

O Pacote computacional IPOPT

On the implementation of an interior-point filter line-search algorithm for large-scale nonlinear programming

Andreas Wächter & Lorenz T. Biegler

Mathematical Programming 106, 25–57 (2006) | Cite this article

Problema a ser resolvido:

$$\begin{aligned} \min_{x \in \mathbb{R}^n} \quad & f(x) \\ \text{s.t. } & c(x) = 0 \\ & x_L \leq x \leq x_U, \end{aligned}$$

where $x_L \in [-\infty, \infty]^n$ and $x_U \in (-\infty, \infty]^n$, with $x_L^{(i)} \leq x_U^{(i)}$,

f, c duas vezes continuamente diferenciáveis.

- restrições $g(x) \leq 0 \rightarrow g(x) + w = 0, w \geq 0$

Representação da teoria para o problema simplificado

$$\begin{aligned} \min_{x \in \mathbb{R}^n} \quad & f(x) \\ \text{s.t. } & c(x) = 0 \\ & x \geq 0. \end{aligned}$$

IPOPT implementa barreira logarítmica. Seus subproblemas são

$$\min_{x \in \mathbb{R}^n} \varphi_\mu(x) := f(x) - \mu \sum_{i=1}^n \ln(x^{(i)})$$

$$\text{s.t. } c(x) = 0$$

onde $\mu \rightarrow 0^+$ (teoria vista em aula)

Resolva-se o subproblema acima por suas condições KKT:

veja as contas no anexo

$$\left[\begin{array}{l} \nabla f(x) + \nabla c(x)\lambda - z = 0 \\ c(x) = 0 \\ XZe - \mu e = 0, \end{array} \right] \quad \left(\mathbf{c} = \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \right)$$

onde, como visto em aula,

$$X = \text{diag}(x_1, \dots, x_n) = \begin{bmatrix} x_1 & & 0 \\ & \ddots & \\ 0 & & x_n \end{bmatrix}$$

(análogo para Z).

- veja as contas no anexo*
- Note que KKT para o problema original é o sistema acima com $\mu = 0$.
 (a complementariedade $x_i z_i = 0$, $\forall i$, pode ser escrita como $XZe = 0$. Note que z_i é o multiplicador de Lagrange para $x_i \geq 0$).

Por isso queremos $\mu \rightarrow 0^+$.

Critério de parada

- Baseado no cumprimento aproximado das condições KKT do problema original.
- Medida de qualidade de KKT do subproblema

$$E_\mu(x, \lambda, z) := \max \left\{ \frac{\|\nabla f(x) + \nabla c(x)\lambda - z\|_\infty}{s_d}, \|c(x)\|_\infty, \frac{\|XZe - \mu e\|_\infty}{s_c} \right\}$$

↳ $\|\nabla f(x) + \nabla c(x)\lambda - z\|_\infty$ é o resíduo da 1ª equação do sistema KKT.

↳ $\|c(x)\|_\infty$ é a medida de infeasibilidade.

↳ $\|XZe - \mu e\|_\infty$ é o resíduo da complementariedade.

↳ $s_d > 1$ e $s_c > 1$ são parâmetros de escalamento. Eles visam afrontar a parada em problemas mal-condicionados.

↳ Deja que $\|c(x)\|_\infty$ não é escalada. O que se deseja, obter um ponto viável é

prioridade, IPOPT não flexibiliza isso.

Parada com sucesso

$$E_0(\tilde{x}_*, \tilde{\lambda}_*, \tilde{z}_*) \leq \epsilon_{\text{tol}}$$

- $\epsilon_{\text{tol}} > 0$: Tolerância fornecida pelo usuário
(padrão 10^{-8})
- $\mu = 0 \Rightarrow \approx \text{KKT}$ do problema original



Solução do subproblema

- Passos Newtonianos:

$$\begin{bmatrix} W_k & A_k & -I \\ A_k^T & 0 & 0 \\ Z_k & 0 & X_k \end{bmatrix} \begin{pmatrix} d_k^x \\ d_k^\lambda \\ d_k^z \end{pmatrix} = - \begin{pmatrix} \nabla f(x_k) + A_k \lambda_k - z_k \\ c(x_k) \\ X_k Z_k e - \mu_j e \end{pmatrix} \quad (*)$$

onde $W_k = \nabla_{xx}^2 L(x_k, \lambda_k, z_k)$ e $A_k = \nabla c(x_k)$

- d = direção de Newton (visto em aula)

- IPOPT não resolve (*) diretamente. Ao invés disso, resolve o seguinte sistema

equivalente:

$$\begin{bmatrix} W_k + \Sigma_k & A_k \\ A_k^T & 0 \end{bmatrix} \begin{pmatrix} d_k^x \\ d_k^\lambda \end{pmatrix} = - \begin{pmatrix} \nabla \varphi_{\mu_j}(x_k) + A_k \lambda_k \\ c(x_k) \end{pmatrix} \quad (**)$$

onde $\Sigma_k := X_k^{-1} Z_k$. Com isso, a componente z da direção de Newton é calculada por

$$d_k^z = \mu_j X_k^{-1} e - z_k - \Sigma_k d_k^x$$

Observe que o sistema acima é menor e sua matriz é simétrica (W_k e Σ_k são simétricas). Isso facilita a resolução, pois existem boas técnicas para sistemas simétricos (Cholesky etc).

→ Problema: se $A_k = \nabla c(x_k)$ não tiver posto completo (i.e., x_k não for regular), então a matriz do sistema $(**)$ pode ser singular, e uma solução pode não existir. Para contornar este problema, em

IPOPT resolve-se o sistema "perturbado"

$$\begin{bmatrix} W_k + \Sigma_k + \delta_w I & A_k \\ A_k^T & -\delta_c I \end{bmatrix} \begin{pmatrix} d_k^x \\ d_k^\lambda \end{pmatrix} = - \begin{pmatrix} \nabla \varphi_{\mu_j}(x_k) + A_k \lambda_k \\ c(x_k) \end{pmatrix},$$

onde $\delta_w, \delta_c \geq 0$ são calculados a cada iteração de IPOPT. Este sistema sempre possui solução para certos $\delta_w, \delta_c \geq 0$, mesmo que $A_k = \nabla c(x_k)$ não tenha posto completo.

Novo iterando do método

Calculados (x_k, λ_k, z_k) e a direção de Newton d_k , o novo iterando consiste em um passo a partir de (x_k, λ_k, z_k) na direção d_k :

$$x_{k+1} := x_k + \alpha_k d_k^x$$

$$\lambda_{k+1} := \lambda_k + \alpha_k d_k^\lambda$$

$$z_{k+1} := z_k + \alpha_k^z d_k^z.$$

onde os passos $\alpha_k, \alpha_k^z \in (0, 1]$ são calculados para manter positividade de x e z .

Sendo $x_k > 0$ e $z_k > 0$, o IPOPT garante os próximos $x_{k+1} > 0$ e $z_{k+1} > 0$ dando passos que mantêm uma fração de x_k e z_k :

$$\alpha_k^{\max} := \max \{ \alpha \in (0, 1] : x_k + \alpha d_k^x \geq (1 - \tau_j) x_k \}$$

$$\alpha_k^z := \max \{ \alpha \in (0, 1] : z_k + \alpha d_k^z \geq (1 - \tau_j) z_k \}$$

onde

$$\tau_j = \max\{\tau_{\min}, 1 - \mu_j\} \quad , \quad \tau_{\min} \in (0, 1) . \quad \begin{matrix} (\text{pense que}) \\ j=k \end{matrix}$$

Note que $(1 - \tau_k) x_k > 0$ e que

$1 - \tau_k \rightarrow \tau_{\min}$ à medida que $\mu_k \rightarrow 0^+$.

A ideia é permitir $x_k \approx 0$ apenas no fim do método, quando $\mu_k \approx 0$.

Nota: IPOPT implementa muitas outras estratégias, não vistas em aula, que o tornam muito eficaz numericamente. A referência do pacote explica as principais.

Uma delas diz respeito ao tratamento de problemas com "interior vazio", ou seja, aqueles em que não existe x tal que

$$x_L < x < x_U$$

$$\left(\begin{array}{l} \text{relativo ao problema original} \\ \min_{x \in \mathbb{R}^n} f(x) \\ \text{s.t. } c(x) = 0 \\ x_L \leq x \leq x_U \end{array} \right).$$

Antes de iniciar a resolução, por padrão IPOPT relaxa/alarga os limitantes x_L, x_U trocando-os da seguinte forma:

$$x_L^{(i)} \leftarrow x_L^{(i)} - \epsilon_{\text{tol}} \max\{1, |x_L^{(i)}|\}$$

onde $\epsilon_{\text{tol}} > 0$ é a precisão de parada. Note que o lado direito é menor que x_L . Estratégia similar é usada para aumentar x_U .

→ o exercício 4 da lista 2 discute essa estratégia

ANEXO

$$SP(\mu): \min_{x \in \mathbb{R}^n} \varphi_\mu(x) := f(x) - \mu \sum_{i=1}^n \ln(x^{(i)})$$

s.t. $c(x) = 0$

KKT do subproblema:

$$\nabla f(x) - \mu \begin{bmatrix} \frac{1}{x_1} \\ \vdots \\ \frac{1}{x_n} \end{bmatrix} + \nabla c(x) \lambda = 0,$$

$$c(x) = 0.$$

Definimos $\beta_i = \frac{\mu}{x_i}$, $\forall i$. Assim,

$$\nabla f(x) + \nabla c(x) \lambda - \beta = 0$$

$$c(x) = 0$$

$$x_i \beta_i - \mu = 0, \forall i$$

Notação: $X = \text{diag}(x_1, \dots, x_n) = \begin{bmatrix} x_1 & & 0 \\ & \ddots & \\ 0 & & x_n \end{bmatrix}$

$$Z = \text{diag}(\beta_1, \dots, \beta_n) = \begin{bmatrix} \beta_1 & & 0 \\ & \ddots & \\ 0 & & \beta_n \end{bmatrix}$$

Nota que $XZ e - \mu e = 0$, onde $e = [1, \dots, 1]^T$

o vetor de 1's, temos

$$XZc - \mu e = \begin{bmatrix} x_1 & \dots & 0 \\ \vdots & \ddots & 0 \\ 0 & x_m \end{bmatrix} \begin{bmatrix} z_1 & \dots & 0 \\ \vdots & \ddots & 0 \\ 0 & z_m \end{bmatrix} \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} - \mu \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix}$$

$$= \begin{bmatrix} x_1 & \dots & 0 \\ \vdots & \ddots & 0 \\ 0 & x_m & z_m \end{bmatrix} \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} - \mu \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix}$$

$$= \begin{bmatrix} x_1 z_1 \\ \vdots \\ x_m z_m \end{bmatrix} - \mu \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} = \begin{bmatrix} x_1 z_1 - \mu \\ \vdots \\ x_m z_m - \mu \end{bmatrix}$$

Assim, $XZc - \mu e = 0 \Leftrightarrow x_i z_i - \mu = 0, \forall i$.
Dai, KKT do subproblema fica

$$\boxed{\begin{array}{l} \nabla f(x) + \nabla c(x) \lambda - z = 0 \\ c(x) = 0 \\ XZc - \mu e = 0 \end{array}}$$

(sistema no artigo de referência)

No método, $x_k > 0$, $\forall k$. Consequentemente,
 $(z_k)_i = \frac{\mu_k}{(x_k)_i} > 0, \forall k, i$. ($\mu_k > 0$)

KKT do problema original

$$\min_{x \in \mathbb{R}^n} f(x)$$

s.t. $c(x) = 0$

$x \geq 0 \quad \leftarrow -x \leq 0$

$$\nabla f(x) + \nabla c(x) \lambda - z = 0$$

$$c(x) = 0$$

(z é multíp.
associado à
 $-x \leq 0$)

garantido
pelo método,

$$x \geq 0, z \geq 0$$

$$x_i z_i = 0, \forall i \quad (\mu = 0)$$

Passo de Newton para o subproblema

$$\min_{x \in \mathbb{R}^n} \varphi_\mu(x) := f(x) - \mu \sum_{i=1}^n \ln(x^{(i)})$$

s.t. $c(x) = 0$

KKT: $\nabla f(x) + \nabla c(x) \lambda - z = 0$

$$c(x) = 0$$

$$Xze - \mu e = 0$$

$$F(x, \lambda, z) = \begin{bmatrix} \nabla f(x) + \nabla c(x)\lambda - g \\ c(x) \\ x^T e - \mu e \end{bmatrix}$$

Newton: $(x^{k+1}, \lambda^{k+1}, z^{k+1}) = (x^k, \lambda^k, z^k) + \alpha d^k$

onde d^k é solução do sistema

$$F'(x^k, \lambda^k, z^k) d = -F(x^k, \lambda^k, z^k)$$

$$F'(x, \lambda, z) = \begin{bmatrix} \nabla^2 f(x) + \sum_{i=1}^m \nabla^2 c_i(x) \lambda_i & \nabla c(x) & -I \\ Z & O & O \\ A = \nabla c(x) & X \end{bmatrix}$$

(matriz do sistema no artigo de referência)

Executando pacote IPOPT em um exemplo

```
julia> using NLPModelsIpopt
```

```
julia> include("prob.jl")
```

```
julia> println(P)
Min  $(x[1] - 2.0)^2 + (x[2] - 1.0)^2$ 
Subject to
 $x[1] + x[2] \leq 2.0$ 
 $x[1] \geq -10.0$ 
 $x[2] \geq -10.0$ 
 $x[1] \leq 10.0$ 
 $x[2] \leq 10.0$ 
 $(x[1]^2 - x[2]) - 0.0 \leq 0$ 
```

minimizar $f(x) = (x_1 - 2)^2 + (x_2 - 1)^2$

sujeito a $g_1(x) = x_1 + x_2 - 2 \leq 0$ ✓

$g_2(x) = x_1^2 - x_2 \leq 0$. ✓

Minimizando: $x^* = (1, 1)$, $f(x^*) = 1$.

```
julia> saída = ipopt(nlp, tol=1e-10)
```

iter	objective	$\ c(x)\ _\infty$	F.O.	$\ d\ $ (direção de Newton)
0	1.0000000e+00	0.00e+00	2.94e-01	-1.0 0.00e+00
1	1.1438333e+00	0.00e+00	2.41e-03	-1.0 9.28e-02
2	1.0467454e+00	0.00e+00	3.86e-03	-1.7 6.90e-02
3	1.0018560e+00	0.00e+00	6.79e-04	-3.8 3.46e-02
4	1.0000089e+00	0.00e+00	1.92e-07	-5.7 2.27e-03
5	9.9999999e-01	0.00e+00	2.21e-12	-8.6 1.16e-05

Number of Iterations....: 5

$\log(\mu)$

parâmetro α .

	(scaled)	(unscaled)
Objective.....	9.999998516736233e-01	9.999998516736233e-01
Dual infeasibility.....	2.2134336861702505e-12	2.2134336861702505e-12
Constraint violation.....	0.0000000000000000e+00	0.0000000000000000e+00
Complementarity.....	2.6740268467060290e-09	2.6740268467060290e-09
Overall NLP error.....	2.6740268467060290e-09	2.6740268467060290e-09

F.O. ←

	(scaled)	(unscaled)
Objective.....	9.999998516736233e-01	9.999998516736233e-01
Dual infeasibility.....	2.2134336861702505e-12	2.2134336861702505e-12
Constraint violation.....	0.0000000000000000e+00	0.0000000000000000e+00
Complementarity.....	2.6740268467060290e-09	2.6740268467060290e-09
Overall NLP error.....	2.6740268467060290e-09	2.6740268467060290e-09

$\|x - \bar{x}\|_\infty$

$E_0(x, \lambda, z)$

$\|c(x)\|_\infty$

$\|\nabla f(x) + \nabla c(x)x - z\|_\infty$

Escalonamento do problema (saída "scaled")

$$\begin{array}{ll} \min & w_f f(x) \\ \text{s.a.} & w_1 c_1(x) = 0 \\ & w_2 c_2(x) = 0 \\ & \vdots \\ & w_m c_m(x) = 0 \end{array}$$

$$10^6 x_1 + 10^{10} x_2 = 0$$

$\nabla: \begin{bmatrix} 10^6 \\ 10^{10} \end{bmatrix}$

$$x \geq 0$$

$$x_1 - 0,01x_2 = 0$$

$\nabla: \begin{bmatrix} 1 \\ -0,01 \end{bmatrix}$

$$\nabla f + \underbrace{\nabla c_1 \lambda_1}_{\gg 1} + \underbrace{\nabla c_2 \lambda_2}_{\ll 1} \cdots - z = 0$$

w_f, w_1, \dots, w_m : fatores de escalonamento,
 iriam rescrever o problema
 ≥ 0

tentando colocar os dados

na mesma magnitude.

Suponha que queremos $\|\nabla f + \nabla c(x)\lambda - z\|_\infty \leq 10^{-6}$.
 Se escalamos o problema, passamos a testar

$$\|w_f \nabla f + w \nabla c(x)\lambda - z\|_\infty \leq 10^{-6}. \quad \neq$$

```
julia> saida.objective  
0.999999800181822
```

```
julia> saida.solution  
2-element Vector{Float64}:  
1.000000009990909  
1.0000000099954545
```