

Załącznik nr 2 do Wniosku o przeprowadzenie postępowania habilitacyjnego

Dr inż. Piotr Szymczyk

Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie,
Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej
Katedra Automatyki i Inżynierii Biomedycznej

Al. Mickiewicza 30, 30-059 Kraków

Autoreferat

Spis treści

1. Stopnie naukowe	4
2. Przebieg zatrudnienia w jednostkach naukowych.....	4
3. Wskazanie osiągnięcia wynikającego z art. 16 ust. 2 ustawy z dnia 14 marca 2003 r. o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki	5
3.1. Tytuł osiągnięcia naukowego.....	5
3.2. Publikacje i inne prace wchodzące w skład osiągnięcia naukowego.....	5
3.3. Omówienie celu naukowego prac i osiągniętych wyników wraz z omówieniem ich wykorzystania	6
3.3.1. Cel naukowy.....	6
3.3.2. Osiągnięte wyniki.....	6
3.3.2.1. Wprowadzenie.....	6
3.3.2.2. Klasyczne sieci neuronowe z preprocesingiem danych wejściowych do postaci współczynników wielomianów aproksymujących sygnał.....	6
3.3.2.3. Sieci neuronowe z przekształceniem Laplace'a	7
3.3.2.4. Sieci neuronowe z przekształceniem Z	13
3.3.3. Omówienie wykorzystania wyników prac	18
3.3.3.1. Przykład zastosowań klasycznych sieci neuronowych z preprocesingiem danych wejściowych do postaci współczynników wielomianów aproksymujących sygnał.....	18
3.3.3.2. Przykład zastosowań sieci neuronowych z przekształceniem Laplace'a	26
3.3.3.3. Przykład zastosowań sieci neuronowych z przekształceniem Z	34
4. Pozostałe osiągnięcia naukowo – badawcze	37
4.1. Statystyki bibliometryczne.....	37
4.2. Kierowanie krajowymi projektami badawczymi lub udział w takich projektach.....	37
4.3. Referaty i postery na konferencjach tematycznych	37
4.4. Nagrody za działalność naukową.....	38
4.5. Udział w komitetach organizacyjnych konferencji naukowych.....	38
4.6. Członkostwo w organizacjach i towarzystwach naukowych	39
4.7. Osiągnięcia dydaktyczne w zakresie popularyzacji nauki	39
4.8. Udział w zespołach eksperckich i konkursowych.....	39
4.9. Recenzowanie projektów międzynarodowych lub krajowych oraz publikacji w czasopiśmie międzynarodowych i krajowych	39
4.10. Opieka nad kołem naukowym	40
4.11. Prace dyplomowe	40
4.11.1. Prace magisterskie	40

4.11.2. Prace inżynierskie	41
4.12. Prowadzone przedmioty.....	41
4.13. Pozostała działalność dydaktyczna	42
4.14. Działalność organizacyjna po uzyskaniu stopnia doktora.....	42
4.15. Inne osiągnięcia	42

1. Stopnie naukowe

Institucja, rok	Uzyskane stopnie
Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie; Wydział Elektrotechniki, Automatyki i Elektroniki; 1997	dr inż. nauk technicznych, specjalność informatyka
Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie; Wydział Elektrotechniki, Automatyki i Elektroniki; 1988	mgr inż. elektroniki specjalność automatyka

2. Przebieg zatrudnienia w jednostkach naukowych

Data	Institucja	Stanowisko	Opis zakresu zadań
od 01.10.1997	Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie; Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej; Katedra Automatyki i Inżynierii Biomedycznej	Adiunkt	Badania i dydaktyka w obszarze automatyki i informatyki
2005 - 2008	Wyższa Szkoła Bankowości i Finansów w Bielsku-Białej; Wydział Bankowości i Finansów; Katedra Informatyki i Metod Ilościowych	Kierownik Katedry	Kierowanie Katedrą
2004 - 2009	Wyższa Szkoła Bankowości i Finansów w Bielsku-Białej	Adiunkt	Badania i dydaktyka w obszarze informatyki
2000	Wyższa Szkoła Biznesu i Przedsiębiorczości w Ostrowcu Świętokrzyskim; Wydział Informatyki	Adiunkt	Badania i dydaktyka w obszarze informatyki
od 01.10.1995 do 30.09.1997	Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie; Wydział Elektrotechniki, Automatyki i Elektroniki; Katedra Automatyki	Asystent	Badania i dydaktyka w obszarze automatyki i informatyki
od 01.10.1991 do 30.09.1995	Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie; Wydział Elektrotechniki, Automatyki, i Elektroniki	Studia doktoranckie (urlop bezpłatny, stypendium)	Badania w obszarze informatyki
od 05.01.1988 do 30.09.1991	Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie; Wydział Elektrotechniki, Automatyki, i Elektroniki; Katedra Automatyki	Stanowisko techniczne	Konserwacja sprzętu komputerowego, nadzór nad sprzętem w trakcie zajęć dydaktycznych, udział w opracowaniu nowych stanowisk laboratoryjnych

3. Wskazanie osiągnięcia wynikającego z art. 16 ust. 2 ustawy z dnia 14 marca 2003 r. o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki

3.1. Tytuł osiągnięcia naukowego

Badanie możliwości i własności sieci neuronowych

3.2. Publikacje i inne prace wchodzące w skład osiągnięcia naukowego

Szymczyk P.: Z-Transform artificial neural network applied for identification of dynamic object in digital control system, Bulletin of the Polish Academy of Sciences Technical Sciences; ISSN 0239-7528 — w druku (LF) (IF 1.000) (Pkt. MNiSW = 25)

Szymczyk P., Tomecka-Suchoń S., Szymczyk M.: Neural networks as a tool for georadar data processing, International Journal of Applied Mathematics and Computer Science, ISSN: 1641-876X, 2015 vol. 25, no. 4, s. 955–960 (LF) (IF 1.390) (Pkt. MNiSW = 25)

Szymczyk P.: Z-transform artificial neural networks, Neurocomputing ; ISSN 0925-2312. — 2015 vol. 168, s. 1207–1210 (LF) (IF 2.005) (Pkt. MNiSW = 30)

Szymczyk P., Szymczyk M.: Supervised learning Laplace transform artificial neural networks and using it for automatic classification of geological structure, Neurocomputing ; ISSN 0925-2312. — 2015 vol. 154, s. 70-76. (LF) (IF 2.005) (Pkt. MNiSW = 30)

Szymczyk P., Szymczyk M.: Classification of geological structure using ground penetrating radar and Laplace transform artificial neural networks, Neurocomputing ; ISSN 0925-2312. — 2015 vol. 148, s. 354-362. (LF) (IF 2.005) (Pkt. MNiSW = 30)

Szymczyk P., Marczak H., Tomecka-Suchoń S., Szymczyk M., Gajer M., Gołębiowski T.: Komputerowe przetwarzanie i analiza danych georadarowych, Wydawnictwo Naukowe IAE, Kraków 2015, ISBN 978-83-65003-00-3 (Pkt. MNiSW = 24)

3.3. Omówienie celu naukowego prac i osiągniętych wyników wraz z omówieniem ich wykorzystania

3.3.1. Cel naukowy

Celem naukowym prowadzonych prac było badanie możliwości i własności sieci neuronowych. W tym celu opracowano nowe rodzaje sztucznych sieci neuronowych a mianowicie sieci z wagami w postaci współczynników wielomianów aproksymujących sygnał oraz sieci z przekształceniami całkowitymi ciągłymi i dyskretnymi. W celu sprawdzenia możliwości tych nowych rodzajów sieci neuronowych użyto je między innymi do analizy, przetwarzania i interpretacji sygnałów.

3.3.2. Osiągnięte wyniki

3.3.2.1. Wprowadzenie

Sieci neuronowe jako jeden z istotnych obszarów badań biocybernetyki cały czas są przedmiotem badań i rozwoju ze względu na fakt, że są bardzo efektywnym narzędziem uczącym się. Od lat 40-tych XX wieku można datować początek prac nad sieciami neuronowymi jako próby opisu matematycznego komórek nerwowych. Przez szereg lat wiedza na ten temat bardzo poszerzyła się i ugruntowała, będąc w chwili obecnej bardzo obszerną dziedziną nauki, posiadającą gruntowne podstawy teoretyczne i znaczące zastosowania. Istnieje wiele różnych rodzajów sieci neuronowych przeznaczonych do różnych celów. Przedstawione poniżej wyniki badań pokazują nowe rodzaje sieci neuronowych, które mogą być stosowane do analizy, przetwarzania i interpretacji różnego rodzaju sygnałów. Sygnałami tymi mogą być na przykład obrazy medyczne uzyskiwane z takich metod obrazowania jak: rentgenografia, tomografia komputerowa, rezonans magnetyczny czy tomografia pozytonowa. Możliwe jest także zastosowanie tego rodzaju sieci w innych dziedzinach nauki – takich jak na przykład geologia. W zamieszczonych przykładach pokazano możliwości sieci neuronowych między innymi do badania anomalii geologicznych na obrazach georadarowych. Tego rodzaju dane nie były jeszcze przetwarzane i analizowane z wykorzystaniem sieci neuronowych (wskazują na to przeprowadzone analizy literaturowe), więc ich wprowadzenie przydaje prezentowanym badaniom dodatkowego waloru oryginalności.

3.3.2.2. Klasyczne sieci neuronowe z preprocesingiem danych wejściowych do postaci współczynników wielomianów aproksymujących sygnał

Użycie klasycznej sieci neuronowej do interpretacji sygnału, który jest przebiegiem zmiennym w czasie nie jest możliwe. Powstaje więc problem sposobu reprezentacji danych na wejściu sieci neuronowej.

Wprowadzenie sygnału bezpośrednio na wejście sieci neuronowej – absolutnie nie wchodzi

w rachubę. Pomijając bardziej subtelne powody – niemożność wprowadzenia takiego sygnału wynika z faktu, że składa się on z ogromnej liczby (kilkuset tysięcy) próbek. W związku z tym więc warstwa wejściowa sieci, która by taki obraz akceptowała, musiałaby zawierać tyleż samo neuronów, co byłoby trudne do realizacji. Jeszcze większy problem wiązałby się z faktem, że powiązania takiej ogromnej warstwy wejściowej z odpowiednio bogatą warstwą ukrytą (warstwą neuronów analizujących informacje) wymagałyby ustalenia (na etapie uczenia sieci) wartości przynajmniej kilku milionów współczynników wagowych. To jest całkowicie technicznie niewykonalne.

W związku z tym sygnały wejściowe do sieci neuronowej muszą zawierać informację o ogólnym kształcie sygnału, gdyż kształt ten niesie informację, którą chcemy właśnie analizować.

Zaproponowano oryginalny i nie spotykany w znanej literaturze przedmiotu sposób reprezentacji sygnału na wejściu sieci neuronowej poprzez aproksymację przebiegu tego sygnału wielomianem, a następnie próbowano wykorzystać współczynniki tego wielomianu jako sygnały podawane na wejście sieci neuronowej.

Konkretyzując i formalizując ten opis można zaproponować następujący model przyjętego sposobu postępowania. Oznaczmy jako $G_x(d)$ przebieg sygnału o numerze x w punkcie o współrzędnej d . Zakładamy, że sygnał $G_x(d)$ może być aproksymowany wielomianem stopnia N o współczynnikach $a_{0x}, a_{1x}, a_{2x}, \dots, a_{Nx}$. Można to symbolicznie zapisać w formie zależności:

$$G_x \cong \sum_{i=0}^N a_{ix} d^i \quad (1)$$

Po dokonaniu takiej aproksymacji można przyjąć, że sygnał $G_x(d)$ na wejściu sieci neuronowej reprezentowany będzie przez wektor $N+1$ współczynników $a_{0x}, a_{1x}, a_{2x}, \dots, a_{Nx}$.

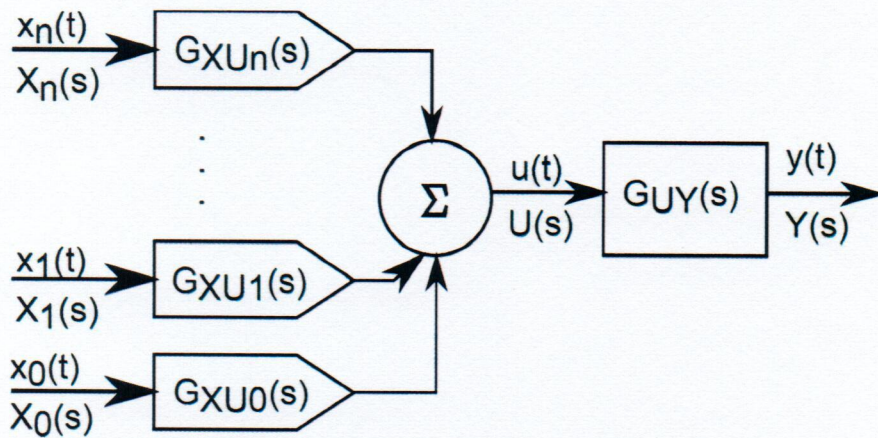
Takie podejście prowadzi do stworzenia klasycznej sieci z wagami w postaci współczynników wielomianów aproksymujących sygnał.

Struktury sieci oraz sposoby uczenia tak uzyskanej sieci są powszechnie znane - są analogiczne do zwykłych, klasycznych sieci neuronowych.

3.3.2.3. Sieci neuronowe z przekształceniem Laplace'a

Neuron z przekształceniem Laplace'a

Jedną z odmian sieci neuronowych jest sieć neuronowa z przekształceniem Laplace'a. Na rysunku (Rysunek 1) pokazano neuron z przekształceniem Laplace'a (ang. Laplace transform artificial neuron - LTAN). Definicja przekształcenia Laplace'a oraz jego podstawowe własności zostały opisane bardzo dokładnie w dostępczej powszechnie literaturze.



Rysunek 1 Neuron z przekształceniem Laplace'a

Jeśli przyjmiemy, że:

$$X_i(s) = \mathcal{L}\{x_i(t)\} \quad (2)$$

$$U(s) = \mathcal{L}\{u(t)\} \quad (3)$$

$$Y(s) = \mathcal{L}\{y(t)\} \quad (4)$$

to możemy napisać:

$$U(s) = \sum_{i=0}^n G_{XU_i}(s) X_i(s) \quad (5)$$

oraz

$$Y(s) = G_{UY}(s) U(s) \quad (6)$$

Po wstawieniu równania (5) do (6) otrzymujemy:

$$Y(s) = G_{UY}(s) \sum_{i=0}^n G_{XU_i}(s) X_i(s) \quad (7)$$

Co daje w efekcie:

$$Y(s) = \sum_{i=0}^n G_{UY}(s) G_{XU_i}(s) X_i(s) \quad (8)$$


Równanie (8) może być uproszczone poprzez zastąpienie formuły:

$$G_i(s) = G_{UY}(s) G_{XU_i}(s) \quad (9)$$

Wtedy otrzymujemy:

$$Y(s) = \sum_{i=0}^n G_i(s) X_i(s) \quad (10)$$

Uproszczenie to pokazano również na rysunku (Rysunek 2).



Rysunek 2 Neuron z przekształceniem Laplace'a po uproszczeniu

Wektor transformat można zapisać też w następującej postaci:

$$G(s) = [G_0(s), G_1(s), \dots, G_n(s)] \quad (11)$$

Wektor wejść:

$$X(s) = \begin{bmatrix} X_0(s) \\ X_1(s) \\ \vdots \\ X_n(s) \end{bmatrix} \quad (12)$$

Używając notacji z równań (11) i (12) równanie (10) przyjmuje następującą postać:

$$Y(s) = G(s)X(s) \quad (13)$$

Uczenie neuronu z przekształceniem Laplace'a

Tak zdefiniowany sztuczny neuron może być poddany procesowi uczenia, którego idea jest pokazana na rysunku (Rysunek 3). Algorytm jest podobny do znanej powszechnie metody zaproponowanej przez B. Widrow'a i M. E. Hoff'a. Polega on na iteracyjnej modyfikacji transmitancji $G(s)$ w celu minimalizacji wartości $\Delta(s)$, która wyraża się wzorem:

$$\Delta(s) = Z(s) - Y(s) \quad (14)$$

gdzie $Z(s)$ jest znaną wartością uczącą wyjściowego sygnału uzyskiwaną w odpowiedzi na sygnał wejściowy $X(s)$. Natomiast $Y(s)$ jest rzeczywistą odpowiedzią. Iteracyjne uczenie można wyrazić w postaci następujących równań:

$$Y^k(s) = G^k(s)X^k(s) \quad (15)$$

$$\Delta^k(s) = Z^k(s) - Y^k(s) \quad (16)$$

$$G^{k+1}(s) = G^k(s) - \beta(k)\Delta^k(s) \quad (17)$$

gdzie

$$k=0,1,\dots,p-1$$

p jest liczbą iteracji

$\beta(k)$ jest współczynnikiem spełniającym warunek:

$$\beta(k) = [\beta_0(k), \beta_1(k), \dots, \beta_n(k)] \quad (18)$$

$$1 \geq \beta_i(k) > 0 \quad (19)$$

Z równań (11) i (17) można otrzymać:

$$G_i^{k+1}(s) = G_i^k(s) - \beta_i(k)\Delta^k(s) \quad (20)$$

Proces uczenia rozpoczyna się od ustawienia transmitancji:

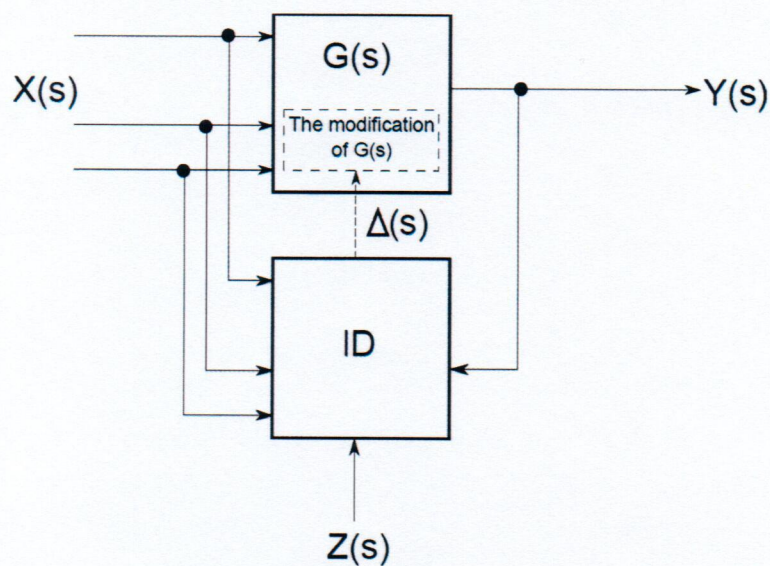
$$G^0(s) = [0, 0, \dots, 0] \quad (21)$$

oraz wartości współczynnika:

$$\beta_i(0) = 1 \quad (22)$$

W rezultacie otrzymujemy:

$$G(s) = G^{p-1}(s) \quad (23)$$



Rysunek 3 Schemat uczenia LTAN z nauczycielem

Sieć neuronowa z przekształceniem Laplace'a

Mając zdefiniowany neuron z przekształceniem Laplace'a można stworzyć sieć neuronową z przekształceniem Laplace'a (ang. Laplace transform artificial neural network - LTANN).

Wektor wartości wejściowych będzie miał następującą postać:

$$X(s) = \begin{bmatrix} X_0(s) \\ X_1(s) \\ \vdots \\ X_n(s) \end{bmatrix} \quad (24)$$

Wektor wyjściowy:

$$Y(s) = \begin{bmatrix} Y_0(s) \\ Y_1(s) \\ \vdots \\ Y_m(s) \end{bmatrix} \quad (25)$$


Tablica transformat (będąca odpowiednikiem funkcji przejścia dla klasycznych sieci neuronowych) ma następującą postać:

$$F(s) = \begin{bmatrix} F_{0,0}(s) & \cdots & F_{0,n}(s) \\ \vdots & \ddots & \vdots \\ F_{m,0}(s) & \cdots & F_{m,n}(s) \end{bmatrix} \quad (26)$$

Równanie opisujące sieć neuronową z przekształceniem Laplace'a przyjmuje następującą postać:

$$Y(s) = F(s)X(s) \quad (27)$$

Graficzna reprezentacja równania (27) pokazana została na rysunku (Rysunek 4).



Rysunek 4 Sieć neuronowa z przekształceniem Laplace'a

Uczenie sieci neuronowej z przekształceniem Laplace'a

Algorytm uczenia sieci neuronowej z przekształceniem Laplace'a został pokazany schematycznie na rysunku (Rysunek 5). Uczenie sieci polega na minimalizowaniu wartości $\Theta(s)$, która jest określona wzorem:

$$\Theta(s) = Z(s) - Y(s) \quad (28)$$

gdzie

$$Z(s) = \begin{bmatrix} Z_0(s) \\ Z_1(s) \\ \vdots \\ Z_n(s) \end{bmatrix} \quad (29)$$

oraz

$$\Theta(s) = \begin{bmatrix} \Theta_0(s) \\ \Theta_1(s) \\ \vdots \\ \Theta_n(s) \end{bmatrix} \quad (30)$$

$Z(s)$ jest znaną wartością uczącą sygnału wyjściowego otrzymywanego w odpowiedzi na sygnał wejściowy $X(s)$. $Y(s)$ jest rzeczywistą wartością sygnału wyjściowego dla sieci neuronowej.

$$Y^k(s) = F^k(s)X^k(s) \quad (31)$$

k oznacza kolejne iteracje procesu uczenia, który ma p kroków uczenia.

$$\Theta^k(s) = Z^k(s) - Y^k(s) \quad (32)$$

$$F^{k+1}(s) = F_{i,j}^k(s) - \Psi(s)\Theta^k(s) \quad (33)$$

$\Psi(k)$ jest współczynnikiem, który spełnia następujące warunki:

$$\Psi(k) = [\Psi_0(k), \Psi_1(k), \dots, \Psi_n(k)] \quad (34)$$

$$1 \geq \Psi_i(k) > 0 \quad (35)$$

Na podstawie równań (26) i (33) otrzymujemy:

$$F_{i,j}^{k+1}(s) = F_{i,j}^k(s) - \Psi(s)\Theta^k(s) \quad (36)$$

Proces uczenia sieci neuronowej rozpoczyna się z macierzą transmitancji z następującymi wartościami:

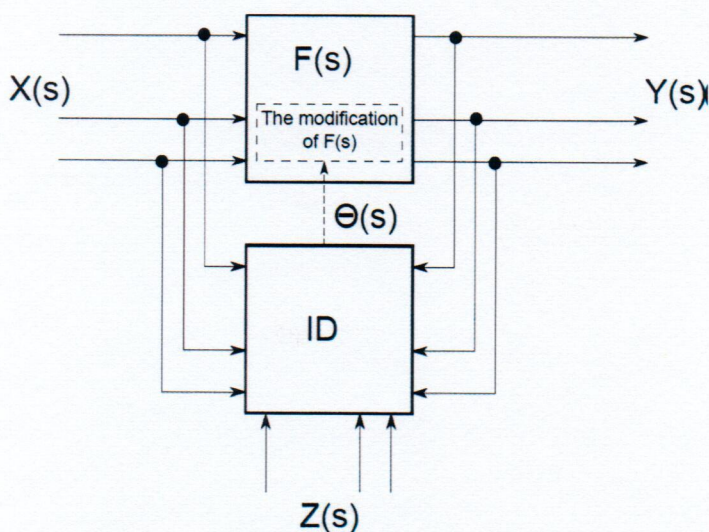
$$F^0(s) = \begin{bmatrix} 0 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & 0 \end{bmatrix} \quad (37)$$

i wartościami współczynników:

$$\Psi_i(0) = 1 \quad (38)$$

W efekcie procesu uczenia otrzymujemy dla $(p-1)$ kroku transmitancję:

$$F(s) = F^{p-1}(s) \quad (39)$$



Rysunek 5 Uczenie LTANN z nauczycielem

3.3.2.4. Sieci neuronowe z przekształceniem Z

Drugą z zaproponowanych odmian sieci neuronowych są sieci neuronowe z przekształceniem Z. Powstają one w sposób analogiczny do opisanych poprzednio sieci neuronowych z przekształceniem Laplace'a. Zasadnicza różnica polega na tym, że zostało zastąpione przekształcenie Laplace'a przekształceniem Z, co umożliwi zastosowanie tych sieci do analizy sygnałów dyskretnych.

Neuron z przekształceniem Z

Na rysunku (Rysunek 6) pokazano neuron z przekształceniem Z (ang. Z transform artificial neuron - ZTAN). Podobnie jak dla przekształcenia Laplace'a tak i dla przekształcenia Z w literaturze można znaleźć bardzo dokładnie opisane własności tego przekształcenia.

Jeśli przyjmujemy, że:

$$X_i(z) = Z\{x_i[n]\} \quad (40)$$

$$U(z) = Z\{u[n]\} \quad (41)$$

$$Y(z) = Z\{y[n]\} \quad (42)$$

to można napisać:

$$U(z) = \sum_{i=0}^k G_{XU_i}(z) X_i(z) \quad (43)$$

oraz

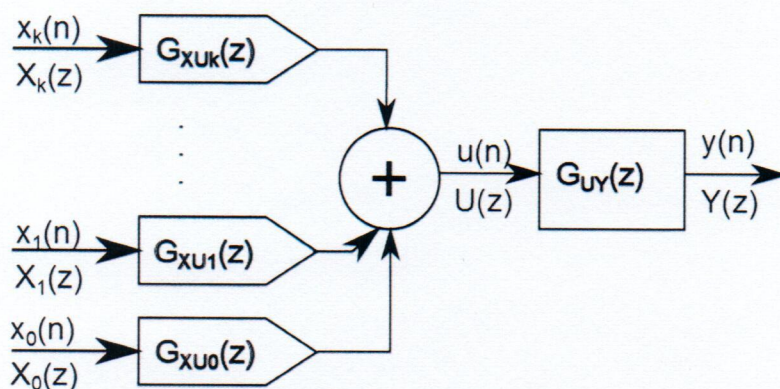
$$Y(z) = G_{UY}(z) U(z) \quad (44)$$

Jeśli teraz wstawimy równanie (43) do równania (44) to otrzymamy:

$$Y(z) = G_{UY}(z) \sum_{i=0}^k G_{XU_i}(z) X_i(z) \quad (45)$$

Równanie to można również zapisać w następującej postaci:

$$Y(z) = \sum_{i=0}^k G_{UY}(z) G_{XU_i}(z) X_i(z) \quad (46)$$



Rysunek 6 Neuron z przekształceniem Z


Równanie (46) można uprościć jeśli zastosujemy następującą formułę:

$$G_i(z) = G_{UY}(z)G_{XU_i}(z) \quad (47)$$

Wtedy otrzymujemy

$$Y(z) = \sum_{i=0}^k G_i(z)X_i(z) \quad (48)$$

Wynik tego uproszczenia można przedstawić graficznie na rysunku (Rysunek 7).



Rysunek 7 Neuron z przekształceniem Z po uproszczeniu

i -ta transmitancja może być zapisana również w następującej postaci:

$$G_i(z) = \frac{\sum_{l=0}^{\beta_i} b_{i,l}z^l}{\sum_{j=0}^{\alpha_i} a_{i,j}z^j} \quad (49)$$

gdzie:

- i – numer wejścia,
- k – liczba wejść,
- j – potęga w wielomianie w mianowniku,
- α_i – stopień wielomianu mianownika,
- l – potęga w wielomianie w liczniku,
- β_i – stopień wielomianu licznika.

Wektor transformat można zapisać równaniem:

$$G(z) = [G_0(z), G_1(z), \dots, G_k(z)] \quad (50)$$

Wektor wejść na następującą postać:

$$X(z) = \begin{bmatrix} X_0(z) \\ X_1(z) \\ \vdots \\ X_k(z) \end{bmatrix} \quad (51)$$

Można więc teraz zapisać:

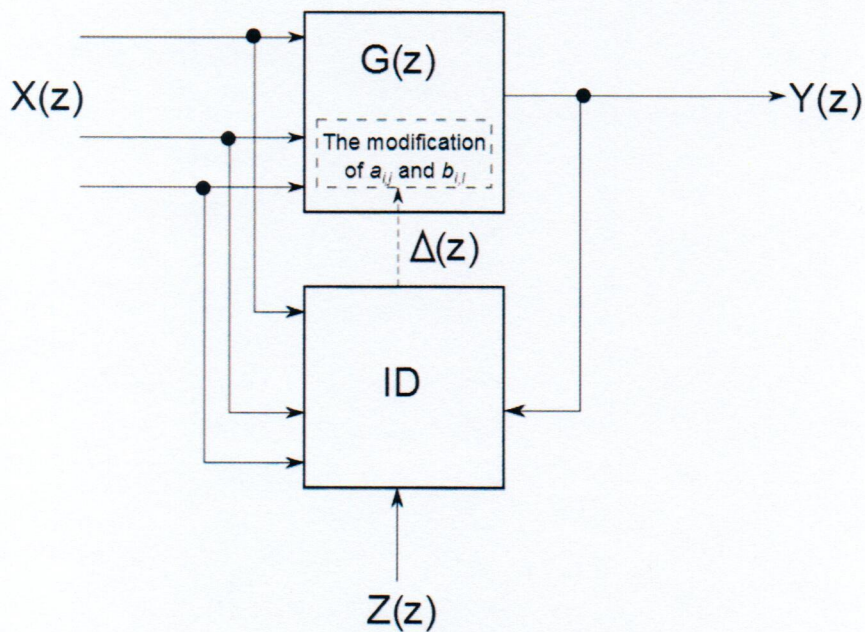
$$Y(z) = G(z)X(z) \quad (52)$$

Uczenie neuronu z przekształceniem Z

Proces uczenia neuronu ZTAN został pokazany na rysunku (Rysunek 8). Polega on na iteracyjnej modyfikacji transformacji $G(z)$ w celu minimalizacji wartości $\Delta(z)$ określonej następującym wzorem:

$$\Delta(z) = Z(z) - Y(z) \quad (53)$$

Gdzie $Z(z)$ jest znaną wartością uczącą wyjściowego sygnału uzyskiwaną w odpowiedzi na sygnał wejściowy $X(z)$. Natomiast $Y(z)$ jest rzeczywistą odpowiedzią neuronu.



Rysunek 8 Schemat uczenia ZTAN z nauczycielem

Definicja sieci neuronowej z przekształceniem Z

Mając zdefiniowany neuron ZTAN można stworzyć sieć neuronową z przekształceniem Z (ang. Z-transform artificial neural network - ZTANN), sieć ta pokazana jest na rysunku (Rysunek 9).

Wektor wejść można zapisać jako:


$$X(z) = \begin{bmatrix} X_0(z) \\ X_1(z) \\ \vdots \\ X_k(z) \end{bmatrix} \quad (54)$$

Wektor wyjść:

$$Y(z) = \begin{bmatrix} Y_0(z) \\ Y_1(z) \\ \vdots \\ Y_m(z) \end{bmatrix} \quad (55)$$

Macierz transformacji (odpowiednik funkcji przejścia dla klasycznych sieci neuronowych) będzie miała następującą postać:

$$F(z) = \begin{bmatrix} F_{0,0}(z) & F_{0,1}(z) & \dots & F_{0,k}(z) \\ F_{1,0}(z) & F_{1,1}(z) & \dots & F_{1,k}(z) \\ \vdots & \vdots & \ddots & \vdots \\ F_{m,0}(z) & F_{m,1}(z) & \dots & F_{m,k}(z) \end{bmatrix} \quad (56)$$



Rysunek 9 Sieć neuronowa z przekształceniem Z

Równanie opisujące sieć ZTANN będzie następujące:

$$Y(z) = F(z)X(z) \quad (57)$$

Transmitancja pomiędzy i -tym wejściem a k -tym wyjściem będzie miała postać:

$$F_{i,h}(z) = \frac{\sum_{l=0}^{\beta_{i,h}} b_{(i,h),l} z^l}{\sum_{j=0}^{\alpha_{i,h}} a_{(i,h),j} z^j} \quad (58)$$

gdzie:


- i – numer wejścia,
- h – numer wyjścia,
- j – potęga wielomianu w mianowniku,
- $\alpha_{i,h}$ – stopień wielomianu mianownika,
- l – potęga wielomianu w liczniku,
- $\beta_{i,h}$ – stopień wielomianu licznika.

Jedno warstwowa sieć ZTANN z rysunku (Rysunek 10) może być opisana następującą transmitancją:

$$F(z) = \begin{bmatrix} F_0(z) \\ F_1(z) \\ \vdots \\ F_m(z) \end{bmatrix} \quad (59)$$

gdzie

$$F_p(z) = [F_{p,0}(z), F_{p,1}(z), \dots, F_{p,k}(z)] \quad (60)$$

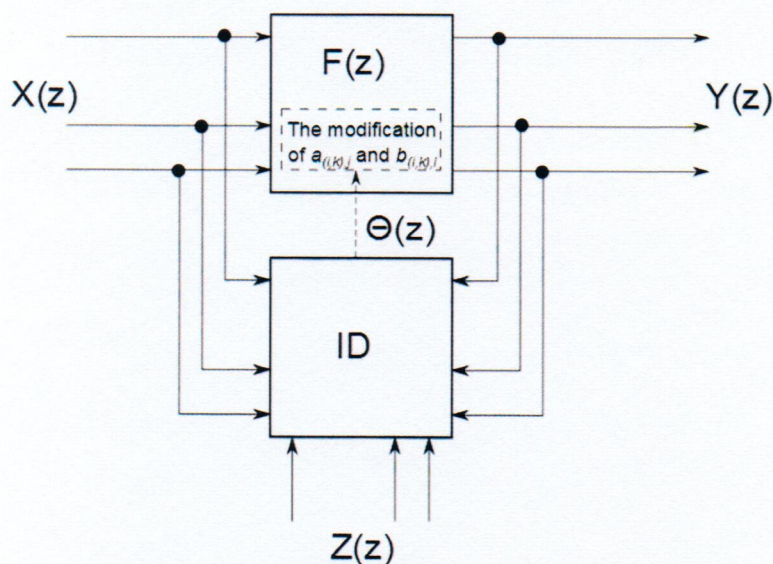


Rysunek 10 Sieć neuronowa z jedną warstwą z przekształceniem Z

Uczenie sieci neuronowej z przekształceniem Z

Proces uczenia sieci ZTANN pokazany jest na rysunku (Rysunek 11). Polega on na iteracyjnej modyfikacji $a_{(i,k),l}$ oraz $b_{(i,k),l}$ z równania (58) w celu minimalizacji błędu $\theta(z)$, który jest dany jako:

$$\theta(z) = Z(z) - Y(z) \tag{61}$$



Rysunek 11 Schemat uczenia ZTANN z nauczycielem

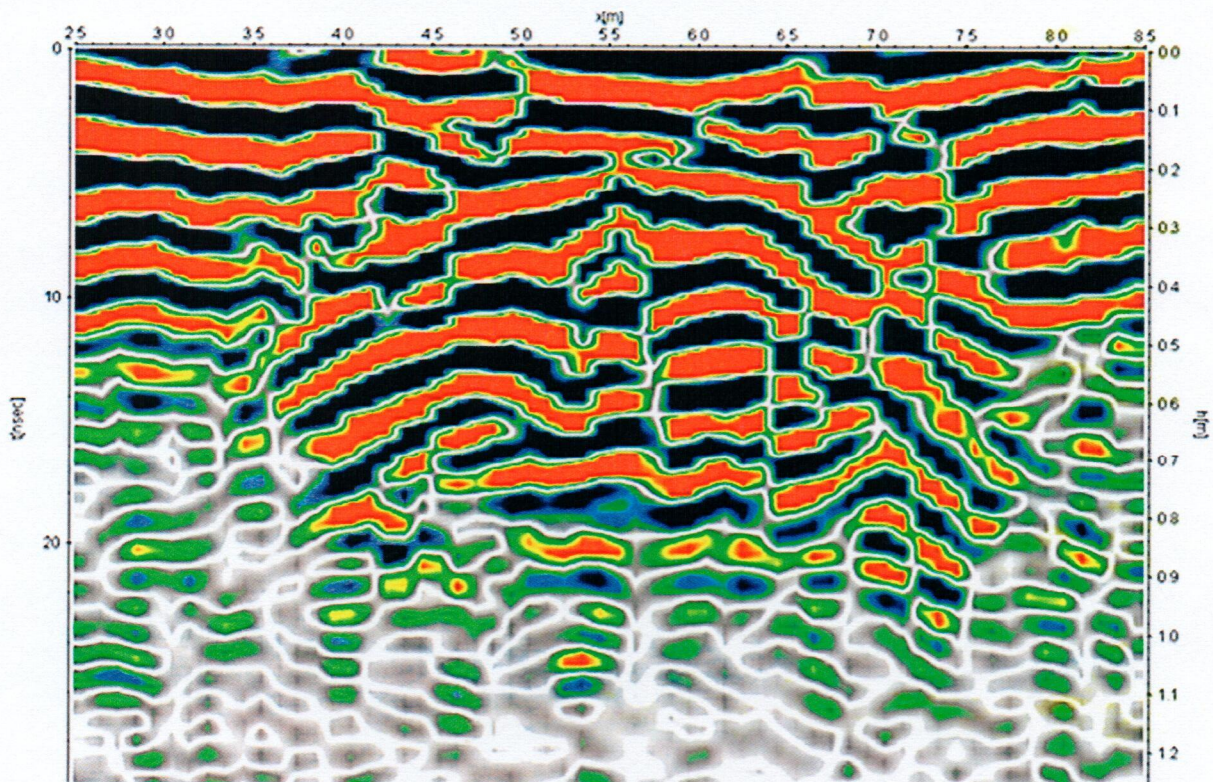
Proces uczenia można zakończyć jeśli poziom błędu osiągnie wymaganą wartość.

3.3.3. Omówienie wykorzystania wyników prac

3.3.3.1. Przykład zastosowań klasycznych sieci neuronowych z preprocesingiem danych wejściowych do postaci współczynników wielomianów aproksymujących sygnał

Problemem naukowym opisanym w tym przykładzie jest ocena przydatności sieci neuronowych jako narzędzi pozwalających na analizę, przetwarzanie i interpretację sygnałów georadarowych. Zaczniemy od wyjaśnienia, dlaczego przyjęto właśnie sieci neuronowe jako narzędzia do rozważanych zadań.

Decydującym czynnikiem jest fakt, że sieci są bardzo efektywnym narzędziem uczącym się. Jak wiadomo, sygnały georadarowe niosą informację o strukturach geologicznych znajdujących się pod ziemią na podstawie propagacji i odbić (od granicy pomiędzy warstwami o różnej względnej przenikalności elektrycznej) sygnałów w postaci fal elektromagnetycznych. Pomimo efektownego wyglądu tak uzyskiwanych zobrazowań sygnałów georadarowych, których przykładem może być rysunek (Rysunek 12), interpretacja tych obrazów nie jest prosta.



Rysunek 12 Przykładowy obraz georadarowy

Wynika to ze skomplikowanego charakteru zjawisk fizycznych, jakie mają miejsce podczas propagacji i odbić fal elektromagnetycznych w gruncie, a także z tego, że poszczególne aparaty wykorzystywane w technice GPR (Ground-Penetrating Radar) dostarczają obrazów o zróżnicowanych właściwościach i cechach. W rezultacie nawet dobrzy specjaliści, wyszkoleni w ocenie sygnałów georadarowych uzyskiwanych za pomocą jednego typu aparatu GPR, przy zmianie wykorzystywanego aparatu muszą

się ponownie uczyć poprawnej interpretacji tego, co widzą. Tym bardziej uczenia wymaga też narzędzie informatyczne, które ten proces interpretacji sygnałów georadarowych ma przyspieszać, automatyzować i obiektywizować. Ponieważ najlepszym z systemów uczących się są współcześnie sieci neuronowe – postanowiono zastosować właśnie to narzędzie do wspomaganie procesu interpretacji danych georadarowych.


Jako pierwsza kwestia do rozwiązania pojawia się problem sposobu reprezentacji danych georadarowych na wejściu sieci neuronowej. Wprowadzenie takiego obrazu, jaki przykładowo przedstawiono na rysunku (Rysunek 12), bezpośrednio na wejście sieci neuronowej – absolutnie nie wchodzi w rachubę. Pomijając bardziej subtelne powody – niemożność wprowadzenia takiego obrazu wynika z faktu, że składa się on z ogromnej liczby (kilkuset tysięcy) voxelów. W związku z tym, warstwa wejściowa sieci, która by taki obraz akceptowała, musiałaby zawierać tyleż samo neuronów, co byłoby trudne do realizacji. Jeszcze większy problem wiązałby się z faktem, że powiązania takiej ogromnej warstwy wejściowej z odpowiednio bogatą warstwą ukrytą (warstwą neuronów analizujących informacje) wymagałyby ustalenia (na etapie uczenia sieci) wartości przynajmniej kilku milionów współczynników wagowych. To jest całkowicie niewykonalne technicznie.

Zagadnienie to jest zresztą znane także z innych zastosowań sieci neuronowych, które są związane z przetwarzaniem komputerowym, analizą i rozpoznawaniem obrazów. W zastosowaniach tych stosowane są niekiedy metody dzielenia obrazu na okna lub wydobywania tak zwanych ROI (region of interest). Metody te, stosowane niekiedy przy zwykłych obrazach, zawodzą jednak całkowicie w odniesieniu do obrazów georadarowych. Dzieje się tak ze względu na fakt, że związki kontekstowe zachodzące pomiędzy voxelami obrazów GPR, są całkowicie odmienne od związków między pikselami, wykorzystywanych między innymi przy kodowaniu obrazów w standardzie JPG, charakterystycznych dla zwykłych obrazów wizyjnych.

Poszukując metody prawidłowego odwzorowania obrazów georadarowych w sieci neuronowej wzięto pod uwagę fakt, że obraz GPR (tak zwany profil) składa się z kolekcji ścieżek, pokazanych przykładowo na rysunku (Rysunek 13), gdzie typowy echogram (radargram) przedstawiono w tak zwanym formacie Wiggle. W tym formacie wyniki poszczególnych sondaży przedstawione są jako linie przebiegające z góry na dół. Na liniach tych, odchylenia od ich idealnie pionowego przebiegu odpowiadają kolejnym echem docierającym do aparatu GPR w następstwie odbić fal elektromagnetycznych od kolejnych struktur geologicznych, przy czym odchylenia w jedną stronę sygnalizują fale odbijające się w fazie zgodnej z wysyłanym sygnałem, a odchylenia w drugą stronę odpowiadają odbiciom w przeciwfazie. Amplituda odchylenia linii sygnalizuje energię fali odbitej.

Każda ścieżka odpowiada wynikowi jednego georadarowego sondażu, przeprowadzanego w kolejnym punkcie na trajektorii, jaką był prowadzony w terenie aparat GPR. Na osi poziomej rysunku oznaczone są położenia poszczególnych punktów pomiarowych w postaci zmiennej x reprezentującej odległość od punktu początkowego (miejsca wykonania pierwszego sondażu). Pionowy wymiar ścieżki prezentuje zróżnicowanie odbicia fal elektromagnetycznych docierające z różnych głębokości. Jest to związane z faktem, że odbicia pochodzą głównie od granic struktur geologicznych położonych na różnych głębokościach. Symbolizuje to zmienna DEPTH odkładana na osi pionowej po prawej stronie rysunku (Rysunek 13). Trzeba w tym miejscu podkreślić, że wartości tej zmiennej mają charakter przybliżony, gdyż dokładnie wyznaczone przez aparaturę GPR są tylko opóźnienia elektromagnetycznego echa w stosunku do momentu wysłania impulsu skanującego (zmienna t na

osi pionowej po lewej stronie). Natomiast wartości hipotetycznej głębokości DEPTH, na jakiej nastąpiło odbicie, są obliczane przy założeniu określonej (jednakowej dla całej drogi przebiegu sygnału) prędkości propagacji fali elektromagnetycznej w gruncie. Ta prędkość w konkretnym przypadku na ogół nie jest dokładnie znana, co więcej – w rzeczywistości jest ona zmienna a nie stała, gdyż poszczególne struktury geologiczne znajdujące się na drodze fal elektromagnetycznych mają różną stałą dielektryczną co wiąże się z różną szybkością propagacji fal elektromagnetycznych. Na szczęście w rozważanych tu badaniach dokładna wartość głębokości położenia wykrywanej i ocenianej struktury geologicznej nie ma zasadniczego znaczenia.



Rysunek 13 Obraz georadarowy jako kolekcja ścieżek

W przedstawianych badaniach użyto profilu złożonego z 645 ścieżek, a każda ścieżka w cyfrowej reprezentacji zawierała 416 punktów pomiarowych (łącznie 268 320 voxel). Tych 416 punktów tworzyło nadal zbyt duży wektor wejściowy, żeby można było go wprowadzić na wejście sieci, dlatego poszukiwano takiej reprezentacji tego sygnału, która by mogła odwzorować jego cechy istotne z punktu widzenia rozważanego zadania, redukując równocześnie znacząco wymiar wejściowego wektora. Żeby osiągnąć ten efekt należało nieco dokładniej określić cel interpretacji rozważanych sygnałów georadarowych. W rozważanym tu problemie przedmiotem oceny ich miało być wykrywanie tak zwanej podziemnej pustki – niebezpiecznej pozostałości po nieprawidłowo zakończonej eksploatacji górniczej. Obecność takiej pustki pod ziemią i jej systematyczne przemieszczanie się ku powierzchni stwarza zagrożenie dla znajdujących się na tej powierzchni obiektów (budynków, dróg – a nawet ludzi).

Zgodnie z przedstawioną w rozdziale 3.3.2.2 metodologią dokonano aproksymacji sygnału

georadarowego z poszczególnych ścieżek w postaci wielomianu.

Empirycznie stwierdzono, że optymalną wartością stopnia wielomianu aproksymacyjnego jest 20. Przy mniejszych wartościach stopnia wielomianu aproksymacja była mało dokładna i niektóre subtelności kształtu przebiegu ścieżki nie były dostatecznie dobrze odwzorowywane na wejściu sieci neuronowej. Natomiast przy wyborze stopnia wielomianu większego niż 20 znaczna część współczynników a_{ix} dla dużych wartości i była zerowa, co dowodziło, że wielomian tak wysokiego stopnia do tej aproksymacji nie był potrzebny.

Jako przykłady wartości współczynników wielomianu wyznaczonych w wyżej omówiony sposób można podać wartości a_{0x} , a_{1x} , a_{2x} , ..., a_{Nx} dla ścieżki nr 27, przypadającej w obszarze, w którym pustka podziemna nie występuje oraz dla ścieżki nr 330 pochodzącej z obszaru, w którym obecność pustki potwierdziło powstałe po latach zapadlisko. Porównanie wartości poszczególnych współczynników pokazuje, jak dobrze zaproponowana reprezentacja sygnału odwzorowuje jego interesujące w tych badaniach cechy.

Tabela 1 Wartości współczynników wielomianu dla dwóch wybranych ścieżek


Współczynnik	Numer ścieżki	
	27	330
a_0	-0.3505	0.2699
a_1	0.3331	-0.0028
a_2	4.8442	-4.0662
a_3	-4.3115	0.2897
a_4	-28.4144	25.8351
a_5	23.4807	-3.0743
a_6	92.0963	-90.1236
a_7	-69.9186	13.8706
a_8	-179.8618	188.2779
a_9	123.7323	-33.1554
a_{10}	216.4069	-241.0737
a_{11}	-132.3002	44.7143
a_{12}	-157.3952	185.9049
a_{13}	83.0048	-33.7151
a_{14}	65.0304	-81.3861
a_{15}	-28.1220	13.2299
a_{16}	-13.4095	17.8733
a_{17}	4.2997	-2.2748
a_{18}	1.0421	-1.5068
a_{19}	-0.1884	0.1113
a_{20}	0.0717	0.0902

Ustaliwszy jak reprezentowane będzie wejście sieci, rozważono następnie pożądane wyjście sieci. Ustalono, że wyjście binarne (jest pustka albo jej nie ma) będzie w rozważanym zadaniu

nieprzydatne, gdyż wiązać się będzie z dostarczaniem przez sieć bardzo kategoriycznych rozstrzygnięć przy wysoce prawdopodobnej dużej stopie błędów. Założono więc, że budowana sieć będzie miała charakter sieci regresyjnej, a nie klasyfikacyjnej i sygnał wyjściowy z tej sieci określać będzie prawdopodobieństwo, że badana ścieżka odpowiada pustce.

Wybór struktury sieci neuronowej oraz jej uczenie

We wszystkich podręcznikach dotyczących stosowania sieci neuronowych zwraca się uwagę na znaczenie właściwego doboru struktury sieci. W rozważanym tu zadaniu należało ustalić rodzaj sieci, liczbę jej warstw i liczbę neuronów w poszczególnych warstwach. Do realizacji tego zadania użyto specjalistycznego narzędzia informatycznego, mianowicie modułu automatycznego projektanta sieci wchodzącego w skład pakietu Statistica Neural Networks firmy StatSoft. Automat ten po przeanalizowaniu dostępnych danych i wypróbowaniu kilkudziesięciu potencjalnie możliwych struktur zaproponował strukturę sieci zawierającą 21 neuronów w warstwie wejściowej (ma to związek z omówionym wyżej wyborem współczynników wielomianu 20 stopnia jako danych wejściowych charakteryzujących badaną ścieżkę sygnału georadarowego), posiadającą jedną warstwę ukrytą z 10 neuronami o sigmoidalnych funkcjach przejścia i z pojedynczym neuronem (też sigmoidalnym) w warstwie wyjściowej. Sieć takiego typu bywa opisywana w literaturze pod nazwą MLP (Multi-Layer Perceptron). Jej struktura w symbolice stosowanej w pakiecie Neural Network Toolbox należącym do środowiska Matlab (bo tego kolejnego narzędzia używano do uczenia sieci i do badania jej użyteczności, w szczególności używany był Neural Network Pattern Recognition Tool) przedstawiona jest na rysunku (Rysunek 14).

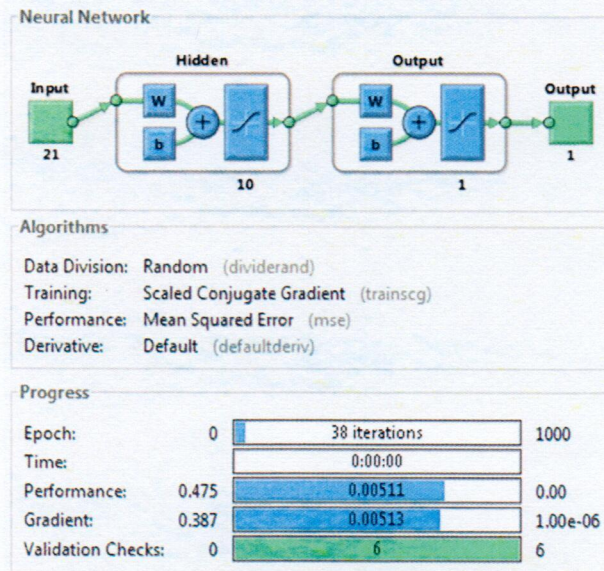


Rysunek 14 Struktura użytej sieci neuronowej

Opisaną sieć poddano procesowi uczenia. W tym celu zebrano zbiór danych z sondowań georadarowych dotyczących takiego obszaru badań, w którym przewidywano istnienie podziemnej pustki i owa pustka następnie rzeczywiście zmanifestowała swoją obecność powodując duże zapadlisko na powierzchni. Wiążąc miejsca wcześniejszych sondowań georadarowych z całkowicie pewną wiedzą na temat tego, gdzie się pustka ujawniła – w badanym profilu georadarowym do każdej ścieżki został przypisany atrybut mówiący o tym, czy na tej ścieżce powinna być wykryta pustka (bo ona tam była!) czy jest to "normalna" struktura geologiczna. Tak przygotowane dane obejmujące łącznie 645 ścieżek zostały następnie wykorzystane do nauki sieci.

Dane te – zgodnie z zasadami obowiązującymi przy uczeniu sieci neuronowych - zostały podzielone na trzy części: 70% posiadanych danych (451 ścieżek) zostało użytych bezpośrednio do nauki sieci (learning set), 15% (97 ścieżek) zostało użyte do walidacji mającej na celu zapobieganie efektowi „przeuczenia sieci” (validation set), zaś pozostałe 15% (97 ścieżek) zostało użyte do testów badających czy sieć potrafi uogólnić zdobytą wiedzę (test set).

Uczenie było prowadzone przy pomocy algorytmu skalowanych gradientów sprzężonych, przy czym założono, że maksymalny czas uczenia nie przekroczy 1000 epok. W rzeczywistości czas ten był skrócony przez warunek zapobiegania symptomom przeuczenia sieci, kontrolowany po każdej zakończonej epoce uczenia przy użyciu zbioru walidacyjnego. Obraz sieci w trakcie procesu jej uczenia w środowisku Matlab przedstawia rysunek (Rysunek 15).




Rysunek 15 Widok panelu kontrolnego programu Neural Network Toolbox w trakcie uczenia sieci

Przebieg procesu uczenia sieci można śledzić obserwując zmiany wartości błędów popełnianych przez sieć w poszczególnych epokach procesu uczenia obliczonych i uśrednionych odpowiednio dla zbioru uczącego, walidacyjnego i testowego - rysunek (Rysunek 16). Warto może wspomnieć, że „epoka” przy uczeniu sieci neuronowych to po prostu okres potrzebny na pokazanie sieci wszystkich obiektów wchodzących w skład zbioru uczącego. Proces uczenia należy przerwać, gdy błąd obliczany dla zbioru walidacyjnego zamiast maleć wraz z maleniem błędu dla zbioru uczącego - zaczyna rosnać, co sygnalizuje efekt przeuczenia sieci. Na rysunku (Rysunek 16) widać, że moment ten nastąpił w 32 epoce procesu uczenia.

Obserwując błędy w trakcie procesu uczenia sieci neuronowej - tak, jak to przedstawiono na rysunku (Rysunek 16) warto zwrócić uwagę na fakt, że oś pionowa, podająca wartości błędu średniokwadratowego dla odpowiednich trzech zbiorów danych, wyskalowana jest w sposób logarytmiczny. Sprawia to wrażenie, że błąd maleje równomiernie w trakcie całego procesu uczenia, podczas gdy w rzeczywistości ma miejsce bardzo szybki spadek wartości błędu w początkowym okresie uczenia (w pierwszych epokach), który potem wyraźnie spowalnia.

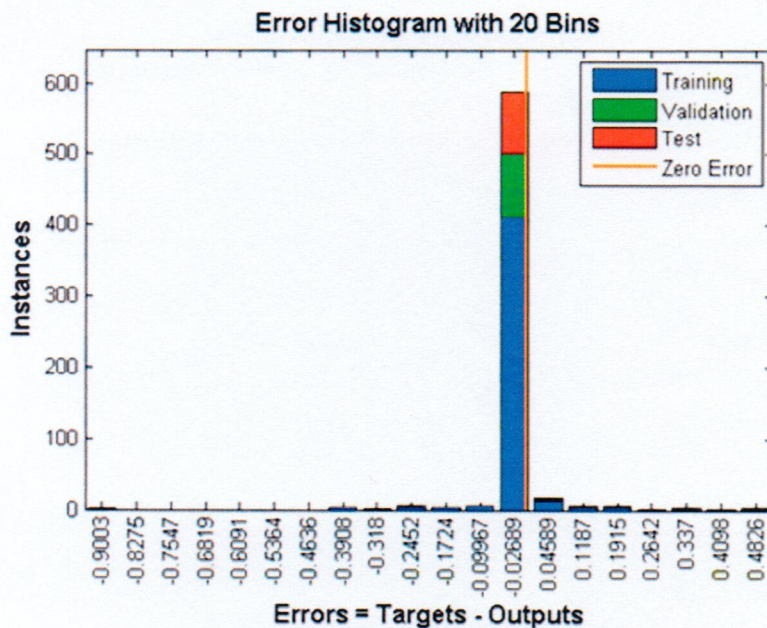
Wykres taki, jak przedstawia rysunek (Rysunek 16), pokazuje zmiany (malenie) błędu uśrednionego. Dla pełnej oceny przebiegu procesu uczenia korzystne jest pokazanie, jakie błędy popełniała sieć dla poszczególnych danych (poszczególnych ścieżek) w trakcie procesu uczenia. Informację taką przedstawia histogram wartości błędów - rysunek (Rysunek 17). Na histogramie takim pozioma oś wyskalowana jest w wartościach przyjętej miary błędu, a wysokość słupków odpowiada częstotliwości występowania takiej właśnie (jak oznaczona na osi poziomej) wartości błędu. Przy budowie

wspomnianego histogramu uwzględnia się podział danych na uczące, walidacyjne i testowe.



Rysunek 16 Przebieg zmian błędów w trakcie procesu uczenia

Histogram widoczny na rysunku (Rysunek 17) pokazuje, że zdecydowana większość ścieżek zarówno w zbiorze uczącym, jak i w zbiorach walidacyjnym oraz testowym, rozpoznawana była przez sieć z bardzo małym błędem (największy słupek histogramu zlokalizowany jest tuż w pobliżu zera). Przypadki większych błędów (zarówno in plus, jak i in minus) występowały rzadko i wyłącznie w zbiorze uczącym.



Rysunek 17 Histogram błędów w sieci w końcowym etapie procesu uczenia

Ocena wyników działania sieci oraz wnioski

Zadaniem rozważanej w tym przykładzie sieci neuronowej było przypisywanie do każdej ścieżki informacji, czy jest to ścieżka sygnalizująca obecność podziemnej pustki, czy też sondowana struktura geologiczna jest w danym miejscu „bezpieczna” (pustki nie występują). Stopień skuteczności realizacji tego zadania przez sieć neuronową najlepiej jest oceniać na podstawie tzw. confusion matrix czyli tabeli pokazującej, ile razy w rozpoznaniach dostarczanych przez sieć („Output Class”) obiekt wskazany jako należący do klasy 1 (czyli z obecnością pustki) odpowiadał rzeczywiście występującej w badaniach ścieżce przebiegającej przez obszar pustki (Target Class = 1). Analogicznie prawidłowe rozpoznania odpowiadają sytuacji Output Class = 0 gdy równocześnie Target Class = 0. Sytuacje Output Class = 0 Target Class = 1 oraz Output Class = 1 Target Class = 0 odpowiadają błędom. Tabele confusion matrix pokazano osobno dla zbiorów uczącego (Tabela 2), walidacyjnego (Tabela 3) i testowego (Tabela 4), a następnie także dla wszystkich danych rozważanych łącznie (Tabela 5). Jak widać w zbiorach walidacyjnym i testowym błędy nie zaistniały wcale, a w zbiorze uczącym nie przekraczały one 0,5%.

O tym, jak dobre wyniki dostarczała opracowana sieć świadczyć może także kontrola jej działania na przykładowych ścieżkach, dla których współczynniki wielomianu pokazano w tabeli (Tabela 1). Otóż dla ścieżki nr 27 wyliczone przez sieć prawdopodobieństwo, że jest to pustka wyniosło: 0,04655, co jest zgodne z rzeczywistością, ponieważ była to ścieżka leżąca poza obszarem w którym wiemy, że występowała pustka. Natomiast dla ścieżki numer 330 wyznaczone przez sieć prawdopodobieństwo, że jest tam pustka wyniosło: 0,94318 – co odpowiadało prawidłowym wynikom potwierdzonym potem przez powstanie w tym miejscu zapadliska.

Tabela 2 Macierz uczenia dla sieci neuronowej

		Docelowa klasa		
		0	1	X
Wyjściowa klasa	0	267	1	99,6 %
		59,2 %	0,2 %	0,4 %
	1	1	182	99,5 %
		0,2 %	40,4 %	0,5 %
	X	99,6 %	99,5 %	99,6 %
		0,4 %	0,5 %	0,4 %

Tabela 3 Macierz walidacji dla sieci neuronowej

		Docelowa klasa		
		0	1	X
Wyjściowa klasa	0	59	0	100 %
		60,6 %	0,0 %	0,0 %
	1	0	38	100 %
		0,0 %	39,2 %	0,0 %
	X	100 %	100 %	100 %
		0,0 %	0,0 %	0,0 %

Tabela 4 Macierz testów dla sieci neuronowej

		Docelowa klasa		
		0	1	X
Wyjściowa klasa	0	57	0	100 %
		58,8 %	0,0 %	0,0 %
	1	0	40	100 %
		0,0 %	41,2 %	0,0 %
	X	100 %	100 %	100 %
		0,0 %		0,0 %

Tabela 5 Macierz całościowa dla sieci neuronowej

		Docelowa klasa		
		0	1	X
Wyjściowa klasa	0	383	1	99,7 %
		59,4 %	0,2 %	0,3 %
	1	1	260	99,6 %
		0,2 %	40,3 %	0,4 %
	X	99,7 %	99,6 %	99,7 %
		0,3 %	0,4 %	0,3 %

Podsumowując omówione wyniki można stwierdzić, że przydatność sieci neuronowej jako narzędzia wspomagającego interpretację zobrazowań georadarowych zostało potwierdzone.

3.3.3.2. Przykład zastosowań sieci neuronowych z przekształceniem Laplace'a

Klasyczna sieć neuronowa

Jeśli przyjmiemy że:

$$b_{*,1} = b_{*,2} = \dots = b_{*,\beta_i} = 0 \quad (62)$$

oraz

$$a_{*,1} = a_{*,2} = \dots = a_{*,\alpha_i} = 0 \quad (63)$$

i

$$\begin{aligned} b_{*,0} &\neq 0 \\ a_{*,0} &\neq 0 \end{aligned} \quad (64)$$


w równaniu:

$$G_i(s) = \frac{\sum_{l=0}^{\beta_i} b_{i,l} s^l}{\sum_{j=0}^{\alpha_i} a_{i,j} s^j} \quad (65)$$

gdzie $G_i(s)$ jest transmitancją dla i-tego wejścia neuronu z rysunku (Rysunek 2) i z równania (10), to neuron z przekształceniem Laplace'a staje się klasycznym neuronem z liniową funkcją przejścia. Czyli klasyczne sieci neuronowe są szczególnym przypadkiem sieci neuronowych z przekształceniem Laplace'a.

Sieci neuronowe i opóźnieniem czasowym

Znane z literatury sieci neuronowe z opóźnieniem czasowym, gdzie kolejne wejścia są opóźniane o czas d pokazano na rysunku (Rysunek 18).



Rysunek 18 Sieć neuronowa z opóźnieniem czasowym

Własność przesunięcia w czasie dla przekształcenia Laplace'a wyrażona jest następująco:

$$\mathcal{L}\{f(t - a)\} = e^{-as}F(s) \quad (66)$$

Stąd wynika, że powyższą sieć można opisać za pomocą sieci neuronowej z przekształceniem Laplace'a wyrażając to przesunięcie w postaci transmitancji Laplace'a przesunięcia czasowego, które wyrażone jest następująco:

$$T(s) = e^{-ds} \quad (67)$$

gdzie d jest czasem opóźnienia.

Dla m -tego opóźnienia mamy:

$$T_m(s) = e^{-mds} \quad (68)$$

Transmitancja i-tego wejścia sieci neuronowej z przekształceniem Laplace'a dla takiej sieci będzie następująca:

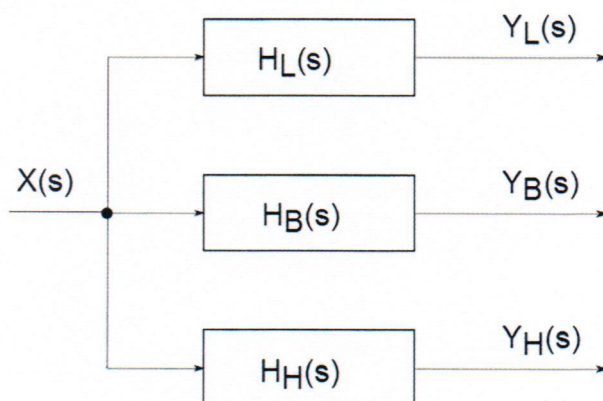
$$G_{T_m i}(s) = e^{-mds}G_i(s) \quad (69)$$

gdzie $G_i(s)$ jest oryginalną transmitancją (dla klasycznej sieci transmitancja ta będzie

współczynnikiem w postaci liczby rzeczywistej).

Filtr pasmowy

Możemy rozważyć użycie sieci neuronowej z przekształceniem Laplace'a jako filtra do podziału sygnału na 3 pasma częstotliwości (poniżej f_1 , między f_1 a f_2 oraz powyżej f_2). Na rysunku przedstawiono ideę takiego dzielnika.



Rysunek 19 Dzielnik częstotliwości na sieci neuronowej z przekształceniem Laplace'a

Transmitancja pasywnego dolnoprzepustowego filtra drugiego rzędu jest następująca:

$$H_L(s) = \frac{b_{L,0}}{a_{L,2}s^2 + a_{L,1}s + a_{L,0}} \quad (70)$$

Transmitancja pasywnego pasmowoprzepustowego filtra drugiego rzędu jest następująca:

$$H_B(s) = \frac{b_{B,0}s}{a_{B,2}s^2 + a_{B,1}s + a_{B,0}} \quad (71)$$

Transmitancja pasywnego górnoprzepustowego filtra drugiego rzędu jest następująca:

$$H_H(s) = \frac{b_{H,0}s^2}{a_{H,2}s^2 + a_{H,1}s + a_{H,0}} \quad (72)$$

Zwykle współczynniki $b_{*,0}$ oraz $a_{*,*}$ są wyznaczone analitycznie z założonych częstotliwości f_1 i f_2 . W przypadku sieci neuronowej z przekształceniem Laplace'a taki filtr można „nauczyć” jakie mają być te współczynniki.

Użycie sieci neuronowych z przekształceniem Laplace'a do tworzenia modeli gruntu z radargramu

Sygnał nadawany przez GPR ma następującą postać:

$$x(t) = \eta(\sin(\omega t) - \sin(\omega t - \tau)\mathcal{H}(\omega t - \tau)) \quad (73)$$

gdzie \mathcal{H} jest funkcją skoku jednostkowego (ang. Heaviside step function).

Transmitancja tego sygnału jest następująca:

$$X(s) = \mathcal{L}\{x(t)\} = \eta \left(\frac{\omega}{s^2 + \omega^2} \right) (1 - e^{-\tau s}) \quad (74)$$

Odbierany (odbity) sygnał może być aproksymowany przez wielomian:

$$y(t) = \sum_{i=0}^N a_i t^i \quad (75)$$

Na podstawie własności przekształcenia Laplace'a:

$$\mathcal{L}\{at^n\} = a \frac{n!}{s^{n+1}} \quad (76)$$

można uzyskać wzór na transformatę Laplace'a aproksymującego wielomianu:

$$Y(s) = \mathcal{L}\left\{ \sum_{i=0}^N a_i t^i \right\} = \sum_{i=0}^N a_i \frac{i!}{s^{i+1}} \quad (77)$$

Transmitancja (model) będzie w związku z tym następująca:

$$H(s) = \frac{Y(s)}{X(s)} = \frac{\sum_{i=0}^N a_i \frac{i!}{s^{i+1}}}{\eta \left(\frac{\omega}{s^2 + \omega^2} \right) (1 - e^{-\tau s})} \quad (78)$$

Na podstawie zarejestrowanych sygnałów GPR dla struktury bez anomalii można wyznaczyć następującą transmitancję:

$$H_{WA}(s) = \frac{Y_{WA}(s)}{X(s)} \quad (79)$$

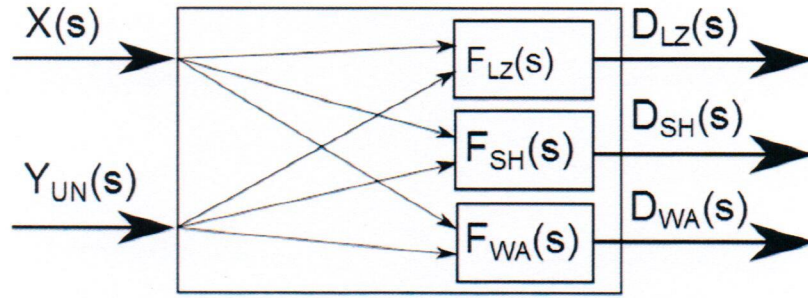
Na podstawie zarejestrowanych sygnałów GPR dla struktury z pustką można wyznaczyć następującą transmitancję:

$$H_{SH}(s) = \frac{Y_{SH}(s)}{X(s)} \quad (80)$$

Na podstawie zarejestrowanych sygnałów GPR dla struktury ze strefą rozluźnień można wyznaczyć następującą transmitancję:

$$H_{LZ}(s) = \frac{Y_{LZ}(s)}{X(s)} \quad (81)$$

Można zbudować sieć neuronową z przekształceniem Laplace'a, która będzie rozpoznawała typ anomalii (pustka, obszar rozluźnień) tak jak to pokazano na rysunku (Rysunek 20).



Rysunek 20 Sieć LTANN do rozpoznawania anomalii geologicznych

$X(s)$ - sygnał nadawany,

$Y_{UN}(s)$ - sygnał odbierany dla nieznanej struktury geologicznej,

$F_{WA}(s)$ - transmitancja reprezentująca strukturę bez anomalii,

$F_{SH}(s)$ - transmitancja reprezentująca strukturę z pustką,

$F_{LZ}(s)$ - transmitancja reprezentująca strukturę ze strefą rozluźnień,

$D_{WA}(s)$ - różnica w transmitancji reprezentująca nieznaną strukturę i strukturę bez anomalii,

$D_{SH}(s)$ - różnica w transmitancji reprezentująca nieznaną strukturę i strukturę z pustką,

$D_{LZ}(s)$ - różnica w transmitancji reprezentująca nieznaną strukturę i strukturę ze strefą rozluźnień,

Stąd można napisać:

$$F_{WA}(s) = \begin{bmatrix} H_{WA}(s) & 0 \\ 0 & -1 \end{bmatrix} \quad (82)$$

$$F_{SH}(s) = \begin{bmatrix} H_{SH}(s) & 0 \\ 0 & -1 \end{bmatrix} \quad (83)$$

$$F_{LZ}(s) = \begin{bmatrix} H_{LZ}(s) & 0 \\ 0 & -1 \end{bmatrix} \quad (84)$$

$$D_{WA}(s) = H_{WA}(s)X(s) - Y(s) \quad (85)$$

$$D_{SH}(s) = H_{SH}(s)X(s) - Y(s) \quad (86)$$

$$D_{LZ}(s) = H_{LZ}(s)X(s) - Y(s) \quad (87)$$

Różnica pomiędzy modelem znanej struktury geologicznej, a nieznanym (badanym) modelem daje możliwość jej klasyfikacji.

Zastosowanie sieci LTANN do analizy radargramów

Sieci neuronowe z przekształceniem Laplace'a można również wykorzystać do analizy radargramów w nieco inny sposób niż to przedstawiono w uprzednio. Radargram będący wynikiem pomiarów GPR jest zbiorem wartości dyskretnych amplitudy odbitej fali dla kolejnych ścieżek pomiarowych. Na

podstawie tych wartości można wyznaczyć wielomiany aproksymujące te przebiegi, co pokazano w tabeli (Tabela 6).

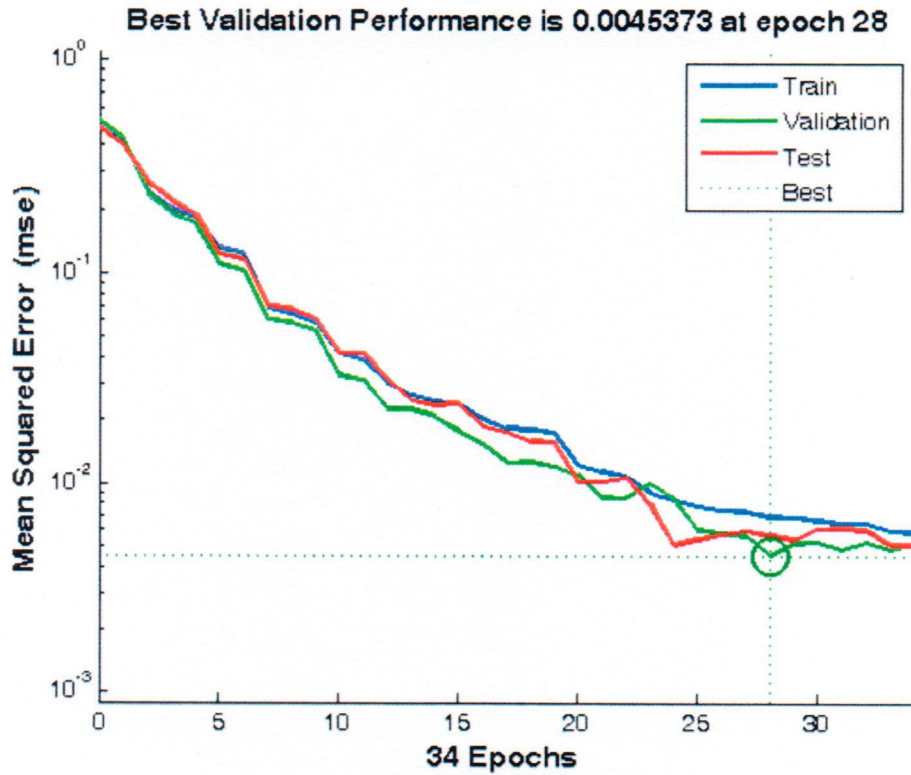
Tabela 6 Współczynniki a_i dla 4-rech pierwszych wielomianów

Współczynniki	Wielomian				
	P_1	P_2	P_3	P_4	...
a_0	-0,36407	-0,36321	-0,74577	-0,69961	...
a_1	0,49535	0,52057	0,86788	0,80945	...
a_2	4,76018	4,69878	9,99935	9,38168	...
a_3	-6,27714	-6,56136	-11,1733	-10,4053	...
a_4	-26,1438	-25,5040	-56,5006	-53,0456	...
a_5	33,1326	34,4399	60,0536	55,8612	...
a_6	78,5906	75,6643	175,237	164,731	...
a_7	-94,6055	-97,7644	-174,966	-162,631	...
a_8	-141,268	-134,017	-325,638	-306,709	...
a_9	158,906	163,196	300,292	279,054	...
a_{10}	155,721	145,311	371,343	350,669	...
a_{11}	-159,948	-163,175	-308,891	-287,129	...
a_{12}	-103,629	-94,9225	-255,510	-242,054	...
a_{13}	94,0281	95,2228	185,222	172,306	...
a_{14}	39,1846	35,1280	99,8797	94,9579	...
a_{15}	-29,846	-29,9676	-59,7272	-55,6176	...
a_{16}	-7,37107	-6,43267	-19,5023	-18,6071	...
a_{17}	4,29675	4,26638	8,68186	8,08658	...
a_{18}	0,51298	0,43071	1,43283	1,37089	...
a_{19}	-0,17833	-0,17403	-0,36188	-0,33565	...
a_{20}	0,03713	0,03820	0,03208	0,03705	...


Z przeprowadzonych eksperymentów wynika, że wartość stopnia wielomianu aproksymującego z równania (77) równa 20 jest optymalna, ponieważ wpływ wyższych stopni jest zaniedbywalny.

Znając miejsce położenia anomalii możemy podzielić wyznaczone w powyższy sposób transformaty na dwa zbiory: z anomaliami i bez anomalii. Uzyskane w ten sposób zbiory posłużą do uczenia sieci rozpoznawania anomalii. Do uczenia użyto 645 przebiegów, z kolei podzielonych na trzy części: 70% to zbiór uczący, 15% zbiór do walidacji oraz pozostałe 15% to zbiór testowy.

Rezultaty uczenia pokazano na rysunkach (Rysunek 21) i (Rysunek 22) oraz w tabelach (Tabela 7), (Tabela 8), (Tabela 9) i (Tabela 10).



Rysunek 21 Przebieg zmian błędów w trakcie procesu uczenia dla sieci LTANN



Rysunek 22 Histogram błędów w sieci LTANN w końcowym etapie uczenia

Tabela 7 Macierz uczenia dla sieci LTANN

		Docelowa klasa		
		0	1	X
Wyjściowa klasa	0	242	0	100 %
		53,7 %	0,0 %	0,0 %
	1	29	180	86,1 %
		6,4 %	39,9 %	13,9 %
	X	89,3 %	100 %	93,6 %
		10,7 %	0,0 %	6,4 %

Tabela 8 Macierz walidacji dla sieci LTANN

		Docelowa klasa		
		0	1	X
Wyjściowa klasa	0	46	0	100 %
		47,4 %	0,0 %	0,0 %
	1	12	39	76,5 %
		12,4 %	40,2 %	23,5 %
	X	79,3 %	100 %	87,6 %
		20,7 %	0,0 %	12,4 %

Tabela 9 Macierz testów dla sieci LTANN

		Docelowa klasa		
		0	1	X
Wyjściowa klasa	0	51	1	98,1 %
		52,6 %	1,0 %	1,9 %
	1	4	41	91,1 %
		4,1 %	42,3 %	8,9 %
	X	92,7 %	97,6 %	94,8 %
		7,3 %	2,4 %	5,2 %

Tabela 10 Macierz całościowa dla sieci LTANN

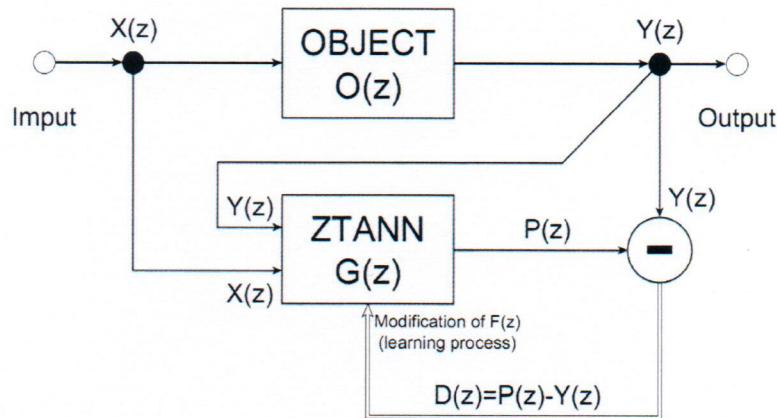
		Docelowa klasa		
		0	1	X
Wyjściowa klasa	0	339	1	99,7 %
		52,6 %	0,2 %	0,3 %
	1	45	260	85,2 %
		7,0 %	40,3 %	14,8 %
	X	88,3 %	99,6 %	92,9 %
		11,7 %	0,4 %	7,1 %

Jak pokazują wyniki sieć neuronowa z przekształceniem Laplace'a z dużą skutecznością rozpoznaje anomalie geologiczne.

3.3.3.3. Przykład zastosowań sieci neuronowych z przekształceniem Z

Bardzo ważnym problemem w dziedzinie cyfrowych systemów sterowania jest automatyczne określenie własności sterowanego obiektu. Wiedza ta jest potrzebna do dokonania właściwego wyboru algorytmów sterowania. Problem ten może być rozwiązany poprzez identyfikację obiektu. Ponieważ transmitancja Z obiektu opisuje jego własności, więc zadanie to sprowadza się do jej wyznaczenia. Rysunek (Rysunek 23) pokazuje ideę procesu identyfikacji transmitancji Z obiektu przy użyciu sieci neuronowej z przekształceniem Z.

Wejściowy sygnał $x[n]$ o transformacie $X[z]$ jest wprowadzany na obiekt, który odpowiada sygnałem wyjściowym $y[n]$ o transformacie $Y[z]$. Przekształcenie sygnału wejściowego w wyjściowy jest określone przez transmitancję $O[z]$ obiektu. Sieć neuronowa z przekształceniem Z (ZTANN) rejestruje obydwa sygnały i na tej podstawie w każdym kroku czasu oblicza transmitancję $G[z]$, która aproksymuje transmitancję obiektu $O[z]$. Błąd jest obliczany na podstawie różnicy sygnału wyjściowego z sieci oraz z obiektu.



Rysunek 23 Sieć neuronowa z przekształceniem Z do automatycznej identyfikacji obiektów w systemie sterowania

Z definicji przekształcenia Z wynika:

$$F(z) = Z\{f[n]\} = \sum_{n=0}^{\infty} f[n]z^{-n} \quad (88)$$

co można zapisać również w postaci następującego równania:

$$F(z) = \sum_{n=0}^m f[n]z^{-n} + \sum_{n=m+1}^{\infty} f[n]z^{-n} \quad (89)$$

Można zdefiniować następującą funkcję:

$$f'_m[n] = \begin{cases} f[n] & \text{dla } 0 \leq n \leq m \\ 0 & \text{dla } m < n \end{cases} \quad (90)$$

Transformata Z dla tej funkcji będzie następująca:

$$F'_m(z) = \mathcal{Z}\{f'_m[n]\} = \sum_{n=0}^m f[n]z^{-n} \quad (91)$$

Jeśli wstawimy równanie (91) do równania (89) to otrzymamy:

$$F(z) = F'_m(z) + \sum_{n=m+1}^{\infty} f[n]z^{-n} \quad (92)$$

Transformata $F'_m(z)$ dąży do $F(z)$ gdy m dąży do nieskończoności:

$$F(z) = \lim_{m \rightarrow \infty} F'_m(z) \quad (93)$$

Transformata $F'_{m+1}(z)$ może być obliczona na podstawie $F'_m(z)$ oraz $f[m+1]$:

$$F'_{m+1}(z) = F'_m(z) + f[m+1]z^{-(m+1)} \quad (94)$$

Transmitancja obiektu:

$$O(z) = \frac{Y(z)}{X(z)} \quad (95)$$

Można wprowadzić oznaczenie transmitancji sieci neuronowej z przekształceniem Z w i -tym kroku uczenia:

$$G'_i(z) = \frac{Y'_i(z)}{X'_i(z)} \quad (96)$$

Transmitancja sieci neuronowej z przekształceniem Z w $(i+1)$ kroku uczenia:

$$G'_{i+1}(z) = \frac{Y'_i(z) + y[i+1]z^{-(i+1)}}{X'_i(z) + x[i+1]z^{-(i+1)}} \quad (97)$$

Transmitancja $G'_i(z)$ dąży do $G(z)$ gdy i dąży do nieskończoności:

$$O(z) = \lim_{i \rightarrow \infty} G'_i(z) = G(z) \quad (98)$$

Transformatę Z sygnału wyjściowego z sieci neuronowej z przekształceniem Z z rysunku (Rysunek 23) można zapisać:

$$P(z) = G(z)X(z) \quad (99)$$

Sygnał błędu z rysunku (Rysunek 23) można zapisać:

$$D(z) = P(z) - Y(z) \quad (100)$$

Po wstawieniu równania (95) i (99) do równania (100) otrzymujemy:

$$D(z) = [G(z) - O(z)]X(z) \quad (101)$$

Błąd w i -tym kroku uczenia będzie wynosił:

$$D'_i(z) = [G'_i(z) - O(z)]X(z) \quad (102)$$

Błąd dąży do zera gdy i dąży do nieskończoności:

$$D(z) = \lim_{i \rightarrow \infty} D'_i(z) = 0 \quad (103)$$

Jako wynik otrzymujemy aproksymację transmitancji identyfikowanego obiektu, która jest coraz bardziej dokładna w miarę upływu czasu – procesu uczenia sieci. Dla wielu obiektów już po kilku krokach będziemy otrzymywać transmitancję na tyle dokładną aby mogła być użyta w systemach sterowania jako dobra informacja o obiekcie.

4. Pozostałe osiągnięcia naukowe – badawcze

4.1. Statystyki bibliometryczne

Łączny impact factor:	9,8 (10,8 [*])
Łączny impact factor po uwzględnieniu podziału pomiędzy współautorów:	5,74 (6,74 [*])
Liczba cytowań według Web of Science:	9
Indeks h według Web of Science:	2
Liczba cytowań według Google Scholar (wszystkie):	49
Indeks h według Google Scholar (wszystkie):	4
Suma punktów MNiSW:	342 (367 [*])
Suma punktów MNiSW po uwzględnieniu podziału pomiędzy współautorów:	167,67 (192,67 [*])
Liczba publikacji:	81 (82 [*])
Liczba publikacji po uzyskaniu stopnia doktora:	75 (76 [*])
Liczba publikacji z impact factor:	6 (7 [*])
Liczba książek i monografii:	2

(^{*}) – z artykułem będącym w druku

4.2. Kierowanie krajowymi projektami badawczymi lub udział w takich projektach

Kierowanie projektem:

- Analiza cyfrowych danych georadarowych przy użyciu komputerowego przetwarzania i rozpoznawania obrazów dla oceny stanu technicznego wałów przeciwpowodziowych oraz wykrywania niebezpiecznych zmian w strefach przypowierzchniowych ośrodka geologicznego (NCN - UMOWA Nr UMO-2011/01/B/ST7/06178)

Udział w projektach:

- Inteligentne, energooszczędne systemy sterowania orientowanymi systemami solarnymi (NCN – UMOWA Nr 6693/B/T02/2011/40)
- Udział w projekcie: System inteligentnego monitoringu przestrzeni i obiektów szczególnego znaczenia – SIMPOZ (grant z Ministerstwa Nauki i Szkolnictwa Wyższego nr 0128/R/t00/2010/12)

4.3. Referaty i postery na konferencjach tematycznych

- Cybernetic Modeling of Biological Systems (MCSB) 2015
- Przetwarzanie i analiza sygnałów w systemach wizji i sterowania SŁOK 2013
- Przetwarzanie i analiza sygnałów w systemach wizji i sterowania SŁOK 2012
- Systemy Czasu Rzeczywistego 2011
- XIX Międzynarodowe Sympozjum Zastosowania Teorii Systemów 2011
- Systemy Czasu Rzeczywistego 2010
- Systemy Czasu Rzeczywistego 2009

- Systemy Czasu Rzeczywistego 2006
- 5-th Conference on Computer Methods and Systems 2005
- XVI Międzynarodowe Sympozjum Zastosowania Teorii Systemów 2005
- Systemy Czasu Rzeczywistego 2005
- 12th MIXDES Conference 2005
- Systemy Czasu Rzeczywistego 2004
- 10th IEEE International Conference on Methods and Models in Automation and Robotics 2004
- International Carpathian Control Conference - ICC2004
- 6th International Scientific - Technical Conference Process Control 2004
- Systemy Czasu Rzeczywistego 2003
- XV Międzynarodowe Sympozjum Zastosowania Teorii Systemów 2003
- International Carpathian Control Conference - ICC2003
- IV Krajowa Konferencja „Metody i systemy komputerowe w badaniach naukowych i projektowaniu inżynierskim” 2003
- Systemy Czasu Rzeczywistego 2002
- International Carpathian Control Conference - ICC2002
- Systemy Czasu Rzeczywistego 2001
- XIV Międzynarodowe Sympozjum Zastosowania Teorii Systemów 2001
- International Carpathian Control Conference - ICC2001
- Systemy Czasu Rzeczywistego 1999
- XIII Międzynarodowe Sympozjum Zastosowania Teorii Systemów 1999
- I Krajowa Konferencja „Metody i systemy komputerowe w badaniach naukowych i projektowaniu inżynierskim” 1997

4.4. Nagrody za działalność naukową

- Nagroda rektorska indywidualna II stopnia za osiągnięcia naukowe, 2016
- Nagroda rektorska indywidualna III stopnia za osiągnięcia naukowe, 2011
- Nagroda rektorska II stopnia za osiągnięcia naukowe, 1998

4.5. Udział w komitetach organizacyjnych konferencji naukowych

- KES-2015 19th Annual International Conference on Knowledge-Based and Intelligent Information & Engineering Systems, Singapore 7, 8 & 9 Sept. 2015
- KES IDT 2015 INTELLIGENT DECISION TECHNOLOGIES - SMART DIGITAL FUTURES 2015 Sorrento, Italy 17-19 June 2015
- Komitet Programowy Konferencji „Systemy Czasu Rzeczywistego” 2004
- Komitet Programowy Konferencji „Systemy Czasu Rzeczywistego” 2003
- Komitet Programowy Konferencji „Systemy Czasu Rzeczywistego” 2002
- Komitet Programowy Konferencji „Systemy Czasu Rzeczywistego” 2001
- Komitet Programowy Konferencji „Systemy Czasu Rzeczywistego” 2000

4.6.Członkostwo w organizacjach i towarzystwach naukowych

- Polska Akademia Nauk Oddział w Krakowie - członek Komisji Ergonomicznej
- Polskie Towarzystwo Sieci Neuronowych
- Polskie Towarzystwo Matematyczne, Oddział Krakowski
- Polskie Towarzystwo Informatyczne
- Polskie Towarzystwo Ergonomiczne

4.7.Osiągnięcia dydaktyczne w zakresie popularyzacji nauki

Popularyzacja wiedzy w zakresie projektu pt.: „Analiza cyfrowych danych georadarowych przy użyciu komputerowego przetwarzania i rozpoznawania obrazów dla oceny stanu technicznego wałów przeciwpowodziowych oraz wykrywania niebezpiecznych zmian w strefach przypowierzchniowych ośrodka geologicznego”:

- Wywiad „na żywo” w Radiu Kraków
- Wywiad dla Informacyjnej Agencji Radiowej (IAR)
- Wywiad w TVP 1 (główne Wiadomości o 19:30)
- Wywiad w TVN 24 (2 emisje)
- Wywiad w Dzienniku Polskim - 03.10.2012

4.8.Udział w zespołach eksperckich i konkursowych

- Zespół ekspertów zewnętrznych ds. analiz Delphi Narodowego Programu Foresight Polska 2020.
- Grono ekspertów OPI (eCentrum) (NCBiR)

4.9.Recenzowanie projektów międzynarodowych lub krajowych oraz publikacji w czasopiśmie międzynarodowych i krajowych

- Publikacje w czasopiśmie “International Journal of Applied Mathematics and Computer Science” (Impact Factor: 1.390), ISSN: 1641-876X
- Publikacje w czasopiśmie „Expert Systems with Applications” (Impact Factor: 2.240, ISSN: 0957-4174)
- Publikacje w czasopiśmie „Neural Computing and Applications” (Impact Factor: 1.569, ISSN: 0941-0643)
- Publikacje w czasopiśmie „Automation in Construction” (Impact Factor: 1.812 , ISSN: 0926-5805)
- Publikacje w czasopiśmie „Applied Energy” (Impact Factor: 5.613, ISSN: 0306-2619)
- Publikacje w czasopiśmie „Journal of Health & Medical Informatics” (Impact Factor: 1.98, ISSN: 2157-7420)

- Publikacje w czasopiśmie „Przegląd Elektrotechniczny” (ISSN 0033-2097)
- Referaty i materiały konferencyjne Konferencji KES IDT 2015 INTELLIGENT DECISION TECHNOLOGIES
- Referaty i materiały konferencyjne Konferencji „Systemy Czasu Rzeczywistego” 2004
- Referaty i materiały konferencyjne Konferencji „Systemy Czasu Rzeczywistego” 2003
- Referaty i materiały konferencyjne Konferencji „Systemy Czasu Rzeczywistego” 2002
- Referaty i materiały konferencyjne Konferencji „Systemy Czasu Rzeczywistego” 2001
- Referaty i materiały konferencyjne Konferencji „Systemy Czasu Rzeczywistego” 2000

4.10. Opieka nad kołem naukowym

Koło naukowe SCR-RTS przy Katedrze Automatyki, Zakładzie Zastosowań Informatyki na Wydziale Elektrotechniki Automatyki Informatyki i Elektroniki Akademii Górniczo – Hutniczej w Krakowie w latach 2009 – 2011.

4.11. Prace dyplomowe

4.11.1. Prace magisterskie

- Analiza porównawcza współczesnych języków programowania na przykładach języków Java, C# i C++
- Energooszczędne systemy wbudowane na mikrokontrolerach ARM Cortex M3 z wykorzystaniem systemu operacyjnego czasu rzeczywistego
- Rozpoznawanie obrazów z wykorzystaniem technologii GPGPU i CUDA
- Interfejs pomiarowy współpracujący z oprogramowaniem MATLAB
- Systemy wbudowane o niskim poborze mocy zasilania
- Rozpoznawanie kształtów z wykorzystaniem sieci neuronowych i technologii GPGPU OPEN_CL
- Mikrokontrolerowy sterownik położenia ogniw fotowoltaicznych
- Lokalizacja nadajników w bezprzewodowych sieciach ZigBee
- Algorytmy szeregujące procesy w systemach czasu rzeczywistego
- Symulator systemu operacyjnego czasu rzeczywistego
- Mechanizmy czasu rzeczywistego w systemach Windows CE i Windows NT
- Rozszerzenie protokołu SNMP o nowe możliwości czasu rzeczywistego dla systemu RT_Linux
- Internetowy zdalny system egzaminacyjny
- Wbudowany Internet z dynamiczną reprezentacją danych
- Edytor sieci Petriego
- Rozszerzenie protokołu SNMP w systemach czasu rzeczywistego
- Graficzne środowisko projektowania aplikacji czasu rzeczywistego dla systemu VxWorks

4.11.2. Prace inżynierskie

- Regulator ogniw fotowoltaicznych
- Monitorowanie zasilania wózka inwalidzkiego
- Współczesne systemy sterowania w samochodzie
- Przedstawienie strategii w grach niełosowych o sumie zerowej
- Kontrola dostępu z wykorzystaniem kart RFID
- Sterownik przenośnika taśmowego
- Sterownik silnika DC za pomocą mikrokontrolera
- Układ pomiaru i prezentacji napięcia, prądu i mocy
- Lokalizator położenia z wykorzystaniem sieci bezprzewodowej i fali dźwiękowej
- Interfejsy komunikacyjne mikrokontrolerów w systemach wbudowanych
- Specjalistyczny system radiowy do obsługi zawodów sportowo-pożarniczych
- Lokalizacja pojazdu w oparciu o technologię GPS i GSM
- Lokalizator położenia zrealizowany w technologii GPS i GPRS
- Stacja pogodowa z komunikacją ZigBee
- Sterowanie platformą mobilną za pomocą mikrokontrolera
- Sterownik orchidarium
- Analiza wydajności baz danych na podstawie testów znanych darmowych aplikacji PHP
- Zdalna obsługa wieżyczki strzelniczej
- Sterownik akwarystyczny
- Bezprzewodowe sieci w systemach wbudowanych
- Mikrokontrolery czasu rzeczywistego
- Mikrokontrolery w systemach wbudowanych
- Bezprzewodowy system sterowania i pomiaru mocy czynnej urządzeń
- System operacyjny FreeRTOS w systemach wbudowanych
- Energooszczędne systemy wbudowane oparte na mikrokontrolerach ARM
- Mikroprocesorowy regulator parametrów wody w uprawach hydroponicznych

4.12. Prowadzone przedmioty

- Systemy operacyjne czasu rzeczywistego
- Podstawy użytkowania systemów operacyjnych
- Komputerowe systemy sterujące
- Informatyka czasu rzeczywistego
- Informatyka
- Techniki mobilne
- Algorytmy i struktury danych
- Modelowanie systemów
- Techniki komunikacji w organizacjach gospodarczych

- Zarządzanie informacją
- Systemy operacyjne Unix / Linux
- Systemy operacyjne

4.13. Pozostała działalność dydaktyczna

W latach 2011- 2012 prowadziłem Wirtualne Koło Naukowe Informatyki dla gimnazjalistów z całej Polski w ramach projektu e-Akademia Przyszłości.

4.14. Działalność organizacyjna po uzyskaniu stopnia doktora

- Komisja Rekrutacyjna
- Dzień otwarty Wydziału EAIiE - wykład "Bezprzewodowe systemy wbudowane - automatyka w twoim domu" - 26.11.2010
- Dni otwarte AGH - wykład "Jakość światła" - 17.04.2015
- Dni otwarte AGH - wykład "Jakość światła" - 15.04.2016

4.15. Inne osiągnięcia

- Uzyskanie certyfikatu National Instruments CLAD (numer 100-316-10019)
- Recenzja i opinia dla wydawnictwa Elsevier na temat wydania książki

