



Programação Não Linear

No Capítulo 1 vimos

Hipóteses fundamentais de PL:

H1) **Proporcionalidade**: a contribuição de cada atividade para o valor da função objetivo, bem como para o primeiro membro das restrições, é **proporcional** ao nível da atividade

(a contribuição de cada variável para o valor da função objetivo, bem como para o primeiro membro das restrições, é proporcional ao valor da variável)

H2) **Aditividade**: a contribuição de cada atividade para o valor da função objetivo, bem como para o primeiro membro das restrições, é **independente** da contribuição das restantes

H3) **Divisibilidade**: cada variável pode tomar qualquer valor

H4) **Certeza**: todos os valores dos parâmetros são conhecidos



Em PL todas as funções envolvidas são lineares.

Muitos problemas práticos correspondem a esse modelo, mas outros não.

Em Economia, a não linearidade é a regra e não a exceção (por exemplo, Baumeol, W.J., Bushnell, R.C., 'Error produced by linearization in Mathematical Programming, v35, p 447-471, 1967, 'Econometrica')



Problema PNL

$$\begin{array}{ll} \max & z = f(\mathbf{x}) \\ \text{s. a} & \begin{cases} g_i(\mathbf{x}) \leq b_i, & i = 1, \dots, m \\ \mathbf{x} \geq \mathbf{0} \end{cases} \end{array}$$

Obs: diferentes características de f e g_i

=>

diferentes tipos de problemas de PNL

=>

diferentes algoritmos de resolução

Obs: Para alguns destes problemas, mesmo a resolução de pequenos problemas é muito difícil



Tipos de Problemas de PNL

- Otimização sem restrições
- Otimização com restrições lineares
 - Programação Quadrática
(f.o. quadrática, restrições lineares;
Bons algoritmos se max f concava ou min f convexa)
 - ...
- Programação Convexa
(max $f(x)$ concava e todas $g_i(x)$ convexas)
- Programação Separável
(todas as fçs são separáveis,
 $f(x)=f_1(x_1)+f_2(x_2)+\dots+f_m(x_m)$
 $g_i(x)=g_{i1}(x_1)+g_{i2}(x_2)+\dots+g_{im}(x_m)$)
(...)



Exemplo protótipo: variante

$$\begin{aligned} \text{Max } z &= 10x_1 - x_1^2 + 12x_2 - x_2^2 \\ \text{s.a } &\begin{cases} x_1 \leq 4 \\ 2x_2 \leq 12 \\ 3x_1 + 2x_2 \leq 18 \\ x_1 \geq 0, x_2 \geq 0 \end{cases} \end{aligned}$$

Resolução gráfica

Problema de Programação Quadrática

em que se pretende maximizar uma função côncava



Exemplo de Aplicação da PNL à Seleção de Investimentos (§8.2, HHSS 2008)

Os gestores profissionais de grandes carteiras de títulos sabem que os investidores estão preocupados com o **ganho esperado** e com o **risco associado** aos seus investimentos.

É prática comum decidir

min $z =$ **risco** do investimento
s.a **ganho** esperado \geq nível **mínimo** aceitável

O risco dum título costuma medir-se pela sua variação (variância) e o risco de adquirir 2 títulos costuma medir-se pela variação conjunta (covariância).



Vejam os um exemplo numérico com apenas 3 títulos e onde se considera que o ganho mínimo aceitável é de 18% do investimento total.

Sejam

$S_j = \%$ do investimento dedicada ao título j , $j=1,2,3$

e considerem-se os seguintes dados:

Título	Ganho esperado	Risco (desvio padrão)
1	21%	25%
2	30%	45%
3	8%	5%

Par de Títulos	Risco conjunto (covariância)
1 e 2	0,04
1 e 3	-0,005
2 e 3	-0,01



Então,

$$\min \quad z = (0,25S_1)^2 + (0,45S_2)^2 + (0,05S_3)^2 + \\ 2(0,04)S_1S_2 + 2(-0,005)S_1S_3 + 2(-0,01)S_2S_3$$

$$s.a \quad \begin{cases} 21S_1 + 30S_2 + 8S_3 \geq 18 \\ S_1 + S_2 + S_3 = 1, \\ S_1, S_2, S_3 \geq 0. \end{cases}$$



Condições de Karush-Kuhn-Tucker (KKT) (otimização com restrições)

Sejam f e g_i diferenciáveis e satisfazendo certas condições de regularidade.

Considere-se

$$(PNL) \quad \begin{array}{ll} \max & z = f(\mathbf{x}) \\ \text{s. a} & \begin{cases} g_i(\mathbf{x}) \leq b_i, \quad i = 1, \dots, m \\ \mathbf{x} \geq \mathbf{0} \end{cases} \end{array}$$

Teor: Se \mathbf{x}^* é s.o. do (PNL) então existem escalares u_1, u_2, \dots, u_m tais que

$$(KKT) \quad \left\{ \begin{array}{l} \frac{df}{dx_j} - \sum_{i=1}^m u_i \frac{dg_i}{dx_j} \leq 0, \quad j = 1, \dots, n \\ x_j^* \left(\frac{df}{dx_j} - \sum_{i=1}^m u_i \frac{dg_i}{dx_j} \right) = 0, \quad j = 1, \dots, n \\ g_i(\mathbf{x}^*) - b_i \leq 0, \quad i = 1, \dots, m \\ u_i (g_i(\mathbf{x}^*) - b_i) = 0, \quad i = 1, \dots, m \\ x_j^* \geq 0, \quad u_i \geq 0, \quad i = 1, \dots, m, \quad j = 1, \dots, n \end{array} \right.$$

Teor: Se f for uma função concava e g_i funções convexas, $i = 1, \dots, m$, (isto é, PPC), então

\mathbf{x} é s.o. do (PNL) se e só se existe \mathbf{u} tal que (\mathbf{u}, \mathbf{x}) verificam KKT.

