

INVESTIGAÇÃO OPERACIONAL

PROGRAMAÇÃO NÃO LINEAR

(Exercícios)

(Texto revisto para o ano lectivo 2001-2002)

António Carlos Morais da Silva
Professor de I.O.

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 Bissecção e do Gradiente*

- 1.1. Calcular o Máximo livre de $f(x) = -2x^6 - 3x^4 + 12x$ pelo Método da Bissecção (tolerância = 0.01)
- 1.2. Calcular o Máximo livre de $f(x) = -0.25x^4 + x^3 - 2x^2 + 2x$ pelo Método da Bissecção (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 Bissecção.
- 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, λ) 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:

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

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

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

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

$$\text{s.a. } g(x) \leq b$$

2.6. Calcular pelo Método dos Multiplicadores de Lagrange:

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 5x_1 - 2x_1^2 + 3x_1x_2 - 2x_2^2 \\ \text{s.a. } x_1 + x_2 &\leq 2 \end{aligned}$$

2.7. Calcular pelo Método dos Multiplicadores de Lagrange:

$$\begin{aligned} \text{Max } f(x_1, x_2) &= 3x_1^2 + x_2^2 + 2x_1x_2 + 6x_1 + 2x_2 \\ \text{s.a. } 2x_1 - x_2 &= 4 \end{aligned}$$

O ponto ótimo 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 ótima de um modelo de PNL pode ser atingida em ponto da fronteira do convexo de soluções ?
- 3.3. A solução ótima 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 às 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 ótima 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 $f(x_1, x_2) = 2x_1x_2 + 3x_2 - x_1^2 - x_2^2$
- Calcular o gradiente da função no ponto $X_1 = (2, 3)^T$.
 - 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 :

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

a. Estabeleça as condições KKT

b. Calcule a solução óptima.

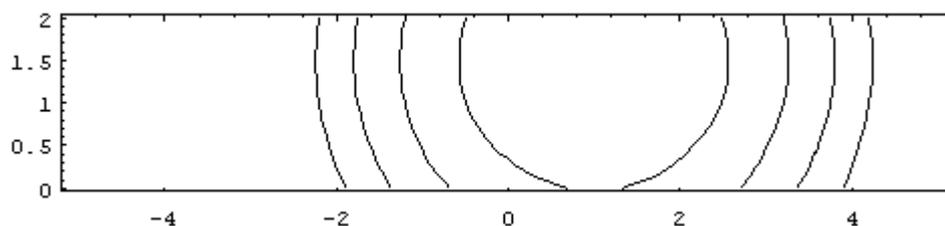
4.5. Considere o seguinte problema de programação não linear :

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

a. Demonstre que o problema é de programação convexa.

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

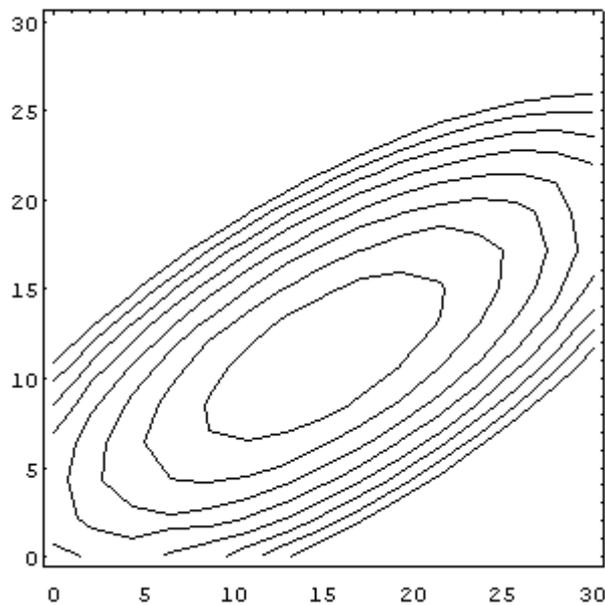
c. Verifique geometricamente a solução calculada (a figura apresenta a projecção horizontal das curvas de nível da função).



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.

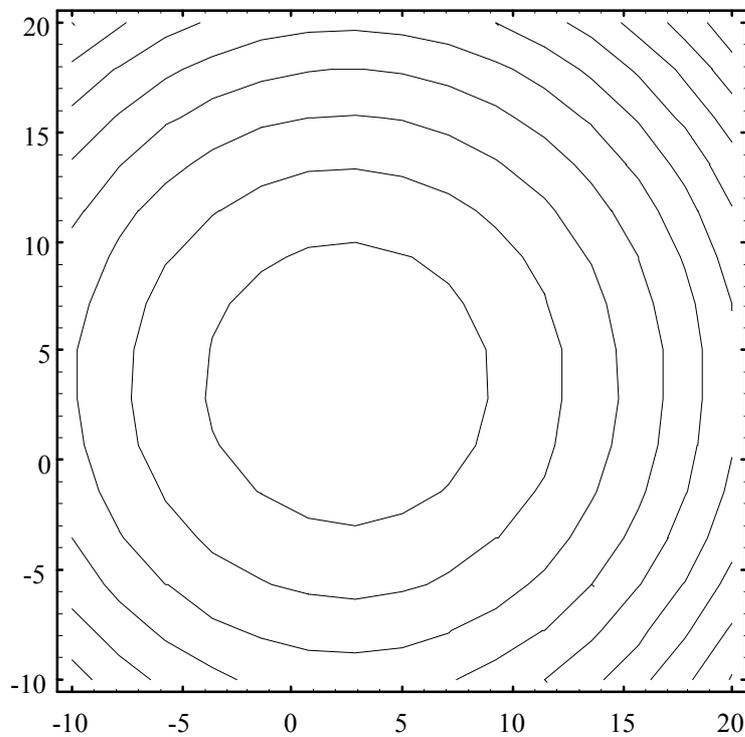
4.9. Descrever a solução óptima de $\text{Max } f(x)$ para $a \leq x \leq b$ recorrendo às condições KKT sabendo que $f'(x)$ existe para qualquer valor no intervalo $[a, b]$.

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 :

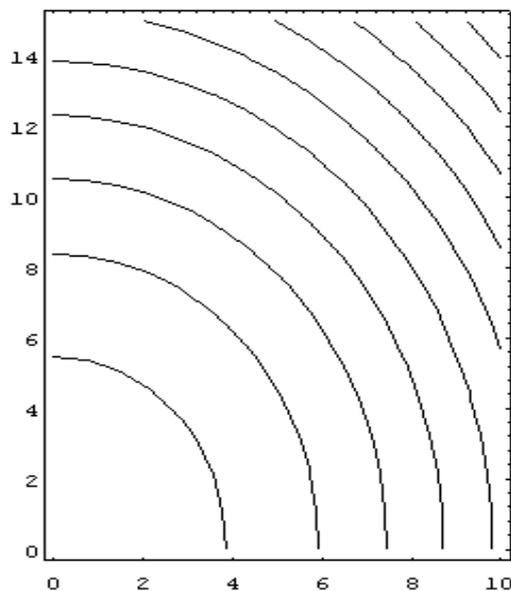
$$\begin{aligned} \text{Min } f(x_1, x_2) &= x_1^2 + 2x_1 + 2x_1x_2 + 4x_2^2 \\ \text{s.a. } 2x_1 + x_2 &\geq 10 \\ x_1 + 2x_2 &\geq 10 \\ x_1, x_2 &\geq 0 \end{aligned}$$

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.

a. Dispondo de 100 u.m. para promoção como pode a empresa maximizar o lucro?

b. 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 ?

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.

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

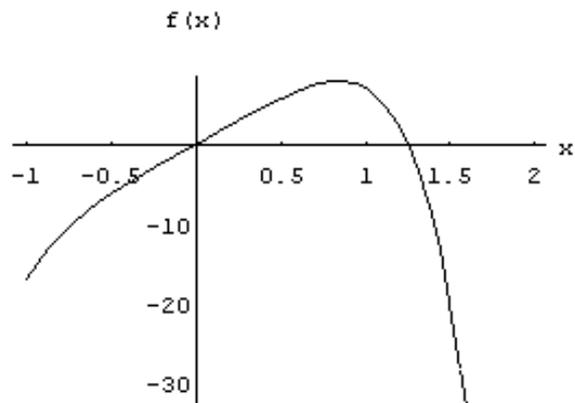
SOLUÇÃO	
f(x) = 7.8838682	
EXTREMO ÓPTIMO	
ABCISSA	0.8281250
	0.8359375
	0.8437500

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

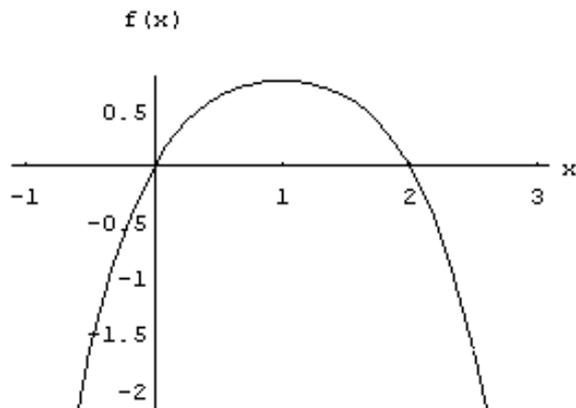
SOLUÇÃO	
f(x) = 0,7499805	
EXTREMO OPTIMO	
ABCISSA	0,9750000
	0,9937500
	1,0125000

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	1,200000
5	0,03	a	0,900000	1,050000
6	-0,01	b	0,975000	1,050000

Médio	OK ?	Valor f(M)
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 $x_1 = 1/3$; $x_2 = 4/3$; $f(x_1, x_2) = 14/3$.

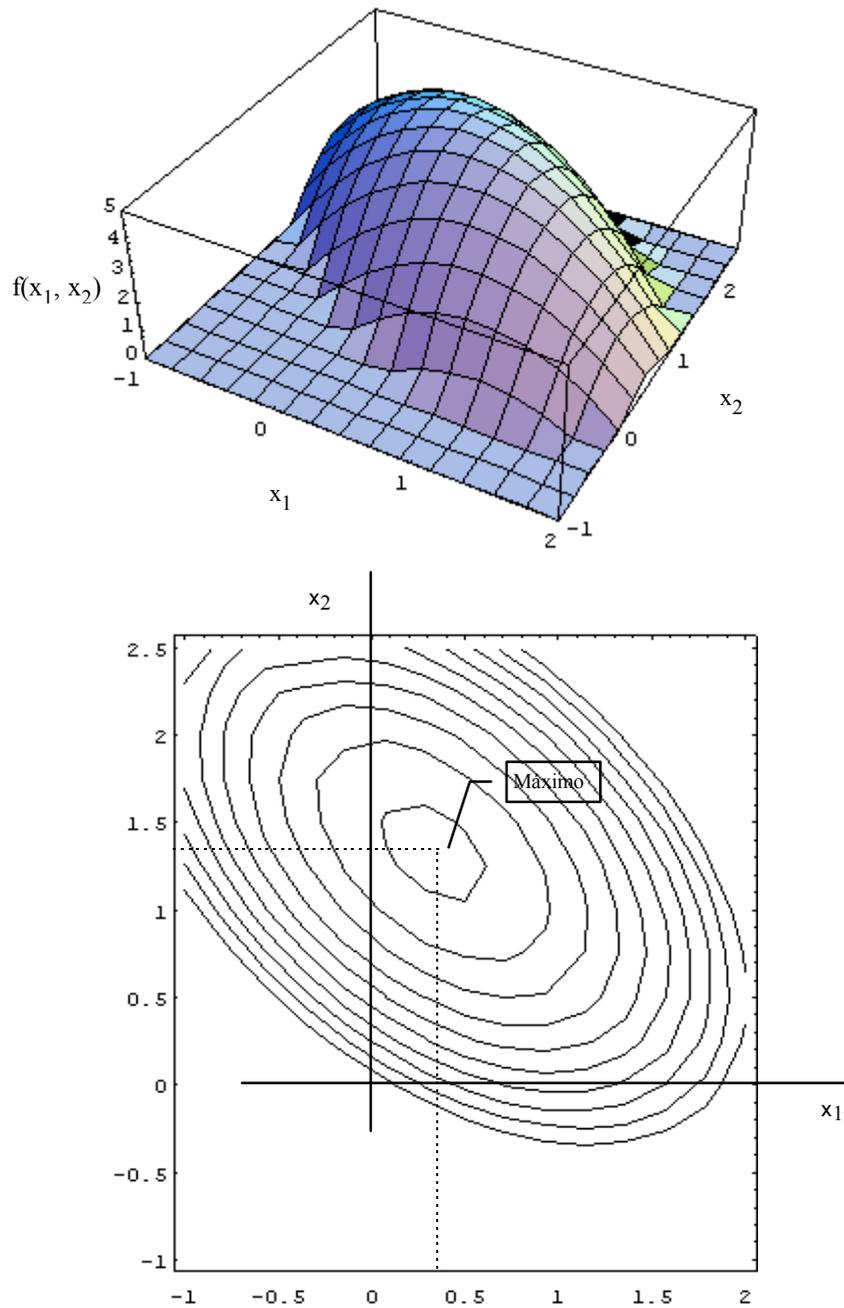
Para cada uma das iterações foi organizada a função $f(x_1, x_2)$ com x_1 e x_2 parametrizados e calculado o seu máximo. Os resultados obtidos são apresentados no quadro seguinte:

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 $x_1 = 1$; $x_2 = 1$; $f(x_1, x_2) = 1$.

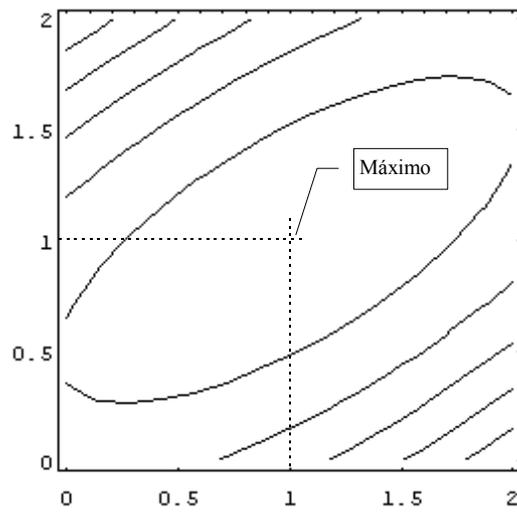
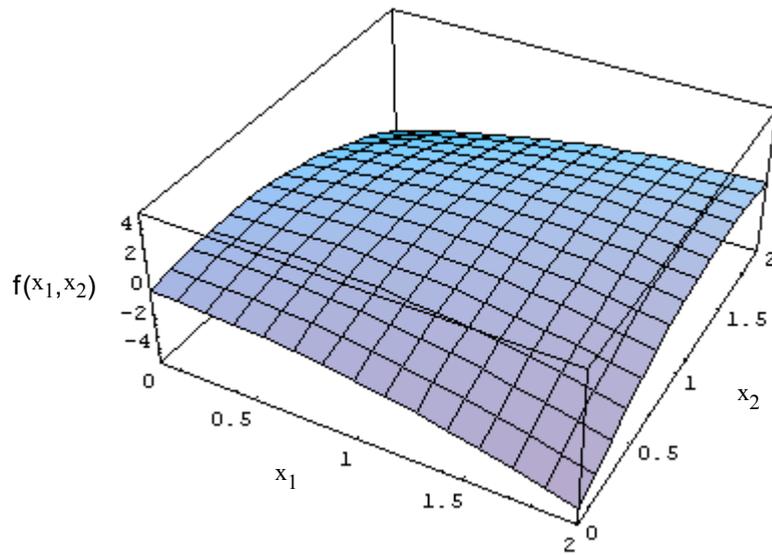
Para cada uma das iterações foi organizada a função $f(x_1, x_2)$ com x_1 e x_2 parametrizados e calculado o seu máximo. Os resultados obtidos são apresentados no quadro seguinte.

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

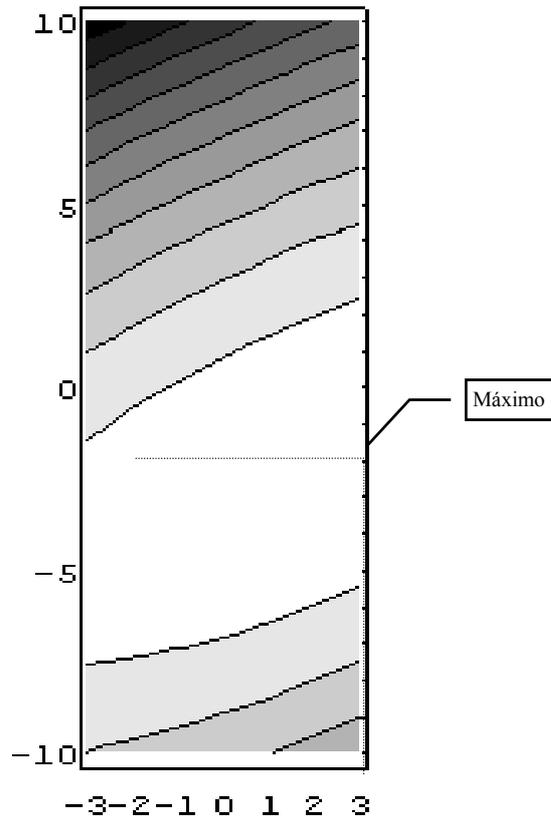
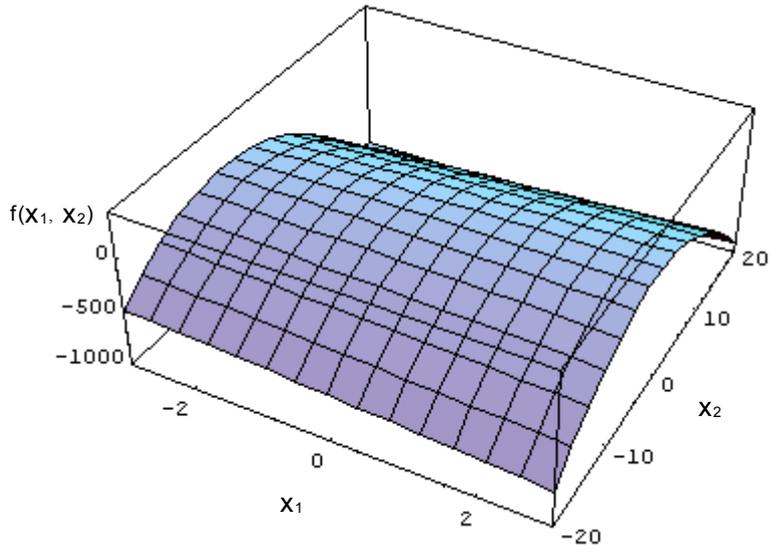
Na iteração 33 as derivadas parciais de $f(x_1, x_2)$ têm valor absoluto inferior à tolerância 0,01 (termina processo iterativo)

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 Bisseção.

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

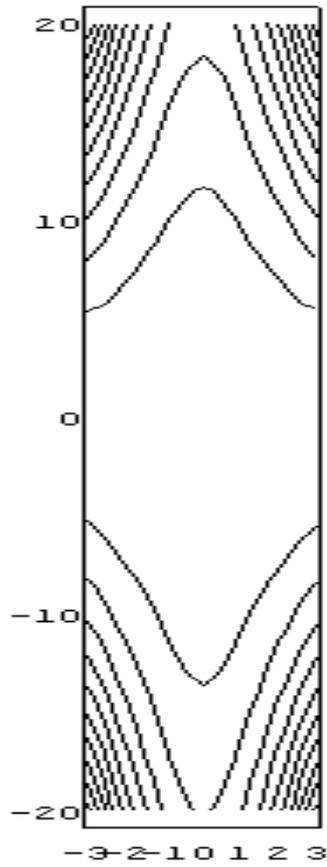
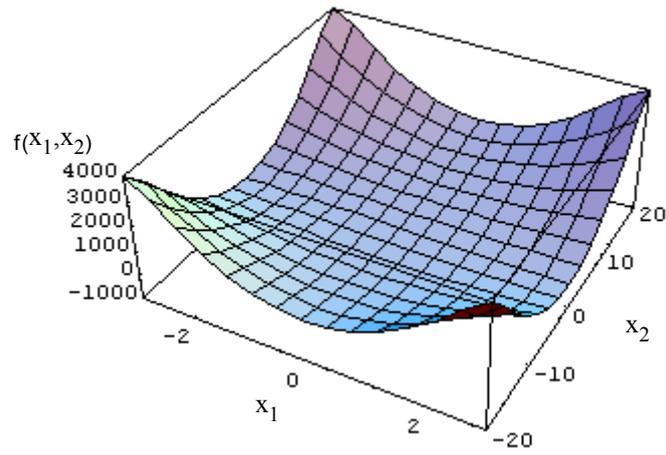
Nota : Para cada uma das iterações foi organizada a função $-f(x_1, x_2)$ com x_1 e x_2 parametrizados e calculado o seu máximo. Os resultados obtidos são apresentados no quadro seguinte:

Quadro 2 - Determinação do valor óptimo “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

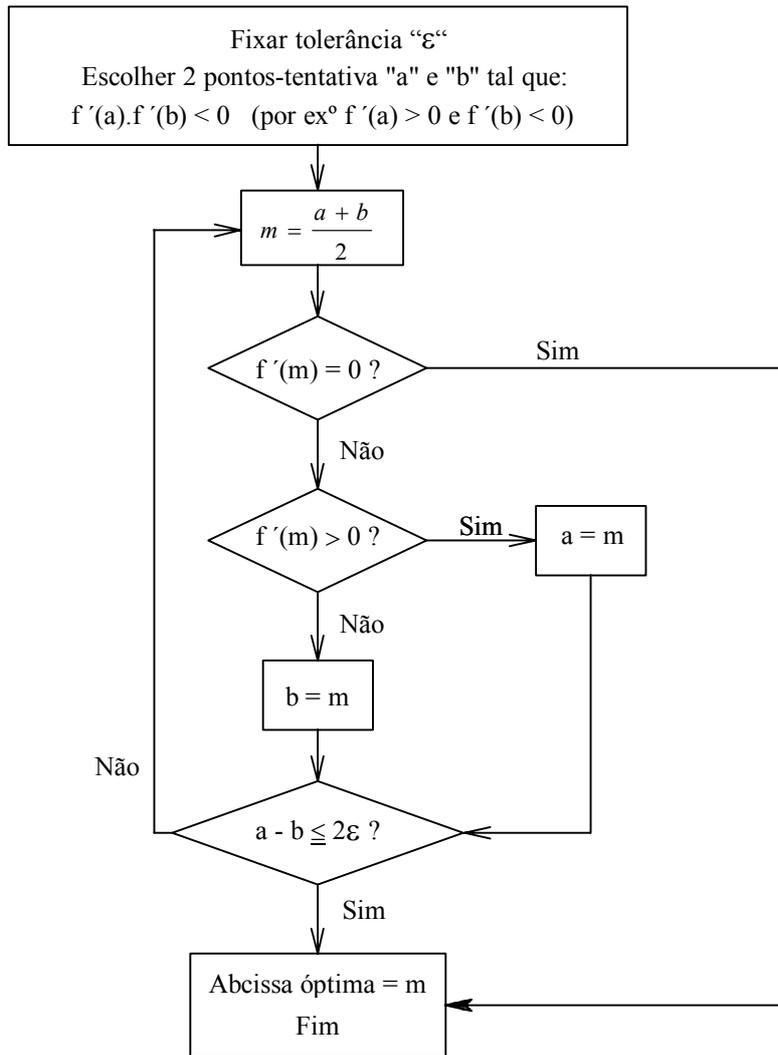
Book Gradient.xls Sheet 1.6

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 abcissa do extremo de uma função monovariável no intervalo [a,b].

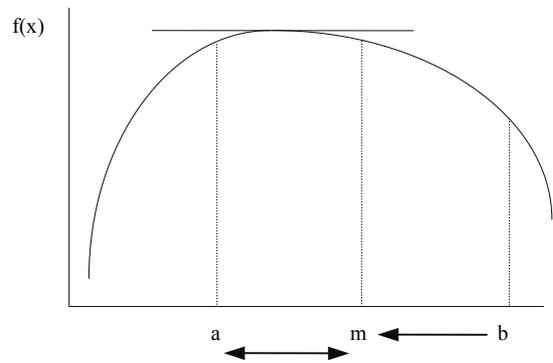
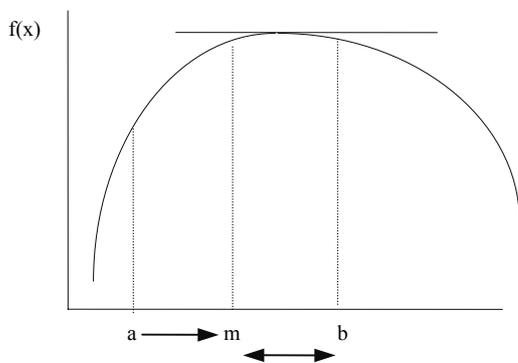
Fluxograma do método:



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

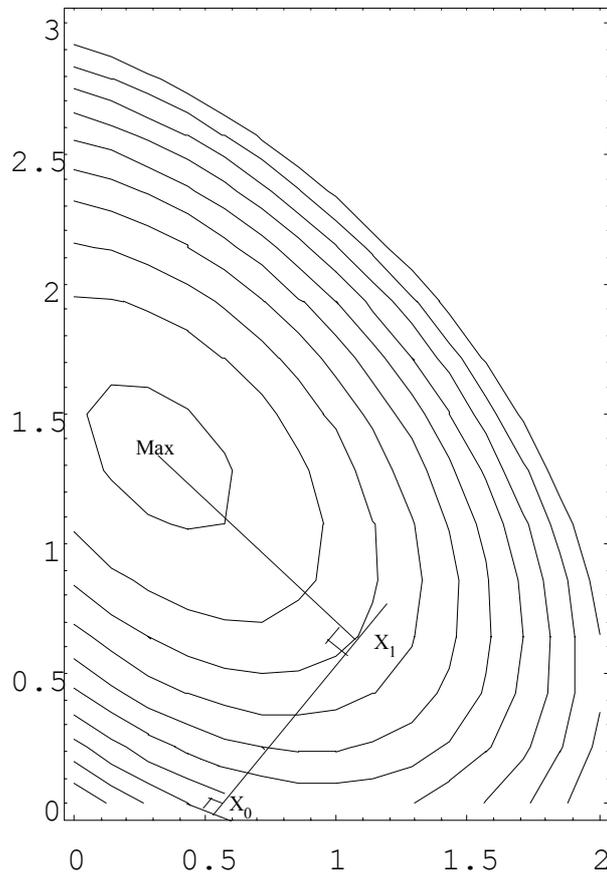
1ª Hipótese
Reduzir intervalo com a = m

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:

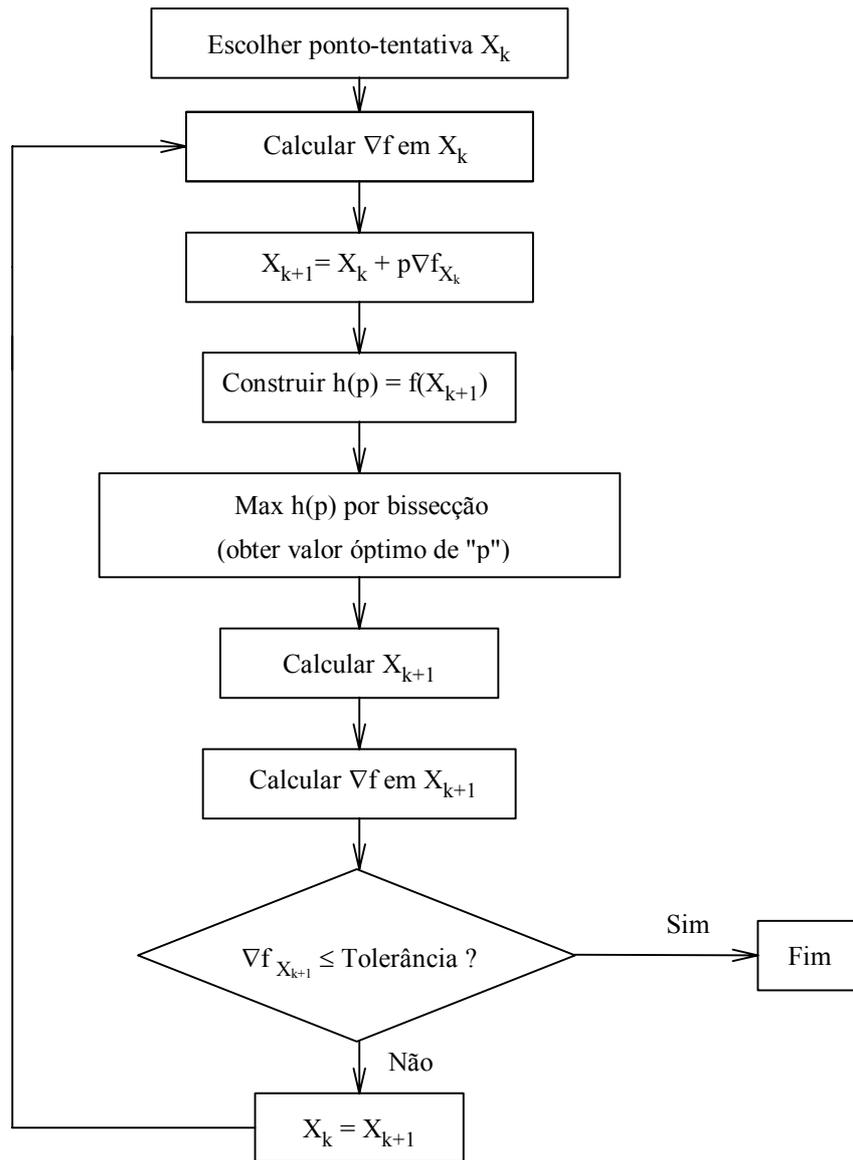
$$X_{k+1} = X_k + p \nabla f_{X_k}$$

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^*, λ^*) 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, λ) os *pontos de Lagrange*.

- Analisar cada uma das soluções (X^*, λ^*) 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 $\partial f_i / \partial x_j$ 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)

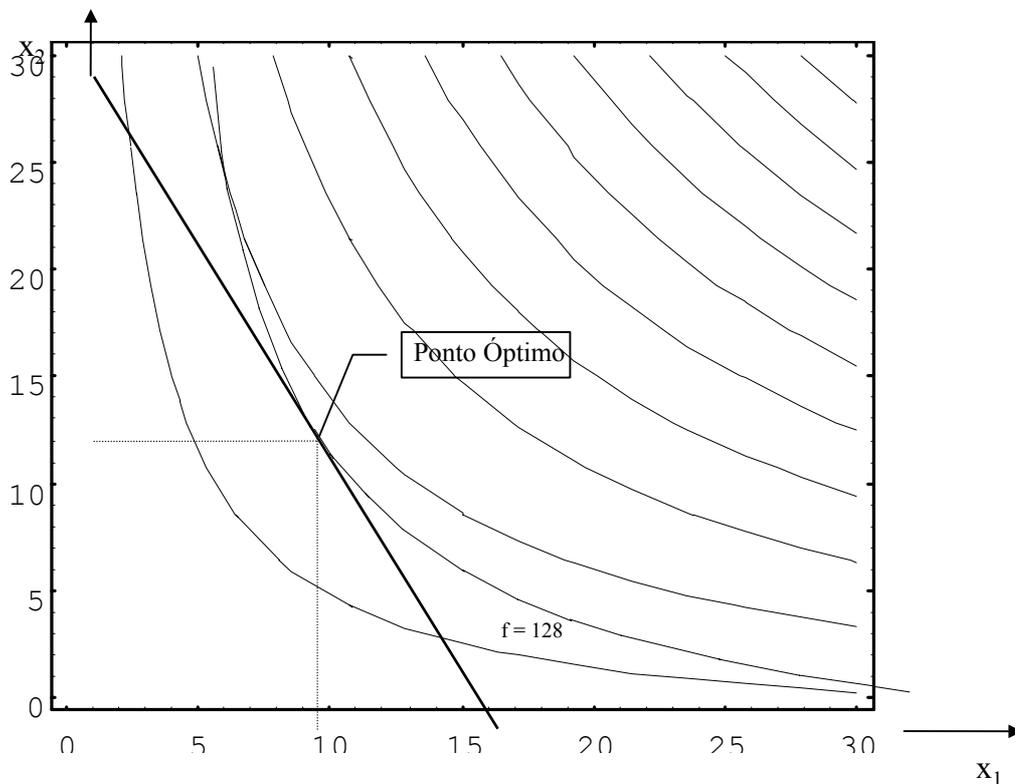
3. Calcular as derivadas parciais de 1ª ordem, igualar a zero e resolver o sistema de equações:

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

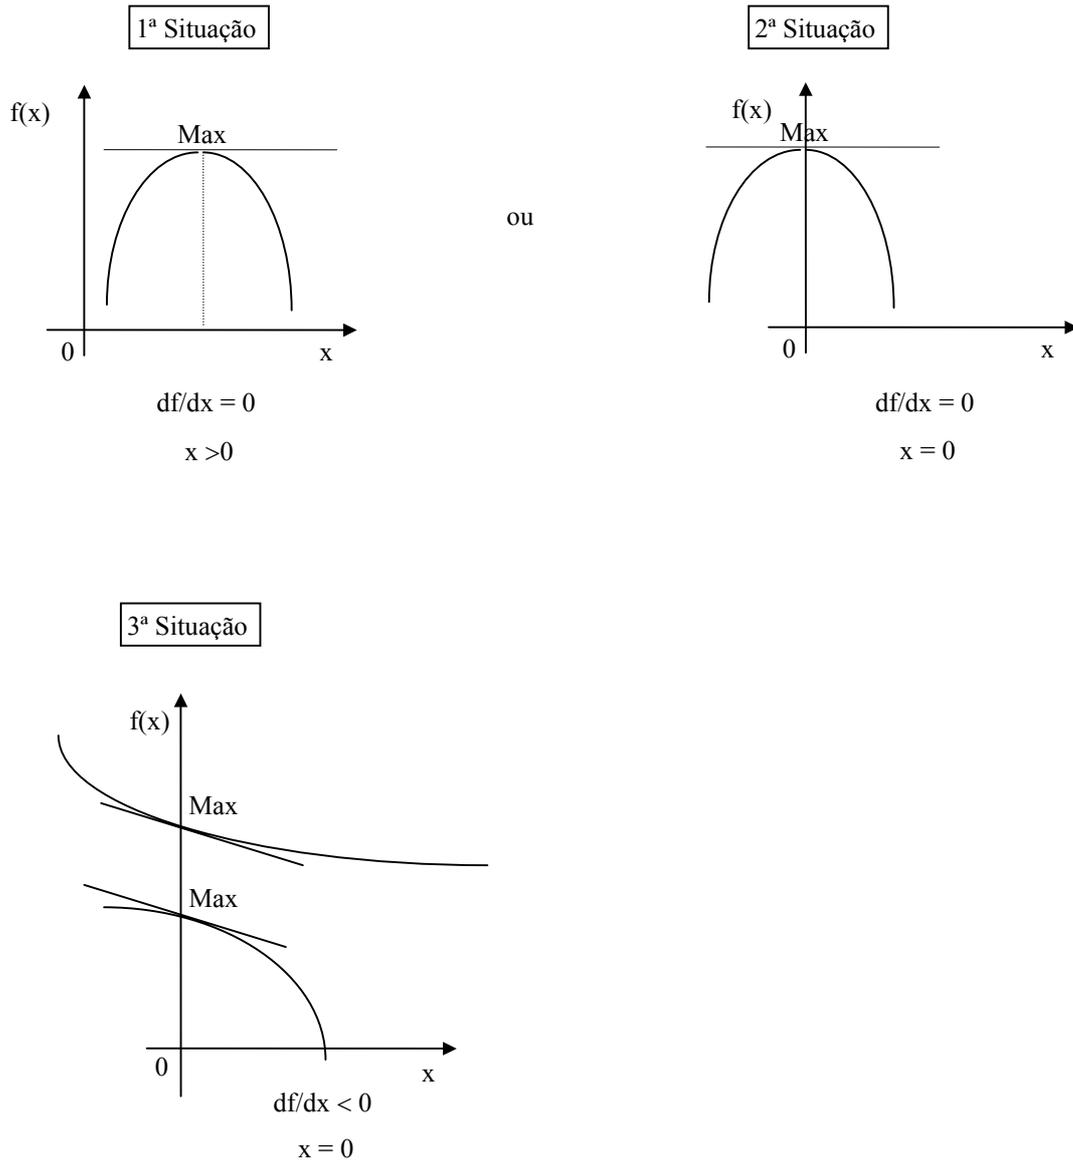
A solução que satisfaz as condições de Lagrange é única pelo que é ótima (Max $f = 128$):

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

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:

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

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:

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

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 “ λ ” 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:

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

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:

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

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 “ λ ”)

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 $x_1 = 2 - x_2$

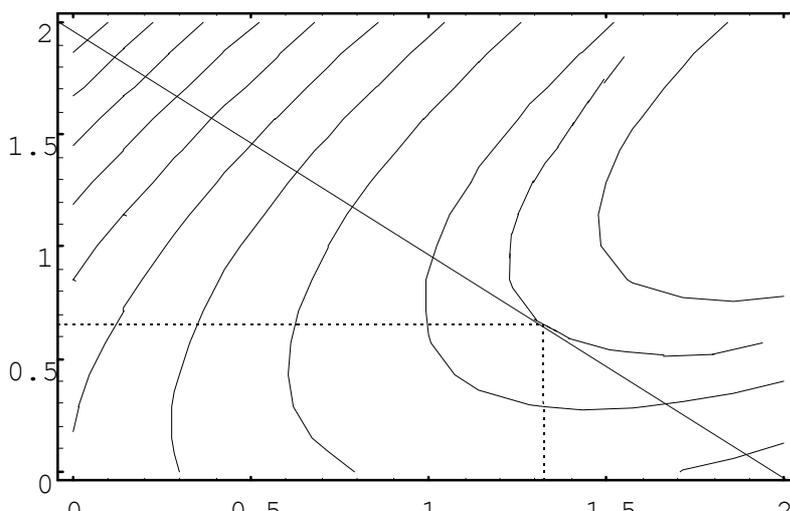
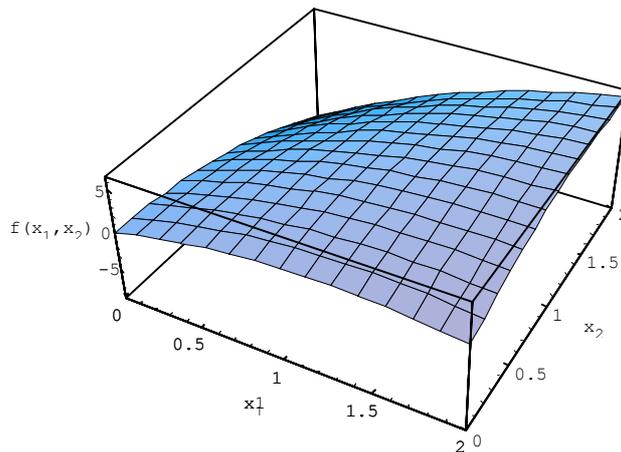
Substituindo em (1) e (2) tem-se:

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

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:

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

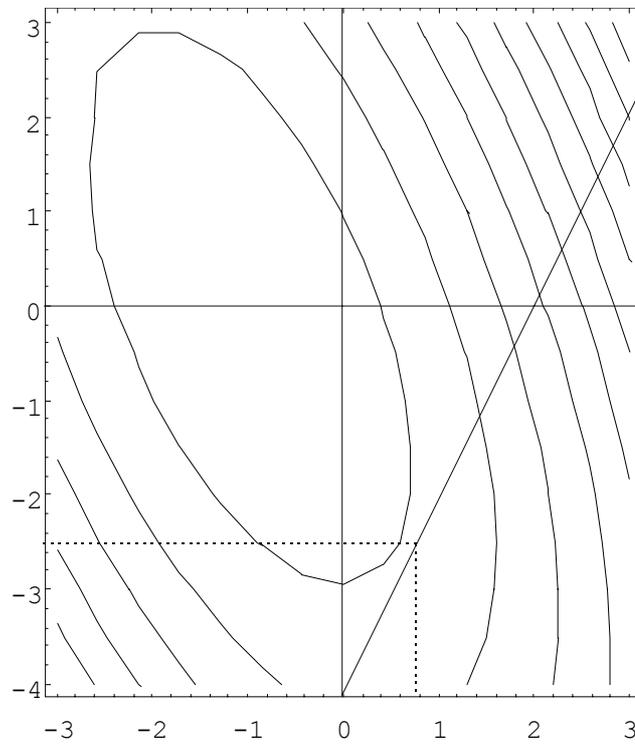
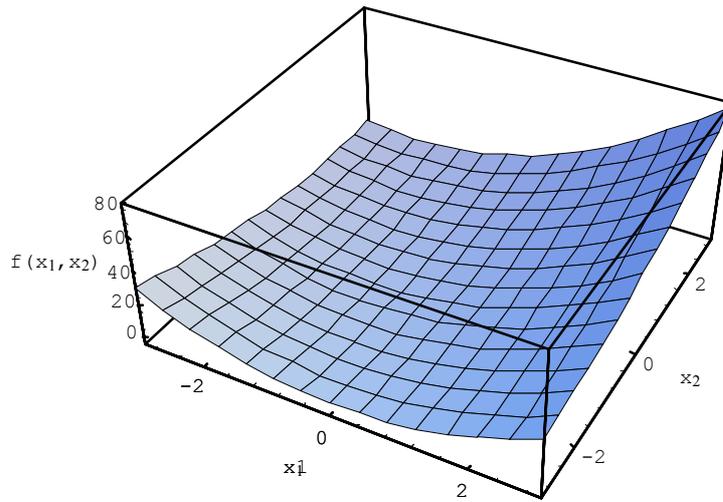
As condições a satisfazer pelo extremo são:

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

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:

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

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

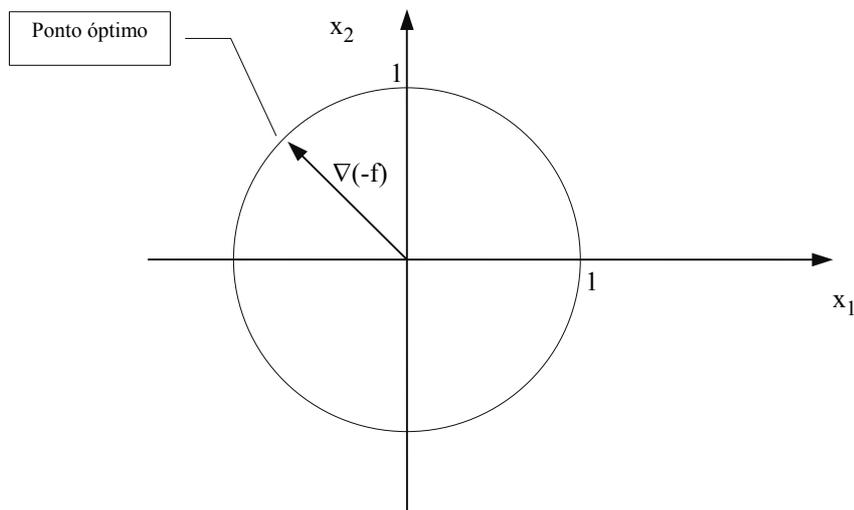
$$1. \quad x_1 = -\frac{\sqrt{2}}{2} ; x_2 = \frac{\sqrt{2}}{2} ; \lambda = -\frac{\sqrt{2}}{2} ; f = -1.41421$$

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

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:

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

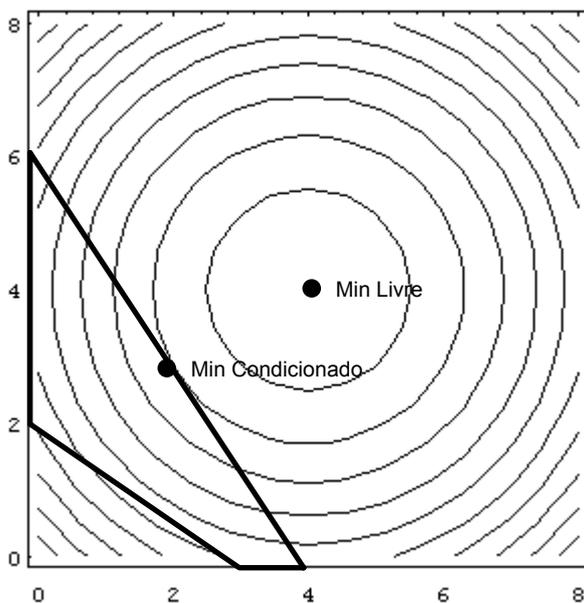
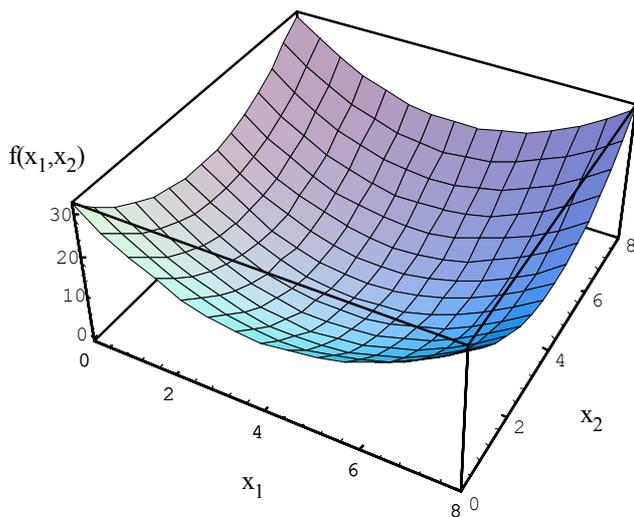
s.a. $2x_1 + 3x_2 \geq 6$

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

$x_1, x_2 \geq 0$

A solução ótima 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 ótimo NÃO É EXTREMO (o que não se passa em Programação Linear).



3.3 É possível como o exemplo seguinte demonstra:

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

$$\text{s.a. } x_1 + x_2 \geq 5$$

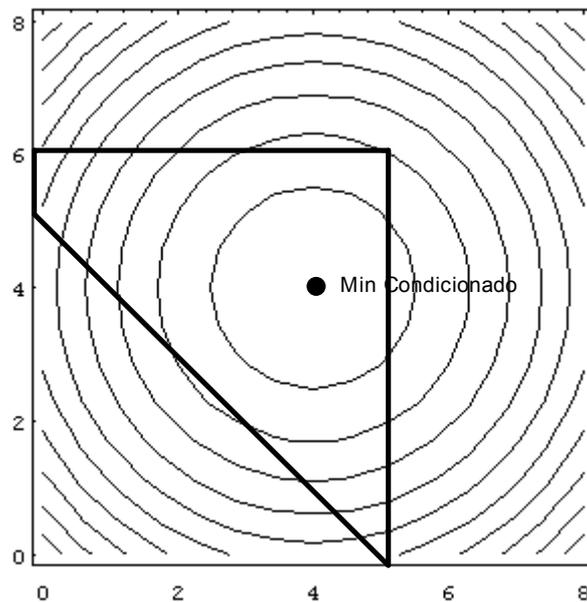
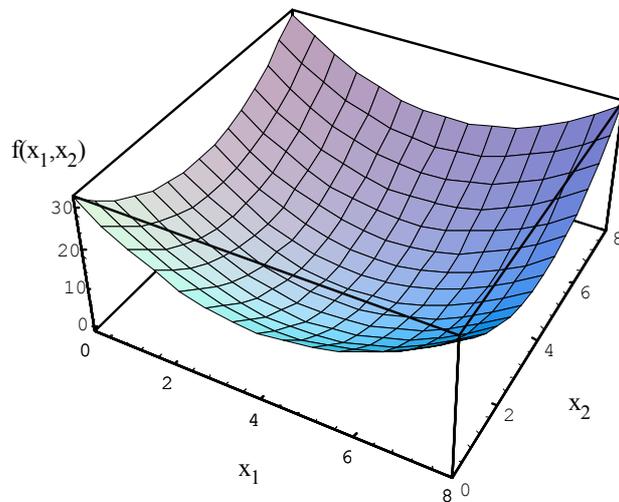
$$-x_1 \geq -5$$

$$-2x_2 \geq -12$$

$$x_1, x_2 \geq 0$$

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:

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

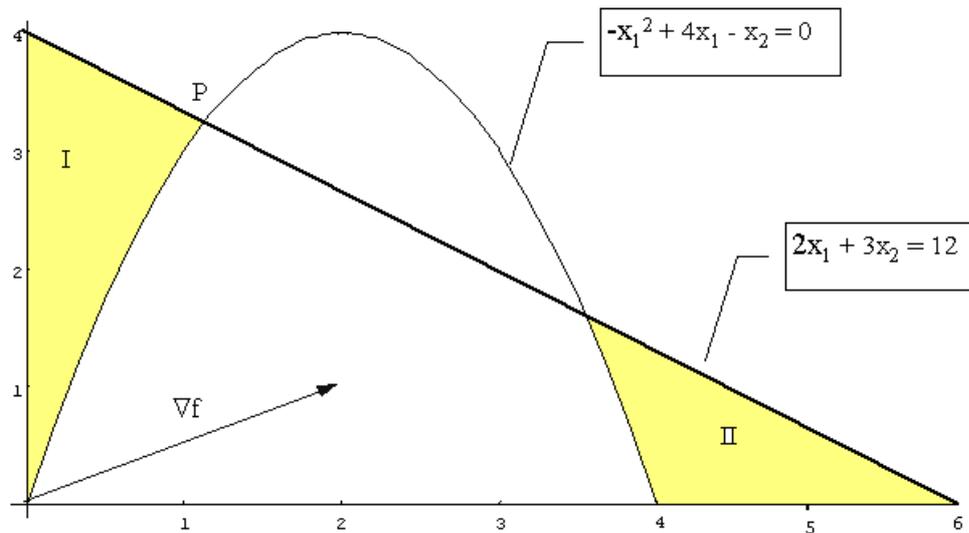
$$\text{s.a. } -x_1^2 + 4x_1 - x_2 \leq 0$$

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

$$x_1, x_2 \geq 0$$

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 (5.508). Veja-se que tal é apenas máximo local pois na área II a função tem maior valor em qualquer ponto sendo o ponto (6,0) o extremo onde a função atinge o máximo ($f(X)=12$).



3.5 CONCLUSÕES SOBRE DIFERENÇAS ENTRE PNL E PL :

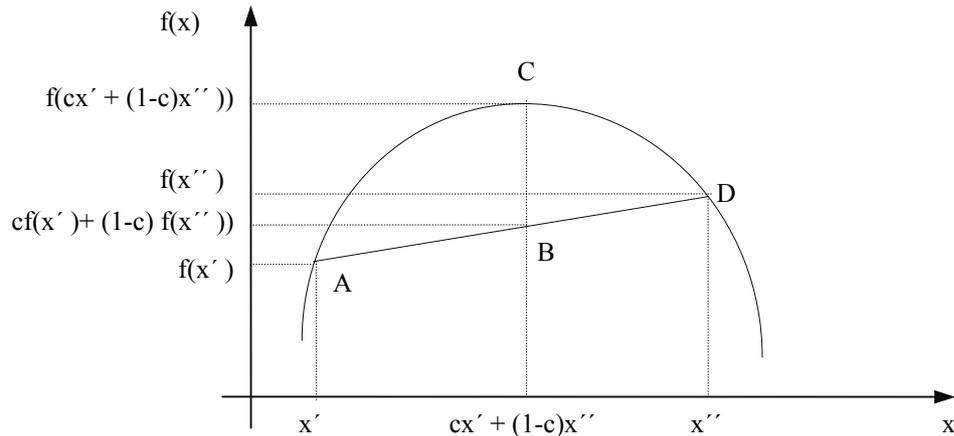
- Em PNL, qualquer ponto do espaço de solução pode ser ótimo. A procura do ponto ótimo **não pode** ficar limitada aos extremos como na PL.
- O número de restrições técnicas saturadas, no ótimo, **pode ser nulo**. (ver problema 3.3 onde nenhuma restrição é satisfeita como igualdade).
- O deslocamento 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 extremo 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 $f = p_1 d_1 + p_2 d_2$

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:

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

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:

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

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

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

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

em que :

C = matriz dos coeficientes das variáveis x_{ii} , 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:

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

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 “ λ ” 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 λ_i é a variável Dual associada à restrição “i”; como as duas restrições são do tipo “≤” 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:

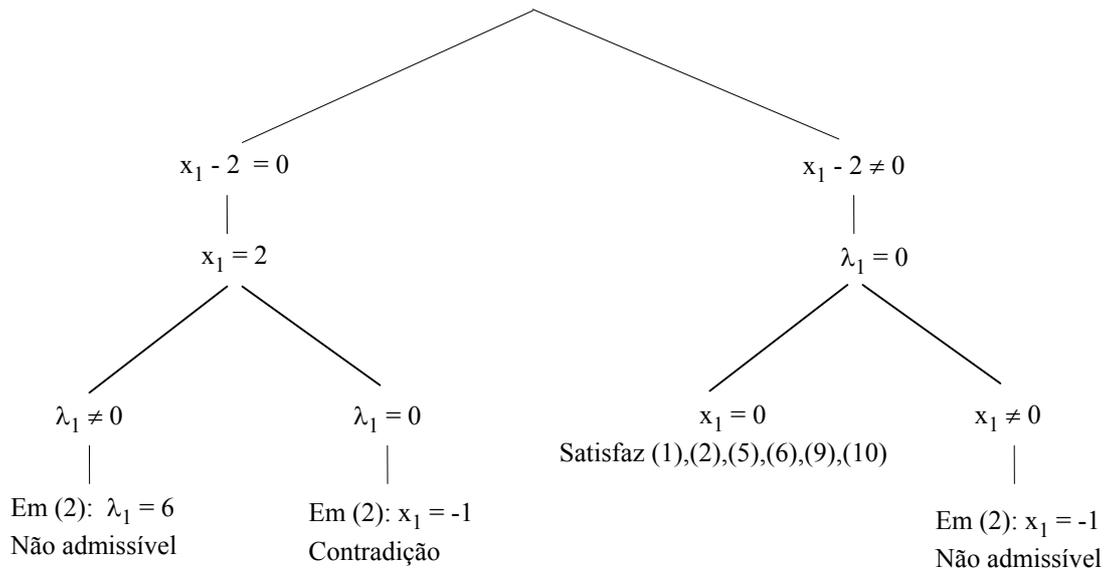
- (1) $2x_1 + 2 - \lambda_1 \geq 0$
- (2) $x_1 (2x_1 + 2 - \lambda_1) = 0$
- (3) $2x_2 - 4 - \lambda_2 \geq 0$
- (4) $x_2 (2x_2 - 4 - \lambda_2) = 0$
- (5) $x_1 - 2 \leq 0$
- (6) $\lambda_1 (x_1 - 2) = 0$
- (7) $x_2 - 1 \leq 0$
- (8) $\lambda_2 (x_2 - 1) = 0$
- (9) $x_1, x_2 \geq 0$
- (10) $\lambda_1,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

Das condições de ortogonalidade tem-se:

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

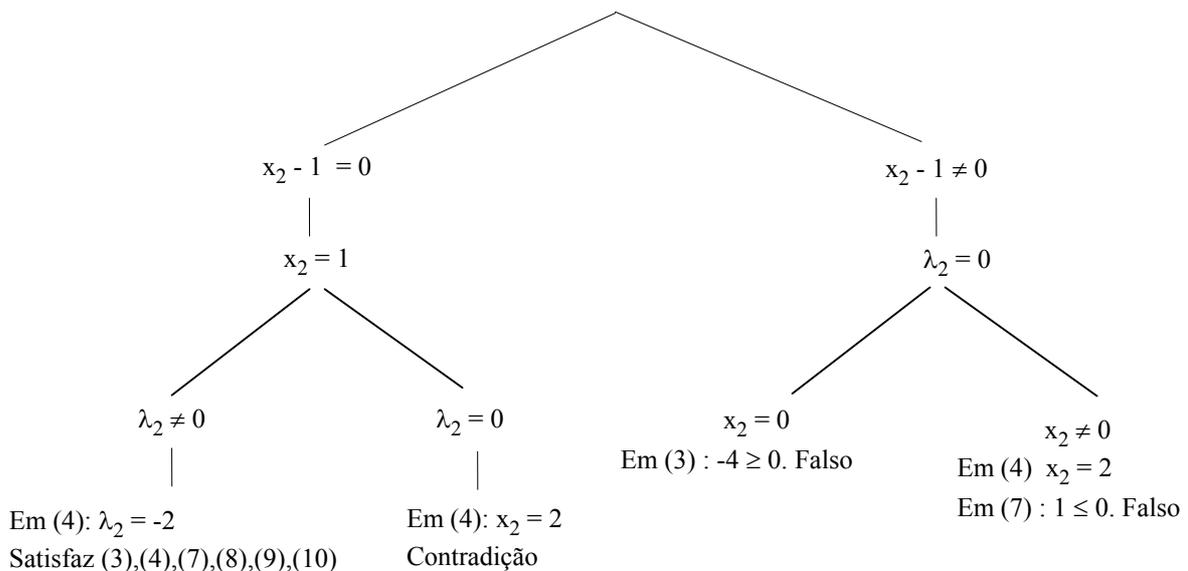
Explorando uma das condições até estabelecer incompatibilidade (contradição) com as restantes condições será possível concluir se é nulo o multiplicador λ_i ou $g_i(X)$ ou ambos. Deste modo como se vai concluindo quais as restrições activas e inactivas, as desigualdades KKT que se verificam como igualdades 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 ótima.

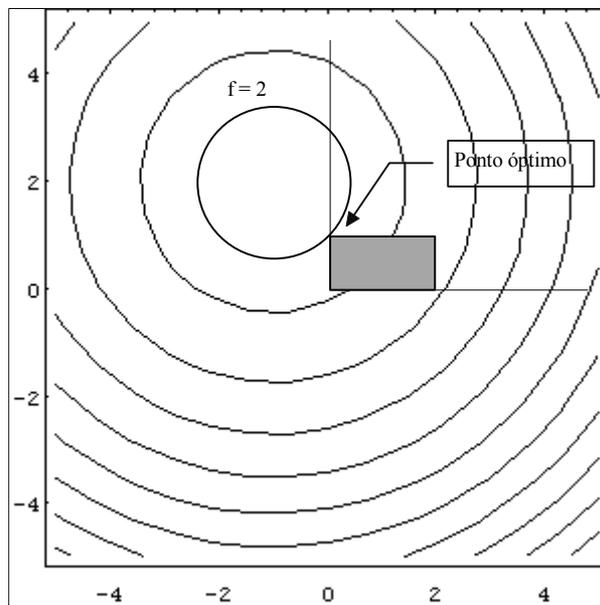
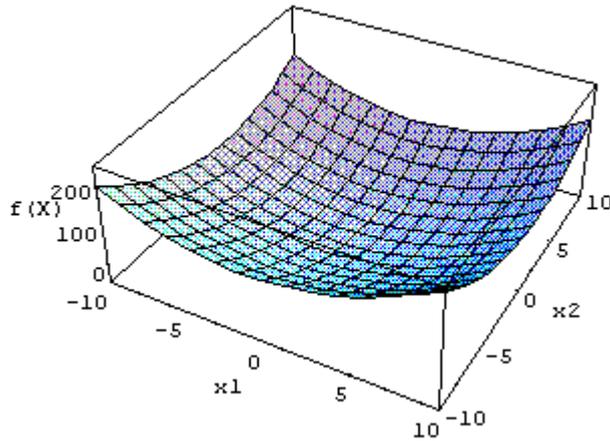
Acresce ainda que sendo Convexa a função proposta para otimizar em espaço Convexo (restrições são lineares) é condição necessária que a solução satisfaça integralmente as condição KKT.

O ponto ótimo 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 λ_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 $x_2 \neq 0$.

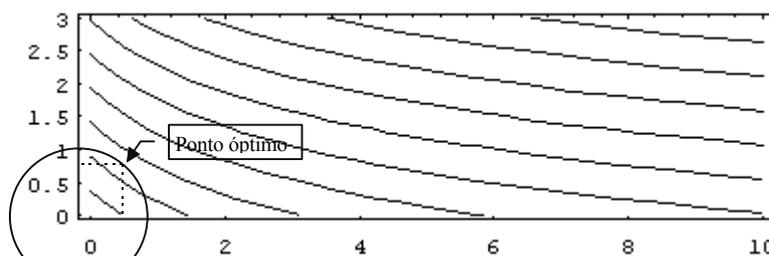
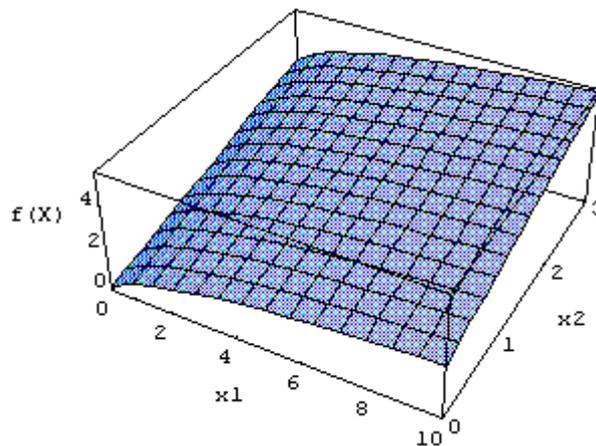
Os multiplicadores λ_1 e λ_2 são complementares pelo que $\lambda_2 = 0$. De facto considerando a restrição na forma de igualdade seria utilizado apenas um multiplicador “ λ ” sem restrição de sinal que poderia ser considerado $\lambda = \lambda_1 - \lambda_2$ com $\lambda_1, \lambda_2 \geq 0$. Ora nesta 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 $x_1 = 0.543689 \approx 0.54$; $x_2 = 0.839287 \approx 0.84$; $\lambda = 0.595744 \approx 0.6$; 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 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 λ_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 λ_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:

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

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

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

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

$$A_1, A_2 \geq 0$$

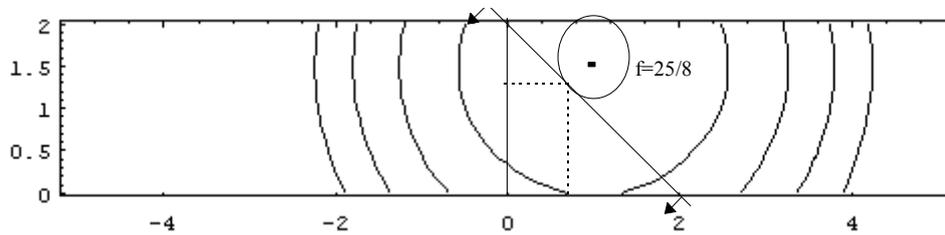
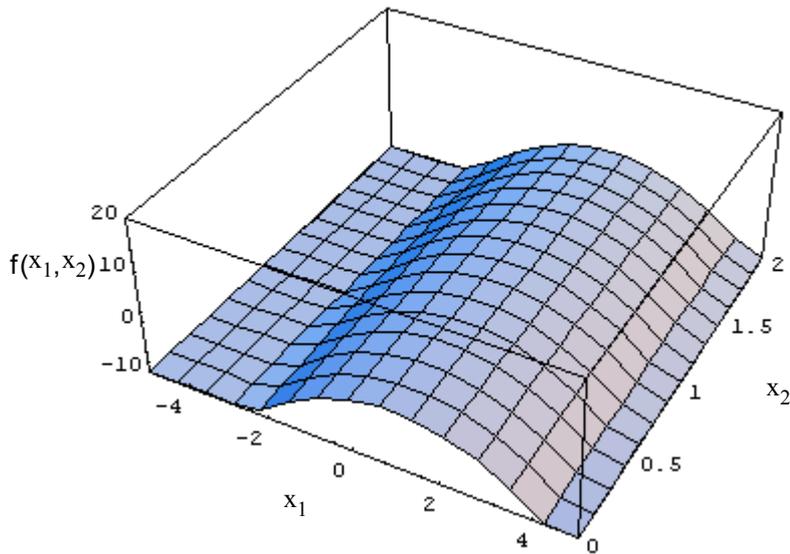
Aplicando o método Simplex modificado por Wolfe tem-se:

VB	x_1	x_2	λ	e_1	e_2	s_1	A_1	A_2	VSM	Obs.
A_1	2	0	2	-1	0	0	1	0	2	“ λ ” 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	0	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	“ λ ” 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 λ .
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	
λ	0	0	1	-1/4	-1/4	-1/4	1/4	1/4	1/4	Sol. óptima.
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 Óptima: $x_1 = 3/4$; $x_2 = 5/4$; $\text{Max } f(x_1, x_2) = 25/8$

Nota: “ λ ” 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:

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

$$\left| H_1 \right| = -4 < 0$$

Matriz H é Definida Negativa

$$\left| H_2 \right| = 16 > 0 \quad \text{A função é Côncava}$$

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:

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

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

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

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

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

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

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

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

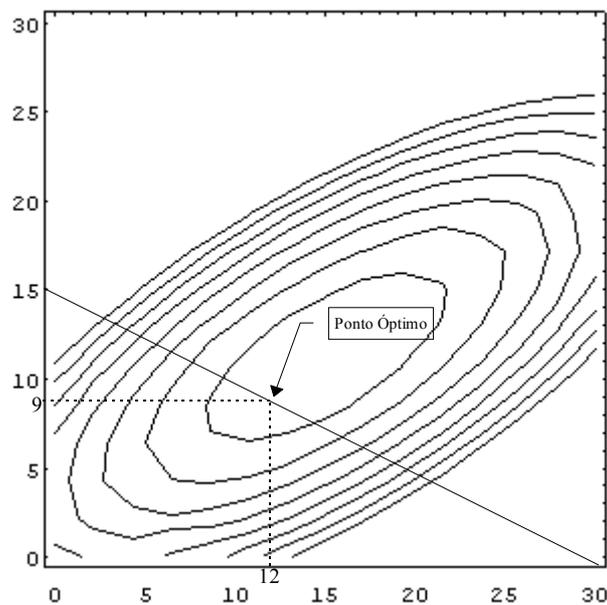
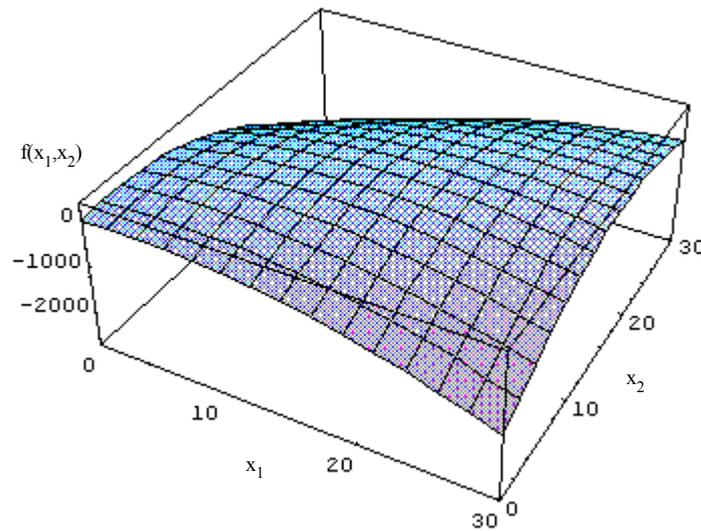
Aplicando o método Simplex modificado por Wolfe tem-se:

VB	x_1	x_2	λ	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 λ não é seleccionável pois s_1 é VB e não sai da base por troca com λ .
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 λ (pode porque s_1 é VNB)
x_2	0	1	1/8	0	-1/16	1/4	0	1/16	75/8	Solução óptima.
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	
λ	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: $x_1 = 12$; $x_2 = 9$; Max $f(x_1, x_2) = 270$

Nota: “ λ ” 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.



4.7 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:

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

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 óptimo.

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:

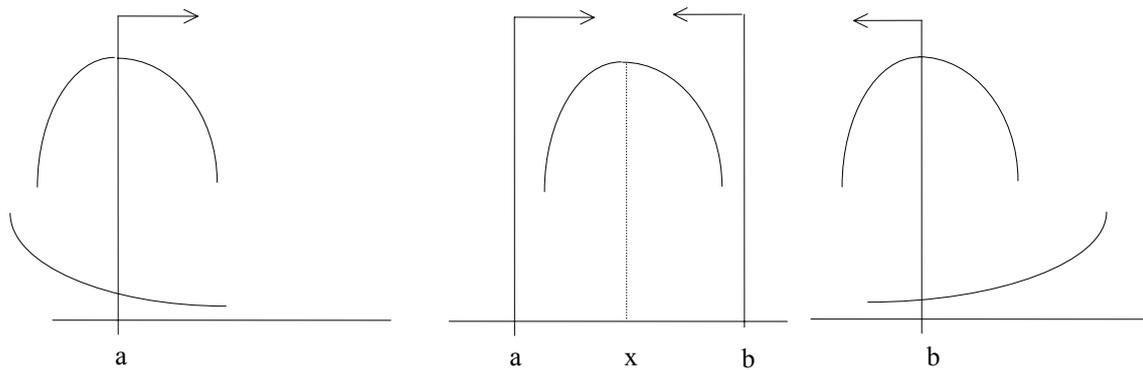
$\frac{\partial f}{\partial x_j} - \sum_{i=1}^m \lambda_i \frac{\partial g_i}{\partial x_j} \leq 0$	(1) $-2+2\lambda x_1 \leq 0$
$x_j \left(\frac{\partial f}{\partial x_j} - \sum_{i=1}^m \lambda_i \frac{\partial g_i}{\partial x_j} \right) = 0$	(2) $-3x_2^2 + 4\lambda x_2 \leq 0$
$g_i - b_i \leq 0$	(3)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

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

(1) $-2+2\lambda x_1 \leq 0$	(1) $-2+2\lambda \leq 0$	(1) $\lambda \leq 1$
(2) $-3x_2^2 + 4\lambda x_2 \leq 0$	(2) $-3+4\lambda \leq 0$	(2) $\lambda \leq 4/3$
(3) $-2x_3 + 2\lambda x_3 \leq 0$	(3) $-2+2\lambda \leq 0$	(3) $\lambda \leq 1$
(4) $x_1 (-2+2\lambda x_1) = 0$	(4) $-2+2\lambda = 0$	(4) $\lambda = 1$ Contradição nos valores de λ
(5) $x_2 (-3x_2^2 + 4\lambda x_2) = 0$	(5) $-3+4\lambda = 0$	(5) $\lambda = 3/4$
(6) $x_3 (-2x_3 + 2\lambda x_3) = 0$	(6) $-2+2\lambda = 0$	(6) $\lambda = 1$
(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 $f(x)$

$$\begin{aligned} \text{s.a.} \quad -x &\leq -a \\ x &\leq b \end{aligned}$$

ou seja:

Max $f(x)$

$$\begin{aligned} \text{s.a.} \quad -x + s_1 + a &= 0 \\ x + s_2 - b &= 0 \\ s_1, s_2 &\geq 0 \end{aligned}$$

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 :

	λ_1	λ_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 óptima 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:

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

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

- em (7) $4x_1 + x_2 < 20$ pelo que λ_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) $x_1, x_2 \geq 0$

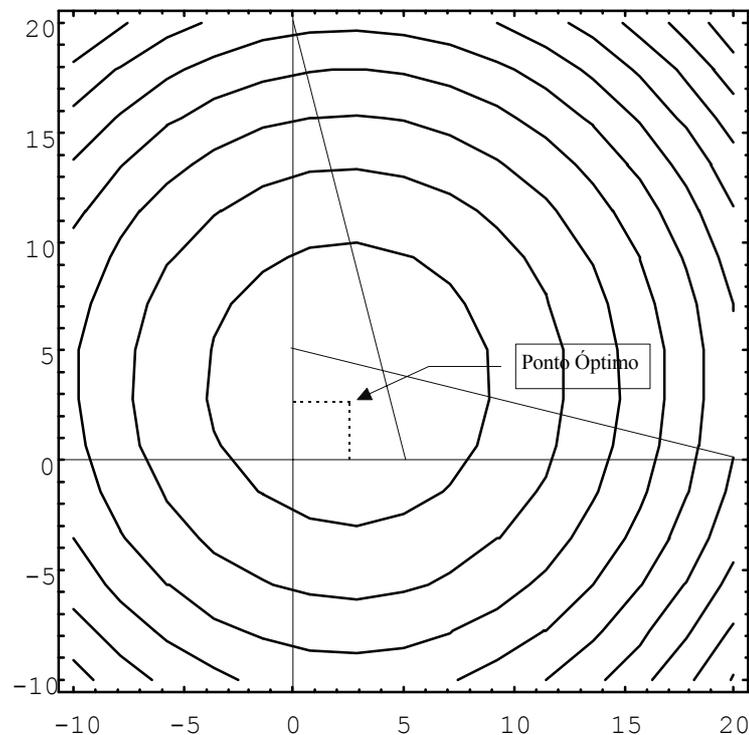
De (3) deduz-se $x_1=0$ ou $(5-2x_1) = 0$. Para $x_1 = 0$ a condição (1) é violada pelo que $(5-2x_1) = 0$ ou seja $x_1=5/2$.

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 $x_2=7/2$.

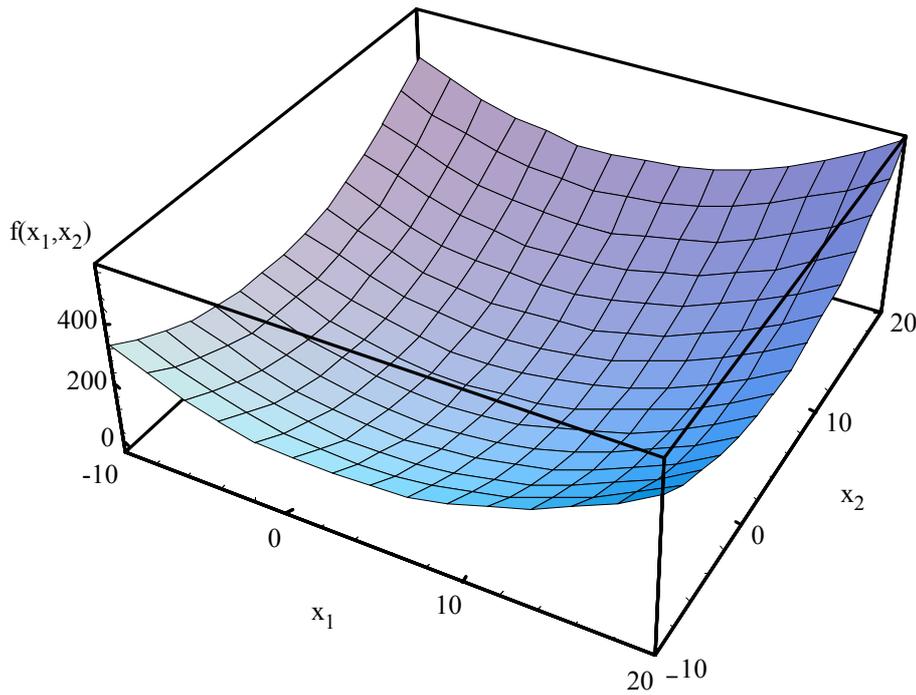
Com $x_1 = 5/2$ e $x_2 = 7/2$ todas as condições KKT são satisfeitas.

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 óptimo 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:

$\frac{\partial f}{\partial x_j} - \sum_{i=1}^m \lambda_i \frac{\partial g_i}{\partial x_j} \leq 0$	(1) $-2x_1 - 2 - 2x_2 + 2\lambda_1 + \lambda_2 \leq 0$
$x_j \left(\frac{\partial f}{\partial x_j} - \sum_{i=1}^m \lambda_i \frac{\partial g_i}{\partial x_j} \right) = 0$	(2) $-2x_1 - 8x_2 + \lambda_1 + 2\lambda_2 \leq 0$
$g_i - b_i \leq 0$	(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) $x_1, x_2 \geq 0$

Colocando as condições (1), (2), (5) e (6) na forma de igualdade tem-se:

$$-2x_1 - 2x_2 + 2\lambda_1 + \lambda_2 + s_1 = 2$$

$$-2x_1 - 8x_2 + \lambda_1 + 2\lambda_2 + s_2 = 0$$

$$2x_1 + x_2 - e_1 = 10$$

$$x_1 + 2x_2 - e_2 = 10$$

$$\text{com } s_1, s_2, e_1, e_2 \geq 0$$

Atendendo ao valor das variáveis auxiliares s_1, s_2, e_1, e_2 e à restrição de complementaridade as condições

KKT são equivalentes a:

$$-2x_1 - 2x_2 + 2\lambda_1 + \lambda_2 + s_1 = 2$$

$$-2x_1 - 8x_2 + \lambda_1 + 2\lambda_2 + s_2 = 0$$

$$2x_1 + x_2 - e_1 = 10$$

$$x_1 + 2x_2 - e_2 = 10$$

$$x_1 s_1 + x_2 s_2 + \lambda_1 e_1 + \lambda_2 e_2 = 0 \text{ (restrição de complementaridade)}$$

$$x_1, x_2, \lambda_1, \lambda_2, s_1, s_2, e_1, e_2 \geq 0$$

Para utilizar o método Simplex é necessário utilizar variáveis Artificiais nas 3ª e 4ª igualdades e Minimizar a sua soma pelo que se tem:

$$-2x_1 - 2x_2 + 2\lambda_1 + \lambda_2 + s_1 = 2$$

$$-2x_1 - 8x_2 + \lambda_1 + 2\lambda_2 + s_2 = 0$$

$$2x_1 + x_2 - e_1 + A_1 = 10$$

$$x_1 + 2x_2 - e_2 + A_2 = 10$$

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

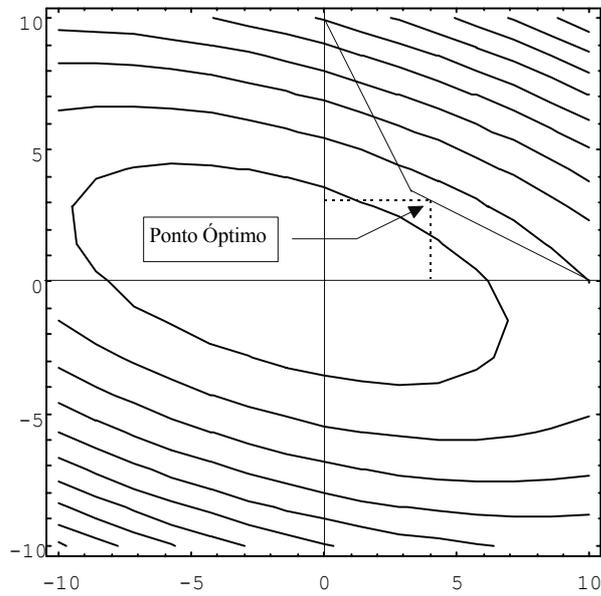
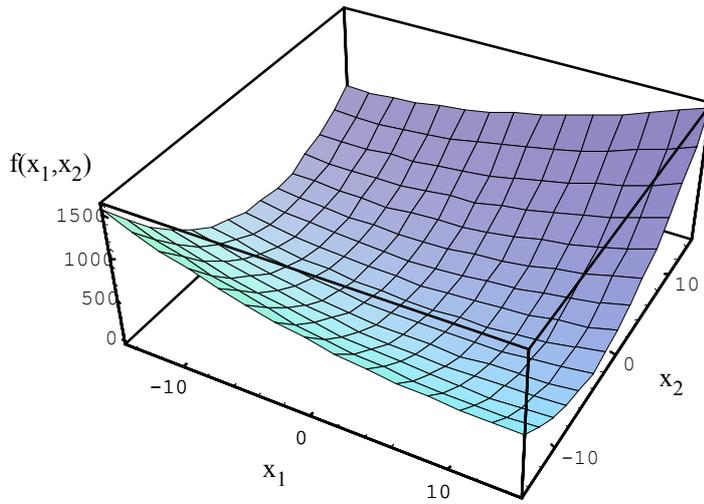
$$A_1, A_2 \geq 0$$

Aplicando o método Simplex modificado por Wolfe:

VB	x_1	x_2	λ_1	λ_2	e_1	e_2	s_1	s_2	A_1	A_2	VSM	Obs.
s_1	-2	-2	2	1	0	0	1	0	0	0	2	Entra x_2 pois s_2 pode sair garantindo-se $x_2 s_2 = 0$
s_2	-2	-8	1	2	0	0	0	1	0	0	0	
A_1	2	1	0	0	-1	0	0	0	1	0	10	
A_2	1	2	0	0	0	-1	0	0	0	1	10	
$-f^a$	0	0	0	0	0	0	0	0	1	1	0	
$-f^a$	-3	-3	0	0	1	1	0	0	0	0	-20	
• •												
x_1	1	0	-3/4	0	0	-1/2	-1/2	1/4	0	1/2	4	Solução óptima
x_2	0	1	3/8	0	0	-1/4	1/4	-1/8	0	1/4	3	
λ_2	0	0	5/4	1	0	-3/2	1/2	1/4	0	3/2	16	
e_1	0	0	-9/8	0	1	-5/4	-3/4	3/8	-1	5/4	1	
$-f^a$	0	0	0	0	0	0	0	0	1	1	0	

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

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:

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

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:

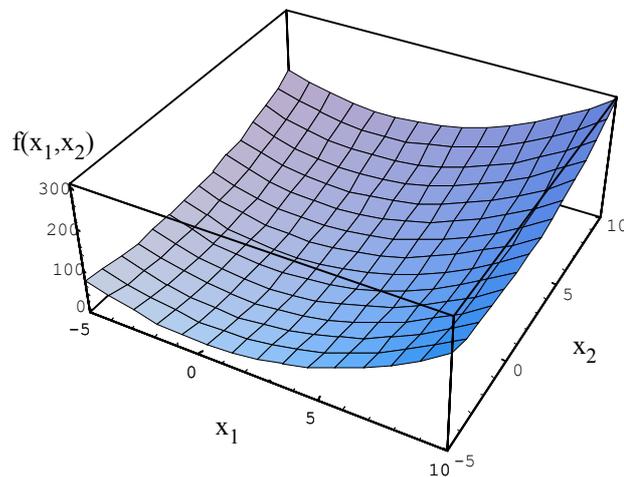
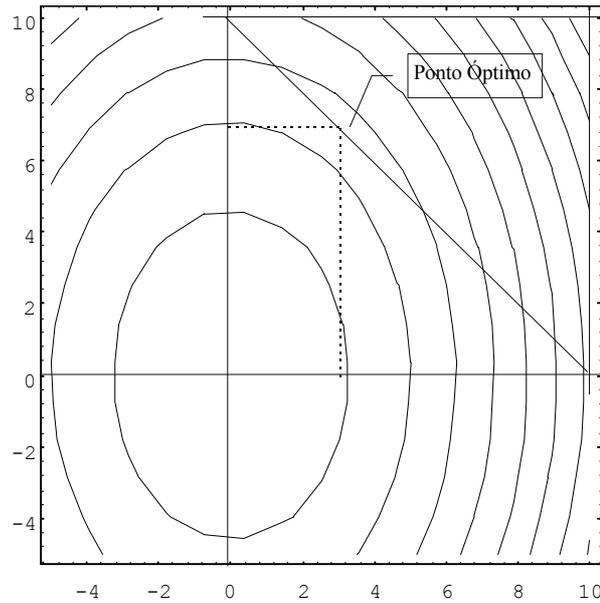
$$\begin{aligned} \text{Min } f^a &= A_1 \\ -4x_1 - \lambda_1 + \lambda_2 + s_1 &= 0 \\ -2x_2 - \lambda_1 + \lambda_2 + s_2 &= 0 \\ x_1 + x_2 + s_3 &= 10 \\ x_1 + x_2 - e_1 + A_1 &= 10 \\ \text{com } x_1, x_2, \lambda_1, \lambda_2, s_1, s_2, s_3, e_1, A_1 &\geq 0 \end{aligned}$$

Aplicando o método Simplex modificado por Wolfe:

VB	x_1	x_2	λ_1	λ_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 λ_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	
λ_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 λ_1)
- $-x_1 + x_2 - s_2 + 1 = 0$ (derivada parcial em ordem a λ_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 λ_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:

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

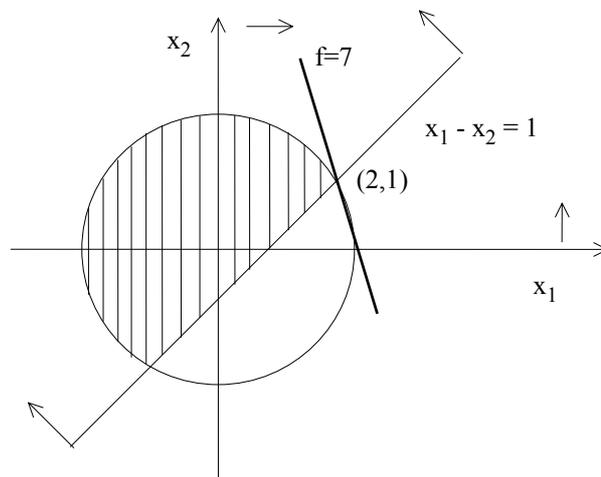
$$x_1 - x_2 = 1$$

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:

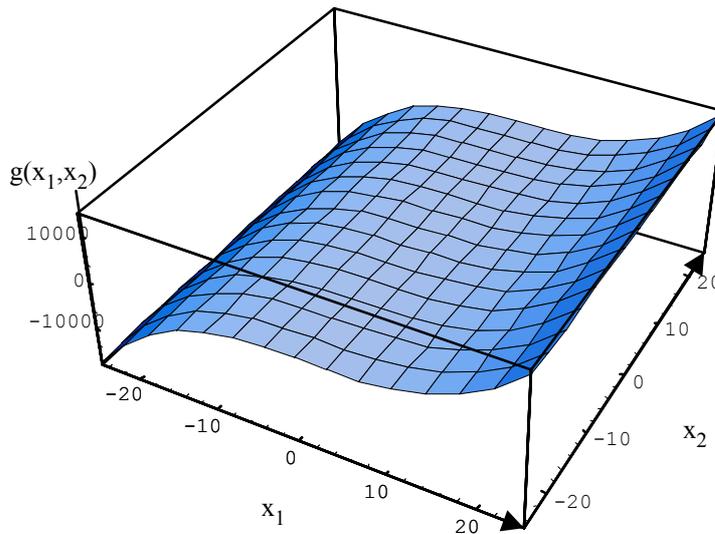
$$1 - 3\lambda(1 - x_1)^2 \leq 0$$

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

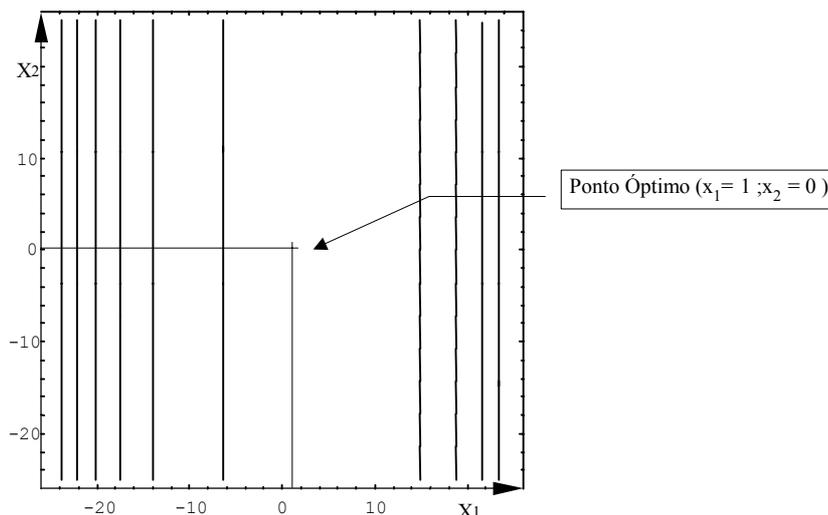
$$1 - 3\lambda(0)^2 \leq 0$$

$$1 \leq 0 \text{ (não satisfaz)}$$

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:

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

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

The diagram shows a central point labeled $x_1=1; x_2=0$. Three vectors originate from this point: $\nabla[x_2 - (1-x_1)^3]$ pointing vertically upwards, $\nabla(f)$ pointing horizontally to the right, and $\nabla(-x_2)$ pointing vertically downwards.

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 “ \geq ”, passá-la a “ \leq ” multiplicando por “-1”.

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

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

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

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

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 “ α ” ficando o sistema de equações:

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

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 “ α ” seja nula e as restantes variáveis tenham valor não negativo garantindo a satisfação da restrição de complementaridade:

$$x_j E_j + \lambda_i S_i = 0$$

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

1ª Iteração

- *Entra* para a base a variável “ α ”.
- *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 “ θ_{\min} ” usual em Simplex

Regra de Paragem

- O processo iterativo termina se “ α ” 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):

$$\begin{cases} -2x_1 - 2\lambda + e_1 - \alpha & = & -2 \\ 3 - 2x_2 - 2\lambda + e_2 - \alpha & = & -3 \\ 2x_1 + 2x_2 + s_1 & = & 4 \end{cases}$$

Recorrendo ao método Simplex tem-se:

VB	x_1	x_2	λ	e_1	e_2	s_1	α	VSM	Obs.
e_1	-2	0	-2	1	0	0	-1	-2	Entra α .
e_2	0	-2	-2	0	1	0	-1	-3	Sai e_2
s_1	2	2	0	0	0	1	-1	4	
α	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
α	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 λ
x_2	0	1	1/3	1/6	-1/3	1/6	0	4/3	Sai α
α	0	0	4/3	-1/3	-1/3	-1/3	1	1/3	
λ	0	0	1	-1/4	-1/4	-1/4	3/4	1/4	Solução óptima pois “ α ” 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:

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

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	λ	e_1	e_2	s_1	α	VSM	Obs.
----	-------	-------	-----------	-------	-------	-------	----------	-----	------

e_1	-4	4	-1	1	0	0	-1	-15	Entra α .
e_2	4	-8	-2	0	1	0	-1	-30	Sai e_2
s_1	1	2	0	0	0	1	-1	30	
α	-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
α	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 λ
x_2	0	1	13/44	-3/44	-5/44	2/11	0	435/44	Sai α
α	0	0	10/11	-4/11	-3/4	-4/11	1	30/11	
λ	0	0	1	-2/5	-3/10	-2/5	11/10	3	Solução óptima pois “ α ” 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:

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

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

$$\left\{ \begin{array}{l} -2x_1 - 2x_2 + 2\lambda_1 + \lambda_2 + e_1 - \alpha = 2 \end{array} \right.$$

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

Recorrendo ao método Simplex tem-se:

VB	x_1	x_2	λ_1	λ_2	e_1	e_2	s_1	s_2	α	VSM	Obs.
e_1	-2	-2	2	1	1	0	0	0	-1	2	Entra α
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	
α	2	1	0	0	0	0	-1	0	1	10	Saiu $s_1 \Rightarrow$ Entra λ_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	
λ_1	0	-1/2	1	1/2	1/2	0	-1/2	0	0	6	Saiu $e_1 \Rightarrow$ Entra x_1
α	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 λ_2
λ_1	0	-1/2	1	1/2	1/2	0	-1/2	0	0	6	Sai e_2
α	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	
λ_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 λ_1
λ_1	0	5/3	1	0	2/3	-1/3	-1/3	0	0	14/3	
α	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
λ_2	0	0	13/5	1	7/5	-1/5	-6/5	0	0	74/5	Sai α
x_1	1	0	3/5	0	2/5	-1/5	-6/5	1	0	14/5	
α	0	0	-9/5	0	-6/5	3/5	8/5	-2	1	8/5	

• • • • • • • • • •

VB	x_1	x_2	λ_1	λ_2	e_1	e_2	s_1	s_2	α	VSM	Obs.
s_1	0	0	-9/8	0	-3/4	3/8	1	-5/4	5/8	1	Solução óptima pois “ α ” é VNB
x_2	0	1	3/8	0	1/4	-1/8	0	-1/4	1/8	3	
λ_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).

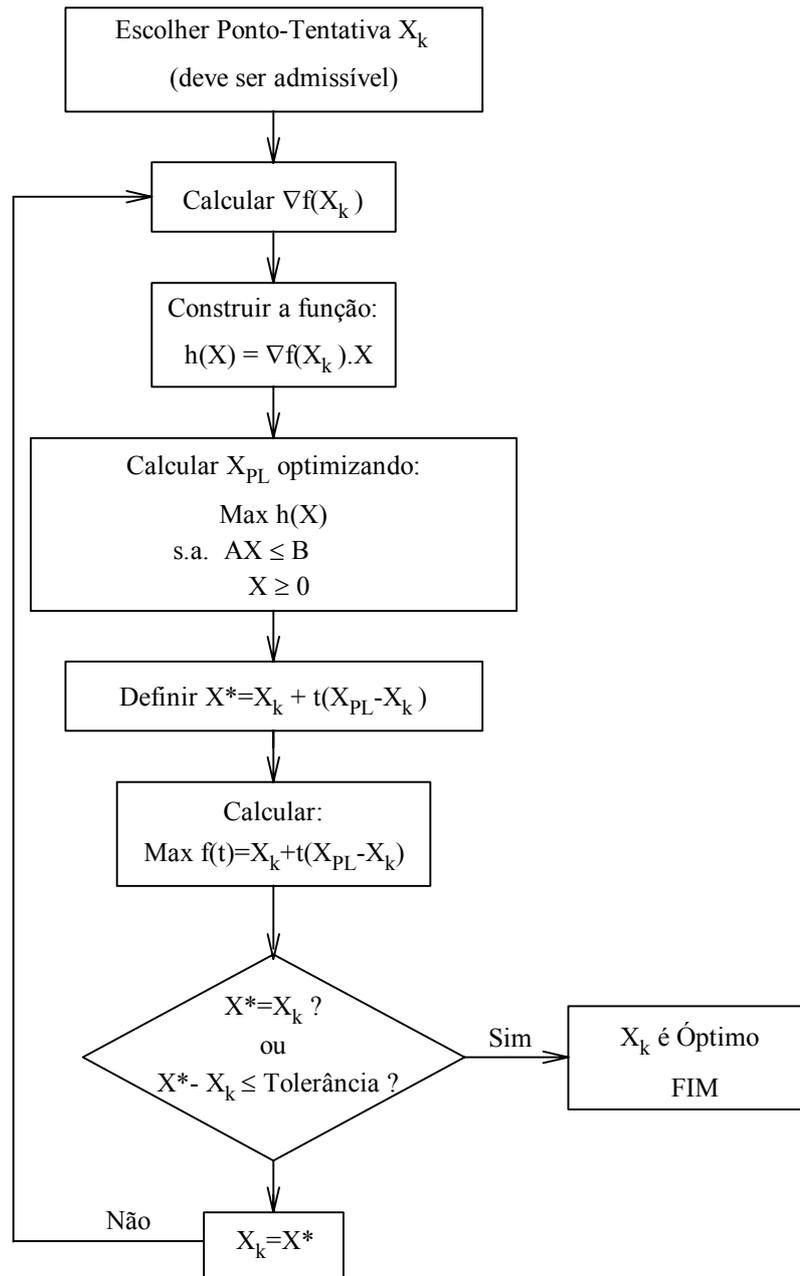
Em X^* tem-se $f(X^*) \geq f(X_0)$ pelo que:

- 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 ótima $X_{PL} = (1, 0)$.

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 ótimo 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 ótima $X_{PL} = (1, 0)$.

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 ótima 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 ótima 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. Porque $X^* \neq X_3$ considerava-se para novo ponto-tentativa $X_4 = X^* = \begin{bmatrix} 7.996 \\ 5.4 \end{bmatrix}$

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 “ ∞ ” 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 “ θ ” 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 $rB(X) \leq \varepsilon$ (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:

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

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

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

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

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

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

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

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

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

Dispõe-se assim do sistema de equações:

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

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:

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

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

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

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 :

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

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

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

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

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

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

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

Admitindo x_1, x_2, λ diferentes de zero, tem-se o sistema de equações:

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

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:

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