

# Propriedades de Programas Estocásticos (Multi-estágios) com Recurso

Prof. Alexandre Salles da Cunha

Universidade Federal de Minas Gerais  
Departamento de Ciência da Computação  
Belo Horizonte, Brasil

[acunha@dcc.ufmg.br](mailto:acunha@dcc.ufmg.br)

2021/2



UNIVERSIDADE FEDERAL  
DE MINAS GERAIS



## Relativas à esta apresentação

- ① J. R. Birge & F. Louveaux. *Introduction to Stochastic Programming*, Springer, 2011, 2a Edição [Caps 2, 3 e 4]

- 1 Revisão de probabilidades
- 2 Problemas multi-períodos vs multi-estágios, um exemplo.
- 3 Propriedades de problemas de Programação Estocástica Lineares (e inteiros) com dois ou múltiplos estágios com recurso.
- 4 Desigualdades envolvendo EVPI, VSS, RP.

- 1 Incerteza é representada por meio de experimentos aleatórios. Os resultados destes experimentos são indicados por  $\omega$ .
- 2 O conjunto de todos os resultados é  $\Omega$ .
- 3 Os resultados podem ser combinados em subconjuntos de  $\Omega$ , denominados **eventos**. Exemplo: se  $\Omega = \{1, 2, 3, 4, 5, 6\}$  representa os possíveis resultados de se jogar um dado, o subconjunto de eventos  $\mathcal{A}$  pode representar os elementos ímpares de  $\Omega$ .
- 4 Para cada elemento  $A \in \mathcal{A}$  é atribuída uma probabilidade  $P(A)$ , satisfazendo  $0 \leq P(A) \leq 1$ ,  $P(\emptyset) = 0$ ,  $P(\Omega) = 1$ ,  $P(A_1 \cup A_2) = P(A_1) + P(A_2)$  se  $A_1 \cap A_2 = \emptyset$ .
- 5 É comum em Programação Estocástica, que os elementos de  $\Omega$  sejam empregados para representar **estados possíveis finitos do mundo** ou **cenários**. Neste caso, todos os elementos incertos dependem destes cenários finitos.

É uma descrição do quanto provável são os valores que podem ser assumidos por uma ou um conjunto de variáveis aleatórias. A forma como apresentamos a distribuição de probabilidades depende das variáveis aleatórias serem discretas ou contínuas.

- ① Para uma variável aleatória  $\xi$ , definimos sua distribuição de probabilidades acumulada como:

$$F_\xi(x) = P(\xi \leq x) = P(\{\omega | \xi \leq x\}).$$

- ② Dois casos devem ser considerados:

- ① Variáveis aleatórias discretas (ou em número contável de estados). Estas variáveis são descritas por **distribuições de probabilidades** (probability mass functions), correspondendo à lista de possíveis valores  $\xi^k, k \in K$ , com probabilidades:

$$0 \leq f(\xi^k) = P(\xi = \xi^k), \text{ satisfazendo } \sum_{k \in K} f(\xi^k) = 1.$$

- ② Variáveis aleatórias contínuas. São descritas por **funções densidade de probabilidade  $f(\xi)$** . A probabilidade de  $\xi$  percenter a um intervalo  $[a, b]$  é dada por:

$$P(a \leq \xi \leq b) = \int_a^b f(\xi) d\xi = \int_a^b dF(\xi)$$

No caso contínuo,  $P(\xi = a) = 0$ , diferentemente do caso discreto.

- 1 A expectativa de uma variável aleatória é calculada como  $\mu = \sum_{k \in K} \xi^k f(\xi^k)$ , no caso discreto, ou  $\mu = \int_{-\infty}^{\infty} \xi dF(\xi)$ , no caso contínuo.
- 2 A variância  $\sigma^2$  de uma variável aleatória é definida como  $\mathbb{E}[(\xi - \mu)^2]$ .
- 3 A expectativa de  $\xi^r$  é denominada de  $r$ -ésimo momento de  $\xi$ , sendo designada por  $\bar{\xi}^r = E(\xi^r)$ .
- 4 Momentos sobre a média  $\mathbb{E}[(\xi - \mu)^r]$ .
- 5 A média é o primeiro momento, a variância é o segundo momento sobre a média.

## Discreta $U[1, n]$


$P(\xi = i) = \frac{1}{n}$  para qualquer  $i = 1, \dots, n, n \geq 1$ .  
 $\mathbb{E}[\xi] = \frac{n+1}{2}, \sigma^2 = \frac{n^2-1}{12}$ .

## Contínua $U[0, a]$

$f(\xi) = \frac{1}{a}, a > 0, 0 \leq \xi \leq a$ .  $\mathbb{E}[\xi] = \frac{a}{2}, \sigma^2 = \frac{a^2}{12}$ .

## Geração de amostra de dados segundo distribuição uniforme

```
from scipy.stats import uniform
n = 100000
a = 5
delta = 15
data_uniform = uniform.rvs(size=n, loc = a, scale=delta)
ax = sns.distplot(data_uniform,bins=50,kde=True,color='red',
                   hist_kws={"linewidth": 10,'alpha':1})
ax.set(xlabel='i', ylabel='Probabilidade (discreta)')
print("%5.2f" % data_uniform.mean(),"%5.2f" % data_uniform.var())
```



Binomial:  $Bi(n, p)$ 

Dois resultados possíveis: sucesso ou fracasso,  $p$  denota a probabilidade de sucesso.  $P(i, n)$  fornece a probabilidade de  $i$  sucessos em  $n$  tentativas.  $\mathbb{E}[\xi] = np$  e  $\sigma^2 = np(1 - p)$ .


$$P(\xi = i, n) = \binom{n}{i} p^i (1 - p)^{n-i}$$

A distribuição binomial é uma extensão da distribuição de Bernoulli.

Nesta, temos dois estados possíveis: fracasso e sucesso, probabilidade de sucesso é  $p$ , probabilidade de fracasso é  $1 - p$ . Ou seja, a distribuição binomial é a distribuição de probabilidades para o número de sucessos em uma sequência independente de tentativas que seguem uma distribuição de Bernoulli.

## Geração de amostra de dados segundo distribuição binomial

```
from scipy.stats import binom
data_binom = binom.rvs(n=10,p=0.8,size=10000)
ax = sns.distplot(data_binom,kde=False,color='red',\
hist_kws={"linewidth": 10,'alpha':1})
ax.set(xlabel='i', ylabel='Frequênci')
print("%5.2f" % data_binom.mean(),"%5.2f" % data_binom.var())
8.00 1.62
```



## Poisson


Bastante empregada para modelar o número de vezes que um evento ocorre em um determinado período de tempo. Por exemplo, número de vezes que um serviço de emergência é chamado em uma hora de atendimento. A distribuição é caracterizada pela taxa  $\lambda$  através dos quais o evento ocorre.  $P(i)$  fornece a probabilidade de que o evento ocorra  $i$  vezes no período.

$$P(\xi = i) = e^{-\lambda} \frac{\lambda^i}{i!}$$

$$\mathbb{E}[\xi] = \lambda, \sigma^2 = \lambda.$$

## Geração de amostra de dados segundo distribuição de Poisson

```
from scipy.stats import poisson
data_poisson = poisson.rvs(mu=4, size=10000)
ax = sns.distplot(data_poisson,bins=40,kde=False,color='red',
                   hist_kws={"linewidth": 8,'alpha':1})
ax.set(xlabel='i', ylabel='Frequênci')
print("%5.2f" % data_poisson.mean(),"%5.2f" % data_poisson.var())
4.01 3.97
```




## Exponencial

$$f(\xi) = \lambda e^{-\lambda \xi}, \lambda > 0, 0 \leq \xi$$

$$\mathbb{E} = \frac{1}{\lambda}, \sigma^2 = \frac{1}{\lambda^2}.$$

## Geração de amostra de dados segundo distribuição exponencial

```
from scipy.stats import expon
data_expon = expon.rvs(scale=1,loc=0,size=10000)
ax = sns.distplot(data_expon,kde=True,bins=100,color='red',
                   hist_kws={"linewidth": 15,'alpha':1})
ax.set(xlabel='variável aleatória', ylabel='Frequência')
print("%5.2f" % data_expon.mean(),"%5.2f" % data_expon.var())
1.00 1.02
```




## Normal

$$f(\xi) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(\xi-\mu)^2}{2\sigma^2}}, \sigma > 0$$

Parâmetros da distribuição: expectativa  $\mu$  e variância  $\sigma^2$ .

## Geração de amostra de dados segundo distribuição normal

```
from scipy.stats import norm
# N(0,1)
data_normal = norm.rvs(size=10000,loc=0,scale=1)
ax = sns.distplot(data_normal,bins=100,
                   kde=True,color='red',
                   hist_kws={"linewidth": 10,'alpha':1})
ax.set(xlabel='distribuição normal', ylabel='Frequênci
-0.00 1.01
```



## Teorema

Se executarmos um grande número de tentativas de um processo aleatório, então a distribuição de probabilidades para a soma (ou para a média) do resultado é aproximadamente uma distribuição gaussiana. Quanto maior o número de tentativas, melhor a aproximação com a distribuição de Gauss.

## Exemplo

Evento aleatório: jogar uma moeda não adulterada  $n$  vezes, retornando o número de caras divido por  $n$ . O evento base em si segue uma distribuição binomial com  $p = \frac{1}{2}$ . Porém, se executarmos este experimento por muitas vezes, a distribuição dos resultados retornados no experimento será aproximadamente uma gaussiana com média  $\frac{1}{2}$ .

É um resultado fundamental para os métodos baseados em Simulação de Monte-Carlo.

- A principal classe de problemas de otimização a ser investigada no curso é de Problemas de Programação Estocástica Lineares com Estágios, com recurso.
- Nesta grande classe incluimos as variantes onde as variáveis de decisão de primeiro estágio e de estágios subsequentes podem assumir valores inteiros apenas.
- O termo recurso significa que o modelo de otimização prevê ações a serem tomadas após a incerteza se revelar, uma vez que alguns dados que definem o problema são representados por meio de variáveis aleatórias  $\xi = \xi(\omega)$ .

As decisões são divididas em dois grupos, relativos à sua ordem cronológica:

- **1o. estágio (*here-and-now*)**. Precisam ser tomadas antes do experimento ou da revelação dos dados incertos. Normalmente, são indicadas pelo vetor  $x$ . Uma vez escolhida a decisão de primeiro estágio,  $x$ , não pode ser alterada.
- **2o. estágio (*wait-and-see*)**. São tomadas após as variáveis aleatórias serem definidas, considerando também as decisões  $x$  do estágio anterior. São normalmente indicadas pelo vetor  $y$ .

$$x \rightarrow \xi(\omega) \rightarrow y(\omega, x)$$

$$\min z = c^T x + \mathbb{E}_\xi [q(\omega)^T y(\omega)]$$

$$s.t. \quad Ax = b$$

$$T(\omega)x + Wy(\omega) = h(\omega)$$

$$x \geq 0, y(\omega) \geq 0$$

- ① Dados determinísticos relativos às decisões de 1o. estágio:  $c, b, A$  de dimensões  $n_1, m_1, m_1 \times n_1$ , respectivamente.
- ② No segundo estágio, um conjunto de eventos aleatórios  $\omega \in \Omega$  se realizam. Para uma dada realização  $\omega$ , os dados do problema de segundo estágio são:  $q(\omega), h(\omega)$  e  $T(\omega)$  se tornam conhecidos, com dimensões (fixas, independentes de  $\omega$ )  $n_2, m_2$  e  $m_2 \times n_1$ , respectivamente.
- ③  $\xi(\omega)^T = (q(\omega)^T, h(\omega)^T, T_1(\omega), \dots, T_{m_2}(\omega))$  possui potencialmente até  $N = n_2 + m_2 + m_2 n_1$  entradas.  $T_i(\omega)$  denota a  $i$ -ésima linha de  $T(\omega)$ ;

- $\Xi \subset \mathbb{R}^N$  denota o suporte de  $\xi$ , isto é, o menor subconjunto fechado do  $\mathbb{R}^N$  que satisfaz  $P(\Xi) = 1$ .
- A dependência de  $y(\omega, x)$  em função de  $\omega$  difere da dependência de  $q(\omega), h(\omega), T(\omega)$  em relação a  $\omega$ . No caso de  $y$ , indica que uma vez que uma realização acontece, a decisão  $y$  pode ser tomada. Também indica que a decisão  $y$  seria possivelmente diferente diante de realizações distintas de  $\omega$ . No caso de  $q(\omega), h(\omega), T(\omega)$ , indica que as grandezas não são conhecidas até a realização do experimento.

## Two-stage SP with recourse

$$\begin{aligned}
 \min \quad & z = c^T x + \mathbb{E}_\xi \left[ q(\omega)^T y(\omega) \right] \\
 \text{s.t.} \quad & Ax = b \\
 & T(\omega)x + Wy(\omega) = h(\omega) \\
 & x \geq 0, y(\omega) \geq 0
 \end{aligned}$$

## PDE

$$\begin{aligned}
 \min \quad & z = c^T x + Q(x) \\
 \text{s.t.} \quad & Ax = b \\
 & x \geq 0
 \end{aligned}$$

- Para uma dada realização  $\omega$ , definimos:

$$Q(x, \xi(\omega)) = \min_y \left\{ q(\omega)^T y : Wy = h(\omega) - T(\omega)x, y \geq 0 \right\}$$

como o **valor da parcela da fo** relativa ao segundo estágio.

- Definimos  $Q(x) = \mathbb{E}_\xi Q(x, \xi)$  como a *second stage value function* e o Problema Determinístico Equivalente (PDE).
- Nos modelos acima, podemos impor a integralidade das variáveis,** restringindo, por exemplo:  $x \in X = \mathbb{Z}^{n_1}$ ,  $y(\omega) \in Y = \mathbb{Z}^{n_2}$ .

## Problema de Localização de Facilidades - Determinístico

- Versão não capacitada.
- $I = \{1, \dots, m\}$ : conjunto de clientes. Demandas  $d_i : i \in I$  de uma dada mercadoria.  $r_i$  denota a receita obtida ao se atender 100% da demanda de  $i$ .
- $J = \{1, \dots, n\}$ : conjunto de potenciais localidades onde instalar um armazém, a partir de onde a mercadoria será distribuída.  $c_j : j \in J$  é o custo fixo de abrir a localidade  $j$ .  $v_j : j \in J$  representa o custo variável de operar a localidade  $j$  e  $t_{ij}$  é o custo de atender 100% da demanda de  $i$  pela localidade  $j$ .
- $q_{ij} := (r_i - v_j - t_{ij})d_i$  é a margem de contribuição de atender a demanda de  $i$  por  $j$ .

$$\max_{x,y} z(x,y) = - \sum_{j \in J} c_j x_j + \sum_{i \in I} \sum_{j \in J} q_{ij} y_{ij}$$

$$s.t. \sum_{j \in J} y_{ij} \leq 1 \quad i \in I$$

$$y_{ij} \leq x_j \quad i \in I, j \in J$$

$$y_{ij} \geq 0 \quad i \in I, j \in J$$

$$x_j \in \{0,1\} \quad j \in J$$

- $x_j \in \{0,1\}$  indica se a localidade  $j \in J$  foi aberta.
- $y_{ij} \in [0,1]$  indica a fração de  $d_i : i \in I$  atendida por  $j \in J$ .

## Variante estocástica #1

- A distribuição será fixa no primeiro estágio, isto é, agora  $y_{ij}$  indica a quantidade transportada de  $j$  para  $i$ , independentemente da demanda que não é conhecida quando esta decisão é tomada.
- Os elementos de custos,  $v_j$ ,  $t_{ij}$ ,  $r_i$  podem ou não ser estocásticos. Independentemente disso,  $y_{ij}$  é uma decisão de primeiro estágio.
- Variáveis de decisão de segundo estágio:  $w_i^+(\omega)$ ,  $w_i^-(\omega)$ , respectivamente indicando a falta e o excesso, no atendimento da demanda de  $i \in I$  quando  $d_i(\omega)$  se revelar. Quando houver falta no atendimento da demanda, paga-se  $q_i^+$  e quando houver excesso, paga-se  $q_i^-$ , proporcionais à quantidade.
- Para fins de acoplamento, usaremos um big-M, representando uma capacidade máxima fictícia para uma localidade qualquer.

$$\begin{aligned}
 & \max - \sum_{j \in J} c_j x_j + \sum_{i \in I} \sum_{j \in J} \mathbb{E}_{\xi}(-v_j - t_{ij}) y_{ij} + \\
 & \mathbb{E}_{\xi} \left[ - \sum_{i \in I} q_i^+ w_i^+(\omega) - \sum_{i \in I} q_i^- w_i^-(\omega) - \sum_{i \in I} r_i d_i(\omega) \right] \\
 & \sum_{i \in I} y_{ij} \leq M x_j \quad j \in J \\
 & w_i^+(\omega) - w_i^-(\omega) = d_i(\omega) - \sum_{j \in J} y_{ij} \quad i \in I \\
 & y_{ij} \geq 0 \quad i \in I, j \in J \\
 & x_j \in \{0, 1\} \quad j \in J \\
 & w_i^+(\omega), w_i^-(\omega) \geq 0 \quad i \in I
 \end{aligned}$$

Este modelo força a demanda a ser atendida...

## Variante estocástica #2

- A **distribuição** será definida no segundo estágio, se ajustando à realização da variável aleatória.
- Porém, precisamos **definir** as capacidades instaladas nas facilidades abertas, no primeiro estágio.
- A variável  $y_{ij}(\omega)$  indica o percentual de  $d_i(\omega)$  atendido por  $j$  quando a demanda se revelar.
- Vamos introduzir uma variável  $w_j$ , de primeiro estágio, que indicará, no caso da facilidade  $j \in J$  ser aberta, a capacidade a ser instalada em  $j$ . O custo por unidade de capacidade instalada é  $g_j : j \in J$ , determinístico.
- $q_{ij}(\omega) := (r_i - v_j - t_{ij})d_i(\omega)$  denota o custo de atender a demanda de  $i$  em uma realização  $\omega \in \Omega$ .

$$\begin{aligned}
 & \max - \sum_{j \in J} c_j x_j - \sum_{j \in J} g_j w_j + \mathbb{E}_\xi \left[ \sum_{i \in I} \sum_{j \in J} q_{ij}(\omega) y_{ij}(\omega) \right] \\
 & \sum_{j \in J} y_{ij}(\omega) \leq 1 \quad i \in I \\
 & \sum_{i \in I} d_i(\omega) y_{ij}(\omega) \leq w_j \quad j \in J \\
 & y_{ij} \geq 0 \quad i \in I, j \in J \\
 & x_j \in \{0, 1\} \quad j \in J \\
 & w_j \geq 0 \quad j \in J
 \end{aligned}$$

Neste modelo, a demanda pode não ser atendida completamente.  
 Poderíamos impor uma penalidade, incorrida na parcela não atendida.

### Variante estocástica #2 do UFLP e as seguintes observações.

- ① Planejamento para os próximos 36 meses.
- ② A decisão de primeiro estágio, instalação das facilidades, leva cerca de 6 meses para ser concluída. As decisões de segundo estágio, como distribuir de  $j$  para  $i$ , ocorrem ao longo dos 30 meses seguintes.
- ③ Embora possa se pensar com mais estágios, o número de estágios necessários, dois no caso considerado nesta discussão, está ligado a quando a decisão de instalar as facilidades é tomada. Ela é que muda a estrutura possível de distribuição.
- ④ Assim, faz sentido um modelo de dois estágios, no qual o segundo estágio é representado pelas decisões ao longo de 30 períodos consecutivos.
- ⑤ Podemos até ter as demandas sendo reveladas mês a mês, o que não muda a natureza do problema ser de dois estágios. O recurso permite não atender a demanda.

Quando haveria a necessidade ou faria sentido em incorporar mais estágios no caso anterior ? Por exemplo, quando se prevê a possibilidade de, ao longo do horizonte de planejamento, reavaliar as localidades abertas, abrindo algumas novas ou fechando outras que foram abertas no passado.

- ➊ Vamos considerar que após 12 meses (isto é, após 6 meses de operação da distribuição), a empresa **possa abrir novas localizações**.
- ➋ Sob as condições acima, o **primeiro estágio** compreenderia a decisão do que abrir hoje, compreendendo o mês 1 ao 6, o **segundo estágio**, a operação do mês 7 ao 18, bem como a decisão de quais novas localidades abrir no mês 12 e, **finalmente**, o **terceiro estágio** compreenderia a operação do mês 19 ao 36.
- ➌  $\xi_2$  e  $\xi_3$  representam vetores de variáveis aleatórias associadas ao segundo e terceiro estágios, neste exemplo.

- ①  $x_j^1$  e  $x_j^2(\omega_2)$  representam variáveis binárias, relativas à abertura ou não da localidade  $j$  no primeiro e no segundo estágio de decisão, respectivamente.
- ②  $y^2(\omega_2), y^3(\omega_3)$  representam os vetores de distribuição da mercadoria, durante o segundo e terceiro estágios, respectivamente.
- ③  $\omega_2 \in \Omega_2, \omega_3 \in \Omega_3$  representam possíveis estados do mundo, no estágio 2 e 3.
- ④ O modelo apresentado na sequência envolve restrições puras de cada estágio e acoplamento entre as decisões em estágios distintos. Também envolve expectativas condicionais.

$$\max - \sum_{j \in J} c_j x_j^1 + \mathbb{E}_{\xi_2} \max \left\{ \sum_{i \in I} \sum_{j \in J} q_{ij}^2(\omega_2) y_{ij}^2(\omega_2) - \sum_{j \in J} c_j^2(\omega_2) x_j^2(\omega_2) \right\}$$

$$+ \mathbb{E}_{\xi_3 | \xi_2} \max \left\{ \sum_{i \in I} \sum_{j \in J} q_{ij}^3(\omega_3) y_{ij}^3(\omega_3) \right\}$$

$$\sum_{j \in J} y_{ij}^2(\omega_2) \leq 1 \quad i \in I$$

$$\sum_{i \in I} d_i(\omega_2) y_{ij}^2(\omega_2) \leq M x_j^1 \quad j \in J$$

$$\sum_{j \in J} y_{ij}^3(\omega_3) \leq 1 \quad i \in I$$

$$\sum_{i \in I} d_i(\omega_3) y_{ij}^3(\omega_3) \leq M(x_j^1 + x_j^2(\omega_2)) \quad j \in J$$

$$x_j^1 + x_j^2(\omega_2) \leq 1 \quad j \in J$$

$$y_{ij}^2(\omega_2), y_{ij}^3(\omega_3) \geq 0 \quad i \in I, j \in J$$

$$x_j^1, x_j^2(\omega_2) \in \{0, 1\} \quad j \in J$$

A frequência dos eventos incertos é relevante. Dois grandes grupos:

- ① Eventos incertos ocorrem com grande frequência, de forma recorrente, no curto prazo, e decisões precisam serem tomadas na mesma frequência. Por exemplo, o UFLP, em que devemos atender a demanda incerta durante todo o horizonte de planejamento. Há vários cenários de demanda, e ao longo dos períodos, muitos deles serão realizados.
- ② Poucos cenários efetivamente serão realizados, uma vez que poucas decisões serão tomadas. Exemplo: especificação de ingressos para um grande evento esporádico como Copa do Mundo. Nestes casos deseja-se maximizar o lucro, mas também se proteger contra cenários potencialmente desastrosos. Nestes casos, faz muito sentido incorporar elementos de Programação Robusta ou Chance Constrained Models, por meio de restrições no Programa Estocástico.

- Modelos em que se maximiza uma função de utilidade, para um dado perfil de risco estabelecido. Por exemplo, modelo de Markowitz para construção da fronteira eficiente de portfólios.
- Risco pode ser representado pela probabilidade de se obter um retorno abaixo de um dado patamar estabelecido, *downside risk*. Incorpora-se uma restrição no modelo, estabelecendo que esta probabilidade deva ser inferior ao valor desejado.
- Abordagem puramente robusta. Por exemplo, são definidos intervalos para as variáveis incertas e busca-se uma solução ótima que permaneça viável ainda que um número de eventos incertos ocorra da maneira mais desfavorável possível.

## Two-stage SPWR

$$\min z = c^T x + \mathbb{E}_\xi \left[ q(\omega)^T y(\omega) \right]$$

$$s.t. \quad Ax = b$$

$$T(\omega)x + Wy(\omega) = h(\omega)$$

$$x \geq 0, y(\omega) \geq 0$$

$$Q(x, \xi(\omega)) = \min_y \left\{ q(\omega)^T y : Wy = h(\omega) - T(\omega)x, y \geq 0 \right\}$$

$$\mathcal{Q}(x) = \mathbb{E}_\xi Q(x, \xi)$$

Precisamos dispor de representação adequada e computacionalmente tratável para a função recurso  $\mathcal{Q}(x)$ :

- ou dispomos da forma analítica de  $\mathcal{Q}(x)$  (raro).
- ou conseguimos computar  $\mathcal{Q}(x)$ , para uma dada decisão  $x$  de 1º. estágio fixa.

## Problema Determinístico Equivalente ao SPWR

$$\begin{aligned} \min \quad & z = c^T x + Q(x) \\ \text{s.t.} \quad & Ax = b \\ & x \geq 0 \end{aligned}$$

$$\begin{aligned} Q(x, \xi(\omega)) &= \min_y \left\{ q(\omega)^T y : Wy = h(\omega) - T(\omega)x, y \geq 0 \right\} \\ Q(x) &= \mathbb{E}_\xi Q(x, \xi) \end{aligned}$$

Hipóteses usuais:

- A matriz de recurso  $W$  é fixa.
- $\Xi$  é um conjunto finito, ou equivalentemente  $\xi$  é uma variável aleatória finita, seja porque de fato dispomos de um conjunto finito de cenários ou porque utilizamos técnicas de amostragem para gerar cenários a partir de distribuições contínuas.

- Conjunto de viabilidade de 1o. estágio:

$$K_1 = \{x \in \mathbb{R}^{n_1} : Ax = b, x \geq 0\}$$

- Para um determinado  $\xi$ , definimos

$$K_2(\xi) = \{x \in \mathbb{R}^{n_1} : \exists y \geq 0, Wy = h(\omega) - T(\omega)x\}$$

- $K_2 = \bigcup_{\xi \in \Xi} K_2(\xi)$
- Reformulação do SPWR:  $\min c^T x + Q : x \in K_1 \cap K_2$ .
- $\text{pos}(W) = \{t | Wy = t, y \geq 0\}$  indica o conjunto dos vetores de termos independentes  $t$  que podem ser escritos como combinação linear não negativa das colunas de  $W$ .

Vamos supor que  $\xi_1$  e  $\xi_2$  só possam assumir valores nos conjuntos  $\{2, 3, 4\}$  e  $\{1, 4, 7\}$ . Considere o seguinte problema de 2o. estágio.

$$\min 2y_1 + y_2$$

$$y_1 + 2y_2 \geq \xi_1 - x_1$$

$$y_1 + y_2 \geq \xi_2 - x_1 - x_2$$

$$0 \leq y_1, y_2 \leq 1$$

- Usando os limites superiores para os valores admissíveis de  $y$ , temos:

$$K_2(\xi) = \{x \in \mathbb{R}^2 : x_1 \geq \xi_1 - 3, x_1 + x_2 \geq \xi_2 - 2\}.$$

- Considerando a distribuição de  $\xi$  que é discreta,

$$K_2 = \{x \in \mathbb{R}^2 : x_1 \geq 1, x_1 + x_2 \geq 5\}$$

## Teorema

- ① Para um dado  $\xi$ ,  $K_2(\xi)$  é um conjunto poliedral.
- ② Se  $\xi$  é uma variável aleatória discreta,  $K_2$  é um conjunto poliedral, e portanto, convexo.

## Teorema

Para um dado  $\xi$  fixo, a função  $Q(x, \xi)$  é:

- 1 linear por partes e convexa em  $(h, T)$ .
- 2 linear por partes côncava em  $q$ .
- 3 linear por partes e convexa em  $x$  para todo  $x \in K_2$ .

Quando  $\xi$  é uma variável aleatória discreta,  $Q$  é linear por partes e convexa em  $K_2$ . Como  $K_1$  é poliédral, o problema é convexo.

Considere o seguinte problema de 2o. estágio e assuma  $0 \leq x_1, x_2 \leq 1$ .

$$\begin{aligned} \min \quad & 2y_1 + y_2 \\ \text{s.t.} \quad & y_1 + y_2 \geq 1 - x_1 \\ & y_1 \geq \xi - x_1 - x_2 \\ & 0 \leq y_1, y_2 \end{aligned}$$

- A decisão ótima de 2o. estágio é:
  - Se  $\xi \leq x_1 + x_2 \rightarrow y_1 = 0, y_2 = 1 - x_1$
  - Se  $\xi > x_1 + x_2 \rightarrow y_1 = \xi - x_1 - x_2, y_2 = \max\{0, 1 - \xi + x_2\}$
- A função recurso é linear por partes em  $x$  (resta provar convexidade).

$$Q(x, \xi) = \begin{cases} 1 - x_1 & 0 \leq \xi \leq x_1 + x_2 \\ \xi + 1 - 2x_1 - x_2 & x_1 + x_2 \leq \xi \leq 1 + x_2 \\ 2(\xi - x_1 - x_2) & 1 + x_2 \leq \xi \end{cases}$$

- Recurso relativamente completo: quando toda solução viável no primeiro estágio possui uma realização viável no segundo estágio, isto é,  $K_1 \subseteq K_2$ . Não é fácil de ser caracterizado.
- Recurso completo: caso particular do recurso relativamente completo, mais fácil de ser caracterizado pois depende da estrutura de  $W$ . Quando para qualquer  $t \in \mathbb{R}^{m_2}$  existir  $y \geq 0$ ,  $Wy = t$ , temos o recurso completo. Em outras palavras:  $\text{pos}(W) = \mathbb{R}^{m_2}$ .
- Recurso simples. Neste caso  $W = [I, -I]$ ,  $y$  é particionada em  $y^+, y^-$  com custos  $q = q^+ - q^-$ , onde  $q_i^+ - q_i^- \geq 0$  para todo  $i$ , com probabilidade 1.

## Integer Two-stage SPWR

$$\min z = c^T x + \mathbb{E}_\xi \left[ q(\omega)^T y(\omega) \right]$$

$$s.t. \quad Ax = b$$

$$T(\omega)x + Wy(\omega) = h(\omega)$$

$$x \in X, y(\omega) \in Y$$

$$Q(x, \xi(\omega)) = \min_{y \in Y} \left\{ q(\omega)^T y : Wy = h(\omega) - T(\omega)x \right\}$$

$$Q(x) = \mathbb{E}_\xi Q(x, \xi)$$

Os conjuntos  $X$  e  $Y$  podem ser, por exemplo,  $\mathbb{Z}^{n_1}$  e  $\mathbb{Z}^{n_2}$ , respectivamente. Mesmas definições anteriores de  $c, b, \xi, A, W, T$ .

- ① Se a integralidade é imposta penas em  $x$ , as propriedades para  $Q(x)$  e  $K_2$  para o caso SPWR de dois estágios linear são preservadas.
- ② Assumimos portanto que a integralidade seja imposta nas variáveis  $y$  de segundo estágio.

### Teorema

A função valor esperado do recurso  $Q(x)$  de um programa inteiro é, no caso geral, semi-contínua inferior, não convexa e descontínua.

$$Q(x, \xi) = \min\{2y_1 + y_2 : y_1 \geq x - \xi, y_2 \geq \xi - x, y \geq 0, y \in \mathbb{Z}\}.$$


Vamos também assumir que  $\xi$  possa valer 1 ou 2 com probabilidade  $\frac{1}{2}$  e que  $x \geq 0$ .

### Caso $\xi = 1$

$$y_1 \geq x - 1$$

$$y_2 \geq 1 - x$$

- Se  $x \leq 1 \rightarrow y_1 = 0$ , e  $y_2 = [1 - x]$
- Se  $x > 1 \rightarrow y_1 = [x - 1]$  e  $y_2 = 0$ .




Caso  $\xi = 2$

$$y_1 \geq x - 2$$


$$y_2 \geq 2 - x$$

- Se  $x \leq 2 \rightarrow y_1 = 0$ , e  $y_2 = \lceil 2 - x \rceil$
- Se  $x > 2 \rightarrow y_1 = \lceil x - 2 \rceil$  e  $y_2 = 0$ .



$$Q(x) = \frac{1}{2}(Q(x, 1) + Q(x, 2))$$

Veja que  $Q(x)$  é:



- Descontínua nos  $x$  inteiros.

- Não convexa.

Considere  $\lambda = \frac{1}{2}$ ,  $x^1 = 1$ ,  $x^2 = 2$ , e  $x(\lambda) = \lambda x^1 + (1 - \lambda)x^2 = \frac{1}{2}1 + \frac{1}{2}2 = 1.5$ . Temos que  $Q(1.5) = 1.5 > 0.5Q(1) + 0.5Q(2) = 0.75$

- Não é fácil encontrar  $\arg \min c^T x + Q(x)$ .

## Proposição

A função recurso  $Q(x)$  de um programa inteiro com variáveis de segundo estágio inteiras é contínua quando a variável aleatória é absolutamente contínua.

$$Q(x, \xi) = \min\{2y_1 + y_2 : y_1 \geq x - \xi, y_2 \geq \xi - x, y \in \mathbb{Z}\}.$$

Assumimos:  $x \geq 0$ , e a distribuição acumulada para  $\xi$  é

$$F(t) = P(\xi \leq t) = 2 - \frac{2}{t} \text{ para } t \in [1, 2].$$

- $1 < x < 2$  e  $1 \leq \xi < x \rightarrow y_1 = 1, y_2 = 0$
- $1 < x < 2$  e  $x < \xi \leq 2 \rightarrow y_1 = 0, y_2 = 1$

$$\begin{aligned} Q(x) &= \int_1^x 2dF(t) + \int_x^2 1dF(t) = 2F(x) + 1 - F(x) \\ &= F(x) + 1 \\ &= 3 - \frac{2}{x} \end{aligned}$$

Assim como nos casos anteriores, assumimos que  $y \in Y$  é inteiro.

- As propriedades do conjunto de viabilidade de 2o. estágio não são muito melhores que as da função recurso  $Q(x)$ .
- Para um valor fixo de  $\xi$ , definimos:

$$K_2(\xi(\omega)) = \{x \in \mathbb{R}^{n_1} : \exists y \in Y, Wy = h(\omega) - T(\omega)x\}$$

onde  $\xi(\omega)$  compreende as componentes estocásticas de  $h(\omega)$  e  $T(\omega)$ .

### Proposição

Geralmente, o conjunto de viabilidade de segundo eságio  $K_2(\xi)$  é um conjunto não convexo.

Consideramos que  $\xi$  assuma valores  $\{1, 2\}$  equiprováveis.

$$-y_1 + y_2 \leq \xi - x_1 \quad (1)$$

$$y_1 + y_2 \leq 2 - x_2 \quad (2)$$


$$y \in \mathbb{Z}_+^2 \quad (3)$$

### $K_2(1)$

- (2)  $\rightarrow x_2 \leq 2$  é necessária para viabilidade no 2o. estágio.
- Para  $x_2 \in (1, 2]$ , o único ponto inteiro satisfazendo (2) é  $y_1 = y_2 = 0$ .
- $y_1 = y_2 = 0$  também satisfaz (1) se  $x_1 \leq \xi = 1$ .
- Para  $x_2 \in (0, 1]$ , valores de  $y$  que satisfazem (2) são  $(0, 0), (0, 1), (1, 0)$ , sendo que  $(1, 0)$  produz o menor lado esquerdo, mais provável de produzir pontos em  $K_2(1)$ .
- Para  $y = (1, 0)$ , (1) requer  $x_1 \leq 2$ .

Veja que a interseção de  $K_2(1)$  com o quadrante positivo de  $\mathbb{R}^2$  pode ser formulada da seguinte forma:

$$K_2(1) = \{x \in \mathbb{R}_+^2 : \min\{x_1 - 1, x_2 - 1\} \leq 0, x_1 \in [0, 2], x_2 \in [0, 2]\}.$$



## Variáveis de decisão contínuas

- $H$  estágios
- $x^1$  : variável de decisão de 1o. estágio.
- $x^t(\omega^t)$  :  $t = 2, \dots, H$  variável de decisão do estágio  $t$ , dependendo da realização  $\omega^t$ .
- $\xi^t(\omega)^T = (c^t(\omega)^T, h^t(\omega)^T, T_1^{t-1}(\omega), \dots, T_{m_t}^{t-1}(\omega))$  é um vetor  $N_t$  dimensional.  $\xi^t(\omega)$  é independente de  $\xi^{t-1}(\omega), \dots, \xi^1(\omega)$ .
- $T^{t-1}(\omega^t)$  é uma matriz  $m_t \times n_{t-1}$  dimensional.
- $W^t$  é uma matriz  $m_t \times n_t$  dimensional, fixa, independentemente de  $\xi$ .
- As decisões  $x$  dependem da história até o instante  $t$ , que indicamos por  $\omega^t$ .
- $\Xi^t$  é o suporte de  $\xi^t$ .
- No modelo seguinte, a notação transposta foi intencionalmente suprimida.

$$\min c^1 x^1 + \mathbb{E}_{\xi^2} \left[ \min c^2(\omega^2) x^2(\omega^2) + \cdots + \mathbb{E}_{\xi^H} \left[ \min c^H(\omega^H) x^H(\omega^H) \right] \cdots \right]$$

$$h^1 = W^1 x^1$$

$$h^2(\omega^2) = T^1(\omega^2) x^1 + W^2 x^2(\omega^2)$$

$$\cdots \vdots$$

$$h^H(\omega^H) = T^{H-1}(\omega^H) x^{H-1} + W^H x^H(\omega^H)$$

$$x_1 \geq 0$$

$$x^t(\omega^t) \geq 0, \quad t = 2, \dots, H.$$

## Estágios vs estados da PD

- Estágios: estágios do programa estocástico  $t = 1, \dots, H$ .
- Estados:  $x^t(\omega^t) : t = 1, \dots, H$

## Formulação recursiva

Como de costume em PD, vamos formular o problema de forma recursiva, detalhando o caso base, quanto  $t = H$ , e os demais, quando  $t \in \{1, \dots, H-1\}$ .

Caso base da recursão,  $t = H$ : observe que assume-se dispor da decisão do estágio anterior,  $x^{H-1}$ , e da realização da incerteza em  $t = H$ .

$$\begin{aligned} Q^H(x^{H-1}, \xi^H(\omega)) &= \min c^H(\omega)x^H(\omega) \\ W^H x^H(\omega) &= h^H(\omega) - T^{H-1}(\omega)x^{H-1} \\ x^H(\omega) &\geq 0 \end{aligned}$$

Observe que se dispusermos de  $x^{H-1}$ , basta resolver o PPL acima. Ou seja, podemos ter uma política ótima para qualquer  $x^{H-1}$  de entrada.

Para  $t = 1, \dots, H - 1$ , desejamos conhecer o estado  $x^t(\omega)$ .

$$\begin{aligned} Q^t(x^{t-1}, \xi^t(\omega)) &= \min c^t(\omega)x^t(\omega) + Q^{t+1}(x^t) \quad (4) \\ W^t x^t(\omega) &= h^t(\omega) - T^{t-1}(\omega)x^{t-1} \\ x^t(\omega) &\geq 0 \end{aligned}$$

onde a função recurso é definida como:

$$Q^{t+1}(x^t) = \mathbb{E}_{\xi^{t+1}} [Q^{t+1}(x^t, \xi^{t+1}(\omega))]$$

**Estrutura ótima explorada na recursão (4) (Princípio de Optimalidade):**  
 Não sabemos se  $x^{t-1}$  é o estado ótimo do estágio  $t - 1$ . Porém, ao minimizar  $c^t(\omega)x^t(\omega) + Q^{t+1}(x^t)$  (note a natureza das duas parcelas), tomamos a decisão ótima caso a política ótima para o estágio anterior seja de fato  $x^{t-1} \dots$

Desejamos resolver o programa abaixo, que tem a forma do PDE de um Problema Estocástico Linear em dois estágios.

### PDE do problema estocástico linear multi-estágio

$$\begin{aligned} \min \quad z &= \min c^1 x^1 + \mathcal{Q}^2(x^1) \\ W^1 x^1(\omega) &= h^1 \\ x^1 &\geq 0 \end{aligned}$$


De forma análoga ao que fizemos para o caso de 2 estágios, vamos definir o conjunto de viabilidade do  $t$ -ésimo estágio como:

$$K^t = \{x^t \in \mathbb{R}^{n_t} : \mathcal{Q}^{t+1}(x^t) < \infty\}$$

### Teorema

Os conjuntos  $K^t$  e as funções  $\mathcal{Q}^{t+1}(x^t)$  são convexas para  $t = 1, \dots, H-1$  e, se o conjunto suporte  $\Xi^t$  é finito para todo  $t = 1, \dots, H$ , então  $K^t$  e  $\mathcal{Q}^{t+1}(x^t)$  são poliedrais.

7 cenários possíveis - folhas da árvore:  $\{A, B, C, D, E, F, G\}$



# Estrutura matricial do PDE equivalente

"Primeira parte" da matriz (colunas/linhas do 1o. ao 3o. estágio)

Est. Nº	1o.	2o.	3o.			
1o. O	$x^1$	$x^2(\omega^L)$	$x^2(\omega^M)$	$x^3(\omega^H)$	$x^3(\omega^I)$	$x^3(\omega^J)$
2o. L		$T^1$		$W^2$		
2o. M		$T^1$			$W^2$	
3o. H			$T^2(\omega^L)$		$W^3$	
3o. I			$T^2(\omega^L)$			$W^3$
3o. J				$T^2(\omega^M)$		$W^3$
3o. K				$T^2(\omega^M)$		$W^3$

"Segunda parte" da matriz (colunas do 3o. ao 4o. estágio), linhas do 4o. estágio.

Est. Nº	3o.	4o.			
4o. A	$x^3(\omega^H)$	$x^3(\omega^I)$	$x^3(\omega^J)$	$x^3(\omega^K)$	$x^4(\omega^A)$
4o. B	$T^3(\omega^H)$				$W^4$
4o. C	$T^3(\omega^H)$				$W^4$
4o. D		$T^3(\omega^I)$			$W^4$
4o. E		$T^3(\omega^J)$			$W^4$
4o. F			$T^3(\omega^K)$		$W^4$
4o. G			$T^3(\omega^K)$		$W^4$

- Os problemas de Programação Estocástica Multi-estágios com suporte finito são programas lineares muito grandes. Dependendo do número de cenários, torna-se difícil carregar estes modelos no computador. Assim, algum algoritmo de decomposição precisa ser utilizado para resolver tais problemas.
- A decomposição explora a **estrutura bloco diagonal da matriz de restrições**.

### Impacto da estrutura bloco-diagonal

Assuma que  $v$  seja um nó no estágio  $e(v)$  da árvore de cenários e que seus sucessores na árvore sejam  $c_i(v) : i = 1, \dots, nc_v$ . Obter o estado  $x^{e(v)+1}(w^{c_i(v)})$  para  $i = 1, \dots, nc_v$  dado o estado  $x^{e(v)}(w^{e(v)})$ , pode ocorrer em paralelo, uma vez que a função objetivo também é desacoplada.

Um conjunto de políticas ótimas a serem adotadas, para cada estado do mundo ao longo dos  $H$  estágios.

- Programas estocásticos são **computacionalmente caros**.
- É comum resolver alternativas mais baratas para tentar evitar este custo:
  - Resolver um **problema determinístico formulado com a expectativa das variáveis aleatórias**.
  - Resolver vários problemas determinísticos, cada um deles **formulado com um dos cenários possíveis**, combinando as soluções obtidas por meio de alguma regra heurística.

Questão que se coloca - nosso objeto de estudo.

- **Estas soluções alternativas são de boa qualidade ou são absolutamente imprecisas e desinformadas ?**
- A resposta para estas questões qualitativas é dada por duas grandezas principais: **O valor esperado da informação perfeita (EVPI) e o valor da solução estocástica. (VSS)**

A incerteza é representada por um vetor de variáveis aleatórias  $\xi$ .

Para um dado  $\xi \in \Xi$

$$\min z(x, \xi) = c^T x + \min\{q^T y : Wy = h - Tx, y \geq 0\} \quad (5)$$

$$s.t. \quad Ax = b$$

$$x \geq 0$$

Hipóteses:

- Para todo  $\xi \in \Xi$ ,  $K_1 \cap K_2(\xi) \neq \emptyset$ .
- Vamos designar por  $\bar{x}(\xi)$  a solução ótima de (5) para um  $\xi \in \Xi$ .

### Recordando

$$RP = \min_x \mathbb{E}_\xi[z(x, \xi)]$$

$$WS = \mathbb{E}_\xi[z(\bar{x}(\xi), \xi)]$$

RP é o valor ótimo do Programa Estocástico. WS é o valor esperado das soluções *wait-and-see*.

### Expected Value of Perfect Information (min)

Mede quanto um tomador de decisão racional se disporia a pagar por informação completa e precisa sobre o futuro.

$$EVPI = RP - WS$$

## Recordando

$$\bar{\xi} = \mathbb{E}(\xi)$$

$$EV = \min_x z(x, \bar{\xi})$$

$$EEV = \mathbb{E}_{\xi}[z(\bar{x}(\bar{\xi}), \xi)]$$

$$VSS = EEV - RP$$

## Valor da solução estocástica (min)

EEV mede o desempenho solução do problema determinístico formulado com a expectativa da variável aleatória,  $\bar{x}(\bar{\xi})$ ). Quanto o desempenho é muito bom, VSS é pequeno, ou seja, não resolver o problema estocástico e obter RP não traz tanto valor adicional.

## Proposição

$$WS \leq RP \leq EEV$$

## Prova

Denote por  $x^*$  a solução ótima de RP. Para um dado  $\xi \in \Xi$  temos:  $z(\bar{x}(\xi), \xi) \leq z(x^*, \xi)$ . Tome a expectativa em ambos os lados e a desigualdade esquerda segue. Para mostrar a desigualdade à direita, basta lembrar que  $x^*$  é a solução ótima de RP enquanto  $\bar{x}(\bar{\xi})$  é apenas uma solução viável para RP.

Os exemplos que discutimos na introdução sugerem que EVPI e VSS normalmente sejam distintos. Vamos discutir relações entre estas grandezas.

## Proposição

- ① Para qualquer programa estocástico,  $EVPI \geq 0$ ,  $VSS \geq 0$ .
- ② Para programas estocásticos com matriz de recurso fixa ( $W$ ) e função objetivo fixa ( $q$  não é estocástico), temos:

$$EVPI \leq EEV - EV$$

$$VSS \leq EEV - EV.$$

Observe que apresentamos o mesmo limite superior,  $EEV - EV$  para  $EVPI$  e  $VSS$ . Naturalmente, se  $EEV = EV$ ,  $VSS = EVPI = 0$ .

$$\mathbb{E}_{\xi}[\min z(\bar{x}(\bar{\xi}), \xi)] = \min_x z(x, \bar{\xi})$$

- Uma condição suficiente (óbvia) para que isto ocorra é que  $\bar{x}(\xi)$  seja independente de  $\xi$ , ou seja, a solução ótima é insenível aos cenários.
- Neste caso, obter a solução ótima  $x(\xi)$  para um cenário  $\xi \in \Xi$  ou para  $\xi = \bar{\xi}$  fornece o mesmo resultado e não há necessidade de se resolver o problema RP. É bastante raro isto acontecer.
- Possibilidades de investigação: Relações entre  $EVPI$  e  $VSS$  e classes de problemas para os quais se espera que  $EVPI$  seja pequeno.

Considere o problema

$$z(x, \xi) = x_1 + 4x_2 + \min \{ y_1 + 10y_2^+ + 10y_2^- \quad (6)$$

$$y_1 + (y_2^+ - y_2^-) = \xi + x_1 - 2x_2$$

$$y_1 \leq 2$$

$$y \geq 0 \}$$

$$s.t. \quad x_1 + x_2 = 1$$

$$x \geq 0$$

e que  $\xi$  assuma uma distribuição uniforme em  $[1, 3]$  e, assim  $\bar{\xi} = 2$ .  
 Veja que  $y_2 = (y_2^+ - y_2^-)$  denota a (variável artificial) violação da restrição.

Para um dado  $x \in K_1$  e  $\xi \in U[1, 3]$ , podemos concluir:

$$y^*(x, \xi) = \begin{cases} y_1 = \xi + x_1 - 2x_2, \quad y_2 = 0 & \text{se } 0 \leq \xi + x_1 - 2x_2 \leq 2 \\ y_1 = 2, \quad y_2^+ = \xi + x_1 - 2x_2 & \text{se } \xi + x_1 - 2x_2 > 2 \\ y_1 = 0, \quad y_2^- = 2x_2 - \xi - x_1 & \text{se } \xi + x_1 - 2x_2 < 0 \end{cases}$$

$$z(x, \xi) = \begin{cases} 2x_1 + 2x_2 + \xi & \text{se } 0 \leq \xi + x_1 - 2x_2 \leq 2 \\ -18 + 11x_1 - 16x_2 + 10\xi & \text{se } \xi + x_1 - 2x_2 > 2 \\ -9x_1 + 24x_2 - 10\xi & \text{se } \xi + x_1 - 2x_2 < 0 \end{cases}$$

Observações, lembrando que  $\xi \in U[1, 3]$ ,  $\bar{\xi} = 2$ :

- Usando o fato de que  $x \in K_1 \iff x_1 + x_2 = 1, x \geq 0$ , temos que  $z(x, \xi) = 2 + \xi$  para o primeiro caso ( $y_2 = 0$ ) e  $z(x, \xi) \geq 2 + \xi$  para os demais ( $y_2 \neq 0$ ).
- O mínimo ocorre em  $z(x, \xi) = 2 + \xi$  (para o caso  $y_2 = 0$ ).
- Assim, qualquer  $x \in K_1$  é uma solução ótima de (6), para  $-x_1 + 2x_2 \leq \xi \leq 2 - x_1 + 2x_2$  ou equivalentemente  $2 - 3x_1 \leq \xi \leq 4 - 3x_1$ .
- Observe a multiplicidade de soluções ótimas:  
 $(\frac{1}{3}, \frac{2}{3})$  é ótimo para qualquer  $\xi \in [1, 3]$ ,  
 $(0, 1)$  é ótimo para qualquer  $\xi \in [2, 3]$  e  
 $(1, 0)$  é ótimo para  $\xi = \{1\}$ .
- Tomando  $(\frac{1}{3}, \frac{2}{3})$  como ótimo para qualquer  $\xi$ , temos:  
 $WS = RP = 4$  e  $EVPI = 0$ .

- Ao resolver  $z(x, \xi = 2)$ , podemos tomar outra solução ótima, por exemplo,  $\bar{x}(2) = (0, 1)$  (claro, também com  $EV = 4$ ).
- Com a solução  $\bar{x}(2)$ , calculamos EEV e VSS:

$$\begin{aligned}EEV &= \mathbb{E}_{\xi < 2}(24 - 10\xi) + \mathbb{E}_{\xi \geq 2}(2 + \xi) \\&= \frac{24 - 10(1.5)}{2} + \frac{2 + 2.5}{2} = 6.75\end{aligned}$$

$$VSS = 6.75 - 4 = 2.75$$

- A existência de múltiplas soluções ótimas para PLLs torna este tipo de caso comum.

Considere o mesmo problema definido anteriormente

$$\begin{aligned} z(x, \xi) = & \color{blue}{x_1 + 4x_2} + \min \{ y_1 + 10y_2^+ + 10y_2^- \\ & y_1 + (y_2^+ - y_2^-) = \xi + \color{red}{x_1 - 2x_2} \\ & y_1 \leq 2 \\ & y \geq 0 \} \\ \text{s.t. } & \color{blue}{x_1 + x_2 = 1} \\ & \color{blue}{x \geq 0} \end{aligned}$$

onde  $\xi$  assume uma distribuição discreta em  $\{0, \frac{3}{2}, 3\}$ , equiprováveis, e assim  $\bar{\xi} = 1\frac{1}{2}$ .

$$z(x, \xi) = \begin{cases} 2x_1 + 2x_2 + \xi & \text{se } 0 \leq \xi + x_1 - 2x_2 \leq 2 \\ -18 + 11x_1 - 16x_2 + 10\xi & \text{se } \xi + x_1 - 2x_2 > 2 \\ -9x_1 + 24x_2 - 10\xi & \text{se } \xi + x_1 - 2x_2 < 0 \end{cases}$$

- $\bar{x}(0) = \{x : x_1 + x_2 = 1, \frac{2}{3} \leq x_1 \leq 1\}$ .
- $\bar{x}(\frac{3}{2}) = \{x : x_1 + x_2 = 1, \frac{1}{6} \leq x_1 \leq \frac{5}{6}\}$ .
- $\bar{x}(3) = \{x : x_1 + x_2 = 1, 0 \leq x_1 \leq \frac{1}{3}\}$ .
- Tomando  $\bar{x}(\frac{3}{2}) = (\frac{2}{3}, \frac{1}{3})$ ,  $EV = z(\bar{x}, \frac{3}{2}) = 2 + \frac{3}{2} = 3.5$  e  $EEV = \frac{1}{3}(2 + 3.5 + 14) = 6.5$ .
- Observe que não há interseção para os três intervalos acima. Logo, como não há uma solução que seja ótima para todos os casos, esperamos observar  $EVPI \neq 0$ .

$$z(x, \xi) = \begin{cases} 2x_1 + 2x_2 + \xi & \text{se } 0 \leq \xi + x_1 - 2x_2 \leq 2 \\ -18 + 11x_1 - 16x_2 + 10\xi & \text{se } \xi + x_1 - 2x_2 > 2 \\ -9x_1 + 24x_2 - 10\xi & \text{se } \xi + x_1 - 2x_2 < 0 \end{cases}$$

- Obtendo o valor de WS:

$$WS = \frac{1}{3}(2 + 0) + \frac{1}{3}\left(\frac{7}{2}\right) + \frac{1}{3}(1 + 4) = 3.5$$

- Resolvendo o RP, obtemos:  $x^* = \left(\frac{2}{3}, \frac{1}{3}\right)$  e  $RP = 6.5$ .
- Logo:  $EV = WS = 3.5 \leq RP = 6.5$ ,  $EVPI = 6.5 - 3.5 = 3.0$  e  $VSS = 0$ .

Quando *EVPI* ou *VSS* assumem valores grandes.

Se ambos os valores são pequenos, não há estímulo para se obter RP, através da resolução de um programa estocástico, de elevado custo computacional:

- ① Se *VSS* é alto, usar a solução de *EV* é muito caro, comparada à solução do programa estocástico, *RP*. Por outro lado, se *VSS* é pequeno, a solução com a incerteza média  $\xi$  funciona bem.
- ② Se *EVPI* é baixo, a incerteza é pouco significante, uma vez que esperar para ver o que acontece e então decidir não é muito melhor do que decidir com base nos cenários que se vislumbram.

## Intuitivamente...

- ① Resolver um problema estocástico parece fazer mais sentido quando há mais aleatoriedade nos dados.
- ② Isto nos faz pensar que EVPI e VSS devem crescer quando a variância das variáveis aleatórias do problema cresce.
- ③ Mas isso pode não ser o caso, como o exemplo a seguir demonstra.

- $x \in \mathbb{R}$  é a única variável do problema
- $\xi$  assume apenas dois valores  $\xi_1, \xi_2$  de forma que  $\bar{\xi} = \frac{1}{2}$ .
- Considere o seguinte problema:

$$\begin{aligned} \min \quad & 6x + 10\mathbb{E}_\xi|x - \xi| \\ \text{s.t.} \quad & x \geq 0 \end{aligned}$$

## Caso base

$$\xi_1 = \frac{1}{3}, \xi_2 = \frac{2}{3}, p_1 = p_2 = \frac{1}{2}. \text{Var}(\xi) = \frac{1}{36}$$

## Problema Determinístico Equivalente

$$\min f(x) = 6x + 10 \frac{1}{2} \left( |x - \frac{1}{3}| + |x - \frac{2}{3}| \right) : x \geq 0$$

## Reformulando o PDE

$$\min f(x) = \begin{cases} -4x + 5 & x \in [0, \frac{1}{3}] \\ 6x + \frac{5}{3} & x \in [\frac{1}{3}, \frac{2}{3}] \\ 16x - 5 & x \geq \frac{2}{3} \end{cases}$$

$$\min f(x) = \begin{cases} -4x + 5 & x \in [0, \frac{1}{3}] \\ 6x + \frac{5}{3} & x \in [\frac{1}{3}, \frac{2}{3}] \\ 16x - 5 & x \geq \frac{2}{3} \end{cases} \quad \text{Solução do PDE:}$$

$$x^* = \frac{1}{3}, RP = 3\frac{2}{3}.$$

- $\bar{x}(\frac{1}{3}) = \frac{1}{3}, f(\bar{x}(\frac{1}{3})) = 2$  e  $\bar{x}(\frac{2}{3}), f(\bar{x}(\frac{2}{3})) = 4$ , WS =  $\frac{1}{2}(2 + 4) = 3$
- EVPI = RP - WS =  $\frac{2}{3}$
- $\bar{\xi} = \frac{1}{2}, \bar{x}(1/2) = 1/2, EV = 3.$
- EEV =  $\frac{1}{2}(\frac{28}{6} + \frac{28}{6}) = \frac{28}{6}$
- VSS =  $3\frac{2}{3} - \frac{28}{6} = 1$

Caso #2 - cresce variância em relação ao caso base.

$$\xi_1 = 0, \xi_2 = 1, p_1 = p_2 = \frac{1}{2}. \text{Var}(\xi) = \frac{1}{4}$$

- EVPI = 2
- VSS = 3

Tanto EVPI quanto VSS crescem com o aumento de variância, em relação ao caso base.

Caso #3 - decresce variância em relação ao Caso #2

$$\xi_1 = 0, \xi_2 = \frac{5}{8} \text{ e } p_1 = 0.2, p_2 = 0.8. \text{Var}(\xi) = \frac{1}{16}$$

- EVPI = 2
- VSS = 0

O EVPI cresceu em relação ao caso base, com variância maior.

Porém, VSS = 0 e se este resultado fosse previamente conhecido, a resolução do problema estocástico poderia ser evitada, resolvendo-se o determinístico formulado para  $\bar{\xi} = \mathbb{E}_{\xi}$ .

Caso #4 - decresce variância em relação ao caso base.

$\xi_1 = 0.4, \xi_2 = 0.8, p_1 = 0.75, p_2 = 0.25. \text{Var}(\xi) = 0.03$

- EVPI = 0.4
- VSS = 1.1

Comportamento inverso ao observado no caso imediatamente anterior, em relação ao caso base: redução em EVPI e incremento em VSS, com a redução de variância.

Observações:

- Um programa estocástico mais difícil (envolvendo variáveis inteiras no primeiro e/ou segundo estágio) não necessariamente produz valores maiores de EVPI e VSS - Exercício 3 §1.1.
- Não é fácil obter uma regra geral para o comportamento de EVPI e VSS.

- Vamos assumir que a **única variável aleatória** é o vetor  $h$ , isto é,  $\xi = h(\omega)$  e que  $\Xi$  é **finito**.  $\xi^1, \dots, \xi^K$  indicam as possíveis realizações de  $\xi$ , com probabilidades  $p^k : k = 1, \dots, K$ .
- Dizemos que o cenário  $k$  corresponde à realização  $\xi^k$  de  $\xi$ .

### Cenários de referência, $\xi^r$

- Para refinar os limites superiores, vamos empregar o **conceito de cenários de referência**. Dois possíveis são:
  - $\bar{\xi} = \mathbb{E}_\xi$ , a **esperança de  $\xi$** .
  - **O cenário de pior caso**, por exemplo, o cenário no qual a maior demanda deve ser atendida. O cenário de pior caso é fácil de ser determinado se as entradas de  $\xi$  são independentes. Caso contrário, não é trivial encontrá-lo.
- Observe que nos dois casos, **os cenários de referência podem não ser cenários em  $\Xi$** .
- Definimos  $p^r = P(\xi = \xi^r)$ . **Se o cenário de referência não é um cenário no suporte  $\Xi$ ,  $p^r = 0$** .

Dado um cenário de referência  $\xi^r$  e um cenário  $\xi^k \in \Xi$ , definimos o subproblema correspondente ao par de cenários:

$$\min z^P(x, \xi^r, \xi^k) = c^T x + p^r q^T y(\xi^r) + (1 - p^r) q^T y(\xi^k)$$

$$s.t. \quad Ax = b$$

$$Wy(\xi^r) = \xi^r - Tx$$

$$Wy(\xi^k) = \xi^k - Tx$$

$$x, y \geq 0$$

- ① O programa acima pode ser entendido como um PDE com dois cenários apenas, com probabilidades  $p^r$  e  $1 - p^r$ .
- ② Assumimos que  $(\bar{x}^k, \bar{y}^k, y(\xi^k))$  represente uma solução ótima para o subproblema associado ao par  $\xi^r, \xi^k$  e  $z_k = z^P(\bar{x}^k, \bar{y}^k, y(\xi^k))$ , sua fo ótima.

- 1  $z^P(x, \xi^r, \xi^r) = z(x, \xi^r)$ , isto é, quando  $\xi^r = \xi^k$ , o problema de par de cenários é o PDE em que há apenas o cenário de referência.
- 2 Se  $\xi^r \notin \Xi$ ,  $P(\xi = \xi^r) = 0$  e  $z^P(x, \xi^r, \xi^k) = z(x, \xi^k)$ .

## Definição

Vamos definir SPEV como a *soma dos pares de valores esperados*:

$$SPEV = \frac{1}{1 - p^r} \sum_{k=1, \xi^k \neq \xi^r}^k p^k \min z^P(x, \xi^r, \xi^k)$$

Veja que SPEV é um conceito que faz sentido mesmo se  $\xi^r \notin \Xi$ , neste caso, não sendo um conceito novo....

## Proposição

Se  $\xi^r \notin \Xi$ ,  $SPEV = WS$ .

## Prova:

$\xi^r \notin \Xi \rightarrow p^r = 0$  e  $z^P(x, \xi^r, \xi^k) = z(x, \xi^k)$ . Então:

$$SPEV = \sum_{k=1, \xi^k \neq \xi^r}^K p^k \min z^P(x, \xi^r, \xi^k) =$$

$$\sum_{k=1, \xi^k \neq \xi^r}^K p^k \min z(x, \xi^k) = WS, \text{ pela definição de } WS.$$

## Proposição

$$WS \leq SPEV \leq RP.$$

Prova - primeira parte:  $WS \leq SPEV$

- $SPEV = \sum_{k=1, \xi^k \neq \xi^r}^K p^k \left( \frac{c^T \bar{x}^k + p^r q^T \bar{y}^k + (1-p^r) q^T y(\xi^k)}{1-p^r} \right)$  onde  $(\bar{x}^k, \bar{y}^k, y(\xi^k))$  é uma solução ótima para o subproblema do par  $\xi^r, \xi^k$ .
- Pela definição do par de subproblemas, o vetor  $(\bar{x}^k, \bar{y}^k)$  é viável para o problema  $z(x, \xi^r)$ , de forma que:  

$$c^T \bar{x} + q^T \bar{y}^k \geq \min z(x, \xi^r) = z_r^*$$
- Vamos escrever  $c^T \bar{x} = p^r c^T \bar{x} + (1-p^r) c^T \bar{x}$  e reescrever  $SPEV$  como  $SPEV = \sum_{k=1, \xi^k \neq \xi^r}^K \frac{p^k [p^r (c^T \bar{x}^k + q^T \bar{y}^k) + (1-p^r) (c^T \bar{x}^k + q^T y(\xi^k))]}{1-p^r}$
- Definimos  $z_k^* = \min z(x, \xi^k)$ .

Prova - primeira parte:  $WS \leq SPEV$  (continua)

$$\begin{aligned}
 SPEV &= \sum_{k=1, \xi^k \neq \xi^r}^K \frac{p^k [p^r(c^T \bar{x}^k + q^T \bar{y}^k) + (1 - p^r)(c^T \bar{x}^k + q^T y(\xi^k))]}{1 - p^r} \\
 &\geq \sum_{k=1, \xi^k \neq \xi^r}^K \frac{p^k p^r z_r^*}{1 - p^r} + \sum_{k=1, \xi^k \neq \xi^r}^K p^k (c^T \bar{x}^k + q^T y(\xi^k)) \\
 &= p^r z_r^* + \sum_{k=1, \xi^k \neq \xi^r}^K p^k (c^T \bar{x}^k + q^T y(\xi^k)) \\
 &\geq p^r z_r^* + \sum_{k=1, \xi^k \neq \xi^r}^K p^k z_k^* \\
 &= WS
 \end{aligned}$$

Prova - segunda parte:  $SPEV \leq RP$ 

- Definimos  $x^*, y^*(\xi^k) : k = 1, \dots, K$  a solução ótima de RP.
- Por simplicidade, assumimos que  $\xi^r \in \Xi$  (isso não reduz a generalidade).
- $(x^*, y^*(\xi^r), y^*(\xi^k))$  é viável para o par  $\xi^r, \xi^k$  de subproblemas.  
Logo:

$$c^T \bar{x}^k + p^r q^T \bar{y}^k + (1-p^r) q^T y(\xi^k) \leq c^T x^* + p^r q^T y^*(\xi^r) + (1-p^r) q^T y^*(\xi^k)$$

- Multiplicando cada desigualdade acima para todo  $k : \xi^k \neq \xi^r$  com peso  $p^k$  e somando, obtemos a desigualdade

$$(1 - p^r) SPEV \leq \sum_{k=1, \xi^k \neq \xi^r}^K p^k (c^T x^* + p^r q^T y^*(\xi^r) + (1 - p^r) q^T y^*(\xi^k))$$

Prova - segunda parte:  $SPEV \leq RP$  (continua)

$$\begin{aligned}
 (1 - p^r)SPEV &\leq \sum_{k=1, \xi^k \neq \xi^r}^K p^k (c^T x^* + p^r q^T y^*(\xi^r) + (1 - p^r)q^T y^*(\xi^k)) \\
 &= (c^T x^* + p^r q^T y^*(\xi^r)) \sum_{k=1, \xi^k \neq \xi^r}^K p^k + \sum_{k=1, \xi^k \neq \xi^r}^K p^k (1 - p^r)q^T y^*(\xi^k) \\
 &= (1 - p^r)(c^T x^* + p^r q^T y^*(\xi^r)) + \sum_{k=1, \xi^k \neq \xi^r}^K p^k (1 - p^r)q^T y^*(\xi^k) \\
 &= (1 - p^r)(c^T x^* + \sum_{k=1}^K p^k q^T y^*(\xi^k)) \\
 &= (1 - p^r)RP \quad \square
 \end{aligned}$$

- Seja  $z(x, \xi^r)$  o problema determinístico formulado com o cenário de referência que, como discutimos, pode não ser um cenário possível (no suporte).
- Definimos  $\bar{x}^r \in \arg \min_x z(x, \xi^r)$

## EVRS e (re)definição de VSS

O *expected value of reference scenario (EVRS)* é definido como

$$EVRS = \mathbb{E}_{\xi} z(\bar{x}^r, \xi)$$

e a partir dele generalizamos o VSS como

$$VSS = EVRS - RP.$$

Veja que o conceito de VSS coincide com o anteriormente dado caso  $\xi^r = \bar{\xi}$ . Independentemente disso,  $VSS \geq 0$ , pois se  $\bar{x}^r$  for viável (para  $\xi^k$ ),  $z(\bar{x}^r, \xi^k)$  fornece um limite superior para o recurso associado a  $k$  e  $EVRS \geq RP$ . Caso contrário, sendo inviável,  $EVRS = \infty$ .

- Assim como antes,  $(\bar{x}^k, \bar{y}^k, y(\xi^k))$  denota uma solução ótima para o par de subproblema  $\xi^r, \xi^k$ .
- Definimos (*expectations of pairs expected value*)

$$EPEV := \min_{k=1, \dots, K \cup \{r\}} \mathbb{E}_{\xi} z(\bar{x}^k, \xi)$$

### Proposição

$$RP \leq EPEV \leq EVRS$$

### Prova

Os três valores são o resultado ótimo para a função recurso  $\min_x \mathbb{E}_{\xi} z(x, \xi)$  em sucessivas relaxações do domínio. Veja que o domínio de RP é  $x \in K_1 \cap K_2$ , o domínio de EPEV é  $\{\bar{x}^k : k = 1, \dots, K \cup \{r\}\} \subseteq K_1 \cap K$  e, o domínio de EVRS é  $\bar{x}^r$ .

## Corolário

$$0 \leq EVRS - EPEV \leq VSS \leq EVRS - SPEV \leq EVRS - WS$$

Exemplo ilustrando caso onde WS e EEV são inconclusivos.

$$\begin{aligned} \min \quad & 3x_1 + 2x_2 + \mathbb{E}_\xi \min(-15y_1 - 12y_2) \\ \text{s.t.} \quad & 3y_1 + 2y_2 \leq x_1 \\ & 2y_1 + 5y_2 \leq x_2 \\ & .8\xi_1 \leq y_1 \leq \xi_1 \\ & .8\xi_2 \leq y_2 \leq \xi_2 \\ & x, y \geq 0 \end{aligned}$$

onde  $\xi_1 \in \{4, 6\}$  e  $\xi_2 \in \{4, 8\}$ , com distribuições independentes, com probabilidade 0.5 para cada um dos casos.

### Interpretação do problema

$x_1, x_2$  podem ser vistos como decisões de investimentos em dois ativos distintos, tomados hoje, que serão necessários em um segundo estágio, para cobrir 80% de uma certa demanda incerta,  $\xi_1, \xi_2$ .

Cenário	Solução		fo ótima $z(\bar{x}(\xi), \xi)$
	$x$ : 1o. estágio	$y$ : 2o. estágio	
1. (4,4)	(18.4,24)	(4,3.2)	4.8
2. (6,4)	(24.4,28)	(6,3.2)	0.8
3. (4,8)	(24.8,40)	(4,6.4)	17.6
4. (6,8)	(30.8,44)	(6,6.4)	13.6

$$\bar{\xi} = (5, 6) \quad (24.6, 34) \quad (5, 4.8) \quad EV = 9.2$$

- A solução  $\bar{x}(\bar{\xi}) = (24.6, 34)$  é inviável para o programa estocástico (cenário 4,  $\xi_1 = 6, \xi_2 = 8$ ). Logo  $EEV = +\infty$ .
- $WS = \frac{1}{4}(4.8 + 0.8 + 17.6 + 13.6) = 9.2$
- $WS = EV = 9.2$
- $EV = WS = 9.2 \leq RP \leq EEV \leq +\infty$ .
- Conclusões óbvias (inúteis):  $0 \leq EVPI \leq +\infty$  e  $0 \leq VSS \leq +\infty$

- Em casos como o do exemplo, a investigação dos pares de subproblemas gera informação relevante.
- Vamos tomar como caso de referência o pior caso,  $\xi^r = (6, 8)$ , quando a demanda é máxima (e não a demanda média).
- Este cenário foi escolhido uma vez que trata-se de um problema de atendimento de demanda, faz mais sentido para a aplicação.
- O caso de referência é um dos cenários previstos, o cenário 4. Portanto,  $p^r = \frac{1}{4}$ .

$$\min 3x_1 + 2x_2 - \frac{1}{4}(15y_1^r + 12y_2^r) - \frac{3}{4}(15y_1^k + 12y_2^k)$$

$$3y_1^r + 2y_2^r \leq x_1$$

$$2y_1^r + 5y_2^r \leq x_2$$

$$3y_1^k + 2y_2^k \leq x_1$$

$$2y_1^k + 5y_2^k \leq x_2$$

$$4.8 \leq y_1^r \leq 6$$

$$6.4 \leq y_2^r \leq 8$$

$$0.8\xi_1^k \leq y_1^k \leq \xi_1^k$$

$$0.8\xi_2^k \leq y_2^k \leq \xi_2^k$$

$$x, y^r, y^k \geq 0$$

Pares de cenários	Solução			fo ótima $z^P$
	$x :$	$y^r :$	$y(\xi^k) :$	
1. (4,4) e $\xi^r$	(27.2,41.6)	(4.8, 6.4)	(4,4)	46.6
2. (6,4) e $\xi^r$	(27.2,41.6)	(4.8, 6.4)	(6,4)	24.1
3. (4,8) e $\xi^r$	(27.2,41.6)	(4.8, 6.4)	(4,6.72)	22.12

- $SPEV = \frac{4}{3} \cdot \frac{1}{4} (46.6 + 24.1 + 22.12) = 30.94$
- $EPEV = \min_k \mathbb{E}_{\xi} z(\bar{x}^k(\xi^k), \xi) = \mathbb{E}_{\xi} z((27.2, 41.6), \xi) = 30.94$
- $EVRS = \mathbb{E}_{\xi} z((30.8, 44), \xi) = 40.6$

Então temos:

$$WS = 9.2 \leq SPEV = 30.94 \leq RP \leq EPEV = 30.94 \leq EVRS = 40.6.$$

Ou seja,  $RP = 30.94$  com  $x = (27.2, 41.6)$  como solução ótima do programa estocástico. Observe que resolvemos RP indiretamente, resolvendo vários PPLs determinísticos, de dimensões muito menores que o PDE.