

# Uma Ferramenta para otimização em Engenharia Mecânica e aplicações na Fundição Eletromagnética de Metais

Alfredo Canelas, Jean R. Roche, José Herskovits

Departamento de Engenharia Mecânica  
COPPE – UFRJ

STIC-AMSUD, Novembro de 2009

# Conteúdo

## Preliminares

Objetivo e Motivação

## Algoritmo FDIPA-H

Problema de Otimização Não Linear

Algoritmo FDIPA

Algoritmo FDIPA-H

## Fundição Eletromagnética

Problema direto

Problema Inverso

Exemplos

## Conclusões

# Conteúdo

## Preliminares

Objetivo e Motivação

## Algoritmo FDIPA-H

Problema de Otimização Não Linear

Algoritmo FDIPA

Algoritmo FDIPA-H

## Fundição Eletromagnética

Problema direto

Problema Inverso

Exemplos

## Conclusões

# Objetivo

- 1) Definir e implementar um método numérico para problemas de otimização da Engenharia Mecânica com as seguintes características:
  - ▶ O **Método dos Elementos de Contorno** (MEC) é utilizado para calcular a solução da equação de estado do problema.
  - ▶ A formulação **SAND** é utilizada para definir o problema de otimização.
  - ▶ Um **algoritmo de ponto interior** é utilizado para a solução do problema de otimização discreto.
- 2) Estudar numericamente o problema inverso de *Fundição Eletromagnética* (EMC).

## Objetivo

- 1) Definir e implementar um método numérico para problemas de otimização da Engenharia Mecânica com as seguintes características:
  - ▶ O **Método dos Elementos de Contorno** (MEC) é utilizado para calcular a solução da equação de estado do problema.
  - ▶ A formulação **SAND** é utilizada para definir o problema de otimização.
  - ▶ Um **algoritmo de ponto interior** é utilizado para a solução do problema de otimização discreto.
- 2) Estudar numericamente o problema inverso de *Fundição Eletromagnética* (EMC).

# Motivação

Esta ferramenta computacional está motivada no seguinte:

- 1) Análise numérica de problemas não lineares:
  - ▶ Problemas de superfície livre:  
Problema direto de Fundição Eletromagnética.  
Problema de infiltração em meio poroso.
  - ▶ Problemas com condições de contorno não lineares:  
Problema de contato.
- 2) Otimização de forma
  - ▶ As funções e as suas derivadas podem ser expressadas como uma integral no contorno.
- 3) Outros problemas de otimização de análise não linear:
  - ▶ Problema inverso de Fundição Eletromagnética.

# Motivação

Esta ferramenta computacional está motivada no seguinte:

- 1) Análise numérica de problemas não lineares:
  - ▶ Problemas de superfície livre:  
Problema direto de Fundição Eletromagnética.  
Problema de infiltração em meio poroso.
  - ▶ Problemas com condições de contorno não lineares:  
Problema de contato.
- 2) Otimização de forma
  - ▶ As funções e as suas derivadas podem ser expressadas como uma integral no contorno.
- 3) Outros problemas de otimização de análise não linear:
  - ▶ Problema inverso de Fundição Eletromagnética.

# Motivação

Esta ferramenta computacional está motivada no seguinte:

- 1) Análise numérica de problemas não lineares:
  - ▶ Problemas de superfície livre:  
Problema direto de Fundição Eletromagnética.  
Problema de infiltração em meio poroso.
  - ▶ Problemas com condições de contorno não lineares:  
Problema de contato.
- 2) Otimização de forma
  - ▶ As funções e as suas derivadas podem ser expressadas como uma integral no contorno.
- 3) Outros problemas de otimização de análise não linear:
  - ▶ Problema inverso de Fundição Eletromagnética.



Objetivo e Motivação

# Método dos Elementos de Contorno

## Por que usar o Método dos Elementos de Contorno?

O MEC utiliza a representação integral:

$$\mathbf{c}(\xi)\mathbf{u}(\xi) = \int_{\Gamma} \mathbf{u}^*(\xi, \mathbf{x})\mathbf{p}(\mathbf{x}) d\Gamma - \int_{\Gamma} \mathbf{p}^*(\xi, \mathbf{x})\mathbf{u}(\mathbf{x}) d\Gamma . \quad (1)$$

- ▶ Não precisa da discretização do interior do domínio.
- ▶ Define um número menor de variáveis.

Muito indicado para:

- ▶ Problemas de domínio infinito.
- ▶ Otimização de forma.





## Método dos Elementos de Contorno

Por que usar o Método dos Elementos de Contorno?

O MEC utiliza a representação integral:

$$\mathbf{c}(\boldsymbol{\xi})\mathbf{u}(\boldsymbol{\xi}) = \int_{\Gamma} \mathbf{u}^*(\boldsymbol{\xi}, \mathbf{x})\mathbf{p}(\mathbf{x}) d\Gamma - \int_{\Gamma} \mathbf{p}^*(\boldsymbol{\xi}, \mathbf{x})\mathbf{u}(\mathbf{x}) d\Gamma . \quad (1)$$

- ▶ Não precisa da discretização do interior do domínio.
- ▶ Define um número menor de variáveis.


Muito indicado para:

- ▶ Problemas de domínio infinito.
- ▶ Otimização de forma.




# Malha

Malha de Elementos Finitos para simulação de um problema de Fundição Eletromagnética.



## Malha

Malha equivalente utilizada pelo Método dos Elementos de Contorno.



## Formulação SAND

### Por que usar a formulação SAND?

Na formulação clássica do problema de otimização em Engenharia Mecânica o objetivo é encontrar  $\mathbf{x} \in \mathbb{R}^n$ :

$$\begin{aligned} & \text{minimize} && f(\mathbf{x}, \tilde{\mathbf{u}}(\mathbf{x})) \\ & \text{sujeito a:} && \mathbf{g}(\mathbf{x}, \tilde{\mathbf{u}}(\mathbf{x})) \geq 0 \end{aligned} \quad (2)$$

Com  $\tilde{\mathbf{u}}$  definida pela equação de estado:

$$\mathbf{h}(\mathbf{x}, \tilde{\mathbf{u}}(\mathbf{x})) = 0 \quad (3)$$

## Formulação SAND

Por que usar a formulação SAND?

Na formulação clássica do problema de otimização em Engenharia Mecânica o objetivo é encontrar  $\mathbf{x} \in \mathbb{R}^n$ :

$$\begin{aligned} & \text{minimize} && f(\mathbf{x}, \tilde{\mathbf{u}}(\mathbf{x})) \\ & \text{sujeito a:} && \mathbf{g}(\mathbf{x}, \tilde{\mathbf{u}}(\mathbf{x})) \geq 0 \end{aligned} \quad (2)$$

Com  $\tilde{\mathbf{u}}$  definida pela equação de estado:

$$\mathbf{h}(\mathbf{x}, \tilde{\mathbf{u}}(\mathbf{x})) = 0 \quad (3)$$



# Formulação SAND

## Na formulação SAND:

- ▶ As variáveis de estados são adicionadas como variáveis de otimização.
- ▶ A equação de estado é adicionada como restrição de igualdade.

$$\begin{aligned} \text{minimize} \quad & f(\mathbf{x}, \mathbf{u}) \\ \text{sujeito a:} \quad & \mathbf{g}(\mathbf{x}, \mathbf{u}) \geq 0 \\ & \mathbf{h}(\mathbf{x}, \mathbf{u}) = 0 \end{aligned} \tag{4}$$

## Vantagens da formulação SAND

- 1) Não precisa da iteração para a solução da equação de estado.
- 2) A análise de sensibilidade é mais simples (dependência explícita de  $\mathbf{x}$  e  $\mathbf{u}$ ).
- 3) Em alguns casos permite utilizar algoritmos de otimização muito eficientes (Problemas lineares ou quadráticos).
- 4) Propriedade de separabilidade parcial das funções. Cálculo eficiente das derivadas → Permite utilizar algoritmos de otimização baseados no método de Newton.

## Vantagens da formulação SAND

- 1) Não precisa da iteração para a solução da equação de estado.
- 2) A análise de sensibilidade é mais simples (dependência explícita de  $\mathbf{x}$  e  $\mathbf{u}$ ).
- 3) Em alguns casos permite utilizar algoritmos de otimização muito eficientes (Problemas lineares ou quadráticos).
- 4) Propriedade de separabilidade parcial das funções. Cálculo eficiente das derivadas → Permite utilizar algoritmos de otimização baseados no método de Newton.

## Vantagens da formulação SAND

- 1) Não precisa da iteração para a solução da equação de estado.
- 2) A análise de sensibilidade é mais simples (dependência explícita de  $\mathbf{x}$  e  $\mathbf{u}$ ).
- 3) **Em alguns casos permite utilizar algoritmos de otimização muito eficientes** (Problemas lineares ou quadráticos).
- 4) Propriedade de **separabilidade parcial** das funções.  
Cálculo eficiente das derivadas → **Permite utilizar algoritmos de otimização baseados no método de Newton.**

## Vantagens da formulação SAND

- 1) Não precisa da iteração para a solução da equação de estado.
- 2) A análise de sensibilidade é mais simples (dependência explícita de  $\mathbf{x}$  e  $\mathbf{u}$ ).
- 3) **Em alguns casos permite utilizar algoritmos de otimização muito eficientes** (Problemas lineares ou quadráticos).
- 4) Propriedade de **separabilidade parcial** das funções.  
Cálculo eficiente das derivadas → **Permite utilizar algoritmos de otimização baseados no método de Newton.**

# Vantagens da formulação SAND

Muito indicada para:

- 1) Problemas não lineares.
- 2) Problemas onde seja necessário achar derivadas segundas.
- 3) Problemas onde seja difícil achar uma configuração inicial conveniente: **permite uma maior liberdade na escolha da configuração inicial.**

# Vantagens da formulação SAND

Muito indicada para:

- 1) Problemas não lineares.
- 2) Problemas onde seja necessário achar derivadas segundas.
- 3) Problemas onde seja difícil achar uma configuração inicial conveniente: **permite uma maior liberdade na escolha da configuração inicial.**

## Vantagens da formulação SAND

Muito indicada para:

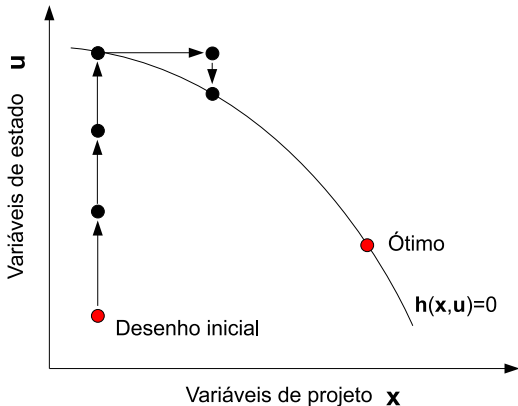
- 1) Problemas não lineares.
- 2) Problemas onde seja necessário achar derivadas segundas.
- 3) Problemas onde seja difícil achar uma configuração inicial conveniente: **permite uma maior liberdade na escolha da configuração inicial.**





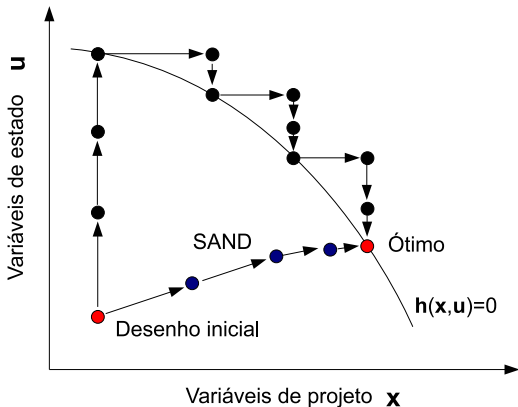


# Formulação SAND





# Formulação SAND



# Algoritmo de ponto interior

Por que usar o algoritmo de ponto interior?

Vantagens:

- 1) Conveniente para problemas de grande porte.
  - 2) Problemas esparsos ou com outro tipo de estrutura.
  - 3) Conveniente para executar em computadores de arquitetura paralela.
- Muito indicado para utilizar junto à formulação SAND.



## Algoritmo de ponto interior

Por que usar o algoritmo de ponto interior?

Vantagens:

- 1) Conveniente para problemas de grande porte.
  - 2) Problemas esparsos ou com outro tipo de estrutura.
  - 3) Conveniente para executar em computadores de arquitetura paralela.
- ▶ Muito indicado para utilizar junto à formulação SAND.



## Algoritmo de ponto interior

Por que usar o algoritmo de ponto interior?

Vantagens:

- 1) Conveniente para problemas de grande porte.
- 2) Problemas esparsos ou com outro tipo de estrutura.
- 3) Conveniente para executar em computadores de arquitetura paralela.

► Muito indicado para utilizar junto à formulação SAND.

## Algoritmo de ponto interior

Por que usar o algoritmo de ponto interior?

Vantagens:

- 1) Conveniente para problemas de grande porte.
  - 2) Problemas esparsos ou com outro tipo de estrutura.
  - 3) Conveniente para executar em computadores de arquitetura paralela.
- **Muito indicado para utilizar junto à formulação SAND.**

## Vantagens do método proposto

- 1) MEC: Redução do número de variáveis.
- 2) MEC: Problemas de domínio infinito.
- 3) SAND: Problemas não lineares.
- 4) SAND: Análise de sensibilidade simples.
- 5) Ponto interior: Conveniente para problemas de grande porte.

## Vantagens do método proposto

- 1) MEC: Redução do número de variáveis.
- 2) MEC: Problemas de domínio infinito.
- 3) SAND: Problemas não lineares.
- 4) SAND: Análise de sensibilidade simples.
- 5) Ponto interior: Conveniente para problemas de grande porte.

## Vantagens do método proposto

- 1) MEC: Redução do número de variáveis.
- 2) MEC: Problemas de domínio infinito.
- 3) SAND: Problemas não lineares.
- 4) SAND: Análise de sensibilidade simples.
- 5) Ponto interior: Conveniente para problemas de grande porte.

# Conteúdo

## Preliminares

Objetivo e Motivação

## Algoritmo FDIPA-H

Problema de Otimização Não Linear

Algoritmo FDIPA

Algoritmo FDIPA-H

## Fundição Eletromagnética

Problema direto

Problema Inverso

Exemplos

## Conclusões

# Problema de Otimização Não Linear

- ▶ Encontrar  $\mathbf{x} \in \mathbb{R}^n$  tal que:

$$\begin{aligned} & \text{minimize} && f(\mathbf{x}) \\ & \text{sujeito a:} && \mathbf{g}(\mathbf{x}) \geq 0 \\ & && \mathbf{h}(\mathbf{x}) = 0 \end{aligned}$$

- ▶ Região viável:

$$\Omega = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{g}(\mathbf{x}) \geq 0, \mathbf{h}(\mathbf{x}) = 0\}$$

- ▶  $\mathbf{x}^*$  é **mínimo local** se existe  $\mathcal{N}(\mathbf{x}^*)$  tal que:

$$f(\mathbf{x}) \geq f(\mathbf{x}^*), \quad \forall \mathbf{x} \in \Omega \cap \mathcal{N}(\mathbf{x}^*) \quad (5)$$

# Karush-Kuhn-Tucker

- ▶ **Regularidade das restrições:** para todo  $\mathbf{x} \in \Omega$ :

$$\{\nabla \mathbf{g}_i(\mathbf{x}) \mid g_i(\mathbf{x}) = 0, \nabla \mathbf{h}_i(\mathbf{x}) \mid i \in \{1, \dots, p\}\} \quad \text{é l.i.}$$

- ▶ **TEOREMA** de **Karush-Kuhn-Tucker:**

$$\nabla f(\mathbf{x}^*) - \sum_{i=1}^m \lambda_i \nabla \mathbf{g}_i(\mathbf{x}^*) - \sum_{i=1}^p \mu_i \nabla \mathbf{h}_i(\mathbf{x}^*) = 0 \quad (6)$$

$$\mathbf{g}_i(\mathbf{x}^*) \lambda_i = 0 \quad (7)$$

$$\mathbf{h}(\mathbf{x}^*) = 0 \quad (8)$$

$$\mathbf{g}(\mathbf{x}^*) \geq 0 \quad (9)$$

$$\lambda \geq 0 \quad (10)$$



# Karush-Kuhn-Tucker

- ▶ **Regularidade das restrições:** para todo  $\mathbf{x} \in \Omega$ :

$$\{\nabla \mathbf{g}_i(\mathbf{x}) \mid g_i(\mathbf{x}) = 0, \nabla \mathbf{h}_i(\mathbf{x}) \mid i \in \{1, \dots, p\}\} \quad \text{é l.i.}$$

- ▶ **TEOREMA** de **Karush-Kuhn-Tucker:**

Sistema  
de  
Equações  
(Newton)

$$\nabla f(\mathbf{x}^*) - \sum_{i=1}^m \lambda_i \nabla \mathbf{g}_i(\mathbf{x}^*) - \sum_{i=1}^p \mu_i \nabla \mathbf{h}_i(\mathbf{x}^*) = 0 \quad (6)$$

$$\mathbf{g}_i(\mathbf{x}^*) \lambda_i = 0 \quad (7)$$

$$\mathbf{h}(\mathbf{x}^*) = 0 \quad (8)$$

$$\mathbf{g}(\mathbf{x}^*) \geq 0 \quad (9)$$

$$\lambda \geq 0 \quad (10)$$



## Iteração de Newton

- ▶ Função lagrangiana:

$$L(\mathbf{x}, \lambda, \mu) = f(\mathbf{x}) - \sum_{i=1}^m \lambda_i \mathbf{g}_i(\mathbf{x}) - \sum_{i=1}^p \mu_i \mathbf{h}_i(\mathbf{x})$$

$$\mathbf{H}(\mathbf{x}, \lambda, \mu) = \nabla_{\mathbf{xx}}^2 L(\mathbf{x}, \lambda, \mu) = \nabla^2 f(\mathbf{x}) - \sum_{i=1}^m \lambda_i \nabla^2 \mathbf{g}_i(\mathbf{x}) - \sum_{i=1}^p \mu_i \nabla^2 \mathbf{h}_i(\mathbf{x})$$

- ▶ Iteração de Newton:

$$(\mathbf{x}_{k+1}, \lambda_{k+1}, \mu_{k+1}) = (\mathbf{x}_k, \lambda_k, \mu_k) + (\mathbf{d}_x, \mathbf{d}_\lambda, \mathbf{d}_\mu) \quad (11)$$

$$\begin{pmatrix} \mathbf{H}_k & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ \Lambda_k \nabla \mathbf{g}_k & \mathbf{G}_k & \mathbf{0} \\ \nabla \mathbf{h}_k & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{d}_x \\ \mathbf{d}_\lambda \\ \mathbf{d}_\mu \end{pmatrix} = \begin{pmatrix} -\nabla_x L_k^T \\ -\mathbf{G}_k \lambda_k \\ -\mathbf{h}_k \end{pmatrix} \quad (12)$$

- ▶ NÃO FUNCIONA

## Iteração de Newton

- Função lagrangiana:

$$L(\mathbf{x}, \lambda, \mu) = f(\mathbf{x}) - \sum_{i=1}^m \lambda_i \mathbf{g}_i(\mathbf{x}) - \sum_{i=1}^p \mu_i \mathbf{h}_i(\mathbf{x})$$

$$\mathbf{H}(\mathbf{x}, \lambda, \mu) = \nabla_{\mathbf{xx}}^2 L(\mathbf{x}, \lambda, \mu) = \nabla^2 f(\mathbf{x}) - \sum_{i=1}^m \lambda_i \nabla^2 \mathbf{g}_i(\mathbf{x}) - \sum_{i=1}^p \mu_i \nabla^2 \mathbf{h}_i(\mathbf{x})$$

- Iteração de Newton:

$$(\mathbf{x}_{k+1}, \lambda_{k+1}, \mu_{k+1}) = (\mathbf{x}_k, \lambda_k, \mu_k) + (\mathbf{d}_x, \mathbf{d}_\lambda, \mathbf{d}_\mu) \quad (11)$$

$$\begin{pmatrix} \mathbf{H}_k & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ \Lambda_k \nabla \mathbf{g}_k & \mathbf{G}_k & 0 \\ \nabla \mathbf{h}_k & 0 & 0 \end{pmatrix} \begin{pmatrix} \mathbf{d}_x \\ \mathbf{d}_\lambda \\ \mathbf{d}_\mu \end{pmatrix} = \begin{pmatrix} -\nabla_x L_k^T \\ -\mathbf{G}_k \lambda_k \\ -\mathbf{h}_k \end{pmatrix} \quad (12)$$

- **NÃO FUNCIONA**





# Iteração de Newton

Idéia:

- ▶ Definir um algoritmo de otimização baseado na **direção da iteração de Newton**.

Motivação: problemas com custo de  $H$  pequeno

- ▶ Problemas de programação linear ou quadrática.
- ▶ Problemas da coleção **CUTE**.
  - ▶ Economia.
  - ▶ Controle ótimo.
  - ▶ Otimização de redes.
- ▶ Na Engenharia Mecânica:
  - ▶ Utilizando a formulação SAND.
  - ▶ Utilizando modelos aproximados.

# Iteração de Newton

Idéia:

- ▶ Definir um algoritmo de otimização baseado na **direção da iteração de Newton**.

Motivação: problemas com custo de **H** pequeno

- ▶ Problemas de programação linear ou quadrática.
- ▶ Problemas da coleção **CUTE**.
  - ▶ Economia.
  - ▶ Controle ótimo.
  - ▶ Otimização de redes.
- ▶ Na Engenharia Mecânica:
  - ▶ Utilizando a formulação **SAND**.
  - ▶ Utilizando modelos aproximados.



## Iteração de Newton

Idéia:

- ▶ Definir um algoritmo de otimização baseado na **direção da iteração de Newton**.

Motivação: problemas com custo de **H** pequeno

- ▶ Problemas de programação linear ou quadrática.
- ▶ Problemas da coleção **CUTE**.
  - ▶ Economia.
  - ▶ Controle ótimo.
  - ▶ Otimização de redes.
- ▶ Na Engenharia Mecânica:
  - ▶ Utilizando a formulação **SAND**.
  - ▶ Utilizando modelos aproximados.

## Iteração de Newton

Idéia:

- ▶ Definir um algoritmo de otimização baseado na **direção da iteração de Newton**.

Motivação: problemas com custo de **H** pequeno

- ▶ Problemas de programação linear ou quadrática.
- ▶ Problemas da coleção **CUTE**.
  - ▶ Economia.
  - ▶ Controle ótimo.
  - ▶ Otimização de redes.
- ▶ Na Engenharia Mecânica:
  - ▶ Utilizando a formulação SAND.
  - ▶ Utilizando modelos aproximados.

## Iteração de Newton

Idéia:

- ▶ Definir um algoritmo de otimização baseado na **direção da iteração de Newton**.

Motivação: problemas com custo de **H** pequeno

- ▶ Problemas de programação linear ou quadrática.
- ▶ Problemas da coleção **CUTE**.
  - ▶ Economia.
  - ▶ Controle ótimo.
  - ▶ Otimização de redes.
- ▶ Na Engenharia Mecânica:
  - ▶ Utilizando a formulação SAND.
  - ▶ Utilizando modelos aproximados.

# Conteúdo

## Preliminares

Objetivo e Motivação

## Algoritmo FDIPA-H

Problema de Otimização Não Linear

**Algoritmo FDIPA**

Algoritmo FDIPA-H

## Fundição Eletromagnética

Problema direto

Problema Inverso

Exemplos

## Conclusões
















# Direção de desvio



# Convergência global do FDIPA

- ▶ Regularidade das restrições +  $\mathbf{B}$  positiva definida +  $\lambda > 0$  +  $\mathbf{g}(\mathbf{x}) \geq 0$ :

→ Sistema linear é não singular

- ▶  $\mathbf{x}$  não é ponto estacionário: →  $\|\mathbf{d}_x\| > 0$

- ▶ Viabilidade uniforme: Existe  $\theta_1 > 0$  tal que  $\forall t \in [0, \theta_1]$

$$\rightarrow \mathbf{x}_k + t \mathbf{d}_x \in \Delta$$

- ▶ Descida uniforme: Existe  $\theta_2 > 0$  tal que  $\forall t \in [0, \theta_2]$

$$\phi_{\mathbf{c}_k}(\mathbf{x}_k + t_k \mathbf{d}_x) \leq \phi_{\mathbf{c}_k}(\mathbf{x}_k) + t_k \eta \nabla \phi_{\mathbf{c}_k} \mathbf{d}_x$$

- ▶ Busca linear: Achar  $t$  (Armijo, Wolfe, etc.).

# Convergência global do FDIPA

- ▶ Regularidade das restrições +  $\mathbf{B}$  positiva definida +  $\lambda > 0$  +  $\mathbf{g}(\mathbf{x}) \geq 0$ :

→ Sistema linear é não singular

- ▶  $\mathbf{x}$  não é ponto estacionário:  $\rightarrow \|\mathbf{d}_x\| > 0$

- ▶ Viabilidade uniforme: Existe  $\theta_1 > 0$  tal que  $\forall t \in [0, \theta_1]$

$$\rightarrow \mathbf{x}_k + t \mathbf{d}_x \in \Delta$$

- ▶ Descida uniforme: Existe  $\theta_2 > 0$  tal que  $\forall t \in [0, \theta_2]$

$$\phi_{\mathbf{c}_k}(\mathbf{x}_k + t_k \mathbf{d}_x) \leq \phi_{\mathbf{c}_k}(\mathbf{x}_k) + t_k \eta \nabla \phi_{\mathbf{c}_k} \mathbf{d}_x$$

- ▶ Busca linear: Achar  $t$  (Armijo, Wolfe, etc.).

## Convergência global do FDIPA

- ▶ Regularidade das restrições +  $\mathbf{B}$  positiva definida +  $\lambda > 0$  +  $\mathbf{g}(\mathbf{x}) \geq 0$ :

→ Sistema linear é não singular

- ▶  $\mathbf{x}$  não é ponto estacionário:  $\rightarrow \|\mathbf{d}_x\| > 0$
- ▶ Viabilidade uniforme: Existe  $\theta_1 > 0$  tal que  $\forall t \in [0, \theta_1]$

$$\rightarrow \mathbf{x}_k + t \mathbf{d}_x \in \Delta$$

- ▶ Descida uniforme: Existe  $\theta_2 > 0$  tal que  $\forall t \in [0, \theta_2]$

$$\phi_{\mathbf{c}_k}(\mathbf{x}_k + t_k \mathbf{d}_x) \leq \phi_{\mathbf{c}_k}(\mathbf{x}_k) + t_k \eta \nabla \phi_{\mathbf{c}_k} \mathbf{d}_x$$

- ▶ Busca linear: Achar  $t$  (Armijo, Wolfe, etc.).

## Convergência global do FDIPA

- ▶ Regularidade das restrições +  $\mathbf{B}$  positiva definida +  $\lambda > 0$  +  $\mathbf{g}(\mathbf{x}) \geq 0$ :

→ Sistema linear é não singular

- ▶  $\mathbf{x}$  não é ponto estacionário:  $\rightarrow \|\mathbf{d}_x\| > 0$
- ▶ Viabilidade uniforme: Existe  $\theta_1 > 0$  tal que  $\forall t \in [0, \theta_1]$

$$\rightarrow \mathbf{x}_k + t \mathbf{d}_x \in \Delta$$

- ▶ Descida uniforme: Existe  $\theta_2 > 0$  tal que  $\forall t \in [0, \theta_2]$

$$\phi_{\mathbf{c}_k}(\mathbf{x}_k + t_k \mathbf{d}_x) \leq \phi_{\mathbf{c}_k}(\mathbf{x}_k) + t_k \eta \nabla \phi_{\mathbf{c}_k} \mathbf{d}_x$$

- ▶ Busca linear: Achar  $t$  (Armijo, Wolfe, etc.).

## Convergência global do FDIPA

- ▶ Regularidade das restrições +  $\mathbf{B}$  positiva definida +  $\lambda > 0$  +  $\mathbf{g}(\mathbf{x}) \geq 0$ :

→ Sistema linear é não singular

- ▶  $\mathbf{x}$  não é ponto estacionário:  $\rightarrow \|\mathbf{d}_x\| > 0$
- ▶ **Viabilidade uniforme**: Existe  $\theta_1 > 0$  tal que  $\forall t \in [0, \theta_1]$

$$\rightarrow \mathbf{x}_k + t \mathbf{d}_x \in \Delta$$

- ▶ **Descida uniforme**: Existe  $\theta_2 > 0$  tal que  $\forall t \in [0, \theta_2]$

$$\phi_{\mathbf{c}_k}(\mathbf{x}_k + t_k \mathbf{d}_x) \leq \phi_{\mathbf{c}_k}(\mathbf{x}_k) + t_k \eta \nabla \phi_{\mathbf{c}_k} \mathbf{d}_x$$

- ▶ **Busca linear**: Achar  $t$  (Armijo, Wolfe, etc.).



# Conteúdo

## Preliminares

Objetivo e Motivação

## Algoritmo FDIPA-H

Problema de Otimização Não Linear

Algoritmo FDIPA

**Algoritmo FDIPA-H**

## Fundição Eletromagnética

Problema direto

Problema Inverso

Exemplos

## Conclusões

# Algoritmo FDIPA-H

- ▶ Manter a hessiana  $\mathbf{H}_k$  no sistema:

$$\begin{pmatrix} \mathbf{H}_k & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ -\mathbf{\Lambda}_k \nabla \mathbf{g}_k & -\mathbf{G}_k & \mathbf{0} \\ -\nabla \mathbf{h}_k & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{d}_x^\alpha \\ \lambda^\alpha \\ \mu^\alpha \end{pmatrix} = \begin{pmatrix} -\nabla f_k^T \\ \mathbf{0} \\ \mathbf{h}_k \end{pmatrix}$$

- ▶  $A = \{i \mid \mathbf{g}_i(\mathbf{x}) = 0\}$ ,  $I = \{j \mid \mathbf{g}_j(\mathbf{x}) > 0\}$ .

- ▶ Espaço tangente:

$$\mathcal{T} = \{\mathbf{v} \in \mathbb{R}^n \mid \mathbf{v} \perp \{\nabla \mathbf{g}_i(\mathbf{x}) \mid i \in A, \nabla \mathbf{h}_i(\mathbf{x}) \mid i \in \{1, \dots, p\}\}\} \quad (16)$$

- ▶ Matriz  $\mathbf{M}$ :

$$\mathbf{M}(\mathbf{x}, \lambda, \mu) = \mathbf{H}(\mathbf{x}, \lambda, \mu) + \sum_{i \in I} \mathbf{g}_i(\mathbf{x})^{-1} \lambda_i \nabla \mathbf{g}_i^T(\mathbf{x}) \nabla \mathbf{g}_i(\mathbf{x}) \quad (17)$$

- ▶ Função potencial:

$$\phi_c(\mathbf{x}) = f(\mathbf{x}) + c \Psi(\mathbf{h}(\mathbf{x})) \quad (18)$$



## Algoritmo FDIPA-H

- ▶ Manter a hessiana  $\mathbf{H}_k$  no sistema:

$$\begin{pmatrix} \mathbf{H}_k & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ -\mathbf{\Lambda}_k \nabla \mathbf{g}_k & -\mathbf{G}_k & \mathbf{0} \\ -\nabla \mathbf{h}_k & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{d}_x^\alpha \\ \lambda^\alpha \\ \mu^\alpha \end{pmatrix} = \begin{pmatrix} -\nabla f_k^T \\ \mathbf{0} \\ \mathbf{h}_k \end{pmatrix}$$

- ▶  $A = \{i \mid \mathbf{g}_i(\mathbf{x}) = 0\}$ ,  $I = \{i \mid \mathbf{g}_i(\mathbf{x}) > 0\}$ .
- ▶ Espaço tangente:

$$\mathcal{T} = \{\mathbf{v} \in \mathbb{R}^n \mid \mathbf{v} \perp \{\nabla \mathbf{g}_i(\mathbf{x}) \mid i \in A, \nabla \mathbf{h}_i(\mathbf{x}) \mid i \in \{1, \dots, p\}\}\} \quad (16)$$

- ▶ Matriz  $\mathbf{M}$ :

$$\mathbf{M}(\mathbf{x}, \lambda, \mu) = \mathbf{H}(\mathbf{x}, \lambda, \mu) + \sum_{i \in I} \mathbf{g}_i(\mathbf{x})^{-1} \lambda_i \nabla \mathbf{g}_i^T(\mathbf{x}) \nabla \mathbf{g}_i(\mathbf{x}) \quad (17)$$

- ▶ Função potencial:

$$\phi_c(\mathbf{x}) = f(\mathbf{x}) + c \Psi(\mathbf{h}(\mathbf{x})) \quad (18)$$

## Algoritmo FDIPA-H

- ▶ Manter a hessiana  $\mathbf{H}_k$  no sistema:

$$\begin{pmatrix} \mathbf{H}_k & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ -\mathbf{\Lambda}_k \nabla \mathbf{g}_k & -\mathbf{G}_k & \mathbf{0} \\ -\nabla \mathbf{h}_k & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{d}_x^\alpha \\ \lambda^\alpha \\ \mu^\alpha \end{pmatrix} = \begin{pmatrix} -\nabla f_k^T \\ \mathbf{0} \\ \mathbf{h}_k \end{pmatrix}$$

- ▶  $A = \{i \mid \mathbf{g}_i(\mathbf{x}) = 0\}$ ,  $I = \{i \mid \mathbf{g}_i(\mathbf{x}) > 0\}$ .

- ▶ Espaço tangente:

$$\mathcal{T} = \{\mathbf{v} \in \mathbb{R}^n \mid \mathbf{v} \perp \{\nabla \mathbf{g}_i(\mathbf{x}) \mid i \in A, \nabla \mathbf{h}_i(\mathbf{x}) \mid i \in \{1, \dots, p\}\}\} \quad (16)$$

- ▶ Matriz  $\mathbf{M}$ :

$$\mathbf{M}(\mathbf{x}, \lambda, \mu) = \mathbf{H}(\mathbf{x}, \lambda, \mu) + \sum_{i \in I} \mathbf{g}_i(\mathbf{x})^{-1} \lambda_i \nabla \mathbf{g}_i^T(\mathbf{x}) \nabla \mathbf{g}_i(\mathbf{x}) \quad (17)$$

- ▶ Função potencial:

$$\phi_c(\mathbf{x}) = f(\mathbf{x}) + c \Psi(\mathbf{h}(\mathbf{x})) \quad (18)$$

# Direção de Newton

- ▶ **Assumindo:** Regularidade das restrições +  $\mathbf{M}$  positiva definida no espaço  $\mathcal{T} + \lambda > 0 + \mathbf{g}(\mathbf{x}_k) \geq 0$ :
  - 1) **LEMA 3.44:**  $\rightarrow$  Sistema linear de Newton é não singular
  - 2) **LEMA 3.45:**  $\mathbf{x}$  não é ponto estacionário:  $\rightarrow \|\mathbf{d}_x^\alpha\| > 0$
  - 3) **TEOREMA 3.46:**  $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$ 
    - ▶  $\mathbf{d}_x^1$  é de descida para a função  $f$ : Direção de otimalidade
    - ▶  $\mathbf{d}_x^2$  é de descida para a função  $\Psi(\mathbf{h}(\mathbf{x}))$ : Direção de viabilidade
    - ▶ Existe  $c_0$  tal que  $\forall c \geq c_0$ ,  $\mathbf{d}_x^\alpha$  é de descida para a função potencial  $\phi(\mathbf{x}) = f(\mathbf{x}) + c \Psi(\mathbf{h}(\mathbf{x}))$

# Direção de Newton

- ▶ **Assumindo:** Regularidade das restrições +  $\mathbf{M}$  positiva definida no espaço  $\mathcal{T} + \lambda > 0 + \mathbf{g}(\mathbf{x}_k) \geq 0$ :

1) **LEMA 3.44:** → Sistema linear de Newton é não singular

2) **LEMA 3.45:**  $\mathbf{x}$  não é ponto estacionário: →  $\|\mathbf{d}_x^\alpha\| > 0$

3) **TEOREMA 3.46:**  $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$

- ▶  $\mathbf{d}_x^1$  é de descida para a função  $f$ : Direção de otimalidade
- ▶  $\mathbf{d}_x^2$  é de descida para a função  $\Psi(\mathbf{h}(\mathbf{x}))$ : Direção de viabilidade
- ▶ Existe  $c_0$  tal que  $\forall c \geq c_0$ ,  $\mathbf{d}_x^\alpha$  é de descida para a função potencial  $\phi(\mathbf{x}) = f(\mathbf{x}) + c \Psi(\mathbf{h}(\mathbf{x}))$

## Direção de Newton


- ▶ **Assumindo:** Regularidade das restrições +  $\mathbf{M}$  positiva definida no espaço  $\mathcal{T} + \lambda > 0 + \mathbf{g}(\mathbf{x}_k) \geq 0$ :
- 1) **LEMA 3.44:** → Sistema linear de Newton é não singular
- 2) **LEMA 3.45:**  $\mathbf{x}$  não é ponto estacionário: →  $\|\mathbf{d}_x^\alpha\| > 0$
- 3) **TEOREMA 3.46:**  $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$ 
  - ▶  $\mathbf{d}_x^1$  é de descida para a função  $f$ : Direção de otimalidade
  - ▶  $\mathbf{d}_x^2$  é de descida para a função  $\Psi(\mathbf{h}(\mathbf{x}))$ : Direção de viabilidade
  - ▶ Existe  $c_0$  tal que  $\forall c \geq c_0$ ,  $\mathbf{d}_x^\alpha$  é de descida para a função potencial  $\phi(\mathbf{x}) = f(\mathbf{x}) + c \Psi(\mathbf{h}(\mathbf{x}))$



## Direção de Newton

- ▶ **Assumindo:** Regularidade das restrições +  $\mathbf{M}$  positiva definida no espaço  $\mathcal{T} + \lambda > 0 + \mathbf{g}(\mathbf{x}_k) \geq 0$ :
- 1) **LEMA 3.44:** → Sistema linear de Newton é não singular
- 2) **LEMA 3.45:**  $\mathbf{x}$  não é ponto estacionário: →  $\|\mathbf{d}_x^\alpha\| > 0$
- 3) **TEOREMA 3.46:**  $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$ 
  - ▶  $\mathbf{d}_x^1$  é de descida para a função  $f$ : **Direção de otimalidade**
  - ▶  $\mathbf{d}_x^2$  é de descida para a função  $\Psi(\mathbf{h}(\mathbf{x}))$ : **Direção de viabilidade**
  - ▶ Existe  $c_0$  tal que  $\forall c \geq c_0$ ,  $\mathbf{d}_x^\alpha$  é de descida para a função potencial  $\phi(\mathbf{x}) = f(\mathbf{x}) + c \Psi(\mathbf{h}(\mathbf{x}))$

# Direção de Newton



- **M** deve ser **positiva definida** no espaço  $\mathcal{T}$

## $\mathbf{M}_k$ não é positiva definida em $\mathcal{T}$

- ▶ Duas perguntas:
  - 1) Como saber se  $\mathbf{M}$  é positiva definida no espaço  $\mathcal{T}$  ?
  - 2) O que fazer se não é ?
- ▶ **TEOREMA 3.40:**  $\mathbf{M}$  é positiva definida no espaço tangente  $\mathcal{T} \Leftrightarrow$  a matriz  $\mathbf{A}$  do sistema linear tem inércia  $\{n, m + p, 0\}$ 
  - ▶  $n$  é a dimensão de  $\mathbf{x}$
  - ▶  $m$  é a dimensão de  $\mathbf{g}(\mathbf{x})$
  - ▶  $p$  é a dimensão de  $\mathbf{h}(\mathbf{x})$
- ▶ inércia( $\mathbf{A}$ ) =  $\{i_+, i_-, i_0\}$ 
  - ▶  $i_+$  é o número de valores próprios positivos
  - ▶  $i_-$  é o número de valores próprios negativos
  - ▶  $i_0$  é o número de valores próprios nulos


## $\mathbf{M}_k$ não é positiva definida em $\mathcal{T}$

- ▶ Duas perguntas:
  - 1) Como saber se  $\mathbf{M}$  é positiva definida no espaço  $\mathcal{T}$  ?
  - 2) O que fazer se não é ?
- ▶ **TEOREMA 3.40:**  $\mathbf{M}$  é positiva definida no espaço tangente  $\mathcal{T} \Leftrightarrow$  a matriz  $\mathbf{A}$  do sistema linear tem **inércia**  $\{n, m + p, 0\}$ 
  - ▶  $n$  é a dimensão de  $\mathbf{x}$
  - ▶  $m$  é a dimensão de  $\mathbf{g}(\mathbf{x})$
  - ▶  $p$  é a dimensão de  $\mathbf{h}(\mathbf{x})$
- ▶ inércia( $\mathbf{A}$ ) =  $\{i_+, i_-, i_0\}$ 
  - ▶  $i_+$  é o número de valores próprios positivos
  - ▶  $i_-$  é o número de valores próprios negativos
  - ▶  $i_0$  é o número de valores próprios nulos

# Decomposição $LDL^T$

- ▶ Para saber a inércia ou resolver o sistema linear usamos a **decomposição  $LDL^T$** :

$$PAP^T = LDL^T$$




- ▶ **TEOREMA (Sylvester):** inércia( $A$ ) = inércia( $D$ )

# Decomposição $LDL^T$

- ▶ Para saber a inércia ou resolver o sistema linear usamos a **decomposição  $LDL^T$** :

$$PAP^T = LDL^T$$



- ▶ **TEOREMA (Sylvester):** inércia( $A$ ) = inércia( $D$ )



## M não é positiva definida em $\mathcal{T}$

- (1) Substituir  $\mathbf{d}_x^1$  por  $-\mathbf{d}_x^1$ , se  $\mathbf{d}_x^1$  não for de descida para a função objetivo.
  - (2) Na próxima iteração substituir  $\mathbf{H}_k$  por  $\mathbf{H}_k + \gamma \mathbf{I}$ 
    - ▶ Sempre existe  $\gamma$  conveniente
    - ▶ Preserva esparsidade de  $\mathbf{H}_k$
- ▶ Exemplo: utilizar  $\mathbf{H}_k + \gamma \mathbf{I}$  positiva definida:

$$\gamma = \max_{1 \leq i \leq n} \left\{ \max \left( 1.2 \sum_{j \neq i} |(\mathbf{H}_k)_{ij}| - (\mathbf{H}_k)_{ii}, 0 \right) \right\}. \quad (19)$$

- ▶ **TEOREMA 3.50** Toda subsequência convergente da seqüência gerada pelo algoritmo FDIPA-H converge para um ponto de Karush-Kuhn-Tucker do problema de otimização.



# Algoritmo de Otimização FDIPA-H

Dados:  $\mathbf{x}_0 \in \Delta^0$ ,  $\lambda_0 \in \mathbb{R}^m$  positivo,  $\mu_0 \in \mathbb{R}^p$   
 $\omega^I \in \mathbb{R}^m$  positivo,  $\omega^E \in \mathbb{R}^p$  positivo e  $c_0$  positivo.

**Passo 1:** Teste de convergência

**Passo 2:** Cálculo da direção de busca

2.1 Escolha o parâmetro  $\gamma_k$  e solução do sistema:

$$\begin{pmatrix} \mathbf{H}_k + \gamma_k \mathbf{I} & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ -\Lambda_k \nabla \mathbf{g}_k & -\mathbf{G}_k & \mathbf{0} \\ -\nabla \mathbf{h}_k & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{d}_x^\alpha & \mathbf{d}_x^\beta \\ \lambda^\alpha & \lambda^\beta \\ \mu^\alpha & \mu^\beta \end{pmatrix} = \begin{pmatrix} -\nabla f_k^T & \mathbf{0} \\ \mathbf{0} & -\Lambda_k \omega^I \\ \mathbf{h}_k & -\omega^E \end{pmatrix}.$$

2.2 Se  $\mathbf{d}_x^\alpha = \mathbf{0}$  pare

2.4 Atualize  $c_k$

2.5 Calcule  $\rho$  e a direção  $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$

**Passo 3:** Busca linear

**Passo 4:** Atualização:  $\mathbf{x}_{k+1} = \mathbf{x}_k + t_k \mathbf{d}_x$

4.2 Retorne ao Passo 1.

# Algoritmo de Otimização FDIPA-H

Dados:  $\mathbf{x}_0 \in \Delta^0$ ,  $\lambda_0 \in \mathbb{R}^m$  positivo,  $\mu_0 \in \mathbb{R}^p$   
 $\omega^I \in \mathbb{R}^m$  positivo,  $\omega^E \in \mathbb{R}^p$  positivo e  $c_0$  positivo.

**Passo 1:** Teste de convergência

**Passo 2:** Cálculo da direção de busca

2.1 Escolha o parâmetro  $\gamma_k$  e solução do sistema:

$$\begin{pmatrix} \mathbf{H}_k + \gamma_k \mathbf{I} & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ -\Lambda_k \nabla \mathbf{g}_k & -\mathbf{G}_k & \mathbf{0} \\ -\nabla \mathbf{h}_k & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{d}_x^\alpha & \mathbf{d}_x^\beta \\ \lambda^\alpha & \lambda^\beta \\ \mu^\alpha & \mu^\beta \end{pmatrix} = \begin{pmatrix} -\nabla f_k^T & \mathbf{0} \\ \mathbf{0} & -\Lambda_k \omega^I \\ \mathbf{h}_k & -\omega^E \end{pmatrix}.$$

2.2 Se  $\mathbf{d}_x^\alpha = \mathbf{0}$  pare

2.4 Atualize  $c_k$

2.5 Calcule  $\rho$  e a direção  $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$

**Passo 3:** Busca linear

**Passo 4:** Atualização:  $\mathbf{x}_{k+1} = \mathbf{x}_k + t_k \mathbf{d}_x$

4.2 Retorne ao Passo 1.

# Algoritmo de Otimização FDIPA-H

Dados:  $\mathbf{x}_0 \in \Delta^0$ ,  $\lambda_0 \in \mathbb{R}^m$  positivo,  $\mu_0 \in \mathbb{R}^p$   
 $\omega^I \in \mathbb{R}^m$  positivo,  $\omega^E \in \mathbb{R}^p$  positivo e  $c_0$  positivo.

**Passo 1:** Teste de convergência

**Passo 2:** Cálculo da direção de busca

2.1 Escolha o parâmetro  $\gamma_k$  e solução do sistema:

$$\begin{pmatrix} \mathbf{H}_k + \gamma_k \mathbf{I} & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ -\Lambda_k \nabla \mathbf{g}_k & -\mathbf{G}_k & \mathbf{0} \\ -\nabla \mathbf{h}_k & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{d}_x^\alpha & \mathbf{d}_x^\beta \\ \lambda^\alpha & \lambda^\beta \\ \mu^\alpha & \mu^\beta \end{pmatrix} = \begin{pmatrix} -\nabla f_k^T & \mathbf{0} \\ \mathbf{0} & -\Lambda_k \omega^I \\ \mathbf{h}_k & -\omega^E \end{pmatrix}.$$

2.2 Se  $\mathbf{d}_x^\alpha = \mathbf{0}$  pare

2.4 Atualize  $c_k$

2.5 Calcule  $\rho$  e a direção  $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$

**Passo 3:** Busca linear

**Passo 4:** Atualização:  $\mathbf{x}_{k+1} = \mathbf{x}_k + t_k \mathbf{d}_x$

4.2 Retorne ao Passo 1.

## Algoritmo de Otimização FDIPA-H

Dados:  $\mathbf{x}_0 \in \Delta^0$ ,  $\lambda_0 \in \mathbb{R}^m$  positivo,  $\mu_0 \in \mathbb{R}^p$   
 $\omega^I \in \mathbb{R}^m$  positivo,  $\omega^E \in \mathbb{R}^p$  positivo e  $c_0$  positivo.

**Passo 1:** Teste de convergência

**Passo 2:** Cálculo da direção de busca

2.1 Escolha o parâmetro  $\gamma_k$  e solução do sistema:

$$\begin{pmatrix} \mathbf{H}_k + \gamma_k \mathbf{I} & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ -\mathbf{\Lambda}_k \nabla \mathbf{g}_k & -\mathbf{G}_k & \mathbf{0} \\ -\nabla \mathbf{h}_k & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{d}_x^\alpha & \mathbf{d}_x^\beta \\ \lambda^\alpha & \lambda^\beta \\ \mu^\alpha & \mu^\beta \end{pmatrix} = \begin{pmatrix} -\nabla f_k^T & \mathbf{0} \\ \mathbf{0} & -\mathbf{\Lambda}_k \omega^I \\ \mathbf{h}_k & -\omega^E \end{pmatrix}.$$

2.2 Se  $\mathbf{d}_x^\alpha = \mathbf{0}$  pare

2.4 Atualize  $c_k$

2.5 Calcule  $\rho$  e a direção  $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$

**Passo 3:** Busca linear

**Passo 4:** Atualização:  $\mathbf{x}_{k+1} = \mathbf{x}_k + t_k \mathbf{d}_x$

4.2 Retorne ao Passo 1.

# Algoritmo de Otimização FDIPA-H

Dados:  $\mathbf{x}_0 \in \Delta^0$ ,  $\lambda_0 \in \mathbb{R}^m$  positivo,  $\mu_0 \in \mathbb{R}^p$   
 $\omega^I \in \mathbb{R}^m$  positivo,  $\omega^E \in \mathbb{R}^p$  positivo e  $c_0$  positivo.

**Passo 1:** Teste de convergência

**Passo 2:** Cálculo da direção de busca

2.1 Escolha o parâmetro  $\gamma_k$  e solução do sistema:

$$\begin{pmatrix} \mathbf{H}_k + \gamma_k \mathbf{I} & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ -\Lambda_k \nabla \mathbf{g}_k & -\mathbf{G}_k & \mathbf{0} \\ -\nabla \mathbf{h}_k & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{d}_x^\alpha & \mathbf{d}_x^\beta \\ \lambda^\alpha & \lambda^\beta \\ \mu^\alpha & \mu^\beta \end{pmatrix} = \begin{pmatrix} -\nabla f_k^T & \mathbf{0} \\ \mathbf{0} & -\Lambda_k \omega^I \\ \mathbf{h}_k & -\omega^E \end{pmatrix}.$$

2.2 Se  $\mathbf{d}_x^\alpha = \mathbf{0}$  pare

2.4 Atualize  $c_k$

2.5 Calcule  $\rho$  e a direção  $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$

**Passo 3:** Busca linear

**Passo 4:** Atualização:  $\mathbf{x}_{k+1} = \mathbf{x}_k + t_k \mathbf{d}_x$

4.2 Retorne ao Passo 1.

## Algoritmo de Otimização FDIPA-H

Dados:  $\mathbf{x}_0 \in \Delta^0$ ,  $\lambda_0 \in \mathbb{R}^m$  positivo,  $\mu_0 \in \mathbb{R}^p$   
 $\omega^I \in \mathbb{R}^m$  positivo,  $\omega^E \in \mathbb{R}^p$  positivo e  $c_0$  positivo.

**Passo 1:** Teste de convergência

**Passo 2:** Cálculo da direção de busca

2.1 Escolha o parâmetro  $\gamma_k$  e solução do sistema:

$$\begin{pmatrix} \mathbf{H}_k + \gamma_k \mathbf{I} & -\nabla \mathbf{g}_k^T & -\nabla \mathbf{h}_k^T \\ -\boldsymbol{\Lambda}_k \nabla \mathbf{g}_k & -\mathbf{G}_k & \mathbf{0} \\ -\nabla \mathbf{h}_k & \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{d}_x^\alpha & \mathbf{d}_x^\beta \\ \lambda^\alpha & \lambda^\beta \\ \mu^\alpha & \mu^\beta \end{pmatrix} = \begin{pmatrix} -\nabla f_k^T & \mathbf{0} \\ \mathbf{0} & -\boldsymbol{\Lambda}_k \omega^I \\ \mathbf{h}_k & -\omega^E \end{pmatrix}.$$

2.2 Se  $\mathbf{d}_x^\alpha = \mathbf{0}$  pare

2.4 Atualize  $c_k$

2.5 Calcule  $\rho$  e a direção  $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$

**Passo 3:** Busca linear

**Passo 4:** Atualização:  $\mathbf{x}_{k+1} = \mathbf{x}_k + t_k \mathbf{d}_x$

4.2 Retorne ao Passo 1.

## Exemplos: Coleção de Hock e Shitkowski

### Comparação do número de iterações

112 problemas de pequeno tamanho  $\approx 2 - 16$  variáveis.

	Resolveu	Falhou*	Foi o melhor**	Foi o pior***
FDIPA	104 (92.9%)	8 (7.1%)	13	71
FAIPA	103 (92.0%)	9 (8.0%)	24	62
<b>FDIPA-H</b>	<b>104 (92.9%)</b>	<b>8 (7.1%)</b>	<b>84</b>	<b>19</b>

(\*) Falhou: Erro de execução ou mais de 100 iterações para atingir a tolerância exigida.

(\*\*) Melhor: realizou un número de iterações menor ou igual aos outros dois.

(\*\*\*) Pior: realizou un número de iterações maior ou igual aos outros dois.

## Exemplos: Coleção do CUTE

- ▶ 150 problemas de grande porte: 1000 – 50000 variáveis.
  - ▶ Economia.
  - ▶ Controle ótimo.
  - ▶ Otimização de redes.
  - ▶ Engenharia Mecânica.
- ▶ Formulações SAND: problemas grandes e esparsos.
- ▶ As funções têm a propriedade de separabilidade parcial.
- ▶ O custo de cálculo da matriz hessiana é pequeno.
- ▶ É um conjunto de problemas muito importante para os quais os algoritmos de ponto interior baseados na iteração de Newton são ideais.



## Exemplos: Coleção do CUTE

- ▶ 150 problemas de grande porte: 1000 – 50000 variáveis.
  - ▶ Economia.
  - ▶ Controle ótimo.
  - ▶ Otimização de redes.
  - ▶ Engenharia Mecânica.
- ▶ Formulações SAND: problemas grandes e esparsos.
- ▶ As funções têm a propriedade de separabilidade parcial.
- ▶ O custo de cálculo da matriz hessiana é pequeno.
- ▶ **É um conjunto de problemas muito importante para os quais os algoritmos de ponto interior baseados na iteração de Newton são ideais.**

## Exemplos: Coleção do CUTE

### Comparação do número de iterações

	Resolveu	Falhou*	Foi o melhor**	Foi o pior***
KNITRO	93 (62.0%)	57 (38.0%)	31	76
LOQO	138 (92.0%)	12 (8.0%)	39	43
<b>FDIPA-H</b>	<b>114 (76.0%)</b>	<b>36 (24.0%)</b>	<b>81</b>	<b>40</b>
SNOPT	62 (41.3%)	88 (58.7%)	-	-
FDIPA	61 (40.6%)	89 (59.3%)	-	-
FAIPA	59 (39.3%)	91 (60.7%)	-	-

(\*) A comparação compreende os algoritmos KNITRO, LOQO e FDIPA-H.

(\*) Falhou: Erro de execução, mais de 3000 iterações ou mais de 20 min de execução.

(\*\*) Melhor: realizou um número de iterações menor ou igual aos outros dois.

(\*\*\*) Pior: realizou um número de iterações maior ou igual aos outros dois.

# Conclusões sobre o FDIPA-H

- 1) O algoritmo tem convergência global (Teorema 3.50)
- 2) É muito eficiente para os problemas de grande porte da coleção CUTE.

# Conteúdo

## Preliminares

Objetivo e Motivação

## Algoritmo FDIPA-H

Problema de Otimização Não Linear

Algoritmo FDIPA

Algoritmo FDIPA-H

## Fundição Eletromagnética

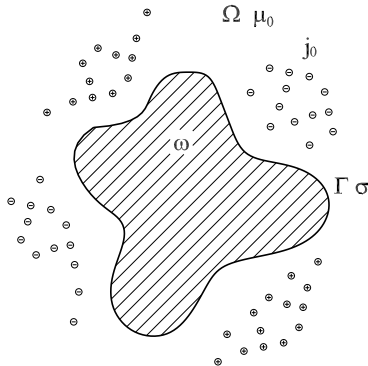
**Problema direto**

Problema Inverso

Exemplos

## Conclusões

# Problema de Fundição Eletromagnética



O modelo aqui considerado assume que a frequência da corrente elétrica é muito alta e, portanto, o campo magnético penetra uma distância desprezível no interior do metal líquido.

# Problema de Fundição Eletromagnética



# Equações do campo magnético

Michel Pierre, Jean R. Roche (1991)

$$\nabla \times \mathbf{B} = \mu_0 \mathbf{j}_0 \quad \text{em } \Omega \quad (20)$$

$$\nabla \cdot \mathbf{B} = 0 \quad \text{em } \Omega \quad (21)$$

$$\mathbf{B} \cdot \nu = 0 \quad \text{em } \Gamma \quad (22)$$

$$\|\mathbf{B}\| = O(\|x\|^{-1}) \quad \text{quando } \|x\| \rightarrow \infty \text{ em } \Omega \quad (23)$$

$\omega$ : domínio ocupado pelo metal líquido.

$\Gamma$ : contorno de  $\omega$ .

$\Omega = \mathbb{R} \setminus \omega$  o exterior do metal líquido.

$\mathbf{j}_0 = (0, 0, j_0)$  e o vetor de densidade de corrente elétrica.

$\mathbf{B} = (B_1, B_2, 0)$  vetor de campo magnético.

$\mu_0$ : permeabilidade magnética do vácuo.

$\nu$ : vetor unitário normal a superfície  $\Gamma$ .

## Equilíbrio e restrições

Além disso temos a equação de equilíbrio:

$$\frac{1}{2\mu_0} \|\mathbf{B}\|^2 + \sigma \mathcal{C} = \bar{p} \quad \text{constante em } \Gamma \quad (24)$$

E a equação do volume:

$$\int_{\omega} d\Omega = S_0 \quad (25)$$

Assume-se também que  $j_0$  tem suporte compacto e verifica:

$$\int_{\Omega} j_0 d\Omega = 0 \quad (26)$$



## Função fluxo magnético

Com isso, existe a função **fluxo magnético**  $\varphi : \Omega \rightarrow \mathbb{R}$  tal que  $\mathbf{B} = (\frac{\partial \varphi}{\partial x_2}, -\frac{\partial \varphi}{\partial x_1}, 0)$  e  $\varphi$  é solução das equações de estado:

$$-\Delta \varphi = \mu_0 j_0 \quad \text{em } \Omega \quad (27)$$

$$\varphi = 0 \quad \text{em } \Gamma \quad (28)$$

$$\varphi(\mathbf{x}) = O(1) \quad \text{quando } \|\mathbf{x}\| \rightarrow \infty \quad (29)$$

O equilíbrio em termos do fluxo  $\varphi$  fica:

$$\frac{1}{2\mu_0} \|\nabla \varphi\|^2 + \sigma \mathcal{C} = \bar{p} \quad \text{constante em } \Gamma \quad (30)$$

## Problema variacional

A formulação variacional consiste em encontrar  $\omega$  como um ponto crítico do funcional Energia Total:

$$E(\omega) = -\frac{1}{2\mu_0} \int_{\Omega} \|\nabla\varphi_{\omega}\|^2 d\Omega + \sigma \int_{\Gamma} d\Gamma, \quad (31)$$

sujeito à restrição de igualdade na área de  $\omega$ :

$$\int_{\omega} d\Omega = S_0. \quad (32)$$

onde  $\varphi_{\omega}$  verifica:

$$-\Delta\varphi_{\omega} = \mu_0 j_0 \quad \text{em } \Omega \quad (33)$$

$$\varphi_{\omega} = 0 \quad \text{em } \Gamma \quad (34)$$


$$\varphi_{\omega}(\mathbf{x}) = O(1) \quad \text{quando } \|\mathbf{x}\| \rightarrow \infty \quad (35)$$

## Diferenciação em relação à forma

Para caracterizar os pontos críticos utilizamos o conceito de diferenciação em relação à forma.

Para um domínio de referência  $\Omega_0$ , são consideradas as transformações:

$$T = Id + V, \quad \text{com} \quad V \in W^{1,\infty}(\mathbb{R}^n, \mathbb{R}^n), \quad \|V\|_{W^{1,\infty}(\mathbb{R}^n, \mathbb{R}^n)} < 1, \quad (36)$$



Definição do domínio transformado pelo campo vetorial  $V$ .

## Condição de equilíbrio

Função lagrangiana:

$$L(\omega, \bar{p}) = E(\omega) - \bar{p}(S(\omega) - S_0), \quad (37)$$

onde  $\bar{p}$  é o multiplicador de Lagrange associado à restrição de área.

Condição de ponto crítico:

$$L'(\omega, \bar{p})(V) = 0, \quad \forall V \in W^{1,\infty}(\mathbb{R}^2, \mathbb{R}^2). \quad (38)$$

**Teorema 5.1** Condição de equilíbrio do problema variacional:

$$\int_{\Gamma} \left( \frac{1}{2\mu_0} \|\nabla\varphi\|^2 + \sigma\mathcal{C} - \bar{p} \right) (V \cdot \nu) \, d\Gamma = 0 \quad \forall V \text{ in } W^{1,\infty}(\mathbb{R}^2, \mathbb{R}^2). \quad (39)$$

## Solução da equação de estado

Para achar a solução é considerada uma solução particular  $\varphi_1$ :

$$\varphi_1(\mathbf{x}) = -\frac{\mu_0}{2\pi} \int_{\mathbb{R}^2} \ln \|\mathbf{x} - \mathbf{y}\| j_0(\mathbf{y}) d\Omega \quad (40)$$

Então, a função  $\varphi$  pode ser calculada como:

$$\varphi(\mathbf{x}) = v(\mathbf{x}) + \varphi_1(\mathbf{x}) \quad (41)$$

onde a função  $v$  é solução de:

$$-\Delta v(\mathbf{x}) = 0 \quad \text{em } \Omega \quad (42)$$

$$v(\mathbf{x}) = -\varphi_1(\mathbf{x}) \quad \text{em } \Gamma \quad (43)$$

$$v(\mathbf{x}) = O(1) \quad \text{quando } \|\mathbf{x}\| \rightarrow \infty \quad (44)$$

## Solução da equação homogênea

Uma representação integral de  $v$  é dada por:

$$v(\mathbf{x}) = -\frac{1}{2\pi} \int_{\Gamma} q(\mathbf{y}) \ln \|\mathbf{x} - \mathbf{y}\| d\Gamma + c \quad (45)$$

onde  $c$  é o valor no infinito, e  $q \in H^{-1/2}(\Gamma)$  deve verificar:

$$\int_{\Gamma} q(\mathbf{x}) d\Gamma = 0 \quad (46)$$

As condições de contorno em  $\Gamma$  são impostas de forma fraca:

$$\begin{aligned} & -\frac{1}{2\pi} \int_{\Gamma} g(\mathbf{x}) \int_{\Gamma} q(\mathbf{y}) \ln \|\mathbf{x} - \mathbf{y}\| d\Gamma d\Gamma + c \int_{\Gamma} g(\mathbf{x}) d\Gamma \\ & = - \int_{\Gamma} \varphi_1(\mathbf{x}) g(\mathbf{x}) d\Gamma \quad \forall g \in H^{-1/2}(\Gamma) \end{aligned} \quad (47)$$

## Resumo das equações do problema direto

- ▶ Em resumo, temos as equações de estado:

$$-\frac{1}{2\pi} \int_{\Gamma} g(x) \int_{\Gamma} q(y) \ln \|x - y\| d\Gamma d\Gamma + c \int_{\Gamma} g(x) d\Gamma = - \int_{\Gamma} \varphi_1(x) g(x) d\Gamma \quad \forall g \in H^{-1/2}(\Gamma) \quad (48)$$

$$\int_{\Gamma} q(x) d\Gamma = 0 \quad (49)$$


- ▶ A restrição de igualdade na área de  $\omega$ :

$$\int_{\omega} d\Omega = S_0 \quad (50)$$

- ▶ A equação de equilíbrio no contorno:

$$\int_{\Gamma} \left( \frac{1}{2\mu_0} \|\nabla\varphi\|^2 + \sigma C - \bar{p} \right) (V \cdot \nu) d\Gamma = 0 \quad \forall V \text{ in } W^{1,\infty}(\mathbb{R}^n, \mathbb{R}^n) \quad (51)$$

# Discretização



Define-se a transformação paramétrica  $T_{\mathbf{u}}$  como:

$$T_{\mathbf{u}}(\mathbf{x}) = \mathbf{x} + V_{\mathbf{u}}(\mathbf{x}) \quad (52)$$

$$V_{\mathbf{u}}(\mathbf{x}) = \sum_{i=1}^n u_i V^i(\mathbf{x}) \quad (53)$$


onde  $\mathbf{u}^T = (u_1, \dots, u_n) \in \mathbb{R}^n$  é o vetor das incógnitas que determinam a evolução do contorno. Então, o contorno atualizado  $\Gamma_{\mathbf{u}}$  é dado por:

$$\Gamma_{\mathbf{u}} = \left\{ X \mid X = x + V_{\mathbf{u}}(x); x \in \Gamma^h \right\} \quad (54)$$




# Exemplo

Iter 0




# Exemplo

## Iter 4




# Exemplo

Iter 10

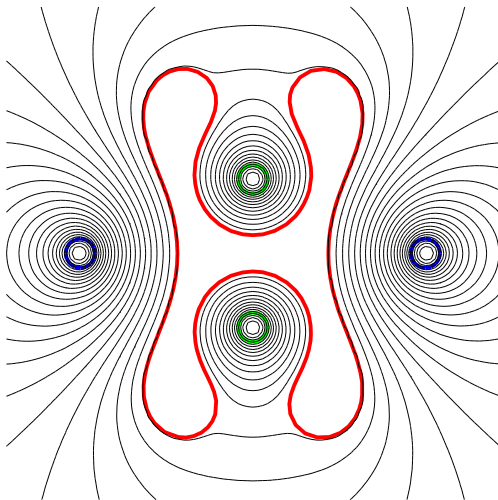


# Exemplo

Iter 29



# Exemplo



# Conteúdo

## Preliminares

Objetivo e Motivação

## Algoritmo FDIPA-H

Problema de Otimização Não Linear

Algoritmo FDIPA

Algoritmo FDIPA-H

## Fundição Eletromagnética

Problema direto

**Problema Inverso**

Exemplos

## Conclusões

# Problema Inverso

- ▶ **Encontrar a configuração de indutores** para ter  $\omega$  aproximadamente igual a uma forma objetivo  $\omega^*$
- ▶ Duas formulações são propostas:
  - 1) Minimização da “distância” entre a forma objetivo e a forma em equilíbrio.
  - 2) Minimização da pressão fictícia que equilibra a forma objetivo.
- ▶ Otimização da posição dos indutores.
- ▶ Otimização da forma dos indutores.

# Problema Inverso

- ▶ **Encontrar a configuração de indutores** para ter  $\omega$  aproximadamente igual a uma forma objetivo  $\omega^*$
- ▶ Duas formulações são propostas:
  - 1) Minimização da “distância” entre a forma objetivo e a forma em equilíbrio.
  - 2) Minimização da pressão fictícia que equilibra a forma objetivo.
- ▶ Otimização da posição dos indutores.
- ▶ Otimização da forma dos indutores.



# Problema Inverso

- ▶ **Encontrar a configuração de indutores** para ter  $\omega$  aproximadamente igual a uma forma objetivo  $\omega^*$
- ▶ Duas formulações são propostas:
  - 1) Minimização da “distância” entre a forma objetivo e a forma em equilíbrio.
  - 2) Minimização da pressão fictícia que equilibra a forma objetivo.
- ▶ Otimização da posição dos indutores.
- ▶ Otimização da forma dos indutores.

## Problema Inverso - Primeira formulação

A primeira formulação considera uma deformação do domínio  $\omega^*$  definida pelo mapeamento seguinte:

$$T_Z(x) = (Id + Z)(x), \quad \forall x \in \mathbb{R}^2 \quad (55)$$

onde  $Z$  é regular e tem suporte compacto em  $\mathbb{R}^2$ . Definindo:

$$\omega_Z = T_Z(\omega^*) \quad (56)$$

$$\Gamma_Z = T_Z(\Gamma^*) \quad (57)$$

**Primeira formulação do problema inverso:**

$$\min_{j_0, Z} \|Z\|_{L^2(\Gamma^*)}^2$$

sujeito a: (58)

$\omega_Z$  é equilibrado sob  $j_0$

## Problema Inverso - Segunda formulação

Considerando uma função de folga  $p(x) : \Gamma^* \rightarrow \mathbb{R}$  de forma que a equação de equilíbrio seja verificada para o domínio objetivo:

$$\int_{\Gamma^*} \left( \frac{1}{2\mu_0} \|\nabla \varphi_\omega\|^2 + \sigma \mathcal{C} - \bar{p} + p \right) (V \cdot \nu) d\Gamma = 0 \quad \forall V \text{ in } C^1(\mathbb{R}^2, \mathbb{R}^2) \quad (59)$$

A função  $p$  pode ser interpretada como sendo uma pressão adicional atuando na interface.

**Segunda formulação do problema inverso:**

$$\begin{aligned} & \min_{j_0, p} \|p\|_{L^2(\Gamma^*)}^2 \\ & \text{sujeito a:} \\ & \omega^* \text{ é equilibrado sob a ação de } j_0 \text{ e } p \end{aligned} \quad (60)$$

## Comparação das formulações

### Primeira formulação:

- 1) Acha a forma em equilíbrio.
- 2) Em geral encontra soluções mais aproximadas à forma objetivo.

### Segunda formulação:

- 1) Não têm variáveis relacionadas à forma do metal líquido.
- 2) Análise de sensibilidade fica mais simples.
- 3) O custo computacional do processo de otimização é muito menor para esta formulação.
- 4) Si for necessário, o resultado pode ser utilizado como ponto inicial da primeira formulação.

## Otimização da posição indutores

A densidade de corrente elétrica  $j_0$  é assumida da forma:

$$j_0 = I \sum_{i=1}^{n_c} \alpha_i \delta_{x_i}, \quad (61)$$


Neste caso a expressão para a função  $\varphi_1$  é:

$$\varphi_1(x) = -\frac{\mu_0 I}{2\pi} \sum_{i=1}^{n_c} \alpha_i \ln \|x - x_i\|. \quad (62)$$

$x_i$  variáveis de projeto do problema.


## Exemplo 3

### Configuração Inicial




## Exemplo 3

### Primeira formulação



# Exemplo 3

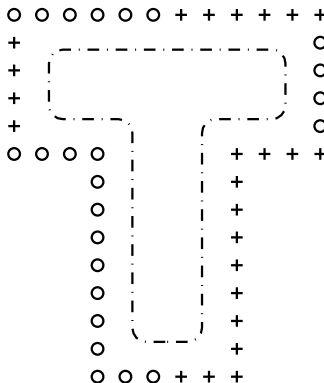
## Segunda formulação






# Exemplo 4

## Configuração Inicial




## Exemplo 4

Resultado da Primeira formulação




## Exemplo 4

Resultado da Segunda formulação



# Otimização de forma dos indutores



A hipótese de densidade uniforme é válida para o caso em que o indutor é composto por filamentos entrelaçados e isolados uns dos outros (Litz-Wire).

## Otimização de forma dos indutores

A densidade de corrente elétrica  $j_0$  é assumida da forma:

$$j_0 = I \sum_{i=1}^{n_c} \alpha_i \chi_{\Theta_i}, \quad (63)$$

Neste caso a expressão para a função  $\varphi_1$  é:


$$\varphi_1(\mathbf{x}) = -\frac{\mu_0 I}{2\pi} \sum_{i=1}^{n_c} \alpha_i \int_{\Theta_i} \ln \|\mathbf{x} - \mathbf{y}\| d\Omega_y. \quad (64)$$

Seja  $w : \mathbb{R}^2 \times \mathbb{R}^2 \rightarrow \mathbb{R}^2$ :


$$w(\mathbf{x}, \mathbf{y}) = (1/4)(1 - 2 \ln \|\mathbf{x} - \mathbf{y}\|)(\mathbf{x} - \mathbf{y}). \quad (65)$$

$$\varphi_1(\mathbf{x}) = -\frac{\mu_0 I}{2\pi} \sum_{i=1}^{n_c} \alpha_i \int_{\Gamma_i} w(\mathbf{x}, \mathbf{y}) \cdot \nu d\Gamma_y. \quad (66)$$

# Indutores



# Restrições geométricas



## Restrições geométricas

A função  $\psi$  proposta é definida pela solução de:


$$\begin{aligned} \Delta\psi(\mathbf{x}) &= 0 && \text{in } \Omega^*, \\ \psi(\mathbf{x}) &= 0 && \text{on } \Gamma^*, \\ \int_{\Gamma^*} \nabla\psi(\mathbf{x}) \cdot \nu \, d\Gamma &= -1. \end{aligned} \tag{67}$$

Definindo  $\psi_j(\mathbf{u}_c) = \psi(\mathbf{x}_j(\mathbf{u}_c)) - \psi_0$ , as restrições geométricas ficam:

$$\psi(\mathbf{u}_c) \leq 0. \tag{68}$$



# Restrições geométricas



Função  $\psi$

# Conteúdo

## Preliminares

Objetivo e Motivação

## Algoritmo FDIPA-H

Problema de Otimização Não Linear

Algoritmo FDIPA

Algoritmo FDIPA-H

## Fundição Eletromagnética

Problema direto


Problema Inverso

**Exemplos**

## Conclusões


# Exemplo 3

## Configuração Inicial




# Exemplo 3

Primeira formulação




## Exemplo 3

### Primeira formulação



# Exemplo 3


## Primeira formulação



Evolução da função objetivo


## Exemplo 3

### Segunda formulação



## Exemplo 3


### Segunda formulação





# Exemplo 3


## Segunda formulação



Evolução da função objetivo


## Exemplo 5

### Configuração Inicial




## Exemplo 5

### Primeira formulação




## Exemplo 5

### Primeira formulação



# Exemplo 5


## Primeira formulação



Evolução da função objetivo


## Exemplo 5

### Segunda formulação




## Exemplo 5

### Segunda formulação



# Exemplo 5

## Segunda formulação



Evolução da função objetivo



## Conclusões

- 1) Neste trabalho foi proposto um método para otimização na Engenharia Mecânica baseado na utilização do MEC, na formulação SAND e na utilização de um algoritmo de ponto interior.
- 2) No Capítulo 3 da tese é apresentado o algoritmo FDIPA-H.
  - ▶ Utiliza a matriz hessiana do problema de otimização nos sistemas lineares.
  - ▶ É muito eficiente para os problemas de grande porte da coleção CUTE.

### Trabalhos futuros

- ▶ Ver convergência assintótica.

## Conclusões

- 3) Uma aplicação do método proposto ao problema de Fundição Eletromagnética foi apresentada no Capítulo 5.
- ▶ Duas formulações para a solução do problema inverso.
  - ▶ Técnica geral para satisfazer as restrições geométricas de não penetração.

### Trabalhos futuros

- ▶ Ver o problema de otimização topológica dos indutores.
- ▶ Considerar modelos para baixas frequências da corrente elétrica.