可能經由聲譽受損與融資條件惡化逐步轉化為資金壓力，因此其重要性具有明確的經濟意涵。

然而，在非財務指標的比較分析中，本研究發現事件雷達轉換計分 (X2) 之重要性普遍高於 TESG 原始量化分數 (X1)。此現象反映了兩類指標在危機預警中扮演不同角色：X1 作為半年更新之結構性指標，其捕捉的是企業長期治理體質與合規框架，屬『狀態型變數』；而 X2 則屬『衝擊型變數』，能即時反映負面事件對經營層面的急性衝擊。究其排名差異之原因，可能存在資訊稀釋效應 (Information Dilution Effect)：由於 X1 之評分邏輯部分源於對過往事件的加權累積，當模型中同時納入顆粒度更細且具即時性的 X2 時，模型傾向優先選取能顯著降低不純度的動態事件作為分割節點。然而，X1 仍能穩定維持在排序前段 (第六與第十名)，顯示其在事件衝擊之外，仍提供了不可忽視的制度面解釋價值，與 X2 共同構成『結構體質』與『外部衝擊』之雙重預警維度。

在財務變數中，前2年股東權益總額 (X19\_2) 與前1年淨值成長率 (X15\_1) 亦為高排名特徵，顯示資本厚度與資本侵蝕趨勢為關鍵依據。其資訊價值主要來自跨期變動而非單期水準；當股東權益持續下降且淨值成長轉為負值時，表示企業需以資本支撐營運，風險已由潛在壓力轉為實質壓力。

償債能力指標如前1年利息保障倍數 (X6\_1)、有息負債利率 (X7\_1) 與負債比率 (X3\_1) 亦進入前段排序，但整體落後於事件型變數，顯示財務惡化多屬風險累積後期的結果，而非最初訊號來源。

綜合特徵排序可觀察一致之時序關係：事件型非財務訊號首先出現，其後伴隨資本侵蝕，最後表現在償債壓力。結果支持企業財務危機具有可觀測的形成機制，財務報表在辨識上較接近確認訊號。將治理與負面事件資訊納入預警架構，可使辨

識時點前移，提升形成期的預警效益，而非僅改善分類表現。

## 5. 結論

本研究之目的在釐清不同資訊在企業危機形成過程中的訊號角色，而非僅比較預測方法之優劣。整合多期財務資料與 TESG 非財務資訊之實證結果顯示，企業財務危機並非單一年度財務狀態所導致的突發事件，而具有可觀測的形成歷程。

三年觀測窗口之辨識能力明顯優於單年度資料，顯示企業於終止上市前存在一段可辨識的風險累積期間。模型效能的提升主要來自跨期變動所呈現的趨勢訊號，而非單一變數水準，說明企業體質惡化具有持續性特徵，危機在發生前即已逐步形成。

特徵影響力分析進一步指出，TESG 事件型指標具有領先性。負面治理與外部事件變數的重要性普遍高於多數財務比率，且跨期紀錄具穩定解釋力；相對地，償債能力與資本結構指標多出現在後期階段。整體呈現一致的訊號順序：非財務風險訊號首先出現，其後為資本侵蝕，最終表現在償債壓力與終止上市結果。此結果顯示財務報表較接近危機確認訊號，而非最早可觀察訊號。

在不對稱錯誤成本情境下，模型合理的運作目標並非追求最高整體準確率，而是降低漏判風險。透過調整分類門檻，模型可在財務指標尚未全面惡化前辨識部分高風險企業，顯示預警系統的功能在於提前篩選潛在風險，而非於危機發生後進行確認。

綜合而言，企業財務危機可視為由治理與外部事件觸發，經資本結構惡化後逐步形成財務困境的過程；財務資訊在此過程中主要扮演確認訊號，而事件型非財務資訊則提供早期示警。

在理論層面，本研究補充傳統破產預測文獻對風險形成機制之理解。既有研究多以單期財務資訊辨識風險，將危機視為特定時點的狀態判斷；本研究則顯示風險訊號具有時間序列與層級結構。公司治理與負面事件資訊不僅與績效相關，亦為危機

形成初期的訊號來源，風險評估架構因此由以財務結果為主，轉為納入形成過程的動態觀點。

在實務層面，預警系統的重點不在辨識已陷入困境的企業，而在於提前識別風險累積中的企業。非財務事件與治理資訊提供早期警示，資本結構變化則提供後續確認。結合兩者之監測機制，可使風險評估由事後判斷轉為事前辨識，並提升監測效率與資源配置的準確性。

本研究仍存在若干限制。首先，樣本以台灣上市櫃公司為主，結果可能受制度與資訊揭露規範影響，對未公開發行企業之適用性仍需進一步驗證。其次，本研究著重企業個體特徵，尚未納入利率循環或景氣變動等總體經濟因素，未來可將宏觀變數納入模型，以檢驗不同經濟環境下之穩健性。此外，樣本處理與缺失值處理方式可能影響資料分布，其對模型穩定性的影響仍有待進一步檢驗。

後續研究可結合即時與非結構化資訊，例如新聞揭露與公司公告，以觀察事件訊號在風險形成過程中的作用。整合多來源資料將有助於更完整描述企業風險由形成至實現的動態過程。

## 參考文獻

1. Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The journal of finance*, 23(4), 589-609.
2. Beaver, W. H. (1966). Financial ratios as predictors of failure. *Journal of accounting research*, 71-111.
3. Broadstock, D. C., Chan, K., Cheng, L. T., & Wang, X. (2021). The role of ESG performance during times of financial crisis: Evidence from COVID-19 in China. *Finance research letters*, 38, 101716.
4. Friede, G., Busch, T., & Bassen, A. (2015). ESG and financial performance: aggregated evidence from more than 2000 empirical studies. *Journal of sustainable finance & investment*, 5(4), 210-233.

5. Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., ... & Liu, T. Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. *Advances in neural information processing systems*, 30.
6. Li, M. Y. L., & Miu, P. (2010). A hybrid bankruptcy prediction model with dynamic loadings on accounting-ratio-based and market-based information: A binary quantile regression approach. *Journal of Empirical Finance*, 17(4), 818-833.
7. Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.
8. Merton, R. C. (1974). On the pricing of corporate debt: The risk structure of interest rates. *The Journal of finance*, 29(2), 449-470.
9. Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of accounting research*, 109-131.
10. Qiu, J., Xiao, Z., Xu, W., & Zhou, Y. (2025). Soft probability based random forest for financial distress prediction. *Information Sciences*, 122870.
11. Stulz, R. M. (2025). Risk, the limits of financial risk management, and corporate resilience. *Annual Review of Financial Economics*, 17.
12. Wang, C., Gong, P., Li, J., & Wang, Z. (2025). Corporate financial distress prediction with multiperiod annual report data: A fusion deep neural network model. *Plos one*, 20(9), e0333064.
13. Yousaf, U. B., Jebran, K., & Ullah, I. (2024). Corporate governance and financial distress: A review of the theoretical and empirical literature. *International Journal of Finance & Economics*, 29(2), 1627-1679.
14. Zmijewski, M. E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting research*, 59-82.
15. Zhao, S., Xu, K., Wang, Z., Liang, C., Lu, W., & Chen, B. (2022). Financial distress prediction by combining sentiment tone features. *Economic Modelling*, 106, 105709.