

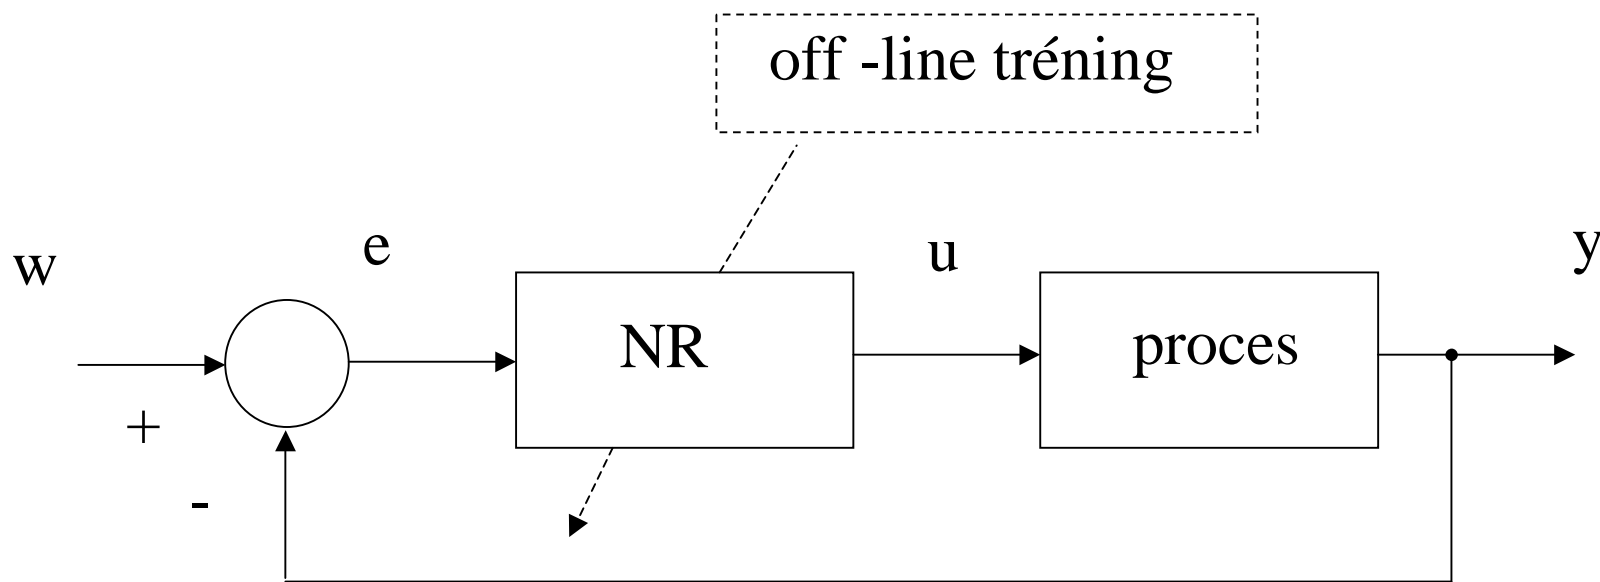
3.6 Neurónové siete v regulačných obvodoch

3.6.1 UNS ako priamy regulátor

Umelá neurónová sieť plní funkciu priameho regulátora, generuje riadiacu (rozhodovaciú) veličinu na priame ovplyvňovanie objektu riadenia.

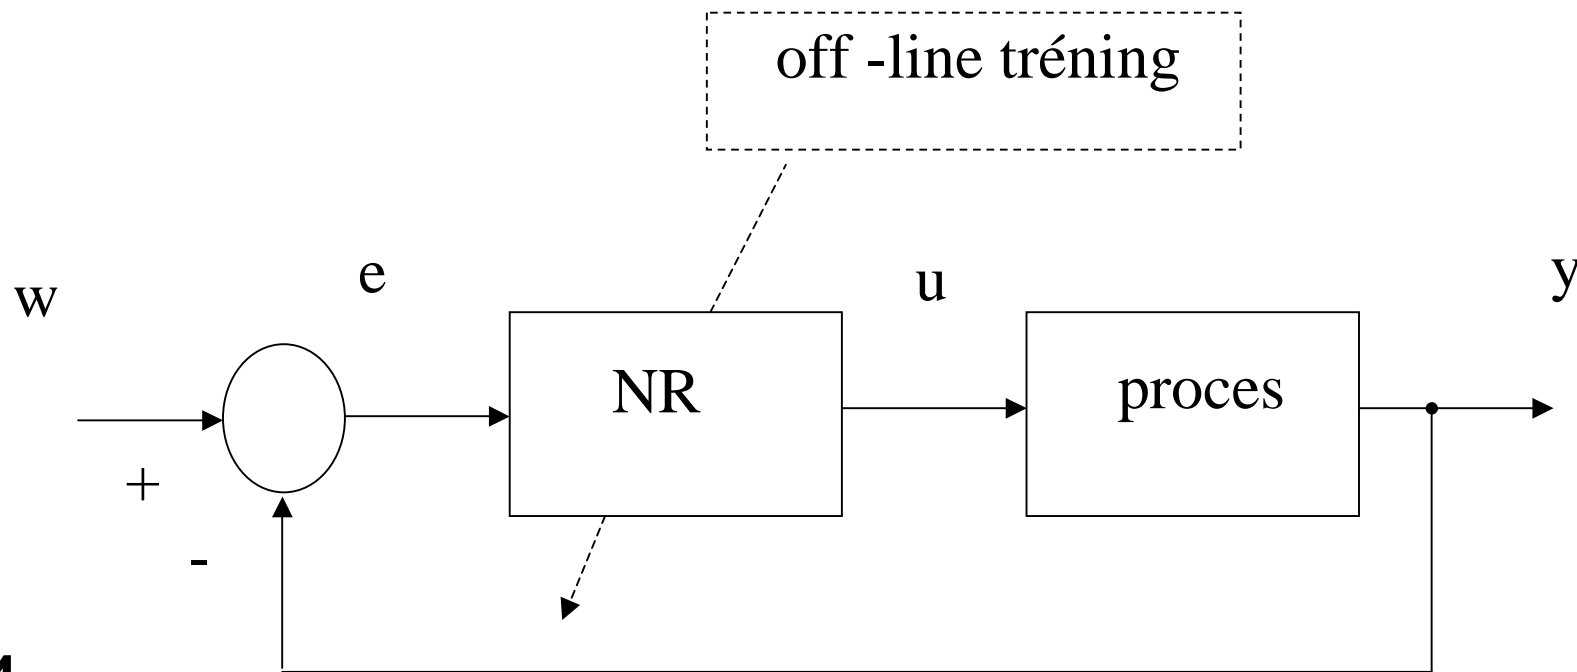
a₁) napodobenie experta

UNS modeluje na základe dostupných V/V dát vypozerované správanie sa experta (t'azko algoritmizovateľné postupy riadenia, znalosti, skúsenosti, štatisticky vyhodnotené dáta ...)



a₂) napodobenie iného typu regulátora

Ak je k dispozícii funkčný algoritmus riadenia, ktorý môže byť výpočtovo veľmi náročný, problematcky realizovateľný ... , UNS si na základe dostupných vstupných a výst. informácií natrénuje jeho správanie a potom ho môže rovnocenne nahradiť napr. jednoduchším hardvérom, znížením výpočtovej náročnosti ...



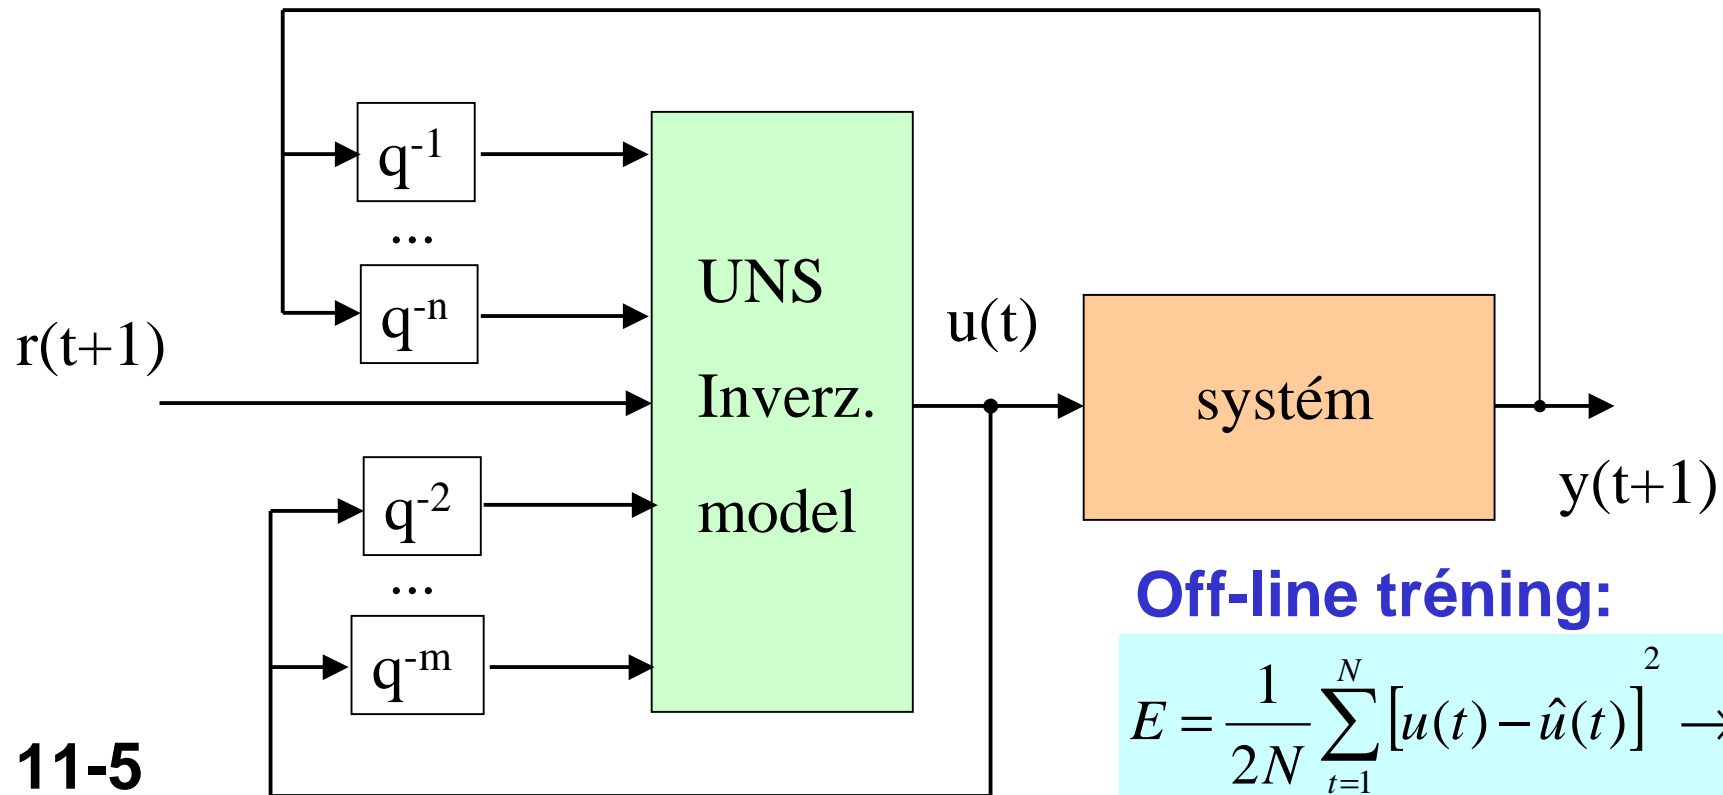
b) priame inverzné riadenie

system:

$$y(t+1) = f(y(t), y(t-1), \dots, y(t-n+1), u(t), \dots, u(t-m))$$

neurónový regulátor - natréňovanie inverz. modelu:

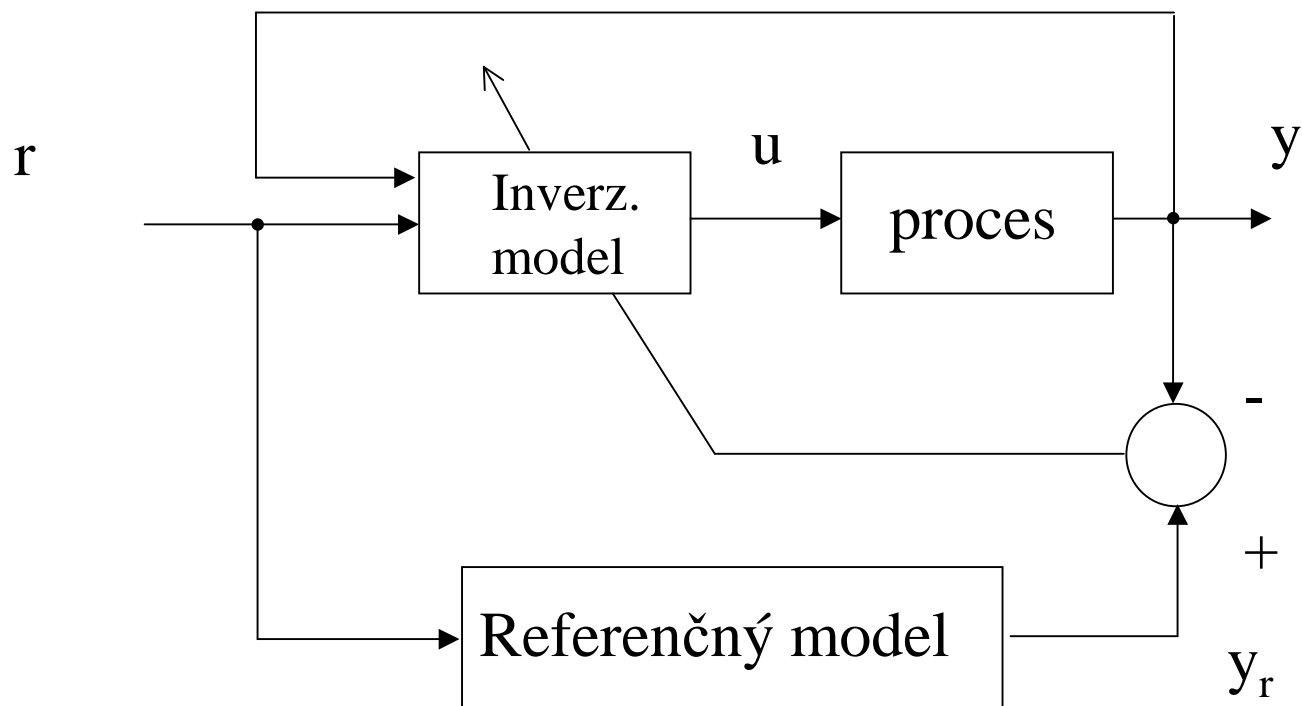
$$\hat{u}(t) = f^{-1}(y(t+1), y(t), \dots, y(t-n+1), u(t-1), \dots, u(t-m))$$



Off-line tréning:

$$E = \frac{1}{2N} \sum_{t=1}^N [u(t) - \hat{u}(t)]^2 \rightarrow \min$$

On-line verzia priameho inverzného riadenia



On-line tréning:

$$E = \frac{1}{2N} \sum_{t=1}^N [y_r(t) - y(t)]^2 \rightarrow \min$$

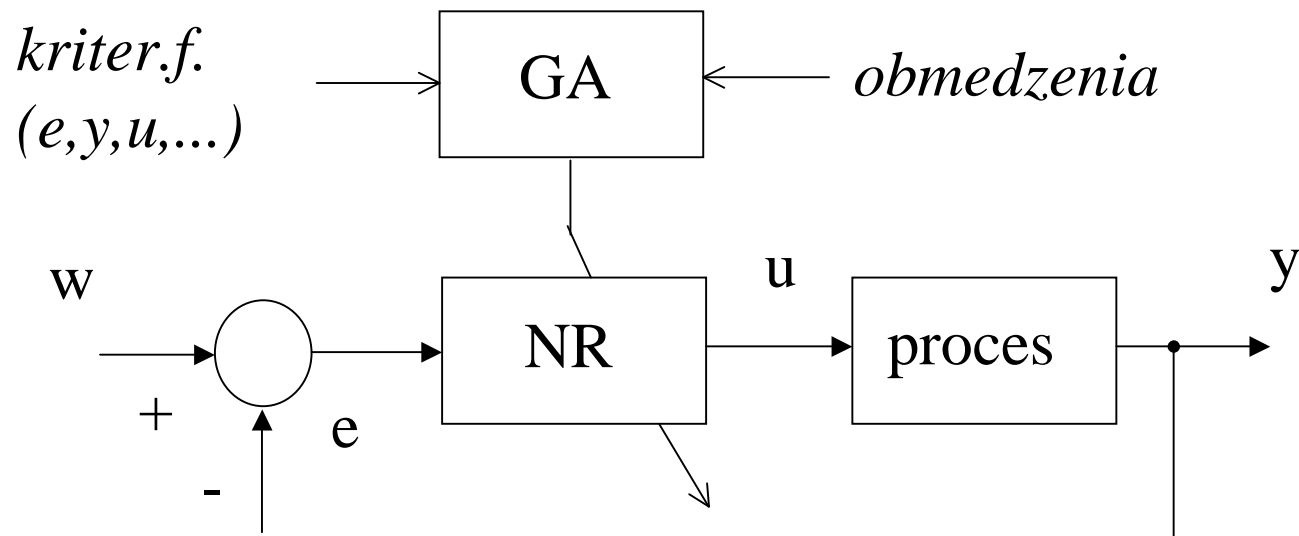
Výhody priameho inverzného riadenia

- Jednoduché
- Dobrá schopnosť sledovania referenčného signálu

Nevýhody priameho inverzného riadenia

- Nepoužíva regulačnú odchýlku
- Nepracuje, ak inverzný model je nestabilný, ale aj silne kmitavý
- Nedostatok parametrov na ladenie
- Veľká citlivosť na poruchy a šum

c) priamy NR optimalizovaný pomocou GA

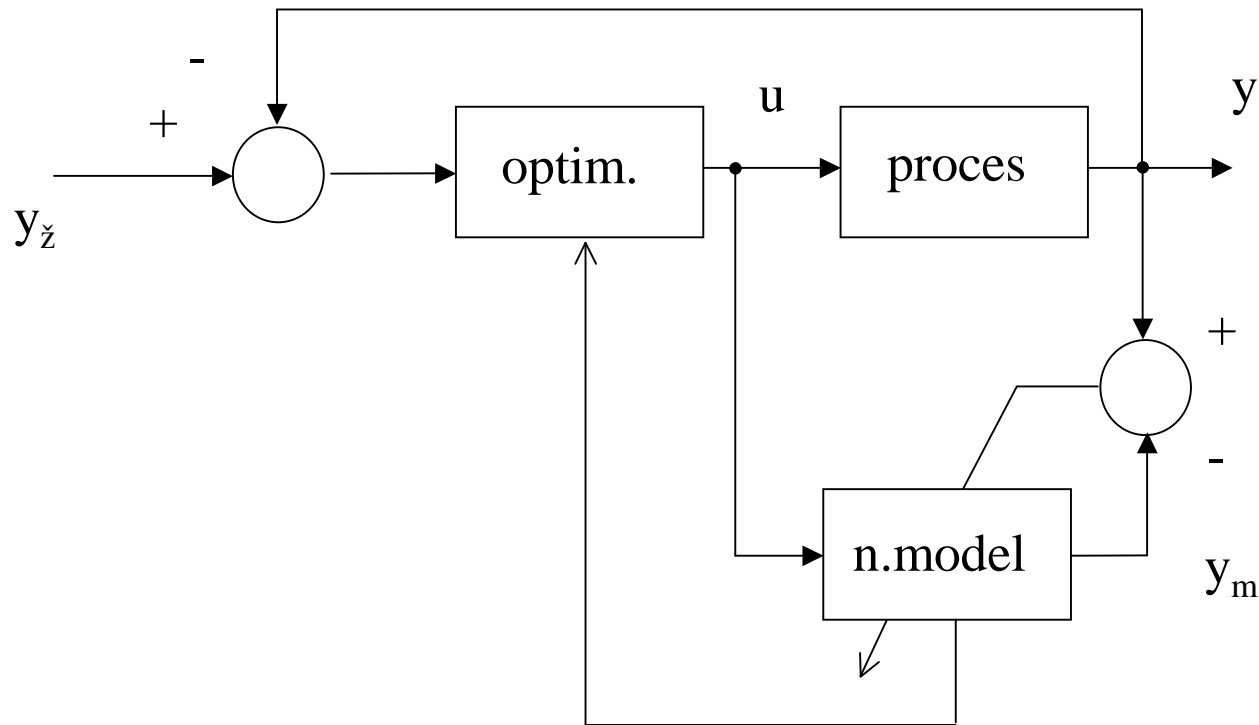


Postup návrhu / optimalizácie je obdobný ako pri návrhu iných systémov pomocou GA

3.6.2 Hybridné štruktúry riadenia s UNS

Riadiace štruktúry na báze UNS sú spojené s inými typmi riadenia, väčšinou ho dopĺňajú, plnia funkciu modelu, pomocnú funkciu, zlepšujú ho alebo ho adaptujú.

d) neuro-prediktívne riadenie



optim. - optimalizácia budúceho správania reg. obvodu

n.model - dostatočne presný neurónový model procesu
(trénovaný off-line, on-line)

Predpokladajme, že máme k dispozícii vhodný model objektu riadenia, pomocou ktorého dokážeme predikovať budúce správanie sa systému na základe súčasných a minulých stavových (výstupných) veličín.

Prediktívny algoritmus potom pracuje na základe nasledovného cyklu:

1. Odhad potrebného počtu (1 alebo aj viacerých) budúcich krokov výstupu systému na základe priebehu predpokladaného referenčného signálu.
2. Výpočet budúcich krokov riadiaceho zásahu tak, aby bolo minimalizované zvolené kritérium J .
3. Aplikácia prvého vypočítaného kroku riadenia a skok na bod 1.

Najčastejšia forma kritéria je v tvare

$$J = \sum_{i=N_1}^{N_2} [r(k+i) - \hat{y}(k+i)]^2 + \rho \sum_{i=1}^{N_u} [\Delta u(k+i-1)]^2 \rightarrow \min$$

$$\Delta u(k+i) = 0$$

$$N_u \leq i \leq N_2$$

N_1 - dolný predikčný horizont

N_2 - horný predikčný horizont

N_u - horizont predikcie riadenia

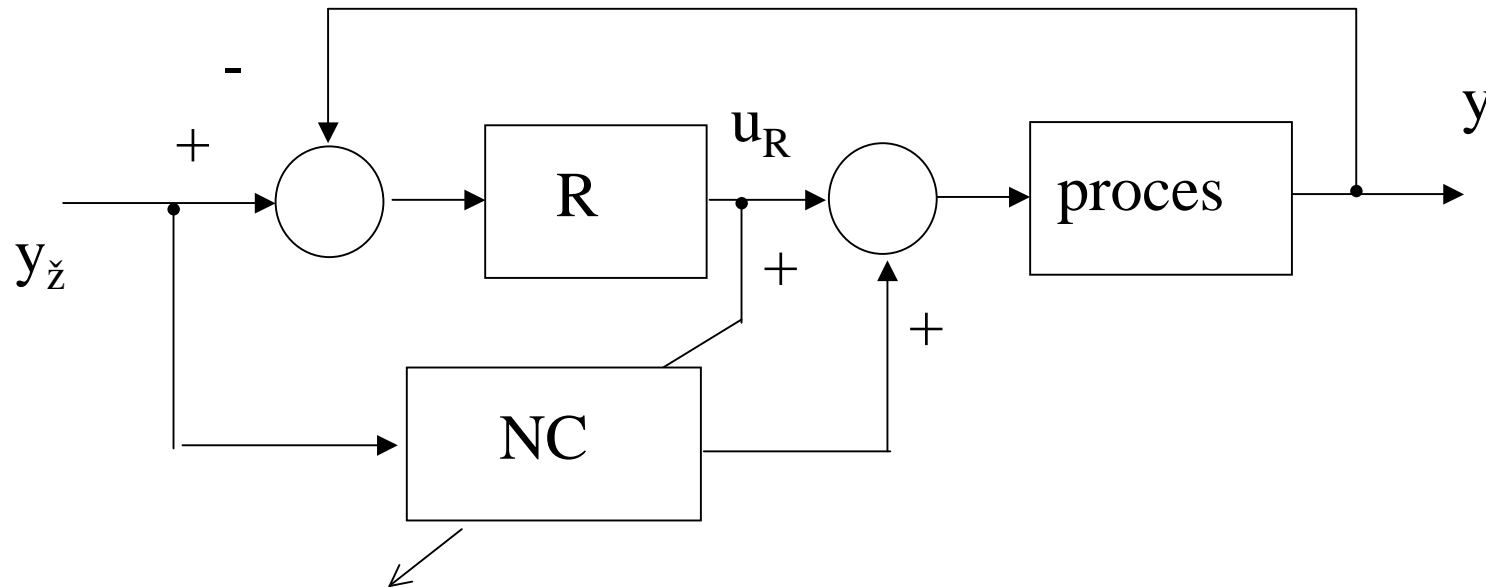
r - predpokladaný referenčný signál (žad. hod.)

\hat{y} - predikovaný výstup procesu

ρ - váha tlmenia zmien výstupu

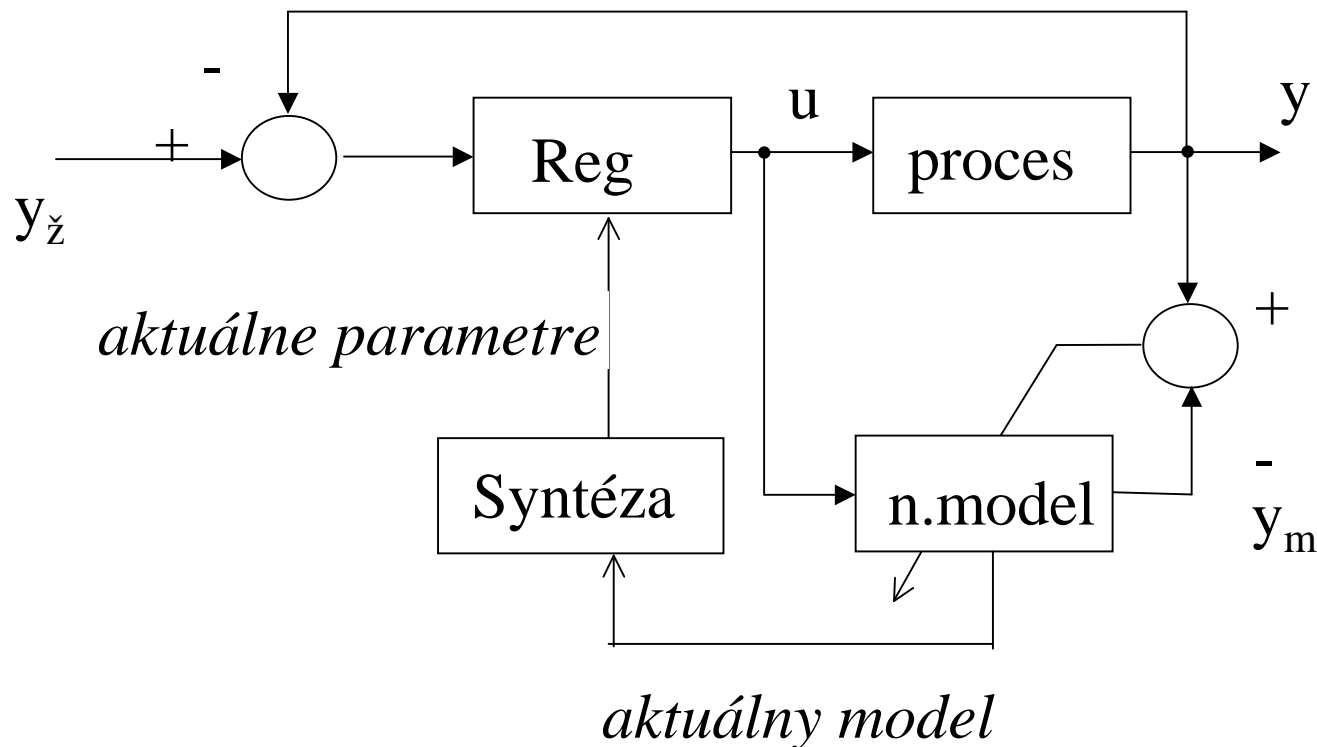
Cieľom algoritmu je zabezpečiť požadované správanie sa systému počas budúcich predpokladaných N_2 krokov.

e) dopredný korekčný člen



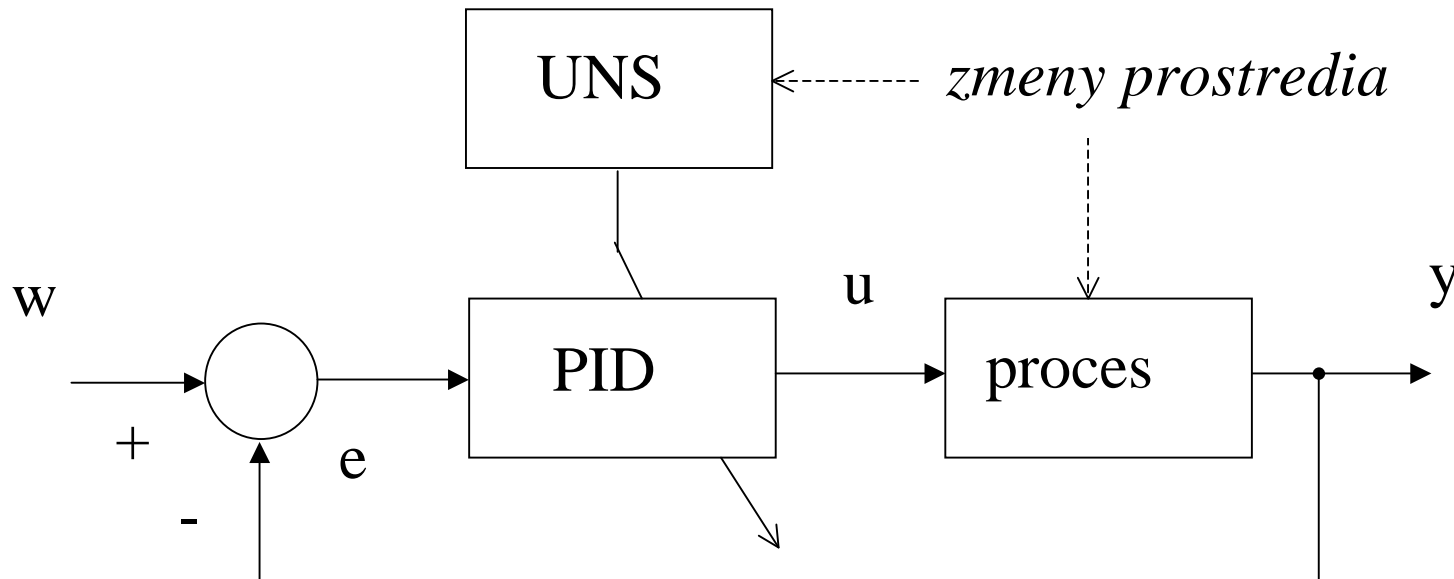
Neurónová sieť je vo funkcii dopredného korekčného člena (NC). Klasický regulátor (R) nemusí optimálne riadiť, ale musí zabezpečiť aspoň stabilizáciu procesu. Neurónový korektor je trénovaný minimalizáciou u_R (pomocou Back-Propagation). Pri regulácii potom minimalizáciou riadiaceho zásahu u_R optimalizuje regulačný pochod. Pokiaľ u_R obsahuje nenulovú ustálenú zložku (z integrátora), táto je na vstupe NR kompenzovaná.

f) Samonastavujúci sa regulátor ("selftuning")



Neurónový model je identifikovaný off-line alebo on-line aby dostatočne presne modeloval zmeny v riadenom procese. Na základe aktuálneho modelu sú zvolenou metódou syntézy aktualizované parametre regulátora. Možným prístupom návrhu regulátora sú genetické algoritmy.

g) Adaptácia klasického regulátora pomocou UNS



Neurónová sieť má natrénovanú závislosť medzi zmenami prostredia (napr. pracovnými bodmi systému, pôsobením poruchových veličín...) a zmenami parametrov regulátora (napr. PID). V závislosti od zmeny stavu prostredia sa potom adaptujú parametre regulátora (podobne ako fuzzy-gain-scheduling).