

# Otimização ELE037

## Introdução

Jaime A. Ramírez  
Felipe Campelo  
Frederico G. Guimarães  
Lucas S. Batista  
Ricardo H.C. Takahashi

Universidade Federal de Minas Gerais  
Departamento de Engenharia Elétrica

- 1 Introdução
- 2 O Jogo da Otimização
- 3 Otimização sem Restrições
- 4 Otimização com Restrições de Desigualdade
- 5 Otimização com Restrições de Igualdade
- 6 Otimização Linear

Assunto abordado:

- O problema de otimização;
- Otimização de funções matemáticas simples (2 variáveis);
- Caracterização de diferentes tipos de funções;
- Caracterização de diferentes estratégias de otimização;
- Princípio de funcionamento dos métodos de otimização.

# O Jogo da Otimização

## Introdução

A *Otimização* representa um conjunto de ferramentas capazes de determinar as melhores configurações possíveis para a construção ou o funcionamento de sistemas de interesse.

A mesma teoria é aplicada a diferentes contextos:

- Projeto de circuitos, antenas, motores (Eng. Elétrica);
- Controle de processos industriais (Eng. CA);
- Política eficiente de vacinação (Mat. Computacional);
- Otimização do tráfego de informação em redes (Cientista da Computação);
- etc.

# O Jogo da Otimização

## Formulação do Problema

Como modelar um problema de otimização?

Formalmente, um problema de otimização pode ser definido por:


$$\begin{aligned} \mathbf{x}^* = \arg \min_{\mathbf{x}} f(\mathbf{x}) \\ \text{sujeito a: } \begin{cases} g_i(\mathbf{x}) \leq 0; i = 1, \dots, p \\ h_j(\mathbf{x}) = 0; j = 1, \dots, q \end{cases} \end{aligned} \quad (1)$$

Obs.: variáveis em negrito são vetores; as demais são escalares.

# O Jogo da Otimização

## Formulação do Problema: exemplo

Seja o problema de otimização de um alto-falante como ilustrado a seguir.



Objetivo:

- Minimizar o volume do alto-falante e atender um valor mínimo de densidade de fluxo magnético  $\mathbf{B}$  no entreferro.


Matematicamente:

$$\begin{cases} \min: f(\mathbf{x}) = \text{volume} \\ \text{sujeito a: } g_1(\mathbf{x}) : |\mathbf{B}| \geq \mathbf{B}_{min} \end{cases}$$

# O Jogo da Otimização

## Formulação do Problema: exemplo

Modelo 2D do alto-falante:



Questões práticas:

- Como calcular o volume do alto-falante usando  $x_1, \dots, x_{16}$ ?
- Quais os limites de  $x_1, \dots, x_{16}$ ?
- Quais materiais serão usados?
- Como calcular **B**?

# O Jogo da Otimização

Formulação do Problema: o vetor de variáveis de decisão

O vetor  $\mathbf{x}$  é o *vetor de variáveis de otimização*.

O processo de otimização busca especificar os valores destas variáveis.

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (2)$$

O vetor  $\mathbf{x}$  possui um significado concreto/físico?

O vetor  $\mathbf{x}$  é composto de variáveis reais ou discretas?

As técnicas de otimização são as mesmas para qualquer representação das variáveis de decisão?



# O Jogo da Otimização

Formulação do Problema: a função objetivo

A *função objetivo*  $f(\cdot)$ , ou *função custo*:

- Representa um índice específico do sistema, cujo valor, por convenção, queremos minimizar para alcançarmos o desempenho ótimo.

Qual a possível função custo do projeto do alto-falante?

Qual a possível função custo do projeto de um motor?

Ex. funções de custo: consumo de combustível; ruído; probabilidade de defeitos, etc.

# O Jogo da Otimização

Formulação do Problema: a função objetivo

Como tratar problemas de maximização?

Neste caso basta minimizarmos a função que se deseja maximizar multiplicada por -1.

Maximizar a função  $p(\mathbf{x})$  é o mesmo que minimizar  $f(\mathbf{x}) = -p(\mathbf{x})$ .

O vetor  $\mathbf{x}$  que minimiza  $f(\cdot)$  é também o vetor que maximiza  $p(\cdot)$ .

Note que  $f(\cdot) : \mathbb{R}^n \mapsto \mathbb{R}$ .

# O Jogo da Otimização

Formulação do Problema: a solução ótima

As variáveis de otimização  $\mathbf{x}$  são reais?

No exemplo anterior, quantas possibilidades de construção existem para o alto-falante?

Na solução ótima de um problema de minimização:

O vetor ótimo  $\mathbf{x}^*$  é igual ao **argumento** da função  $f(\cdot)$  que faz com que essa função atinja seu **mínimo** valor.

Como encontrar  $\mathbf{x}^*$ ?

# O Jogo da Otimização

## Formulação do Problema: as restrições

- As restrições significam o conjunto dos requisitos que o resultado do projeto deve atender para ser admissível enquanto solução.
- Restrições de desigualdade:

$$g_i(\mathbf{x}) \leq 0 \quad (3)$$

- Restrições de igualdade:

$$h_j(\mathbf{x}) = 0 \quad (4)$$

# O Jogo da Otimização

## Formulação do Problema: as restrições

Restrições de natureza não-técnica:

São fisicamente implementáveis, porém violam certos padrões.

Exemplo:

- Objetivo: Projeto de um automóvel de baixo custo;
- Restrição: Emissão de gases poluentes abaixo de um limiar estabelecido por lei.

$$g_i(\cdot) : \mathbb{R}^n \mapsto \mathbb{R}^p: g_i(\mathbf{x}) \leq 0, i = 1, \dots, p$$

$$h_j(\cdot) : \mathbb{R}^n \mapsto \mathbb{R}^q: h_j(\mathbf{x}) = 0, j = 1, \dots, q$$

# O Jogo da Otimização

## Formulação do Problema: as restrições

Em relação às restrições, definimos ainda a seguinte nomenclatura:

- **Região factível:** Conjunto dos pontos do espaço  $\mathbb{R}^n$  que satisfazem, simultaneamente, a todas as restrições;
- **Região infactível:** Conjunto dos pontos do espaço  $\mathbb{R}^n$  que violam pelo menos uma das restrições do problema;
- **Ponto factível:** Ponto pertencente à *região factível*;
- **Ponto infactível:** Ponto pertencente à *região infactível*;
- **Restrição violada:** Cada uma das componentes do vetor  $g_i(\mathbf{x})$  que apresentar valor positivo, ou cada uma das componentes do vetor  $h_j(\mathbf{x})$  que apresentar valor não-nulo será chamada de *restrição violada* no ponto  $\mathbf{x}$ .

# O Jogo da Otimização

As regras do jogo: acesso a informação

Regras de acesso à informação:

- Não conhecemos expressões matemáticas explícitas que representem a função objetivo  $f(\cdot)$  e as funções de restrição  $g_i(\cdot)$  e  $h_j(\cdot)$ ;
- Temos, entretanto, a possibilidade de descobrir quanto valem as funções objetivo e de restrição em qualquer ponto do espaço de variáveis de otimização. Essa é a única informação que conseguiremos adquirir, ao longo do processo de otimização, para nos guiar em direção à solução desejada.

Por que nem sempre conhecemos  $f(\mathbf{x})$ ?

Ex.: Qual a função objetivo do problema do alto-falante? E a função de restrição?

# O Jogo da Otimização

As regras do jogo: custo da informação

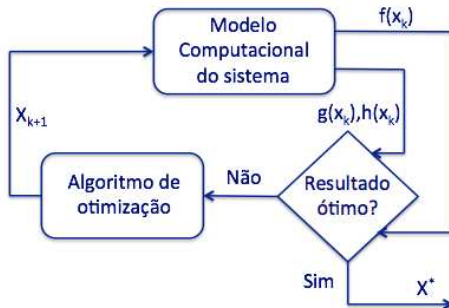
Os métodos de otimização serão comparados entre si de acordo com os critérios:

- Número de avaliações da função objetivo e das restrições;
- Quanto menos avaliações forem necessárias, melhor será considerado o método;
- Precisão e robustez: quanto mais a solução fornecida pelo método se aproximar da solução exata do problema, melhor será considerado o método.



# O Jogo da Otimização

## O processo



# Otimização sem Restrição

## Introdução

Embora  $f(\mathbf{x})$  seja do tipo *caixa-preta*, ela é bem definida.

O processo de otimização utiliza informações locais da superfície de  $f(\mathbf{x})$ .

Problema de minimização de uma função objetivo sem restrição:


$$\mathbf{x}^* = \arg \min_{\mathbf{x}} f(\mathbf{x}) \quad (5)$$

Para viabilizar a representação gráfica do problema, supõe-se  $\mathbf{x} \in \mathbb{R}^2$ .

# Otimização sem Restrição

## Introdução

Consideremos a seguinte função não-linear  $f(\mathbf{x})$ :



**Figura:** Superfície que representa o gráfico de uma função não-linear  $f(\mathbf{x})$  de duas variáveis reais.

# Otimização sem Restrição

## Introdução




Figura: Gráfico de *curvas de nível* de  $f(\mathbf{x})$ .

# Otimização sem Restrição

## Introdução

*Metáfora* para a solução do problema de otimização:

- Um aluno é lançado de pára-quedas sobre um ponto qualquer da superfície de  $f(\mathbf{x})$ ;
- O objetivo do aluno é encontrar o ponto mais baixo de  $f(\mathbf{x})$ , i.e. o *ponto de mínimo*, com o menor número possível de “passos”;
- Deverá caminhar com uma venda cobrindo seus olhos, sem poder “olhar” para a superfície;
- A única informação que ele pode utilizar é a altura do ponto no qual estiver “pisando”;
- Pode, entretanto, se “lembrar” das alturas dos pontos em que já tiver pisado;
- Esta informação pode ser utilizada para tomar a decisão de “para onde caminhar”.

# Otimização sem Restrição

## Introdução

A metáfora descrita anteriormente ilustra bem o que é o problema de otimização.

Construir os chamados **métodos de otimização** corresponde, dentro dessa metáfora, a formular as **estratégias** a serem utilizadas pelo “aluno” em sua **busca pelo ponto de mínimo**.

# Otimização sem Restrição

## Introdução

Que tipo de **estratégia de otimização** utilizar?

Esta escolha depende das características da superfície de  $f(\mathbf{x})$ :

- Diferenciabilidade: diferenciável ou não-diferenciável
- Modalidade: unimodal ou multimodal
- Convexidade: convexa, quasi-convexa, não-convexa
- Linearidade: linear ou não-linear
- Escala: uni-escala ou multi-escala

Estas características são discutidas ao longo da apresentação das diferentes estratégias de otimização.

# Otimização sem Restrição

## Estratégia de direção de busca

Vamos considerar a função quadrática definida por:

$$f(\mathbf{x}) = (\mathbf{x} - \mathbf{x}_0)' Q (\mathbf{x} - \mathbf{x}_0)$$


$$Q = \begin{bmatrix} 2 & 0.3 \\ 0.3 & 1 \end{bmatrix} \quad \mathbf{x}_0 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad (6)$$

cujo gráfico e curvas de nível são ilustrados a seguir.



# Otimização sem Restrição


## Estratégia de direção de busca



**Figura:** Superfície que representa o gráfico de uma função quadrática  $f(x)$  de duas variáveis reais.

# Otimização sem Restrição

## Estratégia de direção de busca



**Figura:** Gráfico de *curvas de nível* da mesma função quadrática de duas variáveis reais,  $f(\mathbf{x})$ .

# Otimização sem Restrição

## Estratégia de direção de busca

*Método do Gradiente (um método de direção de busca)*

O aluno:

- Passo 1: colhe amostras locais da função e determina em qual direção a função decresce mais rapidamente (usa aproximação numérica do **gradiente** da função).
- Passo 2: caminha na direção encontrada enquanto a função decrescer.
- Passo 3: decide se pára (caso considere que esteja suficientemente próximo do ponto de mínimo da função) ou se continua a busca, retornando ao Passo 1.

# Otimização sem Restrição

## Estratégia de direção de busca

### Requisitos exigidos pelas Estratégias de Direção de Busca

- A função deve ser **diferenciável** (a aproximação numérica do gradiente da função contém informação significativa sobre a forma como a função varia nas vizinhanças do ponto em que tiver sido estimado).
- A função deve ser **unimodal** (possuir **um único mínimo global**, no interior de **uma única bacia de atração**).


# Otimização sem Restrição

## Estratégia de direção de busca

Consideremos uma função um pouco mais complexa.

Função de Rosenbrock (diferenciável e unimodal;  $\mathbf{x}^* = [1 \ 1]'$ ).

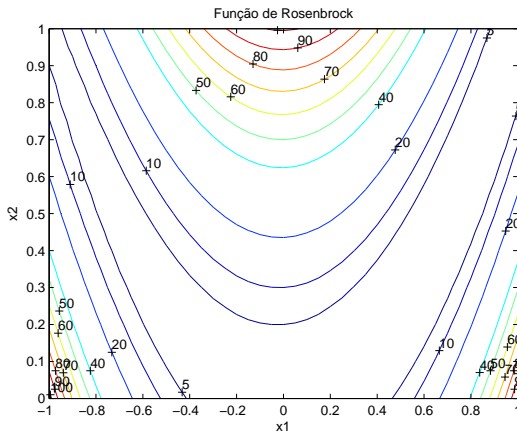
Função de Rosenbrock



# Otimização sem Restrição

## Estratégia de direção de busca

O *Método do Gradiente* é eficiente para resolver este problema?  
Existem outros *Métodos de Direção de Busca* mais eficientes?



# Otimização sem Restrição

## Questões práticas


Consideremos agora uma função  $f(\mathbf{x})$  com as seguintes características:

- Ainda **unimodal**;
- Porém **não-diferenciável**.

Qual a dificuldade encontrada por técnicas de Direções de Busca?

# Otimização sem Restrição

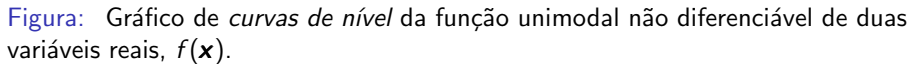
## Questões práticas



**Figura:** Superfície que representa o gráfico de uma função unimodal não diferenciável  $f(\mathbf{x})$  de duas variáveis.



## Questões práticas



# Otimização sem Restrição


## Questões práticas

- Como tratar problemas unimodais e não-diferenciáveis usando Métodos de Direção de Busca?
- A não-diferenciabilidade ocorre em todos os pontos da função?
- Como saber, numericamente, se a função não é diferenciável em um ponto específico?
- Quando identificada a não-diferenciabilidade em um ponto, o que fazer?
- **A otimização por esses métodos pode se tornar inviável.**
- **Esta dificuldade é intrínseca a toda a família dos métodos de direção de busca.**

# Otimização sem Restrição

## Questões práticas

Dificuldade encontrada pelos Métodos de Direção de Busca em funções não-diferenciáveis:



# Otimização sem Restrição

## Estratégia de exclusão de regiões

- Funções não-diferenciáveis são muito comuns em problemas práticos.
- Uma nova família de métodos é formulada para tratar tais problemas.
- Métodos de Exclusão de Regiões:
  - Unimodalidade da função;
  - Diferenciabilidade não é exigida;
  - **Convexidade da função.**

# Otimização sem Restrição

## Estratégia de exclusão de regiões

Por que a função  $f(\mathbf{x})$  precisa ser **convexa**?

- Uma curva de nível de uma função convexa sempre delimita uma região convexa em seu interior.
- O vetor gradiente é sempre perpendicular à curva de nível que passa pelo ponto onde o vetor foi calculado.
- A reta perpendicular ao vetor gradiente que passa no ponto onde esse vetor foi calculado é tangente à curva de nível.
- Devido à convexidade da região no interior da curva de nível, esta região sempre fica inteiramente localizada em apenas um dos lados dessa reta tangente.

### Funcionamento do Método de Exclusão de Regiões

Partindo de um ponto inicial sobre o espaço de busca:

- Passo 1: adquire-se informação local, e faz-se uma **estimativa do gradiente** da função objetivo nesse ponto.
- Passo 2: com base no gradiente, identifica-se qual é a **reta tangente à curva de nível que passa pelo ponto atual** (todo o semi-plano que contém o vetor gradiente é descartado).
- Passo 3: move-se para algum ponto no interior da região que ainda não foi descartada.
- Passo 4: caso o novo ponto esteja suficientemente próximo do mínimo da função, o processo termina. Do contrário, retorna-se ao Passo 1.

# Otimização sem Restrição

## Estratégia de exclusão de regiões

Algumas observações:


- A convergência do método ocorre devido a **diminuição sistemática da região** que contém  $\mathbf{x}^*$ .
- Como a região “viável” diminui, o novo ponto **tende** a aproximar-se cada vez mais de  $\mathbf{x}^*$ .
- A não-diferenciabilidade não impede a convergência do método.

Qual o possível critério de parada do método?

Qual a relação entre a **velocidade de convergência** no início e no final do processo de otimização?

# Otimização sem Restrição

## Estratégia de exclusão de regiões



**Figura:** Iterações de um método de exclusão de regiões, mostradas sobre as curvas de nível de uma função cujo mínimo exato é  $x^*$ .



# Otimização sem Restrição

## Estratégias de populações

- Grande parte das funções objetivo que queremos otimizar na prática, infelizmente, **não são unimodais**.
- Note que **uma função multimodal também não é convexa**. Mas pode apresentar regiões convexas.
- Por consequência, tanto as estratégias de **direção de busca** quanto as estratégias de **exclusão de regiões** *irão falhar* em sua otimização.

# Otimização sem Restrição

## Estratégias de populações

- Caso  $f(\mathbf{x})$  seja multimodal, o resultado encontrado por qualquer uma das técnicas estudadas sempre será o **mínimo local** associado à bacia de atração onde a busca tiver sido iniciada.
- Para determinar o mínimo global, todas as bacias devem ser investigadas.
- As **estratégias de populações** evoluem um **conjunto de soluções candidatas** em paralelo, e estas cooperam entre si.

# Otimização sem Restrição

## Estratégias de populações

Considere a função  $f(\mathbf{x})$  multimodal:




Figura: Função multimodal

# Otimização sem Restrição

## Estratégias de populações




Figura: Curvas de nível da função multimodal

# Otimização sem Restrição

## Estratégias de populações

### Vários Otimizadores:


- Passo 1: encontram-se distribuídos no espaço de busca, e colhem **informações locais** da função.
- Passo 2: comunicam entre si, e **trocam informações** a respeito dos valores da função objetivo em cada ponto.
- Passo 3: um pequeno sub-grupo de Otimizadores, que estiver nas melhores regiões, fica parado.
- Passo 4: os demais se deslocam, com movimentos que simultaneamente: (i) os façam se **aproximarem daqueles melhor localizados**; e (ii) os façam **explorarem outras regiões** ainda não investigadas.
- Passo 5: cada Otimizador avalia a função no ponto para onde foi.
- Passo 6: o algoritmo pára ou retorna ao Passo 2.

### Algoritmos baseados em Populações

- Vantagem (não exigem unimodalidade, convexidade ou diferenciabilidade).
- Limitação (custo computacional elevado).
- Quando são úteis?
- Métodos híbridos:
  - São viáveis? Por que? (ex.: custo computacional)
  - Quando podem ser empregados? (ex.: funções multi-escala)
  - Quais requisitos devem ser considerados? (ex.: convexidade)

# Otimização sem Restrição


## Estratégias de populações



**Figura:** Superfície que representa o gráfico de uma função multimodal  $f(x)$  de duas variáveis que apresenta a característica de *múltiplas escalas*.

# Otimização sem Restrição

## Estratégias de populações



**Figura:** Superfície que representa o gráfico de uma função multimodal  $f(\mathbf{x})$  de duas variáveis que apresenta a característica de *múltiplas escalas*.



# Otimização com Restrições de Desigualdade

## Introdução

Suponha agora um problema de otimização com **restrições de desigualdade**:

$$\mathbf{x}^* = \arg \min_{\mathbf{x}} f(\mathbf{x}) \quad (7)$$

Sujeito a:  $\{ g_i(\mathbf{x}) \leq 0; i = 1, \dots, p$

# Otimização com Restrições de Desigualdade

## Introdução

O ponto de ótimo  $\mathbf{x}^*$  deve satisfazer às  $p$  desigualdades:

$$g_1(\mathbf{x}^*) \leq 0$$

$$g_2(\mathbf{x}^*) \leq 0$$

$$\vdots$$

$$g_p(\mathbf{x}^*) \leq 0$$

(8)

# Otimização com Restrições de Desigualdade

## Interpretação geométrica

Consideremos inicialmente uma única restrição de desigualdade:

$$g_1(\mathbf{x}) \leq 0 \quad (9)$$

- Admitamos que a função  $g_1(\cdot)$  seja contínua;
- Se verdadeiro, essa função nunca muda “bruscamente” de valor;
- Logo, se existem. . .
  - $\mathcal{P}_1 \subset \mathbb{R}^n$  em que  $g_1(\cdot) > 0$ ; e
  - $\mathcal{N}_1 \subset \mathbb{R}^n$  em que  $g_1(\cdot) < 0$ ;
  - Então, deve existir  $\mathcal{G}_1 \subset \mathbb{R}^n$  em que  $g_1(\cdot) = 0$ ;
  - Além disso,  $\mathcal{G}_1$  separa  $\mathcal{P}_1$  de  $\mathcal{N}_1$ .

# Otimização com Restrições de Desigualdade

## Interpretação geométrica

Matematicamente:

$$\mathcal{P}_1 \triangleq \{\mathbf{x} \mid g_1(\mathbf{x}) > 0\}$$


$$\mathcal{N}_1 \triangleq \{\mathbf{x} \mid g_1(\mathbf{x}) < 0\} \tag{10}$$

$$\mathcal{G}_1 \triangleq \{\mathbf{x} \mid g_1(\mathbf{x}) = 0\}$$

# Otimização com Restrições de Desigualdade

## Interpretação geométrica

Exemplo de restrição: superfície  $z = g_1(\mathbf{x})$




# Otimização com Restrições de Desigualdade

## Interpretação geométrica

Exemplo de restrição: curva de nível onde  $g_1(\mathbf{x}) = 0$

- $a = \mathcal{P}_1$ ;  $b = \mathcal{N}_1$ ;  $c = \mathcal{G}_1$



# Otimização com Restrições de Desigualdade

## Interpretação geométrica

A exigência de que  $g_1(\mathbf{x}^*) \leq 0$  implica que:


- $\mathcal{P}_1$  representa o conjunto/região inviável/infactível;
- $\mathcal{N}_1$  e  $\mathcal{G}_1$  são conjuntos/regiões viáveis/factíveis;
- O *conjunto factível* ou a *região factível*  $\mathcal{F}_1$  é a união de  $\mathcal{G}_1$  e  $\mathcal{N}_1$ :

$$\mathcal{F}_1 = \mathcal{G}_1 \cup \mathcal{N}_1 \quad (11)$$

# Otimização com Restrições de Desigualdade

## Interpretação geométrica

Interpretação para problemas com várias restrições:  $a = \mathcal{F}_1$






# Otimização com Restrições de Desigualdade

## Interpretação geométrica


Interpretação para problemas com várias restrições:  $b = \mathcal{F}_2$



# Otimização com Restrições de Desigualdade

## Interpretação geométrica

Interpretação para problemas com várias restrições:  $c = \mathcal{F} = \mathcal{F}_1 \cap \mathcal{F}_2$



# Otimização com Restrições de Desigualdade

## Interpretação geométrica

- Os métodos discutidos são aplicáveis a problemas restritos?
- O ótimo restrito deverá pertencer a  $\mathcal{F}$ .
- Como garantir que  $\mathbf{x}^* \in \mathcal{F}$ ?
- **Como adaptar os métodos conhecidos**, de maneira simples e eficiente, para resolver problemas restritos?

# Otimização com Restrições de Desigualdade

## Barreiras e penalidades

- Solução Geral: **Método de Barreiras** ou **Método de Penalidades**.
- A ideia é transformar a função-objetivo em uma **função pseudo-objetivo**.
- Barreiras: impedem a existência de soluções em regiões inactiváveis.
- Penalidades: penalizam soluções localizadas em regiões inviáveis.
- A função pseudo-objetivo deve ser semelhante à função original na região viável.

# Otimização com Restrições de Desigualdade

## Barreiras e penalidades

Em termos matemáticos, o problema de otimização original:

$$\mathbf{x}^* = \arg \min_{\mathbf{x}} f(\mathbf{x}) \quad (12)$$

Sujeito a:  $\{g_i(\mathbf{x}) \leq 0$

é transformado no problema:

$$\mathbf{x}^* = \arg \min_{\mathbf{x}} f(\mathbf{x}) + F(\mathbf{x}) \quad (13)$$

A função  $F(\cdot)$  deve ser muito pequena (ou zero) no interior da região factível, de tal forma que  $f(\cdot)$  seja muito parecida com  $f(\cdot) + F(\cdot)$  em qualquer ponto deste espaço.

# Otimização com Restrições de Desigualdade

## Barreiras e penalidades

- O valor de  $F(\mathbf{x})$  cresce subitamente perto da fronteira.
- Pré-requisito: **a solução inicial deve ser factível.**





Figura: Ilustração de uma função de barreira.

# Otimização com Restrições de Desigualdade

## Barreiras e penalidades

- O valor de  $F(\mathbf{x})$  cresce a medida que se afasta da região viável.
- **A solução inicial pode ser factível ou não.**



**Figura:** A função de penalidade é igual a zero no interior da região factível, e cresce rapidamente à medida em que o ponto se afasta dessa região.

# Otimização com Restrições de Desigualdade

## Barreiras e penalidades

- O problema restrito é então tratado como irrestrito.
- Logo, os métodos discutidos podem ser aplicados na otimização dos problemas transformados.
- Qual método utilizar: Direção de Busca, Exclusão de Regiões ou Método de Populações?
- Barreiras ou Penalidades?



# Otimização com Restrições de Desigualdade

## Composição pelo máximo

### Exclusão de Regiões e tratamento de $g_i(\mathbf{x}) \leq 0$ por Composição pelo Máximo

- Dado um ponto  $\mathbf{x}$ , identifica-se a restrição mais violada:

$$G(\mathbf{x}) = \max(g_1(\mathbf{x}), g_2(\mathbf{x}), \dots, g_p(\mathbf{x})) \quad (14)$$

- Aplica-se exclusão de região à função  $G(\cdot)$ .
- Caso  $\mathbf{x}$  seja viável, aplica-se exclusão de região à função  $f(\cdot)$ .

# Otimização com Restrições de Desigualdade

## Composição pelo máximo


### **Exclusão de Regiões** e tratamento de $g_i(\mathbf{x}) \leq 0$ por **Composição pelo Máximo**

- A sequência de pontos  $\mathbf{x}$  pode oscilar entre viável e inviável.
- No entanto, a região factível diminui iterativamente.
- A solução final termina arbitrariamente próxima do ótimo.

# Otimização com Restrições de Desigualdade

Composição pelo máximo

## Exclusão de Regiões e Composição pelo Máximo



# Otimização com Restrições de Igualdade

## Introdução

Consideremos agora o problema de otimização com *restrições de igualdade*:

$$\mathbf{x}^* = \arg \min_{\mathbf{x}} f(\mathbf{x}) \quad (15)$$

Sujeito a:  $\{h_j(\mathbf{x}) = 0, \quad j = 1, \dots, q\}$

# Otimização com Restrições de Igualdade

## Introdução

O ótimo  $\mathbf{x}^*$  deve satisfazer às  $q$  equações:

$$h_1(\mathbf{x}^*) = 0$$

$$h_2(\mathbf{x}^*) = 0$$

$$\vdots$$

$$h_q(\mathbf{x}^*) = 0$$

(16)


# Otimização com Restrições de Igualdade

## Introdução

- A região factível é descrita por um conjunto de pontos que satisfazem  $h(\mathbf{x}) = 0$ .
- Esta região viável é uma superfície de dimensão  $n - 1$ .
- No caso de  $q$  restrições de igualdade, o conjunto factível corresponde à interseção de todas as superfícies  $h_j(\mathbf{x}) = 0$ .

# Otimização com Restrições de Igualdade

## Introdução



**Figura:** A linha corresponde ao lugar geométrico dos pontos que satisfazem  $h(\mathbf{x}) = 0$ . Essa linha é a região factível de um problema de otimização com essa restrição.

# Otimização com Restrições de Igualdade

## Introdução

- Como tratar as restrições de igualdade?
- Quais das técnicas discutidas são viáveis neste caso?
- Por que?
- As técnicas de barreiras e composição pelo máximo dependem da existência de pontos *interiores* à região factível do problema.
- A técnica de penalidades é a única viável nestes problemas.



# Otimização Linear

## Introdução

Suponha funções objetivo e de restrições lineares.  
O problema agora é chamado de otimização linear:

$$\mathbf{x}^* = \arg \min_{\mathbf{x}} \mathbf{c}'\mathbf{x} \quad (17)$$

$$\text{Sujeito a: } \{A\mathbf{x} \leq \mathbf{b}$$

De outra forma:

$$f(\mathbf{x}) = c_1x_1 + c_2x_2 + \dots + c_nx_n \quad (18)$$

e o conjunto de restrições corresponde às  $m$  desigualdades:

$$\begin{aligned} a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n &\leq b_1 \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n &\leq b_2 \\ &\vdots \\ a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mn}x_n &\leq b_m \end{aligned} \quad (19)$$

### Importância da otimização linear

- Problemas práticos podem ser modelados via funções lineares;
- Podem ser resolvidos mais rapidamente que problemas não-lineares:
  - Para o mesmo número de variáveis; e
  - Mesmo número de restrições.
- Algoritmos especializados são capazes de lidar com problemas muito grandes (centenas de variáveis de decisão).

# Otimização Linear

## Introdução

- As curvas de nível de uma função linear são retas paralelas.
- Não existe mínimo local irrestrito de um problema linear.





Figura: Superfície correspondente à função objetivo linear  $f(\mathbf{x}) = \mathbf{c}'\mathbf{x}$ .

# Otimização Linear

## Introdução

- A presença de restrições de desigualdade definem um poliedro factível.



**Figura:** Região factível  $\mathcal{F}$  correspondente às restrições lineares de desigualdade.

# Otimização Linear

## Introdução

- Curvas de nível de uma função linear e região factível:




Figura: O vetor gradiente,  $\nabla f(\mathbf{x})$ , é constante em todo o espaço.

# Otimização Linear

## Introdução

- O mínimo da função linear nunca estará no interior da região factível.
- O mínimo deverá estar na fronteira, e sobre algum vértice.
- O conjunto ótimo pode ser toda uma fronteira.
- Como otimizar eficientemente tais funções?
  - Método Simplex.
  - Métodos de Pontos Interiores.