

# Sobre Métodos de busca padrão para Minimização de funções com Restrições Lineares

Deise Gonçalves Ferreira

Orientadora: Profa. Dra. Maria Aparecida Diniz Ehrhardt

Mestrado em Matemática Aplicada  
IMECC - Unicamp

1 de março de 2013

- 1 Introdução
- 2 O Método de Busca Padrão
- 3 Testes Computacionais
- 4 Considerações Finais
- 5 Referências Bibliográficas

# Introdução:

- É frequente nas aplicações problemas em que as derivadas não estão disponíveis;
- Há inúmeras aplicações cujas restrições são apenas lineares;
- Subproblema em métodos voltados para problemas gerais;
- Estudar e propor métodos sem derivadas para resolvê-los;
- Focamos nosso trabalho no Método de Busca Padrão aplicado ao problema com restrições lineares;
- Propomos novas estratégias de busca e um novo Padrão buscando melhorar o desempenho do método.

## Definindo o problema a ser trabalhado

Trabalharemos com um Método de Busca padrão aplicado ao problema de Otimização com restrições lineares definido por:

$$(PRL) \begin{cases} \min & f(x) \\ \text{s.a.} & l \leq Ax \leq u \\ & bl \leq x \leq bu \end{cases}$$

$$f : \mathbb{R}^n \rightarrow \mathbb{R}, \quad x \in \mathbb{R}^n, \quad A \in \mathbb{R}^{m \times n}, \quad l, u, bl, bu \in \mathbb{R}^m$$

# Métodos de Busca direta

## Definição:

Dizemos que um método é de busca direta se, além de não computar derivadas, ele não utilizar os valores de função em nenhum cálculo.

# Vantagens dessa classe de métodos

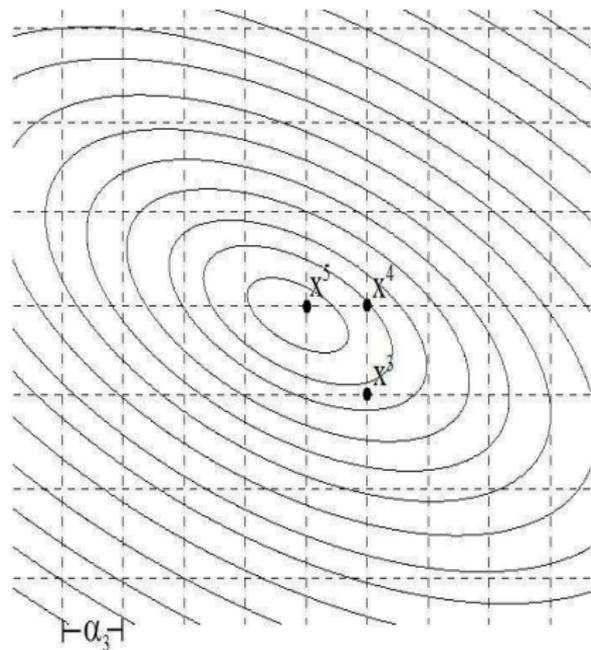
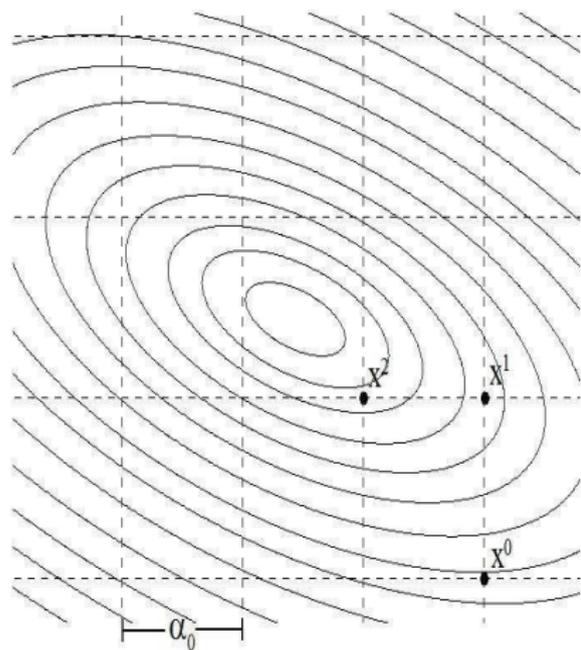
- Algoritmos simples e com forte apelo geométrico;
- Iteração barata cujo passo mais caro é avaliar o valor da função;
- Algoritmos fáceis de serem implementados;
- Aplicação quase que imediata;
- Sob certas hipóteses possui uma robusta teoria de convergência;
- Precisamos de muito pouco para poder aplicar o método;
- É uma alternativa quando métodos mais elaborados falham.

## Desvantagens dessa classe de métodos

- Sem derivadas não podemos verificar se uma determinada direção é de descida;
- Quando a sequência converge não podemos testar se de fato é um ponto estacionário e muito menos se é um minimizador;
- Ao abandonar derivadas o desempenho do método é muito inferior;
- Embora a iteração seja barata em geral o número de iterações é muito alto;
- Não podemos impor condições de decréscimo suficiente;
- Decréscimo lento, ou passos muito curtos;
- Avaliar a função muitas vezes, encarecendo a iteração;

# Métodos de Busca Padrão

- É considerado um método de Busca Direta;
- Utiliza busca monótona;
- A partir de um ponto  $x^k$ , o próximo iterando deve satisfazer  $f(x^{k+1}) < f(x^k)$ ;
- A matriz  $P^k$  contém o conjunto de direções pelas quais será realizada a busca;
- A matriz  $P^k$  é o que chamamos de padrão e pode variar de uma iteração para outra.
- O novo iterando é então da forma:  $x^{k+1} = x^k + \alpha_k d^k$ ;  
onde  $d^k$  é uma coluna de  $P^k$  e  $\alpha_k$  é o tamanho do passo, que é atualizado de acordo com o status da iteração.



## Generalizando o Padrão

- Em 1997, Virginia Torczon [1] generalizou o Método de Busca Padrão para minimização irrestrita;
- Torczon então apresenta uma robusta teoria de convergência.
- Em 2000, Lewis e Torczon [2] generalizam o método aplicando ao problema com restrições lineares;
- Os diferentes Métodos de Busca Padrão são definidos pelas diferentes direções de busca (Padrão) que utilizam e pelas estratégias de atualização do tamanho do passo.

---

[1] V. Torczon. *On the convergence of pattern search algorithms*. *SIAM Journal on Optimization* 7, pp. 1-25 (1997).

[2] R. M. Lewis, V. Torczon. *Pattern search algorithms for linearly constrained minimization*. *SIAM Journal on Optimization* 10, pp. 917-941 (2000).

## Como é construído o Padrão?

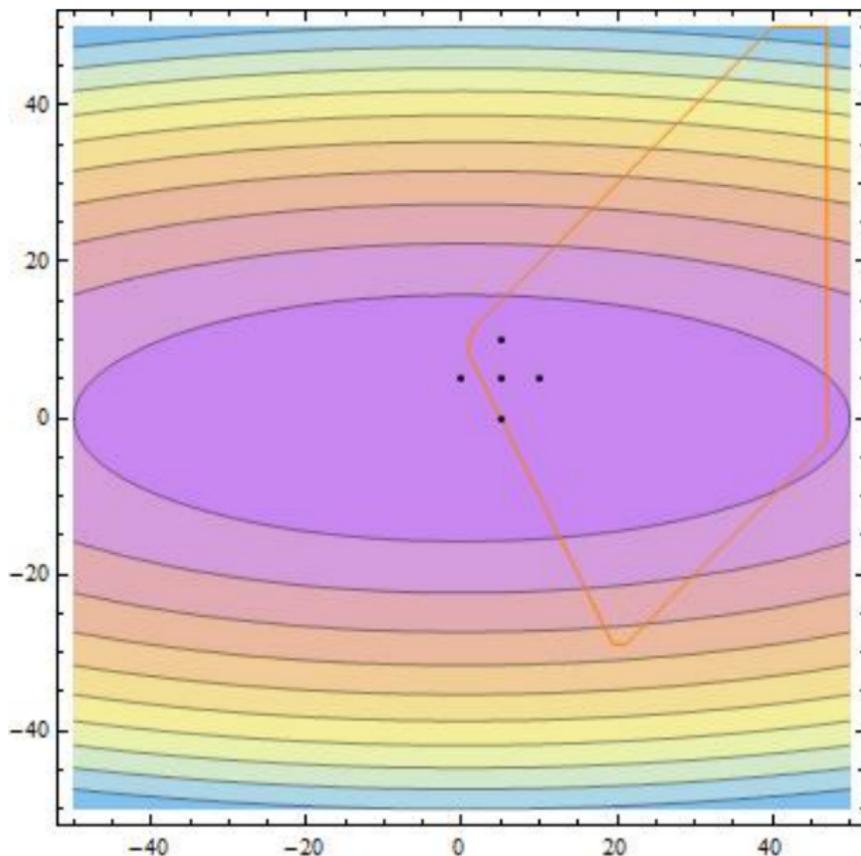
- Para o caso irrestrito as direções contidas em  $P^k$  devem gerar positivamente o  $\mathbb{R}^n$ ;
- Com restrições o padrão deve conter um conjunto de geradores(positivos) para o cone de direções viáveis;
- É necessário preservar a viabilidade em todas as iterações;
- Devemos seguir a geometria da fronteira da região viável, quando estamos próximos desta;
- Garantir que o padrão contenham direções de descida viáveis;
- Considerar as restrições de forma a garantir passos suficientemente longos;

# Problema irrestrito

- Para o caso irrestrito as direções contidas em  $P^k$  têm a característica de gerar positivamente o  $\mathbb{R}^n$ ;
- Seja a matriz  $B \in \mathbb{R}^{n \times n}$ , não singular, (base para  $\mathbb{R}^n$ ), e considere  $M \subset \mathbb{Z}^{n \times n}$  um conjunto finito de matrizes não singulares e  $p \in \mathbb{N}$  tq  $p > 2n$ , onde  $p$  é o número de direções em  $P^k$ .

$$P^k = [BM^k \quad -BM^k \quad BL^k] = [B\Gamma^k \quad BL^k]$$

# Geometria da Fronteira

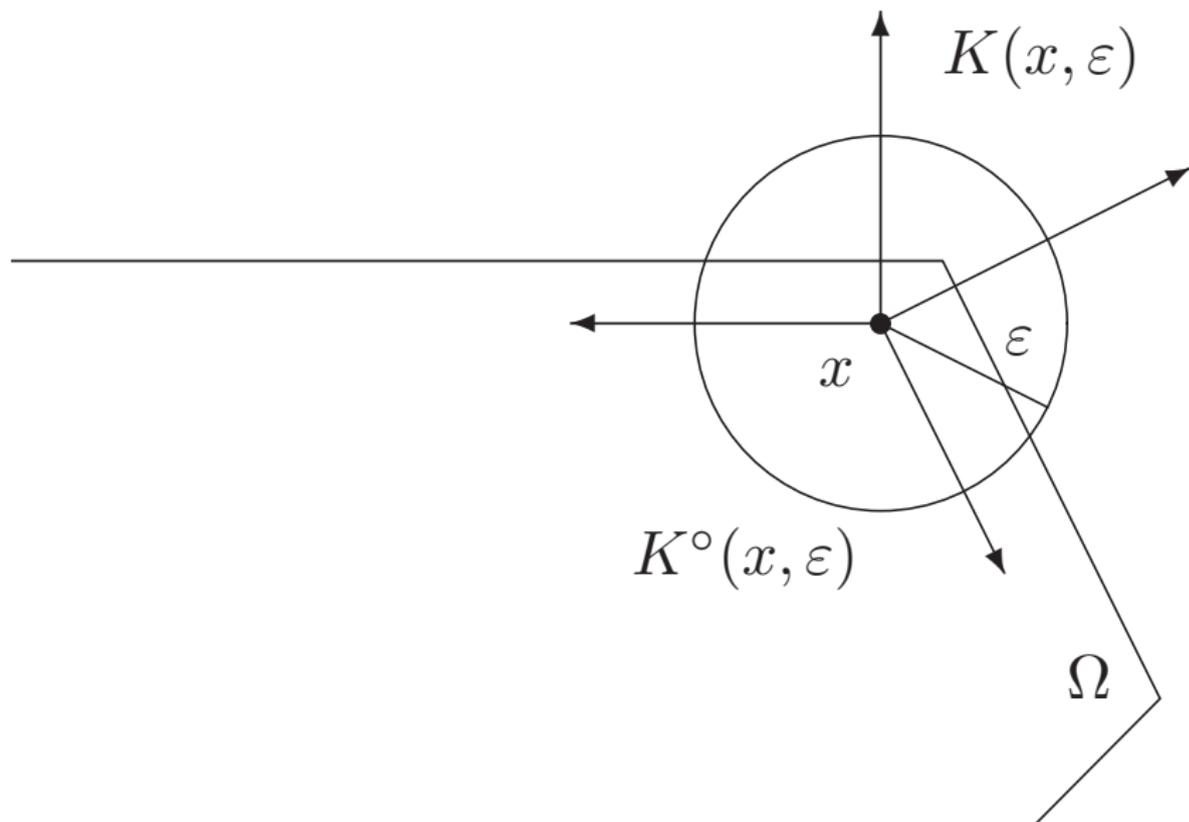


## Padrão para o problema com restrições lineares

- $P^k \in \mathbb{Z}^{n \times p^k}$  (teoricamente) da forma:

$$P^k = [\Gamma^k \quad L^k]$$

- $\Gamma^k \in \mathbb{Z}^{n \times r^k}$  ( $r^k \geq n + 1$ ) - possui as restrições geométricas que deverão ser satisfeitas;
- Por simplicidade tomamos  $B = I$ ;
- $L^k \in \mathbb{Z}^{n \times p^k - r^k}$  - deve conter pelo menos uma coluna, a coluna de zeros;
- Chamaremos de  $c_i^k$  a  $i$ -ésima coluna de  $P^k$
- Dado o passo  $\alpha_k$  então:  $s_i^k = \alpha_k c_i^k$



# Algoritmo de busca padrão - Restrições Lineares

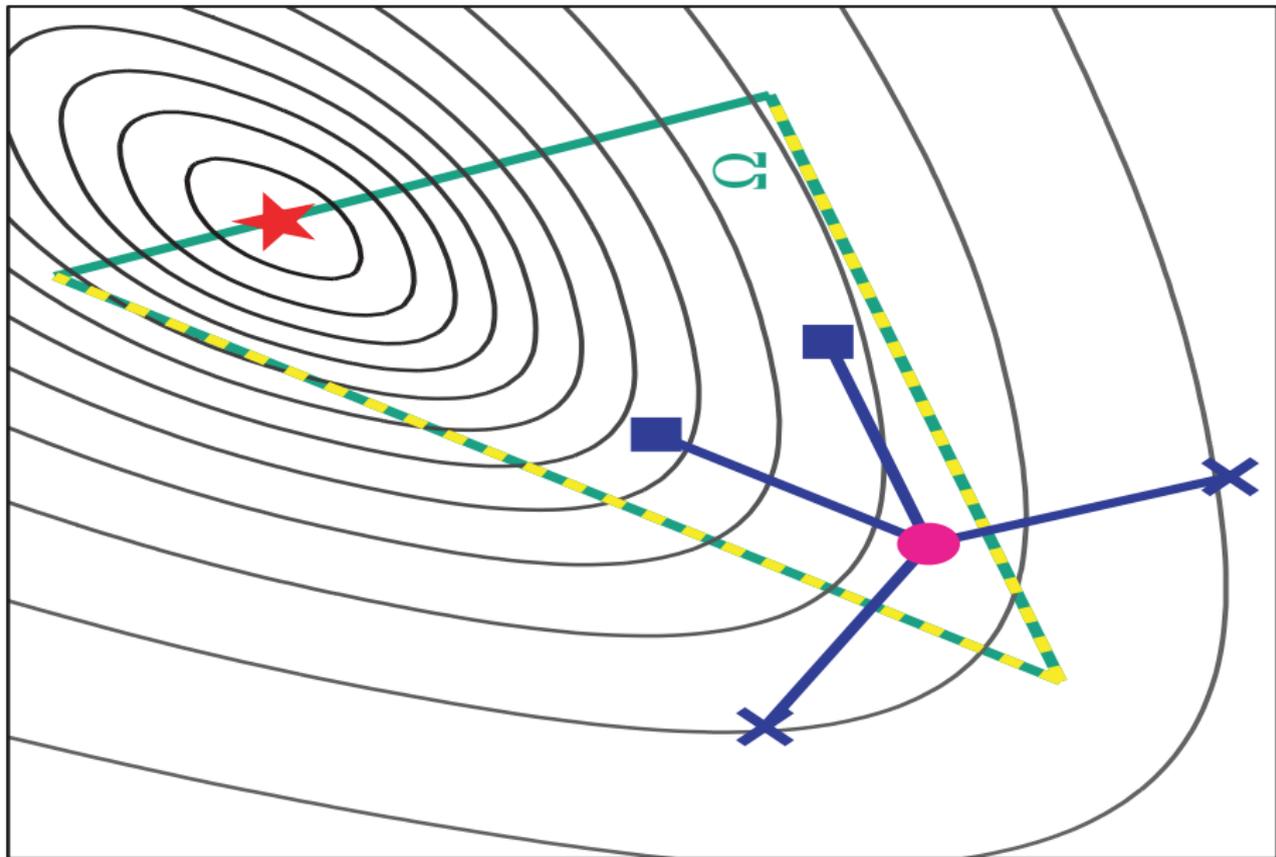
$$\Omega = \{x \in \mathbb{R}^n \mid l \leq Ax \leq u\}$$

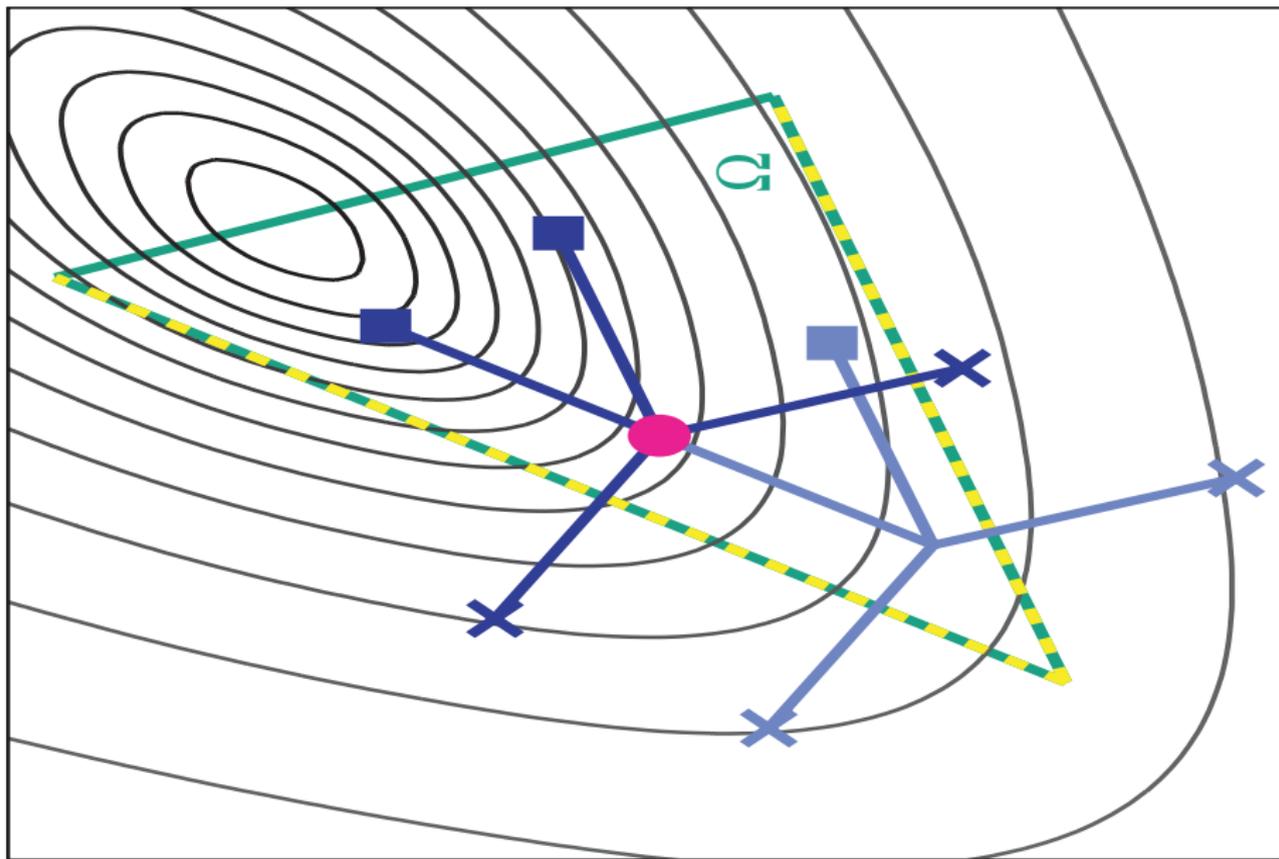
## Algoritmo

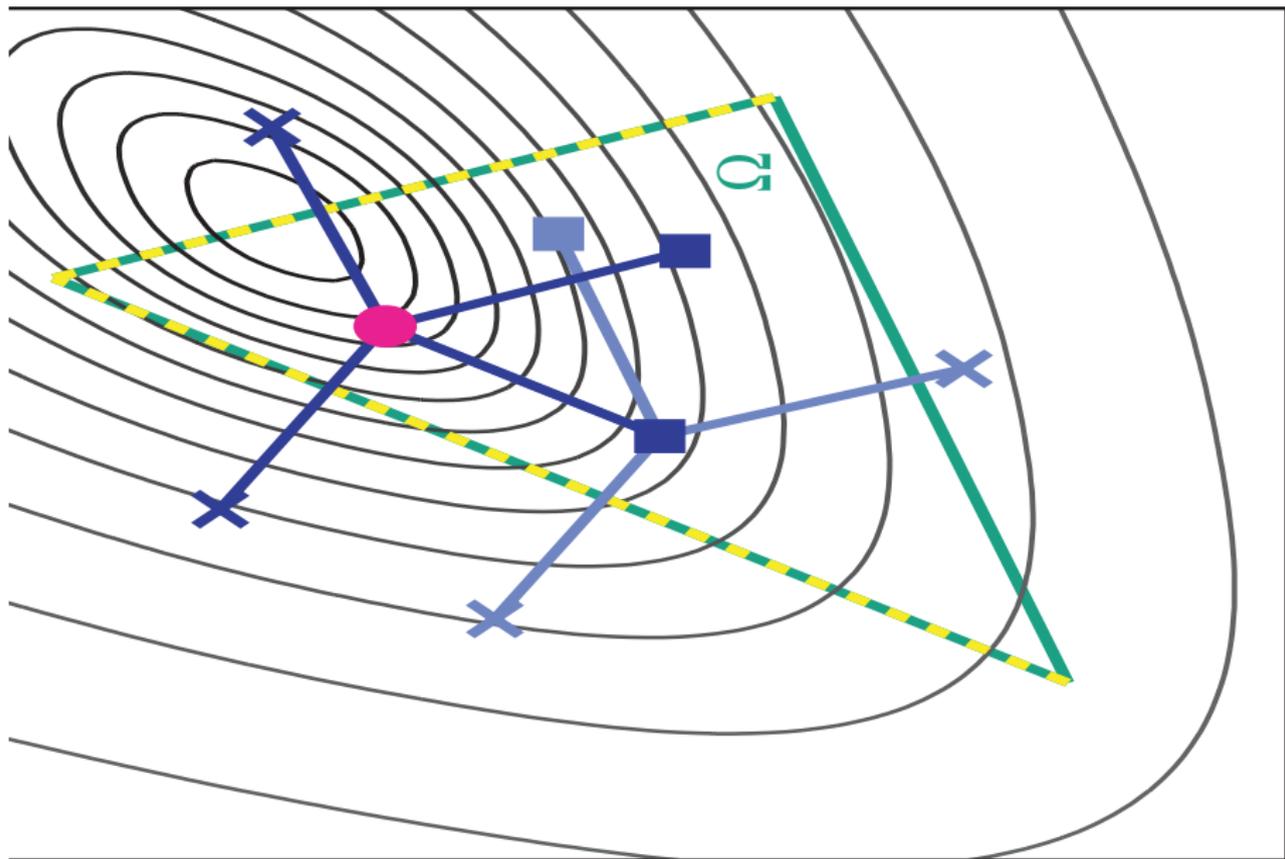
Dado  $x^0 \in \Omega$  e  $\alpha_0 > 0$

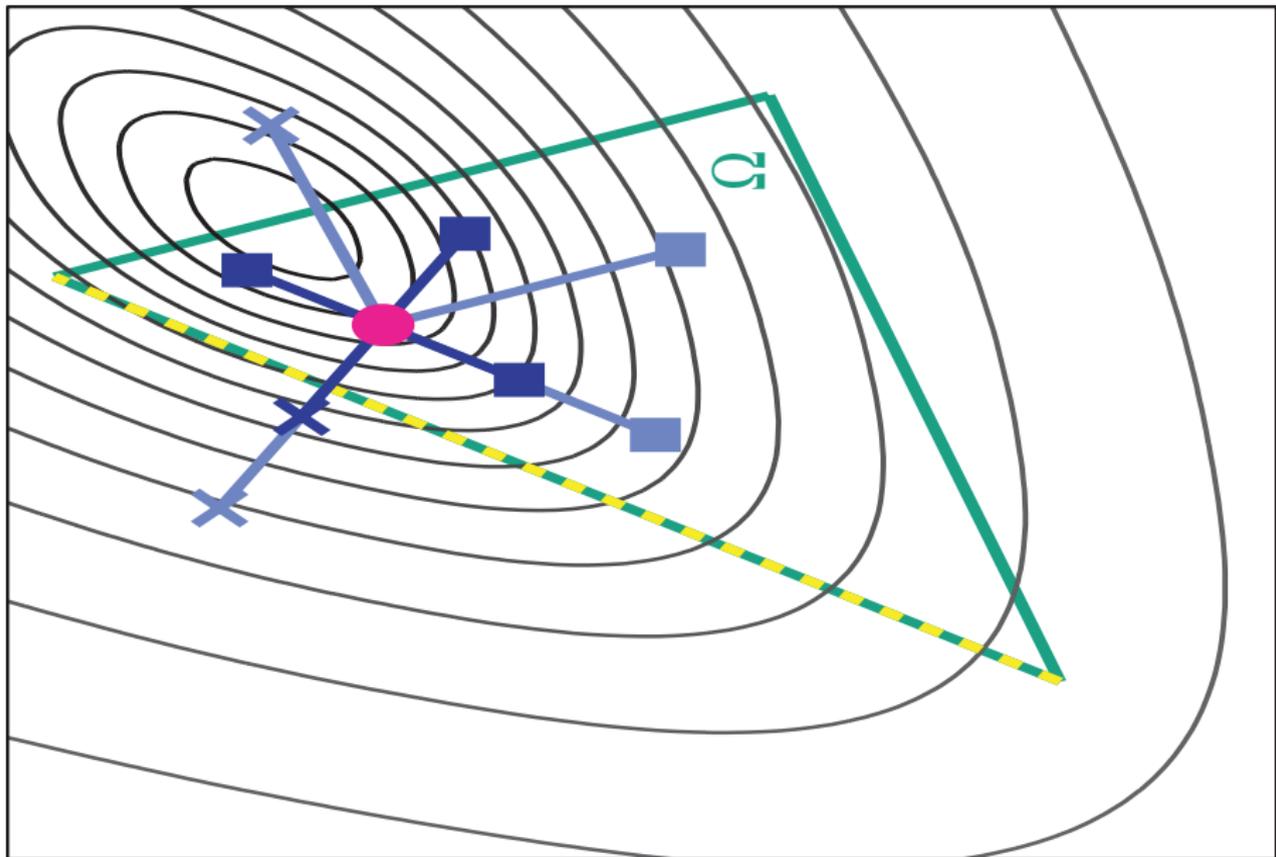
Para  $k = 0, 1, \dots$ ,

- 1 Calcule  $f(x^k)$
- 2 Determine o passo  $s_i^k = \alpha_k c_i^k$
- 3 Verifique a viabilidade:  $(x^k + s_i^k) \in \Omega$
- 4 Se  $f(x^k + s_i^k) < f(x^k)$ , então  $x^{k+1} = (x^k + s_i^k)$  e declare sucesso, caso contrário faça  $x^{k+1} = x^k$ ;
- 5 Atualize  $P^k$  e  $\alpha_k$









# Atualização do tamanho do Passo

## Atualização do tamanho do Passo

- Em caso de sucesso fazemos  $\alpha_{k+1} = \lambda_k \alpha_k$ , onde  $\lambda_k \in [1, +\infty)$
- Em caso de fracasso fazemos  $\alpha_{k+1} = \theta_k \alpha_k$ , onde  $\theta_k \in (0, 1)$

Os parâmetros  $\lambda_k$  e  $\theta_k$  devem ser da forma:

- Seja  $\tau \in \mathbb{Q}$ ,  $\tau > 1$ , e  $\{w_0, \dots, w_L\} \subset \mathbb{Z}$ ,  $w_0 < 0$ ,  $w_L \geq 0$ , ordenados, então:
- $\theta_k = \tau^{w_i}$  para algum  $w_i \in \{w_0, \dots, w_L\}$  tal que  $w_i < 0$ ;
- $\lambda_k = \tau^{w_j}$  para algum  $w_j \in \{w_0, \dots, w_L\}$  tal que  $w_j \geq 0$ ;

## O que propomos...

- Propomos uma estratégia para atualizar o tamanho do passo que leva em consideração as iterações bem-sucedidas consecutivas.
- Criamos a variável *suc* que é incrementada sempre que a iteração é bem-sucedida;
- Quando a iteração fracassa atribuímos zero à esta variável que volta a ser incrementada somente quando o método obter sucesso novamente.
- Então a atualização do tamanho do passo é feita da seguinte forma:

### Atualização do tamanho do passo

- Em caso de sucesso fazemos  $\alpha_{k+1} = \tau^{suc} \alpha_k$ , onde  $\tau \geq 1$  e  $\|\tau^{suc}\| < +\infty$ .
- Em caso de fracasso fazemos  $\alpha_{k+1} = 0.5\alpha_k$ .

# Condições sobre os movimentos exploratórios

## Hipóteses sobre os movimentos exploratórios

- 1  $s^k \in \alpha_k P^k$
- 2  $(x^k + s^k) \in \Omega$ .
- 3 Se  $\min \{f(x^k + y) \mid y \in \alpha_k P^k \text{ e } (x^k + y) \in \Omega\} < f(x^k)$ , então:  
$$f(x^k + s^k) < f(x^k)$$

## Hipóteses fortes sobre os movimentos exploratórios

- 1  $s^k \in \alpha_k P^k$
- 2  $(x^k + s^k) \in \Omega$ .
- 3 Se  $\min \{f(x^k + y) \mid y \in \alpha_k P^k \text{ e } (x^k + y) \in \Omega\} < f(x^k)$ , então:  
$$f(x^k + s^k) \leq \min \{f(x^k + y) \mid y \in \alpha_k P^k \text{ e } (x^k + y) \in \Omega\}$$

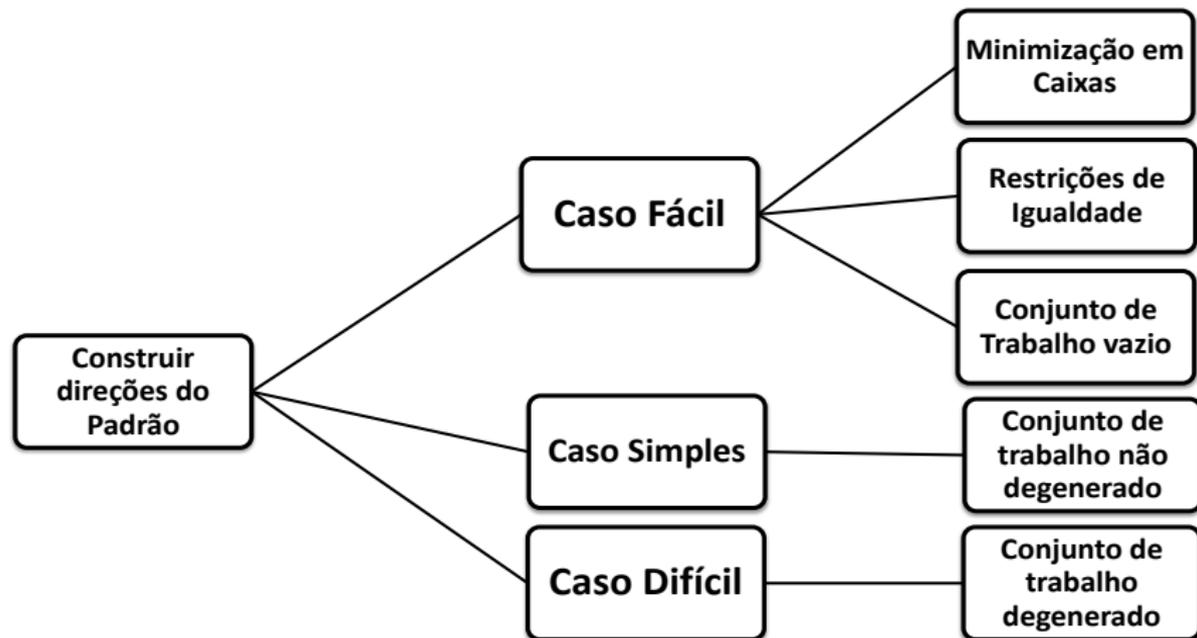
## Resultados de convergência

- Assumindo que a função objetivo  $f(x)$  é continuamente diferenciável;
- O conjunto de nível de  $f(x)$  é compacto;
- Adicionando algumas hipóteses sobre as restrições, Padrão de busca e atualizações;
- Obtemos resultados de convergência global para o método;
- Com busca simples garantimos que existe uma subsequência gerada pelo Método que converge à um ponto KKT do problema;
- Com busca completa garantimos que toda subsequência convergente converge para a solução.
- Testes computacionais mostraram um bom desempenho do método mesmo sem satisfazer todas as condições que garantem a convergência.

## Gerando o conjunto de Direções de busca

- As direções de busca são determinantes para o sucesso do método;
- Construir um padrão adequado para o tipo de problema que estamos trabalhando é essencial;
- Escolhas erradas podem fazer o método convergir para pontos que estão longe da solução;
- Dependendo da escolha o método pode não sair do lugar;
- Podemos dividir os problemas em alguns casos o que nos ajuda a determinar o padrão adequado;

# Considerações ao gerar o Padrão



# Minimização em caixas

O Problema de Minimização em caixas é dado por:

$$\begin{cases} \min & f(x) \\ \text{s.a.} & l \leq x \leq u \end{cases}$$

- Minimizar em caixas seria o caso mais fácil de restrições lineares onde  $A=I$ ;
- Neste caso sabemos de antemão os possíveis geradores para os cones  $K(x, \epsilon)$  e  $K^o(x, \epsilon)$  que serão sempre subconjuntos dos vetores coordenados  $\pm e_i$ , e este conjunto será sempre  $LI$ ;
- Neste caso podemos tomar  $\Gamma = [l - l]$  e usá-lo como padrão em todas as iterações;
- No pior caso teremos  $2n$  avaliações de função por iteração;

# Restrições de Igualdade

- Temos que manter a viabilidade a cada iteração;
- Para restrições de Igualdade pequenos passos podem fazer com que a viabilidade seja perdida;
- A cada iteração devemos ter:

$$\begin{aligned}A(x^k + s^k) &= u \\Ax^k + As^k &= u, \text{ mas } Ax^k = u \\As^k &= 0\end{aligned}$$

- Só conseguimos sair do ponto por direções no  $\mathcal{N}(\mathcal{A})$ ;
- Logo meu padrão deve conter uma base positiva para  $\mathcal{N}(\mathcal{A})$ ;
- Podemos e devemos utilizar o mesmo padrão em todas as iterações;

## Restrições lineares gerais

- No caso geral o problema pode ter restrições de igualdade, desigualdade e de caixas;
- Sendo assim é importante saber as características das restrições que são  $\epsilon$ -ativas no ponto corrente;
- Chamaremos de conjunto de trabalho as restrições que são  $\epsilon$ -ativas na iteração corrente;

### Conjunto de trabalho degenerado

Seja  $V$  a matriz cujas colunas geram o cone  $K(x^k, \epsilon)$ . Se as colunas de  $V$  formam um conjunto linearmente independente, diremos que o conjunto de trabalho em  $x^k$ , ou seja, na iteração corrente, é não-degenerado, caso contrário, diremos que o conjunto de trabalho na iteração corrente é degenerado.

## Construindo o conjunto de trabalho

- Teremos uma restrição de igualdade quando  $l_i = u_i$ ;

$$\mathbb{I} = \{i : l_i = u_i\} \quad e \quad \mathbb{D} = \{i : l_i < u_i\}.$$

- As restrições de desigualdade ativas serão identificadas pelos seguintes conjuntos de índices:

$$\mathbb{D}_l(x, \epsilon) = \{i : x \in \partial\Omega_{l_i}(\epsilon)\}, \quad e \quad \mathbb{D}_u(x, \epsilon) = \{i : x \in \partial\Omega_{u_i}(\epsilon)\},$$

- Podemos ter restrições momentaneamente de igualdade identificadas pelo conjunto:

$$\mathbb{D}_e(x, \epsilon) = \{i : i \in \mathbb{D}_l(x, \epsilon) \cap \mathbb{D}_u(x, \epsilon)\}.$$

- O conjunto de trabalho é dado por:

$$V_e = \{a_i : i \in \mathbb{I}\} \cup \{a_i : i \in \mathbb{D}_e\},$$

$$V_d = \{a_i^T : i \in \mathbb{D}_l \setminus \mathbb{D}_e\} \cup \{-a_i^T : i \in \mathbb{D}_u \setminus \mathbb{D}_e\}.$$

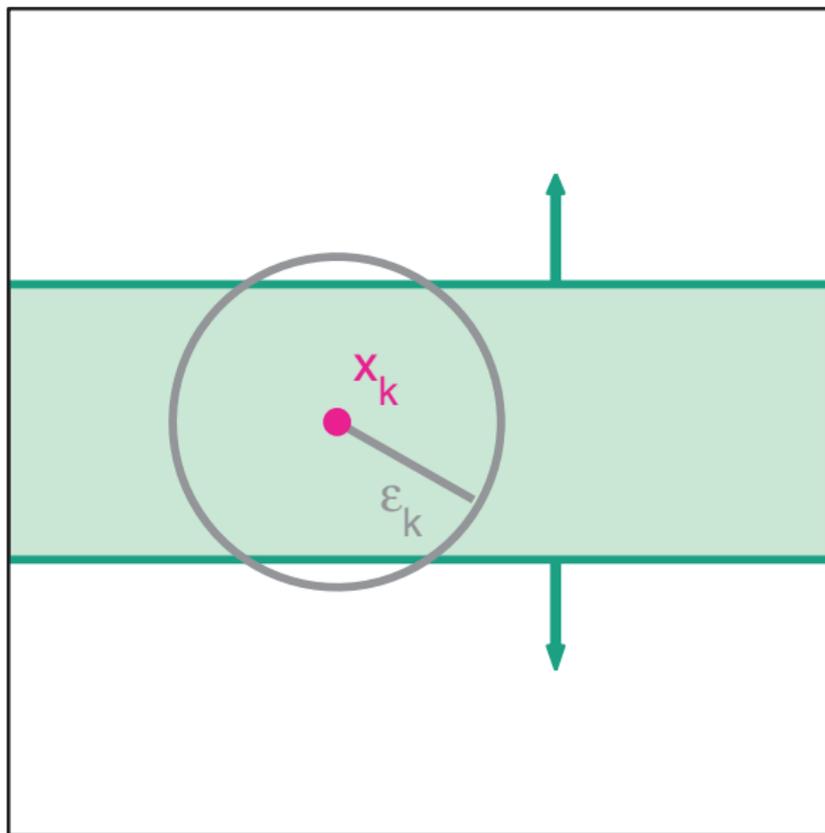


Figura: Restrições momentaneamente de igualdade

## Padrão 1: Proposto por Lewis, Torczon e Shepherd

- Encontre uma base ortonormal  $Z$  para o espaço nulo de  $V_e$ ;
- Calcule a matriz  $B = Z^T V_d$ ;
- Verifique se as colunas de  $B$  formam um conjunto linearmente independente de vetores;
- Caso  $B$  não possua posto completo, o conjunto de trabalho é degenerado e outra estratégia deve ser utilizada;
- Se  $B$  tem posto completo então calcule a pseudoinversa  $R$  da matriz  $B^T$ ;
- Calcule uma base ortonormal positiva  $N$  para o núcleo de  $B^T$ ;
- Então o Padrão  $P^k$  é dado por:

$$P^k = [-ZR \quad ZN].$$

---

[1] R. M. Lewis, A. Shepherd, V. Torczon. *Implementing generating set search methods for linearly constrained minimization. SIAM Journal on Scientific Computing* 29, 6, pp. 2507-2530 (2007).

## Proposição:

Suponha que para algum  $\delta$ ,  $K(x, \delta)$  tem um conjunto linearmente independente de geradores racionais  $V$ . Seja  $N$  uma base racional positiva para o espaço nulo de  $V^T$ . Então para qualquer  $\epsilon$ ,  $0 \leq \epsilon \leq \delta$ , um conjunto racional de geradores para  $K^\circ(x, \epsilon)$  pode ser obtido entre as colunas de  $N$ ,  $V(V^T V)^{-1}$ , e  $-V(V^T V)^{-1}$ .

Considere também o seguinte conjunto de índices que indicam se o ponto atingiu alguma das faces:

$$\mathbb{I}_2(x^k, \epsilon_2) = \left\{ i : |a_i^T x^k - l_i| \leq \epsilon_2 \text{ ou } |a_i^T x^k - u_i| \leq \epsilon_2 \right\},$$

$$V_{\epsilon_2} = \left\{ a_i : i \in \mathbb{I}_2(x^k, \epsilon_2) \right\}.$$

## Padrão 2: Proposto neste trabalho

- Determine uma base racional  $T$  para o núcleo da matriz  $V_e$ ;
- Determine uma base racional  $N$  para o núcleo da matriz  $V_d$ ;
- Determine uma base racional  $T_2$  para o núcleo da matriz  $V_{e2}$ ;
- Determine a matriz  $F = V_d(V_d^T V_d)^{-1}$ , a qual é obtida pela resolução de vários sistemas lineares utilizando a mesma matriz de coeficientes, sendo assim, utilizamos a fatoração de Cholesky da matriz  $(V_d^T V_d)$ ;
- O Padrão  $P^k$  fica da seguinte forma:

$$[P^k] = [-T \quad T \quad -N \quad N \quad F \quad -F \quad T_2 \quad -T_2]$$

# Padrão 1: Problemas degenerados

- Os autores não utilizam a Pseudo-inversa neste caso;
- Citam que trata-se se de um cone com vértice degenerado na origem;
- Encontrar o Padrão é um caso especial de encontrar os vértices e raios extremos de um poliedro;
- Esse é um problema que já foi bastante estudado;
- Vários algoritmos vem sendo desenvolvidos para resolver esse problema;
- Os autores utilizam o pacote [cddlib](#) desenvolvido por K. Fukuda;
- Segundo os autores mostrou-se eficiente na prática em boa parte dos problemas;

## Padrão 2: Problemas degenerados

- Quando o conjunto de trabalho é degenerado não é possível obter a fatoração de Cholesky da matriz  $(V_d^T V_d)$ ;
- Propomos substituir a solução dos sistemas lineares pela solução de Quadrados Mínimos;
- Utilizamos a fatoração QR da matriz  $(V_d^T V_d)$ ;
- É mais cara que a fatoração de Cholesky mas é mais barata que calcular a SVD;
- Se as direções funcionarem não precisamos acionar uma rotina externa para calcular o Padrão.

# Viabilidade dos pontos visitados pelo algoritmo

- Fornecemos um ponto inicial viável;
- A cada iteração devemos manter a viabilidade;
- Lewis, Shepherd e Torczon, utilizam direções de busca normalizadas e constroem o conjunto de restrições  $\epsilon$ -ativas levando em consideração o tamanho do passo na iteração corrente;
- Usando esta estratégia **teoricamente** a viabilidade seria preservada;
- Observamos convergência para pontos não viáveis;
- Devemos tomar cuidado ao adicionar novas direções de busca que possam retornar pontos não viáveis.

## O que propomos...

- Testar a viabilidade de todos os passos antes de aceitar de calcular o valor da função objetivo;
- Garantimos que todos os passos estarão no conjunto viável com a precisão que estipularmos;
- Só calculamos o valor da função objetivo se o passo puder ser aproveitado;
- Podemos adicionar direções de busca que não temos garantias de pertencer ao cone  $K^\circ$ ;
- Consideramos as restrições de caixa neste passo, não adicionando às restrições de desigualdade do problema;
- Diminuímos as chances de trabalhar com conjuntos de trabalho degenerados;
- Aumentamos o custo da iteração, um produto matriz vetor por ponto testado;
- Não precisamos normalizar as direções de busca;
- Podemos tentar passos mais ambiciosos.

# Estratégias de busca

## 1 Busca simples

- ▶ Finalizamos a busca ao encontrar um ponto com valor da função objetivo melhor;

## 2 Busca Completa

- ▶ Testamos todas as direções do Padrão antes de finalizar a busca;

## 3 Busca Simples Ordenando o Padrão

- ▶ Com busca simples a ordem com que testamos as direções pode interferir no número de avaliações da função objetivo;
- ▶ ordenamos as direções considerando resultado de iterações anteriores na qual obtemos sucesso;
- ▶ O custo de ordenar o Padrão deve ser baixo;
- ▶ Testamos primeiramente a direção que ofereceu decréscimo na iteração anterior.

# Testes Computacionais

- Todas as implementações e os testes foram realizados em Matlab versão 7.10;
- Realizamos testes com 62 problemas;
- Os problemas foram divididos em 2 conjuntos:
  - ▶ Problemas suaves: 42 problemas extraídos de [1, 3]
  - ▶ Problemas minimax (não suaves) : 15 problemas extraídos de [2]

---

[1] D. Orban, N.I.M. Gould, P.L. Toint. *CUTEr: Constrained and Unconstrained Testing Environment, revisited*, <http://www.cuter.rl.ac.uk> (2011).

[2] L. Luksan, J. Vlcek. *Test Problems for Nonsmooth Unconstrained and Linearly Constrained Optimization*. Technical report No. 798, (2000).

[3] W. Hock, K. Schittkowski. "Test examples for nonlinear programming code". Springer, Berlin, (1981).

- Testamos todas as estratégias propostas procurando comparar o desempenho de cada Padrão variando a estratégia de busca e atualização do tamanho do passo;
- Testamos a viabilidade para ambos os Padrões;
- Em todos os testes o critério de parada foi  $\alpha_k < 10^{-8}$  ou ao atingir o número máximo de avaliações da função;
- Variamos de  $10$  à  $10^5$  o número máximo de avaliações da função objetivo permitidos;
- Consideramos que o problema foi resolvido se:

$$f(\bar{x}) - f(x^*) \leq 10^{-7} \quad \text{ou} \quad \|\bar{x} - x^*\| \leq 10^{-7}$$

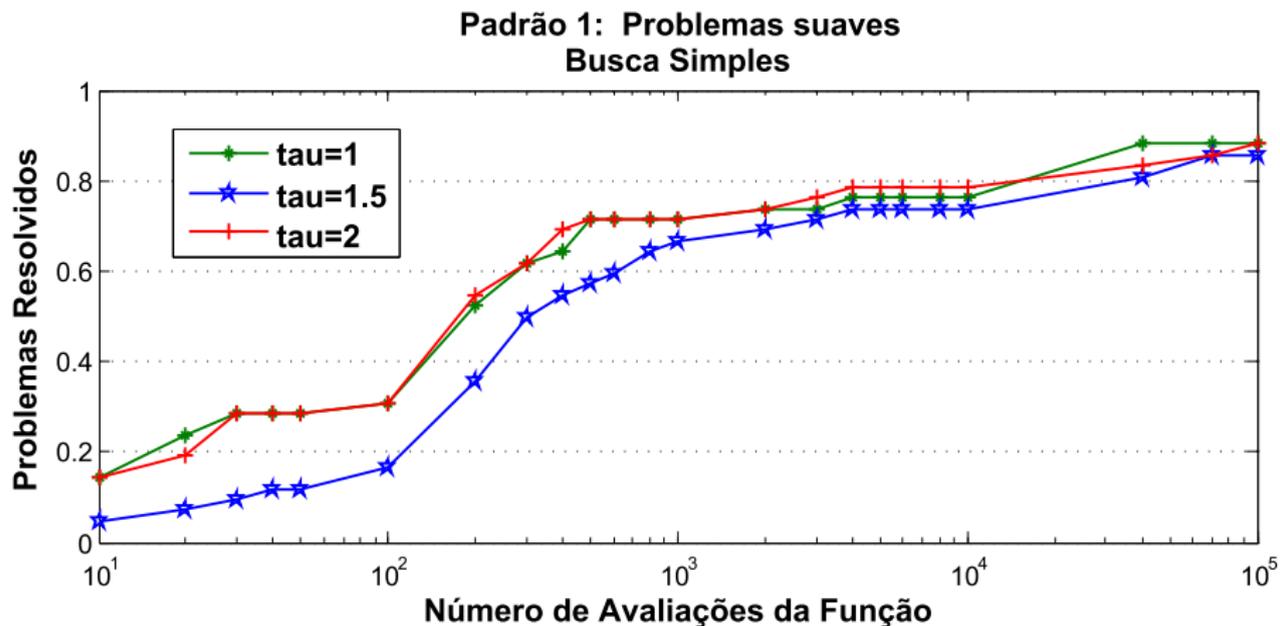


Figura: Problemas suaves: Padrão 1 - Busca Simples

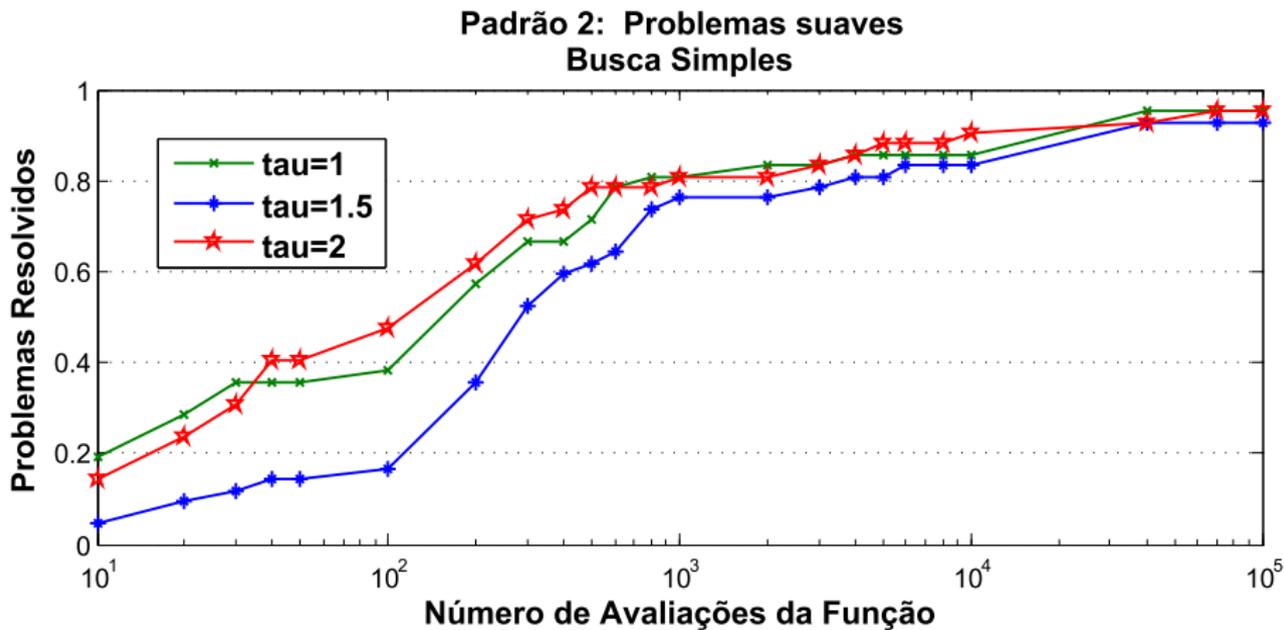


Figura: Atualização do tamanho do passo: Padrão 2 - Busca Simples

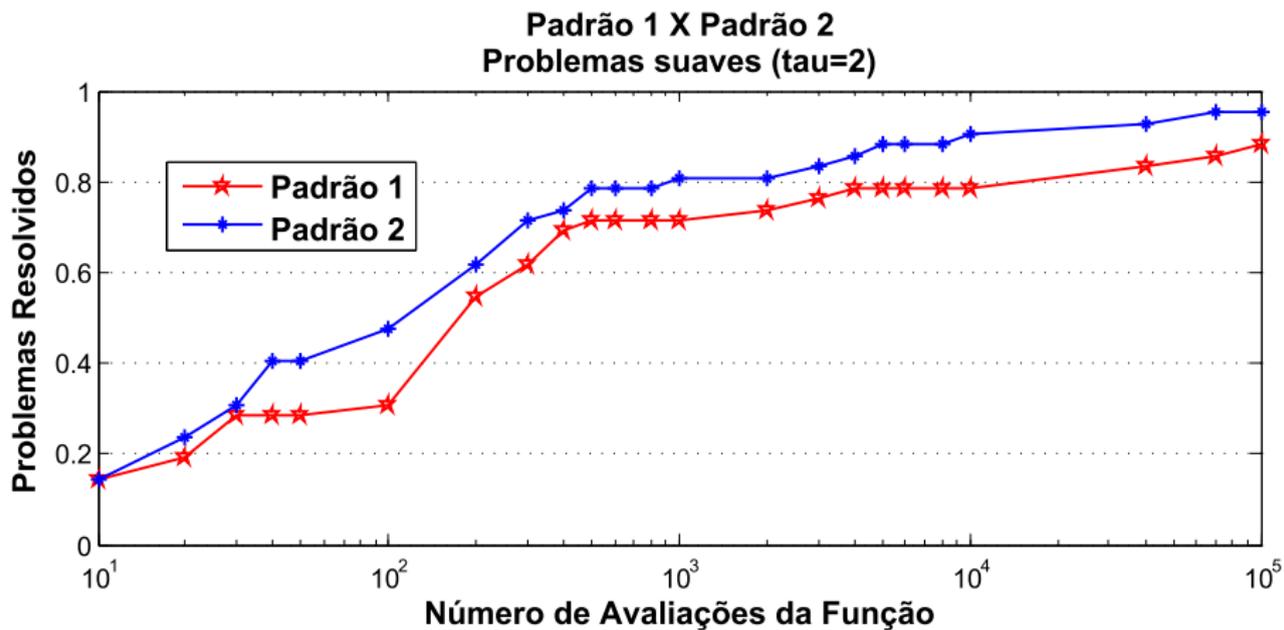


Figura: Padrão 1  $\times$  Padrão 2 - Busca Simples ( $\tau = 2$ )

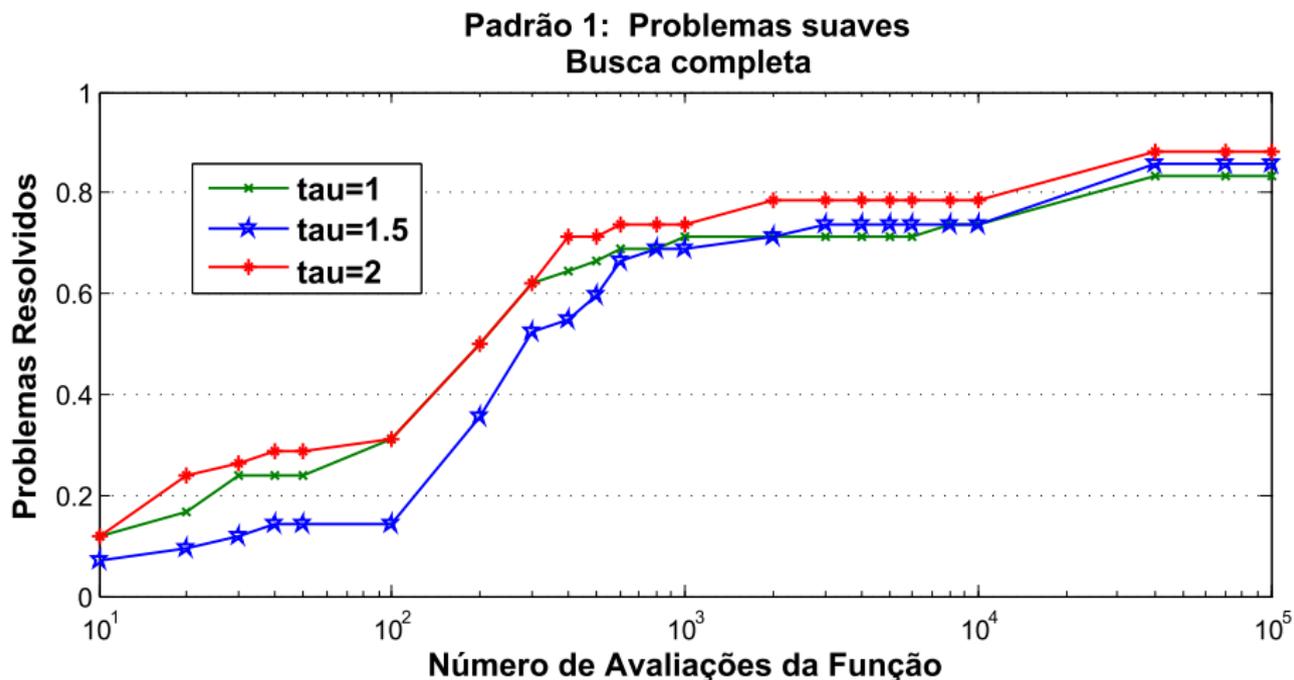


Figura: Atualização do tamanho do passo: Padrão 1 - Busca Completa

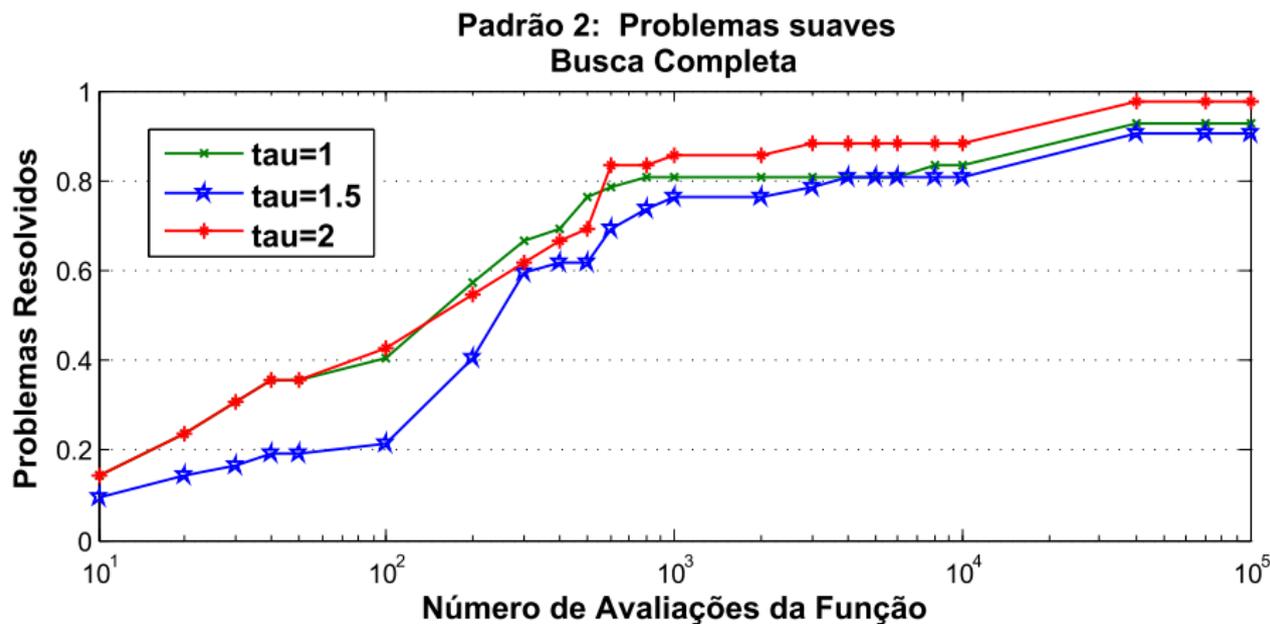


Figura: Atualização do tamanho do passo: Padrão 2 - Busca Completa

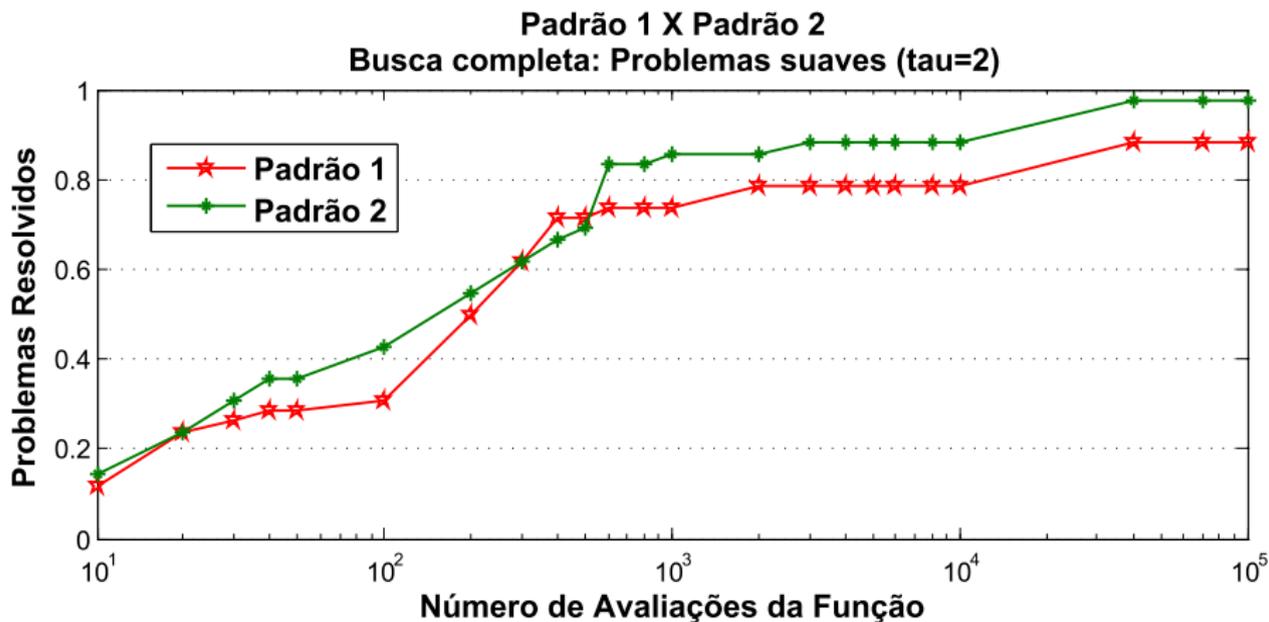


Figura: Padrão 1 × Padrão 2 - Busca Completa ( $\tau = 2$ )

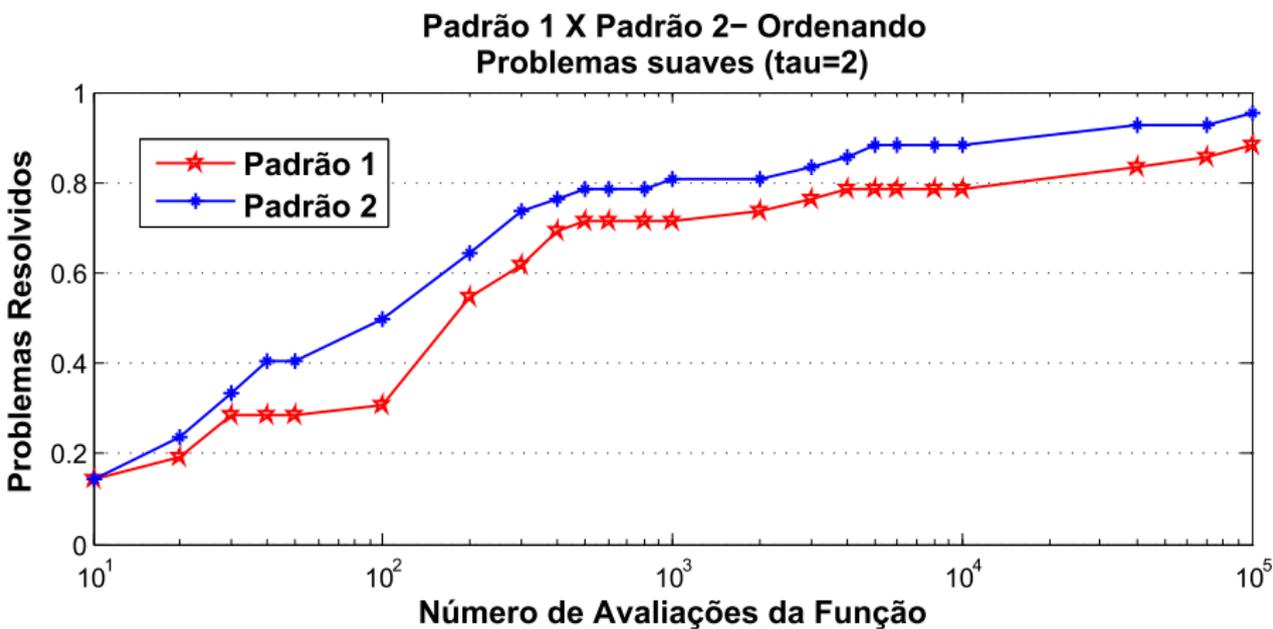


Figura: Padrão 1  $\times$  Padrão 2 - Busca Simples Ordenando o Padrão ( $\tau = 2$ )

### Busca Simples X Busca Completa X Ordenando Padrão 1: Problemas suaves ( $\tau=2$ )

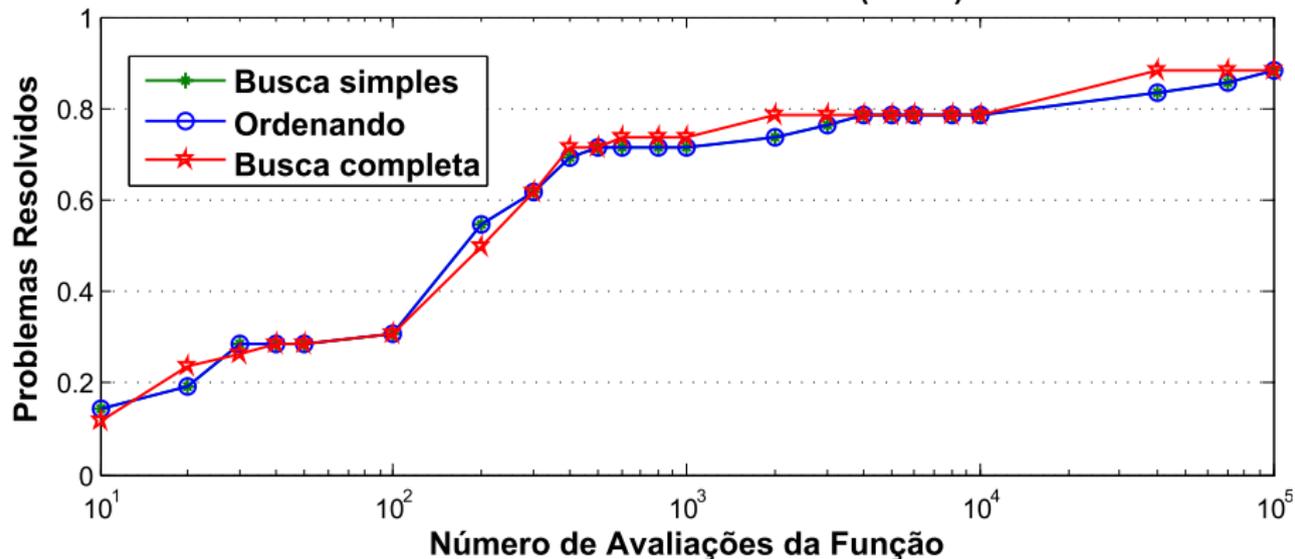


Figura: Padrão 1 - Estratégias de Busca ( $\tau = 2$ )

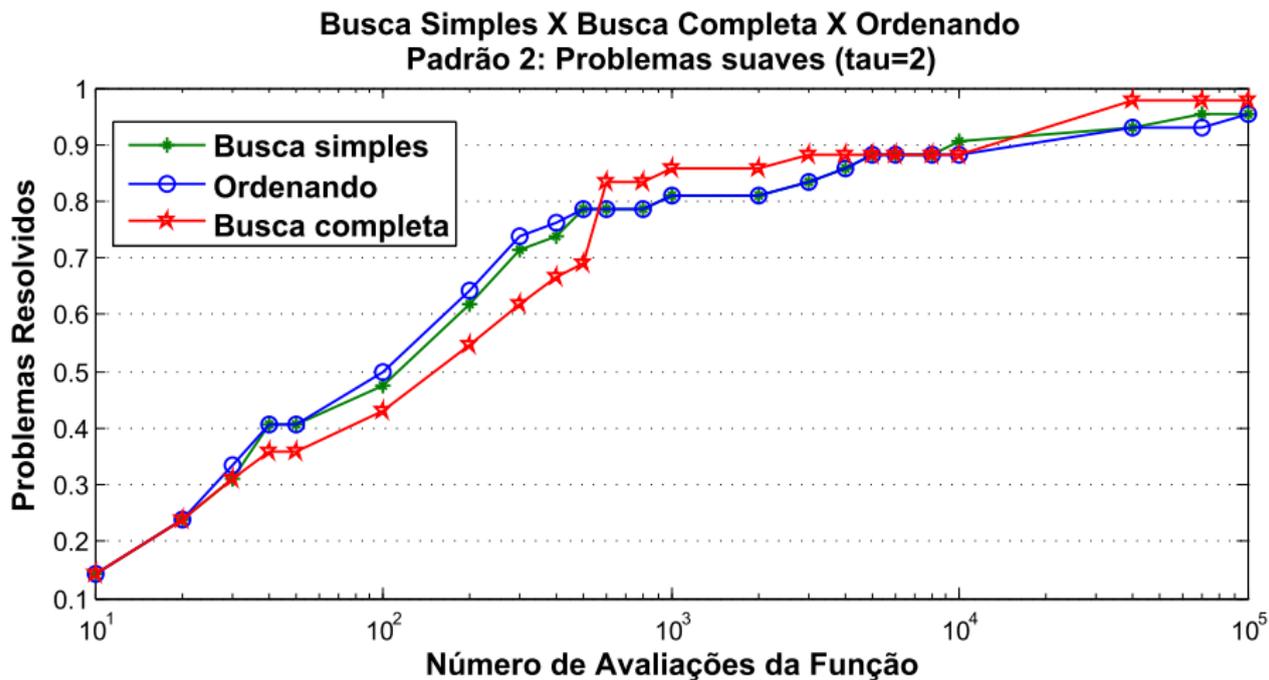


Figura: Padrão 2 - Estratégias de Busca ( $\tau = 2$ )

## Problemas não suaves

- Trabalhamos com problemas minimax definidos por:

$$(P) \begin{cases} \min & f(x) \\ \text{s.a.} & l \leq Ax \leq u \\ & bl \leq x \leq bu \end{cases}$$

onde  $f(x) = \max \{f_1(x), f_2(x), \dots, f_p(x)\}$  tal que  $f_i : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $x \in \mathbb{R}^n$ , e  $A \in \mathbb{R}^{m \times n}$ ,  $l, u \in \mathbb{R}^m$ .

- O custo de avaliar a função objetivo equivale à avaliar  $p$  funções;
- Podemos abordar o problema diretamente ou usando um modelo suave para a função objetivo;
- Não temos teoria de convergência para esse tipo de problema;
- Esperamos um desempenho inferior ao observado para os problemas suaves.

## Padrão 1: Busca Simples

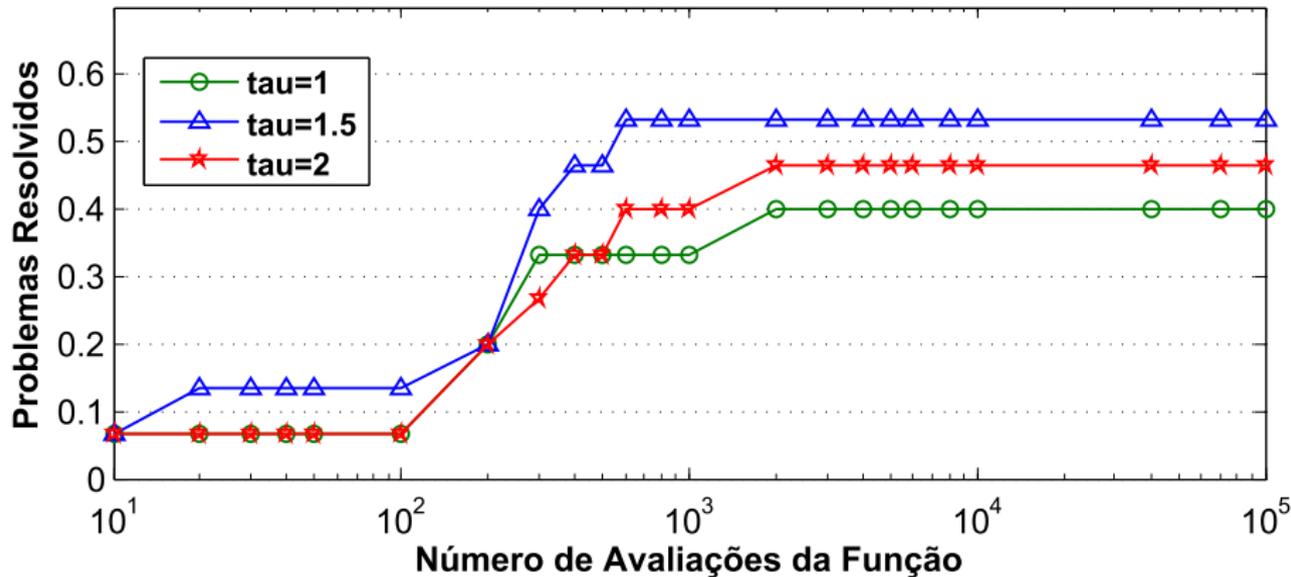


Figura: Problemas não suaves: Padrão 1 - Busca Simples

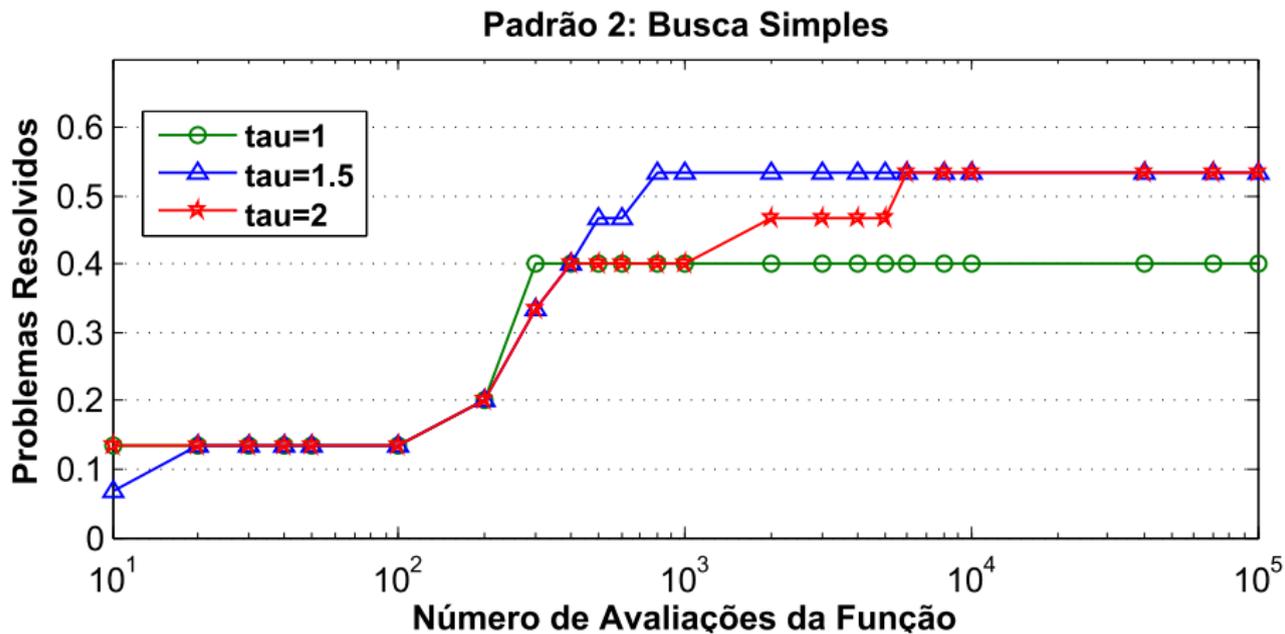


Figura: Problemas não suaves: Padrão 2 - Busca Simples

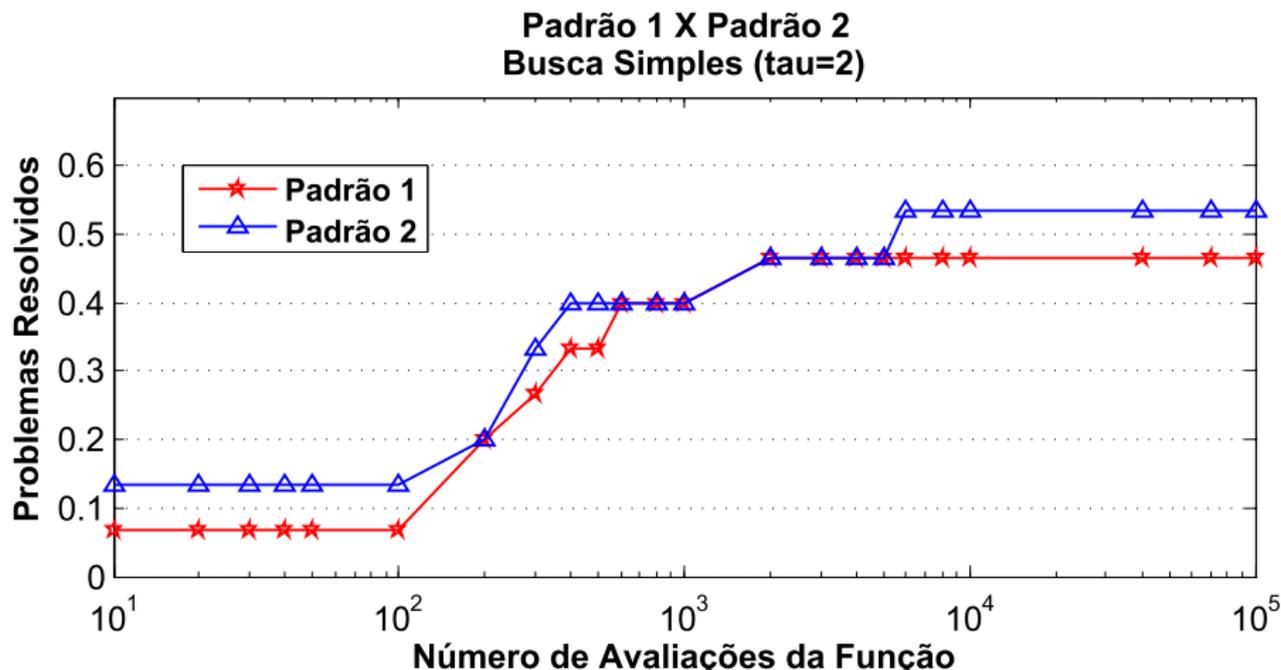


Figura: Padrão 1  $\times$  Padrão 2: Problemas não suaves - Busca Simples ( $\tau = 2$ )

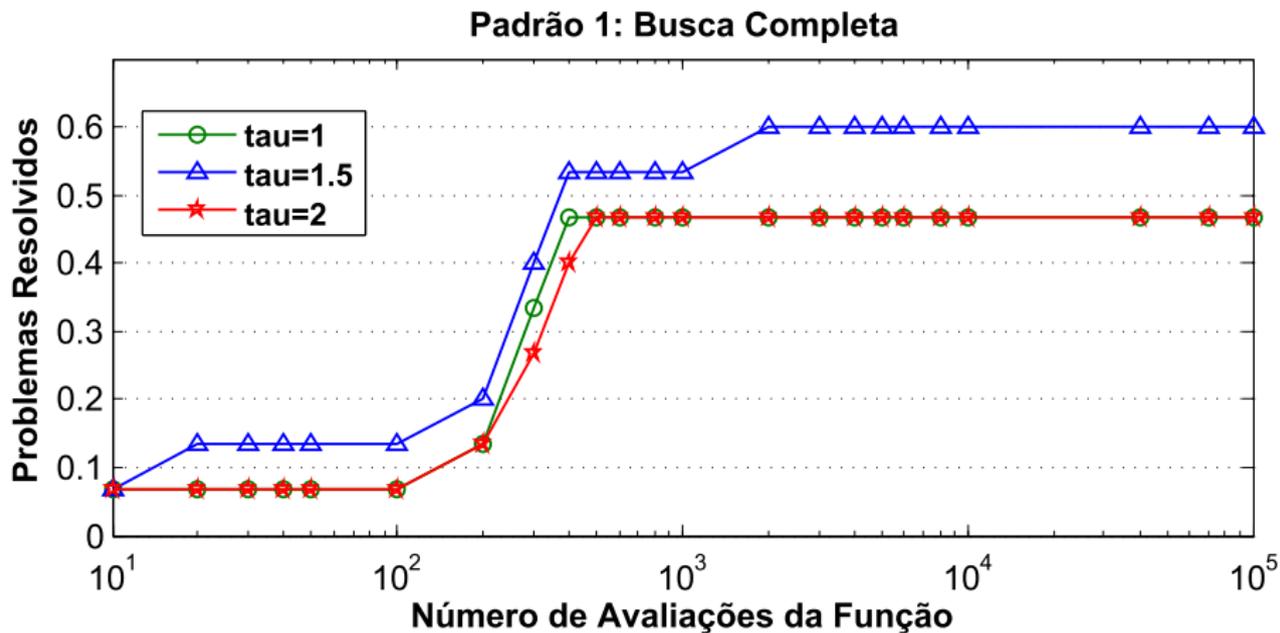


Figura: Problemas não suaves: Padrão 1 - Busca Completa

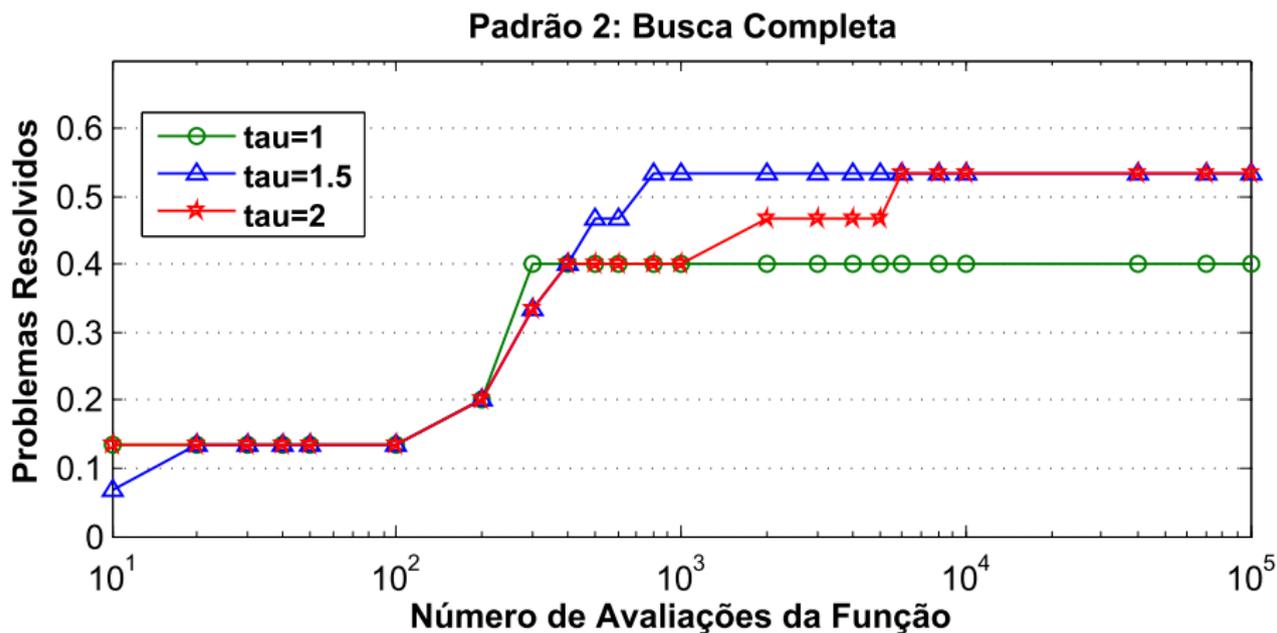


Figura: Problemas não suaves: Padrão 2 - Busca Completa

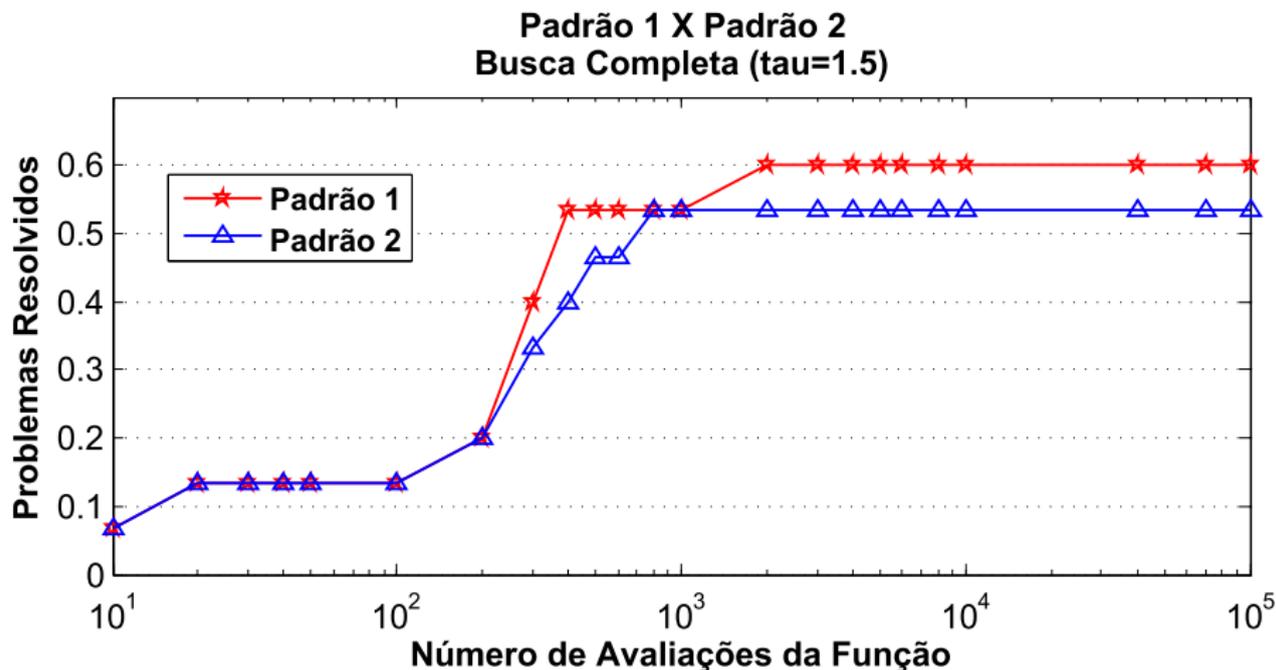


Figura: Padrão 1  $\times$  Padrão 2 - Busca Completa ( $\tau = 1.5$ )

### Busca Simples X Busca Completa X Ordenando Padrão 1 - tau=1.5

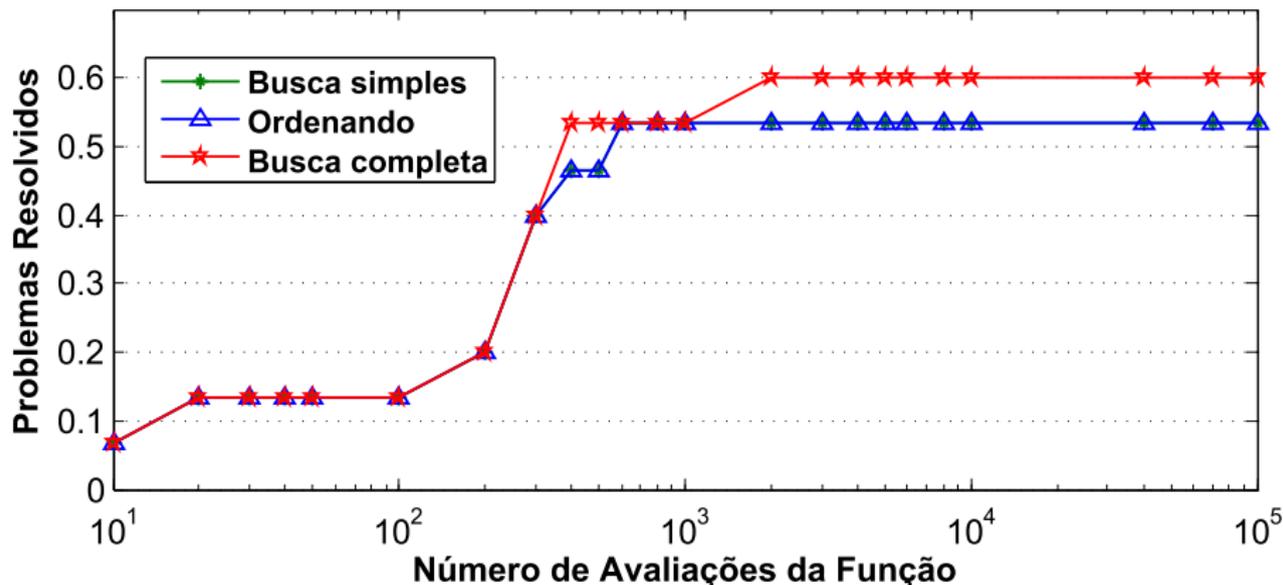


Figura: Problemas não suaves: Padrão 1 - Estratégias de Busca ( $\tau = 1.5$ )

### Busca Simples X Busca Completa X Ordenando Padrão 2 - $\tau=1.5$

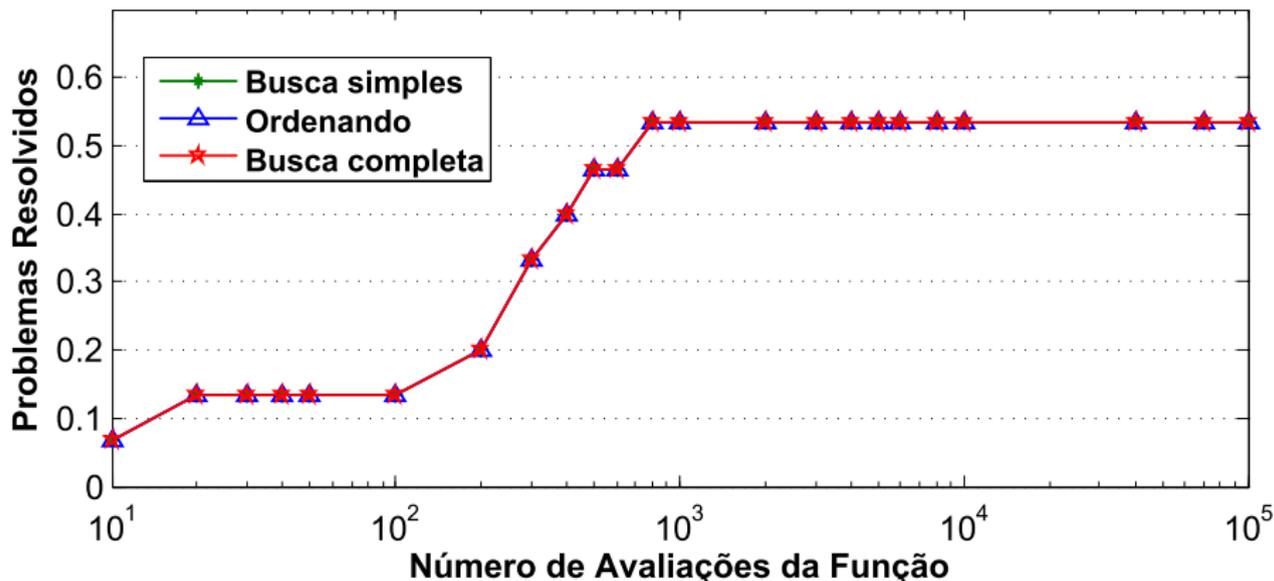


Figura: Problemas não suaves: Padrão 2 - Estratégias de Busca ( $\tau = 1.5$ )

## Modelo suave para problemas Minimax

- O modelo que utilizamos foi proposto em [1] e é dado por:

$$f(x, \mu) = f(x) + \mu \ln \sum_{i=1}^q \exp \left( \frac{f_i(x) - f(x)}{\mu} \right).$$

- Com o uso do modelo esperávamos melhorar a robustez do método;
- No entanto a representação da função através de um modelo já possui um erro;
- Com a precisão considerada nos demais testes os resultados obtidos foram muito ruins.

---

[1] G. Liuzzi, S. Lucide, M. Sciandrone. *A derivative-free algorithm for linearly constrained finite minimax problems*. *SIAM Journal on Optimization* 16, pp. 1054-1075, (2006).

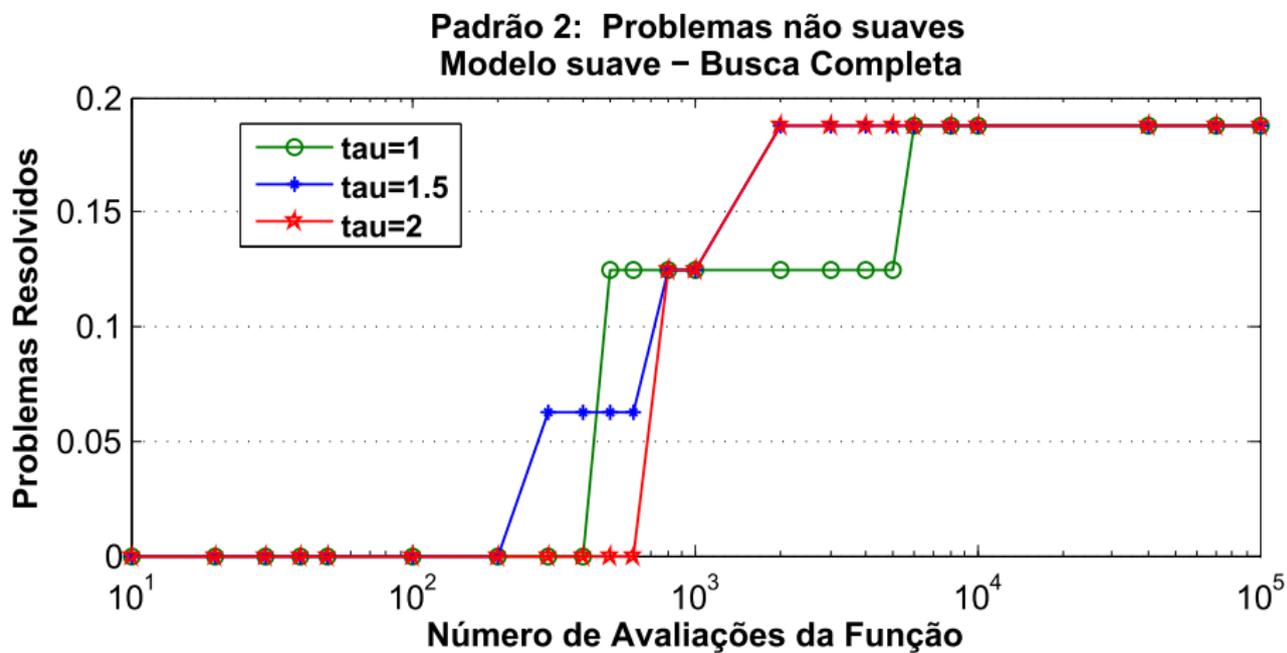


Figura: Busca completa utilizando o modelo exponencial - precisão  $10^{-7}$

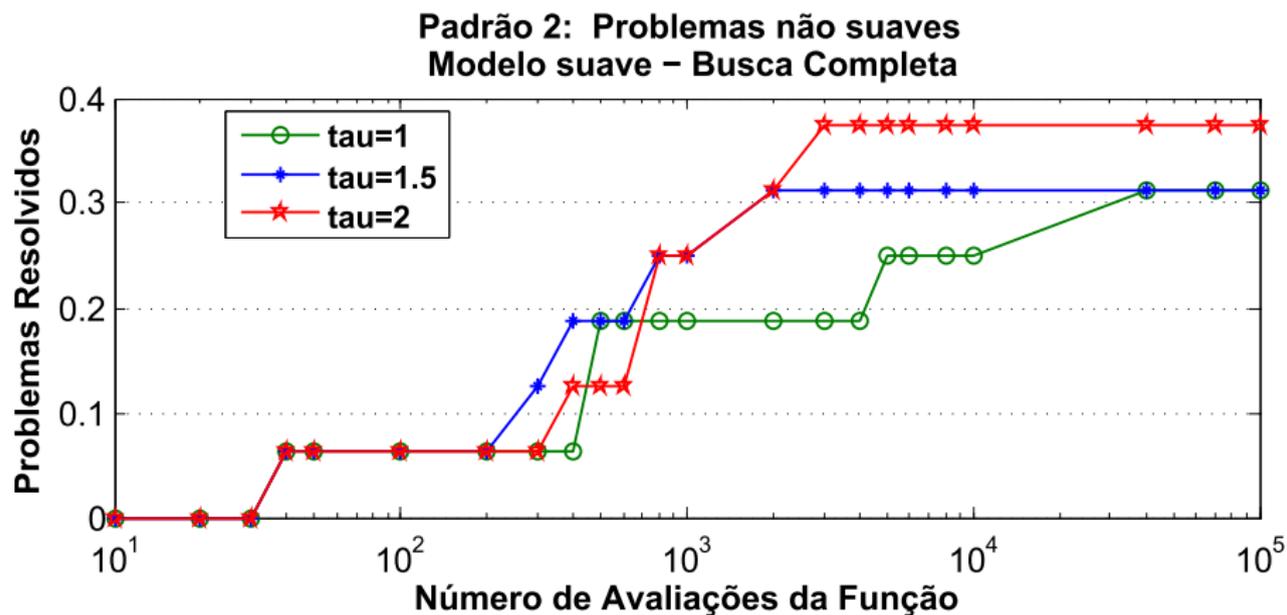


Figura: Busca completa utilizando o modelo exponencial - precisão  $10^{-2}$

# Desempenho Geral do Método

**Número total de avaliações de Função**

Estratégia de busca	$\tau = 1$		$\tau = 1.5$		$\tau = 2$	
	Padrão 1	Padrão 2	Padrão 1	Padrão 2	Padrão 1	Padrão 2
Busca Simples	1157569	922526	954809	716911	1079561	681250
Ordenando o Padrão	1159984	919083	889906	652220	1104810	705836
Busca Completa	976152	798572	599952	524204	778933	545604

**Tabela:** Número total de Avaliações de Função

## Problemas com restrições degeneradas

- Em [1] os autores reportam como problemas degenerados problemas contendo apenas restrições de igualdade e de caixas;
- Em nossa abordagem apenas problemas contendo restrições de desigualdade podem apresentar conjunto de trabalho degenerado;
- Os autores acrescentam as restrições de caixas à matriz de restrições;
- Em nossa abordagem não consideramos as restrições de caixa juntamente com as restrições do problema;
- Apenas fiscalizamos para que estas sejam sempre satisfeitas;
- Considerando restrições de caixa como restrições de desigualdade do problema muitos problemas não degenerados passam a ser degenerados;
- O desempenho do método cai drasticamente como podemos observar pela figura.

---

[1] R. M. Lewis, A. Shepherd, V. Torczon. *Implementing generating set search methods for linearly constrained minimization*. *SIAM Journal on Scientific Computing* 29, 6, pp. 2507-2530 (2007).

## Padrão 1 X Padrão 2 X Padrão 3

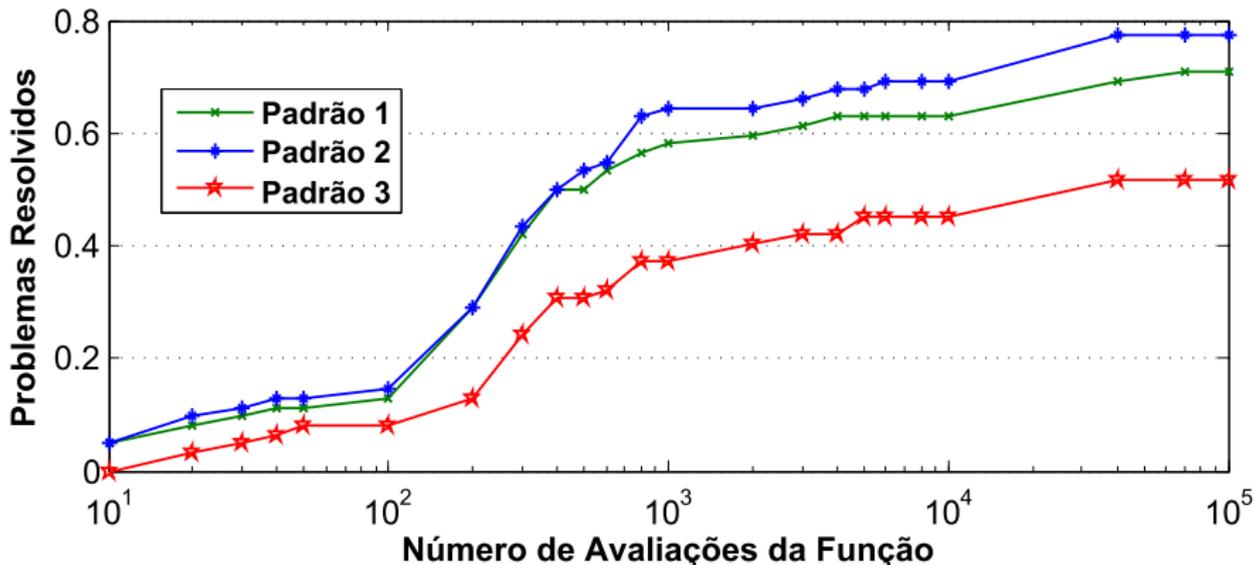


Figura: Teste de viabilidade

Problemas Degenerados				
Problema	# variáveis	# Desigualdades	Lower	Uper
#118 [3]	15	29	15	15
Pentagon [2]	6	15	0	0
Hatfldh [1]	4	7	4	4

Tabela: Problemas Degenerados

[1] D. Orban, N.I.M. Gould, P.L. Toint. *CUTEr: Constrained and Unconstrained Testing Environment, revisited*, <http://www.cuter.rl.ac.uk> (2011).

[2] L. Luksan, J. Vlcek. *Test Problems for Nonsmooth Unconstrained and Linearly Constrained Optimization*. Technical report No. 798, (2000).

[3] W. Hock, K. Schittkowski. "Test examples for nonlinear programming code". Springer, Berlin, (1981).

<b>Busca Simples - <math>\tau = 2</math></b>				
Problema	$f(\bar{x}) - f(x^*)$		# avaliações da Função	
	Padrão 1	Padrão 2	Padrão 1	Padrão 2
#118 [7]	2.1224e+0	-2.0540e-8	100003	4596
Pentagon [3]	4.0689e-4	2.0224e-9	2996	2096
Hatfldh [1]	0.0000e+0	0.0000e+0	128	131

Tabela: Problemas Degenerados - Busca Simples

<b>Busca Completa - <math>\tau = 2</math></b>				
Problema	$f(\bar{x}) - f(x^*)$		# avaliações da Função	
	Padrão 1	Padrão 2	Padrão 1	Padrão 2
#118 [7]	1.4473e+0	-4.8278e-8	42155	15149
Pentagon [3]	3.6431e-3	3.4565e-2	1539	1717
Hatfldh [1]	0.0000e+0	0.0000e+0	132	137

Tabela: Problemas Degenerados - Busca Completa

## Considerações Finais

- O método estudado é simples e exigindo muito pouco do problema para ser aplicado possui teoria de convergência global;
- Obtemos uma excelente precisão na solução;
- As estratégias que propomos obtiveram bons resultados;
- O Padrão 2 que propomos se mostrou muito superior em praticamente todos os testes;
- Com busca simples vale a pena ordenar o Padrão de direções;
- Ainda que a convergência seja lenta o método se mostrou bastante robusto
- Não foi possível observar uma estratégia ótima para todos os problemas;
- Nada podemos concluir a respeito do Padrão proposto para problemas degenerados;

# Referências Bibliográficas

-  D. Orban, N.I.M. Gould, P.L. Toint. CUTER: Constrained and Unconstrained Testing Environment, revisited, <http://www.cuter.rl.ac.uk> (2011).
-  G. Liuzzi, S. Lucide, M. Sciandrone. A derivative-free algorithm for linearly constrained finite minimax problems. *SIAM Journal on Optimization* 16, pp. 1054-1075, (2006).
-  L. Luksan, J. Vlcek. Test Problems for Nonsmooth Unconstrained and Linearly Constrained Optimization. Technical report No. 798, (2000).
-  V. Torczon. On the convergence of pattern search algorithms. *SIAM Journal on Optimization* 7, pp. 1-25 (1997).
-  R. M. Lewis, V. Torczon. Pattern search algorithms for linearly constrained minimization. *SIAM Journal on Optimization* 10, pp. 917-941 (2000).
-  R. M. Lewis, A. Shepherd, V. Torczon. Implementing generating set search methods for linearly constrained minimization. *SIAM Journal on Scientific Computing* 29, 6, pp. 2507-2530 (2007).
-  W. Hock, K. Schittkowski. "Test examples for nonlinear programming code". Springer, Berlin, (1981).

# OBRIGADA!

## Critérios de Parada

- É intuitivo tomar como critério de parada  $|\alpha_k| < tol$ ;
- Deixar o tamanho do passo suficientemente pequeno garante que estamos próximos de um ponto estacionário?

### Proposição 1:

Seja  $x \in \Omega$ . Defina  $q(x) = P_{\Omega}(x - \nabla f(x)) - x$ . Então

$$\|q(x)\| \leq \|\nabla f(x)\|$$

e  $x$  é um ponto estacionário para o problema com restrições lineares (PRL) se e somente se  $q(x) = 0$ .

## Critérios de Parada

### Proposição 2:

Suponha que  $\nabla f(x)$  é Lipschitz contínua em  $L_\Omega(x^0)$ , com constante de Lipschitz  $C$ . Se  $x^k$  é o ponto obtido numa iteração onde houve fracasso, então existe uma constante  $\hat{c} > 0$  que satisfaz:

$$\|q(x^k)\|^2 \leq \hat{c}\alpha_k$$

- Logo o critério de parada mais intuitivo que pode ser tomado é um bom critério de parada, pois temos garantias que de fato estamos próximos da solução.
- Adicionalmente paramos o algoritmo ao atingir um número máximo de avaliações da função objetivo.

## Hipóteses - “Fracas”

- 1 O Padrão  $P^k = [\Gamma^k \ L^k] \in \mathbb{Z}^{n \times p^k}$ ,  $p^k > n + 1$ , Então todas as direções de busca são inteiras, multiplicadas por  $\alpha_k \in \mathbb{R}^n$ ;
- 2  $\Gamma^k \in \mathbb{Z}^{n \times r^k}$ ,  $r^k \geq n + 1$ , pertence à  $\Gamma$ , que é um conjunto finito de matrizes inteiras cujas colunas incluem geradores para todos os cones  $K^o(x^k, \epsilon)$ ;
- 3 A matriz  $L^k \in \mathbb{Z}^{n \times (p^k - r^k)}$  contém pelo menos uma coluna (nula);
- 4 A atualização de  $\alpha_k$  segue as regras especificadas;
- 5 São satisfeitas as hipóteses sobre os movimentos exploratórios;
- 6 A matriz de restrições  $A$  é racional;
- 7 O conjunto de nível  $L_\Omega(x^0) = \{x \in \Omega \mid f(x) \leq f(x^0)\}$  é compacto;
- 8 A função objetivo  $f(x)$  é continuamente diferenciável em uma vizinhança aberta  $D$  de  $L_\Omega(x^0)$ .

# Resultado de Convergência

## Teorema

Assuma que as hipóteses 1-8 são satisfeitas. Seja  $\{x^k\}$  uma sequência gerada pelo Método de busca Padrão Genaralizado para minimização com restrições lineares, então:

$$\liminf_{k \rightarrow \infty} \|q(x^k)\| = 0$$

## Corolário

Existe um ponto limite de  $\{x^k\}$  que é um ponto KKT para o problema (PRL).

## Hipóteses - “Fortes”

- 1 O Padrão  $P^k = [\Gamma^k \ L^k] \in \mathbb{Z}^{n \times p^k}$ ,  $p^k > n + 1$ , Então todas as direções de busca são inteiras, multiplicadas por  $\alpha_k \in \mathbb{R}^n$ ;
- 2  $\Gamma^k \in \mathbb{Z}^{n \times r^k}$ ,  $r^k \geq n + 1$ , pertence à  $\Gamma$ , que é um conjunto finito de matrizes inteiras cujas colunas incluem geradores para todos os cones  $K^o(x^k, \epsilon)$ ;
- 3 A matriz  $L^k \in \mathbb{Z}^{n \times (p^k - r^k)}$  contém pelo menos uma coluna (nula);
- 4 A atualização de  $\alpha_k$  segue as regras especificadas;
- 5 São satisfeitas as hipóteses fortes sobre os movimentos exploratórios;
- 6 A matriz de restrições  $A$  é racional;
- 7 O conjunto de nível  $L_\Omega(x^0) = \{x \in \Omega \mid f(x) \leq f(x^0)\}$  é compacto;
- 8 A função objetivo  $f(x)$  é continuamente diferenciável em uma vizinhança aberta  $D$  de  $L_\Omega(x^0)$ .
- 9 As colunas do padrão  $P^k$  permanecem limitadas em norma;
- 10 temos que:  $\lim_{k \rightarrow \infty} \alpha_k = 0$

# Resultado de Convergência - “ Forte”

## Teorema

Assuma que as hipóteses fortes 1-10 são satisfeitas. Seja  $\{x^k\}$  uma sequência gerada pelo Método de busca Padrão Genaralizado para minimização com restrições lineares, então:

$$\lim_{k \rightarrow \infty} \|q(x^k)\| = 0$$

## Corolário

Todo ponto limite de  $\{x^k\}$  é um ponto KKT para o problema (PRL).