

機器學習在財務研究與應用—— 以交易策略與金融詐欺偵測為例

戴天時、黃子騏*

傳統金融的量化研究長期以來仰賴統計學模型，例如回歸分析、時間序列模型（如 ARIMA）、協整理論及馬可夫鏈等技術分析與預測價格走勢。這些模型以其數學基礎和解釋性受到廣泛應用，然而，它們通常假設數據生成具備穩定性，難以應對市場波動及資料特性的非線性與高維度挑戰。

隨著大數據時代來臨，先進的統計學習工具逐漸興起，例如支持向量機（Support Vector Machine）、隨機森林（Random Forest）及梯度提升機（Gradient Boosting Machine），提供了更強的非線性擬合能力，能處理更大規模的數據。但這些工具仍然受限於特徵工程的依賴，無法完全捕捉市場中更高層次的複雜結構。

深度學習的出現，特別是在運算能力快速提升以及損失函數（Loss function）收斂問題逐漸解決後，提供了前所未有的數據擬合能力。通過卷積神經網路（Convolution Neural Network）和長短期記憶網路（Long Short-Term Memory），研究人員能更精確地處理市場價格、交易量等財務時間序列數據。然而，由於模型結構的高度複雜性，深度學習模型的可解釋性往往受到限制，這對於金融應用中的風險管理和監管需求形成挑戰。

強化學習的出現進一步拓展了動態決策的優化能力，例如自動化資產配置和再平衡（auto rebalance）策略，透過不斷與市場互動學習最優策略，提升交易效能。同時，生成式人工智慧（Generative AI）的發展則為處理更複雜的自然語言文件提供了解決方案，例如財務報表、法條及新聞資訊，並能應用於財務時間序列的生成，有助於風險控制和資產定價。

這些前沿技術正逐漸在 AI 領域的學術文獻中嶄露頭角，並逐步滲透至財務與經濟研究。結合本研究團隊過往在學術與產學合作中的實務經驗，我們在本篇文章重點介紹以下應用方向：

* 戴天時，國立陽明交通大學資訊管理與財務金融學系教授；黃子騏，國立陽明交通大學資訊管理與財務金融學系研究生。

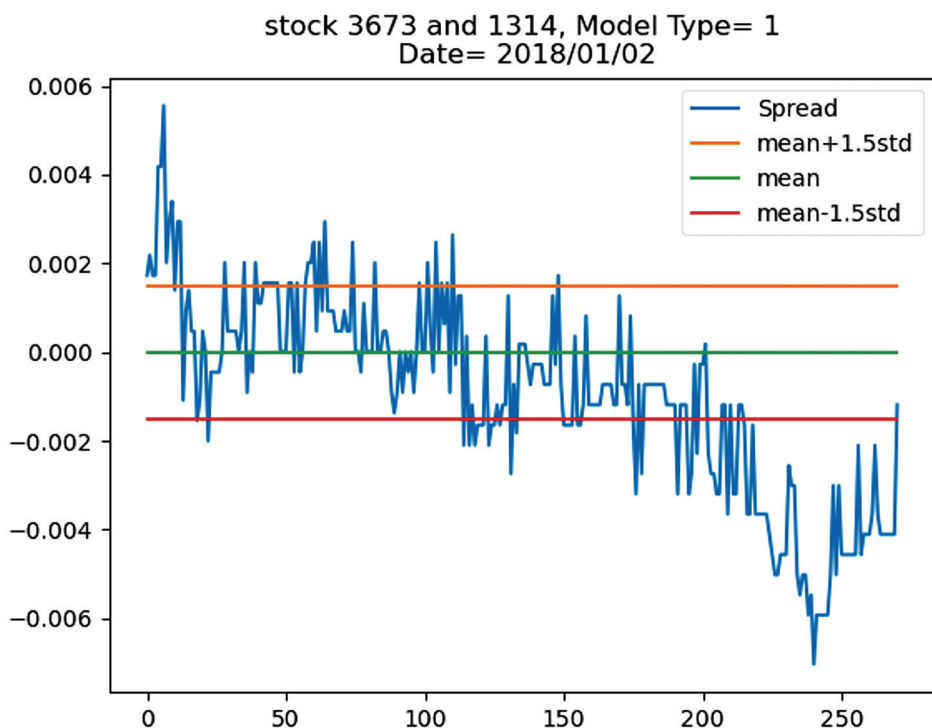
- 1. 配對交易策略：**結合統計模型與深度學習技術，設計出一套能夠捕捉市場均值回歸特性的交易策略，同時適應市場結構性變化，以提升交易穩定性與獲利能力。除了學術研究與發表，我們的技術亦與對沖基金（Hedge Fund）和金融科技新創公司合作，將研究成果應用於實際交易環境，驗證其在不同市場條件下的有效性，推動量化交易策略的創新與發展。
- 2. AI 在金融詐欺偵測中的應用：**結合 Kolmogorov-Smirnov (KS) 檢定篩選穩定特徵、自動編碼器（Autoencoder）生成高層次特徵表示，以及圖神經網絡（GNN）建模交易網絡，精確識別異常交易行為。這套框架有效應對了詐欺行為的時間變化特性與資料稀疏問題，大幅提升金融機構的風險管理效率與準確性。此外，我們與捷智商訊合作，成功將該技術建置至銀行系統，進一步強化金融機構對異常交易的即時監控與預警能力，提升整體防詐欺與洗錢防制的效能。

一、AI 在配對交易的應用

配對交易源自 1980 年代華爾街交易團隊的統計套利策略，現已成為一種成熟且廣泛應用的市場中性策略。其核心理念在於利用兩種高度相關資產：當價格產生異常偏離時開倉，待價格回復至均值後平倉，從而實現套利（Gatev et al., 2006）。由於配對交易屬於市場中性策略，故無需預測整體走勢，僅需關注資產價格間的長期均衡關係。

我們研究團隊將傳統配對交易改良為日內高頻當沖策略，並結合深度學習以提升交易績效。首先，為排除台股開盤 16 分鐘時因資訊湧入導致的劇烈波動，我們以其後 150 分鐘的交易資料作為估計期，建立各配對的價差（Spread）序列。接著，使用 Johansen 共整合檢定篩選具定態特性的配對，納入當天的交易池。交易期為 100 分鐘，採固定開倉門檻：當價差突破均值 ± 1.5 倍標準差時開倉，並在價差回復至均值時平倉，使獲利範圍鎖定在 1.5 倍標準差內（Ti et al., 2024）。如圖一所示，當價差序列（藍線）低於均值減 1.5 倍標準差（紅線），便進行下開倉，待價差回到均值（綠線）後平倉套利。

然而，傳統配對交易多依賴歷史均值與標準差設定開平倉門檻，若市場波動劇烈，部分交易可能無法如預期回歸均值，導致執行偏誤並影響獲利。為此，我們提出一種基於「趨勢穩定性（Trend-Stationarity）」的改進策略，以更精準地掌握開平倉時機並降低風險。



圖一：配對交易開倉示意圖

(一) 趨勢穩定性分析與漸近均值回歸

傳統配對交易通常假設價差序列服從嚴格的均值回歸性質，然而，在現實市場中，許多資產的價差可能呈現趨勢穩定性 (Trend-Stationary) 特徵。Dai et al. (2024) 提出的漸近分析 (Asymptotic Analysis) 方法證明，當價差序列存在趨勢成分，應調整其均值回歸水準，以確保交易策略適應市場變化並提升獲利能力。這一方法的核心概念包括：

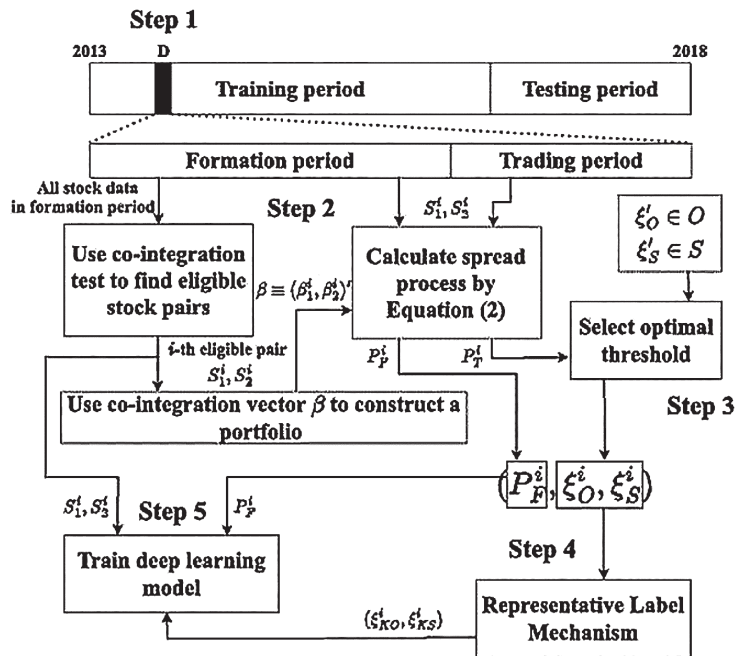
- 漸近均值 (Asymptotic Mean)：相較於傳統樣本均值，漸近均值能更準確地描述長期穩態價差，有助於提高交易決策的準確性。
- 收斂速率過濾器 (Convergence Rate Filter)：根據價差序列回歸均值的頻率篩選配對，排除短期內不易收斂的交易機會，進一步降低風險。

(二) 深度學習的應用

然而，隨著台股市場的競爭日益激烈，固定開倉門檻的模式已難以保證過往的獲利規模。傳統方法透過統一校準所有配對尋找最適開倉門檻，但由於不同配對的分股因其股性差異，其價差偏離均值的幅度亦不同，一刀切的設定恐

降低策略精準度。因此，我們研究團隊探索結合深度學習與配對交易的方法，動態估計各配對的特性，進一步提升交易績效。

Kuo et al. (2022) 提出的兩階段深度學習方法，正是為解決傳統門檻設定的不足。在一般配對交易中，開倉與平倉通常以歷史均值與標準差為依據，但這樣的固定門檻可能會在市場波動性變化時失去準確性。該研究透過深度學習自動尋找最佳交易門檻（見圖二），第一階段的模型先分析大量歷史交易數據，挑選出最適合的開倉與平倉點，避免市場噪音影響決策；第二階段的模型則進一步篩選交易機會，確保進場後的交易更可能回歸均值。此外，研究亦指出，若以時間不變的價差數據（而非股價）作為訓練資料，交易績效更穩定，顯示選擇合適的數據形式對模型成效至關重要。



圖二：兩階段深度學習模型架構

Chang et al. (2024) 則著力於改善機器學習模型在不同股票對上的學習效果。在配對交易中，不同的配對的價格行為與風險特性相異，若獨立為每組配對訓練模型，可能因數據不足而過擬合；若僅用單一模型覆蓋所有配對，則可能忽視各配對的特性。因此該研究提出了一種局部學習 (Local Learning) 的方法，透過無監督學習技術先將股票對進行分群，再針對每個群體訓練獨立的深

度強化學習模型。這樣的做法能夠兼顧不同股票對的特性，又能避免數據不足的問題，使交易決策更加精準。

這兩項研究為配對交易的機器學習應用帶來新契機：一方面以深度學習動態調整交易門檻，讓策略能因應市場波動；另一方面透過局部學習增進模型適應不同股票對的能力，使配對交易從傳統的統計套利更進一步邁向智能化、自適應的發展，在複雜市場中維持競爭力。

二、AI 在金融詐欺偵測中的應用

金融詐欺與洗錢防制是當前金融科技研究中的核心課題，隨著電子支付和數位金融的普及，詐欺行為的規模、複雜性和多樣性不斷提升。因為可解釋和 AI 倫理的要求，許多國家如加拿大、新加坡、澳洲、臺灣¹ 的監管機構採用傳統的規則基礎方法 (rule-based) 雖然能夠快速識別某些簡單的詐欺行為，但對於詐欺手法的快速演變以及交易數據中隱藏的時間變化特性 (time-varying features)，往往力不從心。我們的研究聚焦於結合機器學習、深度學習及統計檢定方法，提供一套高效且具解釋性的金融詐欺偵測解決方案。

(一) 詐欺行為的時間變化特性與挑戰

詐欺行為具有極強的適應能力，隨著市場環境、監管規範及科技發展不斷演變。詐欺者通常會調整策略來規避現有的偵測機制，例如當特定 ATM 提款熱區受到執法單位嚴格監控時，他們可能會迅速轉移到其他 ATM，讓基於過去熱點分析的偵測系統難以維持準確性 (Hsin et al., 2022)。然而，相較於這種高度變動的模式，有些交易特徵則相對穩定，例如臨櫃交易，由於需要實名驗證與人工核對身分，詐欺者通常會選擇避免，因此這類交易的行為模式在長時間內較少改變。這種區別對於提升詐欺檢測的穩定性至關重要，我們的研究便著重於篩選出那些受時間影響較小的特徵，並降低對變動過大的特徵的依賴，確保模型能夠適應詐欺手法的變化，保持長期有效性。

此外，詐欺行為在交易數據中的比例通常極低，這帶來了資料不平衡 (data imbalance) 的問題。當詐欺交易僅占總體交易的一小部分時，機器學習模型在訓練過程中容易受到大量正常交易的影響，導致無法有效學習詐欺模式。如果模型的召回率 (recall) 過低，代表它無法成功識別大部分詐欺交易，使得檢測系統喪失應有的效果，讓許多詐欺案件逃過監控。然而，若一味追求高召回率，

¹ 例如金管會制定的疑似洗錢或資恐交易態樣。

則可能會帶來過高的誤判率 (false positive rate)，使大量正常交易被標記為可疑，影響正常使用者的交易體驗，甚至增加金融機構的審查成本。因此，如何在降低誤判的同時，確保足夠高的召回率，是詐欺檢測系統設計中的關鍵挑戰 (Ti et al., 2022)。

(二)KS 檢定在特徵篩選中的應用

為了提升檢測系統的穩定性，我們採用了 Kolmogorov-Smirnov (KS) 檢定來識別並剔除那些隨時間變化較大的特徵。KS 檢定能夠比較不同時間區間內數據的分布，幫助我們分析哪些特徵在不同時間點的表現較為穩定，哪些特徵則變化劇烈。舉例來說，某些 ATM 的交易筆數、某類電子支付方式的使用頻率，可能在短期內受外部因素影響出現大幅變動，如果模型過度依賴這些變動特徵，可能導致檢測準確性隨時間下降。因此，我們利用 KS 檢定來篩選並剔除這些高變動特徵，保留較為穩定的交易模式，例如帳戶類型、長期持續的交易頻率等，從而提升模型的長期適應性，使其能夠有效應對詐欺行為的變化。

(三)特徵工程與深度學習的結合

除了篩選穩定特徵，我們也結合深度學習技術來進一步提升詐欺檢測的效能。例如，透過自動編碼器 (Autoencoder)，我們可以讓系統從大量交易數據中自動學習出與詐欺行為相關的隱藏模式，發掘出傳統規則難以察覺的異常交易。例如，一些詐欺集團可能會在短時間內利用多個新開戶的帳戶進行轉帳與洗錢，這類行為可能無法單靠固定規則偵測，但深度學習技術可以從大量歷史交易中學習異常模式，進一步提高識別能力。

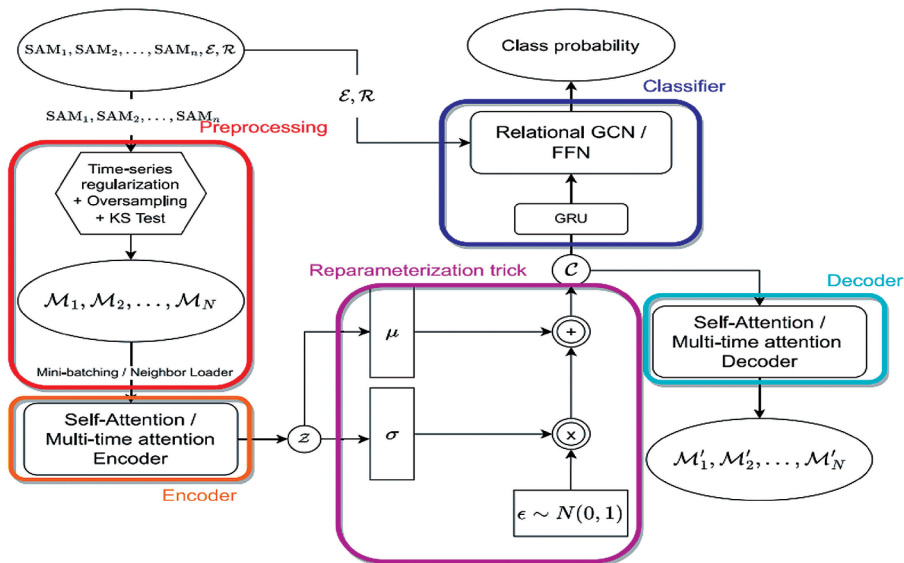
此外，為了解決資料不平衡問題，我們也採用了不同的方法來提升詐欺交易的識別效果。例如，透過生成技術增加詐欺交易的樣本數量，使模型能夠學習更多樣化的詐欺行為模式，或者調整模型的學習權重，使其更關注異常交易，而不被大量正常交易所影響。這些方法能夠有效平衡召回率與誤判率，確保系統能夠偵測足夠多的詐欺行為，同時不會對正常交易造成過多干擾，達到更好的風險控制效果。

綜合來說，透過 KS 檢定來篩選出時間穩定的特徵，結合深度學習技術來提升檢測能力，再透過適當的數據處理技術來解決資料不平衡問題，我們的研究提供了一種更加靈活且高效的詐欺檢測方法。這些技術的應用，能夠幫助金融機構、電子支付平臺和電商交易監控系統更好地應對詐欺行為的變化，確保交易安全，減少經濟損失，為使用者提供更加安心的支付環境。

三、圖神經網絡在詐欺網絡中的應用

詐欺行為往往涉及複雜且多層次的交易網絡，例如透過多個帳戶轉移資金，或利用跨國交易來規避監管，達成洗錢目的。為了更有效地識別這些異常行為，我們使用圖神經網絡（GNN）來建模客戶之間的交易關係，將交易數據轉化為圖結構，使系統能夠理解資金流動的整體模式（見圖三）。在這個圖結構中，節點代表客戶或帳戶，而邊則表示交易往來或法律與血緣關係（例如個人對法人公司的持有關係）。

透過 GNN，我們能夠同時考量局部與全局交易模式，不僅能發現個別帳戶的異常行為，也能識別跨帳戶、跨層級的可疑交易路徑。例如，詐欺者可能會將大筆資金拆分到多個關聯帳戶，以降低單筆交易的可疑程度，但 GNN 能夠捕捉這些分散後再集中的行為模式，進而揭露隱藏的詐欺網絡。此外，GNN 還能適應交易網絡的動態變化，使檢測系統能夠即時發現新的詐欺模式，有效提升金融機構對詐欺行為的應對能力（Shih et al., 2025）。



圖三：GNN模型架構圖

四、結語

AI 與金融的深度融合正持續重塑產業格局，從交易策略、風險管理到法規合規，智能化技術的發展為金融領域帶來全新的應用與變革。除了上述研究，

我們團隊也應用生成式 AI 於財金客戶問答系統與法條對應，精準解析企業內規與外部法規的關聯，幫助企業快速應對監管變化。此外，在選擇權定價領域，我們結合套利分析與深度學習，開發適用於流動性不足市場的高精度定價模型，以提升市場效率與投資決策的準確性。

未來的金融教育不應僅限於傳統的公司理財與投資學，更應與金融機構及科技企業緊密合作，共同推動產業創新。我們致力於透過學界與業界的深度交流，培育具備金融與 AI 雙重專長的跨領域人才，使新一代金融科技專業人士能夠掌握 AI 驅動的市場變革，迎接未來挑戰。

參考文獻

- Chang, W. C., Dai, T. S., Chen, Y. P., Hsieh, C. Y., Chang, Y. W., & Huang, Y. H. (2024, June). Integrating local learning to improve deep-reinforcement-learning-based pairs trading strategies. In *2024 IEEE Conference on Artificial Intelligence (CAI)* (pp. 714-719). IEEE.
- Dai, T. S., Luo, Y. J., Chang, H. H., Kao, C. L., Wang, K. L., & Liu, L. C. (2024). Asymptotic analyses for trend-stationary pairs trading strategy in high-frequency trading. *Review of Quantitative Finance and Accounting*, 63, 1391-1411. <https://doi.org/10.1007/s11156-024-01293-1>
- Gatev, E., Goetzmann, W. N., & Rouwenhorst, K. G. (2006). Pairs trading: Performance of a relative-value arbitrage rule. *The Review of Financial Studies*, 19(3), 797-827.
- Hsin, Y. Y., Dai, T. S., Ti, Y. W., Huang, M. C., Chiang, T. H., & Liu, L. C. (2022). Feature engineering and resampling strategies for fund transfer fraud with limited transaction data and a time-inhomogeneous modi operandi. *IEEE Access*, 10, 86101-86116.
- Shih, Y. C., Dai, T. S., Chen, Y. P., Ti, Y. W., Wang, W. H., & Kuo, Y. (2025). Fund transfer fraud detection: Analyzing irregular transactions and customer relationships with self-attention and graph neural networks. *Expert Systems with Applications*, 259, 125211.
- Ti, Y. W., Dai, T. S., Wang, K. L., Chang, H. H., & Sun, Y. J. (2024). Improving cointegration-based pairs trading strategy with asymptotic analyses and convergence rate filters. *Computational Economics*, 64, 2717-2745. <https://doi.org/10.1007/s10614-023-10539-4>
- Ti, Y. W., Hsin, Y. Y., Dai, T. S., Huang, M. C., & Liu, L. C. (2022). Feature generation and contribution comparison for electronic fraud detection. *Scientific Reports*, 12(1), 18042.