

## 7. Inteligentny regulator neuralny dla układów mechatronicznych

W rozdziale omówiono zaproponowany w pracy Lewisa *et al.* (2002) neuralny adaptacyjny regulator dla manipulatorów sztywnych (nazywany dalej PD+NNC). Zapewnia on dobrą jakość śledzenia, nie wymagając pełnej znajomości modelu dynamiki robota. Do aproksymacji nieliniowej dynamiki (uwzględniającej tarcie) PD+NNC wykorzystuje sieć neuronową o specjalnej strukturze. Uczenie sieci nie wymaga fazy off-line i jest realizowane on-line przy pomocy zmodyfikowanego algorytmu propagacji wstecznej. Dodatkowo prawo adaptacji nie zakłada liniowości względem adaptowanych parametrów (LIP- linearity in the unknown system parameters).

W rozdziale skupiono się przede wszystkim na koncepcji sterowania i omówieniu podstawowych cech algorytmu. Przedstawiono również jego realizację praktyczną w systemie MATLAB/Simulink/RT-CON. Strukturę PD+NNC przetestowano praktycznie, sterując w czasie rzeczywistym obiektem SUP2, tak więc niniejsza praca wraz z publikacją Żabińskiego, Turnaua (2005) potwierdza literaturowe badania symulacyjne.

### 7.1. Koncepcja sterowania z adaptacyjnym regulatorem neuralnym

Śledzenie w układach mechatronicznych, polega na ruchu efektora wzdłuż zadanej i zależnej od czasu trajektorii. Dla dużego zakresu zmian położenia i prędkości, precyzyjna realizacja tego zadania jest trudna. Znaczącą rolę odgrywają wtedy nieliniowości oraz sprzężenia dynamiczne pomiędzy członami układów mechatronicznych. Typowe klasyczne algorytmy śledzenia (Tchoń *et al.* 2000, Lewis *et al.* 2004, Spong, Vidyasagar 1997, Sage *et al.* 1999, Dawson *et al.* 1990) wymagają znajomości nieliniowych równań dynamiki manipulatora. Gdy taki model nie jest w pełni znany, stosowane są regulatory adaptacyjne lub odporne. Jednakże algorytmy te, wymagają zazwyczaj osobnej analizy równań dynamiki dla każdego nowego typu manipulatora. W pracy Lewisa *et al.* (2002), dla zadania śledzenia trajektorii zastosowano układ sterowania z siecią neuronową. Struktura ta, zgodnie z intencją jej twórców, ma spełniać rolę uniwersalnego układu sterowania (*universal reusable controller*) (Kwan *et al.* 2001). Oznacza to, iż może być wykorzystywana dla różnych manipulatorów sztywnych bez modyfikacji struktury regulatora i analizy równań dynamiki.

Dynamika manipulatora sztywnego dana jest zależnością (Lewis *et al.* 2002)

$$M(q)\ddot{q} + C(q, \dot{q}) + G(q) + F(q, \dot{q}) + \tau_d = \tau, \quad (7.1)$$

gdzie  $M(q)$  jest macierzą bezwładności, zaś pozostałe składniki wzoru to wektory opisujące:  $q$  - zmienne przegubowe,  $C(q, \dot{q})$  - siły odśrodkowe i Coriolisa,  $G(q)$  - grawitację,  $F(q, \dot{q})$  - tarcie,  $\tau_d$  - nieznanne lecz ograniczone zakłócenia (wynikające np. z niedokładności modelowania) oraz  $\tau$  - momenty sterujące. W zagadnieniu śledzenia trajektorii  $q_d(t)$ , zakłada się znajomość jej pochodnych  $\dot{q}_d(t)$  i  $\ddot{q}_d(t)$  oraz jej ograniczoność w sensie normy

euklidesowej. Tak więc rozważana trajektoria jest regularna, czyli  $\left\| \begin{matrix} q_d(t) \\ \dot{q}_d(t) \\ \ddot{q}_d(t) \end{matrix} \right\| \leq q_B$ , gdzie  $q_B$  jest

znanym skalarzem. Błąd śledzenia określono jako

$$e(t) = q_d(t) - q(t). \quad (7.2)$$

Analogicznie do algorytmu Slotine'a-Li (Tchoń *et al.* 2000) zdefiniowano zmienną ślizgu ( $r$ ) w postaci zależności (Lewis *et al.* 2002)

$$r = \dot{e} + \Lambda e, \quad \dot{r} = \ddot{e} + \Lambda \dot{e}, \quad (7.3)$$

gdzie  $\Lambda > 0$  jest diagonalną macierzą parametrów. Na podstawie (7.2) i (7.3) wyznaczono zależności

$$\dot{q} = \dot{q}_d + \Lambda e - r, \quad \ddot{q} = \ddot{q}_d + \Lambda \dot{e} - \dot{r}, \quad (7.4)$$

które po wstawieniu do (7.1) prowadzą do równania dynamiki manipulatora w postaci

$$M(q)\dot{r} + C(q, \dot{q})r = -\tau + f(X) + \tau_d, \quad (7.5)$$

gdzie  $X^T = [q^T \quad \dot{q}^T \quad q_d^T \quad \dot{q}_d^T \quad \ddot{q}_d^T]$ , zaś  $f(X)$  to całkowicie lub częściowo nieznana funkcja dana wzorem

$$f(X) = M(q)(\ddot{q}_d + \Lambda \dot{e}) + C(q, \dot{q})(\dot{q}_d + \Lambda e) + G(q) + F(q, \dot{q}). \quad (7.6)$$

Ze względu na tarcie występujące w układach mechatronicznych,  $f(X)$  zawiera nieciągłości pierwszego rodzaju (Leja 1976). Należy podkreślić, iż wyznaczenie funkcji  $f(X)$  nie wymaga mierzenia ani estymacji przyspieszeń. Wyrażenia  $v = \dot{q}_d + \Lambda e$  i  $\dot{v} = \ddot{q}_d + \Lambda \dot{e}$  są w literaturze nazywane trajektorią odniesienia (Tchoń *et al.* 2000). Metoda zaproponowana w pracy Lewisa *et al.* (2002) definiuje moment sterujący jako

$$\tau = K_v r + \hat{f}(X), \quad (7.7)$$

gdzie  $\hat{f}(X)$  jest estymatą funkcji  $f(X)$ , zaś  $K_v > 0$  to diagonalna macierz wzmocnień. Układ sterowania zawiera regulator PD postaci

$$PD = K_v r = K_v \dot{e} + K_p \Lambda e = K_p e + K_v \dot{e}, \quad K_p = K_v \Lambda \quad (7.8)$$

oraz człon  $\hat{f}(X)$  kompensujący nieznane nieliniowości manipulatora (włączając nieciągłą charakterystyką tarcia). Wstawiając (7.7) do (7.5) równanie manipulatora przyjmuje postać

$$M(q)\dot{r} + C(q, \dot{q})r + K_v r = \tilde{f}(X) + \tau_d, \quad \tilde{f}(X) = f(X) - \hat{f}(X). \quad (7.9)$$

Porównując (7.9) z analogicznym równaniem dla algorytmu Slotine'a-Li (Spong, Vidyasagar 1997) można stwierdzić, iż omawiana metoda prowadzi do identycznej struktury układu sterowania. Różnica dotyczy uzyskania  $\hat{f}(X)$  oraz realizacji adaptacji. Należy zwrócić uwagę na fakt, iż proponowana struktura uwzględnia ograniczone zakłócenia ( $\tau_d$ ), które w podstawowym algorytmie Slotine'a-Li, mogą prowadzić do nieograniczonego wzrostu wartości bezwzględnych adaptowanych parametrów (Sage *et al.* 1999).

Dla zagwarantowania stabilności układu (rozumianej jako ograniczoność błędu śledzenia i jego pochodnej) wystarczy określić sterowanie (7.7), zapewniające ograniczoność zmiennej ślizgu  $r$  (Lewis *et al.* 2002). Aby w praktyce wykorzystać zaproponowane prawo sterowania, należy podać wskazówki ułatwiające dobór nastaw regulatora PD, określić metodę uzyskiwania  $\hat{f}(X)$  oraz udowodnić stabilność układu. Jak wykazano w pracy Dawsona *et al.* (1990), dobór wystarczająco dużych nastaw PD zapewnia ograniczoność błędu śledzenia dla manipulatora sztywnego. Pomimo, iż w publikacji Lewisa *et al.* (2002) podano oszacowanie minimalnej wartości wzmocnienia  $K_v$  regulatora PD, to jednak zaleca się dobór jego nastaw metodą prób i błędów. Parametr  $\Lambda$  występujący we wzorze (7.8) wpływa na szybkość zanikania błędu (Tchoń *et al.* 2000), zaś  $K_v$  na dokładność śledzenia (Lewis *et al.* 2002).

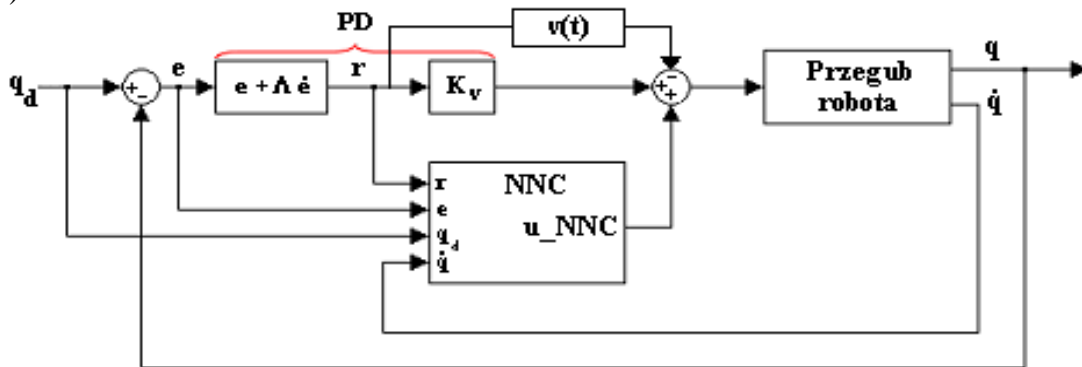
Estymatę  $\hat{f}(X)$  uzyskano przy pomocy zmodyfikowanej sieci neuronowej (dwuwarstwowej), umożliwiającej aproksymację funkcji z nieciągłościami pierwszego rodzaju (w pracy Lewisa *et al.* (2002) podano odpowiednie twierdzenia wraz z dowodami). Ponieważ uczenie sieci jest realizowane *on-line*, tak więc otrzymano strukturę adaptacyjną. Nie wymaga ona liniowości względem nieznanymi parametrów (LIP) oraz znajomości

macierzy regresji (Lewis *et al.* 2002). Podobnie jak w przypadku dysypatywnego algorytmu Slotine'a-Li (Spong, Vidyasagar 1997), prawo sterowania (7.7) nie linearyzuje w pełni równań dynamiki manipulatora, zapewniając, mimo to, dobrą jakość śledzenia. Metoda nie wymaga uczenia sieci neuronowej w trybie *off-line* ani specjalnego doboru początkowych wartości wag. Podstawowym wymaganiem jest, aby manipulator w chwili początkowej znajdował się „wystarczająco blisko” (Lewis *et al.* 2002) zadanej trajektorii, co w praktyce nie stanowi problemu.

Przedstawiony w pracy Lewisa *et al.* (2002), dowód stabilności układu PD+NNC wykorzystuje drugą metodę Lapunowa (Mitkowski 1996) wraz z jej rozszerzeniami. Gwarantuje on małe błędy śledzenia oraz ograniczoność wartości wag sieci neuronowej uzyskiwanych w trakcie procesu uczenia.

## 7.2. Struktura i realizacja praktyczna układu regulacji

Układ PD+NNC tworzy wewnętrzną pętlę z regulatorem neuralnym (NNC) oraz zewnętrzną z liniowym PD (rys. 7.1). NNC eliminuje nieznane nieliniowości, zaś PD stabilizuje system w początkowej fazie ruchu, gdy regulator neuralny rozpoczyna uczenie (Lewis *et al.* 2002). W strukturze pokazanej na rys. 7.1 w stosunku do prawa sterowania (7.7) wprowadzono dodatkowy człon uodparniający  $v(t)$ , gwarantujący stabilność (Lewis *et al.* 2002).



Rys. 7.1. Schemat układu z neuralnym regulatorem PD+NNC

Na rys. 7.2 przedstawiono sieć neuronową (dla jednowymiarowego układu) zawierającą dwa neurony w warstwie ukrytej oraz pojedynczy neuron (z liniową funkcją aktywacji) w warstwie wyjściowej. Składa się ona z klasycznej sieci neuronowej (NN) oraz części rozszerzonej (ANN), umożliwiającej aproksymację funkcji z nieciągłościami pierwszego rodzaju, które występują dla znanych argumentów (Lewis *et al.* 2002).

Wyjście regulatora neuralnego NNC opisuje zależność

$$u_{NNC} = W^T \sigma(V^T x) + W_A^T \phi(x_A), \quad (7.10)$$

dla wejść zdefiniowanych jako

$$x = [1 \quad e \quad \dot{e} \quad q_d \quad \dot{q}_d \quad \ddot{q}_d]^T, \quad x_A = [1 \quad \dot{q}]^T. \quad (7.11)$$

We wzorze (7.10)  $W$  to wektor wag warstwy wyjściowej sieci klasycznej (NN),  $V$  to macierz wag warstwy ukrytej a  $W_A$  to wektor wag warstwy wyjściowej części rozszerzonej (ANN) (rys. 7.2).

Pozostałe zależności opisujące NNC z rys. 7.2 dane są wzorami

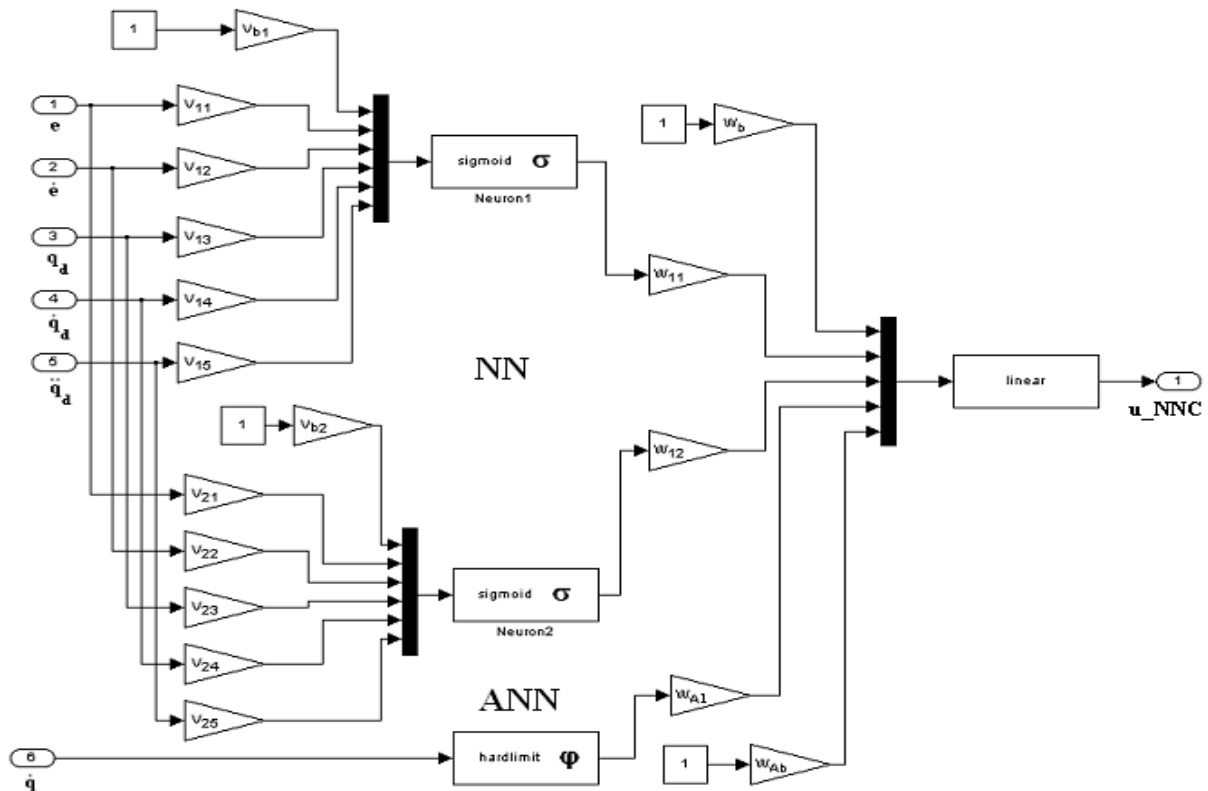
$$V = \begin{bmatrix} V_{b1} & V_{b2} \\ V_{11} & V_{21} \\ V_{12} & V_{22} \\ V_{13} & V_{23} \\ V_{14} & V_{24} \\ V_{15} & V_{25} \end{bmatrix}, \quad W = \begin{bmatrix} W_b \\ W_{11} \\ W_{12} \end{bmatrix}, \quad W_A = \begin{bmatrix} W_{Ab} \\ W_{A1} \end{bmatrix}, \quad \sigma(\circ) = \begin{bmatrix} 1 \\ \sigma(z_1) \\ \sigma(z_2) \end{bmatrix}, \quad \sigma(z_i) = \frac{1}{1+e^{-z_i}}, \quad (7.12)$$

$$z_i = \sum_{j=1}^6 V_{ij}^T \cdot x_j, \quad \varphi(\circ) = \begin{bmatrix} 1 \\ \varphi(\dot{q}) \end{bmatrix}, \quad \varphi(\dot{q}) = \begin{cases} 1: \dot{q} \geq 0 \\ 0: \dot{q} < 0 \end{cases}$$

Wektor sygnałów wejściowych (7.11) umożliwia aproksymację funkcji  $f(X)$  danej wzorem (7.6), gdyż  $q = q_d - e$ ,  $\dot{q} = \dot{q}_d - \dot{e}$ . Człon uodparniający  $v(t)$  opisany jest zależnością

$$v(t) = -K_z (\|Z\|_F + Z_B) r, \quad Z = \begin{bmatrix} W & 0 & 0 \\ 0 & W_A & 0 \\ 0 & 0 & V \end{bmatrix}, \quad (7.13)$$

gdzie  $\| \cdot \|_F$  jest normą Frobeniusa, zaś  $K_Z$  oraz  $Z_B$  dobraćymi eksperymentalnie stałymi.



Rys. 7.2. Struktura regulatora neuralnego (NNC) dla układu jednowymiarowego

Ilość neuronów warstwy ukrytej NN oraz rozszerzonej ANN zależy od stopnia skomplikowania funkcji  $f(X)$  i jest dobraća indywidualnie dla danego manipulatora. Zwiększenie liczby neuronów powoduje zazwyczaj zmniejszenie błędu śledzenia. Jak pokazano w pracy Lewisa *et al.* (2002) po przekroczeniu pewnej granicznej (dla danego problemu) ilości neuronów, dalszy wzrost ich liczby nie wpływa znacząco na polepszenie jakości sterowania.

Regulator NNC w łatwy sposób może zostać dostosowany do sterowania układem wielowymiarowym. W takim przypadku należy rozszerzyć wektor sygnałów wejściowych  $x$  dany wzorem (7.11) oraz określić odpowiednią ilość wyjść sieci (rozdział 9.2).

### Algorytm uczenia neuralnego regulatora NNC

Metoda uczenia NNC to rozszerzona wersja algorytmu propagacji wstecznej (Lewis *et al.* 2002). Minimalizowanym błędem jest zmienna ślizgu  $r$  dana wzorem (7.3). Należy podkreślić fakt, iż NNC jest uczony *on-line* (wagi modyfikowane są w każdym cyklu regulatora) i nie wymaga fazy *off-line*. Dowód stabilności jest niezależny od początkowych wartości wag (Lewis *et al.* 2002), dlatego też przyjmuje się je losowo dla warstwy ukrytej oraz zeruje dla wyjściowej (Lewis *et al.* 2004). Przy takim doborze wag, sygnał sterujący w pierwszych chwilach działania PD+NNC jest wypracowywany głównie przez regulator PD.

Algorytm uczenia (w przypadku ciągłym) dany jest zależnościami

$$\begin{aligned}\hat{W} &= \alpha \cdot \sigma(\hat{V}^T x) \cdot r - \alpha \cdot \sigma'(\hat{V}^T x) \cdot \hat{V}^T \cdot x \cdot r - k \cdot \alpha \cdot \|r\| \cdot \hat{W}, \\ \hat{V} &= \beta \cdot x \cdot r \cdot (\hat{W}^T \cdot \sigma'(\hat{V}^T x)) - k \cdot \beta \cdot \|r\| \cdot \hat{V}, \\ \hat{W}_A &= \gamma \cdot \varphi(\dot{q}) \cdot r - k \cdot \gamma \cdot \|r\| \cdot \hat{W}_A,\end{aligned}\tag{7.14}$$

gdzie  $\hat{W}, \hat{V}, \hat{W}_A$  są otrzymywanymi w każdym kroku sterowania, estymatami idealnych wag aproksymujących funkcję  $f(X)$ , zaś  $\alpha, \beta, \gamma$  i  $k$  są dobieranymi eksperymentalnie współczynnikami. Macierz pochodnych funkcji aktywacji dla sieci przedstawionej na rys. 7.2 przyjmuje postać

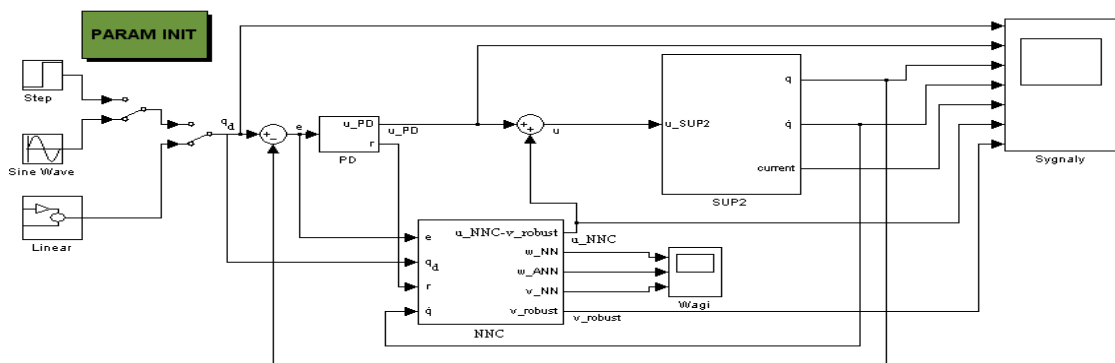
$$\sigma'(\circ) = \begin{bmatrix} 0 & 0 \\ \sigma'(z_1) & 0 \\ 0 & \sigma'(z_2) \end{bmatrix}, \text{ gdzie } \sigma'(z_i) = \frac{d\sigma(z_i)}{dz_i} = \sigma(z_i) \cdot [1 - \sigma(z_i)] \text{ dla sigmoidalnych funkcji}$$

aktywacji danych wzorem (7.12). W przypadku jednowymiarowym  $\|r\|$  wyznacza się jako wartość bezwzględna, zaś w układach wielowymiarowych stosuje się normę euklidesową. Pierwsze człony wzorów (7.14) odpowiadają klasycznej metodzie propagacji wstecznej, w której sygnałem propagowanym jest  $r$ . Ostatnie realizują algorytm e-mod (Narendra, Annaswamy 1987), gwarantujący ograniczoność wag sieci (poprzez pewnego rodzaju mechanizm „zapominania” - Lewis *et al.* 1996). Drugi człon we wzorze opisującym modyfikację  $\hat{W}$  jest nowym elementem, wprowadzonym ze względu na nieliniowość wyjścia sieci względem wag (Lewis 1999). Reprezentuje on propagację sygnału „w przód” (Lewis *et al.* 1996).

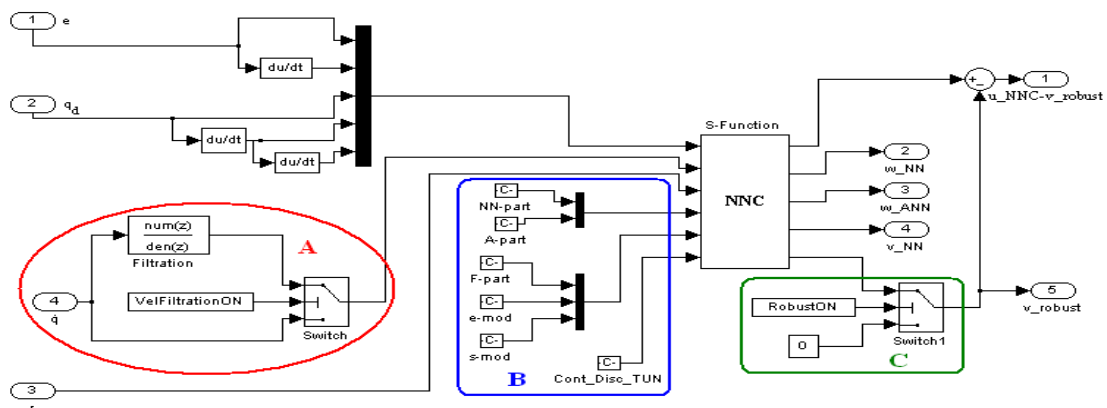
Zarówno regulator NNC, jak i człon uodporniający  $v(t)$ , generują sygnał wyjściowy wykorzystując aktualne (uzyskiwane w danym kroku sterowania) estymaty  $\hat{W}, \hat{V}, \hat{W}_A$ . Nie jest istotne, czy są one zbieżne do idealnych wag dobrze aproksymujących funkcję  $f(X)$ . Ważne jest jedynie to, że takie idealne wagi istnieją. Pomimo braku zbieżności (identycznie jak w adaptacyjnym algorytmie Slotine’a-Li), uzyskuje się dobrą jakość śledzenia (Lewis *et al.* 2002). Z teorii adaptacji wiadomo, że warunek zbieżność wymaga „dostatecznie bogatej” trajektorii zadanej (Spong, Vidyasagar 1997), gdyż musi ona w wystarczającym stopniu pobudzać dynamikę układu. Taka trajektoria może jednak nie być praktyczna w pewnych zastosowaniach robotycznych (Lewis *et al.* 2004).

## Realizacja PD+NNC w systemie MATLAB/Simulink/RT-CON

Regulator NNC oraz moduł członu uodparniającego  $v(t)$  napisano jako S-funkcje w języku C. Algorytm uczenia (7.14) zrealizowano przy pomocy 4-poziomowego jednokrokowego otwartego schematu Rungego-Kutty. Charakteryzuje się on dobrą relacją kosztu obliczeniowego do otrzymywanej dokładności (Palczewski 1999), co jest istotne ze względu na znaczną ilość obliczeń, wykonywanych przez PD+NNC w każdym kroku sterowania. Układ przedstawiony na rys. 7.3 zawiera przykładowy schemat regulatora, umożliwiający sterowanie w czasie rzeczywistym serwomechanizmem SUP2 w środowisku MATLAB/Simulink/RT-CON. Struktura ta pozwala na rejestrację, między innymi, zmian wag sieci neuronowej w czasie. Na rys. 7.4 przedstawiono wewnętrzną budowę bloku NNC. Oprócz obliczania pochodnych błędów oraz trajektorii zadanej, zawiera on opcjonalny układ filtracji prędkości (owal A). Jak wykazały eksperymenty, układ z rozszerzoną siecią neuronową jest wrażliwy na zakłócenia sygnału prędkościowego, które mogą prowadzić do niestabilności. Możliwe jest włączanie i wyłączanie sygnału uodparniającego (owal C), jak również łatwa konfiguracja sieci neuronowej i algorytmu uczenia (owal B). Modyfikacje niewymagające rekompilacji s-funkcji to: włączanie lub wyłączanie części NN oraz ANN (rys. 7.2), uwzględnianie bądź nie poszczególnych składników algorytmu uczenia (7.14) oraz zmiana liczby neuronów sieci. Możliwe jest również wyłączenie członu e-mod lub zastąpienie go  $\sigma$ -mod (Narendra, Annaswamy 1987) oraz pominięcie propagacji „w przód”.



Rys. 7.3. Realizacja systemu sterowania z regulatorem PD+NNC w MATLAB/Simulink/RT-CON

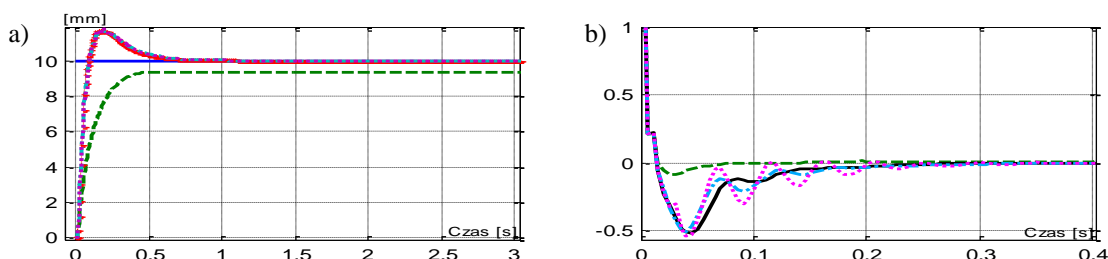


Rys. 7.4. Struktura wewnętrzna bloku NNC

### 7.3. Wyniki badań eksperymentalnych


Poniżej porównano odpowiedzi obiektu SUP2 dla różnych wymuszeń oraz konfiguracji regulatora PD+NNC. SUP2 jest jednowymiarowym układem mechatycznym, w którym nie występują złożone oddziaływania dynamiczne opisywane w punkcie 7.1. Jednakże, użyto go tutaj ze względu na niestacjonarne i zależne od położenia tarcie oraz możliwość wprowa-

dzenia do układu zakłócenia liniowego (rys. 2.1b). Za punkt odniesienia przyjęto system z regulatorem PD, ponieważ jest on stałym elementem badanej struktury. Na rys. 7.5 i rys. 7.6 przedstawiono odpowiedzi SUP2 z PD+NNC o różnej ilości neuronów w warstwie ukrytej oraz z pojedynczym neuronem w części rozszerzonej.



**Rys. 7.5.** Odpowiedzi skokowe SUP2: wykres położenia (a): wartość zadana (-), PD (- -), PD+NNC z 2 (· · ·), 5 (- · - ·), 10 (· · · ·) neuronami w warstwie ukrytej, wykres sterowania (b): PD (- -), PD+NNC z 2 (- · - ·), 5 (- · - · ·), 10 (· · · ·)

Odpowiedzi skokowe układu, mają kształt zbliżony do uzyskiwanych dla regulatora PID (rozdział 4.2). Charakteryzują się, więc około 20% przeregulowaniem, brakiem błędu ustalonego oraz cyklem granicznym powodowanym przez tarcie. Dzięki realizowanemu *on-line* procesowi uczenia, regulator posiada właściwości całkujące. Algorytm (7.14) dąży do całkowitego wyeliminowania błędu, jednakże występujące tu całkowanie ma silnie nieliniowy charakter. Powoduje to, w pewnych sytuacjach, małe ale niezerowe wartości błędu ustalonego. Efekt ten jest zgodny z dowodem stabilności przedstawionym w pracy Lewisa *et al.* (2002).



**Rys. 7.6.** Błędy śledzenia w układzie SUP2 dla wymuszenia liniowego (a) oraz wymuszenia sinusoidalnego (amplituda 10 mm, okres 12.5 s) (b). Oznaczenia: PD (- -), PD+NNC z 2 (- · - ·), 5 (- · - · ·), 10 (· · · ·) neuronami

W tab. 7.1 podano wartości kryteriów całkowych określających dokładność sterowania ( $I_1$ ) oraz jego koszt ( $I_2$ ) dla eksperymentów z obiektem SUP2.

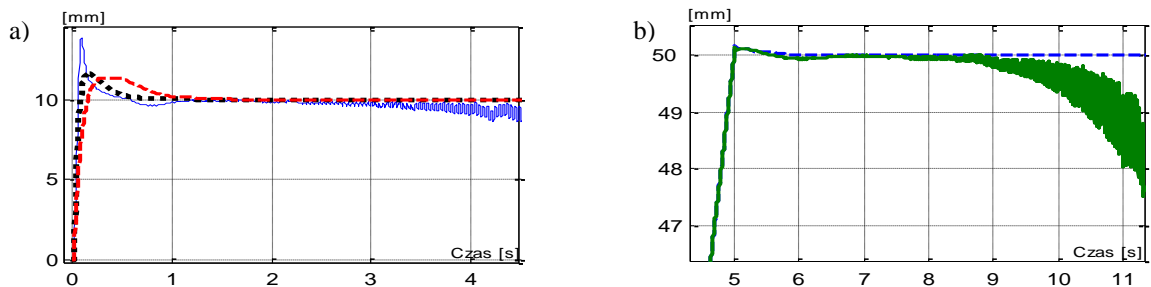
**Tab. 7.1.** Wartości wskaźników jakości dla eksperymentów z różną ilością neuronów w warstwie ukrytej NNC

Wskaźniki jakości $I_1 = \int_0^{t_1}  e  dt, I_2 = \int_0^{t_1}  u  dt$	PD	PD+NNC (2 neurony)	PD+NNC (5 neuronów)	PD+NNC (10 neuronów)
<b>Odpowiedź skokowa (<math>t_1=3</math> sek)</b>				
$I_1$	0.0030	0.00089	0.00096	0.00096
$I_2$	0.047	0.040	0.041	0.040
<b>Wymuszenie liniowe (<math>t_1=6</math> sek)</b>				
$I_1$	0.0031	0.00012	0.00010	0.000084
$I_2$	0.069	0.007	0.008	0.009
<b>Wymuszenie sinusoidalne (<math>t_1=20</math> sek)</b>				
$I_1$	0.0177	0.00045	0.00042	0.00040
$I_2$	0.394	0.051	0.058	0.084

Wyniki eksperymentów dowodzą, iż dla SUP2 należy stosować sieć z dwoma neuronami w warstwie ukrytej oraz jednym w rozszerzonej. Dla takiej konfiguracji realizowane były eksperymenty w dalszej części rozdziału. Większa ilość neuronów może powodować

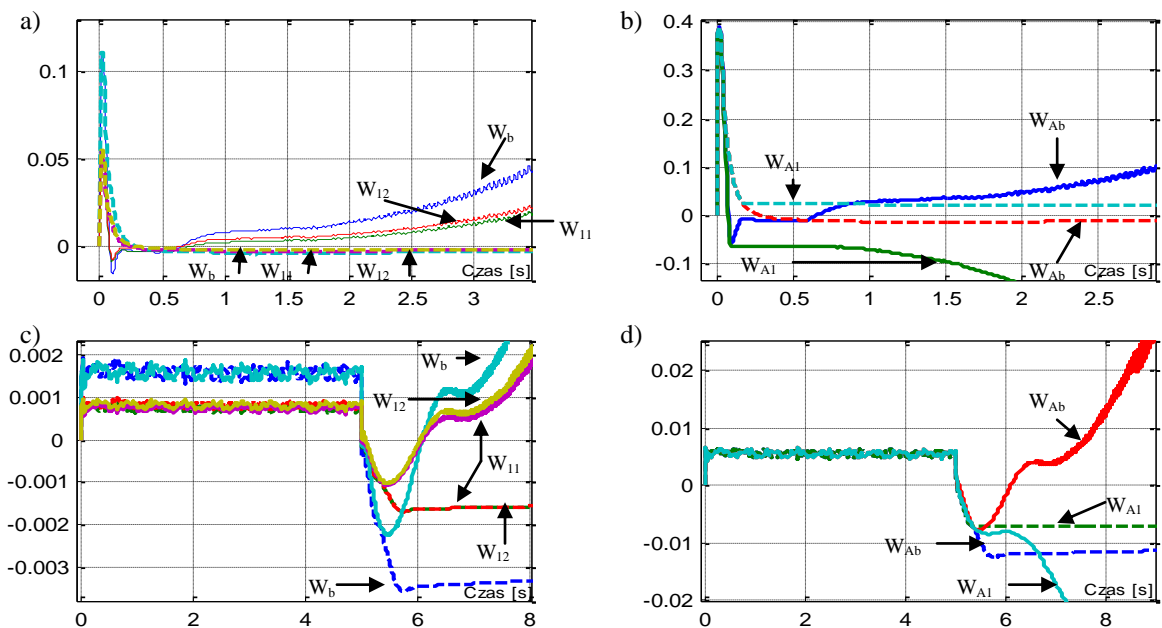
oscylacje dla odpowiedzi skokowej (rys. 7.5b). Dla zadania śledzenia, zwiększenie liczby neuronów zmniejsza błąd ustalony (Lewis *et al.* 2002) przy rosnących kosztach sterowania.

Człon ANN umożliwia aproksymację nieciągłej charakterystyki tarcia, ale równocześnie może być przyczyną niestabilności. Jak pokazano na rys. 7.7a, odpowiedź skokowa SUP2 z regulatorem PD+NNC (bez członu uodparniającego ale z siecią rozszerzoną) jest niestabilna, podczas gdy analogiczna struktura zawierająca jedynie sieć klasyczną (NN), działa poprawnie. Uodpornienie zapewnia stabilną pracę dla skokowych wartości zadanych, jednakże nie jest wystarczające np. dla trapezoidalnych trajektorii (rys. 7.7b). Ponieważ powodem niestabilności są zakłócenia pomiarów oraz wibracje występujące w systemie, najprostszą metodą ich eliminacji jest dodatkowa filtracja prędkości (rys. 7.4 – owal A). Inną metodą zapewniającą stabilność jest wyłączenie członu ANN dla fragmentów trajektorii o stałej wartości. Dla zastosowań praktycznych zaleca się stosowanie członu uodparniającego oraz dodatkową filtrację prędkości.



**Rys. 7.7.** Odpowiedź skokowa układu SUP2 (a): PD+NN (---), PD+NN+ANN bez członu uodparniającego (-), PD+NN+ANN z członem uodparniającym (.), odpowiedź na wymuszenie trapezoidalne (b): PD+NN+ANN z członem uodparniającym (-), PD+NN+ANN z członem uodparniającym oraz filtracją prędkości (---)


Zmiany wartości wybranych wag warstw wyjściowych NNC dla eksperymentów z rys. 7.7 pokazano na rys. 7.8. Ponieważ we wszystkich przypadkach, zmiany wag warstwy ukrytej różnią się nieznacznie nie zamieszczono ich na wykresach. Dla przebiegów stabilnych wagi zbiegają się do ustalonych wartości, zaś dla niestabilnych ich wartości bezwzględne rosną w czasie.



**Rys. 7.8.** Zmiany wag NNC dla odpowiedzi skokowej (a, b): PD+NN+ANN bez członu uodparniającego (-), PD+NN+ANN z członem uodparniającym (---) oraz dla wymuszenia liniowego (c, d): PD+NN+ANN z członem uodparniającym (-), PD+NN+ANN (---) z członem uodparniającym oraz z filtracją prędkości, oznaczenia wag są zgodne z rys. 7.2

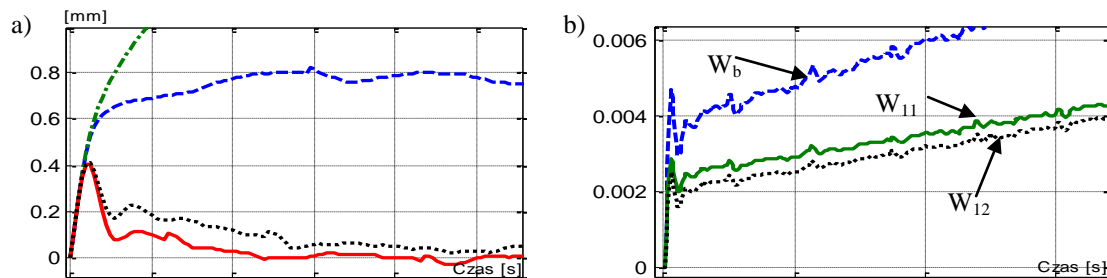


Wynikowe sterowanie PD+NNC tworzą sygnały z regulatora PD, sieci neuronowej oraz członu uodparniającego. Jak pokazano na rys. 7.9b, sygnał sterujący odpowiedzialny za kompensację tarcia jest generowany głównie przez sieć neuronową. Wyjście członu uodparniającego zgodnie z zależnością (7.13) jest proporcjonalne i przeciwne do wartości zmiennej ślizgu, a tym samym do sterowania uzyskiwanego z regulatora PD.



**Rys. 7.9.** Sterowania dla wymuszenia liniowego z PD+NNC i filtracją prędkości. Oznaczenia dla rys. a: wynikowy sygnał sterujący (-), sterowanie NNC (-), dla rys.b: sterowanie PD (-), sygnał uodparniający (..), wyjście sieci neuronowej bez sygnału uodparniającego (-)

W przypadku klasycznych adaptacyjnych algorytmów sterowania manipulatorów, zmiana charakteru oddziaływań dynamicznych wymaga modyfikacji prawa sterowania i adaptacji. Regulator PD+NNC o identycznej strukturze i parametrach zapewnia dobrą jakość śledzenia dla obiektu SUP2 z zestawem sprężyn oraz bez (rys. 7.10a). Eliminacja wprowadzanego przez sprężyny zakłócenia liniowego odbywa się poprzez wzrost wartości wag, co pokazano na rys. 7.10b. Gdy takie zakłócenie nie występuje, wagi stabilizują się wokół ustalonej wartości (rys. 7.8c). Regulator PD+NNC zapewnia dobre parametry śledzenia, mimo znacznej zmiany charakteru dynamiki układu.



**Rys. 7.10.** Błąd śledzenia wymuszenia liniowego w układzie SUP2 (a). Oznaczenia: eksperymenty bez zakłócenia liniowego: PD (-), PD+NNC (-) oraz z zakłóceniem liniowym: PD (-), PD+NNC (..). Rys. b przedstawia przebieg zmian wag warstwy wyjściowej PD+NNC w obecności zakłócenia liniowego (b)

W rozdziale przedstawiono koncepcję sterowania oraz praktyczną realizację adaptacyjnego regulatora neuralnego przeznaczonego do zadań śledzenia. Wykazano również jego podobieństwo do klasycznego algorytmu Slotine'a-Li. Zwrócono uwagę na potrzebę wzmoczonej filtracji prędkości w przypadku stosowania rozszerzonej sieci neuronowej. Eksperymentalnie wykazano odporność regulatora na strukturalne zmiany dynamiki obiektu oraz jego przydatność do realizacji zadań śledzenia w serwomechanizmach. Jakość działania PD+NNC sprawdzono praktycznie sterując w czasie rzeczywistym obiektem SUP2.

Ze względu na wykonywany w każdym kroku sterowania algorytm uczenia sieci neuronowej, układ z regulatorem PD+NNC wymaga znacznej mocy obliczeniowej. W rozdziale 9.2 zastosowano strukturę PD+NNC w zadaniu śledzenia trajektorii dla manipulatora ROB.