

# Ottimizzazione dei Sistemi Complessi

G. Liuzzi<sup>1</sup>

Giovedì 23 Marzo 2017

---

<sup>1</sup>Istituto di Analisi dei Sistemi ed Informatica IASI - CNR

# Definizione

Teoricamente è possibile definire

$$q_{\infty}(x) = \begin{cases} 0 & \text{se } x \in \mathcal{F} \\ +\infty & \text{se } x \notin \mathcal{F} \end{cases}$$

e quindi

$$P_{\infty}(x) = f(x) + q_{\infty}(x)$$

È evidente che:

- risolvere il problema  $\min P_{\infty}(x)$  fornisce soluzioni del problema ( $P_0$ ).
- minimizzare  $P_{\infty}(x)$  è (o può essere) molto “complicato”

# Definizione

Teoricamente è possibile definire

$$q_{\infty}(x) = \begin{cases} 0 & \text{se } x \in \mathcal{F} \\ +\infty & \text{se } x \notin \mathcal{F} \end{cases}$$

e quindi

$$P_{\infty}(x) = f(x) + q_{\infty}(x)$$

È evidente che:

- risolvere il problema  $\min P_{\infty}(x)$  fornisce soluzioni del problema  $(P_0)$ .
- minimizzare  $P_{\infty}(x)$  è (o può essere) molto “complicato”

# Definizione

Anziché  $q_\infty(x)$ , definiamo

$$q(x) = \begin{cases} 0 & \text{se } x \in \mathcal{F} \\ > 0 & \text{se } x \notin \mathcal{F} \end{cases}$$

e quindi

$$P_\epsilon(x) = f(x) + \frac{1}{\epsilon}q(x)$$

**N.B.:**

- se  $f(x)$  e  $q(x)$  sono cont. differenziabili, allora anche  $P_\epsilon(x)$  lo è
- per ogni  $x \in \mathbb{R}^n$ ,  $\lim_{\epsilon \rightarrow 0} P_\epsilon(x) = P_\infty(x)$

# Espressione di $q(x)$

Il termine  $q(x)$  deve “penalizzare con continuità” l’eventuale inammissibilità di  $x$

P.es., con riferimento a  $(P_0)$ ,

$$q(x) = \sum_{i=1}^p [h_i(x)]^2 + \sum_{i=1}^m [\max\{0, g_i(x)\}]^2$$

- per nessun valore di  $\epsilon > 0$ ,  $\min P_\epsilon(x)$  è equivalente a  $(P_0)$
- per ogni valore di  $\epsilon > 0$ , una min. non vincolata di  $P_\epsilon(x)$  produce (in genere) un punto  $x^* \notin \mathcal{F}$ , cioè  $q(x^*) > 0$

# Algoritmo di soluzione

## Algoritmo SEQPEN

INPUT:  $\text{maxit}$ ,  $\tau > 0$ ,  $k = 0$ ,  $\epsilon_0 > 0$

**for**  $k = 0, 1, \dots, \text{maxit}$

Trova una soluzione ( $x(\epsilon_k)$ ) del problema

$$\min_{x \in \mathbb{R}^n} P_{\epsilon_k}(x). \quad (1)$$

**if**  $q(x(\epsilon_k)) \leq \tau$  **then** STOP

$\epsilon_{k+1} = \epsilon_k/2$

**endfor**

OUTPUT: una sol. approssimata  $x^* = x(\epsilon_k)$

# Proprietà di convergenza

Sia  $\mathcal{F}_\sigma = \{x \in \mathbb{R}^n : |h(x)| \leq \sigma, g(x) \leq \sigma\}$  insieme ammissibile "rilassato" ( $\mathcal{F} \subset \mathcal{F}_\sigma$ )

## Teorema (Conv. a minimi globali)

*Siano soddisfatte le ipotesi seguenti:*

- *esiste un  $\sigma > 0$  t.c.  $\mathcal{F}_\sigma$  è compatto;*
- *per ogni  $k$ , la funzione  $P_{\epsilon_k}(x)$  ammette minimo globale  $x^k$ .*

*Allora,  $\{x^k\}$  ammette punti limite ed ogni punto limite è un minimo globale di  $(P_0)$*

# Esempio 1

Consideriamo il seguente problema vincolato (banale)

$$\begin{aligned} \min \quad & x^2 \\ & x \geq 1 \end{aligned}$$

Ammette  $x^* = 1$  come **unico** punto di minimo globale

La funzione di penalità esterna è:

$$P_\epsilon(x) = x^2 + \frac{1}{\epsilon} \max\{0, 1 - x\}^2$$



# Esempio 1

Consideriamo il seguente problema vincolato (banale)

$$\begin{aligned} \min \quad & x^2 \\ & x \geq 1 \end{aligned}$$


Ammette  $x^* = 1$  come **unico** punto di minimo globale

La funzione di penalità esterna è:

$$P_\epsilon(x) = x^2 + \frac{1}{\epsilon} \max\{0, 1 - x\}^2$$

# Esempio 1

Grafici di  $P_\epsilon(x)$  ( $\epsilon = 1, 0.5, 0.2, 0.1, 0.05$ )



## Esempio 2

Consideriamo il seguente problema vincolato (banale)

$$\begin{aligned} \min \quad & -x^4 \\ & x = 1 \end{aligned}$$

Ammette (ovviamente)  $x^* = 1$  come **unico** punto di minimo globale

La funzione di penalità esterna è:

$$P_\epsilon(x) = -x^4 + \frac{1}{\epsilon}(x - 1)^2$$

## Esempio 2

Consideriamo il seguente problema vincolato (banale)

$$\begin{aligned} \min \quad & -x^4 \\ & x = 1 \end{aligned}$$


Ammette (ovviamente)  $x^* = 1$  come **unico** punto di minimo globale

La funzione di penalità esterna è:

$$P_\epsilon(x) = -x^4 + \frac{1}{\epsilon}(x - 1)^2$$

# Esempio 2

Grafici di  $P_\epsilon(x)$  ( $\epsilon = 1, 0.5, 0.2, 0.1, 0.05$ )



# Algoritmo SEQPEN modificato

**Algoritmo** SEQPEN<sub>mod</sub>INPUT: maxit,  $\{\tau_k\} \rightarrow 0$ ,  $\rho > 0$ ,  $k = 0$ ,  $\epsilon_0 > 0$ **for**  $k = 0, 1, \dots, \text{maxit}$     Calcola  $x(\epsilon_k)$  t.c.  $\|\nabla P_{\epsilon_k}(x(\epsilon_k))\| \leq \tau_k$     **if**  $\tau_k < \rho$  **and**  $q(x(\epsilon_k)) \leq \rho$  **then** STOP     $\epsilon_{k+1} = \epsilon_k/2$ **endfor**OUTPUT: una sol. approssimata  $x^* = x(\epsilon_k)$

# Proprietà di convergenza

## Teorema

Sia  $\{x_k\}$  una successione t.c.  $\|\nabla P_{\epsilon_k}(x_k)\| \leq \tau_k$  e  $\{x_k\}_K$  una sottosucc. convergente ad  $x^*$  t.c. siano lin. indipendenti

$$\nabla g_i(x^*), i \in I_0(x^*), \nabla h_j(x^*), \forall j.$$

Allora,  $x^*$  è un punto di KKT di  $(P_0)$  con molt.  $\lambda^*$  e  $\mu^*$  t.c.

$$\left\{ \frac{1}{\epsilon_k} \max\{g(x_k), 0\} \right\}_K \rightarrow \lambda^*$$
$$\left\{ \frac{1}{\epsilon_k} h(x_k) \right\}_K \rightarrow \mu^*$$

## Esempio 3

Consideriamo il seguente problema vincolato (banale)

$$\begin{aligned} \min \quad & -x - y \\ & x^2 + y^2 = 1 \end{aligned}$$

Ammette  $(x^*, y^*) = (1, 1)/\sqrt{2}$  come **unico** punto di minimo globale

La funzione di penalità esterna è:

$$P_\epsilon(x) = -x - y + \frac{1}{\epsilon}(1 - x^2 - y^2)^2$$



## Esempio 3

Consideriamo il seguente problema vincolato (banale)

$$\begin{aligned} \min \quad & -x - y \\ & x^2 + y^2 = 1 \end{aligned}$$


Ammette  $(x^*, y^*) = (1, 1)/\sqrt{2}$  come **unico** punto di minimo globale

La funzione di penalità esterna è:

$$P_\epsilon(x) = -x - y + \frac{1}{\epsilon}(1 - x^2 - y^2)^2$$

# Esempio 3

Grafici di  $P_\epsilon(x)$  ( $\epsilon = 1, 0.5, 0.05$ )



# Tanto per cominciare

Consideriamo il problema con soli vincoli di uguaglianza

$$\begin{array}{ll} \min & f(x) \\ \text{c.v.} & h(x) = 0 \end{array}$$

Funzione Lagrangiana:  $L(x, \mu) = f(x) + \mu^\top h(x)$

con gradiente (vi ricordo):

$$\begin{aligned} \nabla_x L(x, \mu) &= \nabla f(x) + \nabla h(x) \mu \\ \nabla_\mu L(x, \mu) &= h(x) \end{aligned}$$

Perciò, le C.N. di ottimo si possono riassumere in:  $\nabla L(x, \mu) = 0$

# Tanto per cominciare

Consideriamo il problema con soli vincoli di uguaglianza

$$\begin{array}{ll} \min & f(x) \\ \text{c.v.} & h(x) = 0 \end{array}$$

Funzione Lagrangiana:  $L(x, \mu) = f(x) + \mu^T h(x)$

con gradiente (vi ricordo):

$$\begin{aligned} \nabla_x L(x, \mu) &= \nabla f(x) + \nabla h(x) \mu \\ \nabla_\mu L(x, \mu) &= h(x) \end{aligned}$$

Perciò, le C.N. di ottimo si possono riassumere in:  $\nabla L(x, \mu) = 0$

# Tanto per cominciare

Consideriamo il problema con soli vincoli di uguaglianza

$$\begin{array}{ll} \min & f(x) \\ \text{c.v.} & h(x) = 0 \end{array}$$

Funzione Lagrangiana:  $L(x, \mu) = f(x) + \mu^T h(x)$

con gradiente (vi ricordo):

$$\begin{aligned} \nabla_x L(x, \mu) &= \nabla f(x) + \nabla h(x) \mu \\ \nabla_\mu L(x, \mu) &= h(x) \end{aligned}$$

Perciò, le C.N. di ottimo si possono riassumere in:  $\nabla L(x, \mu) = 0$

# Tanto per cominciare

Consideriamo il problema con soli vincoli di uguaglianza

$$\begin{aligned} \min \quad & f(x) \\ \text{c.v.} \quad & h(x) = 0 \end{aligned}$$

Funzione Lagrangiana:  $L(x, \mu) = f(x) + \mu^\top h(x)$

con gradiente (vi ricordo):

$$\begin{aligned} \nabla_x L(x, \mu) &= \nabla f(x) + \nabla h(x) \mu \\ \nabla_\mu L(x, \mu) &= h(x) \end{aligned}$$

Perciò, le C.N. di ottimo si possono riassumere in:  $\nabla L(x, \mu) = 0$

## Quindi ...

Punti che soddisfano le C.N. di ottimo sono punti staz. della funzione Lagrangiana  $L(x, \mu)$  !!

Purtroppo però, accade che le soluzioni del problema originario corrispondono (spesso) con punti di “sella” della funzione Lagrangiana.

Quindi, non si può (banalmente) minimizzare  $L(x, \mu)$  per risolvere il problema originario

## Quindi ...

Punti che soddisfano le C.N. di ottimo sono punti staz. della funzione Lagrangiana  $L(x, \mu)$  !!

Purtroppo però, accade che le soluzioni del problema originario corrispondono (spesso) con punti di “sella” della funzione Lagrangiana.

Quindi, non si può (banalmente) minimizzare  $L(x, \mu)$  per risolvere il problema originario



## Quindi ...

Punti che soddisfano le C.N. di ottimo sono punti staz. della funzione Lagrangiana  $L(x, \mu)$  !!

Purtroppo però, accade che le soluzioni del problema originario corrispondono (spesso) con punti di “sella” della funzione Lagrangiana.

Quindi, non si può (banalmente) minimizzare  $L(x, \mu)$  per risolvere il problema originario

# Fortunatamente ...

Possiamo “convessificare”  $L(x, \mu)$  nell’intorno delle soluzione del problema originario (semplicemente) aggiungendo un termine di penalità, con  $\epsilon > 0$  “sufficientemente” piccolo

$$L_a(x, \mu; \epsilon) = L(x, \mu) + \frac{1}{\epsilon} \|h(x)\|^2$$

*con gradiente*

$$\nabla_x L_a(x, \mu; \epsilon) = \nabla_x L(x, \mu) + \frac{2}{\epsilon} \nabla h(x) h(x)$$

$$\nabla_\mu L_a(x, \mu; \epsilon) = \nabla_\mu L(x, \mu) = h(x)$$

# Fortunatamente ...

Possiamo “convessificare”  $L(x, \mu)$  nell’intorno delle soluzione del problema originario (semplicemente) aggiungendo un termine di penalità, con  $\epsilon > 0$  “sufficientemente” piccolo

$$L_a(x, \mu; \epsilon) = L(x, \mu) + \frac{1}{\epsilon} \|h(x)\|^2$$

*con gradiente*

$$\nabla_x L_a(x, \mu; \epsilon) = \nabla_x L(x, \mu) + \frac{2}{\epsilon} \nabla h(x) h(x)$$

$$\nabla_\mu L_a(x, \mu; \epsilon) = \nabla_\mu L(x, \mu) = h(x)$$

# Prima proprietà

## Proposizione

*Per ogni valore  $\epsilon > 0$ , ogni punto staz. di  $L_a(x, \mu; \epsilon)$  è un punto di KKT del problema originario e viceversa*

**Dim.:** Sia  $(\bar{x}, \bar{\mu})$  un punto t.c.  $\nabla L_a(\bar{x}, \bar{\mu}) = 0$ . Allora, dalla espr. del gradiente risulta, banalmente:  $h(\bar{x}) = 0$  e quindi  $\nabla_x L(\bar{x}, \bar{\mu}) = 0$ , ovvero  $(\bar{x}, \bar{\mu})$  è un punto di KKT.

Supponiamo ora che  $(\bar{x}, \bar{\mu})$  sia un punto di KKT e quindi, in particolare,  $h(\bar{x}) = 0$  e  $\nabla_x L(\bar{x}, \bar{\mu}) = 0$ . Allora, dalla espr. del gradiente di  $L_a$  si ricava nuovamente  $\nabla L_a(\bar{x}, \bar{\mu}) = 0$ . □

# Prima proprietà

## Proposizione

*Per ogni valore  $\epsilon > 0$ , ogni punto staz. di  $L_a(x, \mu; \epsilon)$  è un punto di KKT del problema originario e viceversa*

**Dim.:** Sia  $(\bar{x}, \bar{\mu})$  un punto t.c.  $\nabla L_a(\bar{x}, \bar{\mu}) = 0$ . Allora, dalla espr. del gradiente risulta, banalmente:  $h(\bar{x}) = 0$  e quindi  $\nabla_x L(\bar{x}, \bar{\mu}) = 0$ , ovvero  $(\bar{x}, \bar{\mu})$  è un punto di KKT.

Supponiamo ora che  $(\bar{x}, \bar{\mu})$  sia un punto di KKT e quindi, in particolare,  $h(\bar{x}) = 0$  e  $\nabla_x L(\bar{x}, \bar{\mu}) = 0$ . Allora, dalla espr. del gradiente di  $L_a$  si ricava nuovamente  $\nabla L_a(\bar{x}, \bar{\mu}) = 0$ . □

# Esempio


Consideriamo il problema

$$\begin{aligned} \min \quad & x^3 \\ \text{s.t.} \quad & x = 0 \end{aligned}$$

per cui risulta (banalmente)  $x^* = 0$  e  $\mu^* = 0$


# Esempio

Andamenti della funzione  $L_a(x, -100; \epsilon)$  per  $\epsilon = 1, 0.1, 0.01$



# Esempio

Andamenti della funzione  $L_a(x, -1; \epsilon)$  per  $\epsilon = 1, 0.1, 0.01$





## Seconda proprietà

È possibile “minimizzare  $L_a(x, \mu)$ ” per determinare minimi locali del problema originario?

**No**,  $L_a(x, \mu)$  è lineare in  $\mu$

Si può tentare di minimizzare  $L_a(x, \bar{\mu})$  per  $\mu$  fissato

Cosa manca?

## Seconda proprietà

È possibile “minimizzare  $L_a(x, \mu)$ ” per determinare minimi locali del problema originario?

**No**,  $L_a(x, \mu)$  è lineare in  $\mu$

Si può tentare di minimizzare  $L_a(x, \bar{\mu})$  per  $\mu$  fissato

Cosa manca?

## Seconda proprietà

È possibile “minimizzare  $L_a(x, \mu)$ ” per determinare minimi locali del problema originario?

**No**,  $L_a(x, \mu)$  è lineare in  $\mu$

Si può tentare di minimizzare  $L_a(x, \bar{\mu})$  per  $\mu$  fissato

Cosa manca?

## Seconda proprietà

È possibile “minimizzare  $L_a(x, \mu)$ ” per determinare minimi locali del problema originario?

**No**,  $L_a(x, \mu)$  è lineare in  $\mu$

Si può tentare di minimizzare  $L_a(x, \bar{\mu})$  per  $\mu$  fissato

Cosa manca?

## Seconda proprietà

Sia  $\bar{x}$  una sol. del problema vincolato originale tale che:

- $\bar{x}$  è un punto regolare per i vincoli
- la coppia di KKT  $(\bar{x}, \bar{\mu})$  soddisfa le C.S. del II ordine

### Proposizione

*Per valori sufficientemente piccoli di  $\epsilon > 0$ ,  $\bar{x}$  è un minimo locale stretto di  $L_a(x, \bar{\mu}; \epsilon)$*

**N.B.** è necessario conoscere  $\bar{\mu}$ !

## Seconda proprietà

Sia  $\bar{x}$  una sol. del problema vincolato originale tale che:

- $\bar{x}$  è un punto regolare per i vincoli
- la coppia di KKT  $(\bar{x}, \bar{\mu})$  soddisfa le C.S. del II ordine

### Proposizione

Per **valori sufficientemente piccoli di  $\epsilon > 0$** ,  $\bar{x}$  è un minimo locale stretto di  $L_a(x, \bar{\mu}; \epsilon)$

N.B. è necessario conoscere  $\bar{\mu}$ !

## Seconda proprietà

Sia  $\bar{x}$  una sol. del problema vincolato originale tale che:

- $\bar{x}$  è un punto regolare per i vincoli
- la coppia di KKT  $(\bar{x}, \bar{\mu})$  soddisfa le C.S. del II ordine

### Proposizione

Per **valori sufficientemente piccoli di**  $\epsilon > 0$ ,  $\bar{x}$  è un minimo locale stretto di  $L_a(x, \bar{\mu}; \epsilon)$

**N.B.** è necessario conoscere  $\bar{\mu}$ !

# Esempio

Consideriamo il problema


$$\begin{aligned} \min \quad & \frac{1}{2}x^2 + \frac{1}{6}y^2 \\ \text{s.t.} \quad & x + y = 1 \end{aligned}$$

Calcolare la soluzione del problema  $(x^*, y^*, \mu^*)$



# Esempio

Curve di livello di  $L_a(x, y, \bar{\mu}; \epsilon)$  per  $\epsilon = 1$  a  $\bar{\mu} = 0, -0.15, -0.25$



# Metodo di soluzione

## Algoritmo SEQLAGR

**Dati:**  $\epsilon_0 > 0$ ,  $\beta > 1$ ,  $\{\tau_k\} \rightarrow 0$ ,  $\{\eta_k\} \rightarrow 0$ ,  $\rho > 0$ ,  $\mu_0$ , maxit

**for**  $k = 0, 1, \dots, \text{maxit}$

Calcola  $x_k$  t.c.  $\|\nabla L_a(x_k, \mu_k; \epsilon_k)\| \leq \tau_k$

**if**  $\|\nabla L_a(x_k, \mu_k; \epsilon_k)\| < \rho$  **then**

$x^* \leftarrow x_k$ ,  $\mu^* \leftarrow \mu_k$ , **STOP**

**endif**

**endfor**

**Return:** miglior coppia trovata  $(x^*, \mu^*)$

# Metodo di soluzione

## Algoritmo SEQLAGR

**Dati:**  $\epsilon_0 > 0$ ,  $\beta > 1$ ,  $\{\tau_k\} \rightarrow 0$ ,  $\{\eta_k\} \rightarrow 0$ ,  $\rho > 0$ ,  $\mu_0$ , maxit

**for**  $k = 0, 1, \dots, \text{maxit}$

Calcola  $x_k$  t.c.  $\|\nabla L_a(x_k, \mu_k; \epsilon_k)\| \leq \tau_k$

**if**  $\|\nabla L_a(x_k, \mu_k; \epsilon_k)\| < \rho$  **then**

$x^* \leftarrow x_k$ ,  $\mu^* \leftarrow \mu_k$ , STOP

**endif**

**if**  $\|h(x_{k+1})\| \leq \eta_k$  **then**  $c_{k+1} = c_k$

**else**  $c_{k+1} = c_k/\beta$

Calcola  $\mu_{k+1}$

**endfor**

**Return:** miglior coppia trovata  $(x^*, \mu^*)$

# Metodo di soluzione

## Algoritmo SEQLAGR

**Dati:**  $\epsilon_0 > 0$ ,  $\beta > 1$ ,  $\{\tau_k\} \rightarrow 0$ ,  $\{\eta_k\} \rightarrow 0$ ,  $\rho > 0$ ,  $\mu_0$ , maxit

**for**  $k = 0, 1, \dots, \text{maxit}$

Calcola  $x_k$  t.c.  $\|\nabla L_a(x_k, \mu_k; \epsilon_k)\| \leq \tau_k$

**if**  $\|\nabla L_a(x_k, \mu_k; \epsilon_k)\| < \rho$  **then**

$x^* \leftarrow x_k$ ,  $\mu^* \leftarrow \mu_k$ , STOP

**endif**

**if**  $\|h(x_{k+1})\| \leq \eta_k$  **then**  $\epsilon_{k+1} = \epsilon_k$

**else**  $\epsilon_{k+1} = \epsilon_k / \beta$

Calcola  $\mu_{k+1}$

**endfor**

**Return:** miglior coppia trovata  $(x^*, \mu^*)$

## Metodo di soluzione

**Algoritmo** SEQLAGR

**Dati:**  $\epsilon_0 > 0$ ,  $\beta > 1$ ,  $\{\tau_k\} \rightarrow 0$ ,  $\{\eta_k\} \rightarrow 0$ ,  $\rho > 0$ ,  $\mu_0$ , maxit

**for**  $k = 0, 1, \dots, \text{maxit}$

    Calcola  $x_k$  t.c.  $\|\nabla L_a(x_k, \mu_k; \epsilon_k)\| \leq \tau_k$

**if**  $\|\nabla L_a(x_k, \mu_k; \epsilon_k)\| < \rho$  **then**

$x^* \leftarrow x_k$ ,  $\mu^* \leftarrow \mu_k$ , STOP

**endif**

**if**  $\|h(x_{k+1})\| \leq \eta_k$  **then**  $\epsilon_{k+1} = \epsilon_k$

**else**  $\epsilon_{k+1} = \epsilon_k / \beta$

    Calcola  $\mu_{k+1}$

**endfor**

**Return:** miglior coppia trovata  $(x^*, \mu^*)$

# Aggiornamento del moltiplicatore – 1

Come si passa da  $\mu_k$  a  $\mu_{k+1}$ ?

Consideriamo la *funzione duale*

$$\psi(\mu) = L_a(x(\mu), \mu; \epsilon)$$

ove, per  $\epsilon$  suff. piccoli e per ogni  $\mu$ ,  $x(\mu)$  è **minimo locale** di  $L_a$   
quindi (stazionario e) tale che

$$\nabla_x L_a(x(\mu), \mu; \epsilon) = 0.$$

# Aggiornamento del moltiplicatore – 1

Come si passa da  $\mu_k$  a  $\mu_{k+1}$ ?

Consideriamo la *funzione duale*

$$\psi(\mu) = L_a(x(\mu), \mu; \epsilon)$$

ove, per  $\epsilon$  suff. piccoli e per ogni  $\mu$ ,  $x(\mu)$  è **minimo locale** di  $L_a$  quindi (stazionario e) tale che

$$\nabla_x L_a(x(\mu), \mu; \epsilon) = 0.$$

## Aggiornamento del moltiplicatore – 2

Supponiamo che  $x^*$  sia soluzione del problema originale (quindi punto di KKT) con moltiplicatore  $\mu^*$

Per le prop. di  $L_a$  risulta:  $x(\mu^*) = x^*$  e  $h(x^*) = 0$ , quindi

$$\psi(\mu^*) = L_a(x^*, \mu^*; \epsilon) = f(x^*) = L_a(x^*, \mu; \epsilon) \geq L_a(x(\mu), \mu; \epsilon) = \psi(\mu)$$

Cioè,  $\mu^*$  è un punto di **massimo locale** della funzione duale  $\psi(\mu)$

Quindi ... per determinare  $\mu^*$  è (teoricamente) possibile minimizzare la funzione  $-\psi(\mu)$



## Aggiornamento del moltiplicatore – 2

Supponiamo che  $x^*$  sia soluzione del problema originale (quindi punto di KKT) con moltiplicatore  $\mu^*$

Per le prop. di  $L_a$  risulta:  $x(\mu^*) = x^*$  e  $h(x^*) = 0$ , quindi

$$\psi(\mu^*) = L_a(x^*, \mu^*; \epsilon) = f(x^*) = L_a(x^*, \mu; \epsilon) \geq L_a(x(\mu), \mu; \epsilon) = \psi(\mu)$$

Cioè,  $\mu^*$  è un punto di **massimo locale** della funzione duale  $\psi(\mu)$

Quindi ... per determinare  $\mu^*$  è (teoricamente) possibile minimizzare la funzione  $-\psi(\mu)$

## Aggiornamento del moltiplicatore – 2

Supponiamo che  $x^*$  sia soluzione del problema originale (quindi punto di KKT) con moltiplicatore  $\mu^*$

Per le prop. di  $L_a$  risulta:  $x(\mu^*) = x^*$  e  $h(x^*) = 0$ , quindi

$$\psi(\mu^*) = L_a(x^*, \mu^*; \epsilon) = f(x^*) = L_a(x^*, \mu; \epsilon) \geq L_a(x(\mu), \mu; \epsilon) = \psi(\mu)$$

Cioè,  $\mu^*$  è un punto di **massimo locale** della funzione duale  $\psi(\mu)$

Quindi ... per determinare  $\mu^*$  è (teoricamente) possibile minimizzare la funzione  $-\psi(\mu)$

## Aggiornamento del moltiplicatore – 2

Supponiamo che  $x^*$  sia soluzione del problema originale (quindi punto di KKT) con moltiplicatore  $\mu^*$

Per le prop. di  $L_a$  risulta:  $x(\mu^*) = x^*$  e  $h(x^*) = 0$ , quindi

$$\psi(\mu^*) = L_a(x^*, \mu^*; \epsilon) = f(x^*) = L_a(x^*, \mu; \epsilon) \geq L_a(x(\mu), \mu; \epsilon) = \psi(\mu)$$

Cioè,  $\mu^*$  è un punto di **massimo locale** della funzione duale  $\psi(\mu)$

Quindi ... per determinare  $\mu^*$  è (teoricamente) possibile minimizzare la funzione  $-\psi(\mu)$

## Aggiornamento del moltiplicatore – 2

Supponiamo che  $x^*$  sia soluzione del problema originale (quindi punto di KKT) con moltiplicatore  $\mu^*$

Per le prop. di  $L_a$  risulta:  $x(\mu^*) = x^*$  e  $h(x^*) = 0$ , quindi

$$\psi(\mu^*) = L_a(x^*, \mu^*; \epsilon) = f(x^*) = L_a(x^*, \mu; \epsilon) \geq L_a(x(\mu), \mu; \epsilon) = \psi(\mu)$$

Cioè,  $\mu^*$  è un punto di **massimo locale** della funzione duale  $\psi(\mu)$

Quindi ... per determinare  $\mu^*$  è (teoricamente) possibile minimizzare la funzione  $-\psi(\mu)$

## Aggiornamento del moltiplicatore – 3

Vediamo come è fatto il gradiente della funzione duale

$$\begin{aligned}\nabla\psi(\mu) &= \nabla_{\mu}x(\mu)\nabla_x L_a(x(\mu), \mu; \epsilon) + \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) \\ &\quad (\text{N.B. } \nabla_x L_a(x(\mu), \mu; \epsilon) = 0) \\ &= \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) = h(x(\mu))\end{aligned}$$

## Aggiornamento del moltiplicatore – 3

Vediamo come è fatto il gradiente della funzione duale

$$\begin{aligned}\nabla\psi(\mu) &= \nabla_{\mu}x(\mu)\nabla_xL_a(x(\mu), \mu; \epsilon) + \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) \\ &\quad (\text{N.B. } \nabla_xL_a(x(\mu), \mu; \epsilon) = 0) \\ &= \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) = h(x(\mu))\end{aligned}$$

Una iterazione del metodo del gradiente è quindi:

$$\mu_{k+1} = \mu_k + \alpha h(x_k)$$

## Aggiornamento del moltiplicatore – 3

Vediamo come è fatto il gradiente della funzione duale

$$\begin{aligned}\nabla\psi(\mu) &= \nabla_{\mu}x(\mu)\nabla_x L_a(x(\mu), \mu; \epsilon) + \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) \\ &\quad (\text{N.B. } \nabla_x L_a(x(\mu), \mu; \epsilon) = 0) \\ &= \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) = h(x(\mu))\end{aligned}$$

Una iterazione del metodo del gradiente è quindi:

$$\mu_{k+1} = \mu_k + \alpha h(x_k) = \mu_k + \frac{1}{\epsilon_k} h(x_k)$$

N.B. Se  $(x_k, \mu_k)$  è una coppia di KKT ( $h(x_k) = 0$ ),  
allora  $\mu_{k+1} = \mu_k$

## Aggiornamento del moltiplicatore – 3

Vediamo come è fatto il gradiente della funzione duale

$$\begin{aligned}\nabla\psi(\mu) &= \nabla_{\mu}x(\mu)\nabla_xL_a(x(\mu), \mu; \epsilon) + \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) \\ &\quad (\text{N.B. } \nabla_xL_a(x(\mu), \mu; \epsilon) = 0) \\ &= \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) = h(x(\mu))\end{aligned}$$

Una iterazione del metodo del gradiente è quindi:

$$\mu_{k+1} = \mu_k + \alpha h(x_k) = \mu_k + \frac{1}{\epsilon_k} h(x_k)$$

N.B. Se  $(x_k, \mu_k)$  è una coppia di KKT ( $h(x_k) = 0$ ),  
allora  $\mu_{k+1} = \mu_k$



## Aggiornamento del moltiplicatore – 3

Vediamo come è fatto il gradiente della funzione duale

$$\begin{aligned}\nabla\psi(\mu) &= \nabla_{\mu}x(\mu)\nabla_xL_a(x(\mu), \mu; \epsilon) + \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) \\ &\quad (\text{N.B. } \nabla_xL_a(x(\mu), \mu; \epsilon) = 0) \\ &= \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) = h(x(\mu))\end{aligned}$$

Una iterazione del metodo del gradiente è quindi:

$$\mu_{k+1} = \mu_k + \alpha h(x_k) = \mu_k + \frac{1}{\epsilon_k} h(x_k)$$

N.B. Se  $(x_k, \mu_k)$  è una coppia di KKT ( $h(x_k) = 0$ ),  
allora  $\mu_{k+1} = \mu_k$

## Aggiornamento del moltiplicatore – 3

Vediamo come è fatto il gradiente della funzione duale

$$\begin{aligned}\nabla\psi(\mu) &= \nabla_{\mu}x(\mu)\nabla_xL_a(x(\mu), \mu; \epsilon) + \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) \\ &\quad (\text{N.B. } \nabla_xL_a(x(\mu), \mu; \epsilon) = 0) \\ &= \nabla_{\mu}L_a(x(\mu), \mu; \epsilon) = h(x(\mu))\end{aligned}$$

Una iterazione del metodo del gradiente è quindi:

$$\mu_{k+1} = \mu_k + \alpha h(x_k) = \mu_k + \frac{1}{\epsilon_k} h(x_k)$$

N.B. Se  $(x_k, \mu_k)$  è una coppia di KKT ( $h(x_k) = 0$ ), allora  $\mu_{k+1} = \mu_k$