

Avaliação do Desempenho de Optimizadores Estocásticos

Viviane Grunert da Fonseca

CISUC, Centro de Informática e Sistemas da Universidade de Coimbra

vivianef@dei.uc.pt



4ª Escola Luso-Brasileira de Computação Evolutiva,
Coimbra, 13 de Julho de 2013

Avaliação do Desempenho de

Optimizadores Estocásticos

problema de
otimização
aleatório

condição
inicial
aleatória


estratégia de
procura
aleatória

Optimizadores
Estocásticos (OEs)

Optimização
Estocástica


Exemplos: algoritmos genéticos, estratégias evolutivas, algoritmos de colónias de formigas, simulated annealing, etc.

Avaliação do **Desempenho** de Optimizadores Estocásticos



- O **desempenho** de OEs tem que ver com
 - a **qualidade** dos seus **resultados**, e
 - o **tempo** que é necessário para produzir esses resultados.
(nº de avaliações da função, tempo de CPU, tempo decorrido, etc.)
- Há grande interesse na avaliação do desempenho de OEs. Por exemplo, é comum querer escolher o “melhor” otimizador de entre várias alternativas.
- O que significa **bom desempenho** de um OE?
 - produzir resultados em **pouco tempo**,
 - resultados de **boa qualidade**, ou seja, resultados “**próximos**” do(s) valor(es) **óptimo(s)** da função objectivo.

Avaliação do **Desempenho** de Optimizadores Estocásticos



Questões:

(a) Não se conhece o óptimo no espaço de decisão, nem o(s) valor(es) óptimo(s) da função objectivo!


↪ Problemas de minimização: resultados melhores \equiv valores menores

(b) O desempenho do mesmo OE pode variar em função ...

- da instância do problema de optimização,
- da condição inicial escolhida,
- dos valores dos parâmetros do OE,
- etc.

↪ Delineamento experimental

Avaliação do **Desempenho** de Optimizadores Estocásticos



Para a avaliação do desempenho consideramos **dois cenários**:

Cenário 1 (critério de paragem \Leftrightarrow qualidade dos resultados):

Desempenho \equiv Tempo de Execução

onde o tempo de execução é aleatório e é representado por ...


* uma variável aleatória X em $\mathbb{R}^{\geq 0}$

* com distribuição de probabilidade $F_X = P(X \leq x)$.



Estudar distribuições **univariadas**.

Avaliação do **Desempenho** de Optimizadores Estocásticos



Cenário 2 (critério de paragem \Leftrightarrow tempo de execução):

Desempenho \equiv Qualidade dos Resultados

aleatórios !!



Estudar distribuições de probabilidades

... **univariadas** \longleftrightarrow otimização mono-objectivo

... **multivariadas** ou **ainda mais complexas**
 \longleftrightarrow otimização multi-objectivo

\rightsquigarrow Tema da presente aula!

Estrutura da aula

- Optimizadores mono-objectivo:
 - *Distribuições de resultados e desempenho*
- Optimizadores multi-objectivo:
 - *Distribuições de resultados*
 - *A abordagem da função de aproveitamento*
 - *A abordagem dos indicadores de qualidade*
- Notas finais

Optimizadores mono-objectivo



Vamos considerar os resultados de OEs produzidos no espaço dos objectivos após um determinado tempo de execução, i.e. Cenário 2.



No entanto, a discussão que se segue também se aplica a qualquer distribuição de tempo de execução, i.e. Cenário 1.

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

- O valor mínimo da função objectivo é um escalar $x^* \in \mathbb{R}$.
- Cada execução do OE produz um resultado aleatório que é representado por uma variável aleatória X em \mathbb{R} com realizações $z \in [x^*, \infty)$.
- A distribuição de resultados é uma distribuição *univariada*, discreta ou contínua, com suporte em $\mathbb{R}^{\geq x^*}$ que pode ser caracterizada pela **função de distribuição**


$$F_X(z) = P(X \leq z)$$

onde $F_X(z) = 0$ se $z \in (-\infty, x^*)$.


Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

- Os resultados são de melhor qualidade quando a sua distribuição se concentra mais perto do valor mínimo $x^* \in \mathbb{R}$ da função objectivo ...



função de densidade



função de distribuição

↪ Os resultados com a distribuição a **vermelho** são de melhor qualidade.

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

... , ou seja, quanto ...

- (a) menor no sentido estocástico for a variável aleatória X , ou ainda, quanto maior $F_X(z)$ para todo o $z \geq x^*$.

$$\left[\text{caso "ideal": } F_X(z) = \mathbf{I}\{z \geq x^*\} \right]$$

- (b) menor o valor de uma **medida de localização**, tal como:

- *média*: $\mu = E(X) \geq x^*$
- *mediana*: $x_{0.5} \geq x^*$ onde $P(X \leq x_{0.5}) = 0.5$
- *α -quantil*: $x_\alpha \geq x^*$ onde $P(X \leq x_\alpha) = \alpha$

$$\left[\text{casos "ideais": } \mu = x_{0.5} = x_\alpha = x^* \right]$$

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

(c) menor o valor de uma **medida de dispersão**, tal como:

- *variância*: $\sigma^2 = \text{Var}(X) \geq 0$
- *amplitude interquartil*: $x_{0.75} - x_{0.25} \geq 0$

[casos “ideais”: $\sigma^2 = x_{0.75} - x_{0.25} = 0$]



Não faz sentido considerar o critério (c) sem ter em conta o critério (b).



A média é o *1º momento não-centrado* de uma distribuição e a variância é o *2º momento centrado* de uma distribuição.

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

Problema

$F_X(\cdot)$ e as medidas de localização/dispersão são desconhecidas!

Análise inferencial – Estimação

A função $F_X(\cdot)$ e as medidas de localização/dispersão podem ser estimadas a partir de ...

- uma *amostra aleatória (simple)* X_1, X_2, \dots, X_n , i.e.
- n variáveis aleatórias independentes com a mesma distribuição, que representam os resultados de n execuções independentes do otimizador.

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

Consideram-se, por exemplo, os seguintes estimadores:

- *função de distribuição empírica:*

$$F_n(z) = \frac{1}{n} \cdot \sum_{i=1}^n I\{X_i \leq z\}$$

- *média amostral:* $\bar{X} = \frac{1}{n} \cdot \sum_{i=1}^n X_i$

- *mediana amostral:*

$$Q_{0.5} = \begin{cases} \frac{1}{2} \cdot [X_{(\frac{n}{2})} + X_{(\frac{n+2}{2})}] & \text{se } n \text{ é par} \\ X_{(\frac{n+1}{2})} & \text{se } n \text{ é ímpar,} \end{cases}$$

onde $X_{(1)}, \dots, X_{(n)}$ são as variáveis aleatórias da amostra ordenada.

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

- *α -quantil amostral:*

$$Q_\alpha = \begin{cases} \frac{1}{2} \cdot [X_{(n \cdot \alpha)} + X_{(n \cdot \alpha + 1)}] & \text{se } n \cdot \alpha \in \mathbb{N} \\ X_{(\lceil n \cdot \alpha \rceil)} & \text{se } n \cdot \alpha \notin \mathbb{N} \end{cases}$$

onde $X_{(1)}, \dots, X_{(n)}$ são as variáveis aleatórias da amostra ordenada.

- *variância amostral:* $S^2 = \frac{1}{n-1} \cdot \sum_{i=1}^n (X_i - \bar{X})^2$
- *amplitude interquartil amostral:* $Q_{0.75} - Q_{0.25}$



Como a distribuição de resultados deve ser **enviesada para a direita**, pode ser preferível considerar a mediana amostral em vez da média amostral e a amplitude interquartil amostral em vez da variância amostral.

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

Testes de hipóteses

Frequentemente, o objectivo é ...

comparar o desempenho de OEs

e, com “sorte” ...

afirmar com certo grau de confiança

que

- o desempenho de dois ou mais OEs é diferente (*nalgum sentido*).
- um OE tem melhor desempenho que outro OE (*nalgum sentido*).

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

Para esse efeito, considere-se um dos seguintes **problemas de teste**:

H_0 : O desempenho de dois ou mais OEs é igual
(nalgum sentido).

v.s.

H_1 : *O desempenho de dois ou mais OEs é diferente*
(nalgum sentido).

H_0 : O desempenho de OE-A não é melhor que o de OE-B
(nalgum sentido).

v.s.

H_1 : *O desempenho de OE-A é melhor que o de OE-B*
(nalgum sentido).

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho



H_1

“Com sorte”, há **evidência estatisticamente significativa** de que ...

- o desempenho de dois ou mais OEs é diferente (*nalgum sentido*).
- O desempenho de OE-A é melhor que o de OE-B (*nalgum sentido*).

Isso é: $P(\text{decisão “rejeitar } H_0\text{” é errada}) \leq \alpha, \quad \alpha \in \{0.01, 0.05\}$

“Com menos sorte”, *não se pode rejeitar H_0* !

... **não** há tal evidência estatística.

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

Testes de hipóteses para OEs “*independentes*”:

| Teste | compara | nº de OEs |
|--------------------|------------------------|------------------|
| Kolmogorov-Smirnov | função de distribuição | dois ou mais |
| Mann-Whitney | mediana | dois |
| Kruskall-Wallis | mediana | três ou mais |
| Brown-Forsythe | variância | dois ou mais |

Testes de hipóteses para OEs “*dependentes*”:

| Teste | compara | nº de OEs |
|--------------|----------------|------------------|
| Wilcoxon | mediana | dois |
| Friedman | mediana | três ou mais |

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

- **Comparações múltiplas** com três ou mais OEs,
 - “*entre todos os pares*”,
 - “*com um controlo*” (OE de referência),
 - “*com o melhor*”,

requerem testes múltiplos com ajustamento de α .

- Considerar diferentes ...
 - instâncias do problema de optimização
 - parâmetros do optimizador,
 - critérios de paragem

requer **métodos de delineamento experimental**.

Optimizadores multi-objectivo



Vamos considerar os resultados de OEs produzidos no espaço dos objectivos após um determinado tempo de execução, i.e. Cenário 2.

Optimizadores multi-objectivo:

Distribuições de resultados


- Os valores mínimos (não-dominados) da função objectivo dão origem a uma *fronteira óptima (de Pareto)* \mathcal{X}^* em \mathbb{R}^d .
- Em cada execução, o otimizador produz múltiplos resultados aleatórios em \mathbb{R}^d que se representam por um **conjunto aleatório de pontos não-dominados** (conjunto APN)

$$\mathcal{X} = \{X_1, \dots, X_M \in \mathbb{R}^d : P(X_i \leq X_j) = 0, i \neq j\},$$

sendo

- X_1, X_2, \dots vectores aleatórios em \mathbb{R}^d e
- M uma variável aleatória em \mathbb{N} .

Optimizadores multi-objectivo: Distribuições de resultados



Características de um conjunto APN \mathcal{X} :


- Os pontos (vectors) x_1, x_2, \dots, x_m de uma realização de \mathcal{X} são **não-dominados no sentido de Pareto**.
- Os vectores aleatórios X_1, X_2, \dots, X_M são **dependentes**.
- \mathcal{X} é fechado e é “não-estacionário”.

Optimizadores multi-objectivo: Distribuições de resultados

Representações alternativas de um conjunto APN \mathcal{X} :


→ o conjunto aleatório fechado
(“conjunto atingido”)

$$\mathcal{Y} = \{z \in \mathbb{R}^d \mid X_1 \leq z \vee \dots \vee X_M \leq z\}$$



→ o campo aleatório binário

$$\{B(z), z \in \mathbb{R}^d\} = \{\mathbf{I}\{z \in \mathcal{Y}\}, z \in \mathbb{R}^d\}$$



Optimizadores multi-objectivo: Distribuições de resultados

- A distribuição de resultados é bastante **complexa** pois compreende
 - as distribuições multivariadas (idênticas) de X_1, X_2, \dots
 - a distribuição univariada discreta de M , e
 - a dependência entre X_1, X_2, \dots

Dado $M \leq m^*$, ou seja, dado que o otimizador não produz mais que m^* resultados por execução, a distribuição de \mathcal{X} pode ser caracterizada pela **função de aproveitamento de ordem m^***

$$\alpha_{\mathcal{X}}^{(m^*)}(z_1, \dots, z_{m^*}) = P(\mathcal{X} \preceq z_1 \wedge \dots \wedge \mathcal{X} \preceq z_{m^*})$$

onde **"atinge" / "domina fracamente"**

$[\mathcal{X} \preceq z]$ significa $[X_1 \leq z \vee X_2 \leq z \vee \dots \vee X_M \leq z]$.

Optimizadores multi-objectivo: Distribuições de resultados

Por palavras, $\alpha_{\mathcal{X}}^{(m^*)}(z_1, \dots, z_{m^*})$ é ...

“a **probabilidade** de atingir todas as metas z_1, \dots, z_{m^*} numa única execução do otimizador”.

- Os resultados do otimizador são de melhor qualidade quando a sua distribuição se concentra mais perto da fronteira óptima \mathcal{X}^* em \mathbb{R}^d ,

... , ou seja, quanto ...

menor **no sentido estocástico** for o conjunto APN \mathcal{X} , ou ainda, quanto maior $\alpha_{\mathcal{X}}^{(m^*)}(z_1, \dots, z_{m^*})$ para todo o vector $z_i \in \mathbb{R}^d$, $\mathcal{X}^* \trianglelefteq z_i$.

Optimizadores multi-objectivo: Distribuições de resultados

A **complexidade** da distribuição dos resultados ...

- torna difícil a sua representação gráfica.
 - ↪ No caso $d = 2$ a função $\alpha_{\mathcal{X}}^{(2)}(z_1, z_2)$ já depende de 2×2 variáveis!
- deu origem a muitos critérios de desempenho para optimizadores multi-objectivo!

Duas principais abordagens

1. **Abordagem da função de aproveitamento** que descreve a distribuição do conjunto APN \mathcal{X} directamente através de uma hierarquia de funções encaixadas, cada vez mais informativas.
2. **Abordagem dos indicadores de qualidade** que transforma o conjunto \mathcal{X} numa variável aleatória em \mathbb{R} e estuda a respectiva distribuição univariada, (geralmente) em termos da sua média.

A abordagem da função de aproveitamento

Optimizadores multi-objectivo:

A abordagem da função de aproveitamento

- O desempenho de um otimizador multi-objectivo é avaliado na sua totalidade através de $\alpha_{\mathcal{X}}^{(m^*)}(z_1, \dots, z_{m^*})$, onde m^* é o número máximo de resultados X_i por execução.
- Uma descrição de tipo “média” da distribuição de \mathcal{X} é possível com a **função de aproveitamento (de ordem 1)**

$$\begin{aligned}\alpha_{\mathcal{X}}^{(1)}(z) &= \alpha_{\mathcal{X}}(z) = P(\mathcal{X} \preceq z) \\ &= P(X_1 \leq z \vee X_2 \leq z \vee \dots \vee X_M \leq z),\end{aligned}$$

ou seja, com a

“probabilidade de atingir cada meta $z \in \mathbb{R}^d$ numa única execução do otimizador”.


Optimizadores multi-objectivo:

A abordagem da função de aproveitamento



Tal como a média μ , a função $\alpha_{\mathcal{X}}(\cdot)$ não descreve a distribuição de \mathcal{X} na sua totalidade — a não ser que $\mathcal{X} = \{X\}$. Nesse caso, $\alpha_{\mathcal{X}}(\cdot)$ reduz-se a uma função de distribuição $F_X(\cdot)$!

→ O caso ideal quanto ao desempenho em termos de $\alpha_{\mathcal{X}}(\cdot)$ é a *função de aproveitamento ideal*: $\alpha_I(z) = \mathbf{I}\{\mathcal{X}^* \preceq z\}$.




Optimizadores multi-objetivo:

A abordagem da função de aproveitamento



Tal como a média μ , a função $\alpha_{\mathcal{X}}(\cdot)$ não descreve a distribuição de \mathcal{X} na sua totalidade — a não ser que $\mathcal{X} = \{X\}$. Nesse caso, $\alpha_{\mathcal{X}}(\cdot)$ reduz-se a uma função de distribuição $F_X(\cdot)$!

→ O caso ideal quanto ao desempenho em termos de $\alpha_{\mathcal{X}}(\cdot)$ é a *função de aproveitamento ideal*: $\alpha_I(z) = \mathbf{I}\{\mathcal{X}^* \preceq z\}$.




Optimizadores multi-objectivo:

A abordagem da função de aproveitamento



Tal como a média μ , a função $\alpha_{\mathcal{X}}(\cdot)$ não descreve a distribuição de \mathcal{X} na sua totalidade — a não ser que $\mathcal{X} = \{X\}$. Nesse caso, $\alpha_{\mathcal{X}}(\cdot)$ reduz-se a uma função de distribuição $F_X(\cdot)$!

→ O caso ideal quanto ao desempenho em termos de $\alpha_{\mathcal{X}}(\cdot)$ é a *função de aproveitamento ideal*: $\alpha_I(z) = \mathbf{I}\{\mathcal{X}^* \preceq z\}$.



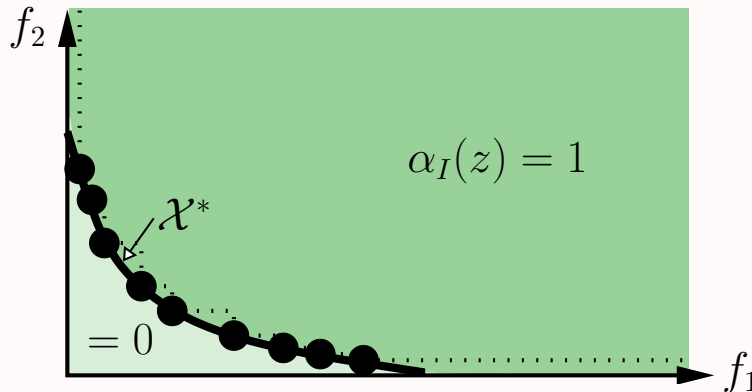
Optimizadores multi-objectivo:

A abordagem da função de aproveitamento



Tal como a média μ , a função $\alpha_{\mathcal{X}}(\cdot)$ não descreve a distribuição de \mathcal{X} na sua totalidade — a não ser que $\mathcal{X} = \{X\}$. Nesse caso, $\alpha_{\mathcal{X}}(\cdot)$ reduz-se a uma função de distribuição $F_X(\cdot)$!

→ O caso ideal quanto ao desempenho em termos de $\alpha_{\mathcal{X}}(\cdot)$ é a *função de aproveitamento ideal*: $\alpha_I(z) = \mathbf{I}\{\mathcal{X}^* \preceq z\}$.



Optimizadores multi-objectivo:

A abordagem da função de aproveitamento


→ Estimação

A função $\alpha_{\mathcal{X}}(\cdot)$, que é desconhecida, pode ser estimada através da *função de aproveitamento empírica*

$$\alpha_n(z) = \frac{1}{n} \cdot \sum_{i=1}^n \mathbf{I}\{\mathcal{X}_i \preceq z\}$$

Ilustração de um caso bi-objectivo ($n = 21$):

Curvas de nível ϵ , 0.25, 0.5, 0.75, e $1 - \epsilon$



Optimizadores multi-objectivo:

A abordagem da função de aproveitamento

→ Teste de hipóteses

Um teste de tipo “Kolmogorov-Smirnov” permite comparar duas funções de aproveitamento de dois optimizadores A e B.

– Problema de teste (bilateral):

$$H_0 : \alpha_{\mathcal{X}_A}(z) = \alpha_{\mathcal{X}_B}(z) \quad \text{para todo o } z \in \mathbb{R}^d$$

v.s.

$$H_1 : \alpha_{\mathcal{X}_A}(z) \neq \alpha_{\mathcal{X}_B}(z) \quad \text{para pelo menos um } z \in \mathbb{R}^d,$$

Optimizadores multi-objectivo:

A abordagem da função de aproveitamento

- Regra de decisão do teste bilateral: Para o nível de significância $\alpha \in (0, 1)$, rejeitar H_0 se

$$D_{n,m} = \sup_{z \in \mathbb{R}^d} |\alpha_n^A(z) - \alpha_m^B(z)| > d_{n,m;1-\alpha},$$

onde $d_{n,m;1-\alpha}$ pode ser aproximado através de simulação (*teste de permutações*).



Também é possível formular testes unilaterais.

Optimizadores multi-objectivo:

A abordagem da função de aproveitamento

- Uma descrição de tipo “mediana” da distribuição de \mathcal{X} é possível através do conjunto

$$V_{0.5} = \{z \in \mathbb{R}^d \mid \alpha_{\mathcal{X}}(z) \geq 0.5\}$$

(*mediana Vorob'ev* do conjunto atingido)

$$\left[\text{caso ideal: } V_{0.5} = \{z \in \mathbb{R}^d \mid \mathcal{X}^* \trianglelefteq z\} \right]$$



Não proporciona mais informação do que a função de aproveitamento $\alpha_{\mathcal{X}}(\cdot)$.

Optimizadores multi-objectivo:

A abordagem da função de aproveitamento

- A descrição de tipo “variância” com a *função de variância*

$$\text{Var}_{\mathcal{X}}(z) = \alpha_{\mathcal{X}}(z) - [\alpha_{\mathcal{X}}(z)]^2$$

também não fornece informação adicional, porque é determinada exclusivamente pela função de aproveitamento $\alpha_{\mathcal{X}}(\cdot)$.

- **Mais informação** sobre a distribuição de \mathcal{X} e, portanto, sobre o desempenho de um otimizador multi-objectivo
 - diz respeito à dependência entre X_1, X_2, \dots, X_M , e
 - é capturada pelas **funções de aproveitamento de ordem ≥ 2** .

Optimizadores multi-objectivo:

A abordagem da função de aproveitamento

Dúvida

- Existem muitas funções de aproveitamento de ordem ≥ 2 ,
(no total: $m^* - 1$)
- e a sua complexidade aumenta gradualmente! ...



... Até que ordem vale a pena considerá-las?

Resposta

Não é claro!

No entanto, é certamente interessante considerar a chamada *função de covariância*.

Optimizadores multi-objectivo:

A abordagem da função de aproveitamento

- Uma descrição de tipo “covariância” da distribuição do conjunto APN \mathcal{X} , baseada na função de aproveitamento de **2ª ordem**, é possível através da *função de covariância*

$$\text{Cov}_{\mathcal{X}}(z_1, z_2) = \alpha_{\mathcal{X}}^{(2)}(z_1, z_2) - \alpha_{\mathcal{X}}(z_1) \cdot \alpha_{\mathcal{X}}(z_2)$$

A função mostra em que regiões do espaço dos objectivos **duas metas** têm tendência a ser ...

- atingidas conjuntamente, na mesma execução do optimizador.

↔ **covariância positiva**

- atingidas em alternativa uma à outra, na mesma execução do optimizador.

↔ **covariância negativa**

Optimizadores multi-objectivo:

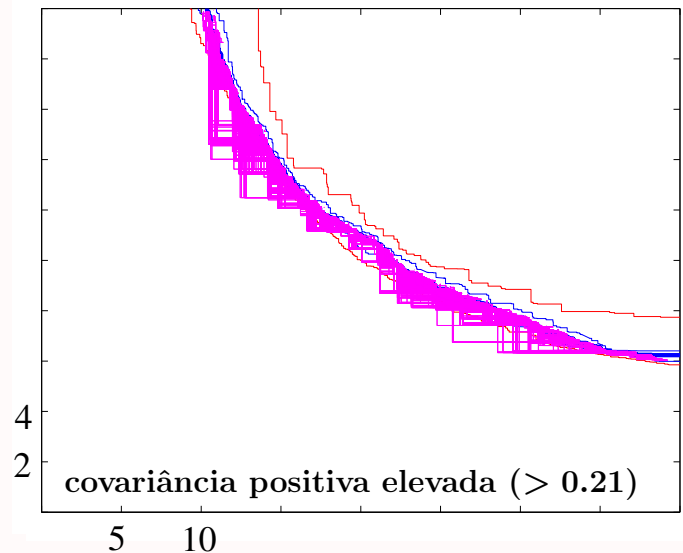

A abordagem da função de aproveitamento



A função $\text{Cov}_{\mathcal{X}}(\cdot, \cdot)$ tem o valor **Zero**, quando ...

- as duas metas podem ser atingidas independentemente.
- uma das duas metas nunca é atingida (ou ambas são sempre).

Ilustração da função de covariância empírica:



Optimizadores multi-objectivo:

A abordagem da função de aproveitamento

→ Casos “não-ideais”:

– Covariância **positiva** entre metas **distantes**.

⇒ Em cada execução, o otimizador aproxima toda a fronteira \mathcal{X}^* de maneira equilibrada, umas vezes melhor que outras.

– Covariância **negativa** entre metas **distantes**.

⇒ Em cada execução, o otimizador aproxima apenas uma região (pequena) da fronteira \mathcal{X}^* , diferente em cada execução.





A covariância é sempre positiva para duas metas próximas e tem o valor da variância para duas metas iguais.

Optimizadores multi-objectivo:

A abordagem da função de aproveitamento

Então ...



- **Existem** valores da função de covariância negativos elevados entre algumas metas **distantes**.
- **Não existem** valores da função de covariância positivos elevados entre metas **distantes**.

A abordagem dos indicadores de qualidade

Optimizadores multi-objectivo:


A abordagem dos indicadores de qualidade

Para **evitar** a complexidade da distribuição de um conjunto APN \mathcal{X} de resultados no espaço dos objectivos $\mathbb{R}^d \dots$

- transforma-se \mathcal{X} numa variável aleatória em \mathbb{R} , com respeito a um conjunto de referência Z_{ref} , i.e.

$$\mathcal{X} \mapsto I_{Z_{ref}}(\mathcal{X}) \in \mathbb{R}$$

- considera-se a respectiva **distribuição univariada**, geralmente, em termos da sua média.



Optimizadores multi-objectivo: Indicadores de qualidade

Há muitos indicadores de qualidade unários na literatura.

Exemplos tratados em seguida:

1. Indicador ϵ unário
2. Indicador da fração atingida (“*covered fraction*”, “*coverage*”)
3. Indicador (ponderado) de hipervolume

Optimizadores multi-objectivo:

Indicadores de qualidade

Indicador ϵ unário:


→ **Definição:** Seja $Z_{ref} = \{z_1^{ref}, z_2^{ref}, \dots, z_k^{ref}\}$ com pontos não-dominados em \mathbb{R}^d .

$$I_\epsilon(\mathcal{X}, Z_{ref}) = \inf \left\{ \epsilon \in \mathbb{R}^+ : \prod_{i=1}^k I\{\mathcal{X} \preceq \epsilon \cdot z_i^{ref}\} = 1 \right\}$$

→ O indicador tem realizações em $(0, \infty)$, onde um valor menor indica melhor qualidade do conjunto de resultados realizado.

Optimizadores multi-objectivo:

Indicadores de qualidade



Ideia:

- Quanto é que Z_{ref} se tem que deslocar para cima para a realização de \mathcal{X} atingir todos os elementos z_i^{ref} ?
- Até onde é que Z_{ref} se pode deslocar para baixo para a realização de \mathcal{X} ainda atingir todos os elementos z_i^{ref} ?

Optimizadores multi-objectivo:

Indicadores de qualidade

Em termos absolutos, Z_{ref} deverá representar um nível de qualidade minimamente satisfatório para um conjunto de resultados. Assim,

- um valor médio do indicador $\boxed{> 1}$ indicará uma qualidade **não-satisfatória**.
- um valor médio do indicador $\boxed{\leq 1}$ indicará uma qualidade **satisfatória**.

??? Mas, por que não usar antes a mediana da distribuição deste indicador, cujo valor é

$$\inf \left\{ \epsilon \in \mathbb{R}^+ : \alpha_{\mathcal{X}}^{(k)}(\epsilon \cdot z_1^{ref}, \dots, \epsilon \cdot z_k^{ref}) = 0.5 \right\} \quad ?$$


Optimizadores multi-objectivo:

Indicadores de qualidade

Indicador da fração atingida:

→ **Definição original** com $Z_{ref} = \mathcal{X}^*$ um conjunto finito de pontos:

Proporção da fronteira óptima de Pareto \mathcal{X}^* atingida por \mathcal{X}





$$I_{FA}(\mathcal{X}, Z_{ref}) = 2/4 = 0.5$$

→ O indicador tem realizações em $[0, 1]$, onde um valor maior indica melhor qualidade do conjunto de resultados realizado.

Optimizadores multi-objectivo:

Indicadores de qualidade

→ **Definição generalizada** com conjuntos $Z_{ref} \in \mathbb{R}^d$ compactos:



O indicador mede ...

- a proporção do conjunto Z_{ref} atingida por \mathcal{X} , ou
- o tamanho da interseção do *conjunto atingido*

$$\mathcal{Y} = \{z \in \mathbb{R}^d : \mathcal{X} \preceq z\}$$

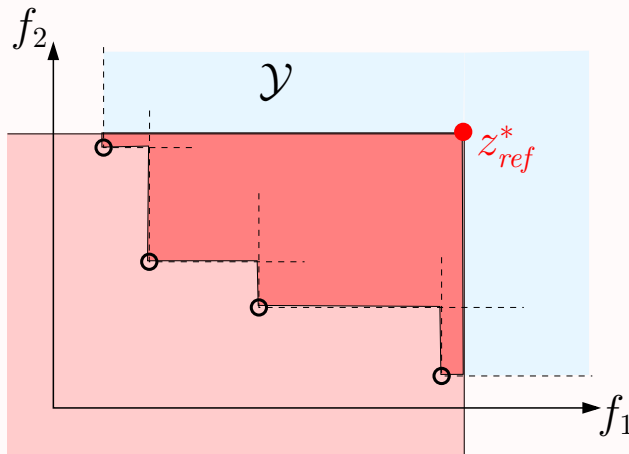
com o conjunto Z_{ref} , multiplicado com $1/\text{tamanho}(Z_{ref})$.

Optimizadores multi-objectivo:

Indicadores de qualidade

Indicador (ponderado) de hipervolume:

→ **Definição** com conjuntos fechados $Z_{ref}^* = \{z \in \mathbb{R}^d : z \leq z_{ref}^*\}$



Mede ...

o tamanho da interseção de \mathcal{Y} com Z_{ref}^* ponderado por uma função de ponderação $w(\cdot)$ não-negativa, integrável sobre Z_{ref}^* .

Optimizadores multi-objectivo:

Indicadores de qualidade

Fórmula comum para os últimos dois indicadores:

$$\int_{Z_{ref}} \mathbf{I}\{\mathcal{X} \trianglelefteq z\} \cdot w(z) \mathcal{H}(dz)$$

medida Hausdorff
adequada

onde para o ...

→ Indicador generalizado de fração atingida:

$$w(z) = \frac{1}{\text{tamanho}(Z_{ref})} = \frac{1}{\mathcal{H}(Z_{ref})}$$

→ Indicador ponderado de hipervolume:

$$Z_{ref} = Z_{ref}^*$$

Optimizadores multi-objectivo:

Indicadores de qualidade

Fórmula comum para a média dos últimos dois indicadores:

$$\int_{Z_{ref}} \alpha_x(z) \cdot w(z) \mathcal{H}(dz)$$

função de aproveitamento de ordem 1



Mostra a ligação entre a abordagem dos indicadores de qualidade e a abordagem da função de aproveitamento!

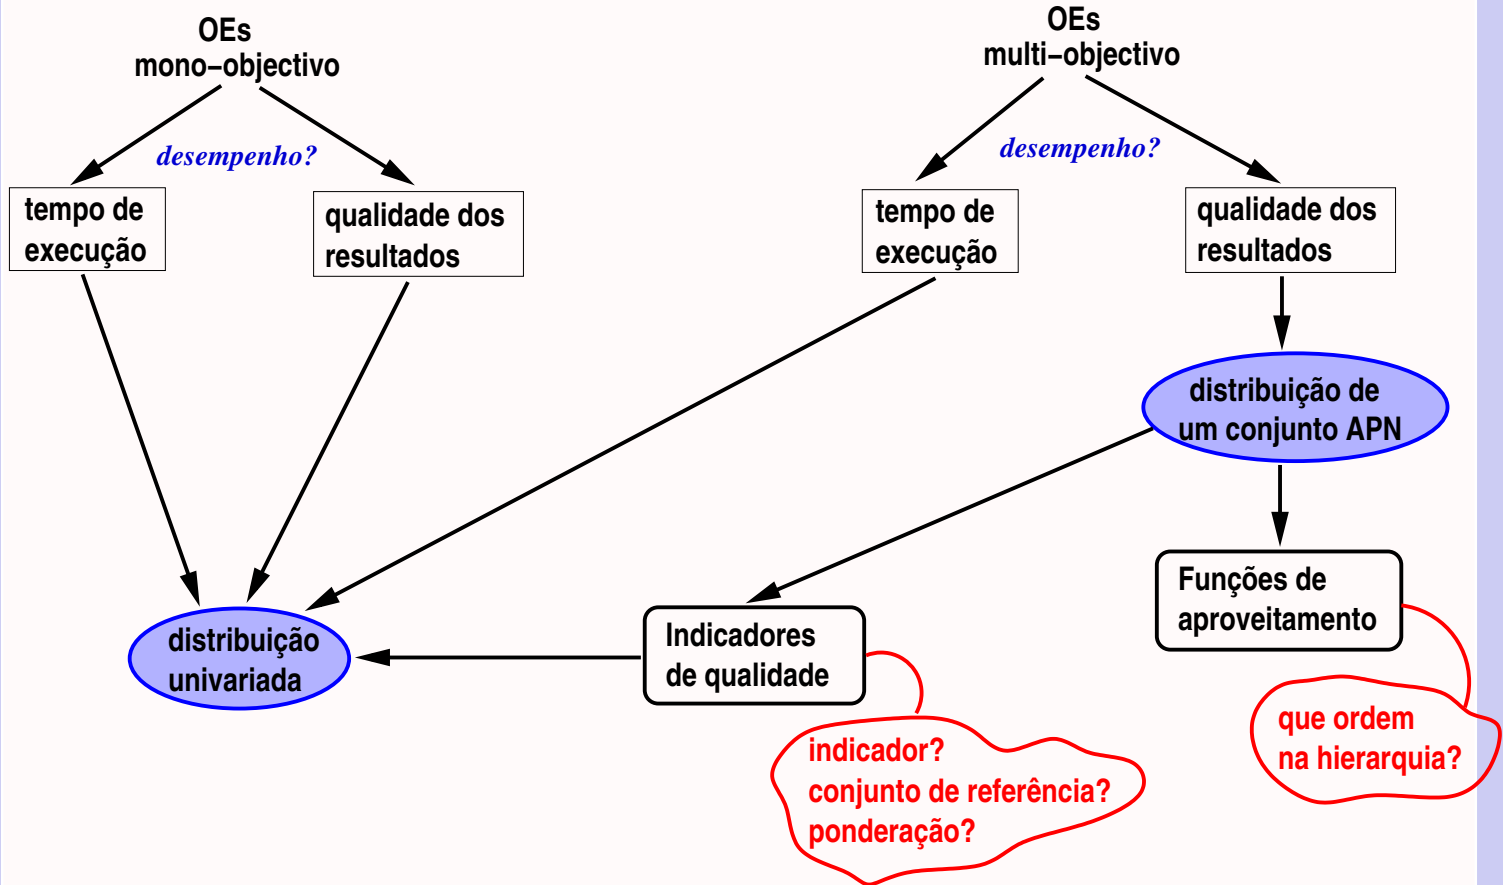
Notas finais

- O desempenho de um OE é associado às

distribuições de probabilidade

dos seus resultados e do tempo de execução.

- A **complexidade** dessas distribuições dificulta a avaliação completa do desempenho de um OE.
- Uma avaliação baseada em informação parcial deve ser planeada com cuidado!



Obrigada!