

# Application de l'optimisation convexe au choix de portefeuilles socialement responsables

Travail d'initiative personnelle encadré

**Réalisé par**  
Ilias Mellouki

Juin 2021

## 1 Introduction

## 2 Problème de Markovitz

- Hypothèses sur le marché
- Modélisation
- Optimisation moyenne-variance

## 3 Optimisation sous contraintes

- Cas général
- Cas convexe

## 4 Résolution du problème

- Expression de la solution
- Partie Python
- Graphiques obtenus

## 5 Investissement socialement responsable

## 6 Annexe

## 1 Introduction

## 2 Problème de Markovitz

- Hypothèses sur le marché
- Modélisation
- Optimisation moyenne-variance

## 3 Optimisation sous contraintes

- Cas général
- Cas convexe

## 4 Résolution du problème

- Expression de la solution
- Partie Python
- Graphiques obtenus

## 5 Investissement socialement responsable

## 6 Annexe

# Problématique

- Comment modéliser les prix des actifs ainsi que les portefeuilles ?
- Comment formuler le problème de recherche d'un portefeuille performant pour un seuil maximal de risque donné ?
- Comment traduire mathématiquement et résoudre le problème en utilisant des outils d'optimisation ?
- Comment introduire la responsabilité sociale dans le choix de portefeuille ?

## 1 Introduction

## 2 Problème de Markovitz

- Hypothèses sur le marché
- Modélisation
- Optimisation moyenne-variance

## 3 Optimisation sous contraintes

- Cas général
- Cas convexe

## 4 Résolution du problème

- Expression de la solution
- Partie Python
- Graphiques obtenus

## 5 Investissement socialement responsable

## 6 Annexe

# Notations et hypothèses sur le marché

- On suppose le marché à 2 dates  $t = 0$  et  $t = 1$
- Il existe  $N$  actifs risqués, et 1 actif sans risque
- L'actif sans risque vaut 1 en  $t = 0$  et  $1+r$  en  $t = 1$
- On note  $p_i(t)$  le prix de l'actif  $i$  à la date  $t$ , avec  $i \in \{1, \dots, N\}$  et  $t \in \{0, 1\}$
- On note  $y_i$  le rapport  $\frac{p_i(1)}{p_i(0)}$

# Modélisation du futur

- Afin de modéliser les valeurs futures des actifs, on utilise des variables aléatoires, pour cela on se donne un espace de probabilité  $(\Omega, \mathcal{F}, \mathbb{P})$

- $Y = \begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix}$  vecteur aléatoire à valeurs dans  $\mathbb{R}^N$  qu'on suppose dans  $L^2$

- On note son espérance

$$\mu = \mathbb{E}[Y] \in \mathbb{R}^N$$

et sa matrice de variance covariance

$$\Omega = \text{Var}(Y) = (\text{Cov}(Y_i, Y_j)_{1 \leq i, j \leq N}) \in \mathbb{S}_n^{++}(\mathbb{R})$$

Donc en particulier  $\Omega$  inversible.

- On suppose que  $\forall i \in \{1, \dots, N\}$  on a  $\mu_i > 1 + r$

# Modélisation du portefeuille

- Un portefeuille est défini par le couple  $(a_0, a) \in \mathbb{R} \times \mathbb{R}^N$ , indiquant la quantité d'actif qu'il contient.
- La valeur du portefeuille aux différents instants est donc

$$\begin{cases} V_0(a_0, a) = a_0 + \sum_{i=1}^N a_i p_i(0) \\ V_1(a_0, a) = a_0(1+r) + \sum_{i=1}^N a_i p_i(1) = a_0(1+r) + \sum_{i=1}^N a_i p_i(0) y_i \end{cases}$$

- Sous forme matricielle:

## Valeurs du portefeuille

$$\begin{cases} V_0(a_0, a) = a_0 + a^T p(0) \\ V_1(a_0, a) = a_0(1+r) + a^T \text{diag}(p(0)) Y \end{cases}$$

où

$$p(0) = \begin{pmatrix} p_1(0) \\ \vdots \\ p_N(0) \end{pmatrix}$$



# Problème d'optimisation

- On considère un portefeuille de valeur  $v$  en  $t = 0$ , i.e  $V_0(a_0, a) = v$ , on se donne un niveau maximal de variance  $\sigma^2$ , on veut naturellement maximiser l'espérance de gain.
- On cherche à trouver les couples  $(a_0, a)$  qui résolvent :

## Problème de Markowitz

$$\begin{aligned} \max_{a_0, a} \quad & \mathbb{E}[V_1(a_0, a)] \\ \text{sous} \quad & \text{Var}[V_1(a_0, a)] \leq \sigma^2 \\ & V_0(a_0, a) = v \end{aligned} \tag{1}$$

# Formulation de la moyenne et de la variance

- On note

$$w_a = \text{diag}(p(0))a = \begin{pmatrix} p_1(0) \cdot a_1 \\ \vdots \\ p_N(0) \cdot a_N \end{pmatrix}$$

le vecteur des valeurs initialement investies en chaque actif risqué

- Donc

$$\begin{cases} V_0(a_0, a_1) = a_0 + w_a^T e \\ V_1(a_0, a_1) = a_0(1+r) + w_a^T Y \end{cases}$$

où  $e = (1 \dots 1)^T$

- En général pour un vecteur aléatoire  $X \in L^2$  et un vecteur réel  $\lambda$  de même dimension,  $\text{Var}(\lambda^T X) = \lambda^T \text{Var}(X) \lambda$
- On déduit

$$\begin{cases} \mathbb{E}[V_1(a_0, a_1)] = a_0(1+r) + w_a^T \mu \\ \text{Var}[V_1(a_0, a_1)] = w_a^T \Omega w_a \end{cases}$$

# Problème équivalent

- Sachant que  $v$  est une donnée du problème, on peut éliminer la variable  $a_0$  du problème et se retrouver avec une optimisation sur  $\mathbb{R}^N$ :

$$\mathbb{E}[V_1(a_0, a_1)] = (v - w_a^T e)(1 + r) + w_a^T \mu$$

- On se débarrasse en même temps de la contrainte  $V_0(a_0, a) = v$ , le problème est alors équivalent à

$$\begin{aligned} \max_{w_a \in \mathbb{R}^N} \quad & (v - w_a^T e)(1 + r) + w_a^T \mu \\ \text{sous} \quad & w_a^T \Omega w_a = \sigma^2 \end{aligned}$$

- Le terme  $v(1 + r)$  étant constant, celà revient à trouver  $w_a^*$  qui résoudrait

## Problème d'optimisation équivalent

$$\begin{aligned} \max_{w_a \in \mathbb{R}^N} \quad & w_a^T \tilde{\mu} \\ \text{sous} \quad & w_a^T \Omega w_a \leq \sigma^2 \end{aligned} \tag{2}$$

Où  $\tilde{\mu} = \mu - (1 + r)e$

## 1 Introduction

## 2 Problème de Markovitz

- Hypothèses sur le marché
- Modélisation
- Optimisation moyenne-variance

## 3 Optimisation sous contraintes

- Cas général
- Cas convexe

## 4 Résolution du problème

- Expression de la solution
- Partie Python
- Graphiques obtenus

## 5 Investissement socialement responsable

## 6 Annexe

# Formulation standard d'un problème d'optimisation

- La forme standard d'un problème d'optimisation sur  $x \in \mathbb{R}^n$

$$\begin{array}{ll} \min & f_0(x) \\ \text{sous contraintes} & f_i(x) \leq 0, \quad i = 1, \dots, m \\ & h_i(x) = 0, \quad i = 1, \dots, p \end{array}$$

Où toutes les fonctions sont à valeurs dans  $\mathbb{R}$

- La valeur optimale du problème:

$$p^* = \inf_{x \in \mathbb{R}^n} \{f_0(x) \mid f_i(x) \leq 0, i = 1, \dots, m, h_i(x) = 0, i = 1, \dots, p\}$$

- $p^* = +\infty$  si  $\{f_0(x) \mid f_i(x) \leq 0, i = 1, \dots, m, h_i(x) = 0, i = 1, \dots, p\} = \emptyset$
- $p^* = -\infty$  si le problème est non borné inférieurement
- $p^* \in \mathbb{R}$  sinon

# Dualité Lagrangienne

## Lagrangien

On définit le Lagrangien:  $\mathcal{L} : \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p \rightarrow \mathbb{R}$  par

$$\mathcal{L}(x, \lambda, \nu) = f_0(x) + \sum_{i=1}^m \lambda_i f_i(x) + \sum_{i=1}^p \nu_i h_i(x)$$

Les scalaires  $\lambda_i$  et  $\nu_i$  sont appelés multiplicateurs de Lagrange.

# Conditions de KKT

## Conditions de Karush-Kuhn-Tucker

Les 4 conditions suivantes sur le triple  $(x, \lambda, \nu)$  sont appelées conditions de KKT (pour un problème différentiable  $f_i, h_i$ )

- ① Réalisabilité primale:  $f_i(x) \leq 0, h_j(x) = 0$
- ② Réalisabilité duale:  $\lambda \succeq 0$
- ③ Conditions de relâchement supplémentaires:  $\lambda_i f_i(x) = 0, i = 1, \dots, m$
- ④ Condition du premier ordre (le gradient du Lagrangien s'annule)

$$\nabla f_0(x) + \sum_{i=1}^m \lambda_i \nabla f_i(x) + \sum_{i=1}^p \nu_i \nabla h_i(x) = 0$$

## Condition nécessaire d'optimalité

Pour tout problème d'optimisation avec une fonction objective et des fonctions de contrainte différentiables, le triplet  $(x, \lambda, \nu)$  composé des points optimaux satisfait obligatoirement les conditions de KKT.

# Théorème de Salter

## Problème convexe

Un problème d'optimisation est dit **convexe** si les  $f_i$  sont convexes et les  $h_j$  sont linéaires, i.e de la forme  $h_j(x) = a_j^T x - b_j$  avec  $a_j \in \mathbb{R}^n$  et  $b_j \in \mathbb{R}$ . On note  $A \in \mathbb{R}^{p \times n}$  la matrice dont les lignes sont les  $a_j^T$  et  $b \in \mathbb{R}^p$  le vecteur des  $b_j$

## Condition de Salter pour un problème convexe

Il s'agit de l'existence d'un élément strictement réalisable :

$$\exists x \in \mathbb{R}^n : \quad f_i(x) < 0, \quad i = 1, \dots, m, \quad Ax = b$$

## Théorème de Salter

- Pour un problème convexe différentiable les conditions de KKT sont nécessaires et suffisantes pour l'optimalité, en d'autre terme un point  $x$  est optimal pour le primal si on réussit à trouver  $\lambda$  et  $\mu$  de sorte que  $(x, \lambda, \mu)$  satisfasse les conditions de KKT.



## 1 Introduction

## 2 Problème de Markovitz

- Hypothèses sur le marché
- Modélisation
- Optimisation moyenne-variance

## 3 Optimisation sous contraintes

- Cas général
- Cas convexe

## 4 Résolution du problème

- Expression de la solution
- Partie Python
- Graphiques obtenus

## 5 Investissement socialement responsable

## 6 Annexe

# Problème de Markowitz sous la forme standard

- On réécrit le problème sous la forme standard, avec un min, pour cela on utilise le fait que

$$\begin{array}{l} \max_{w_a \in \mathbb{R}^N} \quad w_a^T \tilde{\mu} \\ \text{sous} \quad w_a^T \Omega w_a \leq \sigma^2 \end{array} \iff \begin{array}{l} - \min_{w_a \in \mathbb{R}^N} \quad -w_a^T \tilde{\mu} \\ \text{sous} \quad w_a^T \Omega w_a \leq \sigma^2 \end{array}$$

- La résolution du problème de Markowitz est équivalente à la résolution de

$$\begin{array}{l} \min_{x \in \mathbb{R}^N} \quad f_0(x) \\ \text{sous} \quad f_1(x) \leq 0 \end{array}$$

- $f_0(x) = -x^T \tilde{\mu}$  est linéaire donc convexe.
- $f_1(x) = x^T \Omega x - \sigma^2$  qui est bien convexe, car  $\nabla^2 f_1(x) = 2\Omega \in \mathbb{S}_n^{++}(\mathbb{R})$
- Dans le cas où  $\sigma = 0$  la solution est triviale: on investit tout dans l'actif sans risque (valeur future déterministe donc de variance nulle)

# Conditions d'optimalité

- Dans le cas où  $\sigma > 0$ , en prenant  $x = 0$  on trouve que  $x^T \Omega x = 0 < \sigma^2$  et donc 0 satisfait la condition de Salter i.e  $f_1(0) < 0$
- Les conditions de KKT
  - 1  $x^T \Omega x - \sigma^2 \leq 0$
  - 2  $\lambda \geq 0$
  - 3  $\lambda(x^T \Omega x - \sigma^2) = 0$
  - 4  $-\tilde{\mu} + \lambda \Omega x = 0$

sont alors nécessaires et suffisantes pour l'optimalité de ce problème convexe.

- La condition 3 implique que  $\lambda = 0$  ou  $x^T \Omega x - \sigma^2 = 0$
- Si  $\lambda = 0$  alors la condition 4 donne  $\tilde{\mu} = 0$  or  $\mu > (1 + r)e$  donc  $\tilde{\mu} > 0$  d'où  $\lambda > 0$  et c'est l'autre terme qui s'annule
- Cela fait sens, la variance du portefeuille de gain maximal atteindra la variance maximale permise  $\sigma^2$
- L'équation 4 permet d'obtenir alors  $x = \frac{1}{\lambda} \Omega^{-1} \tilde{\mu}$

# Solution du problème

- En injectant dans l'équation 3 on obtient

$$x^T \Omega x = \left(\frac{1}{\lambda} \Omega^{-1} \tilde{\mu}\right)^T \Omega \frac{1}{\lambda} \Omega^{-1} \tilde{\mu} = \frac{1}{\lambda^2} \tilde{\mu}^T \Omega^{-1} \tilde{\mu} = \sigma^2$$

- Finalement, la solution du problème est

$$\begin{cases} w_a^*(\lambda^*) = \frac{1}{\lambda^*} \Omega^{-1} \tilde{\mu} \\ \lambda^* = \frac{1}{\sigma} \sqrt{\tilde{\mu}^T \Omega^{-1} \tilde{\mu}} \end{cases}$$

- $\lambda^*$  étant proportionnel à  $\frac{1}{\sigma}$ , peut être vu comme **l'aversion au risque** de l'investisseur, plus  $\lambda^*$  est grand moins on investit dans l'actif risqué et donc plus on investit dans l'actif sans risque.

# Calcul de la moyenne et de la variance

- On rappelle que

$$\begin{cases} a^* = \text{diag}(p(0))^{-1} w_a^* \\ a_0^* = v - (w_a^*)^T e \end{cases}$$

- On trouve finalement:

## Solution du problème de Markowitz

$$\begin{cases} a^*(\lambda^*) = \frac{1}{\lambda^*} \text{diag}(p(0))^{-1} \Omega^{-1} \tilde{\mu} \\ a_0^*(\lambda^*) = v - \frac{1}{\lambda^*} \tilde{\mu}^T \Omega^{-1} e \\ \lambda^* = \frac{1}{\sigma} \sqrt{\tilde{\mu}^T \Omega^{-1} \tilde{\mu}} \end{cases}$$

- On rappelle que

$$\begin{cases} \mathbb{E}[V_1(a_0, a_1)] = (v - w_a^T e)(1 + r) + w_a^T \mu \\ \text{Var}[V_1(a_0, a_1)] = w_a^T \Omega w_a \end{cases}$$

# Relation moyenne variance

- En notant  $V_1(\lambda) = V_1(a_0^*(\lambda), a^*(\lambda))$

## Expression de la moyenne et de la variance

$$\begin{cases} \mathbb{E}[V_1(\lambda^*)] = v(1+r) + w_a^T \tilde{\mu} = v(1+r) + \frac{1}{\lambda^*} \tilde{\mu}^T \Omega^{-1} \tilde{\mu} \\ \text{Var}[V_1(\lambda^*)] = \sigma^2 = \frac{1}{(\lambda^*)^2} \tilde{\mu}^T \Omega^{-1} \tilde{\mu} \end{cases}$$

- Avec  $\frac{1}{\lambda^*} \tilde{\mu}^T \Omega^{-1} \tilde{\mu} = \sqrt{\tilde{\mu}^T \Omega^{-1} \tilde{\mu}} \sqrt{\frac{1}{(\lambda^*)^2} \tilde{\mu}^T \Omega^{-1} \tilde{\mu}} = \sqrt{\tilde{\mu}^T \Omega^{-1} \tilde{\mu}} \sqrt{\text{Var}[V_1(\lambda^*)]}$
- L'équation moyenne écart-type des portefeuilles optimaux est:

## Lien moyenne/écart-type pour les portefeuilles optimaux

$$\mathbb{E}[V_1(\lambda^*)] = v(1+r) + \sqrt{\text{Var}[V_1(\lambda^*)]} (\tilde{\mu}^T \Omega^{-1} \tilde{\mu})^{\frac{1}{2}} \quad (3)$$

# Portefeuille optimal sans risque

- On dénote un portefeuille par  $P = \begin{pmatrix} a_0 \\ a \end{pmatrix} \in \mathbb{R}^{N+1}$  de sorte que  $V_0(a_0, a) = v$
- On note  $P^0 := \begin{pmatrix} 1 \\ 0_{\mathbb{R}^N} \end{pmatrix}$ , donc un investisseur purement risquophobe ( qui se fixe  $\sigma^2 = 0$  ou de façon équivalente  $\lambda = +\infty$ ) compose son portefeuille avec la répartition optimale  $a_0 = v$  et  $a = 0$  i.e il choisit le portefeuille  $v.P^0$

# Portefeuille optimal risqué

- On cherche de façon analogue un portefeuille optimal qui serait composé uniquement d'actifs risqués i.e on cherche un  $\lambda^*$  tel que  $a_0^*(\lambda^*) = 0$
- On rappelle que  $a_0^*(\lambda^*) = v - \frac{1}{\lambda^*} \tilde{\mu}^T \Omega^{-1} e$ , donc il suffit de prendre  $\lambda^* = \frac{\tilde{\mu}^T \Omega^{-1} e}{v}$  et on a donc  $a^*(\lambda^*) = \frac{v}{\tilde{\mu}^T \Omega^{-1} e} \text{diag}(p(0))^{-1} \Omega^{-1} \tilde{\mu}$ .
- Le portefeuille d'un tel investisseur serait  $\frac{v}{\tilde{\mu}^T \Omega^{-1} e} P^*$  où

$$P^* := \begin{pmatrix} 0 \\ \text{diag}(p(0))^{-1} \Omega^{-1} \tilde{\mu} \end{pmatrix}$$



# Base de portefeuilles optimaux

optimaux

- Pour une aversion au risque  $\lambda^*$  fixée, le portefeuille optimal s'écrit:

$$\begin{aligned}
 P(\lambda^*) &= \begin{pmatrix} a_0^*(\lambda^*) \\ a^*(\lambda^*) \end{pmatrix} = \begin{pmatrix} v - \frac{1}{\lambda^*} \tilde{\mu}^T \Omega^{-1} e \\ \frac{1}{\lambda^*} \text{diag}(p(0))^{-1} \Omega^{-1} \tilde{\mu} \end{pmatrix} \\
 &= \begin{pmatrix} v - \frac{1}{\lambda^*} \tilde{\mu}^T \Omega^{-1} e \\ 0 \end{pmatrix} + \begin{pmatrix} 0 \\ \frac{1}{\lambda^*} \text{diag}(p(0))^{-1} \Omega^{-1} \tilde{\mu} \end{pmatrix} \\
 &= (v - \frac{1}{\lambda^*} \tilde{\mu}^T \Omega^{-1} e) P^0 + \frac{1}{\lambda^*} P^* \\
 &= \alpha_0(\lambda^*) P^0 + \alpha^*(\lambda^*) P^*
 \end{aligned}$$

Où

$$\begin{cases} \alpha_0(\lambda^*) = (v - \frac{1}{\lambda^*} \tilde{\mu}^T \Omega^{-1} e) \\ \alpha^*(\lambda^*) = \frac{1}{\lambda^*} \end{cases}$$

# Outils

- Librairie `Wallstreet` pour l'extraction de données financières
- Librairie `Pandas` pour la manipulation des données
- Librairie `Numpy` pour le calcul scientifique/matriciel
- Librairie `Matplotlib` pour la visualisation graphique de la solution
- Utilisation des classes pour la modélisation des portefeuilles et des paramètres de marché

# Résultats graphiques

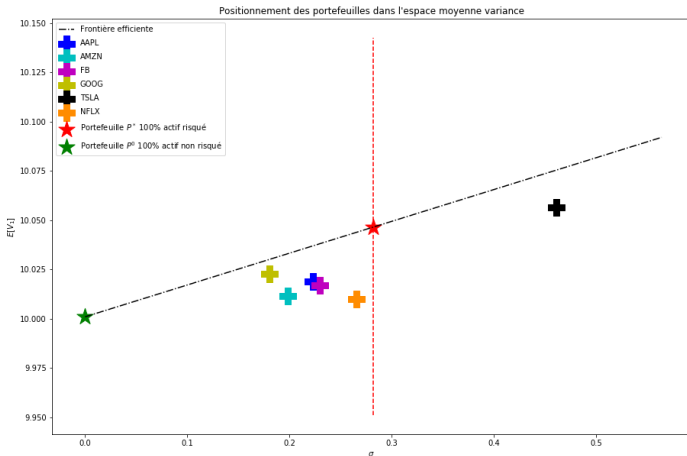


Figure: Comparaison des portefeuilles

- 1 Introduction
- 2 Problème de Markovitz
  - Hypothèses sur le marché
  - Modélisation
  - Optimisation moyenne-variance
- 3 Optimisation sous contraintes
  - Cas général
  - Cas convexe
- 4 Résolution du problème
  - Expression de la solution
  - Partie Python
  - Graphiques obtenus
- 5 Investissement socialement responsable
- 6 Annexe

# Proposition de régulation

- On suppose que les  $N$  entreprises du marché ont une note  $G_i \in [0, 10]$  qu'on regroupe dans le vecteur  $G$
- La note globale d'un portefeuille  $P = \begin{pmatrix} a_0 \\ a \end{pmatrix}$  est obtenue par

$$g_P = w_P^T G$$

où  $w_P = \frac{1}{V_0(a_0, a)} w_a$  le vecteur des poids de chaque action.

- On récompense les portefeuilles socialement responsables par une prime proportionnelle à leur investissement initial et valant

$$\beta(g_P - 5)V_0(a_0, a)$$

Où  $\beta > 0$  est une **prime de gain relative au montant investi** imposée par l'autorité des marchés financiers.

- Ainsi le gain moyen réel du portefeuille  $P$  est égal à

$$\mathbb{E}[V_1(a_0, a)] + \beta(g_P - 5)V_0(a_0, a)$$

# Analogie avec les résultats précédents

- On cherche à trouver les couples  $(a_0, a)$  qui résolvent :

## Problème de Markowitz généralisé

$$\begin{aligned} \max_{a_0, a} \quad & \mathbb{E}[V_1(a_0, a)] + \beta(g_P - 5)V_0(a_0, a) \\ \text{sous} \quad & \text{Var}[V_1(a_0, a)] \leq \sigma^2 \\ & V_0(a_0, a) = v \end{aligned} \quad (4)$$

- Ce qui est équivalent au problème que l'on sait résoudre :

## Problème d'optimisation équivalent

$$\begin{aligned} \max_{w_a \in \mathbb{R}^N} \quad & w_a^T \hat{\mu} \\ \text{sous} \quad & w_a^T \Omega w_a \leq \sigma^2 \end{aligned} \quad (5)$$

Où  $\hat{\mu} = \mu - (1 + r)e + \beta G$

- 1 Introduction
- 2 Problème de Markovitz
  - Hypothèses sur le marché
  - Modélisation
  - Optimisation moyenne-variance
- 3 Optimisation sous contraintes
  - Cas général
  - Cas convexe
- 4 Résolution du problème
  - Expression de la solution
  - Partie Python
  - Graphiques obtenus
- 5 Investissement socialement responsable
- 6 Annexe

-  [Harry Markowitz Portfolio Selection, Journal of Finance, 1952, 7 \(1\), 77-91.](#)
-  [Stephen Boyd and Lieven Vandenberghe Convex Optimization, Cambridge University Press, March 2004.](#)
-  [Idris Kharroubi Gestion de Portefeuilles, Université Paris Dauphine](#)
-  [Estimation Statistique : Estimateurs Classiques \(Wikipedia\)](#)
-  [Overview Of Sustainable Finance , Official Website Of The European Union](#)



*Merci de votre attention*

```

import numpy as np
from math import sqrt
from wallstreet import Stock
import matplotlib.pyplot as plt

def data_retrieving(code_tickers):
    #Recherche des données des ticker à l'aide de Google Finance
    stocks = [Stock(code) for code in code_tickers]
    n_days_back = 365
    data_frames = [s.historical(days_back=n_days_back , frequency='d') for s in stocks]
    market_data_frame = (data_frames[0][["Date"]]).copy()
    for code, df in zip(code_tickers, data_frames):
        market_data_frame[code] = df.Close
    data_frame = market_data_frame.set_index("Date")
    return data_frame

code_tickers = ["AAPL", "AMZN", "FB", "GOOG", "TSLA", "NFLX"]
market_data_frame = data_retrieving(code_tickers)

def statistical_estimation(market_data_frame):
    #Fonction pour estimer empiriquement la moyenne et les covariances du vecteur Y
    hist_y = (market_data_frame.copy()).iloc[:-1, :]
    for i in range(len(hist_y.index)):
        date = market_data_frame.index[i]
        next_date = market_data_frame.index[i+1]
        hist_y.loc[date] = market_data_frame.loc[next_date]/market_data_frame.loc[date]
    return hist_y.mean(), hist_y.cov()

class Market:
    #Classe regroupant les paramètres du marché
    def __init__(self, r, mu, omega, date):
        self.p0 = p0
        self.r = r
        self.mu = mu
        self.omega = omega

N = len(code_tickers)
p0 = market_data_frame.iloc[-1, :]
r = 0.0001
mu, omega = statistical_estimation(market_data_frame)
market = Market(r, mu, omega, p0)

class Portfolio:
    #Classe qui modélise le portefeuille

```

```

def __init__(self, a0, a, name=""):
    self.a0 = a0
    self.a = a
    self.name = name

def value(self, prices):
    s = 0
    for quantity, price in zip(self.composition, prices):
        s += quantity*price
    return s

def mean(self, market):
    wa = np.dot(np.diag(market.p0), self.a)
    return self.a0*(1+market.r) + np.dot(wa.transpose(), mu)

def variance(self, market):
    wa = np.dot(np.diag(market.p0), self.a)
    return np.dot(wa.transpose(), np.dot(market.omega, wa))

def optimal_portfolio(market, v, sigma):
    '''Renvoie un objet Portfolio avec la composition optimale pour
    les paramètres de marché et sigma donnés'''

    N = len(market.mu)
    mu_tilde = market.mu - (1+r)
    if sigma > 0:
        lambda_star = sqrt(np.dot(mu_tilde.transpose(),
            np.dot(np.linalg.inv(omega), mu_tilde)))/sigma
        wa = (1/lambda_star)*np.dot(np.linalg.inv(omega), mu_tilde)
        a = np.dot(np.linalg.inv(np.diag(market.p0)), wa)
        e = np.ones(N)
        a0 = v - np.dot(wa.transpose(), e)
    else:
        a = np.zeros(N)
        a0 = v
    return Portfolio(a0, a)

def efficient_frontier(market, v, sigma_range):
    '''Calcul des moyennes efficaces pour une plage donnée
    de valeurs sigma'''
    efficient = []
    for sigma in sigma_range:
        portfolio = optimal_portfolio(market, v, sigma)
        efficient.append(portfolio.mean(market))
    return efficient

```

```

def plot_portfolios(v, market):
    #Traçage des portefeuilles dans l'espace variance-moyenne
    I = np.eye(N)
    unique_stock_portfolios = []
    for i,code in enumerate(code_tickers):
        a = (v/market.p0[i])*I[i,:]
        portfolio = Portfolio(0, a, code)
        unique_stock_portfolios.append(portfolio)

    min_sigma = 0
    min_return = v*(1+market.r)
    mu_tilde = market.mu - (1+market.r)
    e = np.ones(len(market.mu))
    sigma_star = v*sqrt(np.dot(mu_tilde.transpose(),
                                np.dot(np.linalg.inv(market.omega),
                                mu_tilde)))/np.dot(mu_tilde.transpose(),
                                np.dot(np.linalg.inv(market.omega), e))
    mean_star = optimal_portfolio(market, v, sigma_star).mean(market)

    fig, ax = plt.subplots(figsize=(15, 10))
    colors = ['b','c', 'm', 'y', 'k', 'darkorange']

    sigma_max = 0
    for i, portfolio in enumerate(unique_stock_portfolios):
        sigma = sqrt(portfolio.variance(market))
        if sigma > sigma_max:
            sigma_max = sigma
        mean = portfolio.mean(market)
        ax.scatter(sigma,max,marker="P",color=colors[i],s=500,
                    label=portfolio.name)
    #sigma_max = max(sigma_max, sigma_star)
    sigma_range = np.linspace(0, 2*sigma_star, num=10)
    means = efficient_frontier(market, v, sigma_range)
    ax.scatter(sigma_star,mean_star,marker='*',color='r',s=500,
                label='Portefeuille $P^*$ 100% actif risqué')
    ax.scatter(min_sigma,min_return,marker='*',color='g',s=500,
                label='Portefeuille $P^0$ 100% actif non risqué')
    ax.vlines(sigma_star, 0.995*min(means), 1.005*max(means),
                colors='r', linestyle='dashed')
    ax.plot(sigma_range, means, linestyle='-.', color='black',
            label='Frontière efficiente')
    ax.set_title("Positionnement des portefeuilles dans l'espace moyenne variance")
    ax.set_xlabel('$\sigma$')
    ax.set_ylabel('$E[V_1]$')
    ax.legend(labelspace=0.8)

```

```
plt.savefig("plot.png")  
  
v = 10  
plot_portfolios(v, market)
```