

# NELINEÁRNÍ REGRESNÍ MODELY

Základní úlohy:

1. Konstrukce *kalibračních modelů*,
2. Ověření *teoretických modelů* fyzikálně-chemické zákonitosti,
3. Tvorba *empirických modelů*,

Tvorba regresního modelu  $f(x, \beta)$  čili funkce

- a) vektoru nastavovaných proměnných (*deterministických, kontrolovatelných, vysvětlujících, nezávislých*)  $x$ ,  
tj. bodů  $\{x_i^T, y_i\}$ ,  $i=1, \dots, n$ ,
- b) vektoru parametrů  $\beta$  o rozměru  $(m \times 1)$ ,  $\beta = (\beta_1, \dots, \beta_m)^T$ .
- c)  $y$  je vysvětlovaná proměnná (závisle p., odezva, měření, pozorování) na zvolenou kombinaci nastavovaných veličin  $x_i$ .

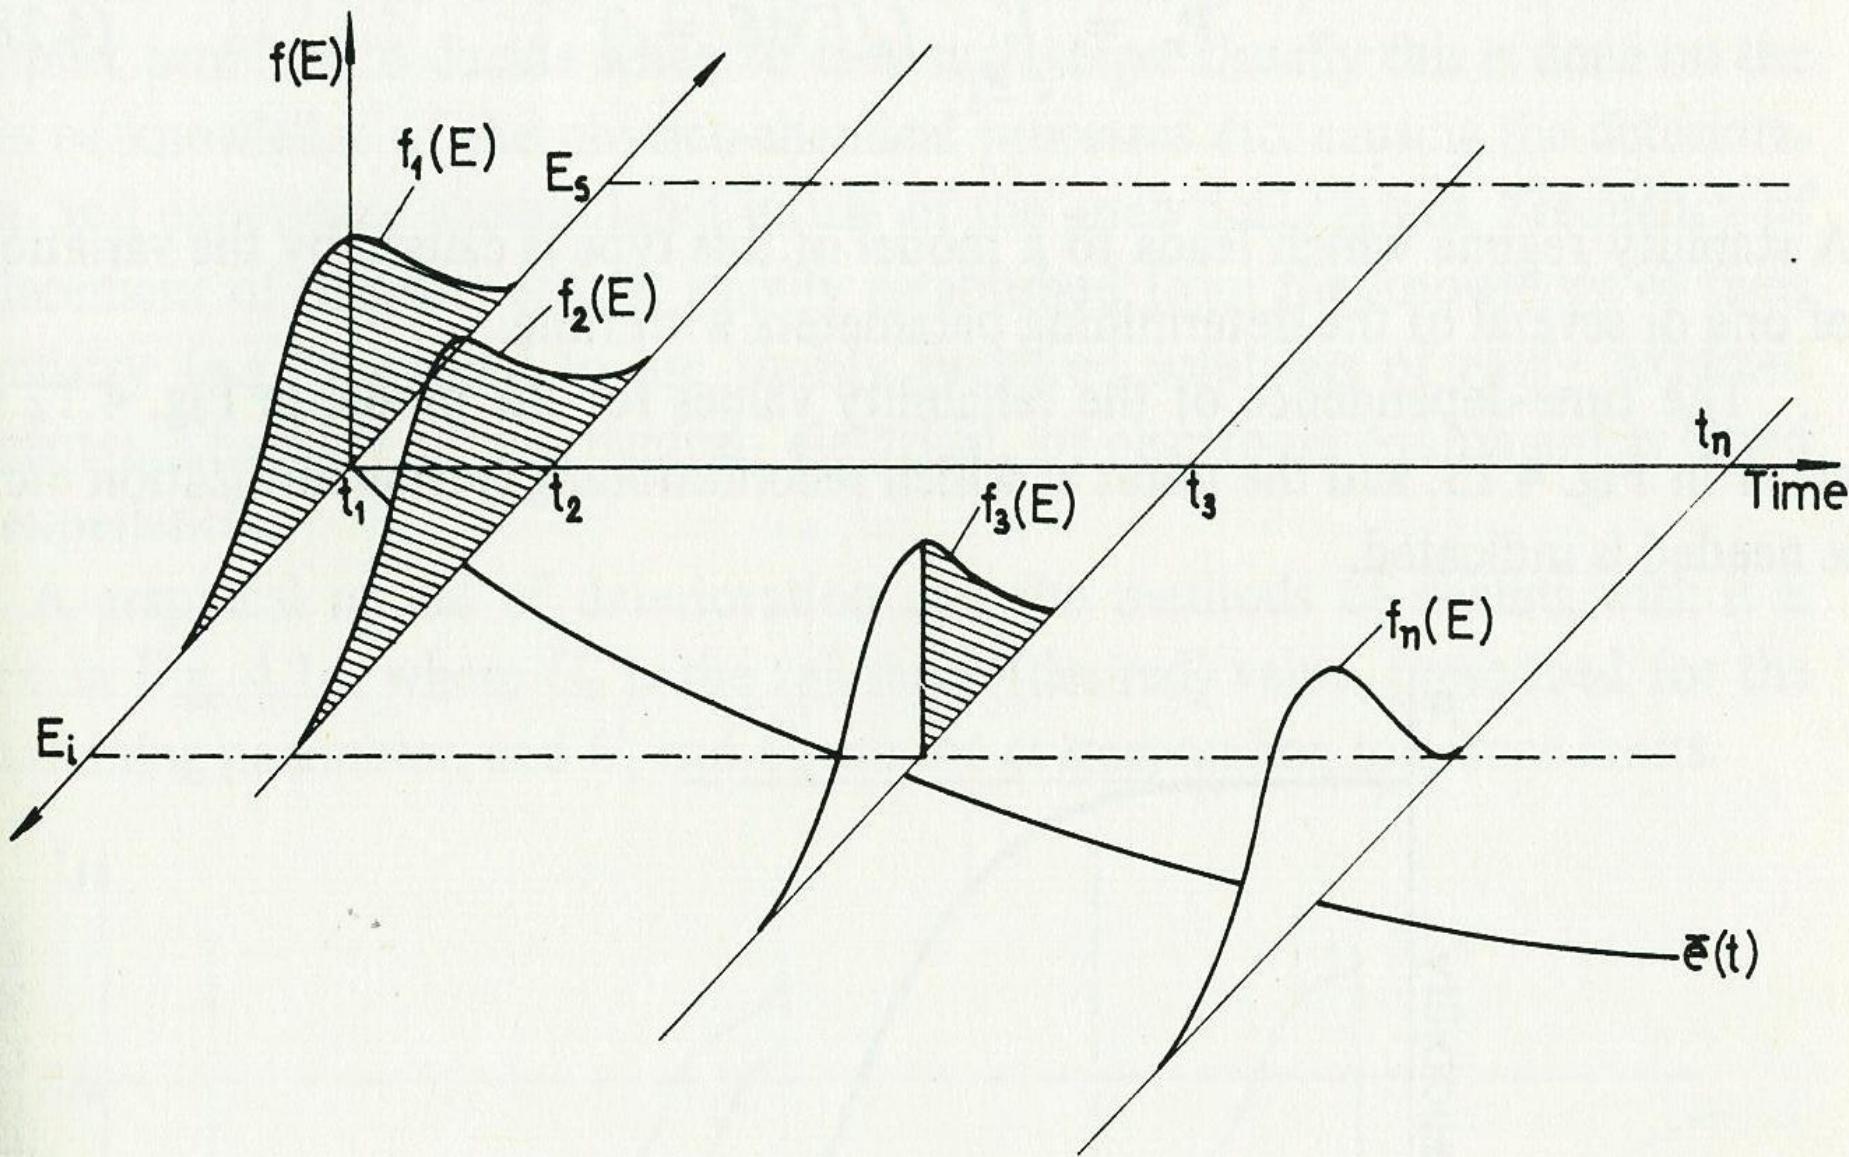


Fig. 4.12 The model of increase of analysis errors with time, for an analytical system with a time-dependent parameter.

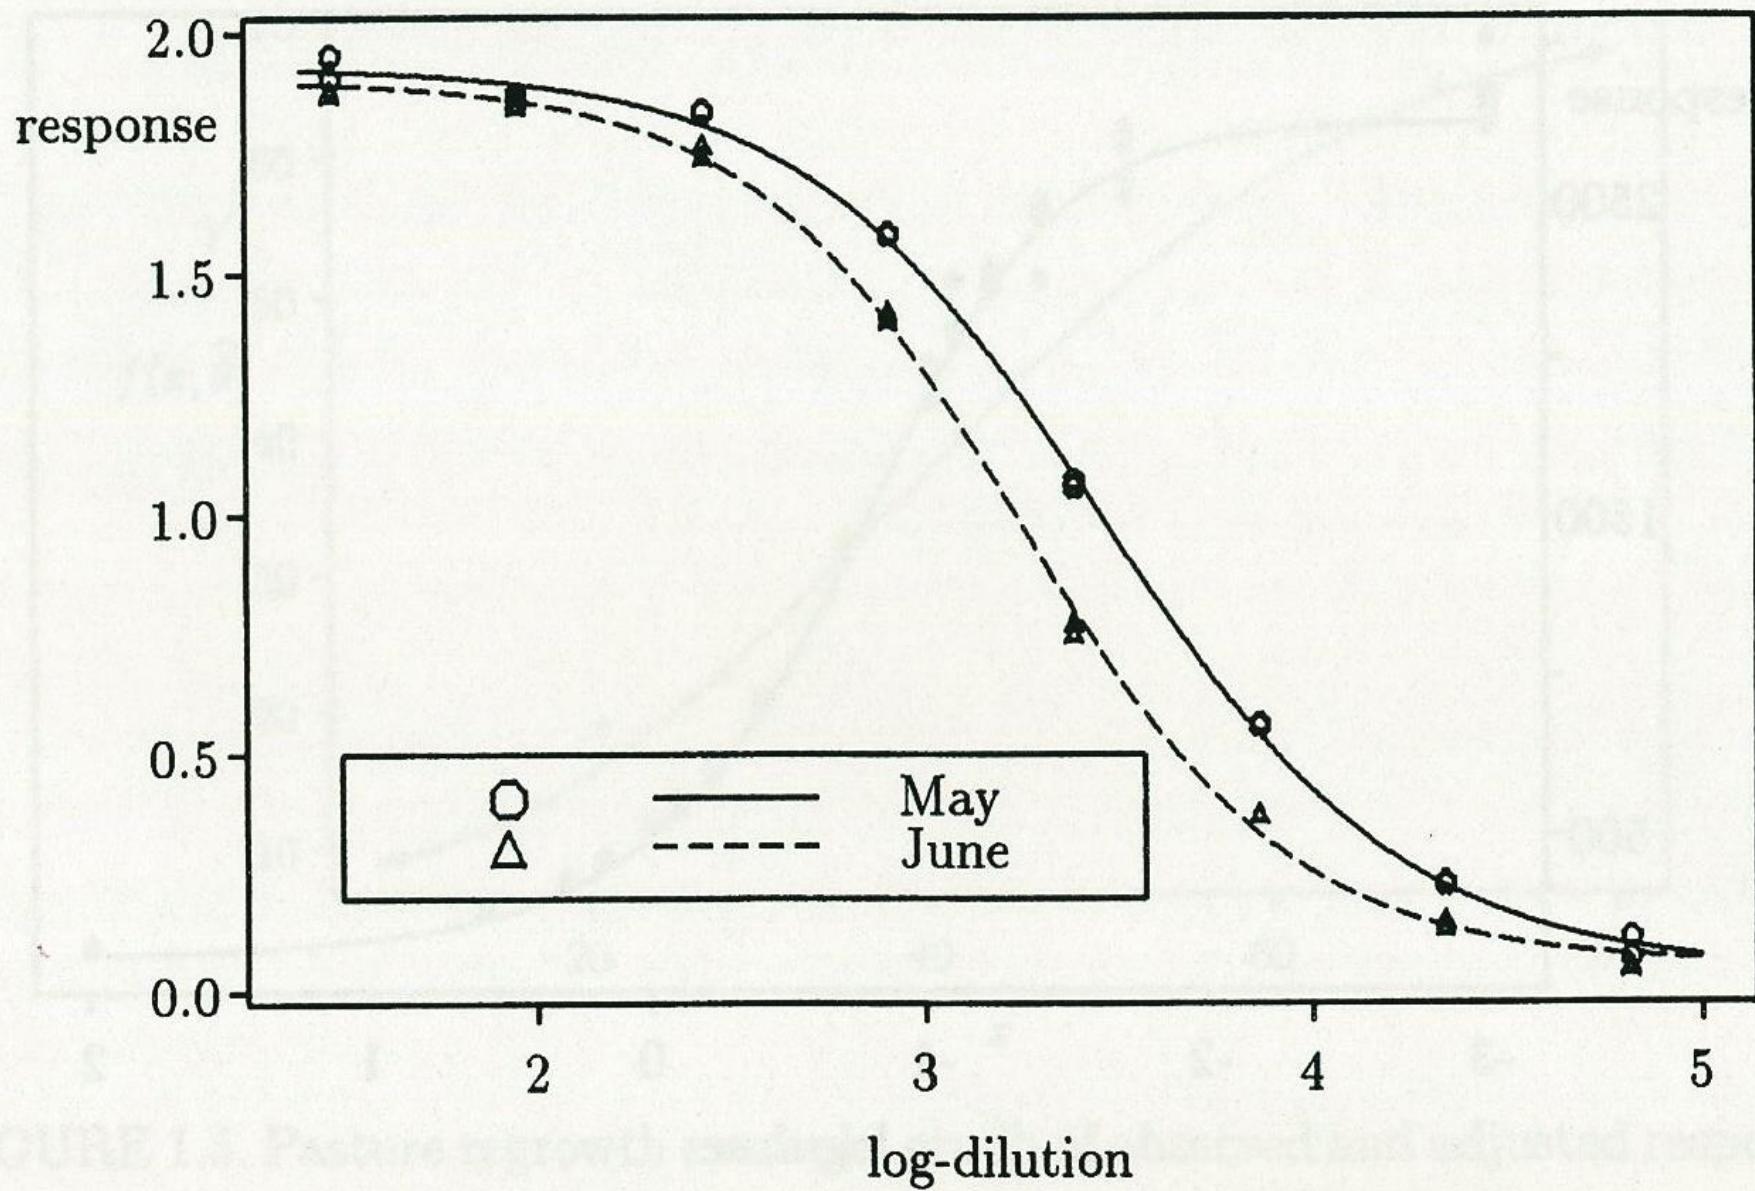


FIGURE 1.7. ELISA test example: graph of observed and adjusted curves for May and June

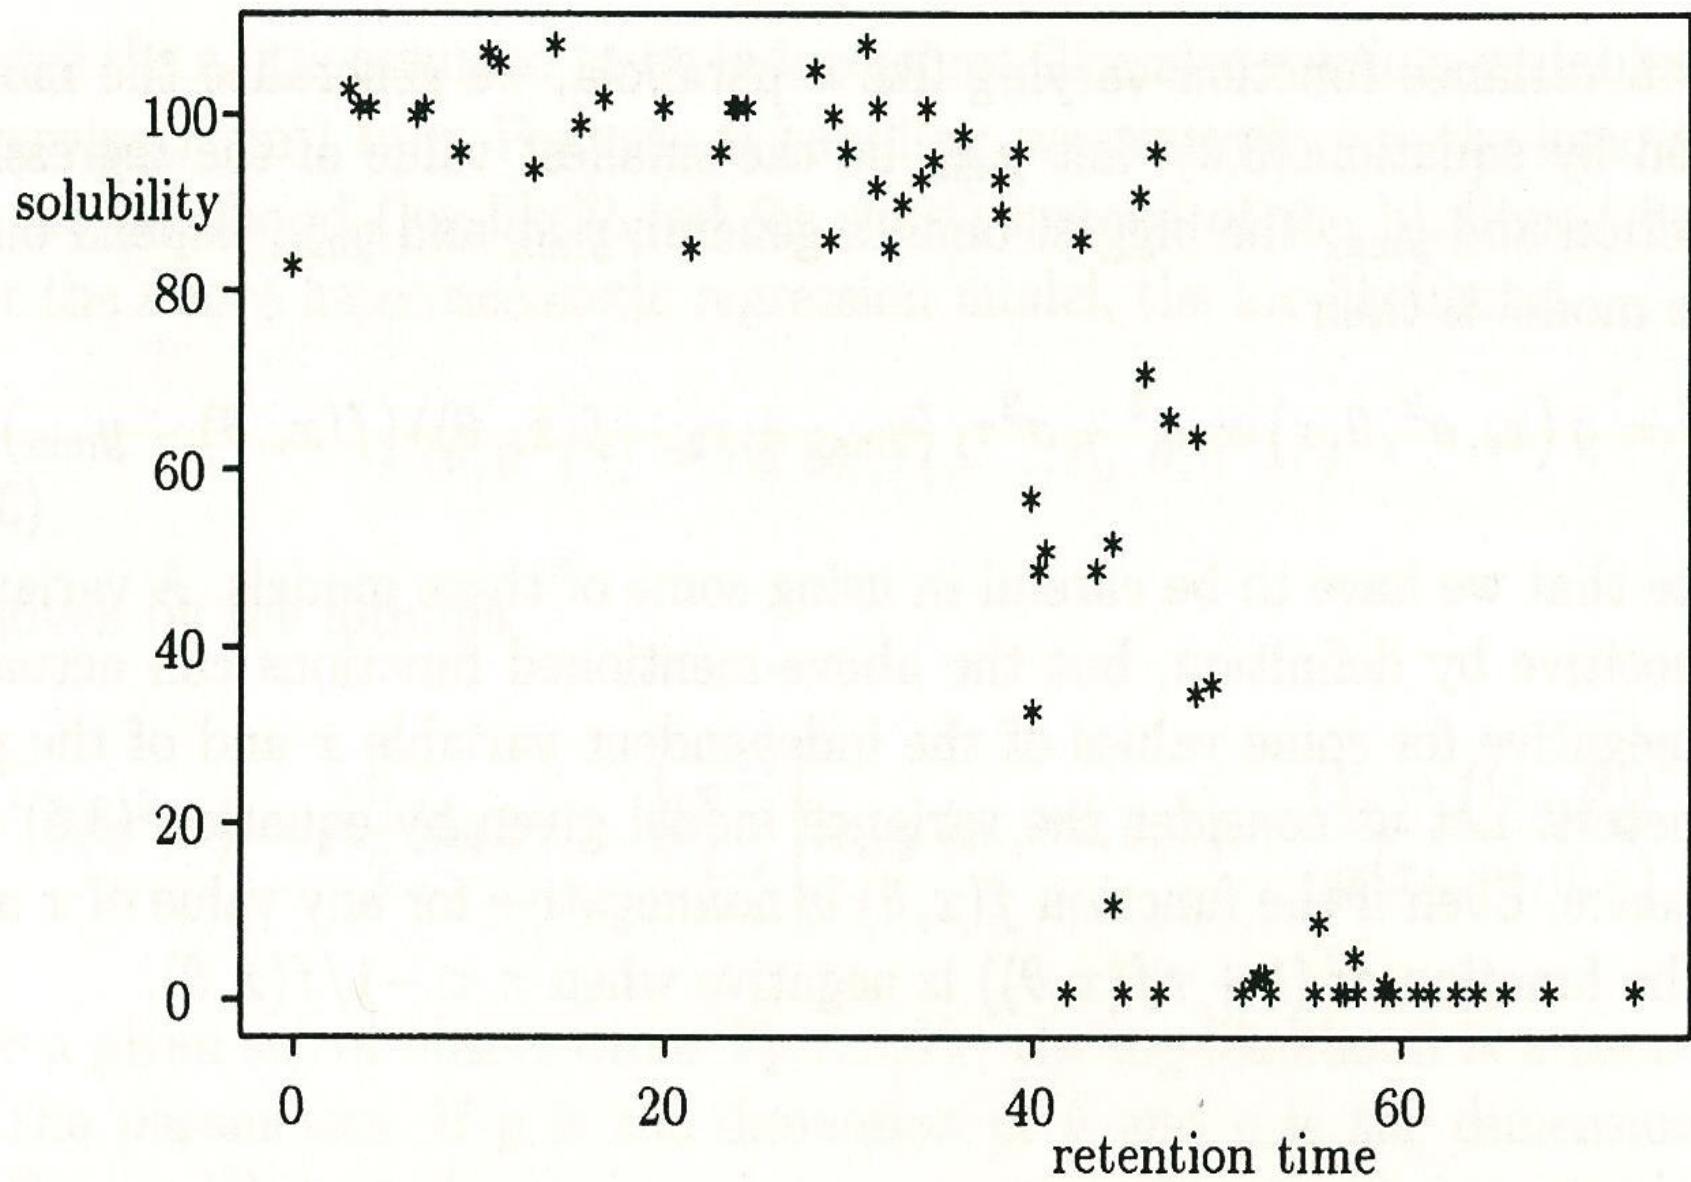


FIGURE 3.3. Peptides example: observed solubility of 75 peptides versus their RP-HPLC retention time

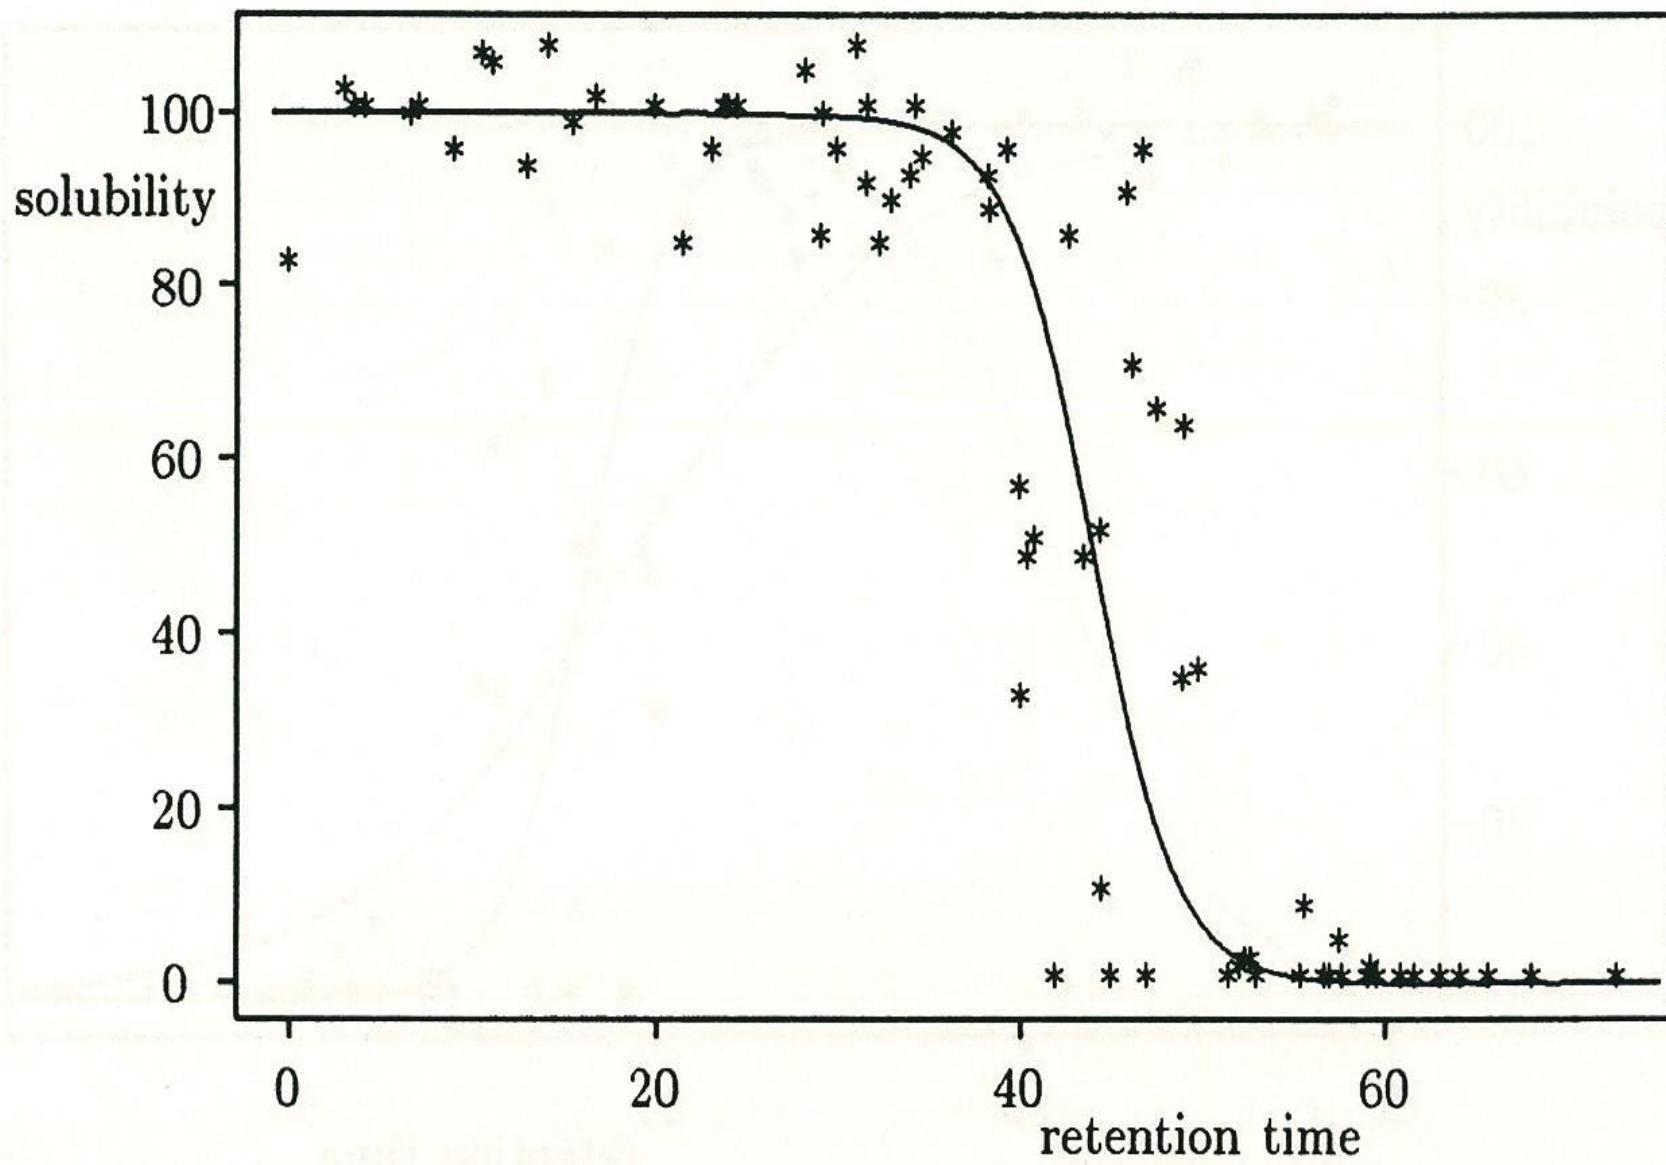


FIGURE 3.7. Peptides example: observed and adjusted solubilities of 75 peptides versus their RP-HPLC retention time

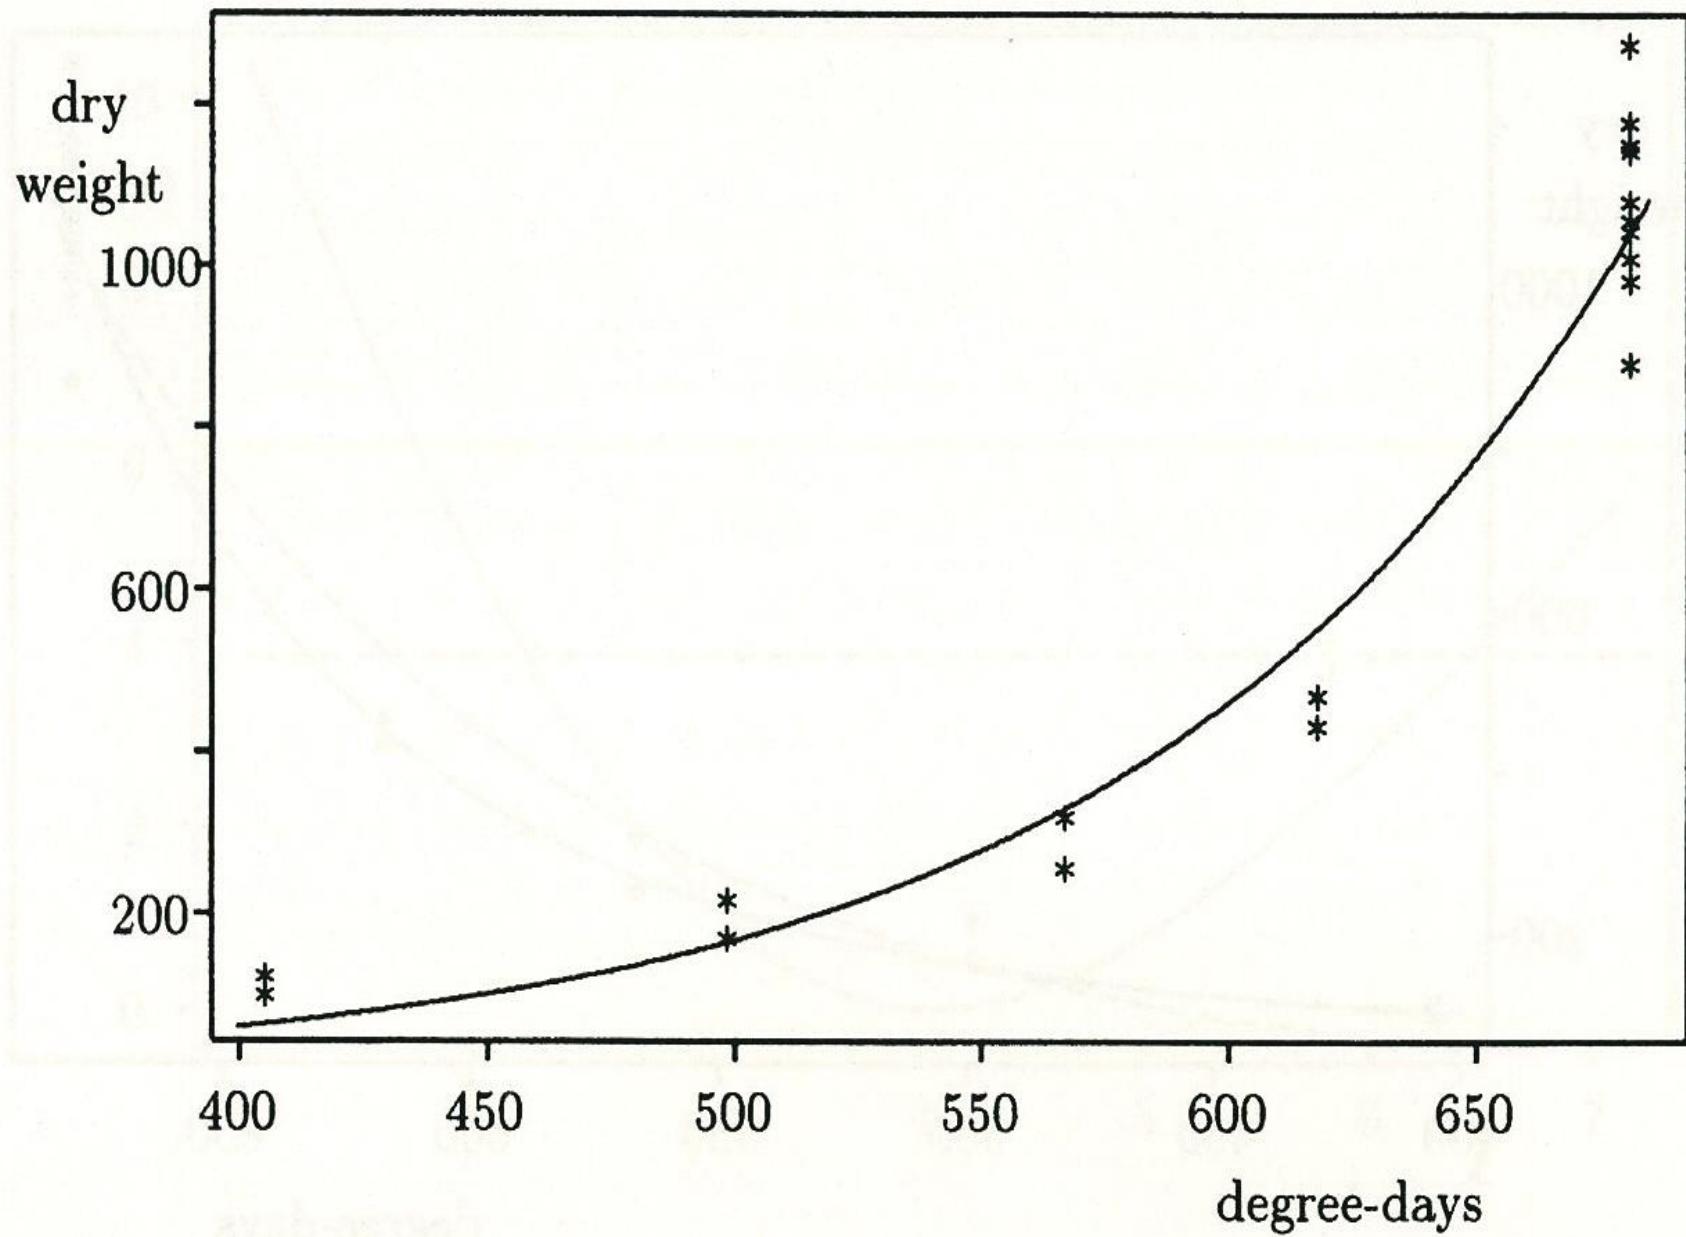


FIGURE 3.4. Weight of tillers example: graph of observed and adjusted curve

Tvorba se formuluje s ohledem na **regresní triplet**:

1. zadaná data,
2. navržený model,
3. kritérium regrese.

### Dělení regresních modelů:

1. **Lineární modely**: parametry nemají fyzikální smysl (koeficienty),
2. **Nelineární modely**: parametry mají přesný fyzikální význam.  
(nepř. rovnovážné konstanty (disociační, stability, součiny rozpustnosti) reakčních produktů, rychlostní konstanty u kinetických modelů, neznámé koncentrace, atd.)

# Model: rozšířený Debye-Hückelův zákon

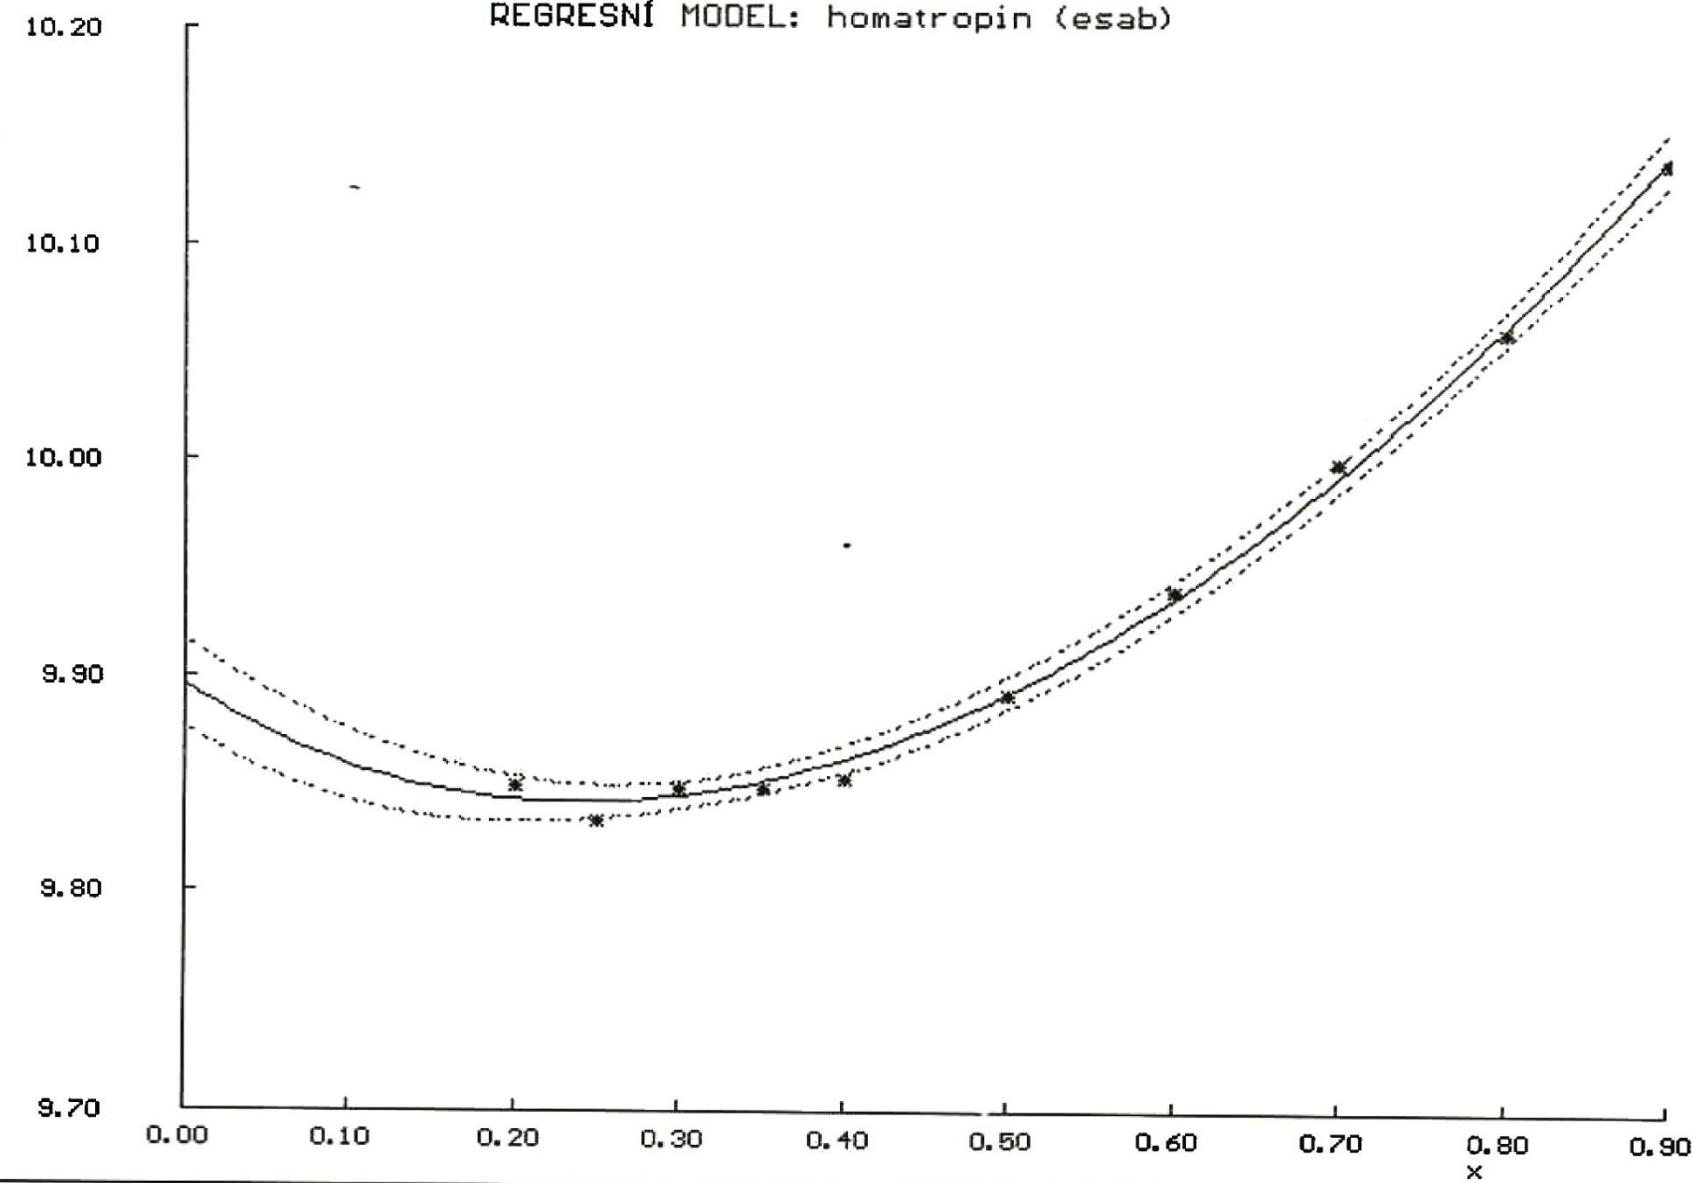
$$pK_{a,smiš} = pK_{a,T} - \frac{0.5115 \sqrt{I}}{1 + 3.29 \times 10^{10} \text{ Å} \sqrt{I}} + C I$$

Proměnné:

Závisle proměnná  $y$ :  $pK_{a, smiš}$ , Nezávisle proměnná  $x$ :  $I$ ,

Neznámé parametry:  $\beta_1$ :  $pK_{a,T}$ ,  $\beta_2$ :  $\text{Å}$ ,  $\beta_3$ :  $C$

REGRESNÍ MODEL: homatropin (esab)



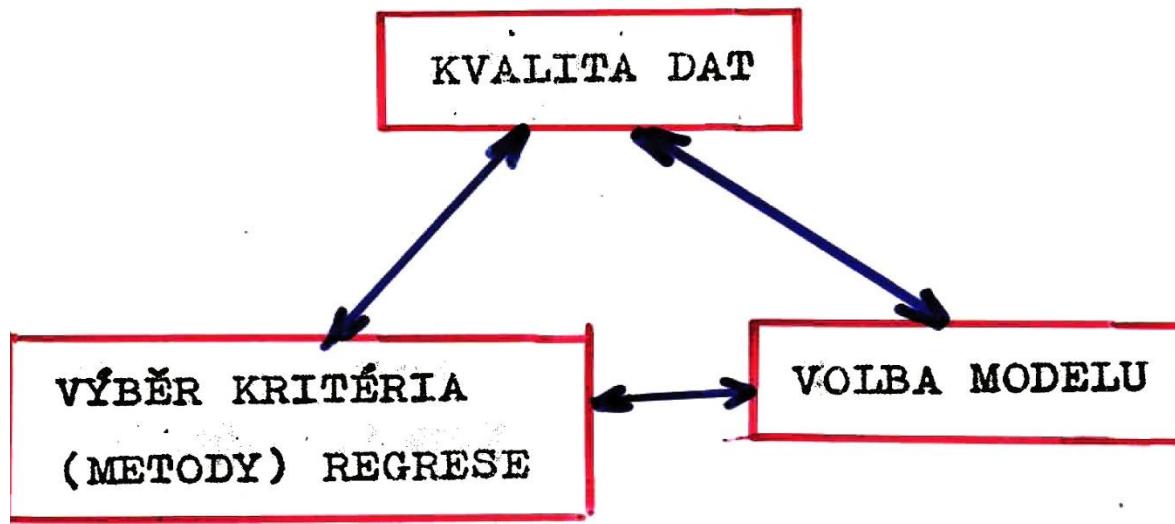
Závislost smíšené disoc. konstanty  $pK_{a,smiš}$  homatropinu na iontové síle:

**Nulté přiblžení:**  $pK_a^T = 1$ ,  $\text{å} = 1 \text{ \AA}$ ,  $C = 1$

**Nalezeno:**  $pK_a^T = 9.90(1)$ ,  $\text{å} = 6(2)\text{\AA}$  a  $C = 0.51(3)$

## POSTUP A DIAGNOSTIKA REGRESE:

Regresní triplet:



$$U = \sum_{i=1}^n w_i (y_{\text{exp}, i} - y_{\text{vyp}, i})^2 = \text{minimum}$$

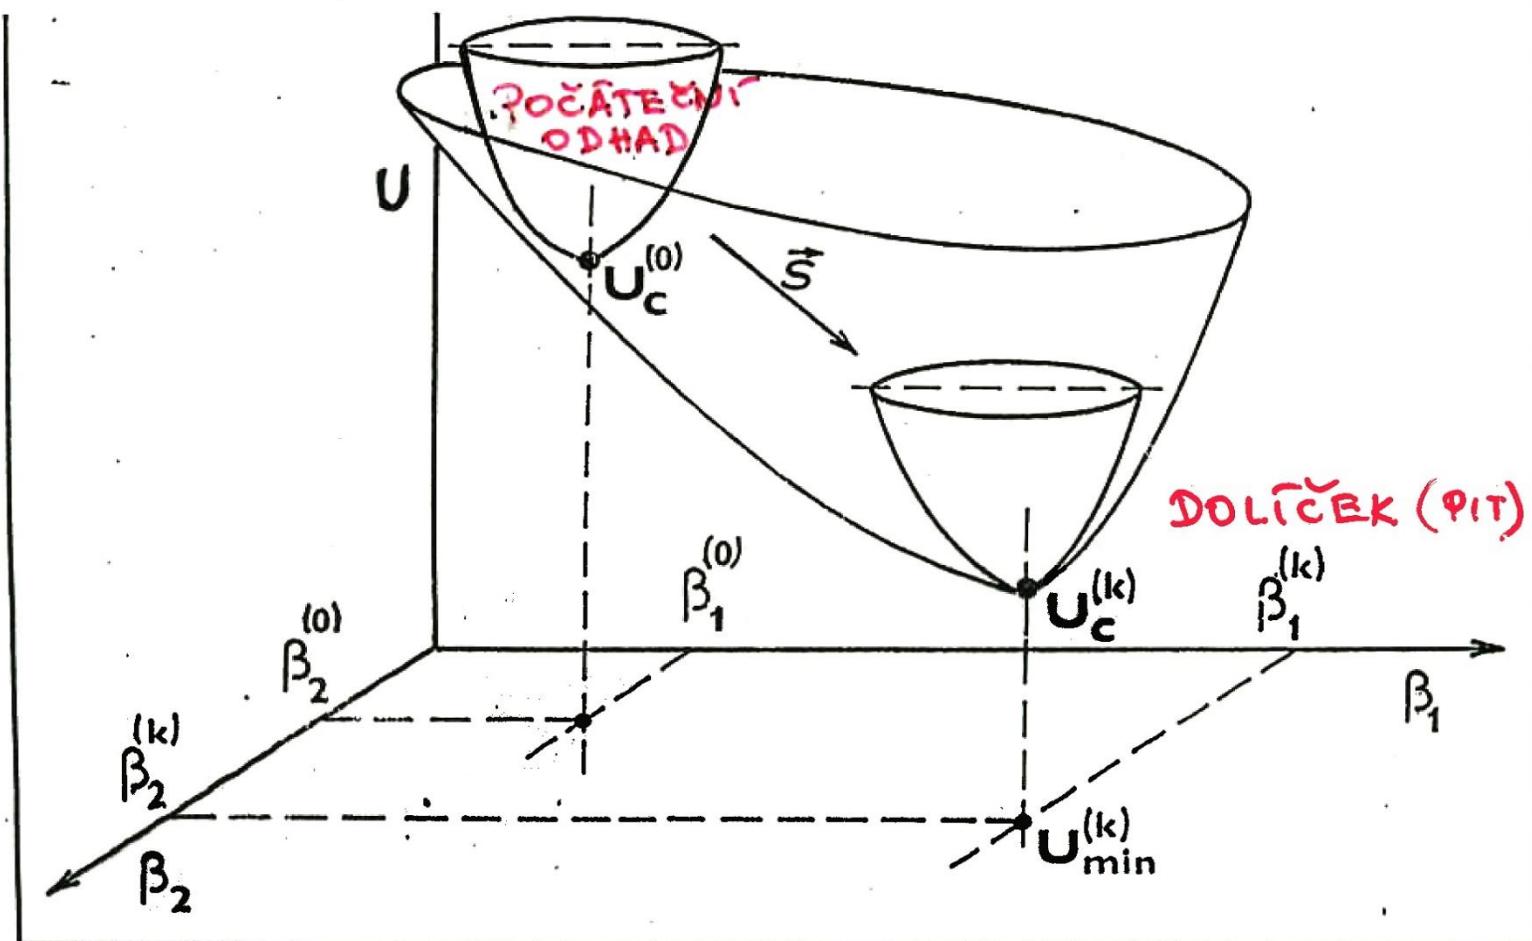
$$\text{kde } y_{\text{vyp}, i} = f(x_i; b_1, \dots, b_m)$$

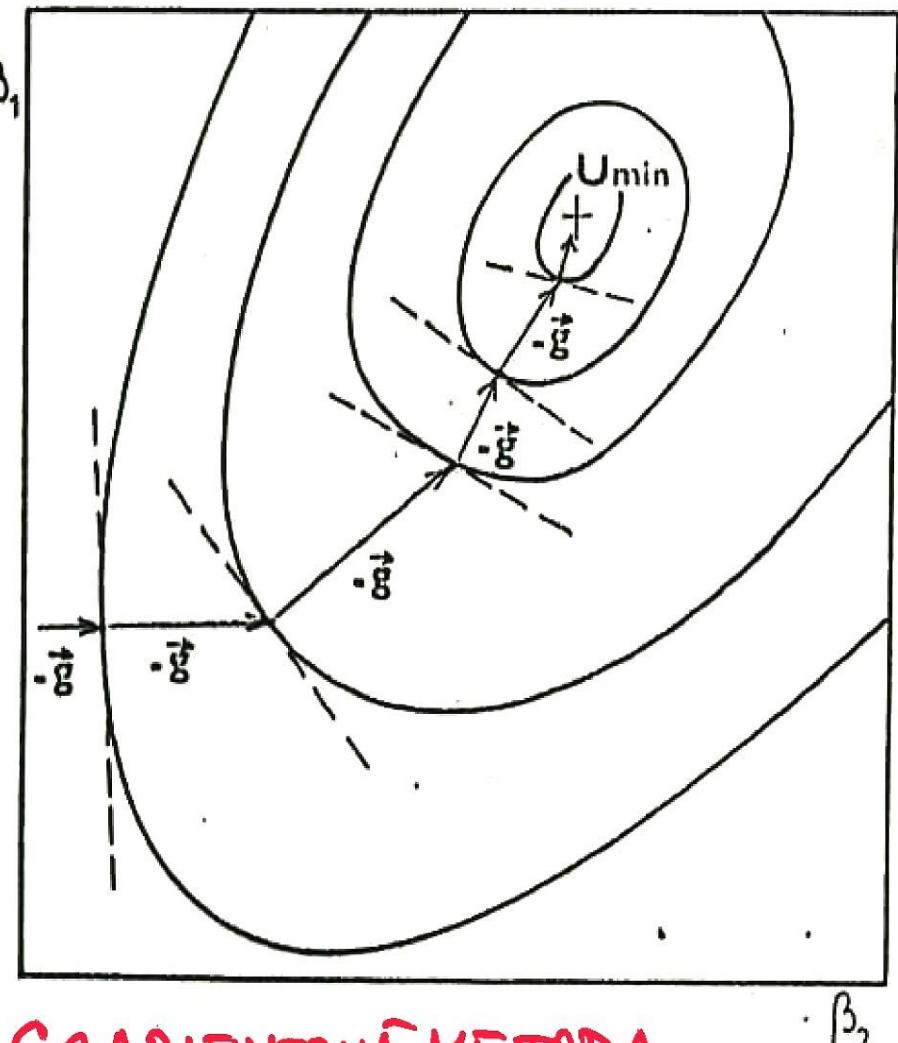
# GEOMETRICKÉ ZNÁZORNĚNÍ KRITÉRIA U

$$U = \sum_{i=1}^m w_i (y_{\text{exp},i} - y_{\text{hyp},i})^2 \approx \text{minimum}$$

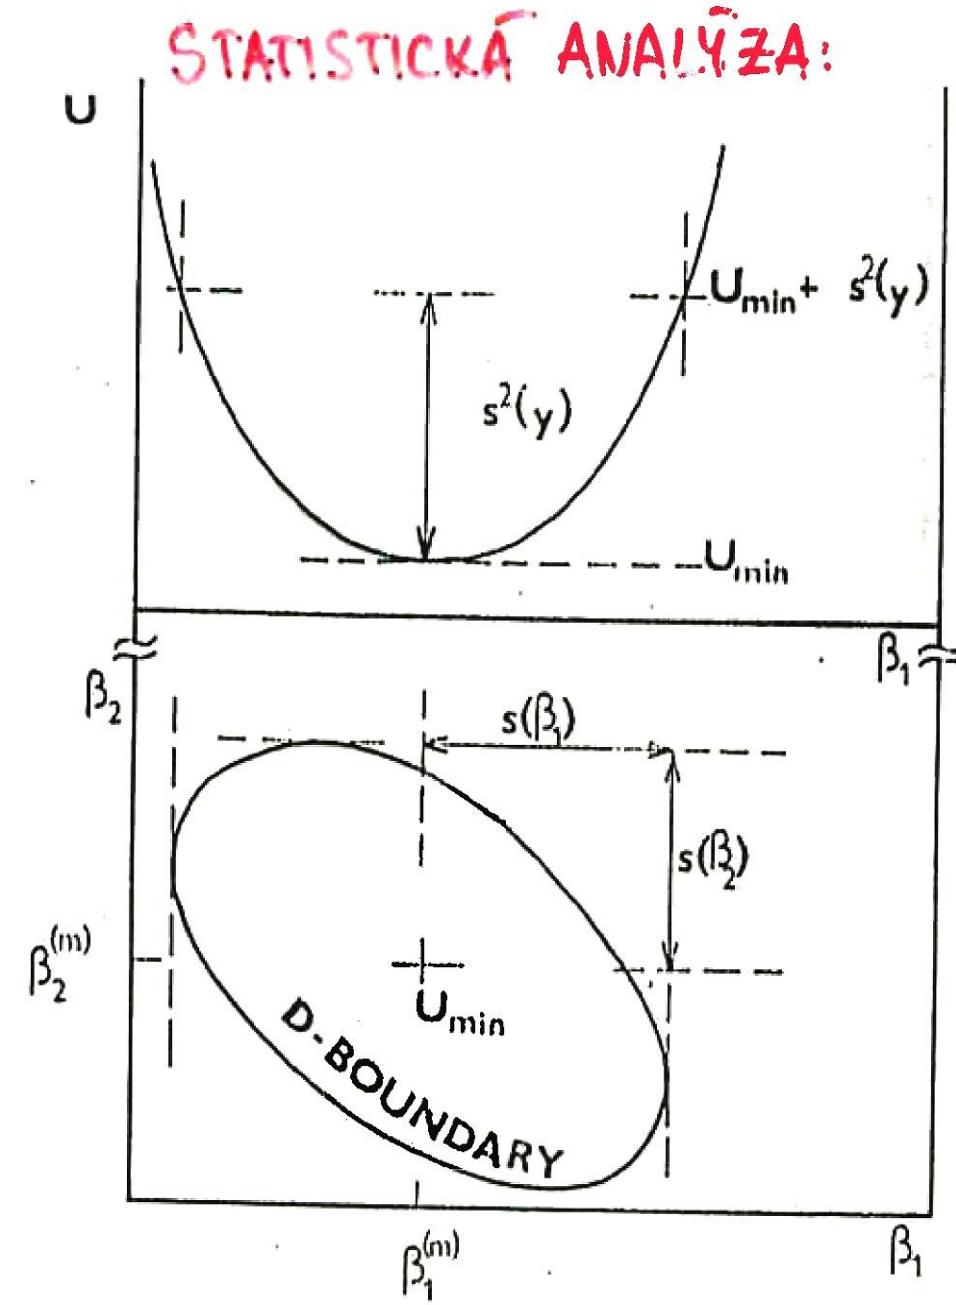
$$y_{\text{hyp},i} = f(x_i; \beta_1, \dots, \beta_m; p_1, \dots, p_j)$$

OPTIMALIZAČNÍ PROBLÉM V  $(m+1)$  ROZMĚRNÉM PROSTORU





**GRADIENTOVÁ METODA  
HLEDÁNÍ MINIMA**



# Formulace modelu

**1. Lineární regresní model:** je lineární kombinací parametrů, např. model

$$f(x, \beta) = \beta_1 + \beta_2 \sin(x)$$

Pro lineární regresní modely platí podmínka

$$g_j = \frac{\delta f(x, \beta)}{\delta \beta_j} = \text{konst.} \quad j = 1, \dots, m$$

**2. Nelineární regresní model:** alespoň pro jeden parametr  $\beta_j$  je parciální derivace  $g_j$  jeho funkcí,

Dělí se:

1. Neseparabilní modely, kdy podmínka parciální derivace  $g_j$  neplatí pro žádný parametr modelu, např.

$$f(x, \beta) = \exp(\beta_1 x) + \exp(\beta_2 x)$$

2. Separabilní modely, kdy podmínka parciální derivace  $g_j$  platí alespoň pro jeden modelový parametr, např.

$$f(x, \beta) = \beta_1 + \beta_2 \exp(\beta_3 x)$$

který je nelineární pouze vzhledem k parametru  $\beta_3$ .

3. Vnitřně lineární modely, jsou nelineární, ale lze je reparametrisací převést na lineární regresní model, např.

$$f(x, \beta) = \beta^2 x$$

který reparametrisací  $\gamma = \beta^2$  přechází na lineární model.

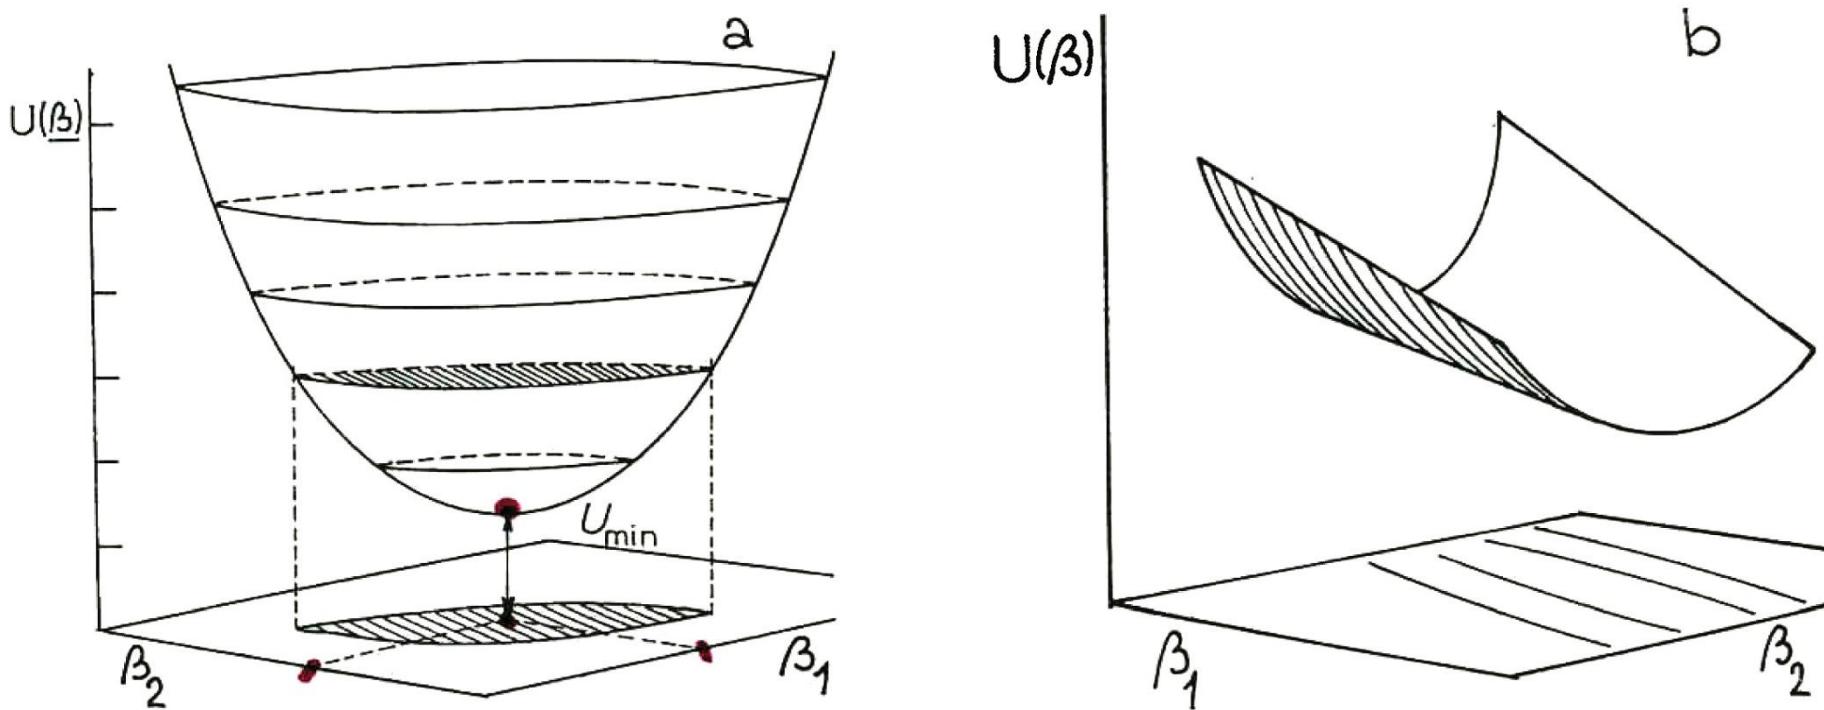
# Geometrie nelineární regrese

Kritérium regrese  $U(\beta)$  vektorovým zápisem

$$U(\beta) = \|\mathbf{y} - \mathbf{f}\|^2$$

kde  $\mathbf{y} = (y_1, \dots, y_n)^T$ ,  $\mathbf{f} = (f(x_1, \beta), \dots, f(x_n, \beta))^T$ ,

a symbol  $\|\mathbf{x}\| = \sqrt{\mathbf{x}^T \mathbf{x}}$  označuje euklidovskou normu.



Minimum účelové funkce  $U(\beta)$  pro (a) lineární modely, (b) nelineární modely

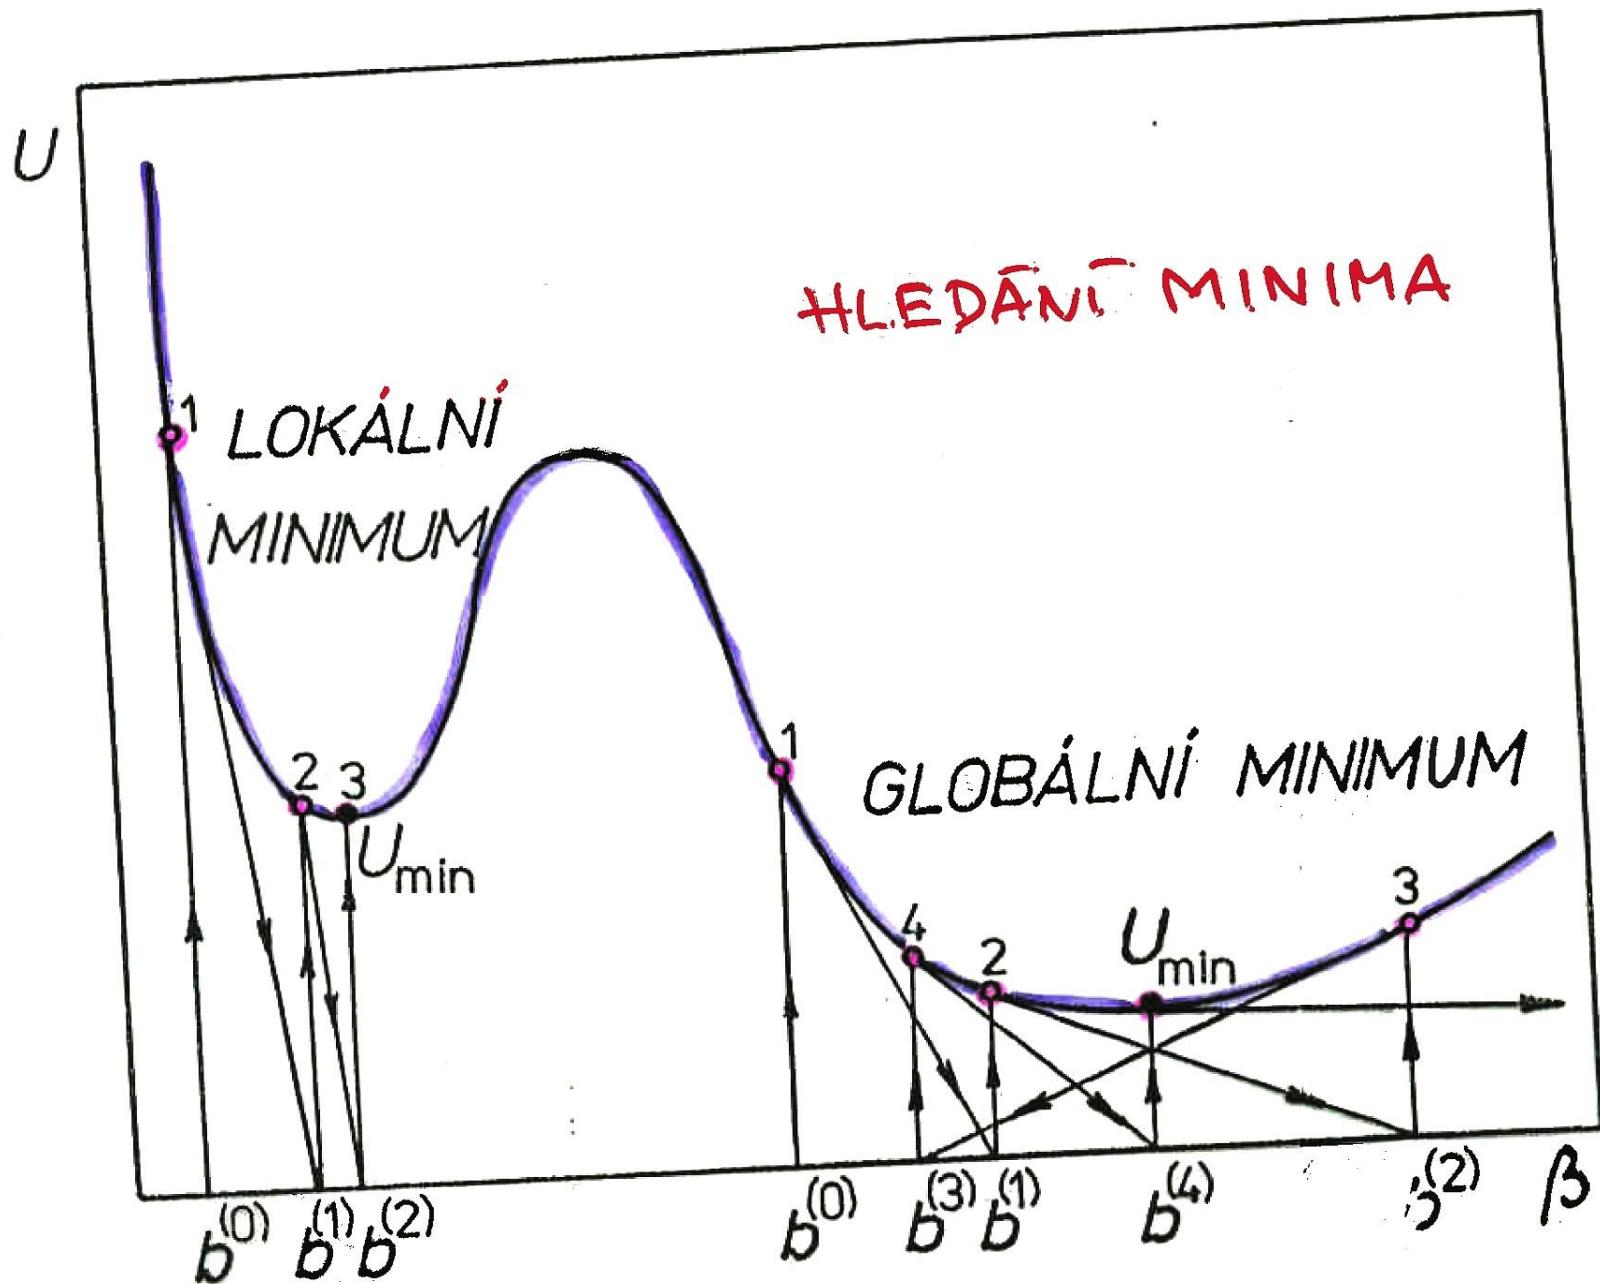
## Pro lineární regresní modely:

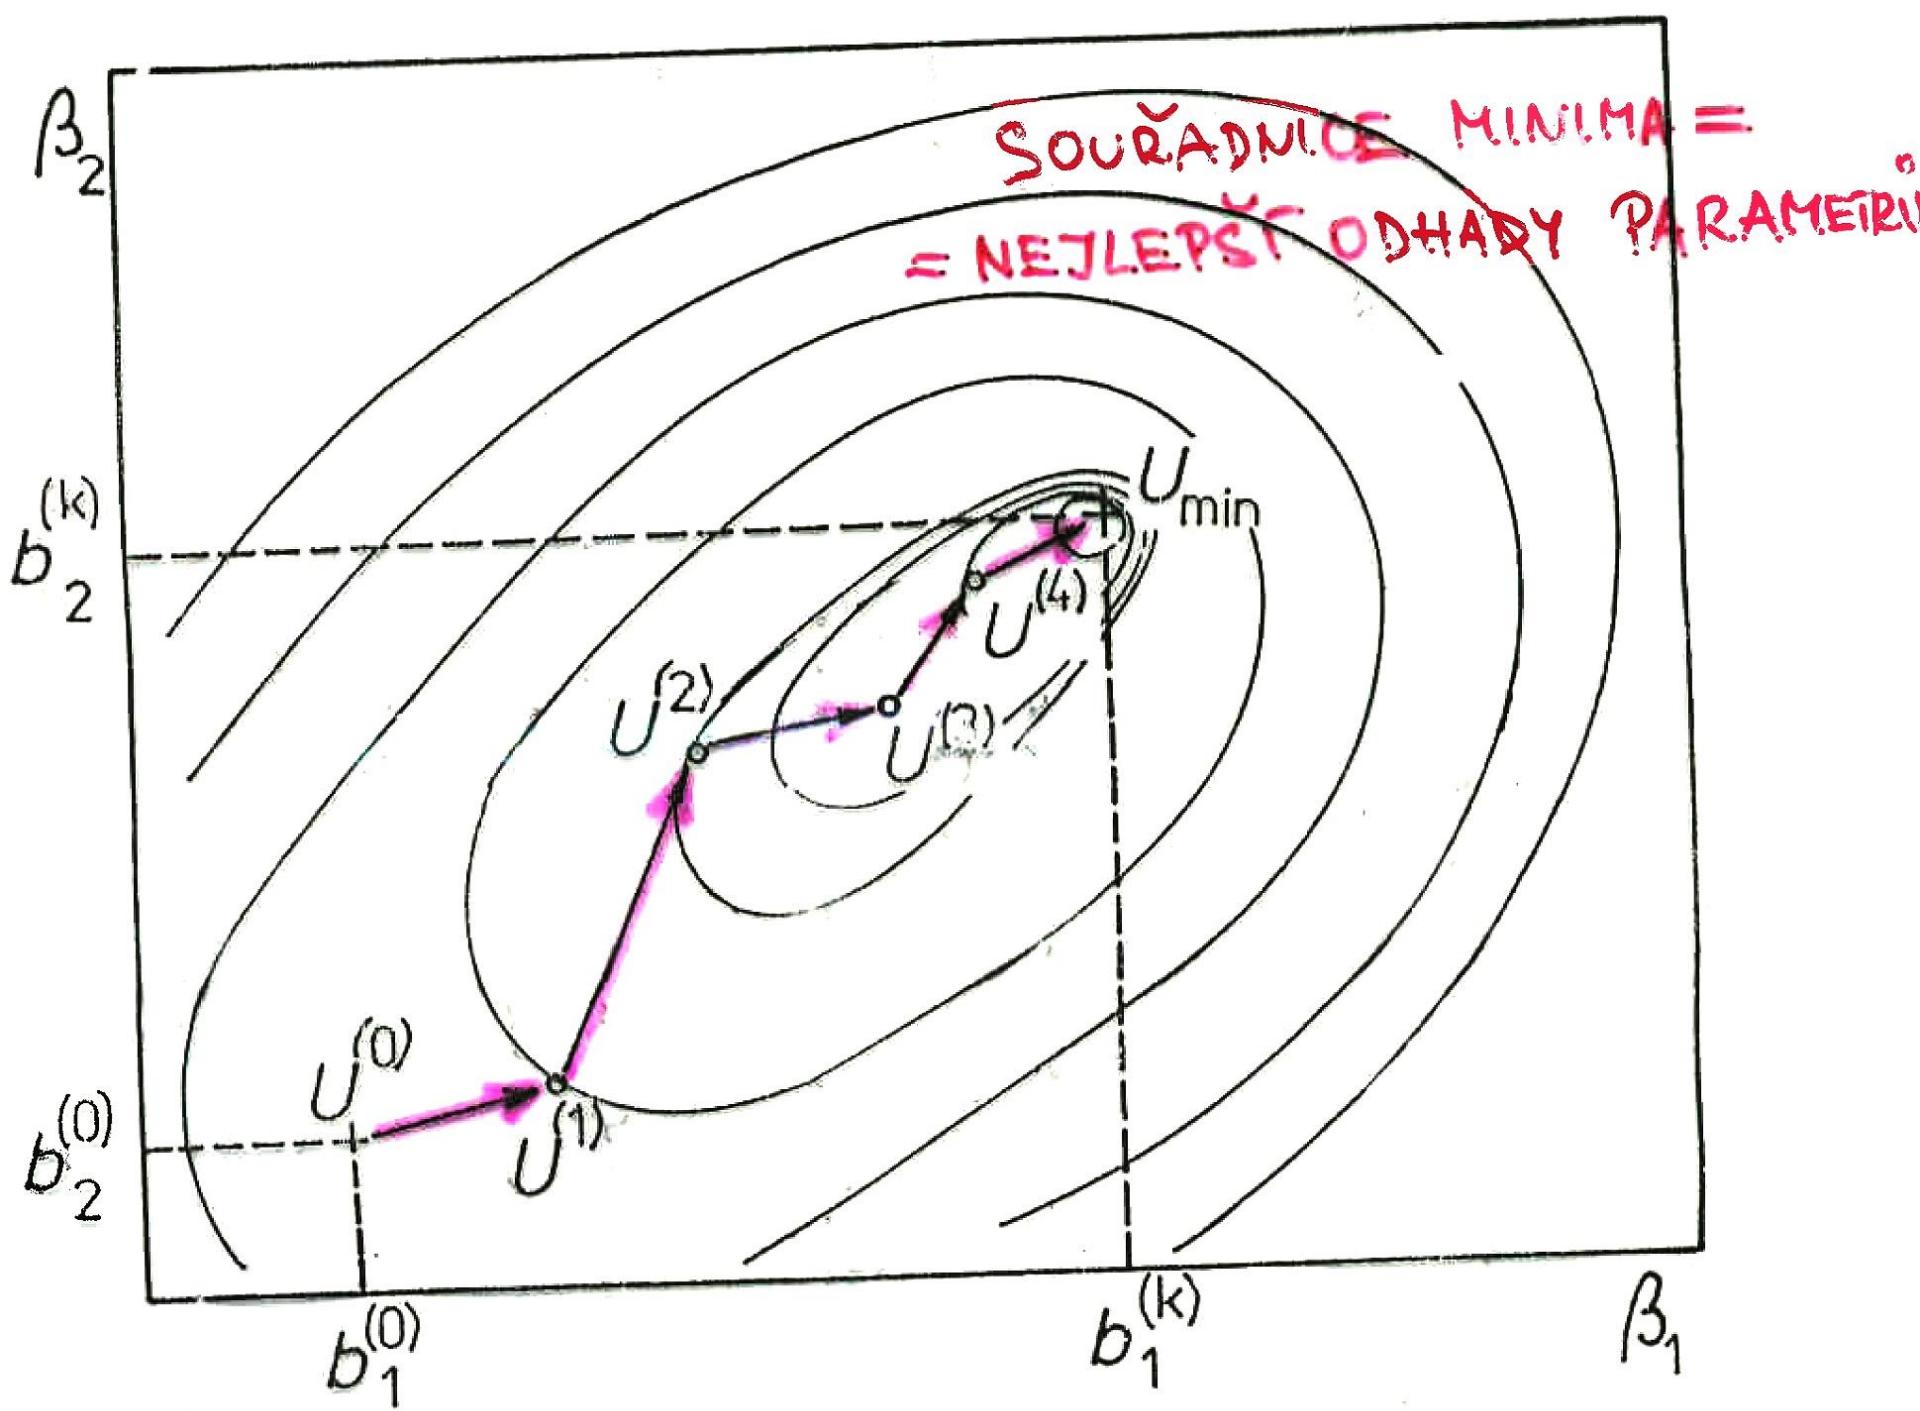
1. Útvar kritéria  $U(\beta)$  v prostoru odhadů je eliptický hyperparaboloid se středem v bodě  $[\hat{\beta}, U(\hat{\beta})]$ , kde nabývá minimální hodnoty.
2. Účelová funkce  $U(\beta)$  je vzhledem k  $\beta$  kvadratickou formou  $\beta^T (X^T X) \beta$  a matice  $X^T X$  je pozitivně definitní.

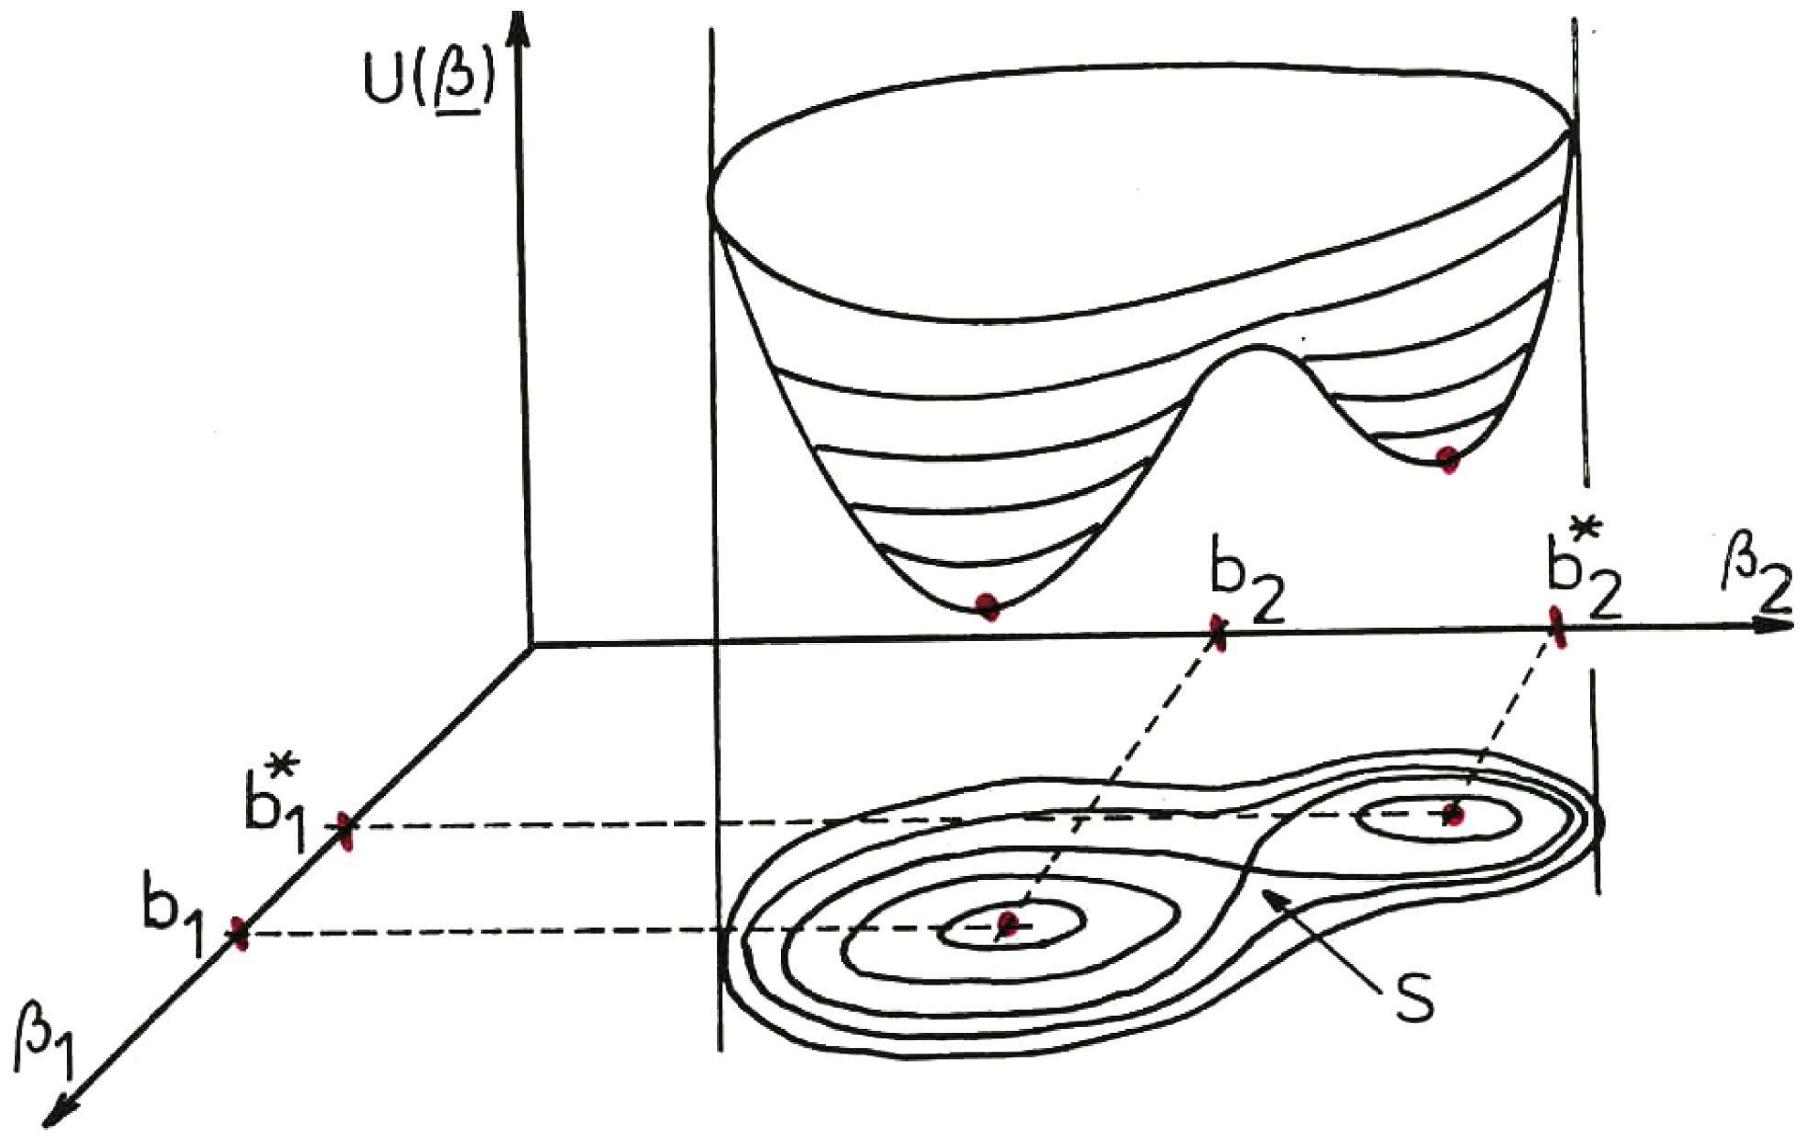
## Pro nelineární regresní modely:

1. Složitější útvary vznikají u nelineárních modelů v závislosti na nelinearitě funkce  $f(x, \beta)$ , počtu extrémů a sedlových bodů.

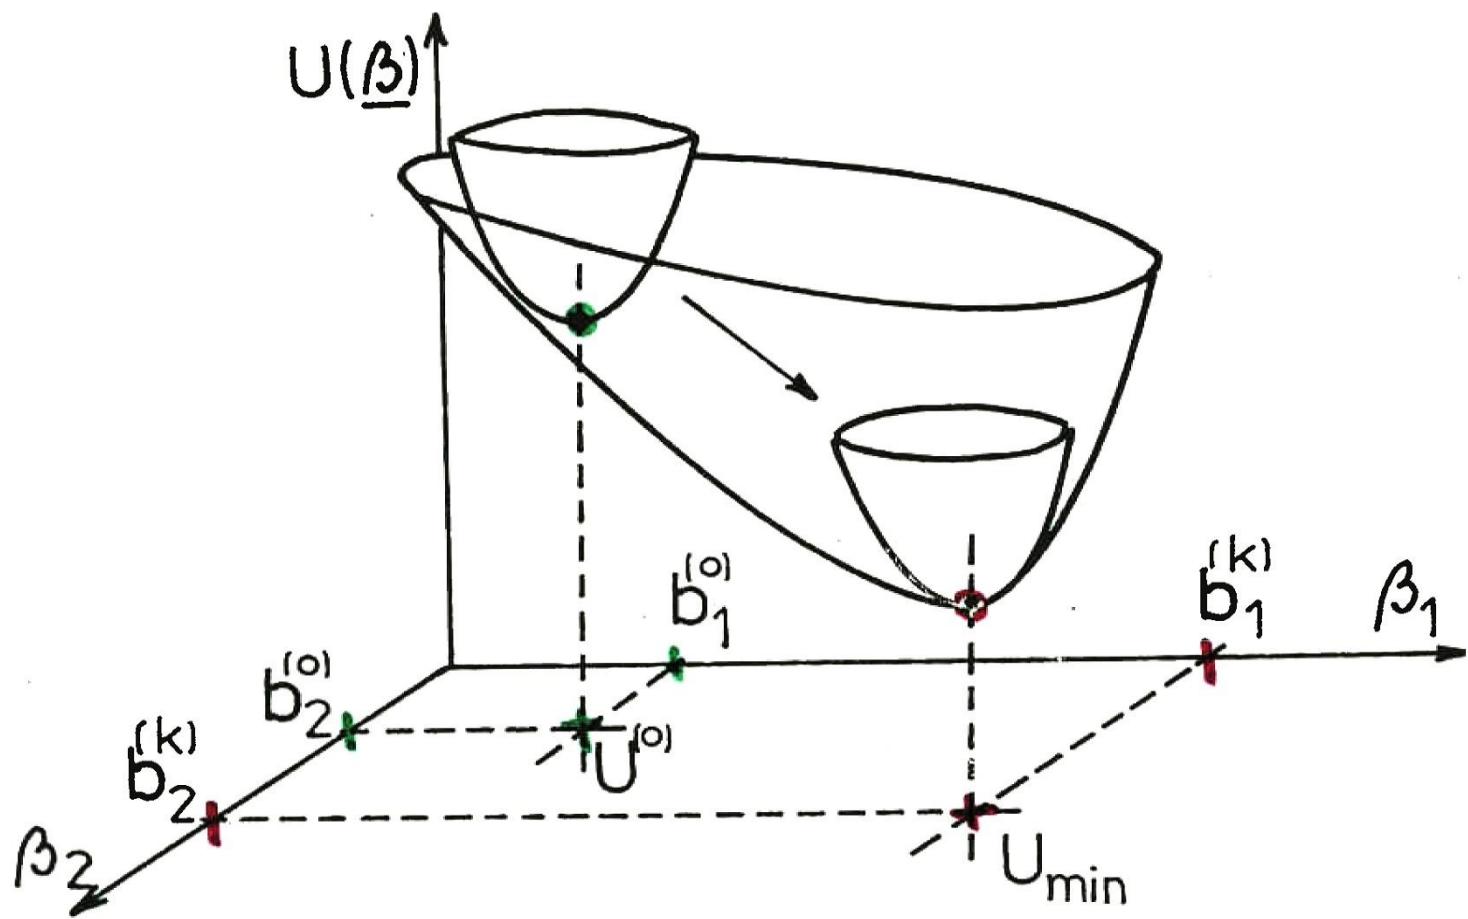
# MINIMALIZAČNÍ PROCES:







Případ dvou lokálních minim  $\beta$  a  $\beta^*$  a sedlového bodu  $S$



Geometrická interpretace hledání minima  $U(\beta)$

2. O lokálním chování funkce  $U(\beta)$  v okolí libovolného bodu  $\beta_j$  lze získat kvantitativní informace z jejího Taylorova rozvoje

$$U(\beta) = U(\beta_j) + \Delta\beta_j^T \mathbf{g}_j + \frac{1}{2} \Delta\beta_j^T \mathbf{H}_j \Delta\beta_j$$

# Numerické postupy

Nelineární minimalizace: model  $f(x, \beta)$  je nelineární vzhledem k parametru  $\beta_r$ ,

Nelineární maximalizace: použití maximální věrohodnosti

Extremalizace: užití libovolného kritéria regrese, kde "proměnné" jsou regresní parametry  $\beta$

Optimalizační metody:

- ***hledání volného extrému***, pokud nejsou na regresní parametry kladena žádná omezení,
- ***hledání vázaného extrému***, jestliže regresní parametry musí splňovat jisté omezující podmínky.

## Programy obsahují:

1. hledání extrému v zadaném směru (jednorozměrná optimalizace),
2. invertaci matic,
3. numerické derivace (u derivačních metod),
4. způsoby překonávání lokálních oblastí divergence.

## Dělení programů:

- a) nederivační optimalizační metody,
- b) derivační metody pro kritérium metody MNČ,
- c) obecné derivační metody,
- d) algoritmy pro speciální případy.

# Nederivační metody

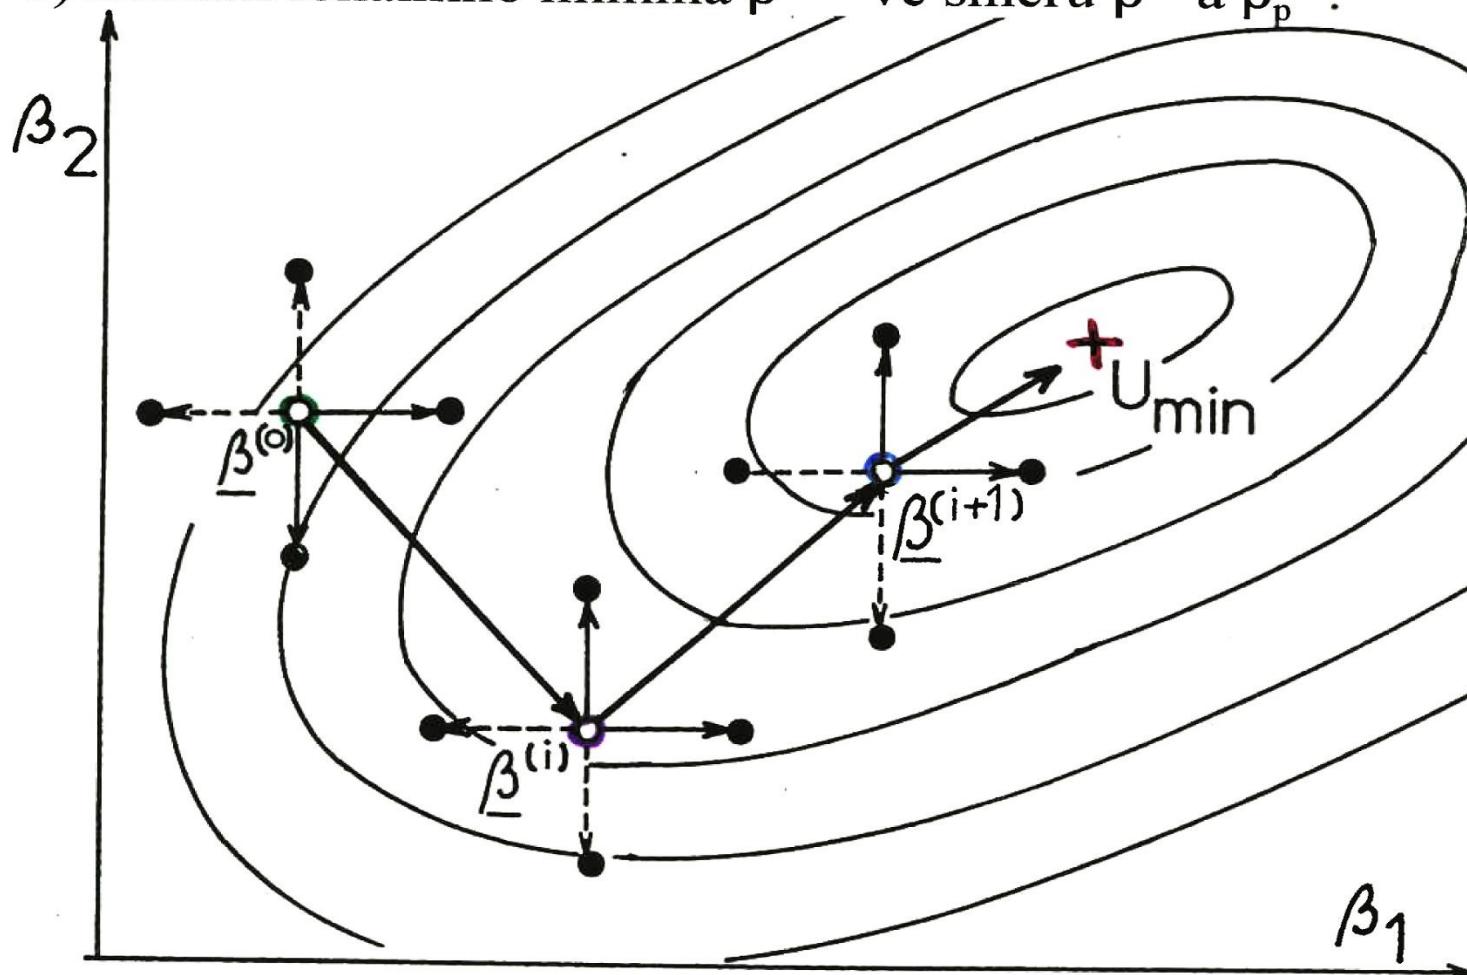
Umožňují nalezení extrému  $G(\beta)$  vzhledem k  $\beta$ :

1. metody přímého hledání,
2. simplexové metody,
3. metody využívající náhodných čísel,
4. postupy speciálně vhodné pro MNČ.

# 1. Metody přímého hledání

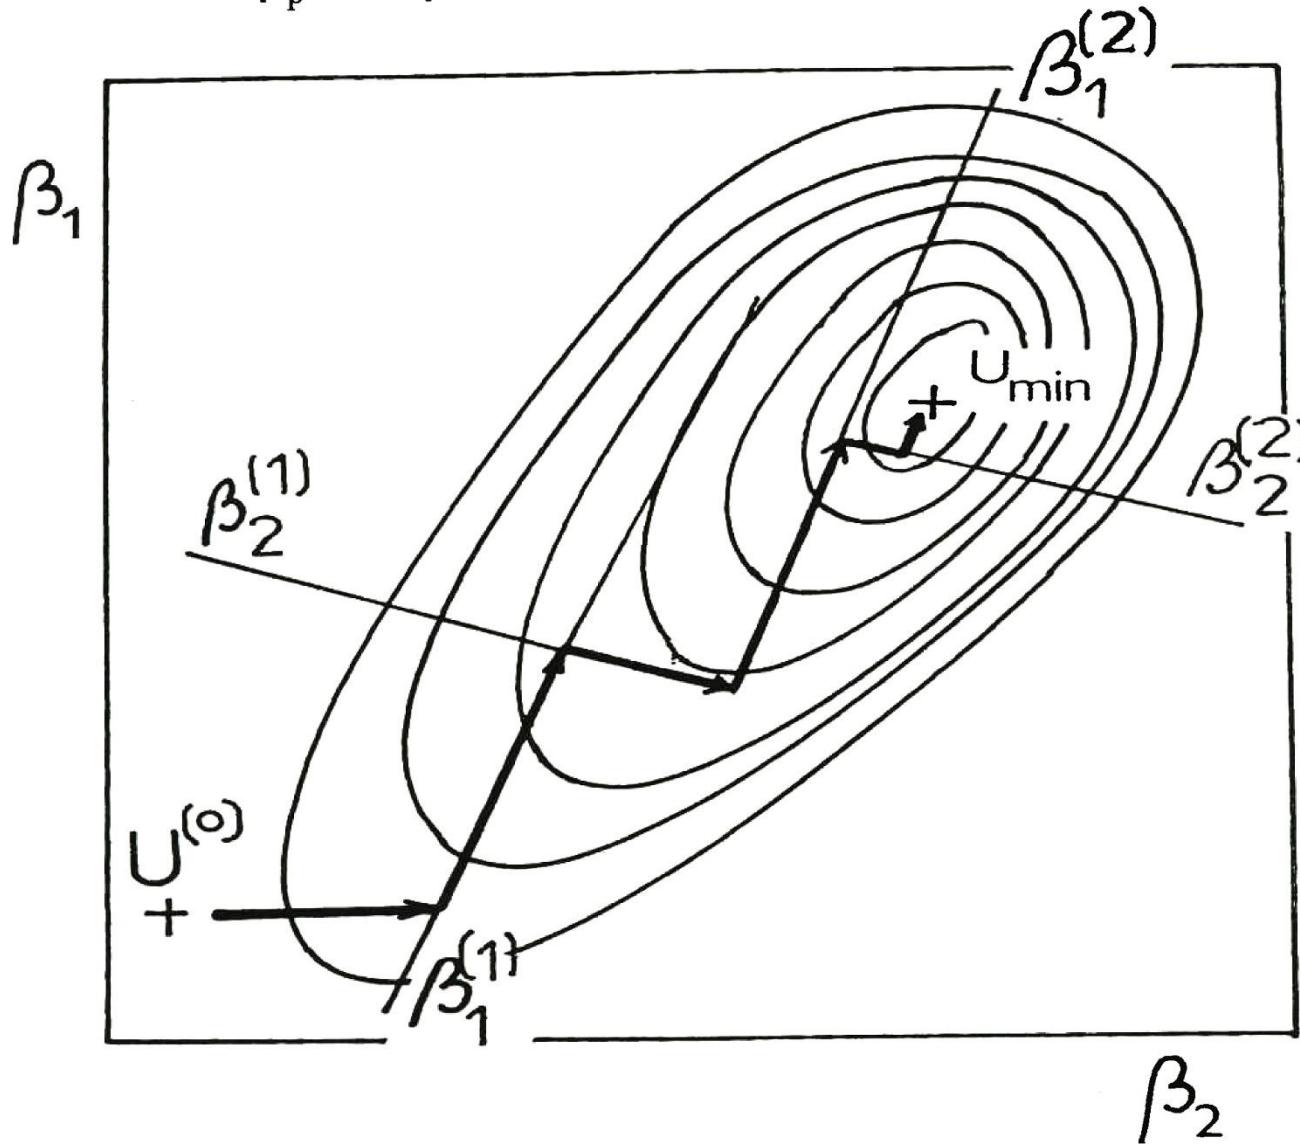
## Hookův-Jeevsův algoritmus:

- a) krokové posuny a nalezení zlepšeného odhadu  $\beta_p^{(i)}$ , pro který je  $G(\beta_p^{(i)}) < G(\beta^{(i)})$ ,
- b) hledání lokálního minima  $\beta^{(i+1)}$  ve směru  $\beta^{(i)}$  a  $\beta_p^{(i)}$ .



Postup koordinátního hledání (čárkovaně znázorněny neúspěšné směry)

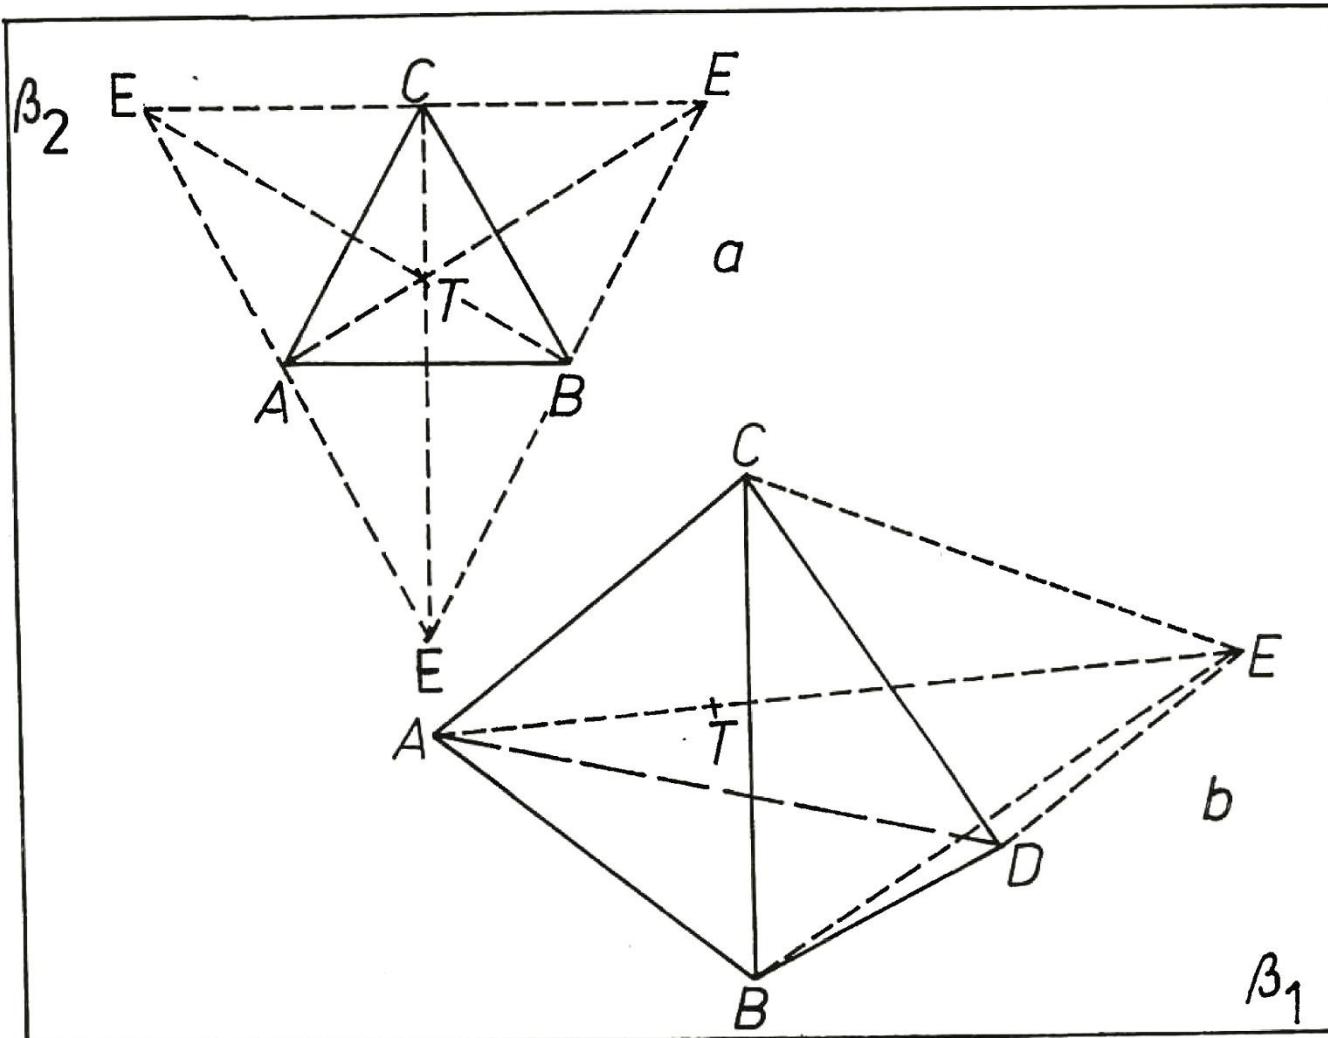
**Rosenbrockova metoda:** místo krokového hledání ve směru s rotací souřadného systému tak, aby jedna osa splynula se směrem  $\mathbf{S} = \beta_p^{(i+1)} - \beta^{(i)}$ .



Postup Rosenbrockovy minimalizace

## 2. Simplexové metody

Postupné vytváření *adaptivních polyedrů* (simplexů):



Simplex pro (a)  $m = 2$ , a (b)  $m = 3$  parametry.

Simplex A, B, C lze převrátit do tří poloh CBE, ABE, ACE

Z počátečního odhadu  $\beta^{(0)}$  se postupně tvoří *simplexy*.

Simplex je konvexní mnohostěn v m-rozměrném prostoru parametrů právě svými (m+1) vrcholy.

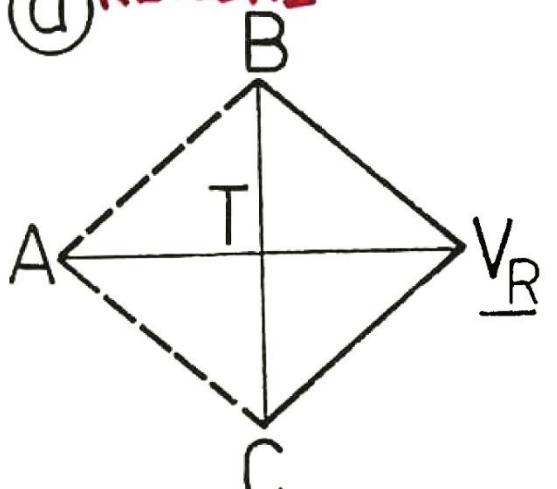
## Postup minimalizace:

1. Konstrukce výchozího simplexu.
2. Iterativní postup k minimu.
3. Identifikace ukončení hledání terminace.

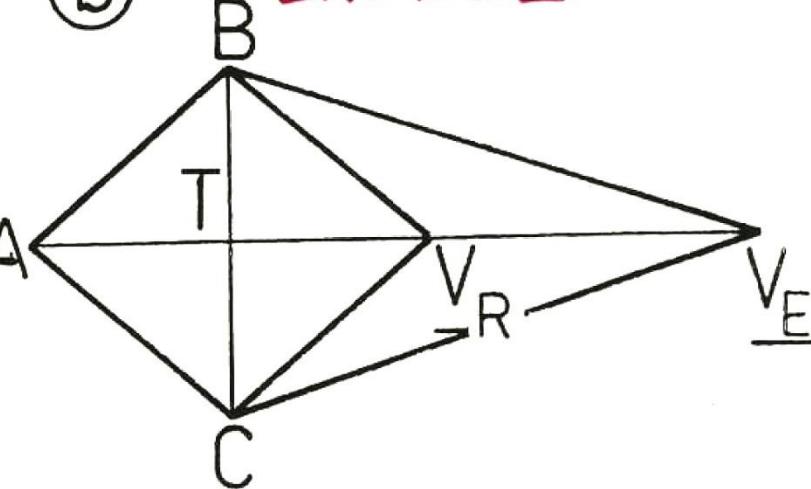
## 2. Iterativní postup k minimu

Na spojnici mezi  $V_H$  a jeho zrcadlovým obrazem pět operací:  
*reflexe, expanze, kontrakce, redukce a přenesení.*

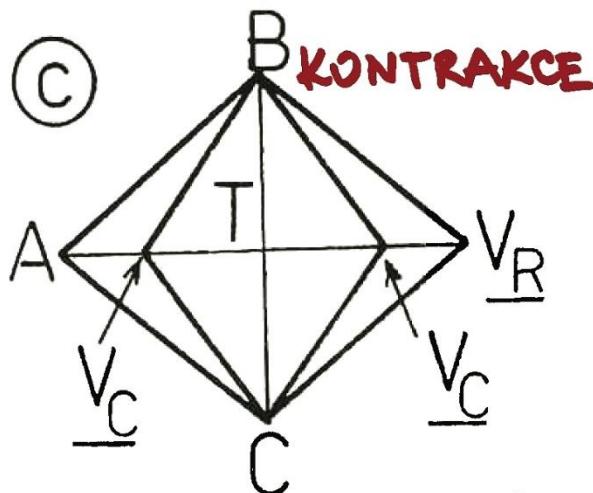
(a) **REFLEXE**



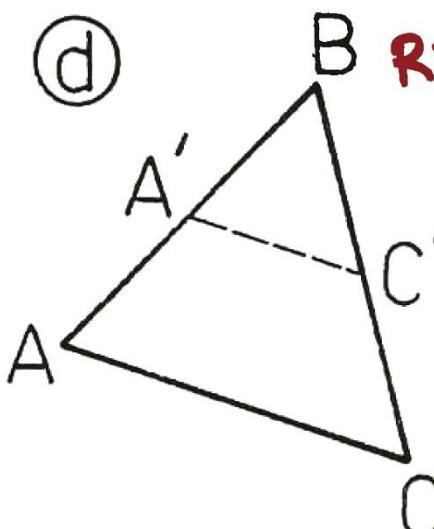
(b) **EXPANZE**

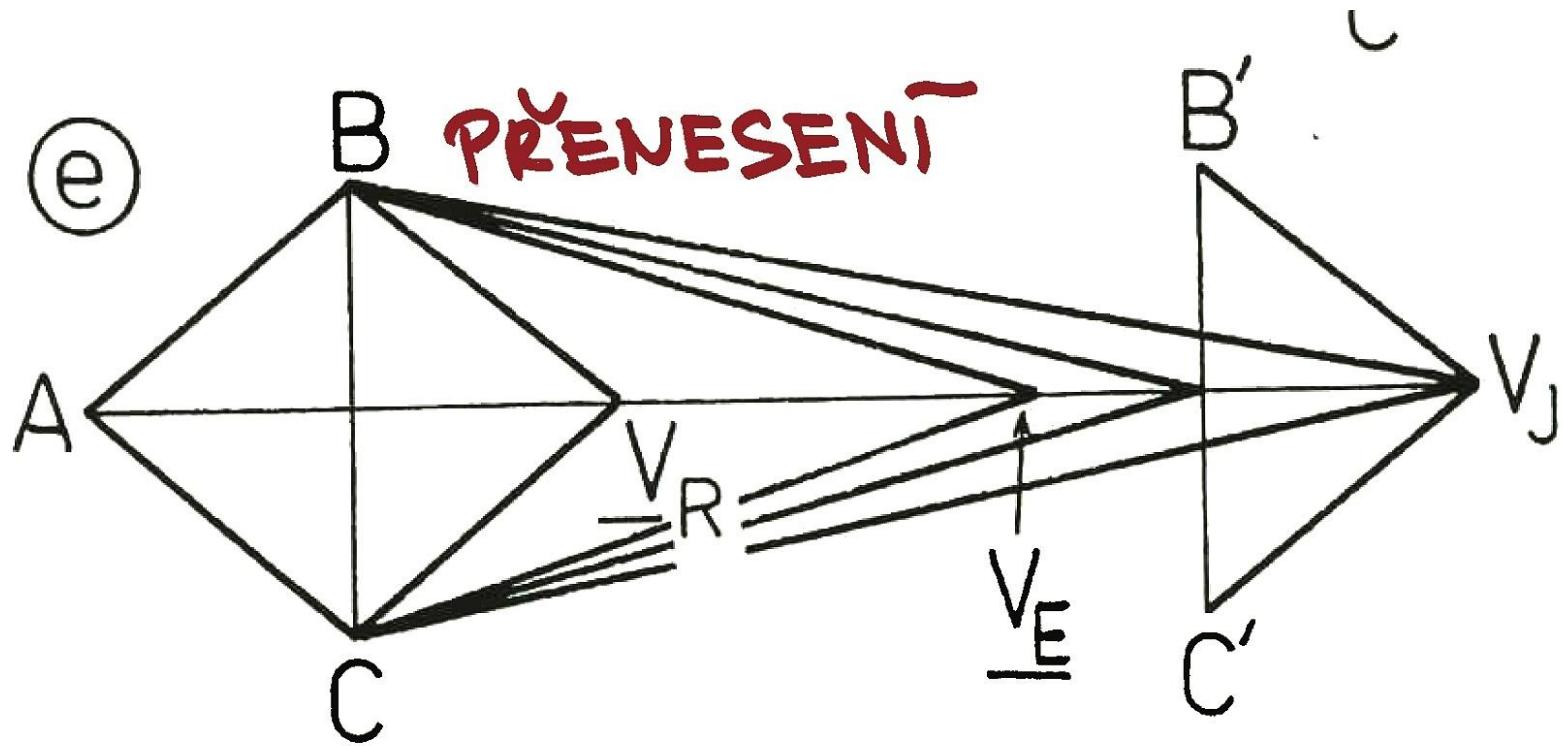


(c) **KONTRAKCE**



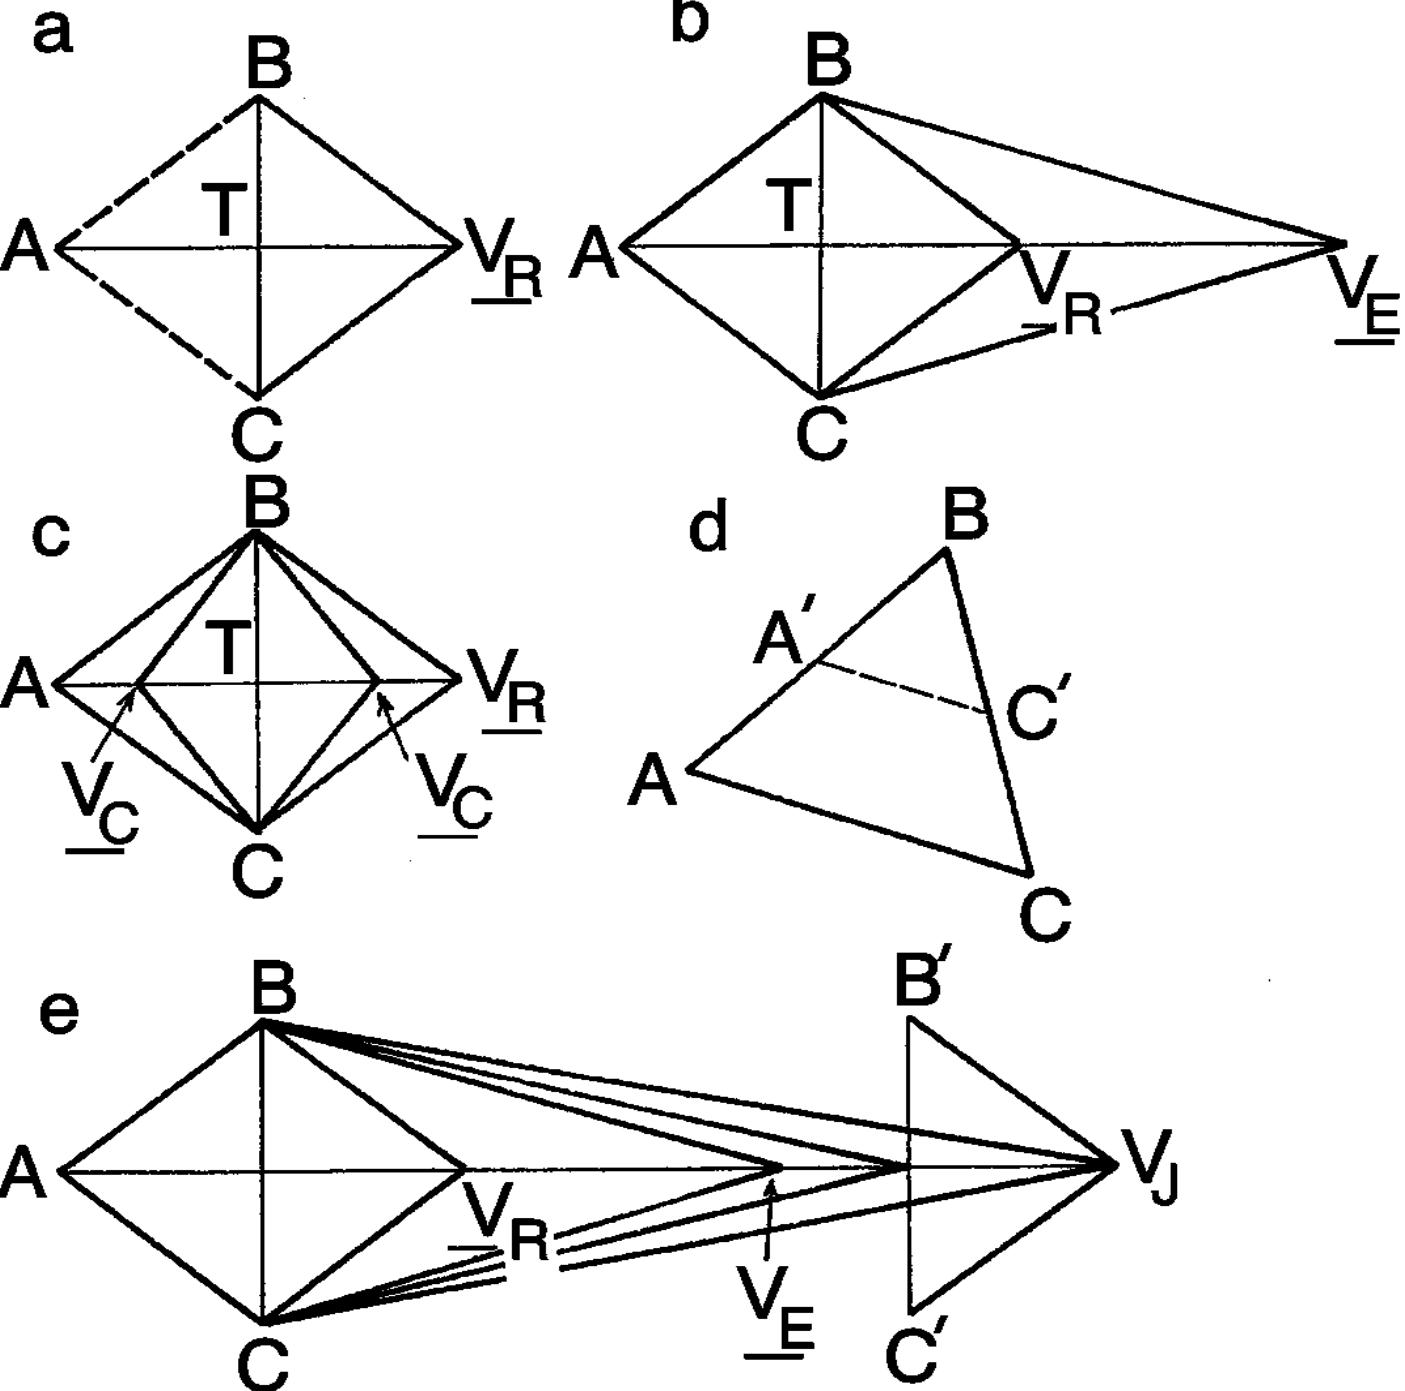
(d) **REDUKCE**





Základní operace simplexu:

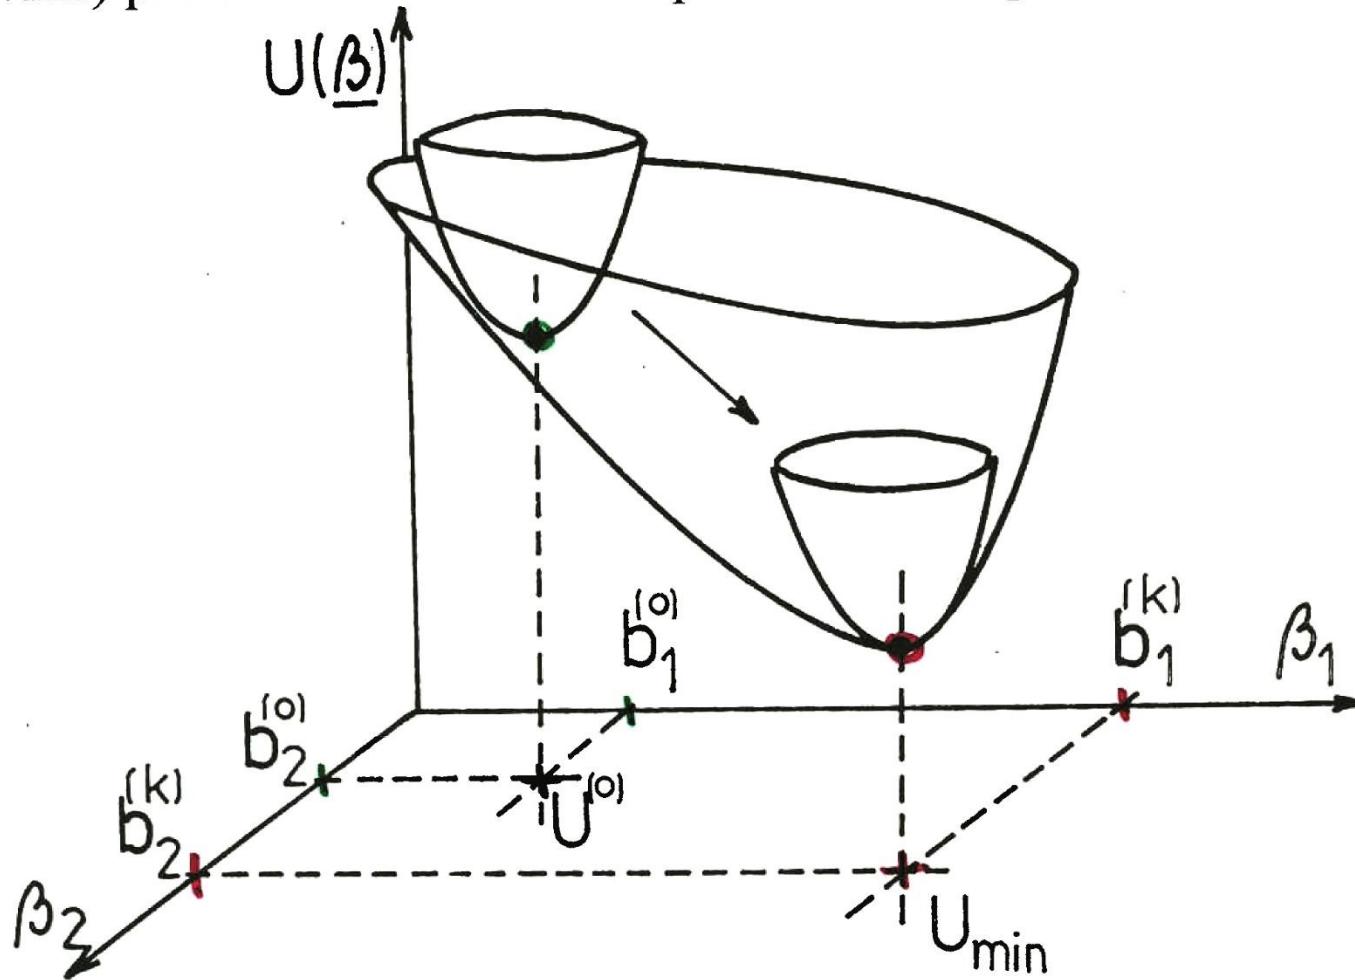
- a) reflexe, b) expanze, c) kontrakce, d) redukce a e) přenesení



## 4. Postupy speciálně pro MNC

Algoritmus LETAGROP: "mapování dolíčku" m-rozměrným eliptickým hyperparaboloidem.

Po dosazení vyjde  $(m + 1)(m + 2)/2$  "nástřelů" (= lineárních rovnic) pro určení koeficientů approximačního paraboloidu.



Geometrická interpretace hledání minima  $U(\beta)$  (LETAGROP)