



Avaliação do Desempenho de Optimizadores Estocásticos

Viviane Grunert da Fonseca^{1,2}


¹ Instituto Universitário Dom Afonso III (INUAF)

² Centro de Estudos de Gestão, Instituto Superior Técnico, Universidade Técnica de Lisboa
(CEG-IST)

`viviane.grunert@vodafone.pt`

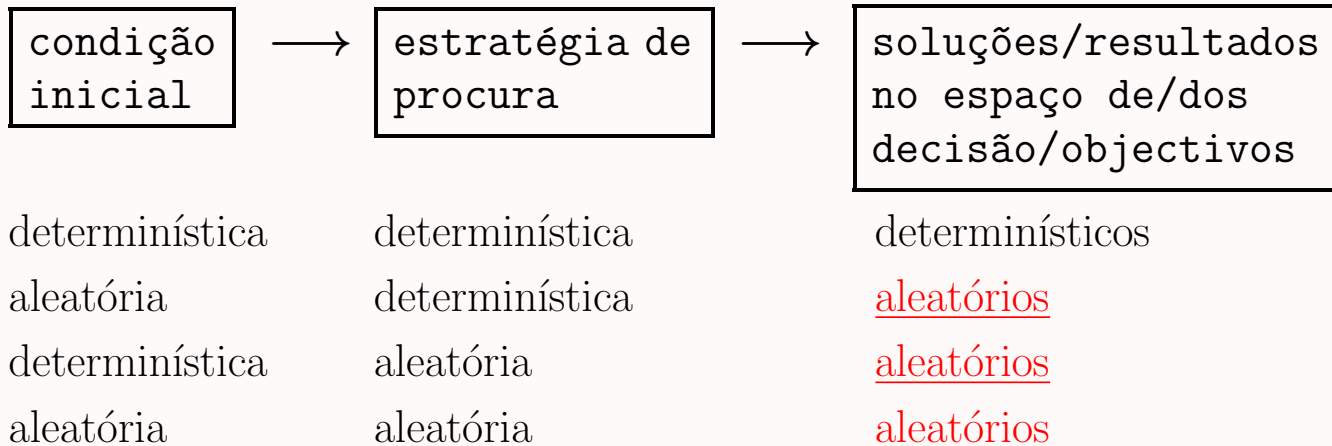
2ª Escola Luso-Brasileira de Computação Evolutiva,
Guimarães, 18 de Julho de 2010


Optimizadores Estocásticos




→ Já conhecemos vários optimizadores evolutivos:

- algoritmos genéticos, estratégias evolutivas,
- algoritmos de colónias de formigas, etc.





- Em geral, os **algoritmos evolutivos** são otimizadores estocásticos (OE) e produzem soluções/resultados aleatórios.
- Existem também outros OEs que não são algoritmos evolutivos, como p. ex. o *simulated annealing* que imita um processo de arrefecimento.
- Tanto as soluções produzidas por um OE no espaço de decisão como os resultados correspondentes no espaço dos objectivos seguem uma distribuição de probabilidades.



→ Caso simples no espaço dos objectivos:

$$P(\text{resultado} = x_i) = p_i, \quad i = 1, 2, \dots$$


O conjunto de resultados possíveis é enumerável e o OE tem uma **distribuição de resultados** discreta.

→ Um optimizador determinístico, que em cada execução produz o mesmo resultado a , pode ser visto como um “caso especial”:

$$P(\text{resultado} = a) = 1.$$


→ No entanto, *a distribuição de resultados de um OE pode ser muito mais complicada!* ...

Avaliação do **Desempenho** de Optimizadores Estocásticos



- O **desempenho** de OEs (no espaço dos objectivos) 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, porque, dada uma instância de um problema de optimização, se deseja escolher o “melhor” optimizador de entre muitas alternativas.
- O que significa **bom desempenho** de um OE?
 - produzir resultados em **pouco tempo**,
 - resultados de boa qualidade, ou seja, **resultados** que se localizam “**próximo**” do(s) valor(es) **óptimo(s)** da função objectivo.

Avaliação do **Desempenho** de Optimizadores Estocásticos



Questões relativas à qualidade dos resultados:

- (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) A distribuição de resultados do mesmo OE varia em função da instância do problema de optimização!
 - ↪ Na prática, assume-se que o desempenho observado anteriormente noutras instâncias do mesmo problema é representativo.

- (c) O significado de “resultados de boa qualidade” tem múltiplos aspectos que provêm da complexidade da **distribuição de resultados**.
 - ↪ 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: Distribuições de resultados e desempenho



Consideram-se os resultados de OEs produzidos no espaço dos objectivos após um determinado tempo de execução.

Optimizador determinístico mono-objectivo

- O valor mínimo da função objectivo é um escalar $x^* \in \mathbb{R}$.
- Cada execução do optimizador produz o mesmo resultado, que é um escalar $a \in \mathbb{R}$, $a \geq x^*$.
- A distribuição de resultados é uma *Distribuição de Um Ponto*:

$$P(X = a) = 1.$$

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

- Os resultados são de melhor qualidade quando o escalar a é menor.
[caso ideal: $a = x^*$]
- Um *Optimizador 1* com resultado(s) a_1 tem melhor desempenho que um *Optimizador 2* com resultado(s) a_2

$$\iff a_1 < a_2.$$



Nos optimizadores determinísticos mono-objectivo, o significado de “resultados de boa qualidade” é evidente, pois envolve um único critério!

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

Optimizador estocástico mono-objectivo

- O valor mínimo da função objetivo 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 (simples)* X_1, X_2, \dots, X_n ,
- de 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

- Um *Optimizador 1* com resultados X_1 tem melhor desempenho que um *Optimizador 2* com resultados X_2

\iff **XXX** **???**

Dúvida

Que critério usar para formular essa afirmação de equivalência?

→ Rigorosamente falando, deve-se considerar a **caracterização completa** das distribuições de X_1 e X_2 , ou seja,

$$\mathbf{XXX} : F_{X_1}(z) > F_{X_2}(z) \quad \text{para todos os } z \geq x^*$$

Optimizadores mono-objectivo:

Distribuições de resultados e desempenho

→ A comparação dos estimadores de $F_{X_1}(\cdot)$ e $F_{X_2}(\cdot)$ parece “pouco prática” porque envolve inúmeras comparações individuais!

... Mas ...

é possível com os *testes de hipóteses* da análise estatística inferencial (e.g. o teste Kolmogorov-Smirnov para duas amostras).

→ Na prática, a comparação do desempenho de dois optimizadores também pode ser feita relativamente a um ou mais aspectos das distribuições de resultados.

↪ e.g. teste de Mann-Whitney (medianas), teste de Levene (variâncias)

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 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

$[\mathcal{X} \preceq z]$ 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 ilustração gráfica para $m^* > 2$.
- deu origem a muitos critérios de desempenho para optimizadores multi-objectivo!

Duas principais abordagens

1. **Abordagem da função de aproveitamento** que é baseada em conceitos da teoria de conjuntos aleatórios, tendo em conta a não-dominância entre os elementos de um conjunto APN.
2. **Abordagem dos indicadores de qualidade** que transforma as realizações de um conjunto APN em valores em \mathbb{R} e estuda a distribuição univariada desses valores, (geralmente) em termos da sua média.

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-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):

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

versus

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

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 o 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.

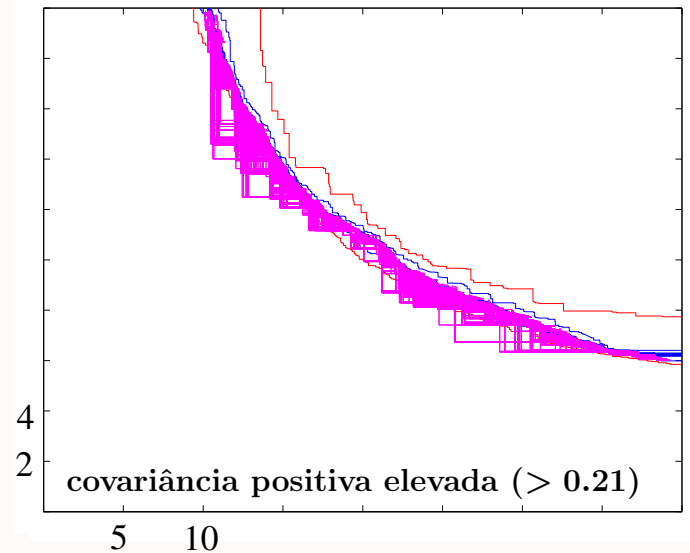



A covariância é sempre positiva para duas metas próximas e tem o valor da variância para duas metas iguais.

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**.

Optimizadores multi-objectivo:

A abordagem dos indicadores de qualidade

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

- transformam-se as realizações de \mathcal{X} em valores em \mathbb{R} , e
- considera-se a respectiva distribuição univariada, geralmente, em termos da sua média.

Exemplos tratados em seguida:

1. Indicador ϵ unário
2. Indicador da fração atingida
3. Indicador de hipervolume

Optimizadores multi-objectivo:

A abordagem dos indicadores de qualidade

- **Indicador ϵ unário** (com conjunto de referência Z_{ref}):


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

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

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

Optimizadores multi-objectivo:

A abordagem dos 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:

A abordagem dos 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:

A abordagem dos indicadores de qualidade

- **Indicador da fração atingida** (com conjunto de referência Z_{ref}):


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

$$C_{Z_{ref}}(\mathcal{X}) = \frac{1}{k} \sum_{i=1}^k \mathbf{1}\{\mathcal{X} \preceq z_i^{ref}\}$$

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

Optimizadores multi-objectivo:

A abordagem dos indicadores de qualidade



→ Em termos absolutos, dever-se-á escolher uma fração $C_{Z_{ref}}^*$ que represente uma qualidade satisfatória, dado Z_{ref} .

→ A média da distribuição do indicador tem a forma

$$\frac{1}{k} \sum_{i=1}^k \alpha_{\mathcal{X}}(z_i^{ref})$$

Optimizadores multi-objectivo:

A abordagem dos indicadores de qualidade

- Indicador de hipervolume (com vector de referência z_{ref}):


→ Definição: Com $z_{ref} \in \mathbb{R}^d$

$$H_{z_{ref}}(\mathcal{X}) = \int \mathbf{I}\{\mathcal{X} \preceq z\} \cdot \mathbf{I}\{z \leq z_{ref}\} dz$$

→ O indicador tem realizações em $[0, H_{z_{ref}}(\mathcal{X}^*)]$, onde um valor maior indica melhor qualidade do conjunto de resultados realizado.

Optimizadores multi-objectivo:

A abordagem dos indicadores de qualidade



→ Em termos absolutos, dever-se-á escolher um valor $H_{z_{ref}}^*$ que represente uma qualidade satisfatória, dado z_{ref} .

→ A média da distribuição do indicador tem a forma

$$\int \alpha_X(z) \cdot \mathbf{I}\{z \leq z_{ref}\} dz$$

Optimizadores multi-objectivo:

A abordagem dos indicadores de qualidade

- **Testes de hipóteses** (bilaterais ou unilaterais) permitem comparar, por exemplo, as médias, medianas, ou as distribuições completas de um indicador, relativamente a dois optimizadores.
- Seria interessante investigar quais dos aspectos “localização”, “variabilidade”, e “dependência entre os elementos X_i ” do conjunto APN \mathcal{X} são avaliados por cada indicador, ou seja ...

Qual é a relação entre um indicador e a função de aproveitamento (de ordem k)?

Notas finais

- O desempenho de optimizadores também pode ser estudado em termos da **qualidade** dos resultados **juntamente** com o **tempo** necessário para chegar a esses resultados.
 - ↪ Na abordagem da função de aproveitamento, basta considerar o tempo como mais um objectivo.
- A função de aproveitamento empírica (de ordem k) é um estimador *não-paramétrico*. Seria interessante encontrar também formulações *paramétricos* para essa função.
- As implementações computacionais continuam em desenvolvimento, havendo ainda limitações na aplicação prática destas funções.
- ...

“Es gibt viel zu tun, packen wir es an!”

Obrigada!