

O METODACH ŚLEPEGO PRZETWARZANIA SYGNAŁÓW DIAGNOSTYCZNYCH

Jacek DYBAŁA

Politechnika Warszawska, Wydział Samochodów i Maszyn Roboczych, Instytut Podstaw Budowy Maszyn
ul. Narbutta 84, 02-524 Warszawa, fax: 022-660-86-22, e-mail: jdybala@simr.pw.edu.pl

Streszczenie

W artykule przedstawiono metody ślepego przetwarzania sygnałów traktując je jako interesujące sposoby wyodrębniania sygnałów informacyjnych i eliminacji zakłóceń. Zaprezentowano różne modele propagacji i mieszania sygnałów oraz różne metody rekonstrukcji tych sygnałów przy pomocy odpowiednich sieci neuronowych. W końcowej części artykułu omówiono problemy związane z zastosowaniem tych metod w diagnostyce technicznej i przedstawiono pewne modyfikacje i rozszerzenia klasycznego ślepego przetwarzania sygnałów dostosowujące przedstawione podejście do specyfiki diagnozowania obiektów technicznych.

Słowa kluczowe: ślepe przetwarzanie sygnałów, ślepa separacja sygnałów, analiza składników niezależnych, sieci neuronowe.

ABOUT METHODS THE BLIND PROCESSING OF DIAGNOSTIC SIGNALS

Summary

The article presents methods of blind signal processing, which make possible the separation the informative signals and the elimination of disturbances. Different models of propagation and mixing of signals are presented and different methods of reconstruction of source signals with use of neural networks are showed. In last section of article, problems related with application of mentioned methods in technical diagnostics are discussed. Also some modifications and extensions of classical blind signal processing are showed, adapting presented approach to peculiarity of diagnosing of technical objects.

Keywords: Blind Signal Processing, Blind Source Separation, Independent Component Analysis, neural networks.

1. WSTĘP

Diagnostyka nieinwazyjna wykorzystuje jako nośnik informacji o stanie obiektu sygnały generowane podczas jego funkcjonowania. Rejestrowane sygnały diagnostyczna są zazwyczaj złożone z wielu generowanych przez obiekt sygnałów a forma tego „złożenia” może być różna. Sygnały, generowane „głęboko” w obiekcie, na swojej drodze do punktu pomiarowego napotykają na różne elementy tego obiektu, które zniekształcają postać tych sygnałów. Postać rejestrowanego sygnału zależy w dużej mierze od sposobu propagacji poszczególnych sygnałów od ich źródeł do punktu pomiarowego oraz od związanego z pomiarem zakłócenia i może być, w ogólnym przypadku, bardzo skomplikowana.

Rzeczywiste sposoby propagacji sygnałów w układach mechanicznych są często nieliniowe, gdzie o nieliniowości decydują własności reologiczne materiału, występowanie luzów i nieliniowość charakterystyk sprężystych elementów. Ograniczone możliwości analizy

nieliniowych sposobów propagacji skłaniają jednak do stosowania liniowych modeli lub wykorzystywania procedur linearyzacji. Rozpatrywanie układów jako liniowych ma sens z uwagi na to, że istnieje duża klasa obiektów mechanicznych, które, z dopuszczalną dla praktyki dokładnością, mogą być reprezentowane przez modele liniowe. Przyjmując liniowe modele propagacji sygnałów mamy do czynienia z sytuacją, w której rejestrowane sygnały są superpozycją sygnałów generowanych przez obiekt podczas jego funkcjonowania. Przyjęte założenia są bardzo upraszczające i mogą być kwestionowane przez zwolenników złożoności otaczającej nas rzeczywistości. Nie zmienia to w niczym faktu, że to właśnie proste modele liniowe okazują się często zdumiewająco przydatne w rozwiązywaniu różnych praktycznych zagadnień.

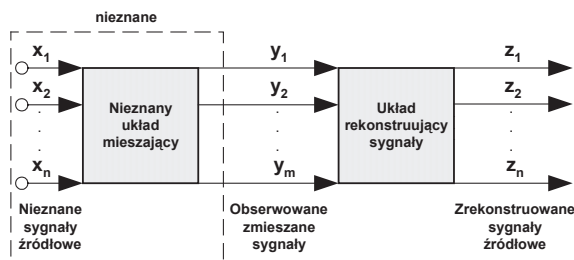
Zazwyczaj tylko niektóre z sygnałów składających się na zarejestrowany sygnał są tymi sygnałami, które chcemy analizować. Zakłócenia zarejestrowane wraz z sygnałem informacyjnym obciążają dalsze etapy procesu diagnostycznego

utrudniając postawienie poprawnej diagnozy. Wydobycie diagnostycznie użytecznej informacji z zarejestrowanego sygnału wymaga przeprowadzenia określonej separacji (rozdzielenia) sygnału informacyjnego (użytecznego) i sygnałów zakłócających.

Wśród różnych metod i technik eliminacji zakłóceń uwagę zwracają metody ślepego przetwarzania sygnałów (ang. Blind Signal Processing - BSP) realizujące separację nieznanego sygnału przy jednoczesnym braku informacji o sposobie ich zmieszania.

2. ŚLEPE PRZETWARZANIE SYGNAŁÓW

Zadanie ślepego przetwarzania sygnałów sformułowane jest następująco: mając do dyspozycji sygnały $Y(t)$ rejestrowane przez sensory zbierające informacje o obiekcie poddajemy je przetwarzaniu prowadzącemu do uzyskania sygnałów $Z(t)$ będących odtworzeniem (rekonstrukcją) źródłowych (pierwotnych) sygnałów $X(t)$ obserwowanego obiektu (rys. 1).



Rys. 1. Schemat ilustrujący ślepe przetwarzanie sygnałów

Pojęcie sygnału źródłowego można traktować szeroko (w sensie sygnału informacyjnego lub zakłócającego). Istotne jest założenie, że zarówno sygnały źródłowe jak i sposób ich zmieszania pozostają dla obserwatora nieznanymi. Ta niepełna informacja skłania do nazwania problemu „ślepy”.

Zgodnie z poprzednimi rozważaniami, przyjmijmy w uproszczeniu, że sygnały źródłowe są liniowo mieszane lub filtrowane. Konsekwencją przyjęcia pewnych założeń co do sposobu liniowego mieszania się sygnałów źródłowych jest stosowanie różnych modeli propagacji sygnałów i różnych metod separacji i wyodrębniania sygnałów źródłowych.

Ciekawą narzędziem realizacji układu rekonstruującego sygnały źródłowe wydają się być sieci neuronowe Heraulta – Juttena [9, 10]. Sieci Heraulta – Juttena są sieciami liniowymi, samouczącymi się (ang. unsupervised learning) o algorytmach uczenia opartych na uogólnionej regule Hebba. Samouczenie jest możliwe dzięki istnieniu redundancji w sygnałach sieci (obserwowane sygnały są superpozycjami sygnałów źródłowych). Sieci wykrywają powiązania korelacyjne między sygnałami i na tej podstawie

modyfikują swoje wagi. Struktura sieci neuronowych Heraulta – Juttena może mieć postać rekurencyjną lub jednokierunkową.

3. SEPARACJA ZMIESZANYCH SYGNAŁÓW

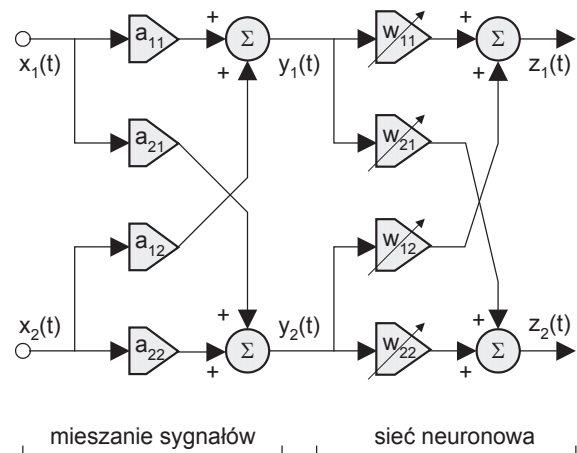
W najprostszym przypadku, obserwowane sygnały $Y(t)$ są liniową kombinacją nieznanymi, statystycznie niezależnych sygnałów $X(t)$ o zerowych wartościach średnich:

$$y_i(t) = \sum_{j=1}^n a_{ij} \cdot x_j(t) \quad (3.1)$$

gdzie: a_{ij} - współczynnik zmieszania uwzględniający udział wagowy sygnału $x_j(t)$ w sygnale wyjściowym $y_i(t)$ i-tego sensora. Innymi słowy, sygnały rejestrowane przez zespół sensorów są ważonymi sumami (liniowymi superpozycjami) pierwotnych sygnałów źródłowych.

Schemat (opisany układem równań 3.2) prostego przypadku mieszania sygnałów oraz sieci neuronowej realizującej rekonstrukcję sygnałów przedstawiono na rysunku 2.

$$\begin{cases} y_1(t) = a_{11} \cdot x_1(t) + a_{12} \cdot x_2(t) \\ y_2(t) = a_{22} \cdot x_2(t) + a_{21} \cdot x_1(t) \\ z_1(t) = w_{11} \cdot y_1(t) + w_{12} \cdot y_2(t) \\ z_2(t) = w_{22} \cdot y_2(t) + w_{21} \cdot y_1(t) \end{cases} \quad (3.2)$$



Rys. 2. Schemat mieszania sygnałów i sieci neuronowej rekonstruującej sygnały

Istnieją dwa równorzędne rozwiązania tak postawionego zadania separacji.

Przypadek I:

$$\text{jeśli } \begin{cases} \frac{w_{12}}{w_{11}} = -\frac{a_{12}}{a_{22}} & ; a_{22} \neq 0 \\ \frac{w_{21}}{w_{22}} = -\frac{a_{21}}{a_{11}} & ; a_{11} \neq 0 \end{cases} \quad (3.3)$$

wówczas

$$\begin{cases} z_1(t) = \frac{a_{11} \cdot a_{22} - a_{12} \cdot a_{21}}{a_{22}} \cdot w_{11} \cdot x_1(t) \\ z_2(t) = \frac{a_{11} \cdot a_{22} - a_{12} \cdot a_{21}}{a_{11}} \cdot w_{22} \cdot x_2(t) \end{cases} \quad (3.4)$$

Przypadek II:

$$\text{jeśli} \begin{cases} \frac{w_{12}}{w_{11}} = -\frac{a_{11}}{a_{21}} ; a_{21} \neq 0 \\ \frac{w_{21}}{w_{22}} = -\frac{a_{22}}{a_{12}} ; a_{12} \neq 0 \end{cases} \quad (3.5)$$

wówczas

$$\begin{cases} z_1(t) = \frac{a_{12} \cdot a_{21} - a_{11} \cdot a_{22}}{a_{21}} \cdot w_{11} \cdot x_2(t) \\ z_2(t) = \frac{a_{12} \cdot a_{21} - a_{11} \cdot a_{22}}{a_{12}} \cdot w_{22} \cdot x_1(t) \end{cases} \quad (3.6)$$

W obu przypadkach na wyjściach sieci pojawiają się sygnały proporcjonalne tylko do jednego z sygnałów źródłowych $\mathbf{X}(t)$. Istnieje jednak możliwość pojawienia się rozseparowanych sygnałów niekoniecznie w takiej kolejności w jakiej występowały sygnały źródłowe. Rozwiązaniem zadania separacji jest wobec tego uzyskanie oryginalnych sygnałów źródłowych ale przeskalowanych oraz mogących występować w innej kolejności niż sygnały źródłowe.

Problem uzyskania sygnałów $\mathbf{Z}(t)$ będących rekonstrukcją źródłowych sygnałów $\mathbf{X}(t)$ nazywany jest ślepą separacją sygnałów (ang. Blind Source Separation - BSS) i/lub analizą składników niezależnych (ang. Independent Component Analysis - ICA) [5].

Separacja sygnałów jest możliwa pod warunkiem odpowiedniego doboru wag sieci w_{ij} . Konieczne jest zatem określenie sposobu uzyskiwania właściwych wartości wag (zdefiniowanie algorytmu uczenia sieci neuronowej). Spośród kilku algorytmów uczenia wyróżnia się algorytm Cichockiego-Moszczyńskiego [11, 13], którego zapis w postaci macierzowej jest następujący:

$$\frac{d\mathbf{W}(t)}{dt} = \mu(t) \cdot [\mathbf{I} - \mathbf{f}[\mathbf{z}(t)] \cdot \mathbf{g}^T[\mathbf{z}(t)]] \cdot \mathbf{W}(t) \quad (3.7)$$


gdzie:

- $\mathbf{W}(t) = \begin{bmatrix} w_{11}(t) & w_{12}(t) \\ w_{21}(t) & w_{22}(t) \end{bmatrix}$ jest macierzą wag,
- $\mathbf{I} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ jest macierzą jednostkową,
- $\mathbf{f}(z)$ i $\mathbf{g}(z)$ to nieparzyste nieliniowe funkcje, przy czym jedna z nich jest typu wypukłego, a druga


typu wklęsłego [popularny wybór tych funkcji to: $\mathbf{f}(z) = z^3$, $\mathbf{g}(z) = \arctg(z)$],

- $\mathbf{z}(t) = \begin{bmatrix} z_1(t) \\ z_2(t) \end{bmatrix}$ jest wektorem sygnałów wyjściowych sieci,
- $\mu(t)$ oznacza współczynnik uczenia (ang. learning rate) sieci neuronowej [w najprostszym rozwiązaniu jest to funkcja wykładnicza czasu postaci: $\mu(t) = \alpha \cdot e^{-\beta t}$, o wartościach α i β dobieranych indywidualnie dla poszczególnych przypadków].

Przykłady separacji symulowanych sygnałów przedstawiono na rysunkach 3 i 4.



Rys. 3. Przykład separacji sygnałów (wraz ze zmianą współczynnika uczenia - lr)



Rys. 4. Przykład separacji sygnałów (wraz ze zmianą współczynnika uczenia - lr)

Przez pierwsze dwie sekundy sieć neuronowa jest nieaktywna (współczynnik uczenia jest równy zero). Możemy przez ten okres obserwować na wyjściach sieci sygnały z czujników, gdyż w tym czasie $z_1(t) = y_1(t)$ i $z_2(t) = y_2(t)$. Po upływie dwóch sekund startuje algorytm uczenia sieci neuronowej, następuje separacja sygnałów i na wyjściach sieci neuronowej pojawiają się zrekonstruowane sygnały źródłowe.

Symulacje komputerowe wykazały, że separacja jest w dużej mierze uniezależniona od stosunku

amplitud sygnałów źródłowych i od stopnia uwarunkowania macierzy reprezentującej układ [7, 8, 14]. Dodatkową cechą tego algorytmu jest samonormalizacja sygnałów wyjściowych $\mathbf{Z}(t)$, sprowadzająca je do amplitudy bliskiej jedności.

4. SEPARACJA SPLECIONYCH SYGNAŁÓW

Separacja splecionych sygnałów jest naturalnym rozszerzeniem lub generalizacją separacji zmieszanych sygnałów. Przyjmujemy, że obserwowane sygnały $\mathbf{Y}(t)$ są wynikiem zastosowania bardziej skomplikowanego modelu propagacji sygnałów $\mathbf{X}(t)$:

$$\begin{aligned} y_i(t) &= \sum_{j=1}^n \sum_{k=0}^{m_{ij}} a_{ij}^k \cdot x_j(t - d_{ij}^k) \\ &= \sum_{j=1}^n \mathbf{A}_{ij}(t) * x_j(t) \end{aligned} \quad (4.1)$$

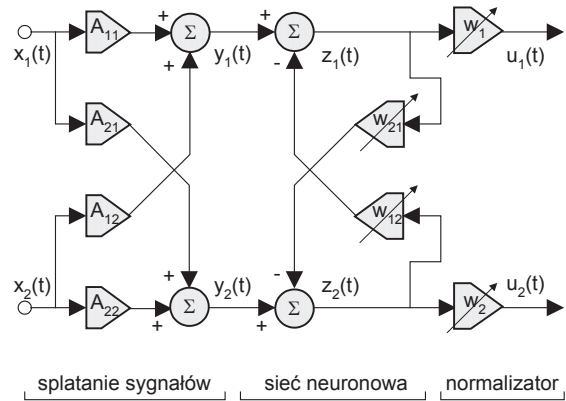
gdzie:

- m_{ij} - rząd filtru o skończonej odpowiedzi impulsowej SOI (ang. FIR – finite impulse response).
- a_{ij}^k - współczynnik zmieszania określający udział wagowy sygnału $x_j(t)$, docierającego do i -tego sensora z opóźnieniem d_{ij}^k , w sygnale wyjściowym $y_i(t)$ tego sensora (k -ty współczynnik filtru SOI),
- $\mathbf{A}_{ij}(t)$ - odpowiedź impulsowa filtru SOI znajdującego się między j -tym „źródłem” a i -tym sensorem,
- $*$ - operator oznaczający splot (symbol splatania lub mnożenia splotowego).

Zatem, w stosunku do poprzedniego modelu propagacji sygnałów $\mathbf{X}(t)$, dokonano uogólnienia współczynników zmieszania do filtrów SOI. Liczba dróg propagacji sygnału $x_j(t)$ do i -tego sensora jest równa $m_{ij}+1$ a każda droga charakteryzuje się innym opóźnieniem i tłumieniem sygnału. Taki model mieszania sygnałów, a raczej ich splatania jest już bardziej realistyczny w stosunku do poprzedniego gdyż uwzględnia opóźnienia w propagowaniu się sygnału poszczególnymi drogami propagacji wynikające choćby z wzajemnego usytuowania źródeł i sensorów.

Schemat (opisany układem równań 4.2) prostego przypadku splatania sygnałów oraz sieci neuronowej realizującej rekonstrukcję sygnałów przedstawiono na rysunku 5.

$$\begin{cases} y_1(t) = \mathbf{A}_{11}(t) * x_1(t) + \mathbf{A}_{12}(t) * x_2(t) \\ y_2(t) = \mathbf{A}_{22}(t) * x_2(t) + \mathbf{A}_{21}(t) * x_1(t) \\ z_1(t) = y_1(t) - \mathbf{W}_{12}(t) * z_2(t) \\ z_2(t) = y_2(t) - \mathbf{W}_{21}(t) * z_1(t) \\ u_1(t) = w_1(t) \cdot z_1(t) \\ u_2(t) = w_2(t) \cdot z_2(t) \end{cases} \quad (4.2)$$



Rys. 5. Schemat splatania sygnałów i sieci neuronowej rekonstruującej sygnały

Korzystając z przekształcenia Laplace'a, za pomocą którego można wygodnie opisywać i badać takie układy liniowe (splot oryginałów jest iloczynem ich transformat), otrzymujemy:

$$\begin{cases} Z_1(s) = \mathbf{A}_{11}(s) \cdot X_1(s) + \mathbf{A}_{12}(s) \cdot X_2(s) \\ \quad - \mathbf{W}_{12}(s) \cdot Z_2(s) \\ Z_2(s) = \mathbf{A}_{22}(s) \cdot X_2(s) + \mathbf{A}_{21}(s) \cdot X_1(s) \\ \quad - \mathbf{W}_{21}(s) \cdot Z_1(s) \end{cases} \quad (4.3)$$

Istnieją dwa równorzędne rozwiązania tak postawionemu zadaniu separacji.

Przypadek I:

$$\text{jeśli} \begin{cases} \mathbf{W}_{12}(s) = \frac{\mathbf{A}_{12}(s)}{\mathbf{A}_{22}(s)} ; \mathbf{A}_{22}(s) \neq 0 \\ \mathbf{W}_{21}(s) = \frac{\mathbf{A}_{21}(s)}{\mathbf{A}_{11}(s)} ; \mathbf{A}_{11}(s) \neq 0 \end{cases} \quad (4.4)$$

wówczas

$$\begin{cases} Z_1(s) = \mathbf{A}_{11}(s) \cdot X_1(s) \\ Z_2(s) = \mathbf{A}_{22}(s) \cdot X_2(s) \end{cases} \quad (4.5)$$

Wykonując odwrotne przekształcenie Laplace'a uzyskujemy:

$$\begin{cases} z_1(t) = \mathbf{A}_{11}(t) * x_1(t) \\ z_2(t) = \mathbf{A}_{22}(t) * x_2(t) \end{cases} \quad (4.6)$$

Przypadek II:

$$\text{jeśli } \begin{cases} \mathbf{W}_{12}(s) = \frac{\mathbf{A}_{11}(s)}{\mathbf{A}_{21}(s)} ; \mathbf{A}_{21}(s) \neq 0 \\ \mathbf{W}_{21}(s) = \frac{\mathbf{A}_{22}(s)}{\mathbf{A}_{12}(s)} ; \mathbf{A}_{12}(s) \neq 0 \end{cases} \quad (4.7)$$

wówczas

$$\begin{cases} Z_1(s) = \mathbf{A}_{12}(s) \cdot X_2(s) \\ Z_2(s) = \mathbf{A}_{21}(s) \cdot X_1(s) \end{cases} \quad (4.8)$$

Wykonując odwrotne przekształcenie Laplace'a uzyskujemy:

$$\begin{cases} z_1(t) = \mathbf{A}_{12}(t) * x_2(t) \\ z_2(t) = \mathbf{A}_{21}(t) * x_1(t) \end{cases} \quad (4.9)$$

Stabilność przedstawionej rekurencyjnej sieci neuronowej określa równanie charakterystyczne:

$$1 - \mathbf{W}_{12}(s) \cdot \mathbf{W}_{21}(s) = 0 \quad (4.10)$$

Zwróćmy jednak uwagę, że w obu przypadkach nie jesteśmy w stanie wyeliminować ze zrekonstruowanych sygnałów źródłowych wpływu poszczególnych filtrów SOI zniekształcających postać oryginalnych sygnałów źródłowych (wzór 4.6 i 4.9). Rozważmy zatem sytuację, w której czujniki umieszczone są blisko poszczególnych źródeł sygnałów (w praktyce pomiarowej jest to często spotykany przypadek - zaleca się bowiem umieszczać czujniki możliwie blisko domniemanych lub zidentyfikowanych źródeł sygnałów [3, 6]). Możemy wówczas założyć, że sygnały źródłowe docierają do właściwych im czujników „bezpośrednio” (jedna droga propagacji, brak opóźnień i zmian poziomu sygnału), godząc się w ten sposób z tym, że już nie możemy „głębiej” sięgnąć do źródeł sygnału :

$$\mathbf{A}_{11}(s) = 1 ; \mathbf{A}_{22}(s) = 1 \quad (4.11)$$

W takiej sytuacji akceptowalne fizycznie pozostaje jedynie rozwiązanie pierwsze [8].

Warto zauważyć, że w tym rozwiązaniu rozseparowane sygnały pojawiają się na wyjściach sieci neuronowej w takiej kolejności w jakiej występowały sygnały źródłowe:

$$\begin{cases} z_1(t) = x_1(t) \\ z_2(t) = x_2(t) \end{cases} \quad (4.12)$$

Będzie to jednak możliwe tylko pod warunkiem spełnienia zależności:

$$\begin{cases} \mathbf{W}_{12}(t) = \mathbf{A}_{12}(t) \\ \mathbf{W}_{21}(t) = \mathbf{A}_{21}(t) \end{cases} \quad (4.13)$$

co oznacza konieczność skompensowania przez sieć neuronową wszystkich dróg propagacji sygnałów

zakłócających (zrównoważenia wpływu sygnałów zakłócających działaniem wag i opóźnień sieci).

Odseparowanie tak splecionych sygnałów jest zadaniem znacznie trudniejszym i bardziej złożonym niż odseparowanie zmieszanych sygnałów. Trzeba bowiem określić zarówno sposób doboru wartości wag jak i opóźnień sieci. Problem uzyskania sygnałów $\mathbf{Z}(t)$ będących rekonstrukcją źródłowych sygnałów $\mathbf{X}(t)$ nazywany jest w tym wypadku wielokanałowa ślepą dekonwolucją (rozplataniem) (ang. Multichannel Blind Deconvolution - MBD) [5].

Problem opóźnień często rozwiązywany jest przy pomocy zespołu (banku) opóźnień [12, 15, 16]. Zespół ten (często bardzo liczny, dochodzący nawet do 1500 elementów [2]) pokrywa cały zakres spodziewanego wystąpienia opóźnień a algorytm doboru wag sieci ma za zadanie wybranie z wszystkich dostępnych opóźnień tylko tych, które są naprawdę potrzebne, odrzucając (zerując ich wagi) pozostałe. Istnieje także możliwość adaptacyjnego doboru opóźnień [8, 15, 17].

Wartości wag sieci neuronowej dobierane są wyłącznie w oparciu o algorytm uczenia sieci neuronowej.

Algorytm doboru wartości wag (algorytm uczenia sieci neuronowej) może być oparty na następującym poglądzie: jeśli dany sygnał źródłowy $x_i(t)$ jest zakłócony przez nieskorelowany z nim inny sygnał źródłowy $x_j(t)$, to obserwowany sygnał $y_i(t)$, będący ich liniową superpozycją, ma wyższą energię niż sygnał $z_i(t)$, będący rekonstrukcją źródłowego sygnału $x_i(t)$, ponieważ energie sygnałów $x_i(t)$ i $x_j(t)$ dodają się do siebie [15]. Problem nauki sieci neuronowej sprowadza się zatem w tym wypadku do zagadnienia minimalizacji energii sygnałów wyjściowych sieci (ang. minimum output power).

Jedną z najprostszych metod minimalizacji jest gradientowa metoda największego spadku, poszukująca kolejnego lepszego punktu w kierunku przeciwnym do gradientu funkcji celu w danym punkcie. Algorytm doboru wag sieci neuronowej wygląda wówczas następująco:

$$\frac{dw_{ij}^k}{dt} = \mu_{w_{ij}^k}^k \cdot z_i(t) \cdot z_j(t - D_{ij}^k) \quad (4.14)$$

gdzie: w_{ij}^k -waga sieci kompensująca współczynnik zmieszania a_{ij}^k , $\mu_{w_{ij}^k}^k$ -współczynnik uczenia wagi w_{ij}^k , D_{ij}^k -opóźnienie sieci (skojarzone z wagą w_{ij}^k) kompensujące opóźnienie d_{ij}^k (skojarzone ze współczynnikiem zmieszania a_{ij}^k).

Istotny wpływ na szybkość i jakość pracy sieci neuronowej ma współczynnik uczenia μ , który określa jak intensywne jest nauczanie. Wybranie zbyt małego współczynnika prowadzi do bardzo powolnego procesu uczenia. Z kolei wybór zbyt

dużego współczynnika uczenia powoduje bardzo gwałtowne zmiany wag sieci, co prowadzi może do braku zbieżności procesu uczenia (wartości wag oscylują wokół poszukiwanego rozwiązania). Najefektywniejszy, choć zarazem najbardziej złożony sposób doboru współczynnika uczenia polega na jego adaptacyjnym doborze opartym o postępy procesu nauki. Przykład takiego rozwiązania przedstawiono w pracy [8].

Ponieważ przedstawiony algorytm nie dokonuje normalizacji sygnałów, sieć neuronową można wzbogacić o normalizator, którego zadaniem będzie normalizacja sygnałów wyjściowych $Z(t)$, sprowadzająca je do amplitudy bliskiej jedności. Algorytm normalizacji może mieć następującą postać:

$$\frac{d w_i(t)}{d t} = \mu_N \cdot [1 - \beta \cdot \text{sgn}(u_i(t)) \cdot \arctg(u_i(t))] \cdot w_i(t) \quad (4.15)$$


gdzie: w_i -waga normalizatora, β -współczynnik skalujący (wartość typowa $\beta=1,85$), μ_N -współczynnik uczenia normalizatora (wartość typowa $\mu_N=3$).

Znormalizowane sygnały wyjściowe można wykorzystać w algorytmach uczenia dzięki czemu prędkość uczenia sieci może być w mniejszym stopniu zależna od poziomów i rodzajów separowanych sygnałów. Uwzględniając obecność normalizatora, algorytm doboru wag sieci neuronowej możemy zapisać w postaci:

$$\frac{d w_{ij}^k}{d t} = \mu_{wij}^k \cdot z_i(t) \cdot u_j(t - D_{ij}^k) \quad (4.16)$$

Normalizacja sygnałów wyjściowych $Z(t)$ odbywa się poza siecią neuronową. Istnieje zatem możliwość korzystania z nieznormalizowanych sygnałów źródłowych.

Powyższe rozważania można oczywiście uogólnić na większą liczbę wejść sieci neuronowej (większą liczbę sensorów). Przykład rekonstrukcji sygnałów źródłowych przez sieć neuronową pracującą z trzema sensorami przedstawiono na rysunku 6.



Rys. 6. Przykład separacji sygnałów pochodzących z trzech sensorów

5. PODSUMOWANIE I WNIOSKI

Przeprowadzone symulacje komputerowe pokazują, że przedstawione sieci neuronowe mogą być ciekawym narzędziem do separacji zakłóceń i identyfikacji źródeł sygnałów. Ślepe przetwarzanie sygnałów spotyka się z coraz szerszym zainteresowaniem i znajduje zastosowanie w takich dziedzinach jak analiza i przetwarzanie sygnałów biomedycznych (EEG, MEG, EKG), przetwarzanie sygnałów geofizycznych, wyodrębnianie sygnału mowy (problem „cocktail party”), rozpoznawanie obrazów i komunikacja bezprzewodowa [5].

Interesująco wyglądają możliwości zastosowania tych sieci neuronowych w zadaniu detekcji uszkodzeniowo-zorientowanej informacji diagnostycznej z niestacjonarnych i zaburzonych sygnałów wibroakustycznych. Pojawia się perspektywa zastosowania takich sieci neuronowych w torze pomiarowym systemu diagnostycznego jako narzędzia eliminacji zakłóceń z rejestrowanych sygnałów. Pełne skorzystanie z dobrodziejstw ślepej separacji sygnałów wibroakustycznych wymaga jednak pewnych modyfikacji i rozszerzeń dostosowujących te metody do specyfiki tego zagadnienia.

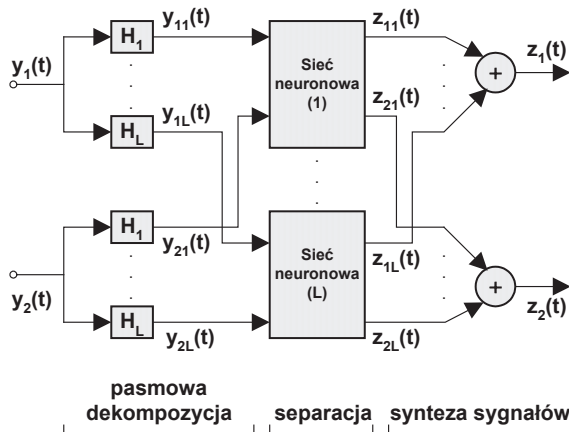
Sieci neuronowe Heraulta – Juttena, należące do klasy korelacyjnych sieci neuronowych, nie są zdolne odtworzyć statystycznie zależnych sygnałów źródłowych gdyż właśnie brak powiązań korelacyjnych między sygnałami wyjściowymi sieci neuronowej jest przyczyną zakończenia samouczenia i uznania przez sieć, że proces separacji został zakończony sukcesem. Tymczasem w diagnostyce wibroakustycznej obiektów technicznych zależność sygnałów źródłowych to dosyć często występujące zjawisko.

Pewnym rozwiązaniem tego problemu może być odwołanie się do rozszerzonych metod ślepego przetwarzania sygnałów wykorzystujących pasmową dekompozycję (ang. Subband Decomposition) obserwowanych sygnałów $Y(t)$ [4].

Kluczową ideą jest w tym wypadku założenie, że choć nieznane, szerokopasmowe sygnały źródłowe są statystycznie zależne, to pewne ich wąskopasmowe komponenty są statystycznie niezależne. Przyjmuje się zatem, że każdy nieznany sygnał źródłowy może być reprezentowany przez liniową kombinację wąskopasmowych sygnałów składowych:

$$x_i(t) = x_{i1}(t) + x_{i2}(t) + \dots + x_{iL}(t) \quad (4.17)$$

Pasmowa dekompozycja zakłada podział każdego obserwowanego sygnału $y(t)$ na wąskopasmowe składowe (identyczne pasma dla każdego obserwowanego sygnału) i dokonywanie ślepego przetwarzania sygnałów w poszczególnych pasmach. Podział obserwowanych sygnałów $Y(t)$ na wąskopasmowe składowe może odbywać się przy pomocy zespołu (banku) filtrów pasmowych. Po wykonaniu separacji w poszczególnych pasmach częstotliwości dokonywana jest synteza zrekonstruowanych sygnałów źródłowych $Z(t)$, w trakcie której należy uwzględnić normalizację i różną kolejność pojawiania się sygnałów wyjściowych poszczególnych „pasmowych” sieci neuronowych. Schemat ilustrujący pasmowo dekomponowane ślepe przetwarzanie sygnałów przedstawiono na rysunku 7.




Rys. 7. Schemat ilustrujący pasmowo dekomponowane ślepe przetwarzanie sygnałów

Pewną niedogodnością klasycznego ślepego przetwarzania sygnałów jest wymóg posługiwania się taką liczbą sensorów, która odpowiada liczbie sygnałów źródłowych. Liczba źródeł sygnałów jest jednak w ogólnym przypadku nieznana a ponadto liczba ta może zmieniać się w czasie. Zatem w ogólności, liczba sensorów może być większa, równa lub mniejsza niż liczba źródeł. Jeśli liczba sensorów jest mniejsza niż liczba źródeł, nie można zrekonstruować wszystkich sygnałów źródłowych.

W diagnostyce technicznej bardzo często mamy jednak do czynienia z sytuacją, że tylko niewielka liczba sygnałów źródłowych niesie interesującą nas informację diagnostyczną i tylko te nieliczne

sygnały źródłowe są przedmiotami naszego zainteresowania. Pozostałe sygnały źródłowe są w tym wypadku traktowane jako zakłócenia i nie interesuje nas ich wyodrębnienie i poznanie a jesteśmy zainteresowani jedynie ich oddzieleniem od informacyjnych sygnałów źródłowych. W takim przypadku wystarczające jest takie przetwarzanie sygnałów, które wyodrębni tylko niektóre sygnały źródłowe, potencjalnie interesujące i zawierające użyteczną informację diagnostyczną.

Taką metodą przetwarzania sygnałów jest ślepa ekstrakcja sygnału (ang. Blind Signal Extraction - BSE), która, w odróżnieniu od ślepej separacji sygnałów, analizy składników niezależnych i wielokanałowej ślepej dekonwolucji dokonujących równoczesnej separacji wszystkich sygnałów źródłowych, dokonuje odtworzenia jedynie jednego, wybranego sygnału źródłowego [5].



Rys. 8. Schemat ilustrujący ślepa ekstrakcję sygnału

Możliwe jest użycie metody ślepej ekstrakcji sygnału do sekwencyjnego wyodrębniania poszczególnych sygnałów źródłowych.

Równie interesująco, w kontekście powyższych rozważań, wygląda metoda zwana ślepa filtracją (ang. Blind Equalization - BE), która odgrywa ważną rolę w dziedzinie cyfrowej komunikacji i dzięki dobrym wynikom separacji sygnałów zdobywa rosnące uznanie [1, 18]. W odróżnieniu od konwencjonalnego adaptacyjnego filtrowania, metoda ta, podobnie jak uprzednio przedstawione metody, jest „ślepa”, czyli odbywa się bez wiedzy o sygnałach źródłowych i sposobie ich zmieszania. Wydobycie sygnału źródłowego jest możliwe dzięki zastosowaniu „ślepego” filtra o odpowiednio dobranych parametrach.

Badania nad zastosowaniem sieci neuronowych do separacji sygnałów wibroakustycznych są nadal na etapie podstawowym i wiele problemów, dotyczących przede wszystkim zbieżności algorytmów i ich skuteczności przy większej liczbie złożonych sygnałów, pozostaje do rozwiązania. Można mieć jednak nadzieję, że przedstawione wyniki i propozycje modyfikacji staną się inspiracją do dalszych prac naukowych w tej dziedzinie.

Stosowane sieci neuronowe wykonano w środowisku programowania MATLAB z wykorzystaniem pakietu SIMULINK.

Praca naukowa finansowana ze środków Komitetu Badań Naukowych w latach 2004 - 2006 jako projekt badawczy nr 4 T07B 013 26.

6. LITERATURA

- [1] Afkhamie K. H., Luo. Z.-Q.: Blind equalization using second-order statistics. In Proc. IEEE ICASSP, pages 1053–1056 Vol. 2, 1053–1056, Detroit, 1995.
- [2] Boll S. F., Pulsipher D. C.: Suppression of Acoustic Noise in Speech Using Two Microphone Acoustic Noise Cancellation. IEEE Trans. on ASSP, Vol. 28, No. 6, 752 – 753, 1980.
- [3] Cempel C.: Podstawy wibroakustycznej diagnostyki maszyn. Wydawnictwa Naukowo - Techniczne, Warszawa, 1982.
- [4] Choi S., Cichocki A., Park H.-M., Lee S.-Y.: Blind source separation and independent component analysis: A review. Neural Information Processing - Letters and Reviews, Vol. 6, No.1, 1–57, 2005.
- [5] Cichocki A., Amari. S.: Adaptive Blind Signal And Image Processing. John Wiley, New York, 2003.
- [6] Dąbrowski Z., Klekot G., Radkowski S.: Przyczyny nadmiernej wibroakustycznej aktywności przekładni zębatach. Zbiór referatów I Konferencji Naukowo-Technicznej Konstrukcja i technologia przekładni zębatach. Przekładnie stożkowe, Warszawa, 35 – 49, 1992.
- [7] Dybała J.: Signal Disturbance Separation with Use of Neural Networks. Machine Dynamics Problems, Wydawnictwo MeT, Warszawa, Vol. 19, 61-74, 1998.
- [8] Dybała J.: Wykrywanie uszkodzeń w przekładni zębatej na podstawie analizy sygnału wibroakustycznego z wykorzystaniem modeli symulacyjnych. Rozprawa doktorska, Politechnika Warszawska, Warszawa, 1999
- [9] Herault J., Jutten C.: Space or Time Adaptive Signal Processing by Neural Network Models. Neural Networks for Computing, AIP Conference Proceedings 151, Snowbird, Utah, 206 – 211, 1986.
- [10] Jutten C., Herault J.: Blind separation of sources. Signal Processing, vol. 24, 1-10, 1991.
- [11] Moszczyński L.: Układy adaptacyjne w zastosowaniu do separacji sygnałów elektrycznych. Praca doktorska, Politechnika Warszawska, Warszawa, 1996
- [12] Nguyen Thi H. L., Jutten C., Caelen J.: Speech enhancement: analysis and comparison of methods on various real situations. In Proc. EUSIPCO'92, 1992.
- [13] Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. Wydawnictwa Naukowo-Techniczne, Warszawa, 1996.
- [14] Osowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2000.
- [15] Platt J. C., Faggin F.: Networks for the separation of sources that are superimposed and delayed. Advances in Neural Information Processing Systems 4, Morgan - Kaufmann, 1992.
- [16] Torkkola K.: Blind separation of convolved sources based on information maximisation. Proc. IEEE Workshop on Neural Networks and Signal Processing, Kyoto (Japan), 1996.
- [17] Torkkola K.: Blind separation of delayed sources based on information maximization. Proc. IEEE ICASSP, Atlanta, 1996.
- [18] Zhang J., Tse P.: Detection of Incipient Impulsive Fault by Blind Equalization. Proceedings of IMS2003, 25 – 27, Xi'an (China), 2003.



dr inż. Jacek DYBAŁA - absolwent Wydziału Samochodów i Maszyn Roboczych Politechniki Warszawskiej oraz Instytutu Organizacji Systemów Produkcyjnych Politechniki Warszawskiej. Adiunkt w Instytucie Podstaw Budowy Maszyn Politechniki

Warszawskiej. Zajmuje się problematyką związaną z diagnostyką techniczną, wibroakustyką maszyn, przetwarzaniem i analizą sygnałów, rozpoznawaniem obrazów oraz sztucznymi sieciami neuronowymi. Członek Polskiego Towarzystwa Diagnostyki Technicznej.