

ALGORITMOS BASEADOS NO MÉTODO DE NEWTON PARA PROBLEMAS DE OTIMIZAÇÃO NÃO LINEARES

Alfredo Canelas José Herskovits Sandro R. Mazorche

Departamento de Engenharia Mecânica
COPPE – UFRJ

CILAMCE, 2008



Conteúdo

Preliminares

Problema de Otimização Não Linear

Objetivo

Algoritmo FDIPA

Estudo da direção de Newton

Direção de Newton

Teoremas

Algoritmo

Matriz \mathbf{M}_k

Algoritmo de Otimização



Conteúdo

Preliminares

Problema de Otimização Não Linear

Objetivo

Algoritmo FDIPA

Estudo da direção de Newton

Direção de Newton

Teoremas

Algoritmo

Matriz \mathbf{M}_k

Algoritmo de Otimização



Problema de Otimização Não Linear

- ▶ Encontrar \mathbf{x} 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} tal que $\forall \mathbf{x} \in \Omega \cap \mathcal{N}$

$$f(\mathbf{x}) \geq f(\mathbf{x}^*)$$



Problema de Otimização Não Linear

- ▶ Encontrar \mathbf{x} 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} tal que $\forall \mathbf{x} \in \Omega \cap \mathcal{N}$

$$f(\mathbf{x}) \geq f(\mathbf{x}^*)$$



Problema de Otimização Não Linear

- ▶ Encontrar \mathbf{x} 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} tal que $\forall \mathbf{x} \in \Omega \cap \mathcal{N}$

$$f(\mathbf{x}) \geq f(\mathbf{x}^*)$$





Problema de Otimização Não Linear

- **Regularidade:** para os pontos \mathbf{x} :

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

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

$$\begin{aligned} \nabla f(\mathbf{x}) - \sum_{i=1}^m \lambda_i \nabla \mathbf{g}_i(\mathbf{x}) - \sum_{i=1}^p \mu_i \nabla \mathbf{h}_i(\mathbf{x}) &= 0 \\ \mathbf{g}_i(\mathbf{x}) \lambda_i &= 0 \\ \mathbf{h}(\mathbf{x}) &= 0 \\ \mathbf{g}(\mathbf{x}) &\geq 0 \\ \lambda &\geq 0 \end{aligned}$$



Problema de Otimização Não Linear

- ▶ **Regularidade:** para os pontos \mathbf{x} :

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

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

$$\begin{aligned} \nabla f(\mathbf{x}) - \sum_{i=1}^m \lambda_i \nabla \mathbf{g}_i(\mathbf{x}) - \sum_{i=1}^p \mu_i \nabla \mathbf{h}_i(\mathbf{x}) &= 0 \\ \mathbf{g}_i(\mathbf{x}) \lambda_i &= 0 \\ \mathbf{h}(\mathbf{x}) &= 0 \\ \mathbf{g}(\mathbf{x}) &\geq 0 \\ \lambda &\geq 0 \end{aligned}$$



Problema de Otimização Não Linear

- ▶ **Regularidade:** para os pontos \mathbf{x} :

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

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

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

$$\mathbf{g}_i(\mathbf{x}) \lambda_i = 0$$

$$\mathbf{h}(\mathbf{x}) = 0$$

$$\mathbf{g}(\mathbf{x}) \geq 0$$

$$\lambda \geq 0$$

Sistema
de
Equações
(Newton)



Direção de Newton

- ▶ **Função lagrangiana:**

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

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

- ▶ **Iteração de Newton:** $(\mathbf{x}_{k+1}, \boldsymbol{\lambda}_{k+1}, \boldsymbol{\mu}_{k+1}) = (\mathbf{x}_k, \boldsymbol{\lambda}_k, \boldsymbol{\mu}_k) + (\mathbf{d}_x, \mathbf{d}_\lambda, \mathbf{d}_\mu)$:

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

- ▶ **NÃO FUNCIONA**



Direção de Newton

- ▶ **Função lagrangiana:**

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

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

- ▶ **Iteração de Newton:** $(\mathbf{x}_{k+1}, \boldsymbol{\lambda}_{k+1}, \boldsymbol{\mu}_{k+1}) = (\mathbf{x}_k, \boldsymbol{\lambda}_k, \boldsymbol{\mu}_k) + (\mathbf{d}_x, \mathbf{d}_\lambda, \mathbf{d}_\mu)$:

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

- ▶ **NÃO FUNCIONA**



Direção de Newton

- ▶ **Função lagrangiana:**

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

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

- ▶ **Iteração de Newton:** $(\mathbf{x}_{k+1}, \boldsymbol{\lambda}_{k+1}, \boldsymbol{\mu}_{k+1}) = (\mathbf{x}_k, \boldsymbol{\lambda}_k, \boldsymbol{\mu}_k) + (\mathbf{d}_x, \mathbf{d}_\lambda, \mathbf{d}_\mu)$:

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

- ▶ **NÃO FUNCIONA**



Direção de Newton

- ▶ Função lagrangiana:

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

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

- ▶ Iteração de Newton: $(\mathbf{x}_{k+1}, \boldsymbol{\lambda}_{k+1}, \boldsymbol{\mu}_{k+1}) = (\mathbf{x}_k, \boldsymbol{\lambda}_k, \boldsymbol{\mu}_k) + (\mathbf{d}_x, \mathbf{d}_\lambda, \mathbf{d}_\mu)$:

Sistema
singular

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

- ▶ NÃO FUNCIONA



Direção de Newton

- ▶ **Função lagrangiana:**

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

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

- ▶ **Iteração de Newton:** $(\mathbf{x}_{k+1}, \boldsymbol{\lambda}_{k+1}, \boldsymbol{\mu}_{k+1}) = (\mathbf{x}_k, \boldsymbol{\lambda}_k, \boldsymbol{\mu}_k) + (\mathbf{d}_x, \mathbf{d}_\lambda, \mathbf{d}_\mu)$:

Sistema
singular

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

- ▶ **NÃO FUNCIONA** $\mathbf{g}(\mathbf{x}) < 0, \boldsymbol{\lambda} < 0$



Conteúdo

Preliminares

Problema de Otimização Não Linear

Objetivo

Algoritmo FDIPA

Estudo da direção de Newton

Direção de Newton

Teoremas

Algoritmo

Matriz \mathbf{M}_k

Algoritmo de Otimização



Objetivo e Motivação

- ▶ **Objetivo:**
 - ▶ Definir um algoritmo de otimização baseado na **direção da iteração de Newton**.
- ▶ **Motivação:**
 - ▶ Existem problemas onde \mathbf{H} pode ser calculada com um custo pequeno.
 - ▶ Maior velocidade de convergência.



Objetivo e Motivação

- ▶ Objetivo:
 - ▶ Definir um algoritmo de otimização baseado na **direção da iteração de Newton**.
- ▶ Motivação:
 - ▶ Existem problemas onde \mathbf{H} pode ser calculada com um custo pequeno.
 - ▶ Maior velocidade de convergência.



Conteúdo

Preliminares

Problema de Otimização Não Linear

Objetivo

Algoritmo FDIPA

Estudo da direção de Newton

Direção de Newton

Teoremas

Algoritmo

Matriz \mathbf{M}_k

Algoritmo de Otimização



Algoritmo FDIPA

- ▶ FDIPA gera seqüência $\{\mathbf{x}_k\}_{k \in \mathbb{N}} \subset \Delta$:

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

- ▶ A seqüência reduz em cada iteração o valor da **função potencial** $\phi_{\mathbf{c}}(\mathbf{x})$:

$$\phi_{\mathbf{c}}(\mathbf{x}) = f(\mathbf{x}) + \sum_{i=1}^p \mathbf{c}_i |\mathbf{h}_i(\mathbf{x})|$$

- ▶ Atualização: $\mathbf{x}_{k+1} = \mathbf{x}_k + t \mathbf{d}_x$:

- ▶ A direção $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$:

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



Algoritmo FDIPA

- ▶ FDIPA gera seqüência $\{\mathbf{x}_k\}_{k \in \mathbb{N}} \subset \Delta$:

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

- ▶ A seqüência reduz em cada iteração o valor da **função potencial** $\phi_{\mathbf{c}}(\mathbf{x})$:

$$\phi_{\mathbf{c}}(\mathbf{x}) = f(\mathbf{x}) + \sum_{i=1}^p \mathbf{c}_i |\mathbf{h}_i(\mathbf{x})|$$

- ▶ Atualização: $\mathbf{x}_{k+1} = \mathbf{x}_k + t \mathbf{d}_x$:

- ▶ A direção $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$:

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



Algoritmo FDIPA

- ▶ FDIPA gera seqüência $\{\mathbf{x}_k\}_{k \in \mathbb{N}} \subset \Delta$:

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

- ▶ A seqüência reduz em cada iteração o valor da **função potencial** $\phi_{\mathbf{c}}(\mathbf{x})$:

$$\phi_{\mathbf{c}}(\mathbf{x}) = f(\mathbf{x}) + \sum_{i=1}^p \mathbf{c}_i |\mathbf{h}_i(\mathbf{x})|$$

- ▶ Atualização: $\mathbf{x}_{k+1} = \mathbf{x}_k + t \mathbf{d}_x$:

- ▶ A direção $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$:

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





Algoritmo FDIPA

- ▶ FDIPA gera seqüência $\{\mathbf{x}_k\}_{k \in \mathbb{N}} \subset \Delta$:

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

- ▶ A seqüência reduz em cada iteração o valor da **função potencial** $\phi_{\mathbf{c}}(\mathbf{x})$:

$$\phi_{\mathbf{c}}(\mathbf{x}) = f(\mathbf{x}) + \sum_{i=1}^p \mathbf{c}_i |\mathbf{h}_i(\mathbf{x})|$$

- ▶ Atualização: $\mathbf{x}_{k+1} = \mathbf{x}_k + t \mathbf{d}_x$:

- ▶ A direção $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$:

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



Algoritmo FDIPA

- ▶ FDIPA gera seqüência $\{\mathbf{x}_k\}_{k \in \mathbb{N}} \subset \Delta$:

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

- ▶ A seqüência reduz em cada iteração o valor da **função potencial** $\phi_{\mathbf{c}}(\mathbf{x})$:

$$\phi_{\mathbf{c}}(\mathbf{x}) = f(\mathbf{x}) + \sum_{i=1}^p \mathbf{c}_i |\mathbf{h}_i(\mathbf{x})|$$

- ▶ Atualização: $\mathbf{x}_{k+1} = \mathbf{x}_k + t \mathbf{d}_x$:

- ▶ A direção $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$:

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

\mathbf{B}_k positiva definida em vez da Hessiana



Algoritmo FDIPA

- ▶ FDIPA gera seqüência $\{\mathbf{x}_k\}_{k \in \mathbb{N}} \subset \Delta$:

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

- ▶ A seqüência reduz em cada iteração o valor da **função potencial** $\phi_{\mathbf{c}}(\mathbf{x})$:

$$\phi_{\mathbf{c}}(\mathbf{x}) = f(\mathbf{x}) + \sum_{i=1}^p \mathbf{c}_i |\mathbf{h}_i(\mathbf{x})|$$

- ▶ Atualização: $\mathbf{x}_{k+1} = \mathbf{x}_k + t \mathbf{d}_x$:

- ▶ A direção $\mathbf{d}_x = \mathbf{d}_x^\alpha + \rho \mathbf{d}_x^\beta$:

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

\mathbf{B}_k positiva definida em vez da Hessiana

\mathbf{d}_x^β : direção de restauração



Convergência global do FDIPA

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

→ Sistema 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 + \mathbf{B}_k positiva definida + $\lambda > 0$ + $\mathbf{g}(\mathbf{x}_k) \geq 0$:

→ Sistema não singular

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

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

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

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

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

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



Convergência global do FDIPA

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

→ Sistema não singular

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

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

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

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

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



Convergência global do FDIPA

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

→ Sistema 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 + \mathbf{B}_k positiva definida + $\lambda > 0$ + $\mathbf{g}(\mathbf{x}_x) \geq 0$:

→ Sistema 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.).



Conteúdo

Preliminares

Problema de Otimização Não Linear

Objetivo

Algoritmo FDIPA

Estudo da direção de Newton

Direção de Newton

Teoremas

Algoritmo

Matriz \mathbf{M}_k

Algoritmo de Otimização



Direção de Newton

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

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

- ▶ Espaço tangente:

$$\mathcal{T} = \{\mathbf{v} \mid \mathbf{v} \perp \{\nabla \mathbf{g}_i(\mathbf{x}) \mid g_i(\mathbf{x}) = 0, \nabla \mathbf{h}_i(\mathbf{x}) \mid i \in \{1, \dots, p\}\}\}$$

- ▶ Matriz \mathbf{M} :

$$\mathbf{M}(\mathbf{x}, \lambda, \mu) = \mathbf{H}(\mathbf{x}, \lambda, \mu) + \nabla \mathbf{g}^{IT}(\mathbf{x}) \mathbf{G}'(\mathbf{x})^{-1} \mathbf{\Lambda}' \nabla \mathbf{g}'(\mathbf{x})$$

- ▶ Função potencial:

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



Direção de Newton

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

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

- ▶ Espaço tangente:

$$\mathcal{T} = \{\mathbf{v} \mid \mathbf{v} \perp \{\nabla \mathbf{g}_i(\mathbf{x}) \mid g_i(\mathbf{x}) = 0, \nabla \mathbf{h}_i(\mathbf{x}) \mid i \in \{1, \dots, p\}\}\}$$

- ▶ Matriz \mathbf{M} :

$$\mathbf{M}(\mathbf{x}, \lambda, \mu) = \mathbf{H}(\mathbf{x}, \lambda, \mu) + \nabla \mathbf{g}^{IT}(\mathbf{x}) \mathbf{G}'(\mathbf{x})^{-1} \mathbf{\Lambda}' \nabla \mathbf{g}'(\mathbf{x})$$

- ▶ Função potencial:

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



Direção de Newton

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

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

- ▶ Espaço tangente:

$$\mathcal{T} = \{\mathbf{v} \mid \mathbf{v} \perp \{\nabla \mathbf{g}_i(\mathbf{x}) \mid g_i(\mathbf{x}) = 0, \nabla \mathbf{h}_i(\mathbf{x}) \mid i \in \{1, \dots, p\}\}\}$$

- ▶ Matriz \mathbf{M} :

$$\mathbf{M}(\mathbf{x}, \lambda, \mu) = \mathbf{H}(\mathbf{x}, \lambda, \mu) + \nabla \mathbf{g}^{IT}(\mathbf{x}) \mathbf{G}'(\mathbf{x})^{-1} \mathbf{\Lambda}' \nabla \mathbf{g}'(\mathbf{x})$$

- ▶ Função potencial:

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



Direção de Newton

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

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

- ▶ Espaço tangente:

$$\mathcal{T} = \{\mathbf{v} \mid \mathbf{v} \perp \{\nabla \mathbf{g}_i(\mathbf{x}) \mid g_i(\mathbf{x}) = 0, \nabla \mathbf{h}_i(\mathbf{x}) \mid i \in \{1, \dots, p\}\}\}$$

- ▶ Matriz \mathbf{M} :

$$\mathbf{M}(\mathbf{x}, \lambda, \mu) = \mathbf{H}(\mathbf{x}, \lambda, \mu) + \nabla \mathbf{g}^{lT}(\mathbf{x}) \mathbf{G}^l(\mathbf{x})^{-1} \mathbf{\Lambda}^l \nabla \mathbf{g}^l(\mathbf{x})$$

- ▶ Função potencial:

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



Conteúdo

Preliminares

Problema de Otimização Não Linear

Objetivo

Algoritmo FDIPA

Estudo da direção de Newton

Direção de Newton

Teoremas

Algoritmo

Matriz \mathbf{M}_k

Algoritmo de Otimização



Direção de Newton

- ▶ **Assumindo:** Regularidade + \mathbf{M}_k positiva definida no espaço \mathcal{T} +
+ $\lambda > 0$ + $\mathbf{g}(\mathbf{x}_k) \geq 0$:
- ▶ **LEMA:** → Sistema não singular
- ▶ **LEMA:** \mathbf{x} não é ponto estacionário: → $\|\mathbf{d}_x^\alpha\| > 0$
- ▶ **TEOREMA:** $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$
 - ▶ \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^α é de descida para a função potencial $\phi(\mathbf{x}) = c \Psi(\mathbf{h}(\mathbf{x}))$



Direção de Newton

- ▶ **Assumindo:** Regularidade + \mathbf{M}_k positiva definida no espaço \mathcal{T} +
+ $\lambda > 0$ + $\mathbf{g}(\mathbf{x}_k) \geq 0$:
- ▶ **LEMA:** → Sistema não singular
- ▶ **LEMA:** \mathbf{x} não é ponto estacionário: → $\|\mathbf{d}_x^\alpha\| > 0$
- ▶ **TEOREMA:** $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$
 - ▶ \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^α é de descida para a função potencial $\phi(\mathbf{x}) = c \Psi(\mathbf{h}(\mathbf{x}))$



Direção de Newton

- ▶ **Assumindo:** Regularidade + \mathbf{M}_k positiva definida no espaço \mathcal{T} +
+ $\lambda > 0$ + $\mathbf{g}(\mathbf{x}_k) \geq 0$:
- ▶ **LEMA:** → Sistema não singular
- ▶ **LEMA:** \mathbf{x} não é ponto estacionário: → $\|\mathbf{d}_x^\alpha\| > 0$
- ▶ **TEOREMA:** $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$
 - ▶ \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^α é de descida para a função potencial $\phi(\mathbf{x}) = c \Psi(\mathbf{h}(\mathbf{x}))$



Direção de Newton

- ▶ **Assumindo:** Regularidade + \mathbf{M}_k positiva definida no espaço \mathcal{T} +
+ $\lambda > 0$ + $\mathbf{g}(\mathbf{x}_k) \geq 0$:
- ▶ **LEMA:** → Sistema não singular
- ▶ **LEMA:** \mathbf{x} não é ponto estacionário: → $\|\mathbf{d}_x^\alpha\| > 0$
- ▶ **TEOREMA:** $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$
 - ▶ \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^α é de descida para a função potencial $\phi(\mathbf{x}) = c \Psi(\mathbf{h}(\mathbf{x}))$



Direção de Newton

- ▶ **Assumindo:** Regularidade + \mathbf{M}_k positiva definida no espaço \mathcal{T} +
+ $\lambda > 0$ + $\mathbf{g}(\mathbf{x}_k) \geq 0$:
- ▶ **LEMA:** → Sistema não singular
- ▶ **LEMA:** \mathbf{x} não é ponto estacionário: → $\|\mathbf{d}_x^\alpha\| > 0$
- ▶ **TEOREMA:** $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$
 - ▶ \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^α é de descida para a função potencial $\phi(\mathbf{x}) = c \Psi(\mathbf{h}(\mathbf{x}))$



Direção de Newton

- ▶ **Assumindo:** Regularidade + \mathbf{M}_k positiva definida no espaço \mathcal{T} + $\lambda > 0$ + $\mathbf{g}(\mathbf{x}_k) \geq 0$:
- ▶ **LEMA:** → Sistema não singular
- ▶ **LEMA:** \mathbf{x} não é ponto estacionário: → $\|\mathbf{d}_x^\alpha\| > 0$
- ▶ **TEOREMA:** $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$
 - ▶ \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^α é de descida para a função potencial $\phi(\mathbf{x}) = c \Psi(\mathbf{h}(\mathbf{x}))$

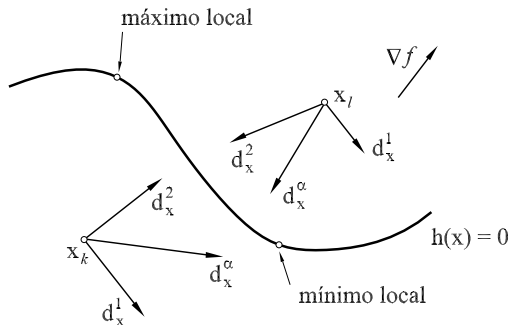


Direção de Newton

- ▶ **Assumindo:** Regularidade + \mathbf{M}_k positiva definida no espaço \mathcal{T} +
+ $\lambda > 0$ + $\mathbf{g}(\mathbf{x}_k) \geq 0$:
- ▶ **LEMA:** → Sistema não singular
- ▶ **LEMA:** \mathbf{x} não é ponto estacionário: → $\|\mathbf{d}_x^\alpha\| > 0$
- ▶ **TEOREMA:** $\mathbf{d}_x^\alpha = \mathbf{d}_x^1 + \mathbf{d}_x^2$
 - ▶ \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^α é de descida para a função potencial $\phi(\mathbf{x}) = c \Psi(\mathbf{h}(\mathbf{x}))$




Direção de Newton



► M_k deve ser **positiva definida** no espaço \mathcal{T}



Direção de Newton



- M_k deve ser **positiva definida** no espaço T



Conteúdo

Preliminares

Problema de Otimização Não Linear

Objetivo

Algoritmo FDIPA

Estudo da direção de Newton

Direção de Newton

Teoremas

Algoritmo

Matriz \mathbf{M}_k

Algoritmo de Otimização



\mathbf{M}_k ?

- ▶ Duas perguntas:
 - ▶ Como saber se \mathbf{M}_k positiva definida no espaço \mathcal{T} ?
 - ▶ O que fazer se não é ?
- ▶ **TEOREMA:** \mathbf{M}_k 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 $\mathbf{h}(\mathbf{x})$
- ▶ $\text{inércia}(\mathbf{A}) = \{i_+, i_-, i_0\}$
 - ▶ 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 ?

- ▶ Duas perguntas:
 - ▶ Como saber se \mathbf{M}_k positiva definida no espaço \mathcal{T} ?
 - ▶ O que fazer se não é ?
- ▶ **TEOREMA:** \mathbf{M}_k 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 $\mathbf{h}(\mathbf{x})$
- ▶ $\text{inércia}(\mathbf{A}) = \{i_+, i_-, i_0\}$
 - ▶ 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 ?

- ▶ Duas perguntas:
 - ▶ Como saber se \mathbf{M}_k positiva definida no espaço \mathcal{T} ?
 - ▶ O que fazer se não é ?
- ▶ **TEOREMA:** \mathbf{M}_k 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 $\mathbf{h}(\mathbf{x})$
- ▶ $\text{inércia}(\mathbf{A}) = \{i_+, i_-, i_0\}$
 - ▶ 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 ?

- ▶ Duas perguntas:
 - ▶ Como saber se \mathbf{M}_k positiva definida no espaço \mathcal{T} ?
 - ▶ O que fazer se não é ?
- ▶ **TEOREMA:** \mathbf{M}_k 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 ?

- ▶ Duas perguntas:
 - ▶ Como saber se \mathbf{M}_k positiva definida no espaço \mathcal{T} ?
 - ▶ O que fazer se não é ?
- ▶ **TEOREMA:** \mathbf{M}_k 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 $\mathbf{h}(\mathbf{x})$
- ▶ $\text{inércia}(\mathbf{A}) = \{i_+, i_-, i_0\}$
 - ▶ 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 ?

- ▶ Duas perguntas:
 - ▶ Como saber se \mathbf{M}_k positiva definida no espaço \mathcal{T} ?
 - ▶ O que fazer se não é ?
- ▶ **TEOREMA:** \mathbf{M}_k 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)






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)



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

- ▶ Substituir \mathbf{H}_k por $\mathbf{H}_k + \gamma \mathbf{I}$
 - ▶ Sempre existe γ conveniente
 - ▶ Preserva esparsidade de \mathbf{H}_k

- ▶ Exemplo: utilizar $\mathbf{H}_k + \gamma \mathbf{I}$ positiva definida:

$$\gamma_k = \max_{1 \leq i \leq n} \left\{ \max \left\{ (\mathbf{H}_k)_{ii}, 1.2 \sum_{j \neq i} |(\mathbf{H}_k)_{ij}| \right\} \right\}$$



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

- ▶ Substituir \mathbf{H}_k por $\mathbf{H}_k + \gamma \mathbf{I}$
 - ▶ Sempre existe γ conveniente
 - ▶ Preserva esparsidade de \mathbf{H}_k

- ▶ Exemplo: utilizar $\mathbf{H}_k + \gamma \mathbf{I}$ positiva definida:

$$\gamma_k = \max_{1 \leq i \leq n} \left\{ \max \left\{ (\mathbf{H}_k)_{ii}, 1.2 \sum_{j \neq i} |(\mathbf{H}_k)_{ij}| \right\} \right\}$$



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

- ▶ Substituir \mathbf{H}_k por $\mathbf{H}_k + \gamma \mathbf{I}$
 - ▶ Sempre existe γ conveniente
 - ▶ Preserva esparsidade de \mathbf{H}_k

- ▶ Exemplo: utilizar $\mathbf{H}_k + \gamma \mathbf{I}$ positiva definida:

$$\gamma_k = \max_{1 \leq i \leq n} \left\{ \max \left\{ (\mathbf{H}_k)_{ii}, 1.2 \sum_{j \neq i} |(\mathbf{H}_k)_{ij}| \right\} \right\}$$



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

- ▶ Substituir \mathbf{H}_k por $\mathbf{H}_k + \gamma \mathbf{I}$
 - ▶ Sempre existe γ conveniente
 - ▶ Preserva esparsidade de \mathbf{H}_k

- ▶ Exemplo: utilizar $\mathbf{H}_k + \gamma \mathbf{I}$ positiva definida:

$$\gamma_k = \max_{1 \leq i \leq n} \left\{ \max \left\{ (\mathbf{H}_k)_{ii}, 1.2 \sum_{j \neq i} |(\mathbf{H}_k)_{ij}| \right\} \right\}$$



Conteúdo

Preliminares

Problema de Otimização Não Linear

Objetivo

Algoritmo FDIPA

Estudo da direção de Newton

Direção de Newton

Teoremas

Algoritmo

Matriz \mathbf{M}_k

Algoritmo de Otimização



Algoritmo de Otimização

Dados: $\mathbf{x}_0 \in \Delta^0$, $\lambda_0 \in \mathbb{R}^m$ positivo, $\mu_0 \in \mathbb{R}^p$
 $\omega^l \in \mathbb{R}^m$ 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 γ_k e solução do sistema:

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

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

2.4 Atualize c_k

2.5 Calcule ρ 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

Dados: $\mathbf{x}_0 \in \Delta^0$, $\lambda_0 \in \mathbb{R}^m$ positivo, $\mu_0 \in \mathbb{R}^p$
 $\omega^l \in \mathbb{R}^m$ 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 γ_k e solução do sistema:

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

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

2.4 Atualize c_k

2.5 Calcule ρ 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

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 γ_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 ρ 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

Dados: $\mathbf{x}_0 \in \Delta^0$, $\lambda_0 \in \mathbb{R}^m$ positivo, $\mu_0 \in \mathbb{R}^p$

$\omega^l \in \mathbb{R}^m$ 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 γ_k e solução do sistema:

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

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

2.4 Atualize c_k

2.5 Calcule ρ 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

Dados: $\mathbf{x}_0 \in \Delta^0$, $\lambda_0 \in \mathbb{R}^m$ positivo, $\mu_0 \in \mathbb{R}^p$
 $\omega^l \in \mathbb{R}^m$ 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 γ_k e solução do sistema:

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

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

2.4 Atualize c_k

2.5 Calcule ρ 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

Dados: $\mathbf{x}_0 \in \Delta^0$, $\lambda_0 \in \mathbb{R}^m$ positivo, $\mu_0 \in \mathbb{R}^p$
 $\omega^l \in \mathbb{R}^m$ 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 γ_k e solução do sistema:

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

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

2.4 Atualize c_k

2.5 Calcule ρ 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.



Conclusões

- ▶ Se \mathbf{M} positiva definida em \mathcal{T}
→ direção de Newton é de descida.
- ▶ \mathbf{M} positiva definida em \mathcal{T}
 \Leftrightarrow inércia(\mathbf{A}) = $\{n, m + p, 0\}$.
- ▶ Um algoritmo de otimização que utiliza \mathbf{H} foi apresentado.

- ▶ Trabalhos futuros
 - ▶ Provar convergência global.
 - ▶ Ver eficiência na solução de exemplos.

FIM



Conclusões

- ▶ Se \mathbf{M} positiva definida em \mathcal{T}
→ direção de Newton é de descida.
- ▶ \mathbf{M} positiva definida em \mathcal{T}
↔ inércia(\mathbf{A}) = $\{n, m + p, 0\}$.
- ▶ Um algoritmo de otimização que utiliza \mathbf{H} foi apresentado.
- ▶ Trabalhos futuros
 - ▶ Provar convergência global.
 - ▶ Ver eficiência na solução de exemplos.

FIM



Conclusões

- ▶ Se \mathbf{M} positiva definida em \mathcal{T}
→ direção de Newton é de descida.
- ▶ \mathbf{M} positiva definida em \mathcal{T}
 $\Leftrightarrow \text{inércia}(\mathbf{A}) = \{n, m + p, 0\}$.
- ▶ Um algoritmo de otimização que utiliza \mathbf{H} foi apresentado.
- ▶ Trabalhos futuros
 - ▶ Provar convergência global.
 - ▶ Ver eficiência na solução de exemplos.

FIM



Conclusões

- ▶ Se \mathbf{M} positiva definida em \mathcal{T}
→ direção de Newton é de descida.
- ▶ \mathbf{M} positiva definida em \mathcal{T}
 \Leftrightarrow inércia(\mathbf{A}) = $\{n, m + p, 0\}$.
- ▶ Um algoritmo de otimização que utiliza \mathbf{H} foi apresentado.

- ▶ Trabalhos futuros
 - ▶ Provar convergência global.
 - ▶ Ver eficiência na solução de exemplos.

FIM



Conclusões

- ▶ Se \mathbf{M} positiva definida em \mathcal{T}
→ direção de Newton é de descida.
- ▶ \mathbf{M} positiva definida em \mathcal{T}
 $\Leftrightarrow \text{inércia}(\mathbf{A}) = \{n, m + p, 0\}$.
- ▶ Um algoritmo de otimização que utiliza \mathbf{H} foi apresentado.

- ▶ Trabalhos futuros
 - ▶ Provar convergência global.
 - ▶ Ver eficiência na solução de exemplos.

FIM

