

**Profesores:** Fernando Ordoñez, Daniel Espinoza  
**Auxiliar:** Renaud Chicoisne  
**Semestre:** Otoño 2012

## IN7K2 Optimización bajo Incertidumbre Control N<sup>o</sup>1

### P1

Considere el problema de optimización de portafolio

$$\begin{aligned}
 (P_\alpha) \quad \vartheta = \quad & \min \quad f(x) = \text{Var}(\mathbf{r}^T x) \\
 & \text{s.t.} \quad g(x) = \mathbb{E}(\mathbf{r}^T x) \geq \alpha \\
 & \sum_{i=1}^n x_i \leq 1 \\
 & x \in \mathbb{R}_+^n
 \end{aligned} \tag{1}$$

donde  $x_i$  corresponde la fracción de la riqueza que se invierte en el activo  $i$  que tiene rentabilidad  $r_i$ , para  $i = 1, \dots, n$ . Suponemos además que las rentabilidades futuras  $\mathbf{r} \sim \mathcal{N}(\mu, \Sigma)$ , pero de parámetros  $\mu, \Sigma$  desconocidos. Asuma que, sin embargo, es posible generar muestras iid de cualquier tamaño para  $\mathbf{r}$ .

1. Escriba una versión sampleada ( $\hat{P}_{N,\alpha}$ ) del problema (1), y demuestre (invocando alguno de los teoremas visto en clases) que  $\hat{\vartheta}_N \xrightarrow[N \rightarrow \infty]{} \vartheta$ .

**Solución:**

Una versión sampleada puede ser formulada como sigue:

$$\begin{aligned}
 (\hat{P}_{N,\alpha}) \quad \hat{\vartheta}_N = \quad & \min \quad \hat{f}_N(x) = \frac{1}{N-1} \sum_{i=1}^N \left( x^\top r^i - \frac{1}{N} \sum_{j=1}^N x^\top r^j \right)^2 \\
 & \text{s.t.} \quad \hat{g}_N(x) = \frac{1}{N} \sum_{i=1}^N x^\top r^i \geq \alpha \\
 & e^\top x \leq 1 \\
 & x \in \mathbb{R}_+^n
 \end{aligned} \tag{2}$$

- (a) Si supongamos que  $(P_\alpha)$  es factible, entonces podemos asumir que el conjunto  $S$  de soluciones óptimas de  $(P_\alpha)$  es no vacío.
- (b)  $X$  es acotado dado que  $x_i \in [0, 1], \forall i = 1, \dots, n$ .
- (c) Mostramos que  $X$  es cerrado. Sea  $x^p \in X^{\mathbb{N}}$  tal que  $\exists x \in \mathbb{R}^n : x^p \xrightarrow[p \rightarrow +\infty]{} x$ . Mostremos que  $x \in X$ . Tenemos:

$$\mathbb{E}[\mathbf{r}^\top x_p] - \mathbb{E}[\mathbf{r}^\top x] \geq \alpha - \mathbb{E}[\mathbf{r}^\top x]$$

Por continuidad de  $g : x \mapsto \mathbb{E}[\mathbf{r}^\top x]$  y porque  $x^p \xrightarrow{p \rightarrow +\infty} x$  obtenemos:

$$\begin{aligned} \mathbb{E}[\mathbf{r}^\top x_p] - \mathbb{E}[\mathbf{r}^\top x] &\xrightarrow{p \rightarrow +\infty} 0 \\ \Rightarrow \mathbb{E}[\mathbf{r}^\top x] &\geq \alpha \end{aligned}$$

De manera trivial tenemos tambien que:

$$\sum_{i=1}^n x_i \leq 1$$

Por lo tanto, cualquier serie convergente de elementos de  $X$  tiene su limite en  $X$  tambien,

ie:  $X$  es cerrado.

- (d) De los dos puntos anteriores se deduce que  $X$  es compacto.
- (e) Por lo tanto  $\hat{f}_N$  converge uniformemente a  $f$  sobre  $X$ .
- (f)  $f$  es continua a valores reales sobre  $X$ .
- (g) El dominio determinista de  $X$  es compacto, y suposimos que  $X \neq \emptyset$ , por lo tanto  $\vartheta > -\infty$  y entonces  $S \neq \emptyset$ .
- (h)  $\hat{S}_N$  está incluido en su dominio determinista que es compacto.
- (i) Supongamos  $P_\alpha$  estrictamente factible, ie:

$$\begin{aligned} \exists \bar{x} \in X : \mathbb{E}[\mathbf{r}\bar{x}] &> \alpha \\ \text{ie: } \exists \bar{x} \in X : \mathbb{E}[\mathbf{r}\bar{x}] &\geq \alpha + \varepsilon \text{ con } \varepsilon > 0 \end{aligned}$$

Para  $N$  suficientemente grande sabemos que:

$$\begin{aligned} \mathbb{P} \left[ g(\bar{x}) \leq \hat{g}_N(\bar{x}) + z_\beta \frac{1}{\sqrt{N}} \sqrt{\hat{f}_N(\bar{x})} \right] &\geq 1 - \beta \\ \Rightarrow \mathbb{P} \left[ \alpha + \varepsilon - z_\beta \frac{1}{\sqrt{N}} \sqrt{\hat{f}_N(\bar{x})} \leq \hat{g}_N(\bar{x}) \right] &\geq 1 - \beta \end{aligned}$$

Sea  $N$  suficientemente grande para que:

$$\varepsilon \geq z_\beta \frac{1}{\sqrt{N}} \sqrt{\hat{f}_N(\bar{x})}$$

Entonces:

$$\Rightarrow \mathbb{P}[\alpha \leq \hat{g}_N(\bar{x})] \geq 1 - \beta$$

Por lo tanto con alta probabilidad  $X_N \neq \emptyset$ , entonces  $\hat{S}_N \neq \emptyset$ .

- (j) Demostramos que cualquier serie convergente  $x_N \in X_N$  tiene su limite  $x \in X$ . Tenemos:

$$\begin{aligned} \alpha - g(x) &\leq g_N(x_N) - g(x) \\ &\leq |g_N(x_N) - g(x)| \\ &\leq |g(x) - g(x_N)| + |g(x_N) - g_N(x_N)| \end{aligned}$$

Además, sabemos que  $g$  es continua sobre  $\mathbb{R}^n$  y que  $x_N \xrightarrow{N \rightarrow +\infty} x$  casi seguramente, por lo tanto:

$$|g(x) - g(x_N)| \xrightarrow[N \rightarrow +\infty]{} 0$$

Por la Ley de los Grandes Números sabemos que  $\hat{g}_N$  converge a  $g$  uniformemente en una vecindad de  $x$ , por lo tanto existe una esfera centrada en  $x$  y de radio  $\mu > 0$  tal que  $\hat{g}_N$  converge a  $g$  uniformemente en  $\mathcal{B}(x, \mu)$ .

Además:

$$\begin{aligned} x_N &\xrightarrow[N \rightarrow +\infty]{} x \text{ casi seguramente} \\ \text{ie: } \forall \varepsilon > 0, \exists N_\varepsilon : \forall N > N_\varepsilon, |x_N - x| \leq \varepsilon \\ &\Rightarrow \exists N_\mu : \forall N > N_\mu, |x_N - x| \leq \mu \\ \text{ie: } \exists N_\mu : \forall N > N_\mu, x \in \mathcal{B}(x, \mu) \end{aligned}$$

Por lo tanto:

$$|g(x_N) - g_N(x_N)| \xrightarrow[N \rightarrow +\infty]{} 0$$

En consecuencia:

$$\begin{aligned} g(x) &\geq \alpha \\ \text{ie: } x &\in X \end{aligned}$$

El teorema 5.5 nos asegura entonces que:

$$\hat{\vartheta}_N \xrightarrow[N \rightarrow \infty]{} \vartheta$$

2. Asumiendo que para todo punto factible  $x \in X$ , hay una secuencia de puntos  $x_N \in X_N$  factibles para  $(\hat{P}_{N,\alpha})$  tal que  $x_N \xrightarrow[N \rightarrow \infty]{} x$  con probabilidad uno, y sabiendo que (por definición)  $\hat{\vartheta}_N \leq \hat{f}_N(x_N), \forall x_N \in X_N$  demuestre que

$$\limsup_{N \rightarrow \infty} \hat{\vartheta}_N \leq \vartheta$$

**Solución:**

Por definición tenemos:

$$\hat{\vartheta}_N \leq \hat{f}_N(x_N), \forall x_N \in X_N$$

Entonces cuando  $N \rightarrow +\infty$ :

$$\limsup_{N \rightarrow \infty} \hat{\vartheta}_N \leq \lim_{N \rightarrow \infty} \hat{f}_N(x_N)$$

Y tenemos convergencia uniforme de  $\hat{f}_N$  a  $f$ , convergencia casi segura de  $x_N$  a  $x$ , y continuidad de  $f(\cdot)$ , por lo tanto tenemos:

$$\begin{aligned} \lim_{N \rightarrow \infty} \hat{f}_N(x_N) &= f(x) \\ \Rightarrow \limsup_{N \rightarrow \infty} \hat{\vartheta}_N &\leq f(x) \end{aligned}$$

En particular para  $x = \arg \min_{x' \in X} f(x')$

$$\limsup_{N \rightarrow \infty} \hat{\vartheta}_N \leq \vartheta$$

3. Construya un intervalo de confianza (i.e. cotas superiores e inferiores) que contenga  $\vartheta$  con alta probabilidad, dependiendo del resultado de  $k$  repeticiones independientes del experimento  $(\hat{P}_{N,\alpha})$ , y asumiendo que conoce una muestra independiente  $\{r^i\}_{i=1}^{N'}$  para algún  $N' \gg N$ . ¿Puede ocurrir que la cota superior resultante sea  $\infty$ ?

**Solución:**

(a) Primero sabemos que:

$$\vartheta \geq \mathbb{E}[\hat{\vartheta}_N]$$

Podemos estimar  $\mathbb{E}[\hat{\vartheta}_N]$  como el promedio de todos los valores óptimos obtenidos con los  $k$  experimentos efectuados:

$$\hat{u}_{N,k} = \frac{1}{k} \sum_{i=1}^k \hat{\vartheta}_N^i$$

es un estimador insesgado de  $\mathbb{E}[\hat{\vartheta}_N]$ . Además, por independencia de los experimentos tenemos:

$$\begin{aligned} \text{Var}[\hat{u}_{N,k}] &= \hat{\sigma}_{N,k}^2 = \frac{1}{k} \text{Var}[\hat{\vartheta}_N] \\ &= \frac{1}{k(k-1)} \sum_{i=1}^k (\hat{\vartheta}_N^i - \hat{u}_{N,k})^2 \end{aligned}$$

El teorema central limite nos dice que  $\hat{u}_{N,k}$  se vuelve aproximadamente normal con  $k$  grande. Por lo tanto se puede ocupar:

$$L_{N,k} = \hat{u}_{N,k} - t_{\varepsilon,k-1} \hat{\sigma}_{N,k}$$

Como cota inferior de  $\mathbb{E}[\hat{\vartheta}_N]$  con nivel de confianza  $(1 - \varepsilon)$ . Con  $t_{\varepsilon,k-1}$  el  $\varepsilon$ -valor crítico de una  $t$ -distribución con  $k - 1$  grados de libertad. Por lo tanto:

$$\mathbb{P}[\hat{u}_{N,k} - t_{\varepsilon,k-1} \hat{\sigma}_{N,k} \leq \vartheta] \geq 1 - \varepsilon$$

(b) Sea  $\bar{x} \in \mathbb{R}^n$ .

Si  $\bar{x} \in X$  sabemos que:

$$\vartheta \leq f(\bar{x})$$

Uno puede estimar la varianza de  $\hat{f}_{N'}(\bar{x})$  por el estimador:

$$\hat{\sigma}_{N'}^2 = \frac{1}{N'(N'-1)} \sum_{i=1}^{N'} (\bar{x}^\top r^i - \hat{f}_{N'}(\bar{x}))^2$$

El teorema central limite nos dice que  $\hat{f}_{N'}(\bar{x})$  se vuelve aproximadamente normal con  $N'$  grande. Por lo tanto se puede ocupar:

$$U_{N'}(\bar{x}) = \hat{f}_{N'}(\bar{x}) + z_\varepsilon \hat{\sigma}_{N'}(\bar{x})$$

Como cota superior de  $f(\bar{x})$  con nivel de confianza  $(1 - \varepsilon)$ . Con  $z_\varepsilon$  el  $\varepsilon$ -valor crítico de una distribución normal. Por lo tanto:

$$\mathbb{P}[\hat{f}_{N'}(\bar{x}) + z_\varepsilon \hat{\sigma}_{N'}(\bar{x}) \leq f(\bar{x})] \geq 1 - \varepsilon$$

Ahora, este resultado vale solamente para  $\bar{x} \in X$ . Queremos encontrar con que probabilidad  $\bar{x}$  es factible para  $(P_\alpha)$ . Primero sabemos que:

$$\mathbb{E}[\hat{g}_N(\bar{x})] = g(\bar{x})$$

Sea  $\tilde{u}_{N,k}(\bar{x})$  un estimador de la media de  $\hat{g}_N(\bar{x})$ :

$$\tilde{u}_{N,k}(\bar{x}) = \frac{1}{k} \sum_{i=1}^k \hat{g}_{N,i}(\bar{x})$$

Sea  $\tilde{\sigma}_{N,k}^2$  un estimador de la varianza de  $\hat{g}_N(\bar{x})$ :

$$\tilde{\sigma}_{N,k}^2(\bar{x}) = \frac{1}{k(k-1)} \sum_{i=1}^k (\tilde{u}_{N,k}(\bar{x}) - \hat{g}_{N,i}(\bar{x}))^2$$

El teorema central limite nos dice que  $\hat{g}_N(\bar{x})$  se vuelve aproximadamente normal con  $N$  grande. Por lo tanto se puede ocupar:

$$\tilde{L}_{N,k}(\bar{x}) = \tilde{u}_{N,k}(\bar{x}) + t_{\beta,k-1} \tilde{\sigma}_{N,k}(\bar{x})$$

Como cota inferior de  $g(\bar{x})$  con nivel de confianza  $(1 - \beta)$ . Con  $t_{\beta,k-1}$  el  $\beta$ -valor crítico de una  $t$ -distribución con  $k - 1$  grados de libertad. Por lo tanto:

$$\mathbb{P} [\tilde{u}_{N,k}(\bar{x}) + t_{\beta,k-1} \tilde{\sigma}_{N,k}(\bar{x}) \leq g(\bar{x})] \geq 1 - \beta$$

ie: si encontramos algún  $\bar{x} \in \mathbb{R}^n$  tal que:

$$\alpha \leq \tilde{u}_{N,k}(\bar{x}) + t_{\beta,k-1} \tilde{\sigma}_{N,k}(\bar{x})$$

Sabemos que:

$$U_{N'}(\bar{x}) = \hat{f}_{N'}(\bar{x}) + z_\varepsilon \hat{\sigma}_{N'}(\bar{x})$$

es cota superior de  $\vartheta$  con probabilidad  $(1 - \varepsilon)(1 - \beta)$ .

En la practica, buscaríamos alguna solución óptima de alguno de los problemas sampleados por la cual averiguaríamos si  $L_{N,k}(\bar{x}) \geq \alpha$ .

Si no existe un tal  $\bar{x}$ , la única cota que podemos tener es  $+\infty$ .

4. Suponga que conoce  $\sigma \geq \text{Var}(\mathbf{r}^\top x)$  para todo  $x$  en el dominio determinista del problema (i.e. sin considerar la restriccion en esperanza), cual es el  $\delta > 0$  mas pequeño que asegura que  $\hat{x}_{N,\alpha+\delta}^*$  (i.e. la solución óptima de  $(\hat{P}_{N,\alpha+\delta})$ ) sea factible para  $P_\alpha$  con probabilidad al menos 95%. ¿Qué cotas superiores se pueden derivar del resultado anterior?

**Solución:**

Sabemos que :

$$\mathbb{E} [\hat{g}_N(x_{N,\alpha+\delta}^*)] = g(x_{N,\alpha+\delta}^*)$$

Por el teorema central límite uno puede estimar la varianza de  $\mathbb{E} [\hat{g}_N(x_{N,\alpha+\delta}^*)]$  con  $\frac{1}{N} \hat{f}_N(x_{N,\alpha+\delta}^*)$ .

Por lo tanto una cota inferior con seguridad  $(1 - \beta)$  de  $g(x_{N,\alpha+\delta}^*)$  es:

$$\begin{aligned} L_N(x_{N,\alpha+\delta}^*) &= \hat{g}_N(x_{N,\alpha+\delta}^*) - \frac{1}{N} t_{\beta,N-1} \hat{f}_N(x_{N,\alpha+\delta}^*) \\ &= \hat{g}_N(x_{N,\alpha+\delta}^*) - \frac{1}{N} t_{\beta,N-1} \hat{\vartheta}_N \\ &\geq \alpha + \delta - \frac{1}{N} t_{\beta,N-1} \vartheta \\ &\geq \alpha + \delta - \frac{1}{N} t_{\beta,N-1} \sigma \end{aligned}$$

En consecuencia con seguridad  $(1 - \beta)$  tenemos:

$$g(x_{N,\alpha+\delta}^*) \geq L_N(x_{N,\alpha+\delta}^*) \geq \alpha + \delta - \frac{1}{N} t_{\beta,N-1} \sigma$$

Por lo tanto el  $\delta$  más chico que podemos encontrar con esta mayoración tal que  $x_{N,\alpha+\delta}^*$  sea factible para  $(P_\alpha)$  con probabilidad al menos  $(1 - \beta)$  es:

$$\delta = \frac{1}{N} t_{\beta,N-1} \sigma$$

Tenemos:

$$\mathbb{P} \left[ \hat{x}_{N, \alpha + \frac{1}{N} t_{\beta, N-1} \sigma}^* \in X \right] \geq 1 - \beta$$

Por lo tanto:

$$\mathbb{P} \left[ \vartheta \leq f \left( \hat{x}_{N, \alpha + \frac{1}{N} t_{\beta, N-1} \sigma}^* \right) \right] \geq 1 - \beta$$

De la pregunta anterior, imponiendo  $\bar{x} = \hat{x}_{N, \alpha + \frac{1}{N} t_{\beta, N-1} \sigma}^*$  se obtiene una cota superior con probabilidad al menos  $(1 - \varepsilon)(1 - \beta)$ .

## P2

Considere el siguiente problema estocástico con  $x \in \mathbb{R}$ :

$$\begin{aligned} \min_x \quad & \frac{1}{2}x + \sum_{i=1}^S p_i Q(x, \xi^i) \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned} \quad (3)$$

Supondremos que este problema tiene tres escenarios equiprobables con  $\xi^1 = 1$ ,  $\xi^2 = 2$ , y  $\xi^3 = 4$ .

1. En el caso en que  $Q(x, \xi) = |x - \xi|$ , resuelva este problema usando el algoritmo de Benders. Para esto, indique la forma del subproblema de generación de cortes; escriba el maestro al comienzo de cada iteración; y los cortes generados. Resuelva los problemas lineales por inspección.

### Solución

El problema maestro es:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x + \frac{1}{3} \sum_{i=1}^3 \gamma^i \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

y cada subproblema esta representado por su valor óptimo

$$Q(x, \xi^i) = |x - \xi^i| = \begin{cases} x - \xi^i & \text{si } x \in [0, \xi^i] \\ \xi^i - x & \text{si } x \in [\xi^i, 10] \end{cases}$$

Se puede representar  $Q(x, \xi^i)$  como el mínimo de un problema de programación lineal:

$$\begin{aligned} Q(x, \xi^i) = \min_y \quad & y \\ \text{s.t.} \quad & x - \xi^i \leq y \\ & \xi^i - x \leq y \end{aligned}$$

ie:

$$\begin{aligned} Q(x, \xi^i) = \max_z \quad & z_1(x - \xi^i) + z_2(\xi^i - x) \\ \text{s.t.} \quad & z_1 + z_2 = 1 \\ & z_1, z_2 \geq 0 \end{aligned}$$

*Iteración 1:* La solución óptima del problema maestro es:

$$(\bar{x}, \bar{\gamma}^1, \bar{\gamma}^2, \bar{\gamma}^3) = (0, -\infty, -\infty, -\infty).$$

Cada subproblema entrega una solución óptima de valor:

$$Q(x=0, \xi^1=1) = 1 > \bar{\gamma}^1 = -\infty . \text{Con } z^1 = (0, 1)$$

$$Q(x=0, \xi^2=2) = 2 > \bar{\gamma}^2 = -\infty . \text{Con } z^2 = (0, 1)$$

$$Q(x=0, \xi^3=4) = 4 > \bar{\gamma}^3 = -\infty . \text{Con } z^3 = (0, 1)$$

Por lo tanto se tienen que agregar cortes de optimalidad para cada uno de los subproblemas:

$$z_1^i(x - \xi^i) + z_2^i(\xi^i - x) \leq \gamma^i, i = 1, 2, 3$$

ie:

$$1 - x \leq \gamma^1$$

$$2 - x \leq \gamma^2$$

$$4 - x \leq \gamma^3$$

*Iteración 2:* El problema maestro es:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x + \frac{1}{3} \sum_{i=1}^3 \gamma^i \\ \text{s.t.} \quad & 0 \leq x \leq 10 \\ & 1 - x \leq \gamma^1 \\ & 2 - x \leq \gamma^2 \\ & 4 - x \leq \gamma^3 \end{aligned}$$

Cuya solución óptima es:

$$(\bar{x}, \bar{\gamma}^1, \bar{\gamma}^2, \bar{\gamma}^3) = (10, -9, -8, -6).$$

Cada subproblema entrega una solución óptima de valor:

$$Q(x=10, \xi^1=1) = 9 > \bar{\gamma}^1 = -9 . \text{Con } z^1 = (1, 0)$$

$$Q(x=10, \xi^2=2) = 8 > \bar{\gamma}^2 = -8 . \text{Con } z^2 = (1, 0)$$

$$Q(x=10, \xi^3=4) = 6 > \bar{\gamma}^3 = -6 . \text{Con } z^3 = (1, 0)$$

Por lo tanto se tienen que agregar cortes de optimalidad para cada uno de los subproblemas:

$$z_1^i(x - \xi^i) + z_2^i(\xi^i - x) \leq \gamma^i, i = 1, 2, 3$$

ie:

$$x - 1 \leq \gamma^1$$

$$x - 2 \leq \gamma^2$$

$$x - 4 \leq \gamma^3$$

*Iteración 3:* El problema maestro es:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x + \frac{1}{3} \sum_{i=1}^3 \gamma^i \\ \text{s.t.} \quad & 0 \leq x \leq 10 \\ & 1 - x \leq \gamma^1 \\ & 2 - x \leq \gamma^2 \\ & 4 - x \leq \gamma^3 \\ & x - 1 \leq \gamma^1 \\ & x - 2 \leq \gamma^2 \\ & x - 4 \leq \gamma^3 \end{aligned}$$

Cuya solución óptima es:

$$(\bar{x}, \bar{\gamma}^1, \bar{\gamma}^2, \bar{\gamma}^3) = (1, 0, 1, 3).$$

Cada subproblema entrega una solución óptima de valor:

$$\begin{aligned} Q(x=1, \xi^1=1) &= 0 = \bar{\gamma}^1 \\ Q(x=1, \xi^2=2) &= 1 = \bar{\gamma}^2 \\ Q(x=1, \xi^3=4) &= 3 = \bar{\gamma}^3 \end{aligned}$$

Por lo tanto la solución actual es factible y óptima con  $\bar{x} = 1$ .

2. En el caso en que  $Q(x, \xi) = -x + \frac{1}{2}\xi x^2$ , haga dos iteraciones del algoritmo de progressive hedging con  $\rho = \frac{1}{2}$  y empezando con el multiplicador de lagrange  $W^0 = 0$ .

**Solución**

Aquí estamos aplicando el algoritmo de progressive hedging con un único periodo de tiempo.

*Inicialización:* Sean los  $x^0(s)$  las soluciones óptimas de:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x + Q(x, \xi^s) \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

ie:  $x^0(1) = \frac{1}{2}, x^0(2) = \frac{1}{4}, x^0(3) = \frac{1}{8}$ . Y empezamos con  $W^0 = 0$ .

*Iteración 1:*

Construyamos la solución no anticipativa  $\hat{x}^0$  derivada de  $x^0$ :

$$\hat{x}^0 = \frac{1}{\sum_{s \in S} p_s} \sum_{s \in S} p_s x^0(s) = \frac{7}{24}$$

Resolvemos el siguiente problema para cada escenario:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x + Q(x, \xi^s) + x \cdot W^0(s) + \frac{\rho}{2} |x - \hat{x}^0(s)|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^1(s)$ . ie:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}x^2 + \frac{1}{4} |x - \frac{7}{24}|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^1(1) = \frac{31}{72}$ .

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}2x^2 + \frac{1}{4} |x - \frac{7}{24}|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^1(2) = \frac{31}{120}$ .

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}4x^2 + \frac{1}{4} |x - \frac{7}{24}|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^1(3) = \frac{31}{216}$ .

Actualizamos el (los) multiplicadores:

$$W^1 = W^0 + \rho K x^1$$

Con:

$$W^0 = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

$$K = \begin{bmatrix} \frac{2}{3} & -\frac{1}{3} & -\frac{1}{3} \\ -\frac{1}{3} & \frac{2}{3} & -\frac{1}{3} \\ -\frac{1}{3} & -\frac{1}{3} & \frac{2}{3} \end{bmatrix}$$

$$x^1 = \begin{bmatrix} \frac{31}{72} \\ \frac{31}{120} \\ \frac{31}{216} \end{bmatrix}$$

Por lo tanto:

$$W^1 = \begin{bmatrix} \frac{1147}{15120} \\ -\frac{31}{3240} \\ -\frac{217}{3240} \end{bmatrix}$$

*Iteración 2:*

Construyemos la solución no anticipativa  $\hat{x}^1$  derivada de  $x^1$ :

$$\hat{x}^1(s) = \frac{1}{\sum_{s' \in S} p_{s'}} \sum_{s' \in S} p_{s'} x^1(s') = \frac{899}{3240}$$

Resolvemos el siguiente problema para cada escenario:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x + Q(x, \xi^s) + x \cdot W^1(s) + \frac{\rho}{2} |x - \hat{x}^1(s)|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^2(s)$ . i.e.:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}x^2 + \frac{1147}{15120}x + \frac{1}{4} |x - \frac{31}{72}|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^2(1) = \frac{2417}{5670}$ .

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}2x^2 - \frac{31}{3240}x + \frac{1}{4} |x - \frac{31}{120}|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^2(2) = \frac{4139}{16200}$ .

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}4x^2 - \frac{217}{3240}x + \frac{1}{4} |x - \frac{31}{216}|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^2(3) = \frac{4139}{29160}$ .

Actualizamos el (los) multiplicadores:

$$W^2 = W^1 + \rho K x^2$$

Con:

$$W^1 = \begin{bmatrix} \frac{1147}{15120} \\ -\frac{3240}{217} \\ -\frac{3240}{3240} \end{bmatrix}$$

$$K = \begin{bmatrix} \frac{2}{3} & -\frac{1}{3} & -\frac{1}{3} \\ -\frac{1}{3} & \frac{2}{3} & -\frac{1}{3} \\ -\frac{1}{3} & -\frac{1}{3} & \frac{2}{3} \end{bmatrix}$$

$$x^2 = \begin{bmatrix} \frac{2417}{5670} \\ \frac{4139}{16200} \\ \frac{4139}{29160} \end{bmatrix}$$

Por lo tanto:

$$W^2 = \begin{bmatrix} \frac{132719}{874800} \\ -\frac{64936813}{1653372000} \\ -\frac{816217}{6123600} \end{bmatrix}$$

XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX

*Inicialización:* Sean los  $x^0(s)$  las soluciones óptimas de:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x + Q(x, \xi^s) \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

ie:  $x^0(1) = \frac{1}{2}$ ,  $x^0(2) = \frac{1}{4}$ ,  $x^0(3) = \frac{1}{8}$ . Y empezamos con  $W^0 = 0$ .

*Iteración 1:*

Construyemos la solución no anticipativa  $\hat{x}^0$  derivada de  $x^0$ :

$$\hat{x}^0 = \frac{1}{\sum_{s \in S} p_s} \sum_{s \in S} p_s x^0(s) = \frac{7}{24}$$

Resolvemos el siguiente problema para cada escenario:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x + Q(x, \xi^s) + x \cdot W^0(s) + \frac{\rho}{2} |x - \hat{x}^0(s)|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^1(s)$ . ie:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}x^2 + \frac{1}{4} |x - \frac{7}{24}|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^1(1) = \frac{31}{72}$ .

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}2x^2 + \frac{1}{4}|x - \frac{7}{24}|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^1(2) = \frac{31}{120}$ .

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}4x^2 + \frac{1}{4}|x - \frac{7}{24}|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^1(3) = \frac{31}{216}$ .

Actualizamos el (los) multiplicadores:

$$W^1 = W^0 + \rho K x^1$$

Con:

$$W^0 = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

$$K = \begin{bmatrix} \frac{2}{3} & -\frac{1}{3} & -\frac{1}{3} \\ -\frac{1}{3} & \frac{2}{3} & -\frac{1}{3} \\ -\frac{1}{3} & -\frac{1}{3} & \frac{2}{3} \end{bmatrix}$$

$$x^1 = \begin{bmatrix} \frac{31}{72} \\ \frac{31}{120} \\ \frac{31}{216} \end{bmatrix}$$

Por lo tanto:

$$W^1 = \begin{bmatrix} \frac{1147}{15120} \\ -\frac{31}{3240} \\ -\frac{217}{3240} \end{bmatrix}$$

*Iteración 2:*

Construyemos la solución no anticipativa  $\hat{x}^1$  derivada de  $x^1$ :

$$\hat{x}^1(s) = \frac{1}{\sum_{s' \in S} p_{s'}} \sum_{s' \in S} p_{s'} x^1(s') = \frac{899}{3240}$$

Resolvemos el siguiente problema para cada escenario:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x + Q(x, \xi^s) + x \cdot W^1(s) + \frac{\rho}{2}|x - \hat{x}^1(s)|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^2(s)$ . i.e.:

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}x^2 + \frac{1147}{15120}x + \frac{1}{4}|x - \frac{31}{72}|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^2(1) = \frac{2417}{5670}$ .

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}2x^2 - \frac{31}{3240}x + \frac{1}{4}\left|x - \frac{31}{120}\right|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^2(2) = \frac{4139}{16200}$ .

$$\begin{aligned} \min_x \quad & \frac{1}{2}x - x + \frac{1}{2}4x^2 - \frac{217}{3240}x + \frac{1}{4}\left|x - \frac{31}{216}\right|^2 \\ \text{s.t.} \quad & 0 \leq x \leq 10 \end{aligned}$$

Cuya solución óptima es  $x^2(3) = \frac{4139}{29160}$ .

Actualizamos el (los) multiplicadores:

$$W^2 = W^1 + \rho K x^2$$

Con:

$$W^1 = \begin{bmatrix} \frac{1147}{15120} \\ -\frac{31}{3240} \\ -\frac{217}{3240} \end{bmatrix}$$

$$K = \begin{bmatrix} \frac{2}{3} & -\frac{1}{3} & -\frac{1}{3} \\ -\frac{1}{3} & \frac{2}{3} & -\frac{1}{3} \\ -\frac{1}{3} & -\frac{1}{3} & \frac{2}{3} \end{bmatrix}$$

$$x^2 = \begin{bmatrix} \frac{2417}{5670} \\ \frac{4139}{16200} \\ \frac{4139}{29160} \end{bmatrix}$$

Por lo tanto:

$$W^2 = \begin{bmatrix} \frac{132719}{874800} \\ -\frac{64936813}{1653372000} \\ -\frac{816217}{6123600} \end{bmatrix}$$

3. En el caso en que  $Q(x, \xi) = -x + \frac{1}{2}\xi x^2$ , haga dos iteraciones del stochastic approximation algorithm. Suponga que el muestreo de la incertidumbre le entrega la siguiente secuencia de escenarios: 2, 3, 1, 1, 3, 2, 2, 1, 2, 3, 3.

**Solución**

Partiendo de una solución factible  $x^0 = 0$  cada iteración del SAAI se hace de la forma siguiente:

$$x^{j+1} = \Pi_X(x^j - \gamma^j G(x^j, \xi^j))$$

Con:

- $X := \{x \in \mathbb{R} : 0 \leq x \leq 10\}$ .
- $\Pi$  el operador de proyección sobre  $X$ .
- $G(x, \xi) = \xi x - \frac{1}{2}$ , que pertenece a  $\partial[\frac{x}{2} + Q(x, \xi)]$

Por lo tanto el iterado  $x^{j+1}$  es la solución óptima del siguiente problema:

$$\min_{x \in [0,10]} \left| x - \left( x^j - \gamma^j \left( \xi^j x^j - \frac{1}{2} \right) \right) \right|$$

Suponemos  $\gamma^j = \frac{1}{4(j+1)}$

*Iteración 1:*  $x^0 = 0$ ,  $\gamma^0 = \frac{1}{4}$ , y elijamos  $\xi^1 = 2$ . Por lo tanto  $x^1$  es la solución óptima de:

$$\min_{x \in [0,10]} \left| x - \left( 0 - \frac{1}{4} \left( 2 \cdot 0 - \frac{1}{2} \right) \right) \right|$$

$$\Rightarrow x^1 = \frac{1}{8}$$

*Iteración 2:*  $x^1 = \frac{1}{8}$ ,  $\gamma^1 = \frac{1}{8}$ , y elijamos  $\xi^2 = 3$ . Por lo tanto  $x^2$  es la solución óptima de:

$$\min_{x \in [0,10]} \left| x - \left( \frac{1}{8} - \frac{1}{8} \left( 3 \cdot \frac{1}{8} - \frac{1}{2} \right) \right) \right|$$

$$\Rightarrow x^2 = \frac{7}{64}$$