
前言

針對每個可想像得到的投資策略而言，最終會讓 *alpha* 歸零嗎？託眾多聰明人類與智慧電腦的福，使得金融市場著實成為完全競爭情況，因而可以安逸的坐享其成，認為所有資產定價正確，此成真之日將會到來嗎？

——Robert Shiller (2015)

人工智慧 (AI) 在 21 世紀 10 年代發展成為關鍵技術，而被認為是 21 世紀 20 年代的主要技術。在技術創新、演算法突破、巨量資料 (大數據) 可用程度與運算能力不斷增強的激勵下，許多行業都在 AI 驅動中發生重大變化。

雖然媒體與大眾的注意力大多集中在諸如遊戲與自駕車領域的突破，不過 AI 也已成爲金融業的主要科技力。然而，金融 AI 仍處於初期階段——相較於網路搜尋或社交媒體行業而言，的確如此。

本書闡述與金融 AI 相關的諸多重要面向。金融 AI 已是範圍廣泛的議題，而單一著作得聚焦特定內容論述。因此，本書將探討相關基礎內容 (參閱第一部分與第二部分)；以 AI (較具體而言是採用類神經網路) 察覺金融市場的統計無效率情況 (參閱第三部分)；這樣的無效率情況 (由成功預測未來市場變化的 AI 演算法具體呈現) 是演算法交易之中經濟無效率的利用前提 (參閱第四部分)；能夠有系統的利用統計無效率與經濟無效率，證明與下列金融既定理論基石互相矛盾：效率市場假說 (EMH)，成功交易機器人的設計被認為是 AI 可能引領的金融聖杯之路，本書末尾探討 AI 對於金融業的結果與金融奇點的可能性 (參閱第五部分)；另外還有技術附錄，以直接的 Python 程式碼從無到有建置類神經網路，並就此列舉應用範例 (參閱第六部分)。

AI 應用於金融行業與應用於其他領域並沒有太大差異。2010 年代 AI 的重大突破，是將增強式學習（RL）應用於遊戲機台（諸如 1980 年代發行的 Atari，參閱 Mnih et al. 2013）以及棋盤遊戲（譬如西洋棋或圍棋，參閱 Silver et al. 2016）所造就的成果。別的領域不說，目前已將用在遊戲環境的 RL 所得經驗，用於設計與建置自駕車或改善醫療診斷這類具有挑戰的問題上。表 P-1 為 AI 與 RL 在不同領域的應用比較。

表 P-1 不同領域的 AI 比較

領域	代理人	目標	作法	獎勵	阻礙	風險
遊戲機台	AI 代理人 (軟體)	分數最大化	虛擬遊戲環境 RL	點數與分數	計畫與延遲 獎勵	無
自動駕駛	自駕車 (軟體 + 車)	位置 A 到 B 的安全駕駛	虛擬 (遊戲) 環境 RL、實境駕駛測試	懲罰錯誤	虛擬到實際 的轉換	財產損失、 人類傷亡
金融交易	交易機器人 (軟體)	長期績效最 大化	虛擬交易環境 RL	金融報酬率	效率市場與 競爭	金融損失

訓練 AI 代理人玩遊戲機台的優點是，具有完美的虛擬學習環境¹ 而且毫無風險。至於自駕車，從虛擬學習環境（諸如《俠盜獵車手》這類電玩）轉到實際環境時（自駕車行駛於有車子與人們存在的實際街道上），將發生重大問題。如此導致汽車事故或人類傷亡這類嚴重的風險。

就交易機器人而言，RL 也可以完全虛擬，即處於模擬的金融市場環境中。交易機器人失常引起的主要風險是金融損失，以及由於交易機器人的從眾效應所產生的潛在系統風險。然而，整個金融領域似乎是訓練、測試與部署 AI 演算法的理想場域。

因為此領域的快速發展，對於願意關注與具有野心的學生來說，配備筆記型電腦與網際網路存取，就應該可以在金融交易環境中成功運用 AI。除了近年來硬體與軟體的改進之外，如此主要歸功於線上經紀商的興盛（提供歷史與即時金融資料以及能夠透過程式 API 進行金融交易）。

1 參閱 Arcade Learning Environment (<https://oreil.ly/bGgZs>)。

本書有下列六個部分：

第一部分

第一部分說明一般 AI 的主要概念與演算法，諸如監督式學習與類神經網路（參閱第一章）。也將提及超級智慧的概念，其中描述擁有人類智慧並在某些領域具備超人智慧的 AI 代理人（參閱第二章）。並不是所有 AI 研究人員都認為在可預見的將來能有超級智慧。然而，此一概念論述為 AI（尤其是金融 AI）的探討提供有用的框架。

第二部分

第二部分有四章，關於傳統的規範金融理論（參閱第三章），以及資料驅動金融（參閱第四章）與機器學習（ML，參閱第五章）讓金融領域有所變革。第六章則將資料驅動金融與 ML 結合產生 AI 第一的金融（無模型）作法。

第三部分

第三部分是以深度學習、類神經網路與增強式學習的應用，加以察覺金融市場的統計無效率情況。此部分包含密集神經網路（DNN，參閱第七章）、循環神經網路（RNN，參閱第八章）以及增強式學習演算法（RL，參閱第九章），而往往用 DNN 顯現與近似 AI 代理人的最佳政策。

第四部分

第四部分說明演算法交易利用統計無效率的情況。主題有向量化回測（參閱第十章）、事件式回測與風險管理（參閱第十一章），以及 AI 能力的演算法交易策略執行與部署（參閱第十二章）。

第五部分

第五部分是金融業 AI 式競爭所產生的相關結果（參閱第十三章）。其中還探討金融奇點的可能性，即 AI 代理人將主宰人類知曉金融所有面向的時間點。就此的論述聚焦於金融人工智慧，即不斷產生高於任何人類或機構基準交易利潤的交易機器人（參閱第十四章）。

第六部分

本書附錄包含互動的類神經網路訓練 Python 程式碼（參閱附錄 A），以 Python 程式碼從無到有實作簡單神經網路與淺層神經網路的類別（參閱附錄 B），以及使用卷積神經網路（CNN）進行金融時間序列預測的示例（參閱附錄 C）。

作者註解

金融交易中的 AI 應用仍然處於初期階段（儘管在撰寫本書時，還有許多書籍於某種程度上探討此一主題）。然而，這類著作未能說明經濟上利用統計無效率情況的意涵為何。

某些避險基金已宣稱完全仰賴「機器學習」管理投資者的資本。顯著的例子是 Voleon Group，此避險基金於 2019 年底有超過 60 億美元的資產管理規模（參閱 Lee and Karsh 2020）。以機器學習超越金融市場的困難度反映在此基金 2019 年達 7% 的業績上，這一年 S&P 500 股票指數上漲將近 30%。

本書基於筆者多年來在開發、回測與部署 AI 能力演算法交易策略相關的實務經驗。呈現的作法與範例大多以筆者自己的研究為基礎，因為本質上來說，這個領域不僅新興還相當隱秘。本書的闡述與風格是持續的以實用為主，在許多情況下，具體範例缺乏適當的理論支持與全面的實證證據。書中提供的某些應用與示例，甚至可能會受到金融或機器學習專家的強烈批判。

某些機器學習與深度學習的專家，譬如 François Chollet (2017)，公然質疑金融市場預測的可能性。某些金融專家，諸如 Robert Shiller (2015)，不相信會有像金融奇點這種論述。而活躍於兩個領域的其他人士，例如 Marcos López de Prado (2018) 則認為，將機器學習用於金融交易與投資，需要大型團隊與龐大預算付出行業規模的努力才行。

本書不會試圖為所涵蓋的各個主題提供平衡的觀點或全面的參考。內容的呈現是基於筆者個人見解與經驗，還有提供具體範例與 Python 程式碼之際的實際考量所造就的結果。多數範例經過篩選與調整，以強調某些觀點或呈現激勵的結果。因此，可以認定的是，書中呈現的許多示例結果都歷經資料窺探與過度配適的效應（關於這些主題的探討，可參閱 Hilpisch 2020 ch. 4）。

本書的主要目標是讓讀者能夠利用書中程式範例作為框架，進而探索 AI 應用於金融交易的精彩之處。為了實現此一目標，本書始終依據一些簡化的假設，而主要以金融時間序列資料為基礎，直接從此類資料中獲得特徵。實務應用中，當然不必限於金融時間序列資料——也可以使用其他類型的資料與來源。本書對所得特徵的作法間接假設：金融時間序列與從其推得之特徵所顯示的樣式（型態），至少在某種程度上會隨著時間持續留存，進而可用於預測未來價格動向。

以此背景而言，本書呈現的所有範例與程式碼皆為技術與說明的性質，不具有任何推薦含意或投資建議。

針對想要部署本書作法與演算法交易策略的讀者而言，筆者的著作《Python for Algorithmic Trading: From Idea to Cloud Deployment》(O'Reilly) 有提供更多程序導向與技術細節內容。這兩本書在諸多面向是相輔相成的。對於剛剛起步使用 Python 進行金融應用或尋求複習與參考書的讀者來說，筆者的著作《Python for Finance: Mastering Data-Driven Finance》(O'Reilly) 完整涵蓋 Python 應用於金融領域的重要主題與基本技能。

參考文獻

下列為前言所引用的論文與書籍：

Chollet, François. 2017. *Deep Learning with Python*. Shelter Island: Manning.

Hilpisch, Yves. 2018. *Python for Finance: Mastering Data-Driven Finance*. 2nd ed. Sebastopol: O'Reilly.

———. 2020. *Python for Algorithmic Trading: From Idea to Cloud Deployment*. Sebastopol: O'Reilly.

Lee, Justina and Melissa Karsh. 2020. “Machine-Learning Hedge Fund Voleon Group Returns 7% in 2019.” *Bloomberg*, January 21, 2020. <https://oreil.ly/TOQiv>.

López de Prado, Marcos. 2018. *Advances in Financial Machine Learning*. Hoboken, NJ: John Wiley & Sons.

Mnih, Volodymyr et al. 2013. “Playing Atari with Deep Reinforcement Learning.” arXiv. December 19. <https://oreil.ly/-pW-1>.

Shiller, Robert. 2015. “The Mirage of the Financial Singularity.” Yale Insights. July 16. <https://oreil.ly/VRkP3>.

Silver, David et al. 2016. “Mastering the Game of Go with Deep Neural Networks and Tree Search.” *Nature* 529 (January): 484-489.

規範金融

CAPM 依據許多不切實際的假設。例如，假設投資人只關心投資組合一期的報酬平均數與變異數，這是過於極端的假設。

——Eugene Fama and Kenneth French (2004)

與人類（而非基本粒子）相關的科學對典雅數學呈現頑強抗拒力。

——Alon Halevy et al. (2009)

本章論述規範金融中主要的理論與模型。就本書的宗旨並簡單來說，**規範理論**（*normative theory*）是依據某些假設（數學公理），並從相關假設中得出對應見解、結果等內容。另一方面，**實證理論**（*positive theory*）是根據觀測、實驗、資料、關係等方面，而從現有資訊與衍生結果中獲得見解，並以見解描述相關現象。Rubinstein (2006) 對於本章提及之理論與模型的淵源，有詳細論述。

第 62 頁〈不確定性與風險〉介紹金融建模的主要概念，諸如不確定性、風險、交易資產等等。第 66 頁〈預期效用理論〉探討不確定性下決策的主要經濟範式：**預期效用理論**（EUT）。EUT 的近代樣式可以追溯到 von Neumann and Morgenstern (1944)。第 72 頁〈平均數—變異數投資組合理論〉介紹 Markowitz (1952) 的平均數—變異數投資組合（MVP）理論。第 83 頁〈資本資產定價模型〉解析 Sharpe (1964) 與 Lintner (1965) 的資本資產定價模型（CAPM）。第 91 頁〈套利定價理論〉概述 Ross (1971, 1976) 的套利定價理論（APT）。

本章以主要的規範金融理論作為本書的基礎。這一點很重要，因為數個世代的經濟學家、金融分析師、資產經理人、交易員、銀行家、會計師等等皆受過這些理論薰陶。就此意義而言，金融肯定能作為一門理論與實務兼具的學科，有很大的範疇是由這些理論所造就的。

不確定性與風險

金融理論的核心是，於不確定性與風險存在的情況下投資、交易與評價。本節會以某種程度的數學形式介紹與這些主題相關的主要概念。重點是機率論的基本概念，這些概念是計量財務金融的骨幹¹。

定義

假設只在兩個時間點觀測活動的經濟結構：今日、 $t = 0$ ；一年後、 $t = 1$ 。本章稍後討論的金融理論有很大程度都是以如此靜態經濟結構（*static economy*）為基礎²。

當 $t = 0$ 時，並無存在不確定性。當 $t = 1$ 時，經濟結構可以接受（有限量） S 個可能狀態 $\omega \in \Omega = \{\omega_1, \omega_2, \dots, \omega_S\}$ 。 Ω 是狀態空間（*state space*），其基數（cardinality）為 $|\Omega| = S$ 。

Ω 的（集合）代數（*algebra*） \mathcal{F} 是具有下列內容的一組集合：

1. $\Omega \in \mathcal{F}$
2. $\mathbb{E} \in \mathcal{F} \Rightarrow \mathbb{E}^c \in \mathcal{F}$
3. $\mathbb{E}_1, \mathbb{E}_2, \dots, \mathbb{E}_I \in \mathcal{F} \Rightarrow \bigcup_{i=1}^I \mathbb{E}_i \in \mathcal{F}$

\mathbb{E}^c 為集合 \mathbb{E} 的補集（*complement*）。冪集（*power set*） $\wp(\Omega)$ 是最大的（集合）代數，而集合 $\mathcal{F} = \{\emptyset, \Omega\}$ 是 Ω 的最小（集合）代數。代數是經濟結構中可觀測事件（*observable event*）的模型。在這種情況下，經濟結構的單一狀態 $\omega \in \Omega$ 可詮釋為原子事件（*atomic event*）。

狀態 $\omega \in \Omega$ 發生的機率是實數 $0 \leq p_\omega \equiv P(\{\omega\}) \leq 1$ ，或事件 $\mathbb{E} \in \mathcal{F}$ 發生的機率是實數 $0 \leq P(\mathbb{E}) \leq 1$ 。若已知所有狀態發生的機率，則 $P(\mathbb{E}) = \sum_{\omega \in \mathbb{E}} P_\omega$ 。

1 關於機率論的介紹內容可參閱 Jacod and Protter (2004)。

2 在動態經濟結構中，不確定性會逐漸解決（例如，今後一年間的每一日逐漸排除）。

機率測度 (probability measure) $P: \mathcal{F} \rightarrow [0, 1]$ 具有下列性質：

1. $\forall \mathbb{E} \in \mathcal{F}: P(\mathbb{E}) \geq 0$
2. 對於互斥集 (disjoint set) $\mathbb{E}_i \in \mathcal{F}$ 而言， $P\left(\bigcup_{i=1}^I \mathbb{E}_i\right) = \sum_{i=1}^I P(\mathbb{E}_i)$
3. $P(\Omega) = 1$

三元素 $\{\Omega, \mathcal{F}, P\}$ 集結形成機率空間。機率空間是此模型經濟結構中不確定性的數學形式表徵。若機率測度 P 固定，則稱經濟結構處於風險之中。若經濟結構中的所有代理人已知此風險，則稱此經濟結構具有對稱資訊 (symmetric information)。

已知機率空間 $\{\Omega, \mathcal{F}, P\}$ ，而隨機變數為函數 $S: \Omega \rightarrow \mathbb{R}_+$ ， $\omega \mapsto S(\omega)$ ，其為 \mathcal{F} -可測的。如此意味著，對每個 $\mathbb{E} \in \{[a, b[: a, b \in \mathbb{R}, a < b\}$ 有下列結果：

$$S^{-1}(\mathbb{E}) \equiv \{\omega \in \Omega : S(\omega) \in \mathbb{E}\} \in \mathcal{F}$$

若 $\mathcal{F} \equiv \wp(\Omega)$ ，則下列為隨機變數的期望值 (expectation) 定義：

$$\mathbf{E}^P(S) = \sum_{\omega \in \Omega} P(\omega) \cdot S(\omega)$$

不然期望值的定義如下：

$$\mathbf{E}^P(S) = \sum_{\mathbb{E} \in \mathcal{F}} P(\mathbb{E}) \cdot S(\mathbb{E})$$

通常，假設某個金融經濟結構為完全競爭 (perfect)，其意味著，別的不說，此時沒有交易成本，可用的資產具有固定價格而且數量無限，一切活動以光速進行，代理人具有完整與對稱的資訊。

數值範例

此時假設處於風險 $\{\Omega, \mathcal{F}, P\}$ 下的簡單靜態經濟結構，而存在以下情況：

1. $\Omega \equiv \{u, d\}$
2. $\mathcal{F} \equiv \wp(\Omega)$
3. $P \equiv \left\{P(\{u\}) = \frac{1}{2}, P(\{d\}) = \frac{1}{2}\right\}$

交易資產

此經濟結構中交易兩筆資產。第一項是風險資產——股票，今日確定價格為 $S_0 = 10$ ，而明日不確定的 payoff 以下列隨機變數形式表示：

$$S_1 = \begin{cases} S_1^u = 20 & \text{if } \omega = u \\ S_1^d = 5 & \text{if } \omega = d \end{cases}$$

第二項是無風險資產——債券，今日確定價格為 $B_0 = 10$ ，明日確定的 payoff 如下：

$$B_1 = \begin{cases} B_1^u = 11 & \text{if } \omega = u \\ B_1^d = 11 & \text{if } \omega = d \end{cases}$$

數學形式上，此模型經濟結構可以寫作 $\mathcal{M}^2 = (\{\Omega, \mathcal{F}, P\}, \mathbb{A})$ ，其中 \mathbb{A} 為可交易資產，其形式為今日的價格向量 $M_0 = (S_0, B_0)^T$ 以及下列明日市場 payoff 矩陣：

$$M_1 = \begin{pmatrix} S_1^u & B_1^u \\ S_1^d & B_1^d \end{pmatrix}$$

套利定價

以此經濟結構，可以解決如下的問題：以股票履約價 $K = 14.5$ 導出歐式買權（*European call option*）的公允價值（fair value）。歐式買權無套利的價值 C_0 是依股票與債券的投資組合 ϕ 複製此選擇權的 payoff（ C_1 ）推導而來。此複製投資組合的價格也必然是歐式買權的價格。否則將存在（無限）套利空間。以 Python 運用這樣的複製論點，輕而易舉³：

```
In [1]: import numpy as np

In [2]: S0 = 10 ❶
        B0 = 10 ❶

In [3]: S1 = np.array((20, 5)) ❷
        B1 = np.array((11, 11)) ❷

In [4]: M0 = np.array((S0, B0)) ❸
        M0 ❸
```

3 有關套利之風險中立評價以及評價相關的詳細資訊，可參閱 Hilpisch (2015, ch. 4)。

```

Out[4]: array([10, 10])

In [5]: M1 = np.array((S1, B1)).T ④
        M1 ④
Out[5]: array([[20, 11],
               [ 5, 11]])

In [6]: K = 14.5 ⑤

In [7]: C1 = np.maximum(S1 - K, 0) ⑥
        C1 ⑥
Out[7]: array([5.5, 0. ])

In [8]: phi = np.linalg.solve(M1, C1) ⑦
        phi ⑦
Out[8]: array([ 0.36666667, -0.16666667])

In [9]: np.allclose(C1, np.dot(M1, phi)) ⑧
Out[9]: True

In [10]: C0 = np.dot(M0, phi) ⑨
         C0 ⑨
Out[10]: 2.0

```

- ① 股票與債券的今日價格。
- ② 股票（不確定）與債券（確定）明日的 payoff。
- ③ 市價向量。
- ④ 市場 payoff 矩陣。
- ⑤ 選擇權的履約價。
- ⑥ 選擇權的不確定 payoff。
- ⑦ 複製投資組合 ϕ 。
- ⑧ 確認其 payoff 是否與選擇權的 payoff 相同。
- ⑨ 複製投資組合的價格是選擇權的無套利價格。



套利定價

如上述範例所示，可將套利定價理論視為最強大的金融理論之一，其具備某些較為紮實的數學結果，如資產定價基本定理（*FTAP*）⁴。姑且不論別的原因，而可以從其他可觀測的市場參數（如：賣權交易標的股價）推出選擇權價格的事實所致。就此意義而言，套利定價先不考慮如何得出公允股價，而只是將其作為輸入內容。因此，套利定價使用少量且緩和的假設行事，凡是少了套利，對許多金融理論來說都無法接受。注意，其中也沒有採用機率測度得出套利價格。

預期效用理論

預期效用理論（EUT）是金融理論的基石。自 1940 年代提出以來，一直是不確定性之下決策建模的主要範式之一⁵。關於金融與投資理論的每本入門教科書通常都會有 EUT 的介紹。其中一個原因是，金融方面的其他主要結果可以從 EUT 範式中得出。

假設與結果

EUT 是個不證自明理論（axiomatic theory），可以追溯到 von Neumann and Morgenstern (1944) 的首創研究。不證自明在此意味著這個理論的主要結果只能從少量的公理中推導出來。有關公理效用理論各種變形與應用的概括論述，可參閱 Fishburn (1968)。

公理與規範理論

在 Wolfram MathWorld (<https://oreil.ly/pZqal>) 中，可以找到針對公理（axiom）的定義：「公理是不經證明就顯而易見的真實陳述」。

當面對不確定性下的抉擇時，EUT 通常以代理人偏好的一小部分主要公理為基礎。雖然公理的定義另有論述，但是並非所有公理都被經濟學家們視為「不經證明就顯而易見的真實」。

4 請參閱 Hilpisch (2015, ch. 4) 以及其中的參考文獻。

5 更多背景與細節，可參閱 Eichberger and Harper (1997, ch. 1) 或 Varian (2010, ch. 12)。

Von Neumann and Morgenstern (1944, p. 25) 對於公理的抉擇評論是：

公理的抉擇並非全然客觀的任務。通常可以預期達到某個明確目標——某些特定的定理可以從公理中推導出來——而且就此範疇來說，問題是確切與客觀的。但除此之外，總會有本質上不那麼確切的其他重要之物：公理不宜過多，其系統盡可能簡單明瞭，每個公理應具有直覺意涵，進而直接判斷其適當性。

依此意義而言，一套公理構成一個規範理論，而以此理論塑造世界（或世界的一部分）。一套公理集結某個先驗（*priori*）應滿足的最小假設集合，而不是以某種數學形式證明或類似作為。在列出造就 EUT 的一套公理之前，於不確定性之下抉擇呈現之際，會有些關於代理人自身偏好的用詞（數學形式是 \succeq ）。

代理人的偏好

假設具有偏好 \succeq 的代理人面臨投資模型經濟結構 \mathcal{M}^2 兩種交易資產的投資問題。例如，代理人可以在未來 payoff 為 $A = \phi_A \cdot M_1$ 的投資組合 ϕ_A 或未來 payoff 為 $B = \phi_B \cdot M_1$ 的投資組合 ϕ_B 之間做抉擇。假設代理人的偏好 \succeq 是依據未來 payoff（而非投資組合）所定義。若代理人偏好 payoff A（強）優於 payoff B，則以 $A \succ B$ 表示，反之則以 $A \prec B$ 代表。若代理人對於兩者偏好無差別，則以 $A \sim B$ 表示。鑒於這些敘述，造就如下所述的一套 EUT 可能公理：

完整性（*completeness*）

代理人依相對的彼此，可將所有的 payoff 排行。即下列其中一項必定成立： $A \succ B$ 、 $A \prec B$ 或 $A \sim B$ 。

遞移性（*transitivity*）

若有第三個投資組合 ϕ_C 搭配未來 payoff $C = \phi_C \cdot M_1$ ，則由 $A \succ B$ 且 $B \succ C$ ，可得 $A \succ C$ 。

連續性（*continuity*）

若 $A \succ B \succ C$ ，則存在一個數值 $\alpha \in [0, 1]$ ，使得 $B \sim \alpha A + (1 - \alpha)C$ 。

獨立性（*independence*）

若 $A \sim B$ 則 $\alpha A + (1 - \alpha)C \sim \alpha B + (1 - \alpha)C$ 。

同理，

若 $A \succ B$ 則 $\alpha A + (1 - \alpha)C \succ \alpha B + (1 - \alpha)C$ 。

優勢性 (dominance)

若 $C_1 = \alpha_1 A + (1 - \alpha_1)C$ 且 $C_2 = \alpha_2 A + (1 - \alpha_2)C$ ，則由 $A \succ C$ 且 $C_1 \succ C_2$ 可得 $\alpha_1 > \alpha_2$ 。

效用函數

效用函數 (utility function) 是以數學與數值方式表示代理人偏好 \succeq 的作法，即這樣的函數會對某個 payoff 賦予某一數值。在此情況下，數值的絕對內容無關緊要，而數值衍生的順序值得關注⁶。假設 \mathbb{X} 代表代理人能夠表達其偏好的所有可能 payoff。則效用函數 U 定義如下：

$$U: \mathbb{X} \rightarrow \mathbb{R}_+, x \mapsto U(x)$$

若 U 表示代理人的偏好 \succeq ，則存在下列關係：

$$A \succ B \Rightarrow U(A) > U(B) \quad (\text{強優於})$$

$$A \succeq B \Rightarrow U(A) \geq U(B) \quad (\text{弱優於})$$

$$A \prec B \Rightarrow U(A) < U(B) \quad (\text{強劣於})$$

$$A \preceq B \Rightarrow U(A) \leq U(B) \quad (\text{弱劣於})$$

$$A \sim B \Rightarrow U(A) = U(B) \quad (\text{無差別})$$

效用函數 U 只能作正線性轉換。因此，若 U 表示偏好 \succeq ，則 $V = a + bU$ (其中 $a, b > 0$) 也是如此作為。關於效用函數，von Neumann and Morgenstern (1944, p. 25) 總結如下：「因此得知：若真的存在這樣的效用數值評價，則必定是作線性轉換。即，效用就是線性轉換的數值。」

預期效用函數

Von Neumann and Morgenstern (1944) 表示，若代理人的偏好 \succeq 滿足前述五個公理，則存在對應的預期效用函數 (expected utility function)：

$$U: \mathbb{X} \rightarrow \mathbb{R}_+, x \mapsto \mathbf{E}^P(u(x)) = \sum_{\omega} P(\omega)u(x(\omega))$$

在此 $u: \mathbb{R} \rightarrow \mathbb{R}, x \mapsto u(x)$ 是單調遞增、狀態獨立的函數，往往稱為 Bernoulli 效用函數，諸如 $u(x) = \ln(x)$ 、 $u(x) = x$ 或 $u(x) = x^2$ 。

6 通常稱之為序號。街道房子的門牌號碼就是貼切的序號示例。

換句話說，預期效用函數 U 將函數 u 套用於某狀態的 payoff ($x(\omega)$)，並使用已知狀態發生的機率 $P(\omega)$ 對單一效用加權。對於特殊的線性 Bernoulli 效用函數 $u(x) = x$ 而言，預期效用就是狀態相關 payoff 的期望值—— $U(x) = \mathbf{E}^P(x)$ 。

風險趨避

風險趨避 (*risk aversion*) 是重要的金融概念。風險趨避最常用的衡量方法是絕對風險趨避 (ARA) 之 Arrow-Pratt 衡量法，其可追溯到 Pratt(1964)。假設代理人的狀態獨立 Bernoulli 效用函數為 $u(x)$ 。則 ARA 之 Arrow-Pratt 衡量法的定義為：

$$ARA(x) = -\frac{u''(x)}{u'(x)}, x \geq 0$$

依據此衡量方法可以分成下列三種情況：

$$ARA(x) = -\frac{u''(x)}{u'(x)} \begin{cases} > 0 & \text{風險趨避} \\ = 0 & \text{風險中立} \\ < 0 & \text{風險愛好} \end{cases}$$

在金融理論與模型中，一般假定的適當情況為風險趨避與風險中立。而在博弈之中，可能也會找到風險愛好的代理人。

依據之前提及的三個 Bernoulli 函數： $u(x) = \ln(x)$ 、 $u(x) = x$ 或 $u(x) = x^2$ 。可以輕易驗證其分別塑造的風險趨避、風險中立以及風險愛好三種代理人。例如 $u(x) = x^2$ ：

$$-\frac{u''(x)}{u'(x)} = -\frac{2}{2x} < 0, x > 0 \Rightarrow \text{風險愛好}$$

數值範例

此 EUT 應用可輕易以 Python 舉例說明。假設範例的模型經濟結構承襲上一節的 \mathcal{M}^2 。偏好 \succeq 之代理人依據的 EUT，是以不同的未來 payoff 而定。此代理人的 Bernoulli 效用函數是 $u(x) = \sqrt{x}$ 。此範例中，投資組合 ϕ_A 造就的 payoff (A_1) 優於投資組合 ϕ_D 造就的 payoff (D_1)。

下列為此應用的程式碼：

```
In [11]: def u(x):
         return np.sqrt(x) ❶
```

```

In [12]: phi_A = np.array((0.75, 0.25)) ❷
         phi_D = np.array((0.25, 0.75)) ❷

In [13]: np.dot(M0, phi_A) == np.dot(M0, phi_D) ❸
Out[13]: True

In [14]: A1 = np.dot(M1, phi_A) ❹
         A1 ❹
Out[14]: array([17.75,  6.5 ])

In [15]: D1 = np.dot(M1, phi_D) ❺
         D1 ❺
Out[15]: array([13.25,  9.5 ])

In [16]: P = np.array((0.5, 0.5)) ❻

In [17]: def EUT(x):
         return np.dot(P, u(x)) ❼

In [18]: EUT(A1) ❽
Out[18]: 3.381292321692286

In [19]: EUT(D1) ❽
Out[19]: 3.3611309730623735

```

- ❶ 風險趨避的 Bernoulli 效用函數。
- ❷ 權重不同的兩個投資組合。
- ❸ 顯示每個投資組合設置的成本相同。
- ❹ 一個投資組合（不確定）的 payoff，
- ❺ 以及另一個投資組合（不確定）的 payoff。
- ❻ 機率測度。
- ❼ 預期效用函數。
- ❽ 兩個（不確定） payoff 的效用值。

在此情況下，典型的問題是，已知代理人的固定預算 $w > 0$ ，要得出最佳投資組合（即預期效用最大化）。下列 Python 程式碼會為此問題建模，並確切的解決。在可用預算中，代理人將 60% 左右的額度投入風險資產中，而約 40% 的額度置於無風險資產中。結果主要由特定類型的 Bernoulli 效用函數而定：

```

In [20]: from scipy.optimize import minimize

In [21]: w = 10 ❶

In [22]: cons = {'type': 'eq', 'fun': lambda phi: np.dot(M0, phi) - w} ❷

In [23]: def EUT_(phi):
          x = np.dot(M1, phi) ❸
          return EUT(x) ❸

In [24]: opt = minimize(lambda phi: -EUT_(phi), ❹
                        x0=phi_A, ❺
                        constraints=cons) ❻

In [25]: opt ❼
Out[25]:      fun: -3.385015999493397
          jac: array([-1.69249132, -1.69253424])
          message: 'Optimization terminated successfully.'
          nfev: 16
          nit: 4
          njev: 4
          status: 0
          success: True
          x: array([0.61122474, 0.38877526])

In [26]: EUT_(opt['x']) ❽
Out[26]: 3.385015999493397

```

- ❶ 代理人的固定預算。
- ❷ 以 `minimize`⁷ 限制預算的使用。
- ❸ 針對投資組合定義預期效用函數。
- ❹ `-EUT_(phi)` 最小化（即 `EUT_(phi)` 最大化）。
- ❺ 優化的初始猜值。
- ❻ 套用限制的預算。
- ❼ 最佳結果，包含 `x` 的最佳投資組合。
- ❽ 在 `w = 10` 預算下最佳（最高）預期效用。

⁷ 細節可參閱 http://bit.ly/aiif_minimize。

平均數—變異數投資組合理論

Markowitz (1952) 的平均數—變異數投資組合 (MVP) 理論是金融理論的另一個基石。其為不確定性方面最早的投資理論之一，只聚焦於股票投資組合建構的統計衡量。MVP 將可能影響公司股票表現的基本面，或者對公司前景成長至關重要的未來競爭力假設完全抽離。基本上，唯一計數的輸入資料是股價的時間序列，以及從中得出的統計內容，諸如（歷史）年化報酬率平均數以及（歷史）年化報酬率變異數。

假設與結果

依據 Markowitz (1952) 的論述，MVP 的主要假設是，投資人只關心預期報酬率與這些報酬率的變異數：

接著考量以下規則：投資人確實（或應該）認為預期報酬率是討喜之物，而報酬率的變異數是不討喜之物。此規則有許多合理之處，既可以作為投資行為的準則，也可以作為投資行為的前提。

預期報酬率為最大的投資組合，不一定是變異數為最小的投資組合。投資人可以接受變異數而獲得預期報酬率，或者放棄預期報酬率以降低變異數。

此種投資人偏好的作法，與直接定義代理人偏好以及 payoff 效用函数的作法大相逕庭。MVP 則是認為可以在投資組合預期產生報酬率的一次及二次動差（first and second moment），定義代理人的偏好與效用函数。



隱含假設的常態分布

一般來說，MVP 理論只關注投資組合於一個期間的風險與報酬，此與標準 EUT 並不相容。此議題的解法是，假設風險資產的報酬率是常態分布，使得一次及二次動差可充分描述資產報酬率的完整分布。下一章將說明，這在實際的金融資料中幾乎未曾出現。另一種方式是假設某個特定的二次式 Bernoulli 效用函数，如下一節所示。

投資組合統計

假定靜態經濟結構 $\mathcal{M}^N = (\{\Omega, \mathcal{F}, P\}, \mathbb{A})$ ，其可交易資產集合 \mathbb{A} ，是由 N 個風險資產 A^1, A^2, \dots, A^N 所組成。以 A_0^n 為資產 n 今日的固定價格，而 A_1^n 為其一年的 payoff，則資產 n 的（簡單）淨報酬率向量 r^n 定義如下：

$$r^n = \frac{A_1^n}{A_0^n} - 1$$

對於具有相同發生機率的所有未來狀態而言，資產 n 的預期報酬率 (*expected return*) 為：

$$\mu^n = \frac{1}{|\Omega|} \sum_{\omega} r^n(\omega)$$

因此，預期報酬率的向量如下：

$$\mu = \begin{bmatrix} \mu^1 \\ \mu^2 \\ \vdots \\ \mu^N \end{bmatrix}$$

投資組合（向量）為 $\phi = (\phi^1, \phi^2, \dots, \phi^N)^T$ ，其中 $\phi_n \geq 0$ 以及 $\sum_n \phi^n = 1$ ，而投資組合裡的每個資產附有權重⁸。

然後，投資組合的預期報酬率則是投資組合加權向量與預期報酬率向量的點積（dot product）：

$$\mu^{phi} = \phi \cdot \mu$$

此時藉由下列內容定義資產 n 與資產 m 之間的共變異數 (*covariance*)：

$$\sigma_{mn} = \sum_{\omega} (r^m(\omega) - \mu^m)(r^n(\omega) - \mu^n)$$

而共變異數矩陣 (*covariance matrix*) 如下：

$$\Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \dots & \sigma_{nn} \end{bmatrix}$$

8 這些假設並非真的必要。例如，在不會顯著變更分析的情況下，可以允許賣空（short sale）。

投資組合的預期變異數則是下列雙點積：

$$\varphi^{phi} = \phi^T \cdot \Sigma \cdot \phi$$

因此投資組合的預期波動率（volatility）如下：

$$\sigma^{phi} = \sqrt{\varphi^{phi}}$$

Sharpe ratio

Sharpe (1966) 提出一種衡量指標，可判斷共同基金以及其他投資組合、甚至是單一風險資產於風險調整後的績效。其最簡單的形式是將投資組合的（預期、已實現）報酬率與其（預期、已實現）波動率相關聯。因此就數學形式而言，Sharpe ratio 的定義如下：

$$\pi^{phi} = \frac{\mu^{phi}}{\sigma^{phi}}$$

若 r 表示無風險短期利率，則投資組合 phi 相對無風險投資的風險溢酬（risk premium）或超額報酬（excess return）為 $\mu^{phi} - r$ 。Sharpe ratio 的另一種形式是風險溢酬位於分子：

$$\pi^{phi} = \frac{\mu^{phi} - r}{\sigma^{phi}}$$

若無風險短期利率相對較低，則在套用相同的無風險短期利率時，兩種 Sharpe ratio 版本的數值結果差別不大。特別是以 Sharpe ratio 對不同的投資組合排行時，兩種版本應該會產生相同的排行（其他條件皆相等的情況下）。

數值範例

再度採用靜態模型經濟結構 \mathcal{M}^2 ，則依然可以使用 Python 輕易說明 MVP 的基本概念。

投資組合統計

第一段是投資組合預期報酬率（expected return）的推導：

```
In [27]: rS = S1 / S0 - 1 ❶
```

```
        rS ❶
```

```
Out[27]: array([ 1. , -0.5])
```

```
In [28]: rB = B1 / B0 - 1 ❷
```

```

rB ②
Out[28]: array([0.1, 0.1])

In [29]: def mu(rX):
         return np.dot(P, rX) ③

In [30]: mu(rS) ④
Out[30]: 0.25

In [31]: mu(rB) ④
Out[31]: 0.10000000000000009

In [32]: rM = M1 / M0 - 1 ⑤
         rM ⑤
Out[32]: array([[ 1. ,  0.1],
                [-0.5,  0.1]])

In [33]: mu(rM) ⑥
Out[33]: array([0.25, 0.1 ])

```

- ① 風險資產的報酬率向量。
- ② 無風險資產的報酬率向量。
- ③ 預期報酬率函數。
- ④ 交易資產的預期報酬率。
- ⑤ 交易資產的報酬率矩陣。
- ⑥ 預期報酬率向量。

第二段是變異數與波動率，以及共變異數矩陣：

```

In [34]: def var(rX):
         return ((rX - mu(rX)) ** 2).mean() ①

In [35]: var(rS)
Out[35]: 0.5625

In [36]: var(rB)
Out[36]: 0.0

In [37]: def sigma(rX):
         return np.sqrt(var(rX)) ②

```

```
In [38]: sigma(rS)
Out[38]: 0.75
```

```
In [39]: sigma(rB)
Out[39]: 0.0
```

```
In [40]: np.cov(rM.T, aweights=P, ddof=0) ❸
Out[40]: array([[0.5625, 0.    ],
                [0.    , 0.    ]])
```

- ❶ 變異數函數。
- ❷ 波動率函數。
- ❸ 共變異數矩陣。

第三段是投資組合預期報酬率、投資組合預期變異數以及投資組合預期波動率，皆以同一個加權投資組合說明：

```
In [41]: phi = np.array((0.5, 0.5))
```

```
In [42]: def mu_phi(phi):
          return np.dot(phi, mu(rM)) ❶
```

```
In [43]: mu_phi(phi)
Out[43]: 0.17500000000000004
```

```
In [44]: def var_phi(phi):
          cv = np.cov(rM.T, aweights=P, ddof=0)
          return np.dot(phi, np.dot(cv, phi)) ❷
```

```
In [45]: var_phi(phi)
Out[45]: 0.140625
```

```
In [46]: def sigma_phi(phi):
          return var_phi(phi) ** 0.5 ❸
```

```
In [47]: sigma_phi(phi)
Out[47]: 0.375
```

- ❶ 投資組合與其報酬率。
- ❷ 投資組合預期變異數。
- ❸ 同資組合預期波動率。

投資機會集合

依據投資組合權重 ϕ 的 Monte Carlo 模擬，可以視覺化呈現波動率報酬率空間中投資機會集合（圖 3-1 是由下列程式碼片段產生的結果）。

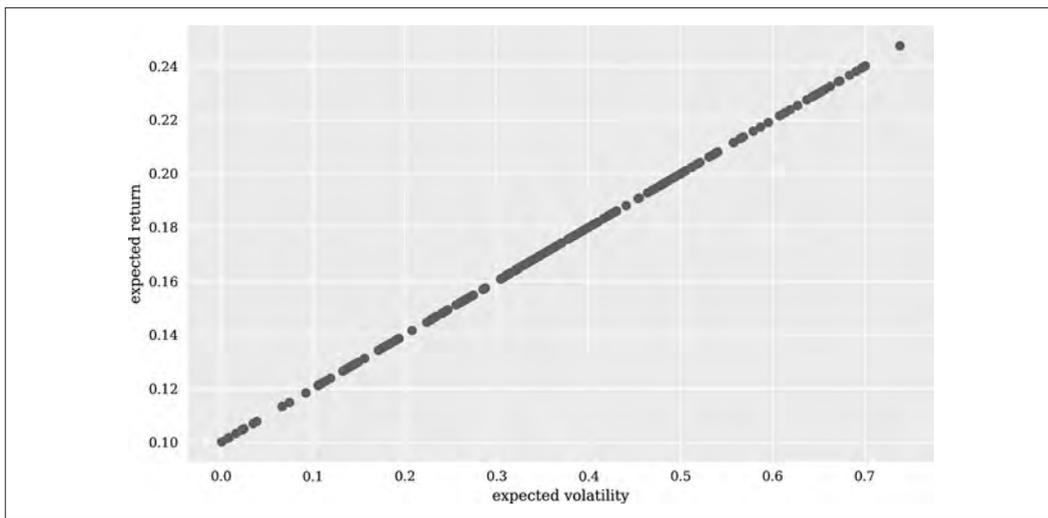


圖 3-1 預期投資組合波動率與報酬率的模擬（一種風險資產）

因為只有一種風險資產與一種無風險資產，所以機會集合為一條直線：

```
In [48]: from pylab import plt, mpl
plt.style.use('seaborn')
mpl.rcParams['savefig.dpi'] = 300
mpl.rcParams['font.family'] = 'serif'
```

```
In [49]: phi_mcs = np.random.random((2, 200)) ❶
```

```
In [50]: phi_mcs = (phi_mcs / phi_mcs.sum(axis=0)).T ❶
```

```
In [51]: mcs = np.array([(sigma_phi(phi), mu_phi(phi))
                        for phi in phi_mcs]) ❷
```

```
In [52]: plt.figure(figsize=(10, 6))
plt.plot(mcs[:, 0], mcs[:, 1], 'ro')
plt.xlabel('expected volatility')
plt.ylabel('expected return');
```

- ❶ 隨機投資組合成分，正規化縮放至 1。
- ❷ 隨機成分的預期投資組合波動率與報酬率。

此時考量具有三個狀態的靜態經濟結構 \mathcal{M}^3 ，其中 $\Omega = \{u, m, d\}$ 。這三個狀態發生的可能性相同，即 $P = \left\{ \frac{1}{3}, \frac{1}{3}, \frac{1}{3} \right\}$ 。可交易資產集合則由兩項風險資產 S 與 T 組成，其初始價格固定為 $S_0 = T_0 = 10$ ，而各自不確定的 payoff 分別如下所示：

$$S_1 = \begin{bmatrix} 20 \\ 10 \\ 5 \end{bmatrix}$$

與

$$T_1 = \begin{bmatrix} 1 \\ 12 \\ 13 \end{bmatrix}$$

依據上述的假設，下列 Python 程式碼再度以 Monte Carlo 模擬，並視覺化呈現結果（如圖 3-2）。結果是這兩項風險資產讓知名的 MVP「bullet」（彈頭）乍現。

```
In [53]: P = np.ones(3) / 3 ❶
          P ❶
Out[53]: array([0.33333333, 0.33333333, 0.33333333])

In [54]: S1 = np.array((20, 10, 5))

In [55]: T0 = 10
          T1 = np.array((1, 12, 13))

In [56]: M0 = np.array((S0, T0))
          M0
Out[56]: array([10, 10])

In [57]: M1 = np.array((S1, T1)).T
          M1
Out[57]: array([[20, 1],
                [10, 12],
                [ 5, 13]])

In [58]: rM = M1 / M0 - 1
          rM
Out[58]: array([[ 1. , -0.9],
                [ 0. ,  0.2],
```

```
[-0.5, 0.3]])
```

```
In [59]: mcs = np.array([(sigma_phi(phi), mu_phi(phi))  
                        for phi in phi_mcs])
```

```
In [60]: plt.figure(figsize=(10, 6))  
        plt.plot(mcs[:, 0], mcs[:, 1], 'ro')  
        plt.xlabel('expected volatility')  
        plt.ylabel('expected return');
```

❶ 針對三個狀態的新機率測度。

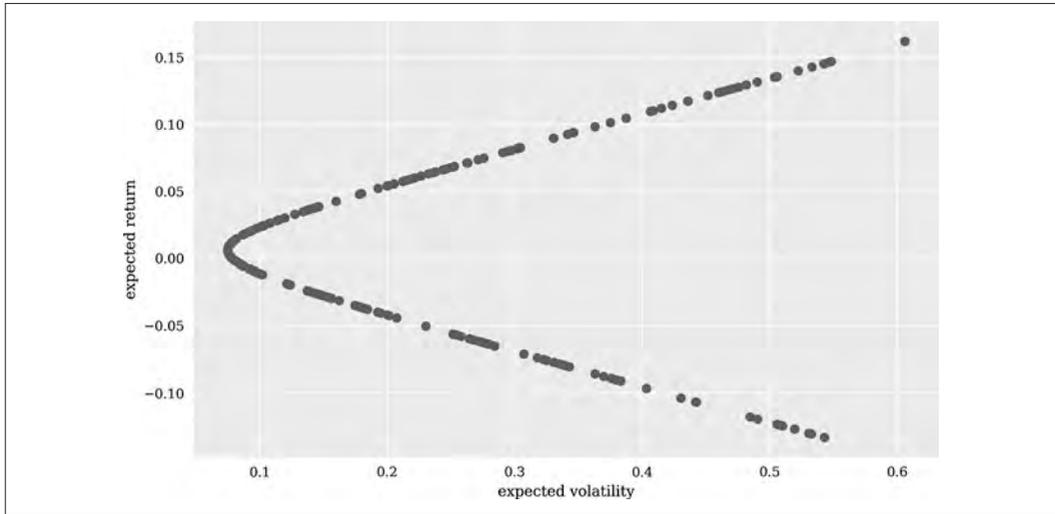


圖 3-2 預期投資組合波動率與報酬率的模擬（兩種風險資產）

最小波動率與最大 Sharpe ratio

接著要取得最小波動率（最小變異數）的投資組合與最大 *Sharpe ratio* 的投資組合。圖 3-3 顯示此風險—報酬空間兩個投資組合對應所求的位置。

儘管風險資產 *T* 的預期報酬率為負值，但是在最大 *Sharpe ratio* 的投資組合中，有顯著的權重。這是因為（風險）分散效應，讓投資組合風險降得比投資組合的預期報酬率低：

```
In [61]: cons = {'type': 'eq', 'fun': lambda phi: np.sum(phi) - 1}
```

```
In [62]: bnds = ((0, 1), (0, 1))
```

```
In [63]: min_var = minimize(sigma_phi, (0.5, 0.5),  
                             constraints=cons, bounds=bnds) ❶
```

```
In [64]: min_var
```

```
Out[64]:      fun: 0.07481322946910632  
          jac: array([0.07426564, 0.07528945])  
          message: 'Optimization terminated successfully.'  
          nfev: 17  
          nit: 4  
          njev: 4  
          status: 0  
          success: True  
          x: array([0.46511697, 0.53488303])
```

```
In [65]: def sharpe(phi):  
         return mu_phi(phi) / sigma_phi(phi) ❷
```

```
In [66]: max_sharpe = minimize(lambda phi: -sharpe(phi), (0.5, 0.5),  
                               constraints=cons, bounds=bnds) ❸
```

```
In [67]: max_sharpe
```

```
Out[67]:      fun: -0.2721654098971811  
          jac: array([ 0.00012054, -0.00024174])  
          message: 'Optimization terminated successfully.'  
          nfev: 38  
          nit: 9  
          njev: 9  
          status: 0  
          success: True  
          x: array([0.66731116, 0.33268884])
```

```
In [68]: plt.figure(figsize=(10, 6))  
         plt.plot(mcs[:, 0], mcs[:, 1], 'ro', ms=5)  
         plt.plot(sigma_phi(min_var['x']), mu_phi(min_var['x']),  
                  '^', ms=12.5, label='minimum volatility')  
         plt.plot(sigma_phi(max_sharpe['x']), mu_phi(max_sharpe['x']),  
                  'v', ms=12.5, label='maximum Sharpe ratio')  
         plt.xlabel('expected volatility')  
         plt.ylabel('expected return')  
         plt.legend();
```

- ❶ 預期投資組合波動率最小化。
- ❷ 定義 Sharpe ratio 函數，假設短期利率為 0。
- ❸ Sharpe ratio 最大化（實際是其負值最小化）。

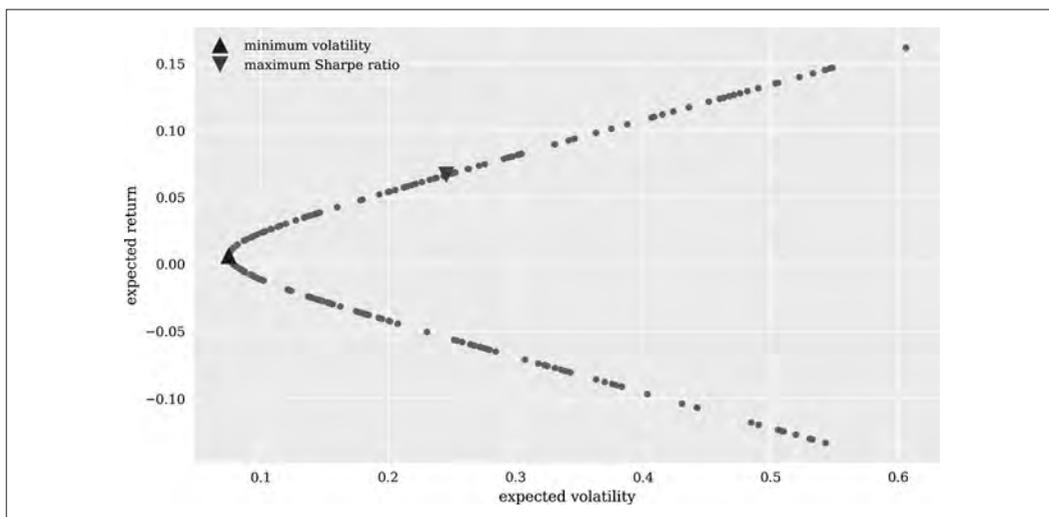


圖 3-3 最小波動率的投資組合與最大 Sharpe ratio 的投資組合

效率前緣

效率投資組合 (*efficient portfolio*) 是在已知預期風險 (報酬率) 之下具有最大 (最小) 預期報酬率 (風險)。在圖 3-3 中，投資組合的預期報酬率低於最小風險投資組合者，這些投資組合都是無效率投資組合。下列程式碼可得出風險—報酬空間中效率投資組合，對應結果如圖 3-4 所示。效率投資組合整個集合稱為效率前緣 (*efficient frontier*)，而代理人只依據效率前緣選取某個投資組合：

```
In [69]: cons = [{'type': 'eq', 'fun': lambda phi: np.sum(phi) - 1},
                {'type': 'eq', 'fun': lambda phi: mu_phi(phi) - target}] ❶
```

```
In [70]: bnds = ((0, 1), (0, 1))
```

```
In [71]: targets = np.linspace(mu_phi(min_var['x']), 0.16) ❷
```

```
In [72]: frontier = []
         for target in targets:
             phi_eff = minimize(sigma_phi, (0.5, 0.5),
```

```

constraints=cons, bounds=bnds)['x'] ❸
frontier.append((sigma_phi(phi_eff), mu_phi(phi_eff)))
frontier = np.array(frontier)

```

```

In [73]: plt.figure(figsize=(10, 6))
plt.plot(frontier[:, 0], frontier[:, 1], 'mo', ms=5,
         label='efficient frontier')
plt.plot(sigma_phi(min_var['x']), mu_phi(min_var['x']),
         '^', ms=12.5, label='minimum volatility')
plt.plot(sigma_phi(max_sharpe['x']), mu_phi(max_sharpe['x']),
         'v', ms=12.5, label='maximum Sharpe ratio')
plt.xlabel('expected volatility')
plt.ylabel('expected return')
plt.legend();

```

- ❶ 針對預期報酬率以新限制來固定某個目標水準。
- ❷ 產生目標預期報酬率集合。
- ❸ 已知目標預期報酬率之下取得最小波動率的投資組合。

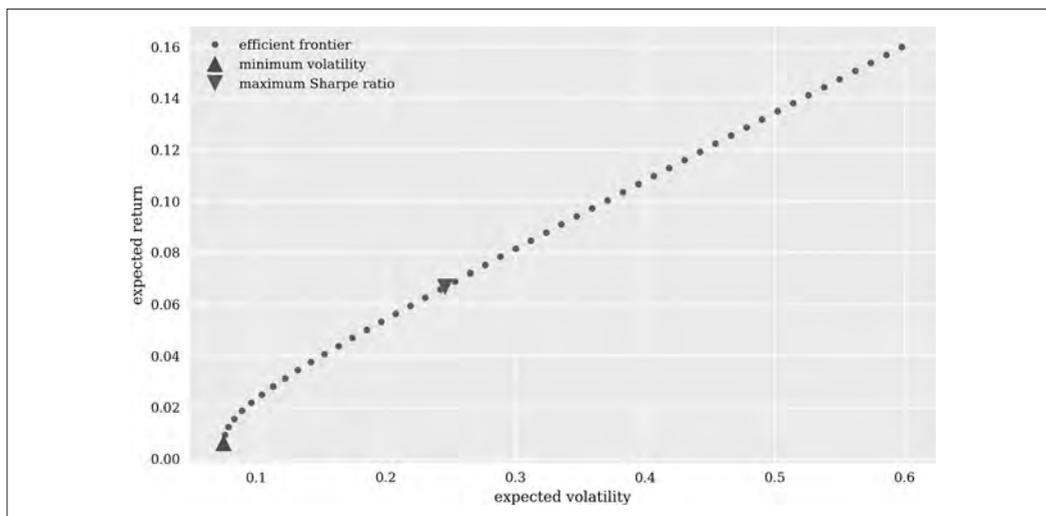


圖 3-4 效率前緣