

**INSTITUTO SUPERIOR DE GESTÃO**

**INVESTIGAÇÃO OPERACIONAL**

**PROGRAMAÇÃO NÃO LINEAR**

***(Exercícios)***

( Texto revisto para o ano lectivo 2001-2002 )

António Carlos Morais da Silva  
Professor de I.O. / ISG

## **Recomendações**

### **1. Fazer dez exercícios ou o mesmo exercício 10 vezes ?**

Em regra obtém-se melhor rendimento executando várias vezes o mesmo exercício, com critério e sentido da descoberta, do que resolvendo vários exercícios com o objectivo enganador de “acertar na solução”.

### **2. Exercício feito, tarefa pronta ?**

Rever criticamente a “história” da execução de um exercício melhora substancialmente a capacidade pessoal de identificação dos problemas e de arquitectar o plano de aplicação do “ferramental” técnico necessário (o quê ; quando ; como).

A Programação Matemática apela ao “engenho e arte” de quem quer mesmo utilizá-la.

### **3. Sim ou não ao software da disciplina ?**

O “passado escolar” ensina que o recurso intensivo ao software académico, desenhado especificamente para apoio do ensino desta disciplina, traduz-se rapidamente na melhoria do rendimento porque além de permitir exercitar a curiosidade intelectual (vertente fundamental) garante a obtenção rápida de respostas rigorosas e detalhadas para exercícios propostos pelo professor ou gizados pelo próprio aluno (aumento da produtividade).

**1. Métodos da Bisseção e do Gradiente**

- 1.1. Calcular o Máximo livre de  $f(x) = -2x^6 - 3x^4 + 12x$  pelo Método da Bisseção (tolerância = 0.01)
- 1.2. Calcular o Máximo livre de  $f(x) = -0.25x^4 + x^3 - 2x^2 + 2x$  pelo Método da Bisseção (tolerância = 0.02)
- 1.3. Calcular o Máximo livre de  $f(x_1, x_2) = 4x_1 + 6x_2 - 2x_1^2 - 2x_1x_2 - 2x_2^2$  pelo Método do Gradiente
- 1.4. Calcular o Máximo livre de  $f(x_1, x_2) = 2x_1x_2 + 2x_2 - x_1^2 - 2x_2^2$  pelo Método do Gradiente.
- 1.5. Calcular o Máximo livre de  $f(x_1, x_2) = 8x_1 - x_1^2 - 12x_2 - 2x_2^2 + 2x_1x_2$  pelo Método do Gradiente.
- 1.6. Calcular o Mínimo livre de  $f(x_1, x_2) = x_1^2x_2^2 + 2x_1^2 + 2x_2^2 - 4x_1 + 4x_2$  pelo Método do Gradiente.
- 1.7. Elabore um fluxograma do Método da Bisseção.
- 1.8. Fundamente e descreva o Método do Gradiente.

## 2. *Método dos Multiplicadores de Lagrange*

2.1. Descrever o Método dos Multiplicadores de Lagrange à luz do respectivo Teorema.

2.2. Se  $(X, \lambda)$  são soluções das condições de Lagrange para um problema de PNL (maximização) só com restrições de igualdade, pode concluir-se que são todos pontos onde a função atinge o máximo ?

2.3. Calcular pelo Método dos Multiplicadores de Lagrange:

$$\begin{aligned} \text{Max } f(x_1, x_2) &= x_1 x_2 + 2x_1 \\ \text{s.a. } 4x_1 + 2x_2 &= 60 \end{aligned}$$

2.4. Deduza as condições de 1ª ordem para extremo de:

$$\begin{aligned} \text{Max } f(x) \\ \text{s.a. } x \geq 0 \end{aligned}$$

2.5. Usando o Método dos Multiplicadores de Lagrange deduza as condições de 1ª ordem para extremo de:

$$\begin{aligned} \text{Max } f(x) \\ \text{s.a. } g(x) \leq b \end{aligned}$$

2.6. Calcular pelo Método dos Multiplicadores de Lagrange:

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 5x_1 - 2x_1^2 + 3x_1 x_2 - 2x_2^2 \\ \text{s.a. } x_1 + x_2 &\leq 2 \end{aligned}$$

2.7. Calcular pelo Método dos Multiplicadores de Lagrange:

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 3x_1^2 + x_2^2 + 2x_1 x_2 + 6x_1 + 2x_2 \\ \text{s.a. } 2x_1 - x_2 &= 4 \end{aligned}$$

O ponto óptimo é extremo global da função ?

2.8. Calcular pelo Método dos Multiplicadores de Lagrange o extremo da função:

$$\begin{aligned} \text{Min } f(x_1, x_2) &= x_1 - x_2 \\ \text{s.a. } x_1^2 + x_2^2 &= 1 \end{aligned}$$

### 3. *Programação Não Linear (alguns conceitos fundamentais)*

- 3.1. Classifique e compare as soluções de modelos de PL e de PNL.
- 3.2. A solução óptima de um modelo de PNL pode ser atingida em ponto da fronteira do convexo de soluções ?
- 3.3. A solução óptima de um modelo de PNL pode ser atingida em ponto interior do convexo de soluções ?
- 3.4. Em PNL o espaço de solução pode não ser convexo ?
- 3.5. Partindo das respostas ás 4 questões anteriores, aponte as principais diferenças entre soluções de PL e PNL.
- 3.6. Considere o modelo de PNL:

$$\text{Max } f(x_1, x_2, \dots, x_n)$$

$$\text{s.a. } g_1(x_1, x_2, \dots, x_n) \quad (\leq, =, \geq) \quad b_1$$

$$g_2(x_1, x_2, \dots, x_n) \quad (\leq, =, \geq) \quad b_2$$

.....

$$g_m(x_1, x_2, \dots, x_n) \quad (\leq, =, \geq) \quad b_m$$

Admitindo que o espaço de soluções é convexo em que circunstâncias pode afirmar-se que um máximo local da função-objectivo é solução óptima do modelo de PNL?

- 3.7. Apresente a matriz Hessiana da função  $f = (x_1^3 + 2x_1x_2 + x_2^4)$
- 3.8. Considere a função não linear  $f(x_1, x_2, \dots, x_n)$  com segundas derivadas parciais contínuas no conjunto "S". Indique as condições a que deve obedecer a matriz Hessiana da função para poder concluir que esta é côncava.
- 3.9. Considere a função não linear  $f(x_1, x_2, \dots, x_n)$  com segundas derivadas parciais contínuas no conjunto "S". Indique as condições a que deve obedecer a matriz Hessiana da função para poder concluir que esta é convexa.
- 3.10. Uma empresa produz dois modelos  $M_1$  e  $M_2$  da mesma máquina.  
As funções de procura são as seguintes:  
modelo  $M_1$  :  $150 - 2p_1 - p_2$   
modelo  $M_2$  :  $200 - p_1 - 3p_2$   
em que  $p_1$  e  $p_2$  são os preços de venda de cada um dos modelos.  
Calcular os preços de venda que maximizam a receita.
- 3.11. Verificar se a função  $f = x_1^2 + x_2^2 + 2x_3^2 - x_1x_2 - x_2x_3 - x_1x_3$  é convexa.
- 3.12. Considere a função quadrática  $f(x_1, x_2) = 2x_1x_2 + 3x_2 - x_1^2 - x_2^2$
- a. Calcular o gradiente da função no ponto  $X_1 = (2, 3)^T$ .
- b. Sendo  $f = 8$  no ponto anterior, calcular o valor aproximado da função no ponto  $X_2 = (2.1, 3.2)^T$  com uma série de Taylor.

3.13. Considerar a função quadrática anterior.

Calcular o vector “V” resultante da diferença dos gradientes da função nos pontos  $X_1$  e  $X_2$  do problema anterior recorrendo exclusivamente à matriz hessiana da função.

3.14. Considere a função  $f(x_1, x_2) = 15x_1 + 30x_2 - 4x_1x_2 - 2x_1^2 - 4x_2^2$

a. Apresentar a função na forma quadrática.

4. **Condições de Karush-Kuhn-Tucker** (condições KKT)

4.1. Deduza as condições KKT a partir da função de Lagrange:

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 2x_1 + 3x_2 - x_1^2 - x_2^2 \\ \text{s.a. } 2x_1 + 2x_2 &\leq 4 \end{aligned}$$

4.2. Deduza as condições KKT a partir da função de Lagrange:

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 2x_1 + 3x_2 - x_1^2 - x_2^2 \\ \text{s.a. } 2x_1 + 2x_2 &= 4 \end{aligned}$$

4.3. Deduza as condições KKT a partir da função de Lagrange e calcule a solução óptima.

$$\begin{aligned} \text{Min } f(x_1, x_2) &= x_1^2 + 2x_1 + x_2^2 - 4x_2 + 5 \\ \text{s.a. } x_1 - 2 &\leq 0 \\ x_2 - 1 &\leq 0 \\ x_1, x_2 &\geq 0 \end{aligned}$$

4.4. Considere o seguinte problema de programação não linear :


$$\begin{aligned} \text{Max } f(x_1, x_2) &= \ln(x_1 + 1) + x_2 \\ \text{s.a. } x_1^2 + x_2^2 &= 1 \\ x_1, x_2 &\geq 0 \end{aligned}$$

- Estabeleça as condições KKT
- Calcule a solução óptima.

4.5. Considere o seguinte problema de programação não linear :

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 2x_1 + 3x_2 - x_1^2 - x_2^2 \\ \text{s.a. } 2x_1 + 2x_2 &\leq 4 \\ x_1, x_2 &\geq 0 \end{aligned}$$


- Demonstre que o problema é de programação convexa.
- Calcule a solução óptima pelo Método do Simplex modificado por Wolfe.
- Verifique geometricamente a solução calculada (a figura apresenta a projecção horizontal das curvas de nível da função).



4.6. Considere o seguinte problema de programação não linear :

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 15x_1 + 30x_2 + 4x_1x_2 - 2x_1^2 - 4x_2^2 \\ \text{s.a. } x_1 + 2x_2 &\leq 30 \\ x_1, x_2 &\geq 0 \end{aligned}$$

- Demonstre que o problema é de programação convexa.
- Calcule a solução óptima pelo Método do Simplex modificado por Wolfe.
- Verifique geometricamente a solução calculada (a figura apresenta a projecção horizontal das curvas de nível da função).



4.7. Considere o seguinte problema de programação não linear :

$$\begin{aligned} \text{Max } f(x_1, x_2) &= \ln(x_1 + 1) - x_2^2 \\ \text{s.a. } x_1 + 2x_2 &\leq 3 \\ x_1, x_2 &\geq 0 \end{aligned}$$

- Demonstre que o problema é de programação convexa.
- Estabeleça as condições KKT.
- Demonstre que o ponto de coordenadas (3,0) é o ponto onde  $f(x_1, x_2)$  atinge o máximo.

4.8. Considere o seguinte problema de programação convexa :

$$\begin{aligned} \text{Min } f(x_1, x_2, x_3) &= 2x_1 + x_2^3 + x_3^2 \\ \text{s.a. } x_1^2 + 2x_2^2 + x_3^2 &\geq 4 \\ x_j &\geq 0 \quad (j=1 \text{ a } 3) \end{aligned}$$

- Recorrendo às condições KKT verifique se  $x_1=1, x_2=1, x_3=1$  pode ser a solução óptima.




4.9. Descrever a solução óptima de  $\text{Max } f(x)$  para  $a \leq x \leq b$  recorrendo às condições KKT sabendo que  $f'(x)$  existe para qualquer valor no intervalo  $[a, b]$ .

4.10. Considere o seguinte problema de programação não linear :

$$\begin{aligned} \text{Min } f(x_1, x_2) &= (x_1 - 1)^2 + (x_2 - 2)^2 - 3(x_1 + x_2) \\ \text{s.a. } &4x_1 + x_2 \leq 20 \\ &x_1 + 4x_2 \leq 20 \\ &x_1, x_2 \geq 0 \end{aligned}$$

a. Sabendo que o ponto óptimo  $X^*$  não pertence à fronteira do convexo de soluções, calcule a solução óptima com base nas condições KKT.

b. Verifique geometricamente a solução calculada (a figura apresenta a projecção horizontal das curvas de nível da função).



4.11. Considere o seguinte problema de programação convexa :

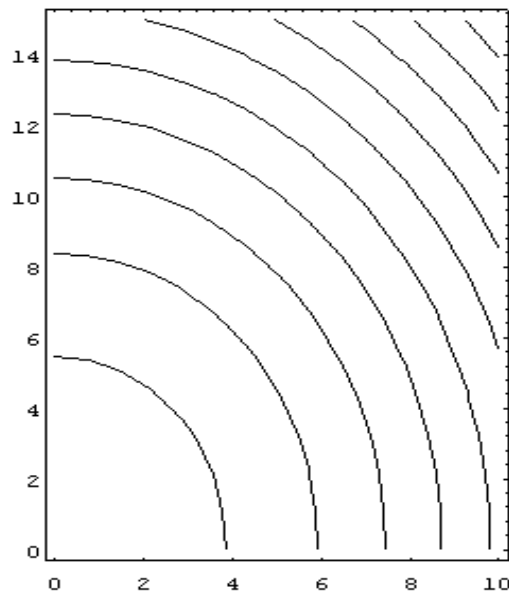
$$\begin{aligned} \text{Min } f(x_1, x_2) &= x_1^2 + 2x_1 + 2x_1x_2 + 4x_2^2 \\ \text{s.a. } &2x_1 + x_2 \geq 10 \\ &x_1 + 2x_2 \geq 10 \\ &x_1, x_2 \geq 0 \end{aligned}$$

a. Calcule a solução óptima pelo Método do Simplex modificado por Wolfe.

4.12. Considere o seguinte problema de programação não linear :

$$\begin{aligned} \text{Min } f(x_1, x_2) &= 2x_1^2 + x_2^2 \\ \text{s.a. } x_1 + x_2 &= 10 \\ x_1, x_2 &\geq 0 \end{aligned}$$

- Demonstre que o ponto de coordenadas  $(10/3, 20/3)$  é o ponto onde  $f(x_1, x_2)$  atinge o mínimo.
- Calcule a solução ótima pelo Método do Simplex modificado por Wolfe.
- Verifique geometricamente a solução calculada (a figura apresenta a projecção horizontal das curvas de nível da função).



4.13. Considere o seguinte problema de PNL :

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 3x_1 + x_2 \\ \text{s.a. } x_1^2 + x_2^2 &\leq 5 \\ x_1 - x_2 &\leq 1 \end{aligned}$$

- Calcule a solução ótima recorrendo exclusivamente às condições KKT.

4.14. Considere o seguinte problema de PNL :

$$\begin{aligned} \text{Max } f(x) &= x_1 \\ \text{s.a. } x_2 - (1 - x_1)^3 &\leq 0 \\ x_1, x_2 &\geq 0 \end{aligned}$$

- Verifique que as condições KKT “**falham**” no ponto ótimo e explique porquê.

- 4.15. Descreva o Método de Lemke (utilizado na Programação Quadrática.).
- 4.16. Calcule a solução ótima do exercício 4.5 utilizando o Método de Lemke.
- 4.17. Calcule a solução ótima do exercício 4.6 utilizando o Método de Lemke.
- 4.18. Calcule a solução ótima do exercício 4.11 utilizando o Método de Lemke.

## 5. *Métodos de Frank-Wolfe e SUMT*

5.1. Descreva e fundamente o método de Frank-Wolfe (direcções viáveis).

5.2. Considere o seguinte problema de programação convexa :

$$\begin{aligned} \text{Min } f(x_1, x_2) &= x_1^2 - 6x_1 + x_2^3 - 3x_2 \\ \text{s.a. } x_1 + x_2 &\leq 1 \\ x_1, x_2 &\geq 0 \end{aligned}$$

a. Determine a solução óptima pelo método de Frank-Wolfe.

5.3. Considere o seguinte problema de programação não linear:

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 15x_1 + 30x_2 + 4x_1x_2 - 2x_1^2 - 4x_2^2 \\ \text{s.a. } x_1 + 2x_2 &\leq 30 \\ x_1, x_2 &\geq 0 \end{aligned}$$

a. Considere  $x_1=5$  e  $x_2=5$  como ponto tentativa inicial. Efectue 3 iterações do método de Frank-Wolfe.

5.4. Considere o seguinte problema de programação não linear :

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 32x_1 - x_1^4 + 8x_2 - x_2^2 \\ \text{s.a. } 3x_1 + x_2 &\leq 7 \\ x_1 - x_2 &\leq 1 \\ x_1, x_2 &\geq 0 \end{aligned}$$

a. Calcule a solução óptima recorrendo ao método de Frank-Wolfe, utilizando o programa distribuído (BL.EXE).

5.5. Descreva e fundamente o método SUMT (Sequential Unrestricted Minimization Technique).

5.6. Considere o seguinte problema de programação não linear :

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 32x_1 - x_1^4 + 8x_2 - x_2^2 \\ \text{s.a. } 3x_1 + x_2 &\leq 7 \\ x_1 - x_2 &\leq 1 \\ x_1, x_2 &\geq 0 \end{aligned}$$

a. Calcule a solução óptima recorrendo ao método SUMT, utilizando o programa distribuído (BL.EXE).

## 6. Modelos de Programação Não Linear

- 6.1. Uma empresa pretende iniciar a produção e venda de dois novos computadores A e B com preços de venda  $p_1$  e  $p_2$  respectivamente.

A relação entre o número de computadores a produzir do tipo A e os preços de venda é a seguinte:

$$x_1 = 4000 - 10 p_1 + p_2$$

Notar que se o preço de venda  $p_1$  sobe 1 unidade o total da produção reduz-se em 10 computadores; se no computador do tipo B aumenta o preço de venda em 1 unidade, tal conduz à produção de mais um computador do tipo A.

A relação entre o número de computadores a produzir do tipo B e os preços de venda é a seguinte:

$$x_2 = 2000 - 9p_2 + 0.8 p_1$$

Das disponibilidades escassas indicam-se as necessidades para cada um dos tipos de aparelho:

	Mão de obra (horas)	Chips
Tipo A	2	3
Tipo B	3	1
Disponibilidade	5000	4500

- Calcular o Plano Ótimo de Produção ( e respectivos preços de venda) recorrendo às condições KKT.
  - Indicar o contributo interno de 1 hora adicional de mão de obra.
  - Se a empresa decidir não produzir e vender o stock de chips qual o preço a praticar ? Justifique.
- 6.2. Uma empresa pretende iniciar a produção e venda de três novos tipos de secretária A, B e C com preços de venda respectivamente de  $p_1$ ,  $p_2$  e  $p_3$  para o que pode disponibilizar, mensalmente, 150 horas/máquina e 280 horas de mão de obra.

As relações entre nível da produção e preços de venda são as seguintes:

- nível da produção de A =  $18 - p_1$
- nível da produção de B =  $9 + 1/3 p_1 - p_2$
- nível da produção de C =  $13 - p_3$

Os consumos por unidade produzida são os seguintes:

Tipo	Horas/máquina	Mão de obra (horas)
A	0.3	0.4
B	0.4	1
C	0.6	0.7

Os preços unitários de produção são, respectivamente, 5, 12 e 9 u.m.

- Apresentar o modelo de PNL para calcular o Plano Ótimo de Produção.
- 6.3. Uma empresa tem disponíveis “T” horas de trabalho e “C” unidades monetárias sendo seu objectivo produzir  $T^{2/3} \cdot C^{1/3}$  máquinas.
- O custo a suportar por hora de trabalho é de 2 u.m. sendo de 1 u.m. por cada unidade de capital aplicado.
- Disponibilizando 30 u.m. para a produção quantas máquinas podem ser produzidas?

- 6.4. Considere-se que no problema anterior se pretende produzir apenas 6 máquinas.  
Calcular o capital mínimo a disponibilizar para a produção.
- 6.5. Uma empresa produz a mesma máquina em Portugal e Espanha.  
Se aplicar  $x_1$  unidades monetárias na promoção em Portugal a previsão de vendas é de  $6x_1^{1/2}$ .  
Se aplicar  $x_2$  unidades monetárias na promoção em Espanha a previsão de vendas é de  $4x_2^{1/2}$ .  
O lucro unitário é de 5 u.m. nos dois países.
- Dispondo de 100 u.m. para promoção como pode a empresa maximizar o lucro?
  - Qual é o aumento de lucro associado ao aumento de 1 u.m. para promoção?
- 6.6. Uma empresa tem 2 clientes para o mesmo produto "A".  
Se produzir  $x_1$  unidades para o cliente X, o preço de venda é de  $70-4x_1$  u.m. ; se produzir  $x_2$  unidades para o cliente Y, o preço de venda é de  $150-15x_2$  u.m..  
Para produzir P unidades tem um custo de  $100 + 15P$  ( $P>0$ ).  
Quantas unidades produzir para cada um dos clientes ?

**INSTITUTO SUPERIOR DE GESTÃO**

**INVESTIGAÇÃO OPERACIONAL**

**PROGRAMAÇÃO NÃO LINEAR**

***(Soluções dos exercícios)***

( Texto revisto para o ano lectivo 2001-2002 )

António Carlos Morais da Silva  
Professor de I.O. / ISG

1.

1.1.

FUNÇÃO	
Coeficientes	
Var.	Coef.
$x^6$	-2
$x^5$	
$x^4$	-3
$x^3$	
$x^2$	
$x$	12
Const.	

Tolerância	
0,01	
Pontos Tentativa	
A	B
0,00	2,00

Controlo da Tentativa Inicial

OK. df/dx em A é Positiva	12
	OK
OK. df/dx em B é Negativa	-468
	OK


SOLUÇÃO	
f(x) = 7,8838682	
EXTREMO ÓPTIMO	
ABCISSA	0,8281250
	0,8359375
	0,8437500

ÁREA DE CÁLCULO			Esq(Dir)	Dir(Esq)
K	(df/dx)M	Lado de	Ponto "a"	Ponto "b"
			0,000000	2,000000
1	-12,00	b	0,000000	1,000000
2	10,13	a	0,500000	1,000000
3	4,09	a	0,750000	1,000000
4	-2,19	b	0,750000	0,875000
5	1,31	a	0,812500	0,875000
6	-0,34	b	0,812500	0,843750
7	0,51	a	0,828125	0,843750

Médio		
M	OK ?	Valor f( M )
1,0000000	Não	7,0000000
0,5000000	Não	5,7812500
0,7500000	Não	7,6948242
0,8750000	Não	7,8438644
0,8125000	Não	7,8671807
0,8437500	Não	7,8829082
0,8281250	Não	7,8815042
0,8359375	Sim	7,8838682

Book Bissec.xls. Sheet Sol. 1.1

Analise o gráfico da função:





1.2.

Método da Bissecção		
FUNÇÃO		
Coeficientes		
Var.	Coef.	
$x^6$		
$x^5$		
$x^4$	-0,25	
$x^3$	1	
$x^2$	-2	
x	2	
Const.		

Tolerância	0,02
------------	------

Pontos Tentativa	
A	B
0,00	2,40

Controlo da Tentativa Inicial	
OK. df/dx em A é Positiva	2,00
	OK
OK. df/dx em B é Negativa	-4,14
	OK


SOLUÇÃO	
f(x) = 0,7499805	
EXTREMO OPTIMO	
ABCISSA	0,9750000
	0,9937500
	1,0125000

ÁREA DE CÁLCULO			Esq(Dir)	Dir(Esq)
K	(df/dx)M	Lado de	Ponto "a"	Ponto "b"
1	-0,21	b	0,000000	2,400000
2	0,46	a	0,000000	1,200000
3	0,10	a	0,600000	1,200000
4	-0,05	b	0,900000	1,050000
5	0,03	a	0,975000	1,050000
6	-0,01	b	0,975000	1,012500

Médio	OK ?	Valor f( M )
1,2000000	Não	0,7296000
0,6000000	Não	0,6636000
0,9000000	Não	0,7449750
1,0500000	Não	0,7487484
0,9750000	Não	0,7496874
1,0125000	Não	0,7499219
0,9937500	Sim	0,7499805

Book Bissec.xls Sheet Sol. 1.2

Analise o gráfico da função:



1.3. Considerando como ponto tentativa inicial  $X_0 = (1,1)$  e a tolerância de 0.01, da aplicação do Método do Gradiente resulta o seguinte:

Quadro 1 - Determinação das coordenadas de  $X_{k+1}$  em ordem ao parâmetro “t”

Iter.	Ponto Tentativa $X_0$		Gradiente em $X_0$		Abcissa de $X_{k+1}$		Ordenada de $X_{k+1}$	
	$x_1$	$x_2$	$x_1$	$x_2$	a	bt	c	dt
1	1.00000	1.00000	-2.00000	0.00000	1.00000	-2.00000	1.00000	0.00000
2	0.50000	1.00000	0.00000	1.00000	0.50000	0.00000	1.00000	1.00000
3	0.50000	1.25000	-0.50000	0.00000	0.50000	-0.50000	1.25000	0.00000
4	0.37549	1.25000	-0.00195	0.24902	0.37549	-0.00195	1.25000	0.24902
5	0.37500	1.31262	-0.12523	-0.00048	0.37500	-0.12523	1.31262	-0.00048
6	0.34385	1.31250	-0.00042	0.06228	0.34385	-0.00042	1.31250	0.06228
7	0.34375	1.32815	-0.03129	-0.00009	0.34375	-0.03129	1.32815	-0.00009
8	0.33596	1.32813	-0.00008	0.01558	0.33596	-0.00008	1.32813	0.01558
9	0.33594	1.33203	-0.00780	0.00002				

Book Gradient.xls Sheet 1.3

Na iteração 9 as derivadas parciais de  $f(x_1, x_2)$  têm valor absoluto inferior à tolerância 0.01 (termina processo iterativo).

**Solução :**  $x_1 = 0.33594$  ;  $x_2 = 1.33203$  ;  $f(x_1, x_2) = 4.6663$

*Nota:* A solução exacta é  $x_1 = 1/3$  ;  $x_2 = 4/3$  ;  $f(x_1, x_2) = 14/3$ .



Para cada uma das iterações foi organizada a função  $f(x_1, x_2)$  com  $x_1$  e  $x_2$  parametrizados e calculado o seu máximo. Os resultados obtidos são apresentados no quadro seguinte:

Quadro 2 - Determinação do valor óptimo “t\*” onde  $f(x_1, x_2)$  atinge o máximo

Iter.	$t^2$	t	Constante	t* (óptimo)	Valor de $f(x_1, x_2)$
1	-8.000	4.000	4.0000	0.251	4.00000
2	-2.000	1.000	4.5000	0.251	4.50000
3	-0.500	0.250	4.6250	0.250	4.62500
4	-0.123	0.062	4.6562	0.252	4.65625
5	-0.031	0.016	4.6641	0.249	4.66406
6	-0.008	0.004	4.6660	0.252	4.66602
7	-0.002	0.001	4.6665	0.250	4.66650
8	0.000	0.000	4.6666	0.251	4.66663

Book Gradient.xls Sheet 1.3

Nas figuras seguintes apresentam-se o gráfico da função e a projecção horizontal das curvas de nível da função.



1.4. Considerando como ponto tentativa inicial  $X_0 = (0.1,0.1)$  e a tolerância de 0.01, da aplicação do Método do Gradiente resulta o seguinte:

Quadro 1 - Determinação das coordenadas de  $X_{k+1}$  em ordem ao parâmetro “t”

Iter.	Ponto Tentativa $X_0$		Gradiente em $X_0$		Abcissa de $X_{k+1}$		Ordenada de $X_{k+1}$	
	$x_1$	$x_2$	$x_1$	$x_2$	a	bt	c	dt
1	0.10000	0.10000	0.00000	1.80000	0.10000	0.00000	0.10000	1.80000
2	0.10000	0.27719	0.35438	1.09125	0.10000	0.35438	0.27719	1.09125
3	0.19784	0.57849	0.76128	0.08174	0.19784	0.76128	0.57849	0.08174
4	0.63738	0.62568	-0.02339	0.77203	0.63738	-0.02339	0.62568	0.77203
5	0.63175	0.81154	0.35959	0.01733	0.63175	0.35959	0.81154	0.01733
6	0.83351	0.82126	-0.02450	0.38197	0.83351	-0.02450	0.82126	0.38197
7	0.82785	0.90949	0.16327	0.01774	0.82785	0.16327	0.90949	0.01774
8	0.93952	0.92163	-0.03578	0.19253	0.93952	-0.03578	0.92163	0.19253
9	0.93230	0.96044	0.05628	0.02284	0.93230	0.05628	0.96044	0.02284
10	0.98625	0.98234	-0.00782	0.04315	0.98625	-0.00782	0.98234	0.04315
11	0.98469	0.99095	0.01252	0.00559	0.98469	0.01252	0.99095	0.00559
12	0.99707	0.99647	-0.00119	0.00824				

Book Gradient.xls Sheet 1.4

Na iteração 12 as derivadas parciais de  $f(x_1, x_2)$  têm valor absoluto inferior à tolerância 0.01 (termina processo iterativo)

**Solução :  $x_1 = 0.99707$  ;  $x_2 = 0.99647$  ;  $f(x_1, x_2) = 0.99988$**

*Nota* : A solução exacta é  $x_1 = 1$  ;  $x_2 = 1$  ;  $f(x_1, x_2) = 1$ .



Para cada uma das iterações foi organizada a função  $f(x_1, x_2)$  com  $x_1$  e  $x_2$  parametrizados e calculado o seu máximo. Os resultados obtidos são apresentados no quadro seguinte.

Quadro 2 - Determinação do valor óptimo “t\*” onde  $f(x_1, x_2)$  atinge o máximo

Iter.	$t^2$	t	Constante	$t^*$ (óptimo)	Valor de $f(x_1, x_2)$
1	-6.480	3.240	0.190	0.099	0.19000
2	-1.733	1.316	0.446	0.277	0.44615
3	-0.467	0.586	0.677	0.578	0.67744
4	-1.233	0.597	0.860	0.241	0.85975
5	-0.115	0.130	0.932	0.562	0.93216
6	-0.316	0.146	0.968	0.232	0.96790
7	-0.020	0.027	0.985	0.685	0.98514
8	-0.095	0.038	0.994	0.203	0.99354
9	-0.001	0.004	0.998	0.960	0.99764
10	-0.005	0.002	1.000	0.200	0.99967
11	0.000	0.000	1.000	0.990	0.99988

Book Gradient.xls Sheet 1.4

Nas figuras seguintes apresentam-se o gráfico da função e a projecção horizontal das curvas de nível da função.



- 1.5. Considerando como ponto tentativa inicial  $X_0 = (0,1,0,1)$  e a tolerância de 0,01, da aplicação do Método do Gradiente resulta o seguinte:

Quadro 1 - Determinação das coordenadas de  $X_{k+1}$  em ordem ao parâmetro “t”

It	Ponto Tentativa $X_0$		Gradiente em $X_0$		Abcissa de $X_{k+1}$		Ordenada de $X_{k+1}$	
	$x_1$	$x_2$	$x_1$	$x_2$	a	bt	c	dt
1	0,10000	0,10000	8,00000	-12,20000	0,10000	8,00000	0,10000	-12,20000
2	1,61563	-2,21133	0,34609	0,07656	1,61563	0,34609	-2,21133	0,07656
3	1,70891	-2,19069	0,20080	0,18058	1,70891	0,20080	-2,19069	0,18058
4	1,73636	-2,16600	0,19527	0,13673	1,73636	0,19527	-2,16600	0,13673
5	1,76458	-2,14624	0,17835	0,11413	1,76458	0,17835	-2,14624	0,11413
6	1,79036	-2,12975	0,15979	0,09970	1,79036	0,15979	-2,12975	0,09970
7	1,81346	-2,11533	0,14242	0,08825	1,81346	0,14242	-2,11533	0,08825
8	1,83376	-2,10275	0,12697	0,07853	1,83376	0,12697	-2,10275	0,07853
9	1,85162	-2,09171	0,11335	0,07007	1,85162	0,11335	-2,09171	0,07007
10	1,86734	-2,08199	0,10135	0,06264	1,86734	0,10135	-2,08199	0,06264
11	1,88119	-2,07343	0,09076	0,05609	1,88119	0,09076	-2,07343	0,05609
12	1,89342	-2,06587	0,08142	0,05032	1,89342	0,08142	-2,06587	0,05032
13	1,90439	-2,05909	0,07304	0,04514	1,90439	0,07304	-2,05909	0,04514
14	1,91409	-2,05309	0,06563	0,04056	1,91409	0,06563	-2,05309	0,04056
15	1,92281	-2,04771	0,05897	0,03644	1,92281	0,05897	-2,04771	0,03644
16	1,93053	-2,04294	0,05307	0,03280	1,93053	0,05307	-2,04294	0,03280
17	1,93747	-2,03864	0,04777	0,02952	1,93747	0,04777	-2,03864	0,02952
18	1,94372	-2,03478	0,04299	0,02657	1,94372	0,04299	-2,03478	0,02657
19	1,94935	-2,03130	0,03869	0,02391	1,94935	0,03869	-2,03130	0,02391
20	1,95434	-2,02822	0,03488	0,02156	1,95434	0,03488	-2,02822	0,02156
21	1,95883	-2,02544	0,03145	0,01944	1,95883	0,03145	-2,02544	0,01944
22	1,96289	-2,02294	0,02835	0,01752	1,96289	0,02835	-2,02294	0,01752
23	1,96654	-2,02068	0,02556	0,01580	1,96654	0,02556	-2,02068	0,01580
24	1,96984	-2,01864	0,02304	0,01424	1,96984	0,02304	-2,01864	0,01424
25	1,97276	-2,01683	0,02081	0,01286	1,97276	0,02081	-2,01683	0,01286
26	1,97540	-2,01520	0,01879	0,01161	1,97540	0,01879	-2,01520	0,01161
27	1,97779	-2,01373	0,01697	0,01049	1,97779	0,01697	-2,01373	0,01049
28	1,97994	-2,01240	0,01532	0,00947	1,97994	0,01532	-2,01240	0,00947
29	1,98189	-2,01119	0,01384	0,00855	1,98189	0,01384	-2,01119	0,00855
30	1,98365	-2,01011	0,01249	0,00772	1,98365	0,01249	-2,01011	0,00772
31	1,98523	-2,00913	0,01128	0,00697	1,98523	0,01128	-2,00913	0,00697
32	1,98666	-2,00824	0,01019	0,00630	1,98666	0,01019	-2,00824	0,00630
33	1,98796	-2,00744	0,00920	0,00569	1,98796	0,00920	-2,00744	0,00569

Book Gradient.xls Sheet 1.5

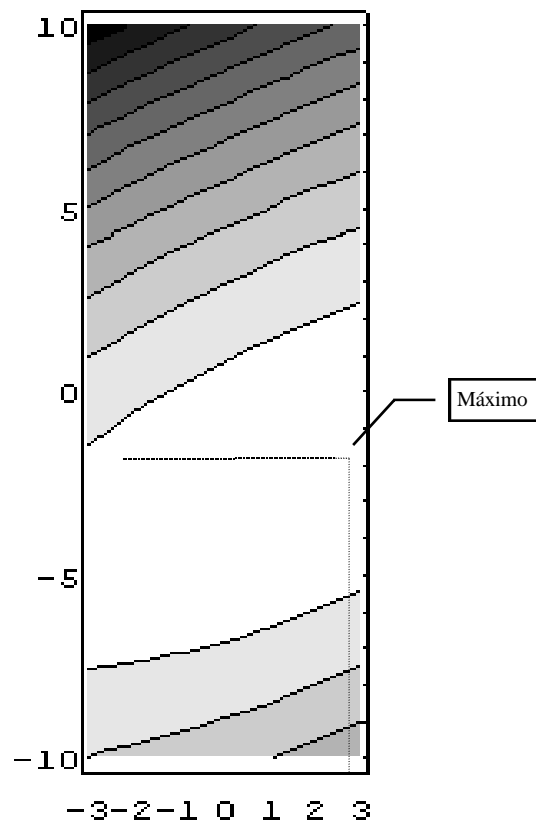

Na iteração 33 as derivadas parciais de  $f(x_1, x_2)$  têm valor absoluto inferior à tolerância 0,01 (termina processo iterativo)

**Solução** :  $x_1 = 1,98796$  ;  $x_2 = -2,00744$  ;  $f(x_1, x_2) = 19,9999234$

*Nota* : A solução exacta é  $x_1 = 2$  ;  $x_2 = -2$  ;  $f(x_1, x_2) = 20$

Para cada uma das iterações foi organizada a função  $f(x_1, x_2)$  com  $x_1$  e  $x_2$  parametrizados e calculado o seu máximo pelo método da Bissecção.

Nas figuras seguintes apresentam-se o gráfico da função e a projecção horizontal das curvas de nível da função.



- 1.6. Considerando como ponto tentativa inicial  $X_0 = (0,0)$  e a tolerância de 0.01, da aplicação do Método do Gradiente, na função simétrica, resulta o seguinte:

Quadro 1 - Determinação das coordenadas de  $X_{k+1}$  em ordem ao parâmetro “t”

Iter.	Ponto Tentativa $X_0$		Gradiente em $X_0$		Abcissa de $X_{k+1}$		Ordenada de $X_{k+1}$	
	$x_1$	$x_2$	$x_1$	$x_2$	a	bt	c	dt
1	0.00000	0.00000	4.00000	-4.00000	0.00000	4.00000	0.00000	-4.00000
2	0.76800	-0.76800	0.02203	-0.02203	0.76800	0.02203	-0.76800	-0.02203
3	0.77111	-0.77111	-0.00143	0.00143	0.77111	-0.00143	-0.77111	0.00143

Book Gradient.xls Sheet 1.6

Na iteração 3 as derivadas parciais de  $-f(x_1, x_2)$  têm valor absoluto inferior à tolerância 0.01 (termina processo iterativo)

**Solução :**  $x_1 = 0.77111$  ;  $x_2 = -0.77111$  ;  $f(x_1, x_2) = -3.437$

*Nota :* Para cada uma das iterações foi organizada a função  $-f(x_1, x_2)$  com  $x_1$  e  $x_2$  parametrizados e calculado o seu máximo. Os resultados obtidos são apresentados no quadro seguinte:



Quadro 2 - Determinação do valor ótimo “t” onde  $f(x_1, x_2)$  atinge o máximo

Iter.	$t^4$	$t^3$	$t^2$	t	Constante	$t^*$ (ótimo)	Valor de $f(x_1, x_2)$
1	-256.000	0.000	-64.000	32.000	0.000	0.192	0.00000
2	0.000	0.000	-0.003	0.001	3.437	0.141	-3.43681
3	0.000	0.000	0.000	0.000	3.437	0.141	-3.43688

Book Gradient.xls Sheet 1.6

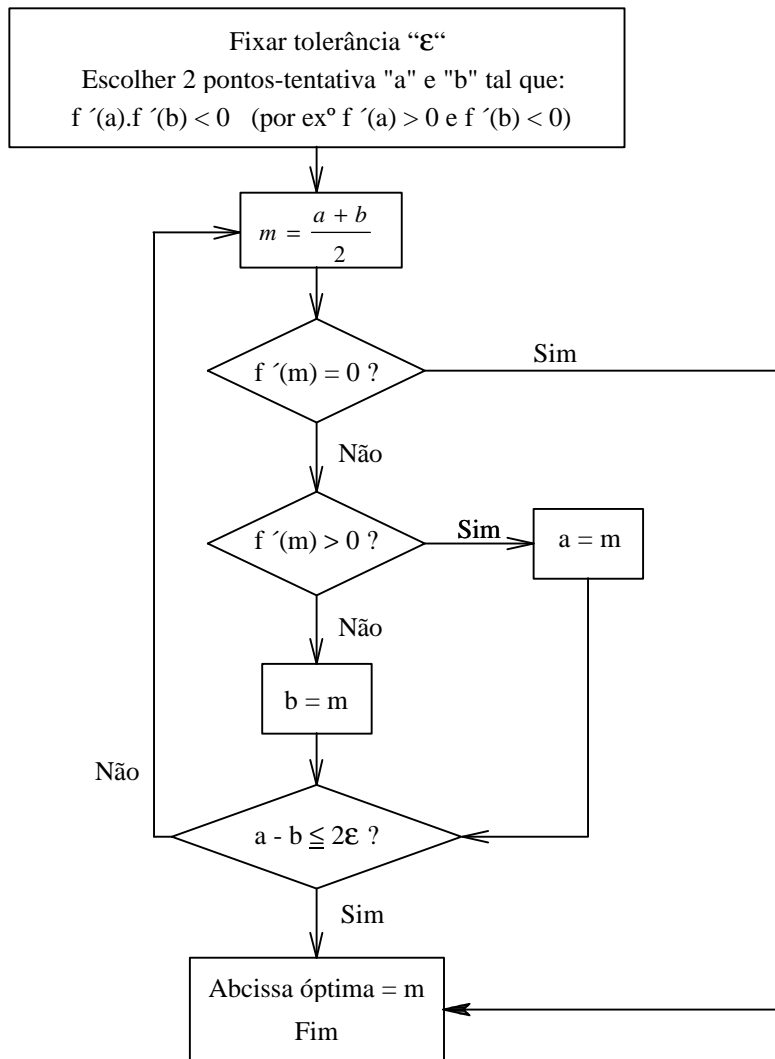


Nas figuras seguintes apresentam-se o gráfico da função e a projecção horizontal das curvas de nível da função.



1.7. O método da bissecção determina a abscissa do extremo de uma função monovariável no intervalo [a,b].



Fluxograma do método:



A figura seguinte visualiza os pontos “a”, “b” e “m” da primeira iteração:


1ª Hipótese  
Reduzir intervalo com a = m

2ª Hipótese  
Reduzir intervalo com b = m



## 1.8. Aspectos essenciais que fundamentam o método:

1. O valor do gradiente da função num ponto  $X_k$ , indica a direcção e sentido de crescimento da função naquele ponto.
2. O vector-gradiente, no ponto  $X_k$ , é perpendicular à curva de nível da função a que pertence  $X_k$  e indica a direcção e sentido de maior aumento da função o que não deve ser confundido com caminho mais curto para atingir o extremo desta (ver figura).



3. No ponto  $X_k$ , conhecendo a direcção e sentido de maior aumento da função, é necessário calcular o tamanho do deslocamento (passo) para atingir o ponto  $X_{k+1}$  de coordenadas:

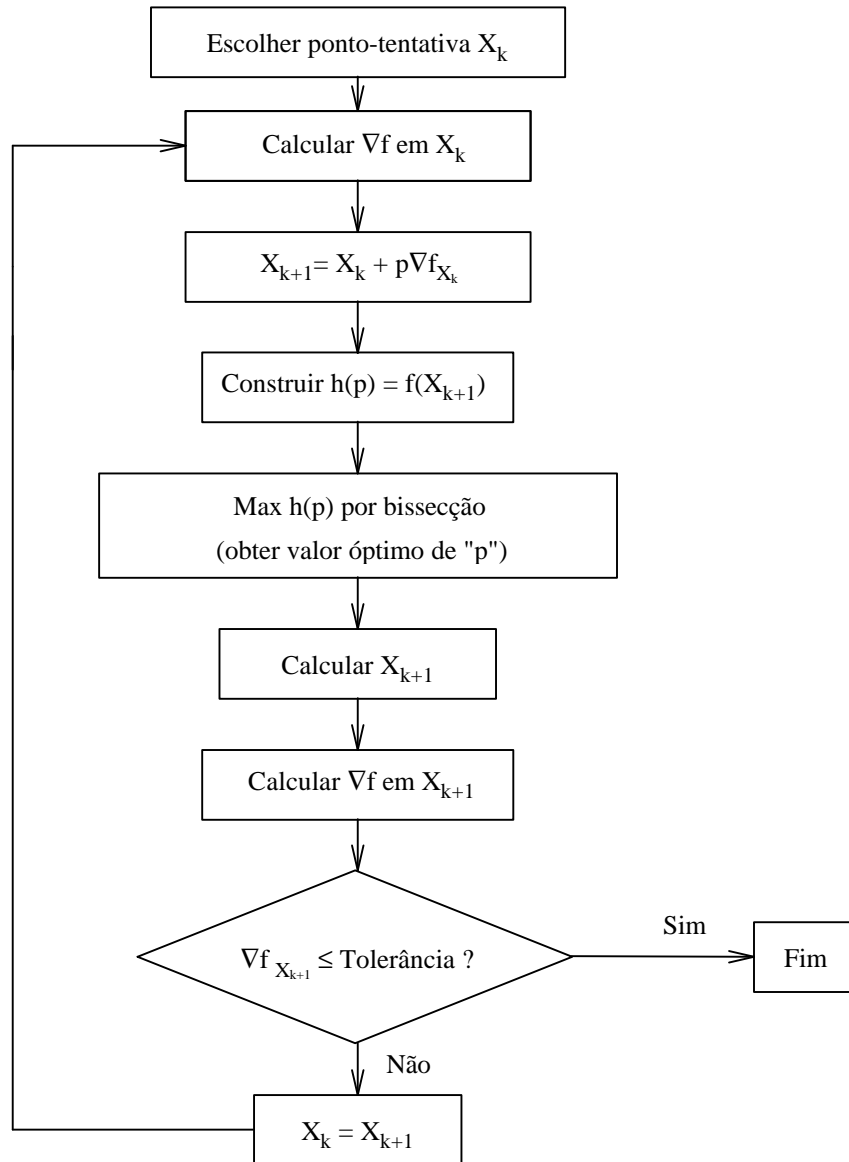
$$X_{k+1} = X_k + p \nabla f_{X_k}$$

onde a função tem o seu maior valor naquela direcção e sentido(ver figura).

Com as coordenadas de  $X_{k+1}$  expressas em função de “p”:

- coloca-se  $f(X)$  em ordem a “p” (dispõe-se de uma função monovariável  $h(p)$  para maximizar);
  - pelo método da bissecção calcula-se o valor óptimo de “p”;
  - calculam-se as coordenadas de  $X_{k+1}$  por substituição de “p”.
4. Em  $X_{k+1}$  calcula-se o valor do gradiente da função ( que se sabe ser nulo no óptimo) e compara-se com a tolerância fixada. Se satisfaz é interrompido o cálculo (regra de paragem) repetindo-se o procedimento descrito no caso contrário.

Fluxograma do Método do Gradiente:



2.

2.1 Teorema dos multiplicadores de Lagrange

Dado o problema de PNL:

$$\text{Max } f_0(X)$$

$$\text{s.a. } f_i(X) = 0 \quad (i = 1, \dots, m)$$

se :

- $X^*$  é um máximo local, e
- $n > m$  (há mais variáveis do que restrições), e
- $f_i$  têm primeiras derivadas parciais contínuas em ordem a  $x_j$ , e
- os gradientes  $\nabla f_i(X^*)$  são vectores linearmente independentes,

então há um vector  $\lambda = [\lambda_1, \lambda_2, \dots, \lambda_m]^T$  tal que :

$$\nabla f_0(X^*) - \sum_{i=1}^m \lambda_i \nabla f_i(X^*) = 0$$

em que:

- $\lambda_1, \lambda_2, \dots, \lambda_m$  são denominados *multiplicadores de Lagrange*;
- a condição da independência linear de  $\nabla f_i(X^*)$  é denominada *restrição de qualificação*.

O teorema sugere o seguinte método para resolver problemas de PNL **só com restrições de igualdade**:

- Verificar se  $n > m$  e se todas as  $f_i$  têm derivadas parciais contínuas
- Considerar a Função de Lagrange :

$$L(X, \lambda) = f_0(X) - \sum_{i=1}^m \lambda_i f_i(X)$$

- Calcular *todas as soluções*  $(X^*, \lambda^*)$  para o sistema de equações algébricas não lineares:

$$\nabla L(X, \lambda) = \nabla f_0(X) - \sum_{i=1}^m \lambda_i \nabla f_i(X) = 0 \quad (\underline{n} \text{ equações})$$

$$\frac{\partial L(X, \lambda)}{\partial \lambda_i} = -f_i(X) = 0 \quad (i = 1, \dots, m) \quad (\underline{m} \text{ equações})$$

Estas equações representam as *condições de Lagrange* sendo os pontos  $(X, \lambda)$  os *pontos de Lagrange*.

- Analisar cada uma das soluções  $(X^*, \lambda^*)$  para verificar se é maximizante.

2.2 A resposta é negativa pois que o teorema não garante que as soluções das condições de Lagrange são pontos óptimos (onde a função-objectivo atinge o máximo) ou mesmo que sejam pontos de estacionaridade; o que o teorema garante é que qualquer ponto onde não se verifiquem as condições de Lagrange não é garantidamente ponto-óptimo. Resumindo, as condições de Lagrange são condição necessária para uma solução ser considerada óptima mas não são condição suficiente excepto *no caso de solução única em que pode concluir-se imediatamente que a mesma é óptima*.

## 2.3

1.  $n=2$  e  $m=1$  portanto tem-se  $n > m$

O gradiente da restrição é:

$$\nabla f_1 = \begin{bmatrix} 4 \\ 2 \end{bmatrix}$$

pois que  $\partial f_1 / \partial x_j$  é contínua.

2. Construir a função Lagrangeana:

$$L(x_1, x_2, \lambda) = f(x_1, x_2) - \lambda (4x_1 + 2x_2 - 60) = x_1x_2 + 2x_1 - \lambda (4x_1 + 2x_2 - 60)$$

(Notar que sendo  $(4x_1 + 2x_2 - 60) = 0$  maximizar "L" é maximizar a função-objectivo)

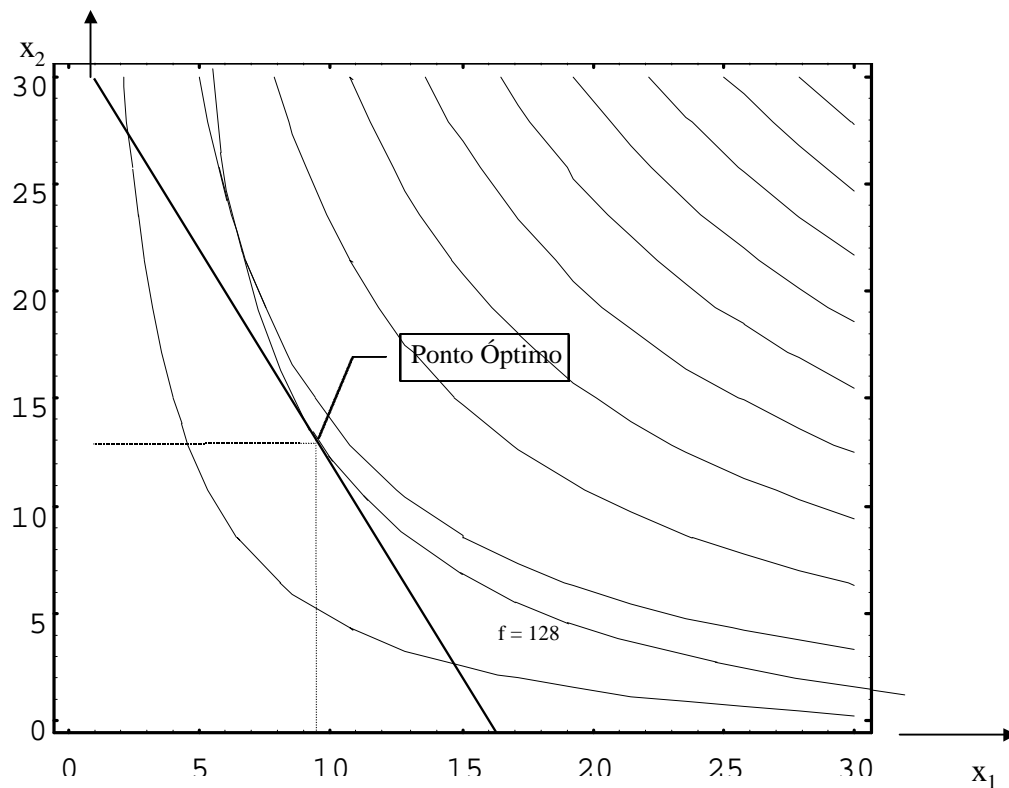
3. Calcular as derivadas parciais de 1ª ordem, igualar a zero e resolver o sistema de equações:

$$\begin{cases} \partial L / \partial x_1 = x_2 + 2 - 4\lambda = 0 & x_1 = 8 \\ \partial L / \partial x_2 = x_1 - 2\lambda = 0 & x_2 = 14 \\ \partial L / \partial \lambda = -4x_1 - 2x_2 + 60 = 0 & \lambda = 4 \end{cases}$$



A solução que satisfaz as condições de Lagrange é única pelo que é ótima (Max  $f = 128$ ):

$$X = \begin{bmatrix} 8 \\ 14 \end{bmatrix} \quad e \quad \lambda = 4$$

A figura seguinte apresenta a projecção horizontal das curvas de nível da função.



2.4 Sendo a variável **não negativa** as situações possíveis são:



**A não negatividade das variáveis independentes, determina as seguintes condições de 1ª ordem para um ponto maximizante** (extremo condicionado):

$$\begin{cases} df/dx \leq 0 \\ x (df/dx) = 0 \end{cases}$$

Naturalmente para  $f(x_1, x_2, \dots, x_n)$  com  $x_1, x_2, \dots, x_n \geq 0$  tem-se:

$$\begin{cases} \partial f / \partial x_j \leq 0 & (j=1 \text{ a } n) \\ x_j (\partial f / \partial x_j) = 0 \end{cases}$$

2.5 Considere-se o modelo na forma:

$$\begin{array}{l} \text{Max } f(x) \\ \text{s.a.} \quad g(x) + s = b \\ \quad \quad s \geq 0 \end{array}$$

A função Lagrangeana é:

$$L = f(x) - \lambda [(g(x) + s - b)]$$

Atendendo a que “s” é variável não negativa, as condições de 1ª ordem para extremo de  $L(x, \lambda)$  são:

$$\left\{ \begin{array}{l} \partial L / \partial x = 0 \\ \partial L / \partial s \leq 0 \\ s (\partial L / \partial s) = 0 \\ \partial L / \partial \lambda = 0 \quad (\text{notar que } \partial L / \partial \lambda = -g(x) - s + b = 0) \end{array} \right.$$

Notar que:

- $(\partial L / \partial s) = -\lambda$  o que implica:  $\lambda \geq 0$  (multiplicador de Lagrange deve ser **não negativo**)
- $s(-\lambda) = 0$ . Como  $-s = g(x) - b$  resulta:  $\lambda [g(x) - b] = 0$  (note que “ $\lambda$ ” é complementar da variável de folga da restrição pelo que é a variável Dual associada...)

2.6

Verificação da concavidade da função:

$$\nabla f = \begin{bmatrix} \partial f / \partial x_1 \\ \partial f / \partial x_2 \end{bmatrix} = \begin{bmatrix} 5 - 4x_1 + 3x_2 \\ 3x_1 - 4x_2 \end{bmatrix}$$

$$H_f = \begin{bmatrix} \partial^2 f / \partial x_1^2 & \partial^2 f / \partial x_1 x_2 \\ \partial^2 f / \partial x_2 x_1 & \partial^2 f / \partial x_2^2 \end{bmatrix} = \begin{bmatrix} -4 & 3 \\ 3 & -4 \end{bmatrix}$$

Na matriz Hessiana os menores principais  $H_k$  com  $k=1,2$  são:

$$H_1 = -4 \text{ e } -4 \text{ (diagonal principal)} ; \quad H_2 = (-4)(-4) - (3)(3) = 7$$

Como os determinantes têm o sinal de  $(-1)^k$  (são respectivamente negativo e positivo) a matriz é Definida Negativa podendo concluir-se que a função é côncava.

A função Lagrangeana é:

$$L = 5x_1 - 2x_1^2 + 3x_1x_2 - 2x_2^2 - \lambda (x_1 + x_2 + s - 2)$$

As condições a satisfazer pelo extremo (ver problema 2.5) são:

$$\left\{ \begin{array}{l} \partial L / \partial x_1 = 0 \Rightarrow 5 - 4x_1 + 3x_2 - \lambda = 0 \quad (1) \\ \partial L / \partial x_2 = 0 \Rightarrow 3x_1 - 4x_2 - \lambda = 0 \quad (2) \\ \partial L / \partial s \leq 0 \Rightarrow -\lambda \leq 0 \quad (3) \\ s (\partial L / \partial s) = 0 \Rightarrow -s\lambda = 0 \quad (4) \\ \partial L / \partial \lambda = 0 \Rightarrow -x_1 - x_2 - s + 2 = 0 \quad (5) \end{array} \right.$$

Estas condições podem tomar a forma mais simples:



$$5 - 4x_1 + 3x_2 - \lambda = 0 \quad (1)$$

$$3x_1 - 4x_2 - \lambda = 0 \quad (2)$$

$$\lambda (x_1 + x_2 - 2) = 0 \quad (3)$$

$$\lambda ; s \geq 0 \quad (4)$$

(Notar a condição de não negatividade do multiplicador “ $\lambda$ ”)

Se  $\lambda = 0$  tem-se de (1) e (2)  $x_1 = 20/7$  e  $x_2 = 15/7$  que não satisfaz  $x_1 + x_2 + s = 2$  com  $s \geq 0$  pelo que se conclui que  $\lambda \neq 0$ .

Para  $\lambda \neq 0$  então em (3) tem-se  $x_1 + x_2 = 2$  ou seja  $x_1 = 2 - x_2$



Substituindo em (1) e (2) tem-se:

$5 - 8 + 4x_2 + 3x_2 - \lambda = 0$  e  $6 - 3x_2 - 4x_2 - \lambda = 0$  que permite calcular  $x_2 = 9/14$  e  $\lambda = 3/2$ .

Em (1) ou (2) tem-se  $x_1 = 19/14$ .

O ponto  $(19/14, 9/14)$  é o ponto óptimo onde  $\text{Max } f(x_1, x_2) = 137/28$ .

Nas figuras seguintes apresentam-se o gráfico da função e a projecção horizontal das curvas de nível da função.



2.7 A matriz Hessiana é:

$$H_f = \begin{bmatrix} \partial^2 f / \partial x_1^2 & \partial^2 f / \partial x_1 x_2 \\ \partial^2 f / \partial x_2 x_1 & \partial^2 f / \partial x_2^2 \end{bmatrix} = \begin{bmatrix} 6 & 2 \\ 2 & 2 \end{bmatrix}$$

Como os determinantes menores principais (1ª e 2ª ordem) são positivos a matriz é Definida Positiva podendo concluir-se que a função é convexa.

A função Lagrangeana é:

$$L = 3x_1^2 + x_2^2 + 2x_1x_2 + 6x_1 + 2x_2 - \lambda (2x_1 - x_2 - 4)$$



As condições a satisfazer pelo extremo são:

$$\begin{cases} \partial L / \partial x_1 = 0 & \Rightarrow & 6x_1 + 2x_2 + 6 - 2\lambda = 0 & (1) \\ \partial L / \partial x_2 = 0 & \Rightarrow & 2x_2 + 2x_1 + 2 + \lambda = 0 & (2) \\ \partial L / \partial \lambda = 0 & \Rightarrow & -2x_1 + x_2 + 4 = 0 & (3) \end{cases}$$

A solução do sistema de equações é  $x_1 = 7/11$  ;  $x_2 = -30/11$  ;  $\lambda = 24/11$ .

Porque a função é convexa só se pode concluir que foi atingido um ponto de estacionaridade.

Nas figuras seguintes apresentam-se o gráfico da função e a projecção horizontal das curvas de nível da função.



2.8 A função-objectivo é linear (côncava e convexa)

A função Lagrangeana é:

$$L = x_1 - x_2 - \lambda (x_1^2 + x_2^2 - 1)$$

As condições a satisfazer pelo extremo são:

$$\left| \begin{array}{l} \partial L / \partial x_1 = 0 \\ \partial L / \partial x_2 = 0 \\ \partial L / \partial \lambda = 0 \end{array} \right. \Rightarrow \left| \begin{array}{l} 1 - 2\lambda x_1 \\ -1 - 2\lambda x_2 \\ -x_1^2 - x_2^2 + 1 \end{array} \right. = 0 \quad \begin{array}{l} (1) \\ (2) \\ (3) \end{array}$$

Do sistema calcula-se  $\lambda = \pm \sqrt{\frac{1}{2}}$  pelo que há 2 soluções:


$$1. \quad x_1 = -\frac{\sqrt{2}}{2} ; x_2 = \frac{\sqrt{2}}{2} ; \lambda = -\frac{\sqrt{2}}{2} ; f = -1.41421$$

$$2. \quad x_1 = \frac{\sqrt{2}}{2} ; x_2 = -\frac{\sqrt{2}}{2} ; \lambda = \frac{\sqrt{2}}{2} ; f = 1.41421$$

Da sua análise verifica-se que o valor óptimo da função é atingido no primeiro destes pontos:

$$x_1 = -\frac{\sqrt{2}}{2} ; x_2 = \frac{\sqrt{2}}{2} ; \text{Min } f = -1.41421$$

A figura seguinte esclarece a situação:



3.

3.1 As soluções de um modelo de PL podem ser agrupadas do seguinte modo:

- não admissível
- ou
- admissível com valor ótimo finito atingido no ponto ótimo
- ou
- admissível com valor ótimo ilimitado

Na Programação Não Linear são possíveis as 3 situações e uma 4ª hipótese:

- admissível com valor limitado para a função-objectivo mas não há ponto ótimo
- Veja-se por exemplo  $\text{Min } f = 1/x$  com  $x \geq 0$  que tem pontos admissíveis sendo zero o maior limite inferior do valor da função-objectivo. Contudo este limite nunca é atingido em ponto admissível pelo que não há ponto ótimo.

3.2 É possível como o exemplo seguinte demonstra:

$$\text{Minimizar } f(x_1, x_2) = (x_1 - 4)^2 + (x_2 - 4)^2$$

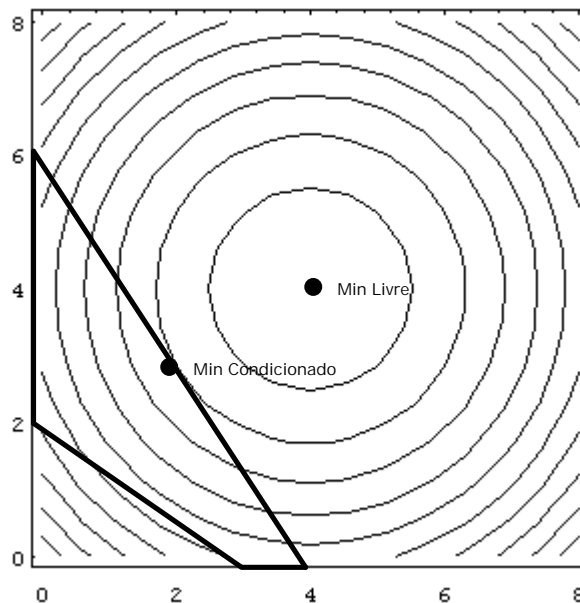

$$\text{s.a. } 2x_1 + 3x_2 \geq 6$$

$$-3x_1 - 2x_2 \geq -12$$

$$x_1, x_2 \geq 0$$

A solução óptima é  $x_1 = 28/13$ ,  $x_2 = 36/13$  e  $\text{Min } f = 64/13$ .

As figuras mostram que, no convexo de soluções, o Ponto óptimo NÃO É EXTREMO (o que não se passa em Programação Linear).



3.3 É possível como o exemplo seguinte demonstra:

Minimizar  $f(x_1, x_2) = (x_1 - 4)^2 + (x_2 - 4)^2$

s.a.  $x_1 + x_2 \geq 5$

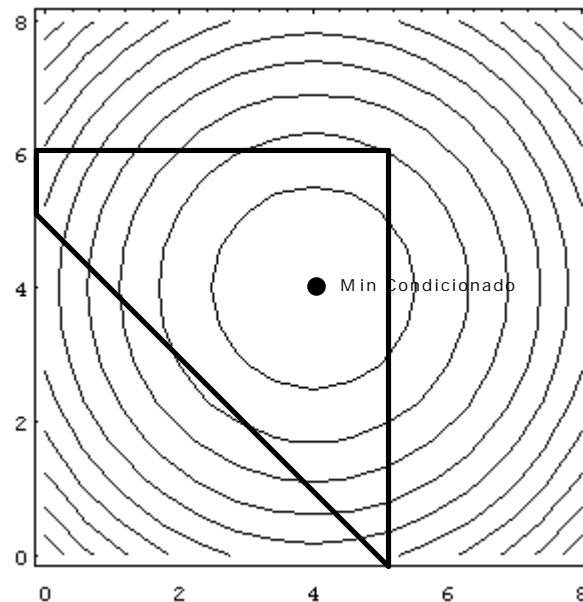

$-x_1 \geq -5$

$-2x_2 \geq -12$

$x_1, x_2 \geq 0$

A solução óptima é  $x_1 = 4, x_2 = 4$  e  $\text{Min } f = 0$ .

As figuras mostram que, no convexo de soluções, o Ponto óptimo É INTERIOR ( o que não se passa em Programação Linear).



3.4 É possível como o exemplo seguinte demonstra:

$$\text{Max } f(x_1, x_2) = 2x_1 + x_2$$


$$\text{s.a. } -x_1^2 + 4x_1 - x_2 \leq 0$$

$$2x_1 + 3x_2 \leq 12$$

$$x_1, x_2 \geq 0$$

Nota: O espaço de solução não é convexo ( 2 conjuntos : áreas I e II ).

Na área I, é no ponto P que a função tem maior valor. Veja-se que tal é apenas máximo local pois na área II a função tem maior valor em qualquer ponto.



3.5 CONCLUSÕES SOBRE DIFERENÇAS ENTRE PNL E PL :

- Em PNL, qualquer ponto do espaço de solução pode ser ótimo. A procura do ponto ótimo **não pode** ficar limitada aos extremos como na PL.
- O número de restrições técnicas saturadas, no ótimo, **pode ser nulo**. (ver problema 3.3 onde nenhuma restrição é satisfeita como igualdade).
- O deslocamento contínuo numa dada direcção **pode não conduzir** a valores crescentes (ou decrescentes) da função-objectivo ao contrário do que se verifica na PL.
- O espaço de solução **pode não constituir** um conjunto convexo (ver problema 3.4).
- Um ótimo local **pode não ser** um ótimo global ( ver problema 3.4).


3.6 Só no caso de  $f(X)$  ser côncava ou seja, no conjunto de soluções  $S$  para qualquer par de pontos  $X'$  e  $X''$  do conjunto  $S$  verifica-se:

$$f(cX' + (1-c)X'') \geq cf(X') + (1-c)f(X'') \quad (1)$$

para valores de "c" tal que  $0 \leq c \leq 1$ .



A figura seguinte visualiza a situação para uma função monovariável:



*Nota: Coordenadas de B obtidas por combinação linear convexa dos extremos do segmento AD.*

*Veja-se que a função é côncava porque se verifica a condição (1) o que geometricamente corresponde a que o segmento que une qualquer par de pontos da curva da função está sempre abaixo desta.*

3.7 A matriz Hessiana de  $f(x_1, x_2, \dots, x_n)$  é uma matriz de ordem “n” em que cada elemento (i,j) é igual a:

$$\frac{\partial^2 f}{\partial x_i \partial x_j}$$

Para a função proposta tem-se  $H = \begin{bmatrix} 6x_1 & 2 \\ 2 & 12x_2^2 \end{bmatrix}$

3.8 A função é CÔNCAVA em “S” se e só se para qualquer ponto  $X \in S$ , os menores principais não nulos da matriz Hessiana têm o sinal de  $(-1)^k$  sendo “k” a ordem do menor.

3.9 A função é CONVEXA em “S” se e só se para qualquer ponto  $X \in S$ , os menores principais da matriz Hessiana são positivos.

3.10 Considerando  $d_1$  e  $d_2$  as funções da procura, o objectivo é Maximizar a função-objectivo  $f = p_1d_1 + p_2d_2$  ou seja  $f = p_1(150 - 2p_1 - p_2) + p_2(200 - p_1 - 3p_2) = 150p_1 - 2p_1^2 - 2p_1p_2 + 200p_2 - 3p_2^2$ .

A matriz Hessiana é:  $\begin{bmatrix} -4 & -2 \\ -2 & -6 \end{bmatrix}$

sendo os seus menores principais:

$$\begin{aligned} \left| H_1 \right| &= -4 \text{ e } -6 \text{ (ambos negativos)} \\ \left| H_2 \right| &= 24 - 4 = 20 \text{ (positivo)} \end{aligned}$$

pelo que a matriz é definida negativa, podendo concluir-se que a função-objectivo é Côncava.

Anulando o gradiente da função tem-se:

$$\nabla f = \begin{bmatrix} 150 - 4p_1 - 2p_2 \\ -2p_1 + 200 - 6p_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \Rightarrow \begin{aligned} p_1 = p_2 = 25 \text{ u.m. com Max } f = 4375 \\ \text{com } d_1 = 75 \text{ e } d_2 = 100 \text{ (unidades)} \end{aligned}$$

3.11

$$\text{A matriz Hessiana é: } \begin{bmatrix} 2 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 4 \end{bmatrix}$$

Os menores principais são :

$$\left| H_1 \right| = 2, 2, 4 \text{ (positivos)}$$

$$\left| H_2 \right| = 8 - 1 = 7 > 0$$

$$\left| H_2 \right| = 8 - 1 = 7 > 0$$

$$\left| H_2 \right| = 4 - 1 = 3 > 0$$

$$\left| H_3 \right| = 6 > 0$$

Dado que todos os menores principais de H são positivos a matriz é definida positiva pelo que a função é Convexa.

3.12 a. Sendo  $X_1 = (2,3)$  o valor do gradiente neste ponto é:

$$\nabla f = \begin{bmatrix} 2x_2 - 2x_1 \\ 2x_1 + 3 - 2x_2 \end{bmatrix} = \begin{bmatrix} 2 \\ 1 \end{bmatrix}$$

b. A função é quadrática pelo que a série de Taylor terá 3 termos:

$$\begin{aligned} f(X_2) &= f(X_1) + \Delta X^T \nabla f_{X_1} + \frac{1}{2} \Delta X^T H_{X_1} \Delta X \\ &= 8 + [0.1 \ 0.2] \begin{bmatrix} 2 \\ 1 \end{bmatrix} + \frac{1}{2} [0.1 \ 0.2] \begin{bmatrix} -2 & 2 \\ 2 & -2 \end{bmatrix} \begin{bmatrix} 0.1 \\ 0.2 \end{bmatrix} \\ &= 8 + 0.4 + \frac{1}{2} [0.2 \ -0.2] \begin{bmatrix} 0.1 \\ 0.2 \end{bmatrix} = 8.39 \end{aligned}$$

$$3.13 \quad V = \nabla f_{X_2} - \nabla f_{X_1} = H(X_2 - X_1) = \begin{bmatrix} -2 & 2 \\ 2 & -2 \end{bmatrix} \begin{bmatrix} 0.1 \\ 0.2 \end{bmatrix} = \begin{bmatrix} 0.2 \\ -0.2 \end{bmatrix}$$

$$3.14 \quad f = CX + \frac{1}{2} X^T H X$$

$$= [15 \ 30] \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \frac{1}{2} [x_1 \ x_2] \begin{bmatrix} -4 & -4 \\ -4 & -8 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

em que :

C = matriz dos coeficientes das variáveis  $x_{ij}$ , na função-objectivo

H = matriz hessiana de f(X)

X = vector coluna das variáveis de decisão

4.

$$4.1 \quad L(x_1, x_2, \lambda) = 2x_1 + 3x_2 - x_1^2 - x_2^2 - \lambda(2x_1 + 2x_2 + s - 4)$$

$$\text{s.a.} \quad s \geq 0$$

O termo “ $-\lambda(2x_1 + 2x_2 + s - 4)$ ” é nulo pelo que maximizar a função L é maximizar a função proposta.

As condições de 1ª ordem para extremo da função Lagrangeana são:

$$\left. \begin{array}{l} \partial L / \partial x_1 = 0 \\ \partial L / \partial x_2 = 0 \\ \partial L / \partial s \leq 0 \\ s(\partial L / \partial s) = 0 \\ \partial L / \partial \lambda = 0 \end{array} \right\} \Rightarrow \left. \begin{array}{l} 2 - 2x_1 - 2\lambda = 0 \\ 3 - 2x_2 - 2\lambda = 0 \\ -\lambda \leq 0 \\ s(-\lambda) = 0 \\ -2x_1 - 2x_2 - s + 4 = 0 \end{array} \right\}$$

As condições KKT são:

- 1ª condição:

$$2 - 2x_1 - 2\lambda = 0$$

$$3 - 2x_2 - 2\lambda = 0$$

- 2ª condição: Dado que  $-s = 2x_1 + 2x_2 - 4$  e que  $-s\lambda = 0$ , deduz-se a condição seguinte:

$$\lambda(2x_1 + 2x_2 - 4) = 0$$

- 3ª condição: A restrição técnica do modelo

$$2x_1 + 2x_2 - 4 \leq 0$$

- 4ª condição:

$$\lambda \geq 0$$

4.2 Nesta situação, dado que a restrição é do tipo “=” não é utilizada qualquer variável de folga pelo que a variável “ $\lambda$ ” é livre.

As condições KKT são:

- 1ª condição:

$$2 - 2x_1 - 2\lambda = 0$$

$$3 - 2x_2 - 2\lambda = 0$$

- 2ª condição: A restrição técnica do modelo

$$2x_1 + 2x_2 - 4 = 0$$

4.3 Considerando  $s_1$  e  $s_2$  variáveis de folga (não negativas) das primeira e segunda restrições técnicas, a função de Lagrange é:

$$L(x_1, x_2, s_1, s_2, \lambda_1, \lambda_2) = f(x_1, x_2) - \lambda_1(x_1 - 2 + s_1) - \lambda_2(x_2 - 1 + s_2)$$

Nesta situação é necessário atender à condição de não negatividade das variáveis  $x_1$ ,  $x_2$ ,  $s_1$ ,  $s_2$  e ao ambiente de Minimização.

Adoptando abordagem semelhante à exposta no problema 2.4, conclui-se que as condições de 1ª ordem para extremo são:

- $\partial L / \partial x_j \geq 0$  e  $x_j (\partial L / \partial x_j) = 0$
- $\partial L / \partial s_i \geq 0$  e  $s_i (\partial L / \partial s_i) = 0$
- $\partial L / \partial \lambda_i = 0$

Da condição  $\partial L / \partial s_i \geq 0$  deduz-se  $\lambda_i \leq 0$  (de facto  $\lambda_i$  é a variável Dual associada à restrição “i” ; como as duas restrições são do tipo “ $\leq$ ” em ambiente de Minimização, as variáveis duais associadas são não positivas).

Da condição  $s_i (\partial L / \partial s_i) = 0$  deduz-se  $\lambda_i (g_i(x_1, x_2) - b_i) = 0$ .

As condições KKT são:

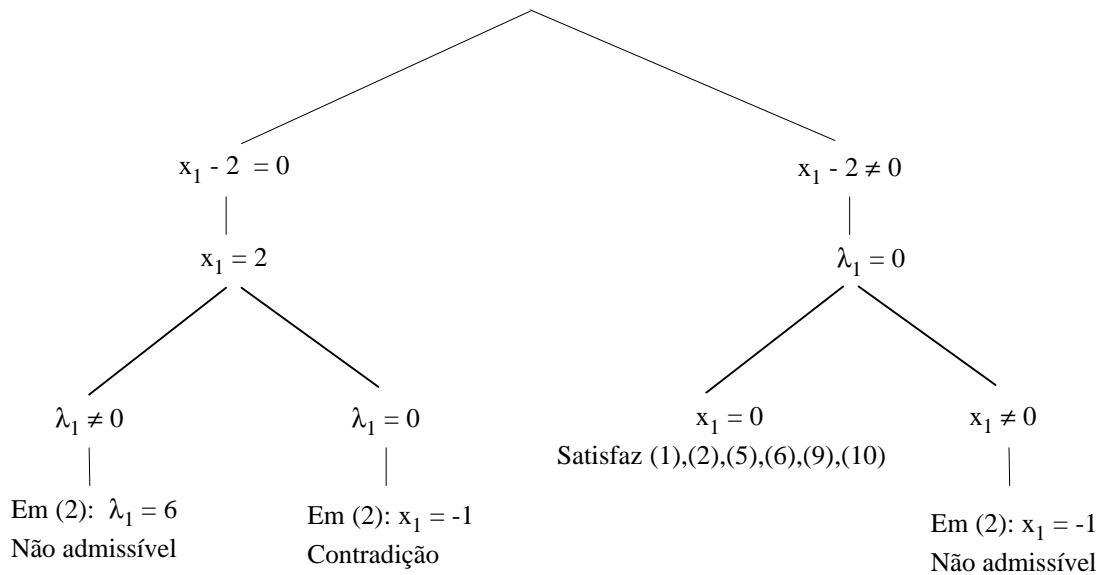
- (1)  $2x_1 + 2 - \lambda_1 \geq 0$
- (2)  $x_1 (2x_1 + 2 - \lambda_1) = 0$
- (3)  $2x_2 - 4 - \lambda_2 \geq 0$
- (4)  $x_2 (2x_2 - 4 - \lambda_2) = 0$
- (5)  $x_1 - 2 \leq 0$
- (6)  $\lambda_1 (x_1 - 2) = 0$
- (7)  $x_2 - 1 \leq 0$
- (8)  $\lambda_2 (x_2 - 1) = 0$
- (9)  $x_1, x_2 \geq 0$
- (10)  $\lambda_1, \lambda_2 \leq 0$

Das condições de ortogonalidade tem-se:

- se  $\lambda_i \neq 0$  então  $g_i(X) = 0$  e se  $g_i(X) \neq 0$  então  $\lambda_i = 0$

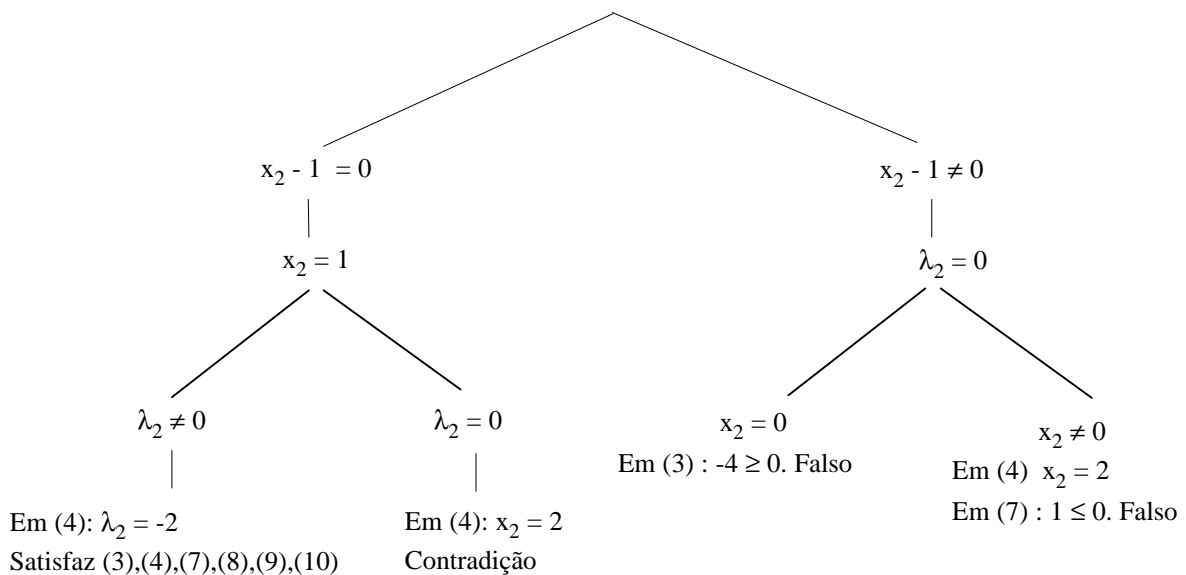
Explorando uma das condições até estabelecer incompatibilidade (contradição) com as restantes condições será possível concluir se é nulo o multiplicador  $\lambda_i$  ou  $g_i(X)$  ou ambos. Deste modo como se vai concluindo quais as restrições activas e inactivas, as desigualdades KKT que se verificam como igualdades e os multiplicadores que são nulos a complexidade do problema reduz-se progressivamente.

Tomando a condição (6) tem-se:



1ª Conclusão :  $x_1 = 0 ; \lambda_1 = 0$  satisfaz as condições KKT.

Tomando a condição (7) tem-se:



2ª Conclusão :  $x_2 = 1 ; \lambda_2 = -2$  satisfaz as condições KKT.

A solução  $x_1 = 0 ; x_2 = 1 ; \lambda_1 = 0 ; \lambda_2 = -2$  satisfaz todas as condições KKT o que é suficiente para afirmar tratar-se da solução óptima.



Acresce ainda que sendo Convexa a função proposta para otimizar em espaço Convexo (restrições são lineares) é condição necessária que a solução satisfaça integralmente as condição KKT.

O ponto óptimo é pois  $x_1 = 0 ; x_2 = 1$  sendo  $\text{Min } f = 2$ .

*Nota: Poder-se-ia ter optado por Maximizar a função simétrica  $-x_1^2 - 2x_1 - x_2^2 + 4x_2 - 5$  com o que se obteria o ponto-solução :  $x_1 = 0 ; x_2 = 1 ; \lambda_1 = 0 ; \lambda_2 = 2$ .*

*O multiplicador  $\lambda_2$  é agora não negativo porque a restrição associada é típica no ambiente de maximização .*

As figuras seguintes apresentam o gráfico da função proposta, e a projecção horizontal das curvas de nível.



4.4

a. Substituindo a restrição de igualdade pelas desigualdades  $x_1^2 + x_2^2 \leq 1$  e  $-x_1^2 - x_2^2 \leq -1$  as condições KKT

são :

$\frac{\partial f}{\partial x_j} - \sum_{i=1}^m \lambda_i \frac{\partial g_i}{\partial x_j} \leq 0$	(1) $[1 / (x_1 + 1)] - \lambda_1 (2x_1) - \lambda_2 (-2x_1) \leq 0$
$x_j \left( \frac{\partial f}{\partial x_j} - \sum_{i=1}^m \lambda_i \frac{\partial g_i}{\partial x_j} \right) = 0$	(2) $1 - \lambda_1 (2x_2) - \lambda_2 (-2x_2) \leq 0$
$g_i - b_i \leq 0$	(3) $x_1 \{ [1 / (x_1 + 1)] - \lambda_1 (2x_1) - \lambda_2 (-2x_1) \} = 0$
$\lambda_i (g_i - b_i) = 0$	(4) $x_2 [1 - \lambda_1 (2x_2) - \lambda_2 (-2x_2)] = 0$
$\lambda_i \geq 0$	(5) $x_1^2 + x_2^2 - 1 \leq 0$
$x_j \geq 0$	(6) $-x_1^2 - x_2^2 + 1 \leq 0$
	(7) $\lambda_1 (x_1^2 + x_2^2 - 1) = 0$
	(8) $\lambda_2 (-x_1^2 - x_2^2 + 1) = 0$
	(9) $\lambda_1, \lambda_2 \geq 0$
	(10) $x_1, x_2 \geq 0$

b.

De (1) deduz-se que  $\lambda_1 \neq 0$  e  $x_1 \neq 0$ .

De (3) deduz-se que  $\lambda_1 \neq 0$  e  $x_2 \neq 0$ .



Os multiplicadores  $\lambda_1$  e  $\lambda_2$  são complementares pelo que  $\lambda_2 = 0$ . De facto considerando a restrição na forma de igualdade seria utilizado apenas um multiplicador “ $\lambda$ ” sem restrição de sinal que poderia ser considerado  $\lambda = \lambda_1 - \lambda_2$  com  $\lambda_1, \lambda_2 \geq 0$ . Ora nesta situação, verifica-se no óptimo, se existe,  $\lambda_1 \lambda_2 = 0$ .

Tem-se assim o sistema de equações:

$$\begin{cases} [1 / (x_1 + 1)] - 2\lambda_1 x_1 & = 0 \\ 1 - 2\lambda_1 x_2 & = 0 \\ x_1^2 + x_2^2 - 1 & = 0 \end{cases}$$

com solução  $x_1 = 0.543689 \approx 0.54$ ;  $x_2 = 0.839287 \approx 0.84$ ;  $\lambda = 0.595744 \approx 0.6$ ;  $\text{Max } f = 1.273462$ .

As figuras seguintes apresentam o gráfico da função proposta, e a projecção horizontal das curvas de nível.



4.5

a. No problema proposto, o espaço “S” de soluções admissíveis é um conjunto convexo pelo que se a função for côncava qualquer máximo local é solução óptima do problema.

A Hessiana de  $f(x_1, x_2)$  é a matriz quadrada de ordem 2:

$$H = \begin{bmatrix} \partial^2 f / \partial x_1^2 & \partial^2 f / \partial x_1 x_2 \\ \partial^2 f / \partial x_2 x_1 & \partial^2 f / \partial x_2^2 \end{bmatrix} = \begin{bmatrix} -2 & 0 \\ 0 & -2 \end{bmatrix}$$

A função  $f(x_1, x_2)$  é côncava no espaço de solução “S” se e só se para qualquer par  $(x_1, x_2) \in S$ , em H todos os menores principais diferentes de zero têm sinal de  $(-1)^k$  sendo “k” a ordem do menor.

*Nota: O menor principal de ordem “i” de uma matriz quadrada de ordem “n” é o determinante de qualquer matriz de ordem “i” obtida quando se eliminam “n-i” linhas e as correspondentes “n-i” colunas da matriz.*

Na matriz H têm-se os menores principais:

- de ordem 1 : -2 e -2 (têm o sinal de  $-1^1$ )
- de ordem 2:  $(-2)(-2) - (0)(0) = 4$  (tem o sinal de  $-1^2$ )

pelo que H é uma matriz definida negativa, pelo que  $f(x_1, x_2)$  é côncava.

O problema é portanto de programação convexa : função côncava e espaço de soluções convexo.

b. O método do Simplex modificado por Wolfe pode ser utilizado em programação convexa quadrática (caso do problema proposto) sendo necessário recorrer às condições KKT:

- (1)  $2 - 2x_1 - 2\lambda \leq 0$
- (2)  $x_1 (2 - 2x_1 - 2\lambda) = 0$
- (3)  $3 - 2x_2 - 2\lambda \leq 0$
- (4)  $x_2 (3 - 2x_2 - 2\lambda) = 0$
- (5)  $2x_1 + 2x_2 - 4 \leq 0$
- (6)  $\lambda (2x_1 + 2x_2 - 4) = 0$
- (7)  $x_1, x_2, \lambda \geq 0$

Colocando as condições (1), (3) e (5) na forma de igualdade tem-se:

$$2x_1 + 2\lambda - e_1 = 2$$

$$2x_2 + 2\lambda - e_2 = 3$$

$$2x_1 + 2x_2 + s_1 = 4$$

Atendendo a que:

- $-e_1 = 2 - 2x_1 - 2\lambda$ , deduz-se da condição (2) que o produto  $x_1 e_1 = 0$ .
- $-e_2 = 3 - 2x_2 - 2\lambda$ , deduz-se da condição (4) que o produto  $x_2 e_2 = 0$ .
- $-s_1 = 2x_1 + 2x_2 - 4$ , deduz-se da condição (6) que o produto  $\lambda s_1 = 0$

pode estabelecer-se a restrição de complementaridade  $x_1 e_1 + x_2 e_2 + \lambda s_1 = 0$ .

As condições KKT são equivalentes a :

$$2x_1 + 2\lambda - e_1 = 2$$

$$2x_2 + 2\lambda - e_2 = 3$$

$$2x_1 + 2x_2 + s_1 = 4$$

$$x_1 e_1 + x_2 e_2 + \lambda s_1 = 0 \text{ (restrição de complementaridade)}$$

$$x_1, x_2, \lambda, e_1, e_2, s_1 \geq 0$$

Analisando a restrição de complementaridade verifica-se que não é linear e impõe:

- as variáveis  $e_1, x_1$  não podem ser simultaneamente positivas;



- a variável auxiliar (folga ou excedentária) da restrição “i” e  $\lambda_i$  não podem ser simultaneamente positivas.

O método Simplex modificado por Wolfe recorre ao 1º passo do Método dos 2 Passos considerando a seguinte regra para calcular soluções que satisfaçam a restrição de complementaridade :

- não formar base em que as variáveis complementares  $e_i$  ,  $x_i$  sejam simultaneamente variáveis básicas positivas (na maior parte dos casos se uma é VB a outra não pode entrar para a base);
- não formar base em que a variável auxiliar (folga ou excesso) da restrição “i” e  $\lambda_i$  (que são complementares) sejam simultaneamente variáveis básicas positivas (na maior parte dos casos se uma é VB a outra não pode entrar para a base);

No exemplo proposto, é necessário utilizar variáveis Artificiais nas duas primeiras restrições e Minimizar a sua soma executando o 1º passo do Método dos 2 Passos:

$$2x_1 + 2\lambda - e_1 + A_1 = 2$$

$$2x_2 + 2\lambda - e_2 + A_2 = 3$$

$$2x_1 + 2x_2 + s_1 = 4$$

$$\text{Min } f^a = A_1 + A_2$$

$$A_1, A_2 \geq 0$$

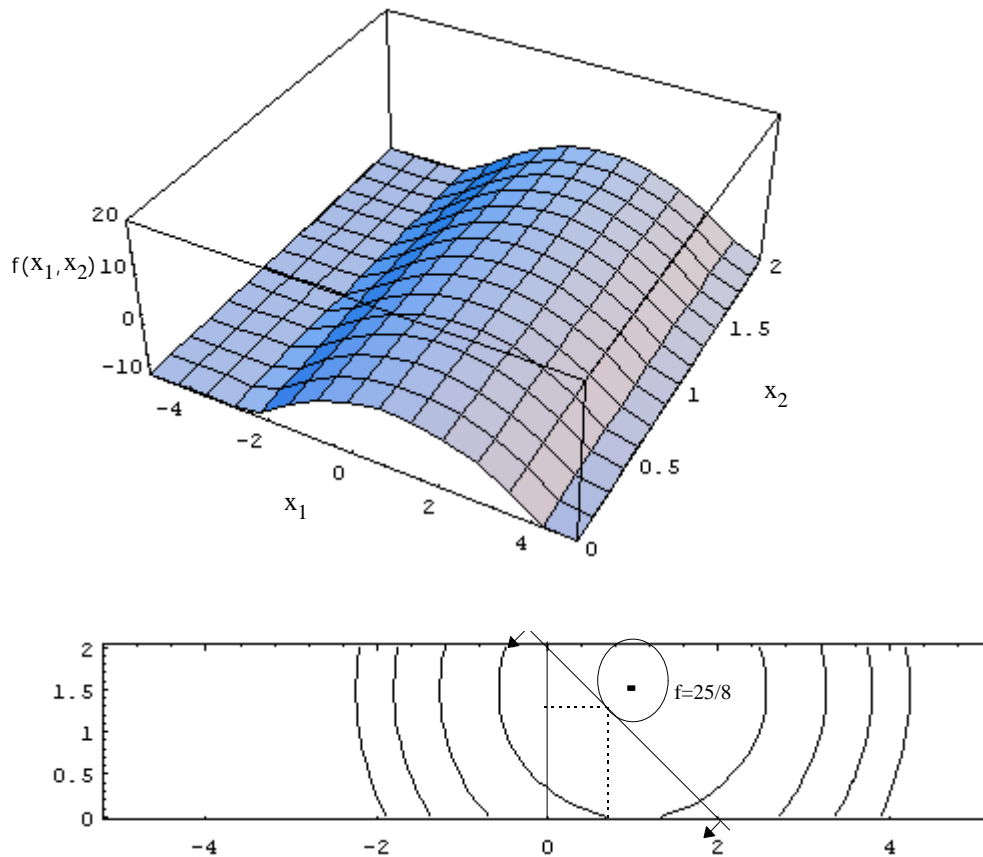
Aplicando o método Simplex modificado por Wolfe tem-se:

VB	$x_1$	$x_2$	$\lambda$	$e_1$	$e_2$	$s_1$	$A_1$	$A_2$	VSM	Obs.
$A_1$	2	0	2	-1	0	0	1	0	2	“ $\lambda$ ” não pode entrar para a base (complementaridade com $s_1$ ). Entra $x_1$ ou $x_2$ .
$A_2$	0	2	2	0	-1	0	0	1	3	
$s_1$	2	2	0	0	0	1	0	0	4	
$-f^a$	0	0	0	0	0	1	1	1	0	
$-f^a$	-2	-2	-4	1	1	0	0	0	-5	
$x_1$	1	0	1	-1/2	0	0	1/2	0	1	“ $\lambda$ ” não pode entrar para a base (complementaridade com $s_1$ ). Entra $x_2$ .
$A_2$	0	2	2	0	-1	0	0	1	3	
$s_1$	0	2	-2	1	0	1	-1	0	2	
$-f^a$	0	-2	-2	0	1	0	1	0	-3	
$x_2$	0	1	-1	1/2	0	1/2	-1/2	0	1	Entra $\lambda$ .
$x_1$	1	0	1	-1/2	0	0	1/2	0	1	
$A_2$	0	0	4	-1	-1	-1	1	1	1	
$-f^a$	0	0	-4	1	1	1	0	0	-1	
$\lambda$	0	0	1	-1/4	-1/4	-1/4	1/4	1/4	1/4	Sol. ótima.
$x_2$	0	1	0	1/4	-1/4	1/4	-1/4	1/4	5/4	
$x_1$	1	0	0	-1/4	1/4	1/4	1/4	-1/4	3/4	
$-f^a$	0	0	0	0	0	0	1	1	0	

Solução Ótima:  $x_1 = 3/4$  ;  $x_2 = 5/4$  ; Max  $f(x_1, x_2) = 25/8$

Nota: “ $\lambda$ ” é a variável dual associada à restrição razão porque  $\lambda s_1 = 0$  (complementaridade das folgas). Neste caso a restrição está saturada.

As figuras seguintes apresentam o gráfico da função proposta, e a projecção horizontal das curvas de nível.



4.6 a.

A Hessiana de  $f(x_1, x_2)$  é a matriz quadrada de ordem 2:

$$H = \begin{bmatrix} \partial^2 f / \partial x_1^2 & \partial^2 f / \partial x_1 x_2 \\ \partial^2 f / \partial x_2 x_1 & \partial^2 f / \partial x_2^2 \end{bmatrix} = \begin{bmatrix} -4 & 4 \\ 4 & -8 \end{bmatrix}$$

$$\begin{vmatrix} H_1 \end{vmatrix} = -4 < 0$$

Matriz H é Definida Negativa

$$\begin{vmatrix} H_2 \end{vmatrix} = 16 > 0 \quad \text{A função é Côncava}$$

O problema é de programação convexa porque:

- a função-objectivo é Côncava e diferenciável
- a função da restrição técnica é convexa e diferenciável ( restrição linear  $\equiv$  função côncava e convexa)

b. Condições KKT:

$$\left\{ \begin{array}{l} \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \leq 0 \\ x_j \left( \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \right) = 0 \\ g_i - b_i \leq 0 \\ \lambda_i (g_i - b_i) = 0 \\ \lambda_i \geq 0 \\ x_j \geq 0 \end{array} \right. \quad \left\{ \begin{array}{l} (1) \quad 15 + 4x_2 - 4x_1 - \lambda(1) \leq 0 \\ (2) \quad 30 + 4x_1 - 8x_2 - \lambda(2) \leq 0 \\ (3) \quad x_1[15 + 4x_2 - 4x_1 - \lambda(1)] = 0 \\ (4) \quad x_2[30 + 4x_1 - 8x_2 - \lambda(2)] = 0 \\ (5) \quad x_1 + 2x_2 - 30 \leq 0 \\ (6) \quad \lambda(x_1 + 2x_2 - 30) = 0 \\ (7) \quad \lambda \geq 0 \\ (8) \quad x_1, x_2 \geq 0 \end{array} \right.$$

Para usar o método Simplex, estabelece-se o sistema de equações:

$$4x_1 - 4x_2 + \lambda - e_1 + A_1 = 15$$

$$-4x_1 + 8x_2 + 2\lambda - e_2 + A_2 = 30$$

$$x_1 + 2x_2 + s_1 = 30$$

$$x_1 e_1 + x_2 e_2 + \lambda s_1 = 0 \quad (\text{restrição de complementaridade})$$

$$\text{Min } f^a = A_1 + A_2$$

$$x_1, x_2, e_1, e_2, s_1, \lambda, A_1, A_2 \geq 0$$



Aplicando o método Simplex modificado por Wolfe tem-se:

VB	$x_1$	$x_2$	$\lambda$	$e_1$	$e_2$	$s_1$	$A_1$	$A_2$	VSM	Obs.
$A_1$	4	-4	1	-1	0	0	1	0	15	Entra $x_2$ (pode porque $e_2$ é VNB)
$A_2$	-4	8	2	0	-1	0	0	1	30	
$s_1$	1	2	0	0	0	1	0	0	30	
$-f^a$	0	0	0	0	0	0	1	1	0	
$-f^a$	0	-4	-3	1	1	0	0	0	-45	
$x_2$	-1/2	1	1/4	0	-1/8	0	0	1/8	15/4	Entra $x_1$ (pode porque $e_1$ é VNB)
$A_1$	2	0	2	-1	-1/2	0	1	1/2	30	Notar que $\lambda$ não é seleccionável pois $s_1$ é VB e não sai da base por troca com $\lambda$ .
$s_1$	2	0	-1/2	0	1/4	1	0	-1/4	45/2	
$-f^a$	-2	0	-2	1	1/2	0	0	1/2	-30	
$x_1$	1	0	-1/4	0	1/8	1/2	0	-1/8	45/4	Entra $\lambda$ (pode porque $s_1$ é VNB)
$x_2$	0	1	1/8	0	-1/16	1/4	0	1/16	75/8	Solução ótima.
$A_1$	0	0	5/2	-1	-3/4	-1	1	3/4	15/2	
$-f^a$	0	0	-5/2	1	3/4	1	0	1/4	-15/2	
$\lambda$	0	0	1	-2/5	-3/10	-2/5	2/5	3/10	3	
$x_1$	1	0	0	-1/10	1/20	2/5	1/10	-1/20	12	
$x_2$	0	1	0	1/20	-1/40	3/10	-1/20	1/40	9	
$-f^a$	0	0	0	0	0	0	1	1	0	

Solução Óptima:  $x_1 = 12$  ;  $x_2 = 9$  ;  $\text{Max } f(x_1, x_2) = 270$

Nota: “ $\lambda$ ” é a variável dual associada à restrição razão porque  $\lambda_1 = 0$  (complementaridade das folgas). Neste caso a restrição está saturada.

As figuras seguintes apresentam o gráfico da função proposta, e a projecção horizontal das curvas de nível.



4.7 a.

A Hessiana de  $f(x_1, x_2)$  é a matriz quadrada de ordem 2:

$$H = \begin{bmatrix} \partial^2 f / \partial x_1^2 & \partial^2 f / \partial x_1 x_2 \\ \partial^2 f / \partial x_2 x_1 & \partial^2 f / \partial x_2^2 \end{bmatrix} = \begin{bmatrix} -1/(x_1+1)^2 & 0 \\ 0 & -2 \end{bmatrix}$$

$$\left| H_1 \right| < 0$$

Matriz H é Definida Negativa

$$\left| H_2 \right| > 0$$

Função Côncava

O problema é de programação convexa porque:

- a função-objectivo é Côncava e diferenciável
- a função da restrição técnica é convexa e diferenciável ( restrição linear  $\equiv$  função côncava e convexa)

b. Condições KKT:

$$\left| \begin{array}{l} \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \leq 0 \\ x_j \left( \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \right) = 0 \\ g_i - b_i \leq 0 \\ \lambda_i (g_i - b_i) = 0 \\ \lambda_i \geq 0 \\ x_j \geq 0 \end{array} \right| \begin{array}{l} (1) \quad 1/(x_1+1) - \lambda(1) \leq 0 \\ (2) \quad -2x_2 - \lambda(2) \leq 0 \\ (3) \quad x_1[1/(x_1+1) - \lambda(1)] = 0 \\ (4) \quad x_2[-2x_2 - \lambda(2)] = 0 \\ (5) \quad x_1 + 2x_2 - 3 \leq 0 \\ (6) \quad \lambda(x_1 + 2x_2 - 3) = 0 \\ (7) \quad \lambda \geq 0 \\ (8) \quad x_1, x_2 \geq 0 \end{array}$$

Verificação das condições KKT no ponto (3, 0);

(1)	$1/(x_1+1) - \lambda(1) \leq 0$	$1/4 - \lambda \leq 0$	$\lambda \geq 1/4$	O.k. condição (7)
(2)	$-2x_2 - \lambda(2) \leq 0$	$-2\lambda \leq 0$	$\lambda \geq 0$	O.k. condição (7)
(3)	$x_1[1/(x_1+1) - \lambda(1)] = 0$	$3[(1/4) - \lambda] = 0$	$\lambda = 1/4$	O.k. condições (1),(2),(3),(7)
(4)	$x_2[-2x_2 - \lambda(2)] = 0$	$0 = 0$		O.k.
(5)	$x_1 + 2x_2 - 3 \leq 0$	$3 + 0 - 3 \leq 0$	$0 \leq 0$	O.k.
(6)	$\lambda(x_1 + 2x_2 - 3) = 0$	$1/4(3-3) = 0$	$0 = 0$	O.k.
(7)	$\lambda \geq 0$			Verificada
(8)	$x_1, x_2 \geq 0$			Verificada

O problema é de programação convexa e as condições KKT verificam-se no ponto (3,0) o que é condição necessária e suficiente para afirmar que (3, 0) é o ponto ótimo.

4.8 Considerando o modelo na forma:

$$\text{Max } [-f(x)] = -2x_1 - x_2^3 - x_3^2$$

$$\text{s.a. } -x_1^2 - 2x_2^2 - x_3^2 \leq -4$$

$$x_1, x_2, x_3 \geq 0$$

as condições KKT são:


$\frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \leq 0$	(1) $-2+2\lambda x_1 \leq 0$ (2) $-3x_2^2 + 4\lambda x_2 \leq 0$ (3) $-2x_3 + 2\lambda x_3 \leq 0$
$x_j \left( \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \right) = 0$	(4) $x_1 (-2+2\lambda x_1) = 0$ (5) $x_2 (-3x_2^2 + 4\lambda x_2) = 0$ (6) $x_3 (-2x_3 + 2\lambda x_3) = 0$
$g_i - b_i \leq 0$	(7) $-x_1^2 - 2x_2^2 - x_3^2 + 4 \leq 0$
$\lambda_i (g_i - b_i) = 0$	(8) $\lambda (-x_1^2 - 2x_2^2 - x_3^2 + 4) = 0$
$\lambda_i \geq 0$	(9) $\lambda \geq 0$
$x_j \geq 0$	(10) $x_1, x_2 \geq 0$

Verificação das condições KKT no ponto (1, 1, 1);

(1) $-2+2\lambda x_1 \leq 0$	$-2+2\lambda \leq 0$	$\lambda \leq 1$	
(2) $-3x_2^2 + 4\lambda x_2 \leq 0$	$-3+4\lambda \leq 0$	$\lambda \leq 4/3$	
(3) $-2x_3 + 2\lambda x_3 \leq 0$	$-2+2\lambda \leq 0$	$\lambda \leq 1$	
(4) $x_1 (-2+2\lambda x_1) = 0$	$-2+2\lambda = 0$	$\lambda = 1$	Contradição nos valores de $\lambda$
(5) $x_2 (-3x_2^2 + 4\lambda x_2) = 0$	$-3+4\lambda = 0$	$\lambda = 3/4$	
(6) $x_3 (-2x_3 + 2\lambda x_3) = 0$	$-2+2\lambda = 0$	$\lambda = 1$	
(7) $-x_1^2 - 2x_2^2 - x_3^2 + 4 \leq 0$			
(8) $\lambda (-x_1^2 - 2x_2^2 - x_3^2 + 4) = 0$			
(9) $\lambda \geq 0$			
(10) $x_1, x_2 \geq 0$			

As condições KKT não se verificam no ponto (1, 1, 1) pelo que o ponto proposto não é o ponto-óptimo (notar que o problema é de programação convexa).

4.9 No intervalo  $[a, b]$  tem-se, no óptimo,  $f'(a) \leq 0$ , ou  $f'(x) = 0$  ou  $f'(b) \geq 0$  como se pode verificar nas figuras seguintes:



O modelo proposto é:

Max  $f(x)$

$$\text{s.a.} \quad -x \leq -a$$

$$x \leq b$$

ou seja:

Max  $f(x)$

$$\text{s.a.} \quad -x + s_1 + a = 0$$

$$x + s_2 - b = 0$$

$$s_1, s_2 \geq 0$$

A função Lagrangeana é:

$$L = f(x) - \lambda_1 (-x + s_1 + a) - \lambda_2 (x + s_2 - b)$$

Não havendo condição de não negatividade para a variável “ $x$ ” têm-se as condições de 1ª ordem para extremo:

- $L'(x) = 0$  ou seja  $f'(x) + \lambda_1 - \lambda_2 = 0$
- $L'(s_1) = -\lambda_1 \leq 0$  e  $s_1 [L'(s_1)] = -\lambda_1 s_1 = 0$  (1) (porque  $s_1$  é variável não negativa)
- $L'(s_2) = -\lambda_2 \leq 0$  e  $s_2 [L'(s_2)] = -\lambda_2 s_2 = 0$  (2) (porque  $s_2$  é variável não negativa)

Sendo  $-s_1 = -x + a$ , substituindo em (1) fica:  $\lambda_1 (-x + a) = 0$

Sendo  $-s_2 = x - b$ , substituindo em (2) fica:  $\lambda_2 (x - b) = 0$

As condições obtidas são:

- (1)  $f'(x) + \lambda_1 - \lambda_2 = 0$
- (2)  $\lambda_1 (-x + a) = 0$
- (3)  $\lambda_2 (x - b) = 0$
- (4)  $\lambda_1 \geq 0$
- (5)  $\lambda_2 \geq 0$

Resta agora verificar se estas condições conduzem às soluções possíveis anteriormente obtidas geometricamente:

	$\lambda_1$	$\lambda_2$	Condição	Solução
1º caso	0	0		$f'(x) = 0 \leftarrow$
2º caso	$> 0$	0	$-x + a = 0 \Rightarrow x = a \Rightarrow$	$f'(x) + \lambda_1 = 0$ $f'(a) = -\lambda_1 \leq 0 \leftarrow$
3º caso	0	$> 0$	$x - b = 0 \Rightarrow x = b \Rightarrow$	$f'(x) - \lambda_2 = 0$ $f'(b) = \lambda_2 \geq 0 \leftarrow$
4º caso	$> 0$	$> 0$	$-x + a = 0 \Rightarrow x = a \Rightarrow$ $x - b = 0 \Rightarrow x = b \Rightarrow$	Impossível porque $a \neq b$

Dado que as restrições são lineares se a função  $f(x)$  for Côncava então a solução ótima ocorre no ponto “a” ou “b” ou em ponto interior do intervalo.

4.10 O problema equivalente é:

$$\begin{aligned} \text{Max } [-f(x_1, x_2)] &= -(x_1 - 1)^2 - (x_2 - 2)^2 + 3(x_1 + x_2) \\ \text{s.a. } &4x_1 + x_2 \leq 20 \\ &x_1 + 4x_2 \leq 20 \\ &x_1, x_2 \geq 0 \end{aligned}$$

As condições KKT são:

$\frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \leq 0$	(1) $-2x_1 + 5 - 4\lambda_1 - \lambda_2 \leq 0$
$x_j \left( \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \right) = 0$	(2) $-2x_2 + 7 - \lambda_1 - 4\lambda_2 \leq 0$
$g_i - b_i \leq 0$	(3) $x_1 (-2x_1 + 5 - 4\lambda_1 - \lambda_2) = 0$
$\lambda_i (g_i - b_i) = 0$	(4) $x_2 (-2x_2 + 7 - \lambda_1 - 4\lambda_2) = 0$
$\lambda_i \geq 0$	(5) $4x_1 + x_2 - 20 \leq 0$
$x_j \geq 0$	(6) $x_1 + 4x_2 - 20 \leq 0$
	(7) $\lambda_1 (4x_1 + x_2 - 20) = 0$
	(8) $\lambda_2 (x_1 + 4x_2 - 20) = 0$
	(9) $\lambda_1, \lambda_2 \geq 0$
	(10) $x_1, x_2 \geq 0$

Se o ponto ótimo não pertence à fronteira do convexo de soluções então tem-se:

- em (7)  $4x_1 + x_2 < 20$  pelo que  $\lambda_1$  é obrigatoriamente nulo porque é complementar da variável de folga.
- em (8) deduz-se que  $\lambda_2 = 0$  pela mesma razão.



Com  $\lambda_1 = \lambda_2 = 0$  as condições KKT ficam reduzidas a:

- (1)  $-2x_1 + 5 \leq 0$
- (2)  $-2x_2 + 7 \leq 0$
- (3)  $x_1 (-2x_1 + 5) = 0$
- (4)  $x_2 (-2x_2 + 7) = 0$
- (5)  $4x_1 + x_2 - 20 \leq 0$
- (6)  $x_1 + 4x_2 - 20 \leq 0$
- (10)  $x_1, x_2 \geq 0$


De (3) deduz-se  $x_1=0$  ou  $(5-2x_1) = 0$ . Para  $x_1 = 0$  a condição (1) é violada pelo que  $(5-2x_1) = 0$  ou seja  $x_1=5/2$ .

De (4) deduz-se  $x_2=0$  ou  $(-2x_2+7) = 0$ . Para  $x_2 = 0$  a condição (2) é violada pelo que  $(-2x_2+7) = 0$  ou seja  $x_2=7/2$ .


Com  $x_1 = 5/2$  e  $x_2 = 7/2$  todas as condições KKT são satisfeitas.

A função maximizada é  $-f=5x_1 - x_1^2 - x_2^2 + 7x_2 - 5$  que é côncava. As restrições técnicas são lineares pelo que o problema é de Programação Convexa situação em que as condições KKT são condição necessária e suficiente para  $x_1 = 5/2$  e  $x_2 = 7/2$  ser garantidamente o ponto ótimo onde a função atinge o seu mínimo condicionado (Min  $f = -13.5$ ).

b.



A figura seguinte apresenta o gráfico da função:



4.11 O problema equivalente é:

$$\begin{aligned} \text{Max } [-f(x_1, x_2)] &= -x_1^2 - 2x_1 - 2x_1x_2 - 4x_2^2 \\ \text{s.a. } -2x_1 - x_2 &\leq -10 \\ -x_1 - 2x_2 &\leq -10 \\ x_1, x_2 &\geq 0 \end{aligned}$$

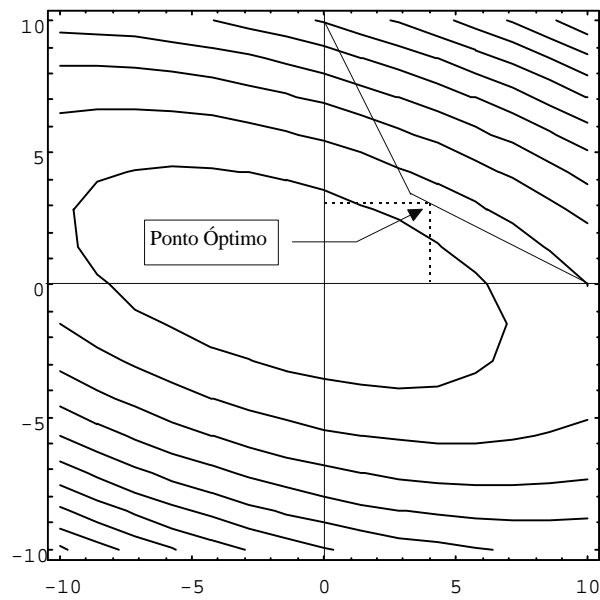

As condições KKT são:

$\frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \leq 0$	(1) $-2x_1 - 2 - 2x_2 + 2\lambda_1 + \lambda_2 \leq 0$
$x_j \left( \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \right) = 0$	(2) $-2x_1 - 8x_2 + \lambda_1 + 2\lambda_2 \leq 0$
$g_i - b_i \leq 0$	(3) $x_1 (-2x_1 - 2 - 2x_2 + 2\lambda_1 + \lambda_2) = 0$
$\lambda_i (g_i - b_i) = 0$	(4) $x_2 (-2x_1 - 8x_2 + \lambda_1 + 2\lambda_2) = 0$
$\lambda_i \geq 0$	(5) $-2x_1 - x_2 + 10 \leq 0$
$x_j \geq 0$	(6) $-x_1 - 2x_2 + 10 \leq 0$
	(7) $\lambda_1 (-2x_1 - x_2 + 10) = 0$
	(8) $\lambda_2 (-x_1 - 2x_2 + 10) = 0$
	(9) $\lambda_1, \lambda_2 \geq 0$
	(10) $x_1, x_2 \geq 0$



Solução Ótima:  $x_1 = 4$  ;  $x_2 = 3$  ; Max  $f(x_1, x_2) = 84$

As figuras seguintes apresentam o gráfico da função proposta, e a projecção horizontal das curvas de nível.



4.12 O problema equivalente é:

$$\begin{aligned} \text{Max } [-f(x_1, x_2)] &= -2x_1^2 - x_2^2 \\ \text{s.a. } x_1 + x_2 &\leq 10 \\ -x_1 - x_2 &\leq -10 \\ x_1, x_2 &\geq 0 \end{aligned}$$

a. As condições KKT são:

$$\left\{ \begin{array}{l} \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \leq 0 \\ x_j \left( \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \right) = 0 \\ g_i - b_i \leq 0 \\ \lambda_i (g_i - b_i) = 0 \\ \lambda_i \geq 0 \\ x_j \geq 0 \end{array} \right. \quad \left\{ \begin{array}{l} (1) \quad -4x_1 - \lambda_1 + \lambda_2 \leq 0 \\ (2) \quad -2x_2 - \lambda_1 + \lambda_2 \leq 0 \\ (3) \quad x_1 (-4x_1 - \lambda_1 + \lambda_2) = 0 \\ (4) \quad x_2 (-2x_2 - \lambda_1 + \lambda_2) = 0 \\ (5) \quad x_1 + x_2 - 10 \leq 0 \\ (6) \quad -x_1 - x_2 + 10 \leq 0 \\ (7) \quad \lambda_1 (x_1 + x_2 - 10) = 0 \\ (8) \quad \lambda_2 (-x_1 - x_2 + 10) = 0 \\ (9) \quad \lambda_1, \lambda_2 \geq 0 \\ (10) \quad x_1, x_2 \geq 0 \end{array} \right.$$

No ponto (10/3, 20/3) todas as condições KKT são satisfeitas.

O problema é de programação convexa pelo que aquele ponto é ótimo.

b. Colocando as condições (1), (2), (5) e (6) na forma padrão Simplex tem-se:

$$\begin{aligned} -4x_1 - \lambda_1 + \lambda_2 + s_1 &= 0 \\ -2x_2 - \lambda_1 + \lambda_2 + s_2 &= 0 \\ x_1 + x_2 + s_3 &= 10 \\ x_1 + x_2 - e_1 &= 10 \\ \text{com } x_1, x_2, \lambda_1, \lambda_2, s_1, s_2, s_3, e_1 &\geq 0 \end{aligned}$$

Atendendo ao valor das variáveis auxiliares estabelece-se a restrição de complementaridade:

$$x_1 s_1 + x_2 s_2 + \lambda_1 s_3 + \lambda_2 e_1 = 0$$

Para utilizar o método Simplex é necessário utilizar uma variável Artificial na 4ª igualdade e Minimizar a função artificial  $f^a(A_1) = A_1$  pelo que se tem:

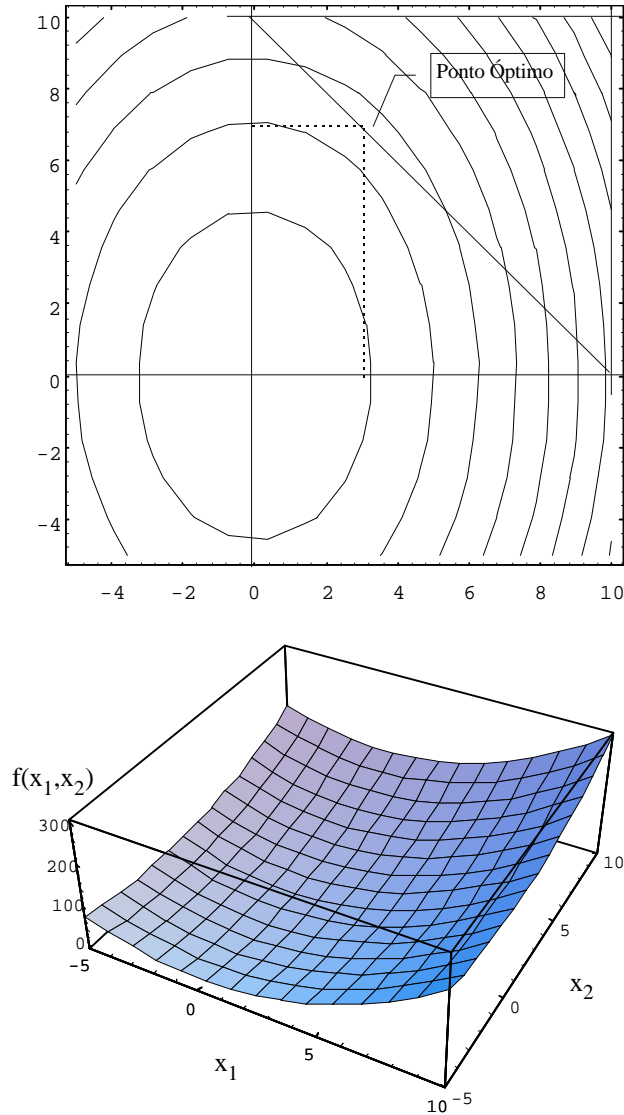
$$\begin{aligned} \text{Min } f^a &= A_1 \\ -4x_1 - \lambda_1 + \lambda_2 + s_1 &= 0 \\ -2x_2 - \lambda_1 + \lambda_2 + s_2 &= 0 \\ x_1 + x_2 + s_3 &= 10 \\ x_1 + x_2 - e_1 + A_1 &= 10 \\ \text{com } x_1, x_2, \lambda_1, \lambda_2, s_1, s_2, s_3, e_1, A_1 &\geq 0 \end{aligned}$$

Aplicando o método Simplex modificado por Wolfe:

VB	$x_1$	$x_2$	$\lambda_1$	$\lambda_2$	$s_1$	$s_2$	$s_3$	$e_1$	$A_1$	VSM	Obs.
$s_1$	-4	0	-1	1	1	0	0	0	0	0	Entra $x_1$ pois pode sair a variável complementar $s_1$ . Notar que $a_{11}$ tem coeficiente negativo e $\theta_{\min} = 0$ .
$s_2$	0	-2	-1	1	0	1	0	0	0	0	
$s_3$	1	1	0	0	0	0	1	0	0	10	
$A_1$	1	1	0	0	0	0	0	-1	1	10	
$-f^a$	0	0	0	0	0	0	0	0	1	0	
$-f^a$	-1	-1	0	0	0	0	0	1	0	-10	
$x_1$	1	0	1/4	-1/4	-1/4	0	0	0	0	0	Entra $x_2$ pois pode sair a variável complementar $s_2$ . Notar que $a_{22}$ tem coeficiente negativo e $\theta_{\min} = 0$ .
$s_2$	0	-2	-1	1	0	1	0	0	0	0	
$s_3$	0	1	-1/4	1/4	1/4	0	1	0	0	10	
$A_1$	0	1	-1/4	1/4	1/4	0	0	-1	1	10	
$-f^a$	0	-1	1/4	-1/4	-1/4	0	0	1	0	-10	
$x_2$	0	1	1/2	-1/2	0	-1/2	0	0	0	0	Entra $\lambda_2$ (pode entrar porque a variável complementar é VNB). Sai $A_1$ .
$x_1$	1	0	1/4	-1/4	-1/4	0	0	0	0	0	
$s_3$	0	0	-3/4	3/4	1/4	1/2	1	0	0	10	
$A_1$	0	0	-3/4	3/4	1/4	1/2	0	-1	1	10	
$-f^a$	0	0	3/4	-3/4	-1/4	-1/2	0	1	0	-10	
$\lambda_2$	0	0	-1	1	1/3	2/3	0	-4/3	4/3	40/3	Solução óptima
$x_2$	0	1	0	0	1/6	-1/6	0	-2/3	2/3	20/3	
$x_1$	1	0	0	0	-1/6	1/6	0	-1/3	1/3	10/3	
$s_3$	0	0	-3/2	0	0	0	1	1	-1	0	
$-f^a$	0	0	0	0	0	0	0	0	1	0	

Solução Óptima:  $x_1 = 10/3$  ;  $x_2 = 20/3$  ; Max  $f(x_1, x_2) = 66 + 2/3$

As figuras seguintes apresentam a projecção horizontal das curvas de nível e o gráfico da função proposta.



4.13 A função Lagrangeana é :

$$L = 3x_1 + x_2 - \lambda_1 (x_1^2 + x_2^2 + s_1 - 5) - \lambda_2 (x_1 - x_2 + s_2 - 1).$$

Tendo em atenção que só as variáveis de folga utilizadas são não negativas, as condições de primeira ordem para extremo são as seguintes:

- $3 - 2\lambda_1 x_1 - \lambda_2 = 0$  (derivada parcial em ordem a  $x_1$ )
- $1 - 2\lambda_1 x_2 + \lambda_2 = 0$  (derivada parcial em ordem a  $x_2$ )
- $-x_1^2 - x_2^2 - s_1 + 5 = 0$  (derivada parcial em ordem a  $\lambda_1$ )
- $-x_1 + x_2 - s_2 + 1 = 0$  (derivada parcial em ordem a  $\lambda_2$ )
- $-\lambda_1 \leq 0$  (derivada parcial em ordem a  $s_1$ )
- $-\lambda_1 s_1 = 0$  (complementaridade)
- $-\lambda_2 \leq 0$  (em ordem a  $s_2$ )
- $-\lambda_2 s_2 = 0$  (complementaridade)

Substituindo o valor das variáveis de folga, têm-se as condições KKT :

$$(1) \quad 3 - 2\lambda_1 x_1 - \lambda_2 = 0$$

$$(2) \quad 1 - 2\lambda_1 x_2 + \lambda_2 = 0$$

$$(3) \quad x_1^2 + x_2^2 - 5 \leq 0$$

$$(4) \quad \lambda_1 (x_1^2 + x_2^2 - 5) = 0$$

$$(5) \quad x_1 - x_2 - 1 \leq 0$$

$$(6) \quad \lambda_2 (x_1 - x_2 - 1) = 0$$

$$(7) \quad \lambda_1, \lambda_2 \geq 0$$

### Estudo:

1ª Hipótese :  $\lambda_1 = 0$

Da condição (2) tem-se  $\lambda_2 = -1$  que não é admissível, concluindo-se que  $\lambda_1 \neq 0$

2ª Hipótese :  $\lambda_1 \neq 0$  ;  $\lambda_2 = 0$

Da condição (4) tem-se  $x_1^2 + x_2^2 = 5$

Da condição (1) tem-se  $(3 - 2\lambda_1 x_1) = 0$  ou seja  $x_1 = 3/2\lambda_1$

Da condição (2) tem-se  $(1 - 2\lambda_1 x_2) = 0$  ou seja  $x_2 = 1/2\lambda_1$

Substituindo “ $x_1$ ” e “ $x_2$ ” por estes valores em  $x_1^2 + x_2^2 = 5$  tem-se  $\lambda_1 = \frac{2}{\sqrt{2}}$  (porque  $\lambda_1 \geq 0$ )

O valor de  $x_1 = 3/2\lambda_1$  é então  $x_1 = \frac{3}{\sqrt{2}}$  e  $x_2 = \frac{1}{\sqrt{2}}$

Estes valores das variáveis não verificam a condição (5) pelo que se conclui que  $\lambda_2$  é diferente de zero.

3ª Hipótese :  $\lambda_1 \neq 0$  ;  $\lambda_2 \neq 0$

Das condições (4) e (6) tem-se o sistema de equações:

$$x_1^2 + x_2^2 = 5$$


$$x_1 - x_2 = 1$$

com 2 soluções :  $x_1 = -1$  ;  $x_2 = -2$  e  $x_1 = 2$  ;  $x_2 = 1$ .

Para  $x_1 = -1$  ;  $x_2 = -2$  obtém-se em (1) e (2) :  $\lambda_1 = -2/3$  que não é admissível.

A solução  $x_1 = 2$  ;  $x_2 = 1$  permite calcular  $\lambda_1 = 2/3$  ;  $\lambda_2 = 1/3$  no mesmo sistema de equações

Com  $x_1 = 2$  ;  $x_2 = 1$  ;  $\lambda_1 = 2/3$  ;  $\lambda_2 = 1/3$  **todas** as condições KKT são observadas pelo que se conclui que o valor máximo da função-objectivo é 7. A figura seguinte permite verificar o exposto:





4.14 Se  $x_1 > 1$  então  $(1 - x_1)^3 < 0$  o que conduziria a  $x_2 < 0$ . Conclui-se assim que o valor óptimo de  $f(x)$  não pode exceder 1.

Dado que  $x_1 = 1$  ;  $x_2 = 0$  é admissível , o ponto com estas coordenadas deve ser a solução óptima.

Uma das condições KKT é:


$$1 - 3\lambda(1 - x_1)^2 \leq 0$$

Para  $x_1 = 1$  e  $x_2 = 0$  tem-se por substituição :


$$1 - 3\lambda(0)^2 \leq 0$$

$$1 \leq 0 \text{ ( não satisfaz )}$$

Conclusão : A condição KKT testada “falha” no ponto óptimo.



A figura seguinte apresenta as curvas de nível da função de restrição:




As condições KKT podem “falhar” no ponto-óptimo quando não forem linearmente independentes os gradientes associados às restrições saturadas.

No ponto  $(1,0)$  a restrição técnica  $x_2 - (1-x_1)^3 \leq 0$  e a restrição lógica  $-x_2 \leq 0$  estão saturadas ou seja verificam-se como igualdades.

Neste ponto os valores dos gradientes destas restrições são:

$$\nabla(x_2 - (1-x_1)^3) = \begin{bmatrix} 3(1-x_1)^2 \\ 1 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

$$\nabla(-x_2) = \begin{bmatrix} 0 \\ -1 \end{bmatrix}$$



Dado que  $[0 \ 1]^T + [0 \ -1]^T = [0 \ 0]^T$  estes gradientes não são linearmente independentes.

Tenha-se então em atenção que:

**“Sendo  $X^*$  a solução ótima de um PNL, se os gradientes das restrições saturadas (técnicas e lógicas) formarem um conjunto de vectores linearmente independentes, verificam-se as condições KKT”.**

**“Se o espaço de solução for definido exclusivamente por restrições lineares as condições KKT vigoram sempre no ótimo”.**

#### 4.15 Resumo do método de Lemke:

- Ambiente : Programação quadrática
- Finalidade : Cálculo da solução das condições KKT
- Forma do modelo para estabelecer as condições KKT:

$$\begin{aligned} & \text{Max } f(x) \\ & \text{s.a. } AX \leq B \\ & X \geq 0 \end{aligned}$$

Se o objectivo é Minimizar, maximizar a função simétrica.

Se uma restrição é do tipo “ $\leq$ ”, passá-la a “ $\geq$ ” multiplicando por “-1”.

Se uma restrição é do tipo “=”, substituí-la por duas restrições: uma do tipo “ $\geq$ ” e outra do tipo “ $\leq$ ”.

- Técnica de cálculo : método Simplex modificado por Lemke
- Descrição

1. Organizar o seguinte sistema de equações a partir das condições KKT:

$$\begin{cases} \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} + E_j = 0 \\ AX + S_i = B \\ E_j, S_i \geq 0 \end{cases}$$

em que:

$E_j$  = variável de folga na condição associada à derivada parcial em ordem a  $x_j$

A = matriz tecnológica

$S_i$  = variável de folga da restrição técnica “i”

B = vector-coluna dos segundos membros das restrições técnicas

2. Acrescentar aos segundos membros das equações precedentes a variável auxiliar “ $\alpha$ ” ficando o sistema de equações:

$$\left\{ \begin{array}{l} \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \mathbf{l}_i \frac{\nabla g_i}{\nabla x_j} + E_j - \mathbf{a} = 0 \\ \mathbf{A}\mathbf{X} + \mathbf{S}_i - \mathbf{a} = \mathbf{B} \\ \mathbf{a} \geq 0 \end{array} \right.$$

As equações obtidas em 1. (forma-padrão do Simplex) são satisfeitas se e só se  $\alpha=0$ . O recurso a esta variável é assim a forma engenhosa apresentada por Lemke para cálculo da solução das condições KKT. Recorrendo ao método Simplex, procura-se por combinação linear uma solução em que a variável “ $\alpha$ ” seja nula e as restantes variáveis tenham valor não negativo garantindo a satisfação da restrição de complementaridade:

$$x_j E_j + \mathbf{I}_i S_i = 0$$

Para tal adoptam-se as seguintes regras para o processo iterativo:

#### 1ª Iteração

- *Entra* para a base a variável “ $\alpha$ ”.
- *Sai* da base a variável com valor negativo de maior valor absoluto

#### Restantes Iterações

- *Entra* para a base a variável complementar da que acabou de sair da base.
- *Sai* da base a variável associada ao valor “ $\theta_{\min}$ ” usual em Simplex

#### Regra de Paragem

- O processo iterativo termina se “ $\alpha$ ” é VNB (valor nulo) ou não é possível obter “ $\theta_{\min} \geq 0$ ”.

No primeiro caso ( $\alpha = 0$ ) *há solução* para as condições KKT enquanto no segundo o problema *não tem solução*.

4.16 As condições KKT são:

- (1)  $2 - 2x_1 - 2\lambda \leq 0$
- (2)  $x_1 (2 - 2x_1 - 2\lambda) = 0$
- (3)  $3 - 2x_2 - 2\lambda \leq 0$
- (4)  $x_2 (3 - 2x_2 - 2\lambda) = 0$
- (5)  $2x_1 + 2x_2 - 4 \leq 0$
- (6)  $\lambda (2x_1 + 2x_2 - 4) = 0$
- (7)  $x_1, x_2, \lambda \geq 0$

O sistema de equações de Lemke é formado a partir das condições (1), (3) e (5):

$$\left\{ \begin{array}{l} -2x_1 - 2\lambda + e_1 - \alpha = -2 \\ 3 - 2x_2 - 2\lambda + e_2 - \alpha = -3 \\ 2x_1 + 2x_2 + s_1 = 4 \end{array} \right.$$

Recorrendo ao método Simplex tem-se:

VB	$x_1$	$x_2$	$\lambda$	$e_1$	$e_2$	$s_1$	$\alpha$	VSM	Obs.
$e_1$	-2	0	-2	1	0	0	-1	-2	Entra $\alpha$ .
$e_2$	0	-2	-2	0	1	0	-1	-3	Sai $e_2$
$s_1$	2	2	0	0	0	1	-1	4	
$\alpha$	0	2	2	0	-1	0	1	3	Sai $e_2 \Rightarrow$ Entra $x_2$
$e_1$	-2	2	0	1	-1	0	0	1	Sai $e_1$
$s_1$	2	4	2	0	-1	1	0	7	
$x_2$	-1	1	0	1/2	-1/2	0	0	1/2	Sai $e_1 \Rightarrow$ Entra $x_1$
$\alpha$	2	0	2	-1	0	0	1	2	Sai $s_1$
$s_1$	6	0	2	-2	1	1	0	5	
$x_1$	1	0	1/3	-1/3	1/6	1/6	0	5/6	Sai $s_1 \Rightarrow$ Entra $\lambda$
$x_2$	0	1	1/3	1/6	-1/3	1/6	0	4/3	Sai $\alpha$
$\alpha$	0	0	4/3	-1/3	-1/3	-1/3	1	1/3	
$\lambda$	0	0	1	-1/4	-1/4	-1/4	3/4	1/4	Solução óptima pois " $\alpha$ " é VNB
$x_1$	1	0	0	-1/4	1/4	1/4	-1/4	3/4	
$x_2$	0	1	0	1/4	-1/4	1/4	-1/4	5/4	

Solução Óptima:  $x_1 = 3/4$  ;  $x_2 = 5/4$  ; Max  $f(x_1, x_2) = 25/8$

4.17

Condições KKT:

$$\begin{cases}
 \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \mathbf{I}_i \frac{\nabla g_i}{\nabla x_j} \leq 0 & (1) \quad 15 + 4x_2 - 4x_1 - \lambda(1) \leq 0 \\
 x_j \left( \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \mathbf{I}_i \frac{\nabla g_i}{\nabla x_j} \right) = 0 & (2) \quad 30 + 4x_1 - 8x_2 - \lambda(2) \leq 0 \\
 g_i - b_i \leq 0 & (3) \quad x_1[15 + 4x_2 - 4x_1 - \lambda(1)] = 0 \\
 \mathbf{I}_i (g_i - b_i) = 0 & (4) \quad x_2[30 + 4x_1 - 8x_2 - \lambda(2)] = 0 \\
 \mathbf{I}_i \geq 0 & (5) \quad x_1 + 2x_2 - 30 \leq 0 \\
 x_j \geq 0 & (6) \quad \lambda(x_1 + 2x_2 - 30) = 0 \\
 & (7) \quad \lambda \geq 0 \\
 & (8) \quad x_1, x_2 \geq 0
 \end{cases}$$

O sistema de equações de Lemke é formado a partir das condições (1), (2) e (5):

$$\begin{cases}
 -4x_1 + 4x_2 - \lambda + e_1 - \alpha = -15 \\
 4x_1 - 8x_2 - 2\lambda + e_2 - \alpha = -30 \\
 x_1 + 2x_2 + s_1 - \alpha = 30
 \end{cases}$$

Recorrendo ao método Simplex tem-se:

VB	$x_1$	$x_2$	$\lambda$	$e_1$	$e_2$	$s_1$	$\alpha$	VSM	Obs.
$e_1$	-4	4	-1	1	0	0	-1	-15	Entra $\alpha$ .
$e_2$	4	-8	-2	0	1	0	-1	-30	Sai $e_2$
$s_1$	1	2	0	0	0	1	-1	30	
$\alpha$	-4	8	2	0	-1	0	1	30	Saiu $e_2 \Rightarrow$ Entra $x_2$
$e_1$	-8	12	1	1	-1	0	0	15	Sai $e_1$
$s_1$	-3	10	2	0	-1	1	0	60	
$x_2$	-2/3	1	1/12	1/12	-1/12	0	0	5/4	Saiu $e_1 \Rightarrow$ Entra $x_1$
$\alpha$	4/3	0	4/3	-2/3	-1/3	0	1	20	Sai $s_1$
$s_1$	11/3	0	7/6	-5/4	1/6	1	0	95/2	
$x_1$	1	0	7/22	-5/22	-1/22	3/11	0	285/22	Saiu $s_1 \Rightarrow$ Entra $\lambda$
$x_2$	0	1	13/44	-3/44	-5/44	2/11	0	435/44	Sai $\alpha$
$\alpha$	0	0	10/11	-4/11	-3/4	-4/11	1	30/11	
$\lambda$	0	0	1	-2/5	-3/10	-2/5	11/10	3	Solução óptima pois " $\alpha$ " é
$x_1$	1	0	0	-1/10	1/20	2/5	-7/20	12	VNB
$x_2$	0	1	0	1/20	-1/40	3/10	-13/40	9	

Solução Óptima:  $x_1 = 12$  ;  $x_2 = 9$  ; Max  $f(x_1, x_2) = 270$

4.18 O problema equivalente é:

$$\begin{aligned} \text{Max } [-f(x_1, x_2)] &= -x_1^2 - 2x_1 - 2x_1x_2 - 4x_2^2 \\ \text{s.a. } -2x_1 - x_2 &\leq -10 \\ -x_1 - 2x_2 &\leq -10 \\ x_1, x_2 &\geq 0 \end{aligned}$$

As condições KKT são:

$$\left\{ \begin{array}{l} \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \leq 0 \\ x_j \left( \frac{\nabla f}{\nabla x_j} - \sum_{i=1}^m \lambda_i \frac{\nabla g_i}{\nabla x_j} \right) = 0 \\ g_i - b_i \leq 0 \\ \lambda_i (g_i - b_i) = 0 \\ \lambda_i \geq 0 \\ x_j \geq 0 \end{array} \right. \quad \left\{ \begin{array}{l} (1) \quad -2x_1 - 2 - 2x_2 + 2\lambda_1 + \lambda_2 \leq 0 \\ (2) \quad -2x_1 - 8x_2 + \lambda_1 + 2\lambda_2 \leq 0 \\ (3) \quad x_1 (-2x_1 - 2 - 2x_2 + 2\lambda_1 + \lambda_2) = 0 \\ (4) \quad x_2 (-2x_1 - 8x_2 + \lambda_1 + 2\lambda_2) = 0 \\ (5) \quad -2x_1 - x_2 + 10 \leq 0 \\ (6) \quad -x_1 - 2x_2 + 10 \leq 0 \\ (7) \quad \lambda_1 (-2x_1 - x_2 + 10) = 0 \\ (8) \quad \lambda_2 (-x_1 - 2x_2 + 10) = 0 \\ (9) \quad \lambda_1, \lambda_2 \geq 0 \\ (10) \quad x_1, x_2 \geq 0 \end{array} \right.$$

O sistema de equações de Lemke é formado a partir das condições (1), (2) (5) e (6):

$$\begin{array}{rcl}
 -2x_1 - 2x_2 + 2\lambda_1 + \lambda_2 + e_1 - \alpha & = & 2 \\
 -2x_1 - 8x_2 + \lambda_1 + 2\lambda_2 + e_2 - \alpha & = & 0 \\
 -2x_1 - x_2 + s & & -10 \\
 -x_1 - 2x_2 + s_1 - \alpha & = & 10
 \end{array}$$

Recorrendo ao método Simplex tem-se:

VB	$x_1$	$x_2$	$\lambda_1$	$\lambda_2$	$e_1$	$e_2$	$s_1$	$s_2$	$\alpha$	VSM	Obs.
$e_1$	-2	-2	2	1	1	0	0	0	-1	2	Entra $\alpha$
$e_2$	-2	-8	1	2	0	1	0	0	-1	0	Sai $s_1$ (ou $s_2$ )
$s_1$	-2	-1	0	0	0	0	1	0	-1	-10	
$s_2$	-1	-2	0	0	0	0	0	1	-1	-10	
$\alpha$	2	1	0	0	0	0	-1	0	1	10	Saiu $s_1 \Rightarrow$ Entra $\lambda_1$
$e_1$	0	-1	2	1	1	0	-1	0	0	12	Sai $e_1$
$e_2$	0	-7	1	2	0	1	-1	0	0	10	
$s_2$	1	-1	0	0	0	0	-1	1	0	0	
$\lambda_1$	0	-1/2	1	1/2	1/2	0	-1/2	0	0	6	Saiu $e_1 \Rightarrow$ Entra $x_1$
$\alpha$	2	1	0	0	0	0	-1	0	1	10	Sai $s_2$
$e_2$	0	-13/2	0	3/2	-1/2	1	-1/2	0	0	4	
$s_2$	1	-1	0	0	0	0	-1	1	0	0	
$x_1$	1	-1	0	0	0	0	-1	1	0	0	Saiu $s_2 \Rightarrow$ Entra $\lambda_2$
$\lambda_1$	0	-1/2	1	1/2	1/2	0	-1/2	0	0	6	Sai $e_2$
$\alpha$	0	3	0	0	0	0	1	-2	1	10	
$e_2$	0	-13/2	0	3/2	-1/2	1	-1/2	0	0	4	
$\lambda_2$	0	-19/3	0	1	-1/3	2/3	-1/3	0	0	8/3	Saiu $e_2 \Rightarrow$ Entra $x_2$
$x_1$	1	-1	0	0	0	0	-1	1	0	0	Sai $\lambda_1$
$\lambda_1$	0	5/3	1	0	2/3	-1/3	-1/3	0	0	14/3	
$\alpha$	0	3	0	0	0	0	1	-2	1	10	
$x_2$	0	1	3/5	0	2/5	-1/5	-1/5	0	0	14/5	Saiu $\lambda_1 \Rightarrow$ Entra $s_1$
$\lambda_2$	0	0	13/5	1	7/5	-1/5	-6/5	0	0	74/5	Sai $\alpha$
$x_1$	1	0	3/5	0	2/5	-1/5	-6/5	1	0	14/5	
$\alpha$	0	0	-9/5	0	-6/5	3/5	8/5	-2	1	8/5	

• • • • • • • • • •

VB	$x_1$	$x_2$	$\lambda_1$	$\lambda_2$	$e_1$	$e_2$	$s_1$	$s_2$	$\alpha$	VSM	Obs.
$s_1$	0	0	-9/8	0	-3/4	3/8	1	-5/4	5/8	1	Solução óptima pois “ $\alpha$ ” é VNB
$x_2$	0	1	3/8	0	1/4	-1/8	0	-1/4	1/8	3	
$\lambda_2$	0	0	5/4	1	1/2	1/4	0	-3/2	3/4	16	
$x_1$	1	0	-3/4	0	-1/2	1/4	0	-1/2	3/4	4	

Solução Óptima:  $x_1 = 4$  ;  $x_2 = 3$  ; Max  $f(x_1, x_2) = 84$

5.

5.1 Considere-se o problema de programação convexa:

$$\text{Max } f(X)$$

$$\text{s.a. } AX \leq B$$

$$X \geq 0$$

em que  $X = [x_1, x_2, \dots, x_n]^T$ ,  $f(X)$  é a função-objectivo não linear,  $A_{m \times n}$  é a matriz tecnológica e  $B$  é o vector-coluna dos segundos membros das restrições técnicas que são lineares.

Sendo  $X_0$  um ponto-tentativa inicial, o valor de  $f(X)$  no intervalo de  $X_0$  a  $X$  é a série de Taylor em potências de  $(X-X_0)$ :

$$f(X) = \sum_{k=1}^{\infty} \frac{f^k(X_0)}{k!} (X - X_0)^k$$

O valor de  $f(X)$  na proximidade de  $X$  pode ser obtido pela aproximação linear:

$$f(X) \approx f(X_0) + \nabla f(X_0)(X - X_0)$$

Dado que  $f(X_0)$  e  $\nabla f(X_0)(X_0)$  são valores constantes, pode construir-se a função:

$$h(X) = \nabla f(X_0)(X)$$

que sendo linear permite calcular, pelo método Simplex, um ponto  $X_{PL}$  que é solução admissível do modelo original e solução óptima do modelo:

$$\text{Max } h(X)$$

$$\text{s.a. } AX \leq B$$

$$X \geq 0$$

O valor da função linear  $h(X)$  aumenta necessariamente ao longo do segmento de extremos  $X_0$  e  $X_{PL}$  mas dada a distância que pode haver entre estes dois pontos nada garante que o mesmo se verifique com  $f(X)$  pelo que é necessário determinar qual o ponto  $X^*$  onde  $f(X)$  atinge o maior valor.

O ponto  $X^*$  pertencente ao segmento tem coordenadas:

$$X^* = X_0 + t(X_{PL} - X_0) \text{ com } 0 \leq t \leq 1,$$

pelo que é necessário calcular  $\text{Max } f [(X_0 + t(X_{PL} - X_0))]$  para o que se recorre a qualquer dos métodos de optimização livre de funções monovariáveis (método da bissecção por exemplo).

Em  $X^*$  tem-se  $f(X^*) \geq f(X_0)$  pelo que:

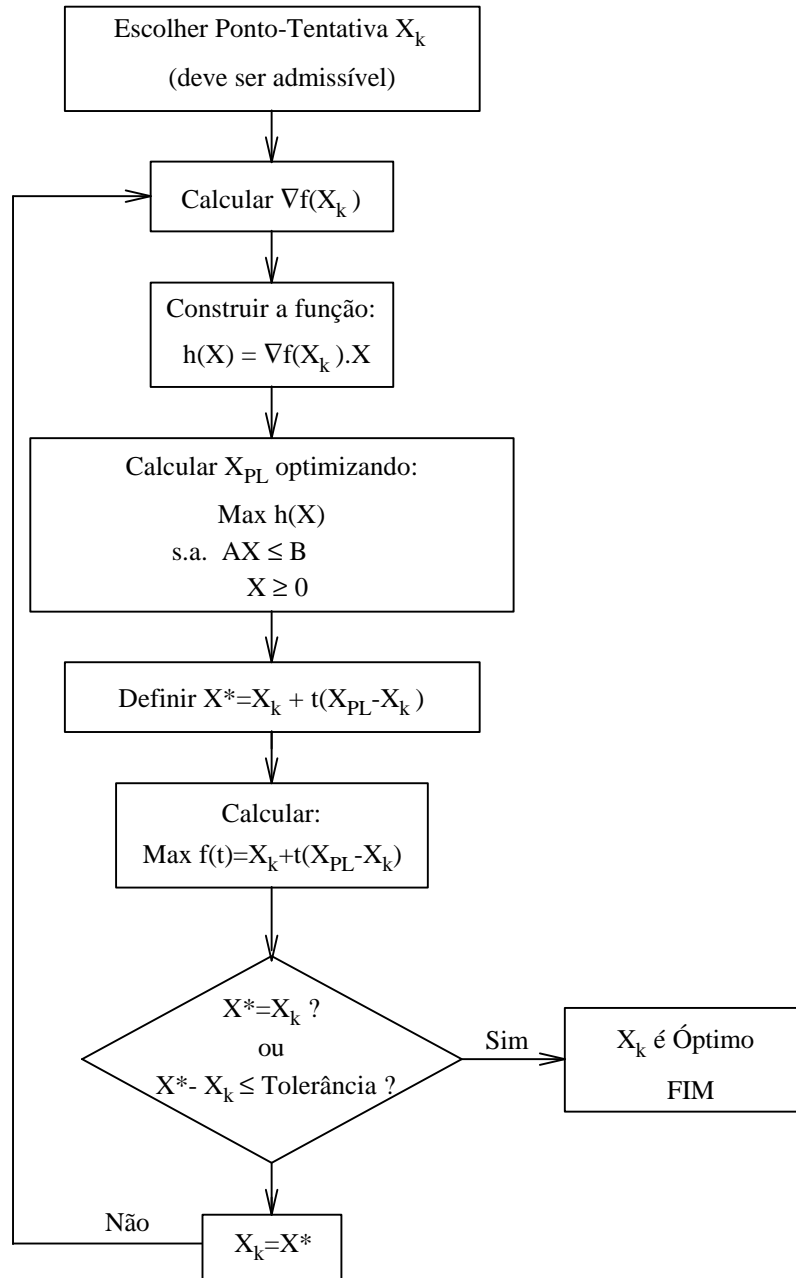
- se  $f(X^*) = f(X_0)$  então  $X_0$  é a solução óptima do modelo de programação não linear
- se  $f(X^*) > f(X_0)$  então  $X^*$  passa a constituir novo ponto-tentativa onde se repete o procedimento descrito

O cálculo termina quando se verificar uma das seguintes situações:

- $X_k = X_{k-1}$  com  $X_{k-1}$  como solução óptima
- quando dois pontos sucessivos estiverem suficientemente próximos (uso de tolerância), no caso de a função-objectivo aumentar sempre ao longo do processo iterativo



Fluxograma do método Frank-Wolfe:



5.2 Considerando o modelo na forma:

$$\text{Max } (-f(X)) = -x_1^2 + 6x_1 - x_2^3 + 3x_2$$

$$\text{s.a. } x_1 + x_2 \leq 1$$

$$x_1, x_2 \geq 0$$

$$\text{tem-se } \nabla(-f) = \begin{bmatrix} -2x_1 + 6 \\ -3x_2^2 + 3 \end{bmatrix}$$

Considerando para ponto-tentativa inicial  $X_1 = (0, 0)$  que é admissível, calcula-se:

$$\nabla[-f(0, 0)] = \begin{bmatrix} 6 \\ 3 \end{bmatrix}$$

Organiza-se a função linear  $h(X) = 6x_1 + 3x_2$  e otimiza-se pelo método Simplex:

$$\text{Max } h(X) = 6x_1 + 3x_2$$

$$\text{s.a. } x_1 + x_2 \leq 1$$

$$x_1, x_2 \geq 0$$

com solução óptima  $X_{PL} = (1, 0)$ .

O valor máximo de  $-f(X)$  é um ponto  $X^*$  (igual a  $X_1 + t(X_{PL} - X_1) = (t, 0)$  com  $0 \leq t \leq 1$ ), do segmento:



$$\text{Calcula-se } \text{Max}(-f(X^*)) = -x_1^2 + 6x_1 - x_2^3 + 3x_2 = -t^2 + 6t.$$

Recorrendo, por exemplo, ao método da bissecção determina-se o valor óptimo de  $t^* = 1$  a que corresponde  $X^* = (1,0)$  onde a função atinge o maior valor. Como  $X_1$  e  $X^*$  são diferentes e muito afastados, considera-se o ponto  $(1,0)$  como *novo ponto-tentativa*  $X_2$ .

Calcula-se novamente:

$$\nabla[-f(1, 0)] = \begin{bmatrix} 4 \\ 3 \end{bmatrix}$$

Organiza-se a função linear  $h(X) = 4x_1 + 3x_2$  e otimiza-se pelo método Simplex:

$$\text{Max } h(X) = 4x_1 + 3x_2$$

$$\text{s.a. } x_1 + x_2 \leq 1$$

$$x_1, x_2 \geq 0$$

com solução óptima  $X_{PL} = (1, 0)$ .

O valor máximo de  $-f(X)$  é atingido no ponto  $X^* = X_2 + t(X_{PL} - X_2) = (1, 0)$  com  $0 \leq t \leq 1$ .

$$\text{Calcula-se } \text{Max}(-f(X^*)) = -x_1^2 + 6x_1 - x_2^3 + 3x_2 = 5.$$

Como  $X_2$  e  $X^*$  são iguais e a função  $-f(x)$  é côncava conclui-se que o ponto de coordenadas  $x_1=1, x_2=0$  é solução óptima com  $\text{Min } f(X) = -5$ .

### 5.3

1. Calcula-se o gradiente da função no ponto tentativa  $X_1 = (5,5)$ :

$$\nabla f = \begin{bmatrix} 15+4x_2-4x_1 \\ 30+4x_1-8x_2 \end{bmatrix} = \begin{bmatrix} 15 \\ 10 \end{bmatrix}$$

2. Otimiza-se recorrendo ao método Simplex:

$$\text{Max } h(X) = 15x_1 + 10x_2$$

$$\text{s.a. } x_1 + 2x_2 \leq 30$$

$$x_1, x_2 \geq 0$$

A solução óptima é  $X_{PL} = (30, 0)$ .

$$3. \text{ Calcula-se } X^* = X_1 + t(X_{PL} - X_1) = \begin{bmatrix} 5 \\ 5 \end{bmatrix} + t \left( \begin{bmatrix} 30 \\ 0 \end{bmatrix} - \begin{bmatrix} 5 \\ 5 \end{bmatrix} \right) = \begin{bmatrix} 5 + 25t \\ 5 - 5t \end{bmatrix}$$

4. Maximiza-se a função  $f(X^*) = -1850t^2 + 325t + 175$ , obtendo-se  $t^* = 0.088$  a que corresponde:

$$X^* = \begin{bmatrix} 7.196 \\ 4.561 \end{bmatrix}$$

5. Porque  $X^* \neq X_1$  considera-se para novo ponto-tentativa  $X_2 = X^* = \begin{bmatrix} 7.196 \\ 4.561 \end{bmatrix}$

6. Recalcula-se o gradiente da função no ponto tentativa  $X_2$  :

$$\nabla f = \begin{bmatrix} 15 + 4x_2 - 4x_1 \\ 30 + 4x_1 - 8x_2 \end{bmatrix} = \begin{bmatrix} 4.459 \\ 22.3 \end{bmatrix}$$

7. Optimiza-se recorrendo ao método Simplex:

$$\text{Max } h(X) = 4.459x_1 + 22.3x_2$$

$$\text{s.a. } x_1 + 30x_2 \leq 30$$

$$x_1, x_2 \geq 0$$

A solução óptima é  $X_{PL} = (0, 15)$ .

$$8. \text{ Calcula-se } X^* = X_2 + t(X_{PL} - X_2) = \begin{bmatrix} 7.196 \\ 4.561 \end{bmatrix} + t \left( \begin{bmatrix} 0 \\ 15 \end{bmatrix} - \begin{bmatrix} 7.196 \\ 4.561 \end{bmatrix} \right) = \begin{bmatrix} 7.196 - 7.196t \\ 4.561 + 10.44t \end{bmatrix}$$

9. Maximiza-se a função  $f(X^*) = -840t^2 + 201t + 189$ , obtendo-se  $t^* = 0.119$  a que corresponde:

$$X^* = \begin{bmatrix} 6.337 \\ 5.807 \end{bmatrix}$$

10. Porque  $X^* \neq X_2$  considera-se para novo ponto-tentativa  $X_3 = X^* = \begin{bmatrix} 6.337 \\ 5.807 \end{bmatrix}$

11. Recalcula-se o gradiente da função no ponto tentativa  $X_3$  :

$$\nabla f = \begin{bmatrix} 15 + 4x_2 - 4x_1 \\ 30 + 4x_1 - 8x_2 \end{bmatrix} = \begin{bmatrix} 12.88 \\ 8.89 \end{bmatrix}$$

12. Optimiza-se recorrendo ao método Simplex:

$$\text{Max } h(X) = 12.88x_1 + 8.89x_2$$

$$\text{s.a. } x_1 + 30x_2 \leq 30$$

$$x_1, x_2 \geq 0$$

A solução óptima é  $X_{PL} = (30, 0)$ .

$$14. \text{ Calcula-se } X^* = X_3 + t(X_{PL} - X_3) = \begin{bmatrix} 6.337 \\ 5.807 \end{bmatrix} + t \left( \begin{bmatrix} 30 \\ 0 \end{bmatrix} - \begin{bmatrix} 6.337 \\ 5.807 \end{bmatrix} \right) = \begin{bmatrix} 6.337 + 23.667t \\ 5.807 - 5.807t \end{bmatrix}$$

15. Maximiza-se a função  $f(X^*) = -1804t^2 + 253t + 201$ , obtendo-se  $t^* = 0.07$  a que corresponde:

$$X^* = \begin{bmatrix} 7.996 \\ 5.4 \end{bmatrix}$$

$$16. \text{ Porque } X^* \neq X_3 \text{ considerava-se para novo ponto-tentativa } X_4 = X^* = \begin{bmatrix} 7.796 \\ 5.4 \end{bmatrix}$$

5.4 Solução ótima no ponto  $x_1 = 1.695$  ;  $x_2 = 1.914$

5.5 O método SUMT é caracterizado pela simplicidade e versatilidade embora propenso a instabilidade numérica.

O problema original é substituído por uma sequência de problemas livres cujas soluções convergem para um máximo local do problema original (máximo global em programação convexa).

Para um modelo do tipo:

$$\text{Max } f(x_1, \dots, x_n)$$

$$\text{s.a. } AX \leq B$$

$$X \geq 0$$

estabelece-se uma função-barreira  $B(X)$  que para  $X$  admissível, satisfaz as seguintes condições:

- $B(X)$  tem valores reduzidos se  $X$  é um ponto afastado das fronteiras do espaço de solução
- $B(X)$  tem valores muito elevados em pontos próximos da fronteira daquele espaço tendendo para “ $\infty$ ” quando a distância do ponto  $X$  à fronteira tende para zero.

A função  $B(X)$  utilizada pelo método é:

$$B(X) = \sum_{i=1}^m \frac{1}{b_i - g_i(X)} + \sum_{j=1}^n \frac{1}{x_j}$$

em que:  $m$  = número de restrições técnicas

$n$  = número de variáveis de decisão

$b_i$  = segundos membros das restrições técnicas

$g_i(X)$  = primeiros membros das restrições técnicas

Para valores admissíveis de  $X$ , o denominador de cada termo é proporcional à distância de  $X$  à fronteira associada à restrição pelo que  $B(X)$  funciona como fronteira de repulsão.

Cada um dos problemas livres a resolver sequencialmente envolve a otimização de :

$$\text{Max } P(X,r) = f(X) - rB(X)$$

em que “ $r$ ” tem valores estritamente positivos sucessivamente decrescentes tendendo para zero.

A redução sucessiva do valor de “ $r$ ” é estabelecida por recorrência (valor seguinte igual ao anterior multiplicado por “ $\theta$ ” que satisfaz  $0 < \theta < 1$  sendo típico usar  $\theta=0.01$ ).

Se  $X_k$  é um máximo de  $P(X,r)$  então:

$$P(X_k,r) = f(X_k) - rB(X_k)$$

e se  $X^*$  for ótimo de  $f(X)$  então:

$$f(X^*) \geq f(X_k) - rB(X_k)$$

$$f(X^*) \leq f(X_k) + rB(X_k)$$

donde resulta que tendendo “ $r$ ” para zero,  $X_k$  tende para  $X^*$ .

O processo iterativo termina quando  $rB(X) \leq \epsilon$  (tolerância).

Casos particulares:

1. Minimização de  $f(X)$  : maximiza-se  $\text{Max } (-f(X))$

2. Restrição técnica do tipo " $\leq$ ": transforma-se em restrição do tipo " $\geq$ "
3. Restrição técnica do tipo " $=$ ": substituir  $\frac{-r}{b_i - g_i(X)}$  por  $\frac{-[b_i - g_i(X)]^2}{\sqrt{r}}$  na expressão de  $P(X,r)$ .

5.6 Solução óptima no ponto  $x_1 = 1.695$  ;  $x_2 = 1.914$

6.

6.1 Variáveis de Decisão :  $x_1$  ( produção do computador A ) ;  $x_2$  ( produção do computador B )Função Objectivo:  $\text{Max } f = p_1 x_1 + p_2 x_2$ 

Restrições técnicas :

$$2x_1 + 3x_2 \leq 5000 \quad (\text{mão de obra})$$

$$3x_1 + x_2 \leq 4500 \quad (\text{chips})$$

Restrições lógicas :  $x_1, x_2 \geq 0$  e Inteiro

As relações das variáveis de decisão com os preços de venda permitem obter por substituição:

$$\text{Max } f = 4000p_1 - 10p_1^2 + 1.8 p_1 p_2 + 2000p_2 - 9p_2^2$$

Esta função é Côncava o que conjugado com restrições lineares permite concluir que as condições KKT vigoram no óptimo.

**Condições KKT:**

$$(1) 4000 - 20p_1 + 1.8 p_2 + 17.6 \lambda_1 + 29.2 \lambda_2 \leq 0$$

$$(2) 1.8 p_1 + 2000 - 18 p_2 + 25\lambda_1 + 6 \lambda_2 \leq 0$$

$$(3) p_1 (4000 - 20p_1 + 1.8 p_2 + 17.6 \lambda_1 + 29.2 \lambda_2) = 0$$

$$(4) p_2 (1.8 p_1 + 2000 - 18 p_2 + 25\lambda_1 + 6 \lambda_2) = 0$$

$$(5) -17.6 p_1 - 25 p_2 \leq -9000$$

$$(6) -29.2 p_1 - 6 p_2 \leq -9500$$

$$(7) \lambda_1 (-17.6 p_1 - 25 p_2 + 9000) = 0$$

$$(8) \lambda_2 (-29.2 p_1 - 6 p_2 + 9500) = 0$$

$$(9) p_1, p_2 \geq 0$$

$$(10) \lambda_1, \lambda_2 \geq 0$$

1ª Hipótese :  $\lambda_1 = 0$  ;  $\lambda_2 \neq 0$ 

$$\lambda_2 \neq 0 \Rightarrow -29.2p_1 - 6p_2 + 9500 = 0$$

$$p_1 \neq 0 \Rightarrow 4000 - 20p_1 + 1.8 p_2 + 17.6 \lambda_1 + 29.2 \lambda_2 = 0$$

$$p_2 \neq 0 \Rightarrow 1.8 p_1 + 2000 - 18 p_2 + 25\lambda_1 + 6 \lambda_2 = 0$$

Resolvendo o sistema tem-se  $p_1 = 292.8093$  u.m. ;  $p_2 = 158.3231$  u.m. ;  $\lambda_2 = 53.80807$  u.m. que é uma solução admissível a que corresponde  $x_1 = 1230$  computadores do tipo A,  $x_2 = 809$  computadores do tipo B e  $f = 488358.4$  u.m.

Não há outro ponto que satisfaça as condições KKT pelo que o calculado é a solução óptima.

**a.** Plano óptimo de produção: 1230 computadores do tipo A ; 809 computadores do tipo B com preços de venda de  $p_1 = 292.81$  u.m. e  $p_2 = 158.33$  u.m. respectivamente.

A receita máxima da venda será de 488358.36 u.m.

**b.** Preço-sombra da hora de mão de obra  $= \lambda_1 = 0$

**c.** Preço-sombra do chip  $= \lambda_2 = 53.81$  u.m.

## 6.2

- Variáveis de Decisão :  $x_1, x_2, x_3$  ( nível de produção de A, B, C respectivamente)

Tem-se assim :

$$x_1 = 18 - p_1 ; x_2 = 9 + 1/3 p_1 - p_2 ; x_3 = 13 - p_3$$

- Restrições técnicas :

$$3x_1 + 4x_2 + 6x_3 \leq 150 \quad (\text{horas máquina})$$

$$4x_1 + 10x_2 + 7x_3 \leq 280 \quad (\text{horas de trabalho})$$

- Restrições lógicas :  $x_1, x_2, x_3 \geq 0$  e Inteiro
- Função-objectivo :  $\text{Max } f = (13x_1 - x_1^2) + (3x_2 - (1/3)x_1x_2 - x_2^2) + (4x_3 - x_3^2)$

*Nota sobre a organização da função objectivo:*

Secretária do tipo A:

- total do lucro = total da venda - total do custo de produção =  $p_1 x_1 - 5x_1 = x_1 (18 - x_1) - 5x_1$   
 $= 13x_1 - x_1^2$

Secretária do tipo B:

- total do lucro = total da venda - total do custo de produção =  $p_2 x_2 - 12x_2 =$   
 $= x_2 (9 + 1/3 p_1 - x_2) - 12x_2 = x_2 [ 9 + (1/3)(18-x_1) - x_2 ] - 12x_2 =$   
 $= 3x_2 - (1/3)x_1x_2 - x_2^2$

Secretária do tipo C:

- total do lucro = total da venda - total do custo de produção =  $p_3 x_3 - 9x_3 = 4x_3 - x_3^2$

## 6.3 O modelo de PNL é:

$$\text{Max } f(T,C) = T^{2/3} \cdot C^{1/3}$$

$$\text{s.a. } 2T + C \leq 30$$

$$T, C \geq 0$$

Para maximizar a função pode maximizar-se  $l_n f(T,C) = \frac{2}{3}l_n T + \frac{1}{3}l_n C$ , dado que  $l_n$  é uma função crescente.

As condições KKT são:

$$(1) \frac{2}{3T} - 2I \leq 0$$

$$(2) T \left( \frac{2}{3T} - 2I \right) = 0$$

$$(3) \frac{1}{3C} - I \leq 0$$

$$(4) C \left( \frac{1}{3C} - I \right) = 0$$

$$(5) 2T + C - 30 \leq 0$$

$$(6) I(2T + C - 30) = 0$$

$$(7) \lambda, T, C \geq 0$$

Admitindo  $2T+C-30 \neq 0$  então  $\lambda=0$  e em (2) tem-se  $\frac{2T}{3T} = 0$  o que é falso pelo que se conclui que  $\lambda \neq 0$  e que

$2T+C-30 = 0$ . Se  $T=0$  tem-se em (1)  $\frac{2}{0}$  o que não é possível pelo que  $T \neq 0$ .

Então em (2) fica  $\left(\frac{2}{3T} - 2I\right) = 0$ .

De (4) conclui-se que  $C \neq 0$  pelo que  $\left(\frac{1}{3C} - I\right) = 0$ .

Dispõe-se assim do sistema de equações:

$$\begin{cases} 2T+C-30 = 0 \\ \left(\frac{2}{3T} - 2I\right) = 0 \\ \left(\frac{1}{3C} - I\right) = 0 \end{cases}$$

com solução  $\lambda=1/30$ ;  $T=10$ ;  $C=10$  a que corresponde  $f(T,C) = 10$  máquinas.

6.4 Do sistema de equações organizado no problema anterior tem-se:

$$T = \frac{1}{3I} \quad e \quad C = \frac{1}{3I}$$

Considerando "x" o capital mínimo a determinar tem-se a restrição  $2T+C=x$ . Substituindo T e C fica:

$$2\left(\frac{1}{3I}\right) + \frac{1}{3I} = x \text{ pelo que } I = \frac{1}{x}. \text{ Resulta assim } T = \frac{x}{3} \quad e \quad C = \frac{x}{3} \text{ pelo que } f = \frac{x}{3} = 6, \text{ implica } x=18.$$

A solução é portanto 18 unidades de capital como mínimo para produzir 6 máquinas.

6.5

a. O modelo de PNL é:

$$\text{Max } f(x_1, x_2) = 30x_1^{1/2} + 20x_2^{1/2}$$

$$\text{s.a. } x_1 + x_2 \leq 100$$

$$x_1, x_2 \geq 0$$

Recorrendo às condições KKT :

$$(1) \frac{15}{\sqrt{x_1}} - I \leq 0$$

$$(2) x_1 \left( \frac{15}{\sqrt{x_1}} - I \right) \leq 0$$

$$(3) \frac{10}{\sqrt{x_2}} - I \leq 0$$

$$(4) x_2 \left( \frac{10}{\sqrt{x_2}} - I \right) \leq 0$$

$$(5) x_1 + x_2 \leq 100$$

$$(6) \lambda(x_1 + x_2 - 100) = 0$$

$$(7) \lambda, x_1, x_2 \geq 0$$



Admitindo  $x_1, x_2, \lambda$  diferentes de zero, tem-se o sistema de equações:

$$\begin{cases} \frac{15}{\sqrt{x_1}} - I = 0 \Rightarrow I\sqrt{x_1} = 15 \\ \frac{10}{\sqrt{x_2}} - I = 0 \Rightarrow I\sqrt{x_2} = 10 \\ x_1 + x_2 = 100 \end{cases}$$

com solução  $x_1 = 69.231$  u.m. ;  $x_2 = 30.769$  u.m. ;  $\lambda = 1.803$  ;  $\text{Max } f = 360.555$  u.m.

b. Aproximadamente  $\lambda = 1.803$  (em rigor, 1.798 pois a função não é linear...).

6.6

a. O modelo de PNL é:

$$\begin{aligned} \text{Max } f(X) &= (70 - 4x_1)x_1 + (150 - 15x_2)x_2 - (100 + 15x_1 + 15x_2) = \\ &= 55x_1 - 4x_1^2 + 135x_2 - 15x_2^2 - 100 \end{aligned}$$

O estudo da função conduz a:

$$\nabla f = \begin{bmatrix} 55 - 8x_1 \\ 135 - 30x_2 \end{bmatrix} ; \quad H = \begin{bmatrix} -8 & 0 \\ 0 & -30 \end{bmatrix}$$

A matriz H é definida negativa pelo que a função é côncava.

Recorrendo à condição de 1ª ordem para extremo tem-se:

$$\begin{cases} 55 - 8x_1 = 0 \\ 135 - 30x_2 = 0 \end{cases} \begin{cases} x_1 = \frac{55}{8} \\ x_2 = \frac{9}{2} \end{cases} ; \quad \text{Max } f(X) = 392.81 \text{ u.m.}$$