

FILTROWANIE DANYCH POMIAROWYCH PRZY WYKORZYSTANIU ANALIZY FALKOWEJ I SZTUCZNYCH SIECI NEURONOWYCH

JOLANTA TALAR, ŁUKASZ RAUCH, JAN KUSIAK

FILTERING OF THE EXPERIMENTAL DATA USING THE WAVELET ANALYSIS AND THE ARTIFICIAL NEURAL NETWORKS

Abstract

The analysis of experimental measurements is sometimes difficult, if the registered data are superimposed by noisy signals. The source of such noise is often the improper sensitivity calibration of measuring devices. Sometimes, such data are even useless for the further analysis. Therefore, the goal of the present paper is an attempt of application of two different filtering techniques, including the artificial intelligence methods (artificial neural networks) to the filtering of the noisy experimental data. Examples of filtering results using described techniques are presented.

Keywords: signal filtering, wavelet analysis, artificial neural networks

1. WPROWADZENIE

W praktyce doświadczalnej wyniki badań są często obciążone zakłóceniami w postaci szumu pomiarowego. Szum ten jest efektem działania zewnętrznych czynników zakłócających lub zbyt dużej czułości urządzeń rejestrujących. Prawidłowe odfiltrowanie wyników badań pozwala na odzyskanie, często kosztownych danych. Konwencjonalne metody filtrowania wyników pomiarów (Montgomery i in., 1976) są uciążliwe, a ich rezultat jest zależny od przyjętych subiektywnie parametrów. W pracy podjęto próbę wykorzystania analizy

falkowej i sztucznych sieci neuronowych (Kusiak i in., 2001) do filtrowania danych pomiarowych próby spęczania metali. Celem próby spęczania jest uzyskanie krzywej umocnienia opisującej zależność naprężenia uplastyczniającego odkształcanego metalu od parametrów odkształcenia takich jak wielkość odkształcenia, prędkość odkształcenia, temperatura, itp. Od prawidłowego opisu krzywej umocnienia odkształcanego metalu zależy dokładność symulacji komputerowej procesów plastycznej przeróbki metali.

Przykładowe wyniki próby spęczania obciążone różnego rodzaju szumem pomiarowym przedstawiono

na rysunku 1. Wyniki te są bezużyteczne do bezpośredniego wykorzystania w analizie numerycznej procesu odkształcenia. W klasycznym podejściu do analizy zniekształconych danych pomiarowych najczęściej stosuje się prostą aproksymację zarejestrowanych wartości. Jednakże jest to zadanie trudne z uwagi na różnorodny charakter szumu nałożonego na właściwe wartości pomiarowe. Filtrowanie wymaga najczęściej opracowania dodatkowych programów, tak zwanych preprocesorów, które pozwalają na wyeliminowanie sygnałów zakłócających. Poprawność działania programów filtrujących uzależniona jest z kolei od właściwie przyjętych kryteriów oceny istotności pomiarów, opartych najczęściej na analizie regresyjnej i ocenie korelacji zarejestrowanych wyników.



W ramach niniejszej pracy podjęto próbę wykorzystania analizy falkowej oraz sztucznych sieci neuronowych do filtrowania danych pomiarowych uzyskanych w próbie śpężania.

2. METODY FILTROWANIA

2.1. Analiza falkowa

Analiza falkowa (AF) jest szeroko stosowanym podejściem przetwarzania sygnałów. Metoda ta wywodzi się z tradycyjnych metod dekompozycji sygnałów Fouriera. Same falki, podobnie jak funkcje trygonometryczne w transformacji Fouriera, są funkcjami matematycznymi określonymi na odpowiednim przedziale. Przedział oraz amplituda funkcji falkowych zależna jest od przyjętej skali (poziomu dekompozycji) oraz przesunięcia. Dzięki wprowadzeniu procesu skalowania na każdym z poziomów analizy, falki posiadają dogodną własność tzw. samopodobieństwa. Cecha ta daje falkom sporą przewagę nad innymi metodami, ponieważ dobrze zaprojektowana w ten sposób baza transformacji jest bazą funkcji ortogonalnych, co umożliwia łatwą analizę sygnałów niestacjonarnych (Białasiewicz, 2000).

Najogólniej ujmując, wyróżnić można dwa typy dekompozycji falkowych, tzw.: analiza dyskretna oraz ciągła. Biorąc pod uwagę charakter danych wejściowych w przypadku odszumiania sygnałów, najważniejszą rolę odgrywa analiza dyskretna – *discrete wavelet analysis* (DWT). Rozwiązanie to zaprojektowane zostało jako alternatywa dla transformaty *short time Fourier transform* (STFT), w której stosowana jest stała rozdzielczość czasowa dla wszystkich częstotliwości w sygnale. Natomiast podejście DWT wprowadza zmienną rozdzielczość czasową – wysoką dla niskich częstotliwości oraz odwrotnie – niską dla wysokich częstotliwości. W ten sposób cały sygnał próbkowany jest różnej wielkości falkami tak, aby wszystkie składowe częstotliwościowe zostały uchwycone. Zastosowanie tej



Rysunek 1. Przykładowe wyniki pomiarów obarczone różnego rodzaju szumem pomiarowym z próby śpężania: (a) - siła w funkcji przemieszczenia, (b) - naprężenie w funkcji odkształcenia logarytmicznego.

własności staje się bardzo istotne w technice zwanej *wavelet shrinkage and thresholding*.

Celem powyższej metody jest likwidacja szumów $n(t)$ z sygnału $s(t)$, aby osiągnąć oryginalny odszumiony sygnał $o(t)$, gdzie $s(t) = o(t) + n(t)$. Pierwszym etapem omawianej metody jest dekompozycja sygnału wejściowego $s(t)$ za pomocą techniki DWT. Sygnał zostaje podzielony na L poziomów dekompozycji w następujący sposób (He, 1998):

$$s(t) = \sum_{j=1}^L \sum_k d_j(k) \psi_j(t) + \sum_k c_L(k) \phi_L(t) \quad (1)$$

gdzie: $\phi_L(t)$ jest funkcją skalującą L -tego poziomu, natomiast $\psi_j(t)$ dla $j = 1..L$ są funkcjami falkowymi dla L różnych poziomów. Wynikiem niniejszych obliczeń jest L częściowy zbiór współczynników dekompozycji $c_L(k)$ i $d_j(k)$ dla dwóch wyżej wymienionych funkcji, przy czym przyjmuje się, iż najniższy poziom (najwyższa skala) odpowiada dyskretnemu sygnałowi wejściowemu $c_0(k) = s(k)$. Powyższy wzór jest rozwinięciem rekurencyjnego sposobu obliczania współczynników dekompozycji poprzez nakładanie filtrów nisko- i wysokopasmowych (odpowiednio funkcje h i g) na kolejne iteracje sygnałów, co przedstawiono na rysunku 2, gdzie: M – oznacza najwyższą częstotliwość w sygnale.

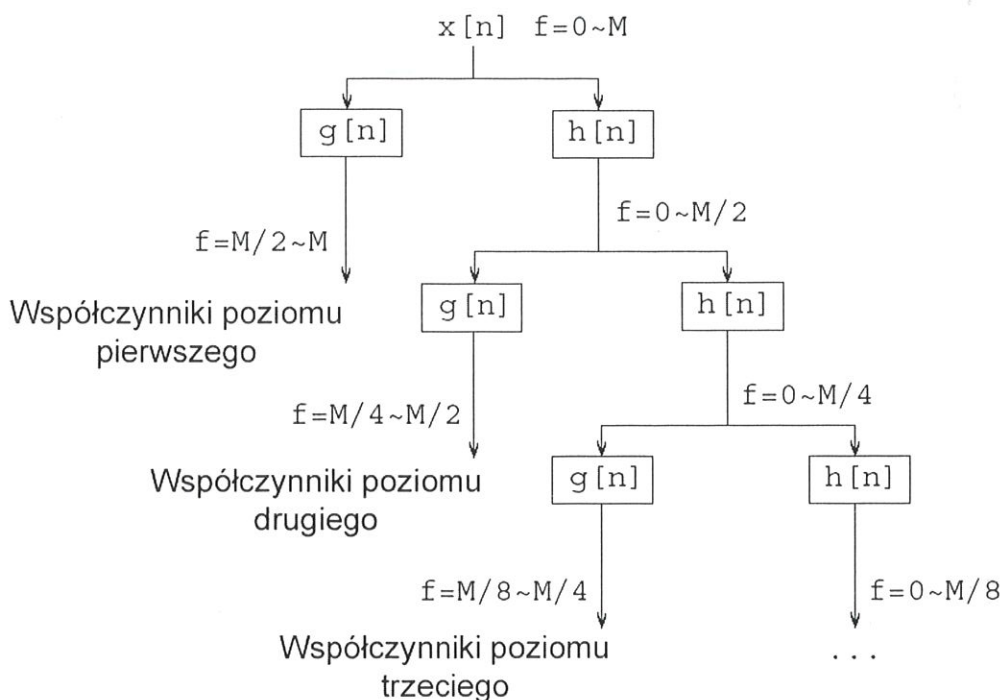
Metoda dekompozycji sygnału DWT jest dosyć specyficzną metodą odwracalnej transformacji sygnału. Oznacza to, iż po zakończeniu procesu dekompozycji otrzymujemy L poziomów współczynników, które w procesie odwrotnym dadzą w rezultacie zaszumiony pierwotny sygnał wejściowy. Zatem w celu redukcji szumów $n(t)$ w takim sygnale, należy wyzerować odpowiednie współczynniki dekompozycji dla wyższych częstotliwości w taki sposób, aby w procesie syntezy sygnału sumy iloczynów współczynników i funkcji falkowych równe były zero. Założenie to osiąga się poprzez ustalenie granicy progowych dla każdego z poziomów dekompozycji, dzięki czemu wszystkie współczynniki, których wartości mniejsze są od granic

progowych, zostają wyzerowane. Redukcja szumów w sygnale wejściowym jest transformacją nieodwracalną zwracającą odfiltrowany sygnał wejściowy.

Dzięki wykorzystaniu dekompozycji czasowo-częstotliwościowej analiza falkowa wydaje się być metodą dość uniwersalną, co pozwala na zastosowanie jej do rozwiązywania problemów o różnym stopniu złożoności. W naszym przypadku oznacza to, iż analizie mogą być poddane sygnały o różnym stopniu zaszumienia. Progi na każdym z poziomów dekompozycji mają wpływ na poziom redukcji szumu. Natomiast jakość procesu odszumiania określić można dzięki analizie wielorozdzielczej (rysunek 2) poprzez ustalenie odpowiedniej liczby poziomów dekompozycji. Należy zwrócić uwagę na fakt, iż w celu przeprowadzenia analizy falkowej bezwzględny wymaganie jest występowanie jednakowych kroków czasowych pomiędzy poszczególnymi pomiarami. Wymaganie to można spełnić poprzez przyjęcie określonej dokładności pomiarów, a następnie ich zagęszczenie wykorzystując metodę interpolacji.

2.2. Sztuczne sieci neuronowe

Sztuczne sieci neuronowe (SSN) są coraz częściej stosowanym narzędziem do rozwiązywania wielu złożonych problemów, w tym inżynierskich (Tadeusiewicz, 1993; Masters, 1996; Osowski, 1996; Żurada i in., 1996). SSN powstały na gruncie wiedzy o działaniu systemu nerwowego istot żywych i stanowią próbę wykorzystania analogii zjawisk zachodzących w syste-



Rysunek 2. Analiza wielorozdzielcza za pomocą filtrów nisko- i wysokopasmowych.



mach nerwowych do rozwiązywania złożonych zadań, w tym również problemów inżynierskich. Podstawową własnością SSN jest zdolność do przyswajania wiedzy na podstawie prezentowanych przykładów, oraz zdolność do uogólnień, które pozwalają na ich zastosowanie do nowych sytuacji - przypadków, nie występujących w zbiorze uczącym. Ponadto SSN dobrze radzą sobie z danymi niekompletnymi i zakłóconymi. Charakteryzują się dużą szybkością działania, co kwalifikuje je do zastosowań w systemach czasu rzeczywistego. SSN stanowią również skuteczne narzędzie do modelowania procesów.

Zasada działania sztucznego neuronu oparta jest na działaniu biologicznej komórki nerwowej. Zadaniem neuronu jest wygenerowanie odpowiedniego sygnału wyjściowego, w zależności od informacji jaka dociera do niego w postaci sygnałów wejściowych. Sygnały wejściowe $x_i, i = 1, \dots, n$, po przemnożeniu przez współczynniki wagowe w_i są sumowane tworząc sygnał s . Następnie sygnał ten ulega modyfikacji w bloku aktywacji i na wyjściu neuronu otrzymywany jest sygnał wyjściowy $y = f(s)$. Generowany sygnał wyjściowy y powinien odpowiadać założonej wielkości oczekiwanej. Osiągnąć to można poprzez odpowiedni dobór wartości współczynników wagowych w_i . Dobór tych współczynników dokonywany jest w procesie uczenia neuronu. Podczas etapu uczenia na wejście komórki neuronowej podawane są sygnały, dla których znane są oczekiwane wielkości wyjściowe y_o . Zadaniem etapu uczenia neuronu jest zminimalizowanie odchyłki pomiędzy sygnałem wyjściowym y , a jego wartością oczekiwaną y_o , poprzez odpowiedni dobór współczynników wagowych w_i . Nauczony w ten sposób neuron potrafi następnie samodzielnie rozpoznawać sygnały wejściowe i generować odpowiadający im sygnał wyjściowy. Sztuczna sieć neuronowa stanowi natomiast system wzajemnie połączonych neuronów. Biorąc pod uwagę możliwości jakie oferują sztuczne sieci neuronowe w pracy podjęto próbę ich wykorzystania do filtrowania sygnałów obciążonych szumem pomiarowym.

3. WYNIKI FILTROWANIA DANYCH DOŚWIADCZALNYCH

Przedmiotem analizy były wyniki pomiarów siły w funkcji przemieszczenia pochodzące z próby plastometrycznej ściskania w płaskim stanie odkształcenia. W pracy wykorzystano wyniki ściskania próbek prostopadłościennych o wymiarach początkowych $35 \times 25 \times 20$ mm ze stali o składzie chemicznym poda-

nym w tabelicy 1. Badania były przeprowadzone na maszynie Gleeble 38000 w Instytucie Metalurgii Żelaza w Gliwicach. Wykonano próby dla temperatur z zakresu $800^\circ\text{C} - 1100^\circ\text{C}$, co 50°C i trzech prędkości odkształcenia $0,1 \text{ s}^{-1}$, 1 s^{-1} i 10 s^{-1} .

Wyniki próby spęczania były obciążone różnego rodzaju szumami (rysunki 3–7). Do filtrowania danych wykorzystano opisaną powyżej metodę analizy falkowej (AF) oraz sztuczne sieci neuronowe (SSN).

W analizie falkowej wykorzystano rodziny falek Coiflet 5 oraz BiorSplines 3.9 dostępne w pakiecie Wavelet środowiska Matlab v6.5. Wybrane rodziny mogą być stosowane zamiennie podczas procesu analizy, gdyż charakteryzują się gładkimi funkcjami skalującą i falkową. Okazuje się jednak, iż falki BiorSplines sprawdzają się lepiej przy dekompozycji bardziej zaszumionych danych, jak w przypadku krzywych: naprężenie-odkształcenie logarytmiczne. W przeprowadzonych obliczeniach ilość poziomów dekompozycji była różna dla różnych prędkości odkształcenia przy stałej częstotliwości próbkowania, zachowując relację: im większa prędkość, tym mniej poziomów dekompozycji. Zbiory danych rozważanych w niniejszej pracy nie wymagały wstępnej obróbki w celu zastosowania analizy falkowej.

Do filtrowania wykorzystano następnie różne typy sieci neuronowych: sieci wielowarstwowe z logistyczną funkcją aktywacji (MLP – Multilayer Perceptron), sieci realizujące regresję uogólnioną (GRNN – Generalized Regression Neural Network) oraz sieci o radialnych funkcjach bazowych (RBF – Radial Basis Functions). W niniejszej pracy przedstawiono wyniki filtrowania danych pomiarowych (siła – przemieszczenie) przy zastosowaniu sieci RBF, ponieważ sieci te uzyskały zdecydowanie lepsze wyniki – szczególnie na początkowym odcinku badanego zakresu danych – w porównaniu z pozostałymi typami sieci.

W sieciach RBF występują trzy warstwy neuronów: warstwa wejściowa, warstwa wyjściowa oraz warstwa ukryta. Neurony warstwy ukrytej wykorzystują funkcje aktywacji w postaci radialnych funkcji bazowych (Mehrotra i in., 1997). Do uczenia sieci wykorzystano zmierzone wartości sił spęczania próbek (sygnał wyjściowy sieci) w funkcji przemieszczenia (sygnał wejściowy sieci). Zbiór dostępnych danych pomiarowych został podzielony na 3 podzbiory: danych uczących (50% danych), weryfikujących (25% danych) i testujących (25% danych). Do uczenia sieci wykorzystano wszystkie dostępne punkty pomiarowe, bez wstępnej obróbki danych. Dla każdego z analizowanych przy-

Tablica 1. Skład chemiczny stali do pracy w niskich temperaturach.

C	Mn	Si	P	S	Cr	Ni	Cu	Mo	Al	V	Nb
0,16	1,60	0,60	0,020	0,005	0,10	0,50	0,20	0,10	0,020	0,12	0,05



padków zbudowano osobną sieć o optymalnej strukturze. W obliczeniach wykorzystano pakiet Statistica Neural Networks PL wersja 4.0F.

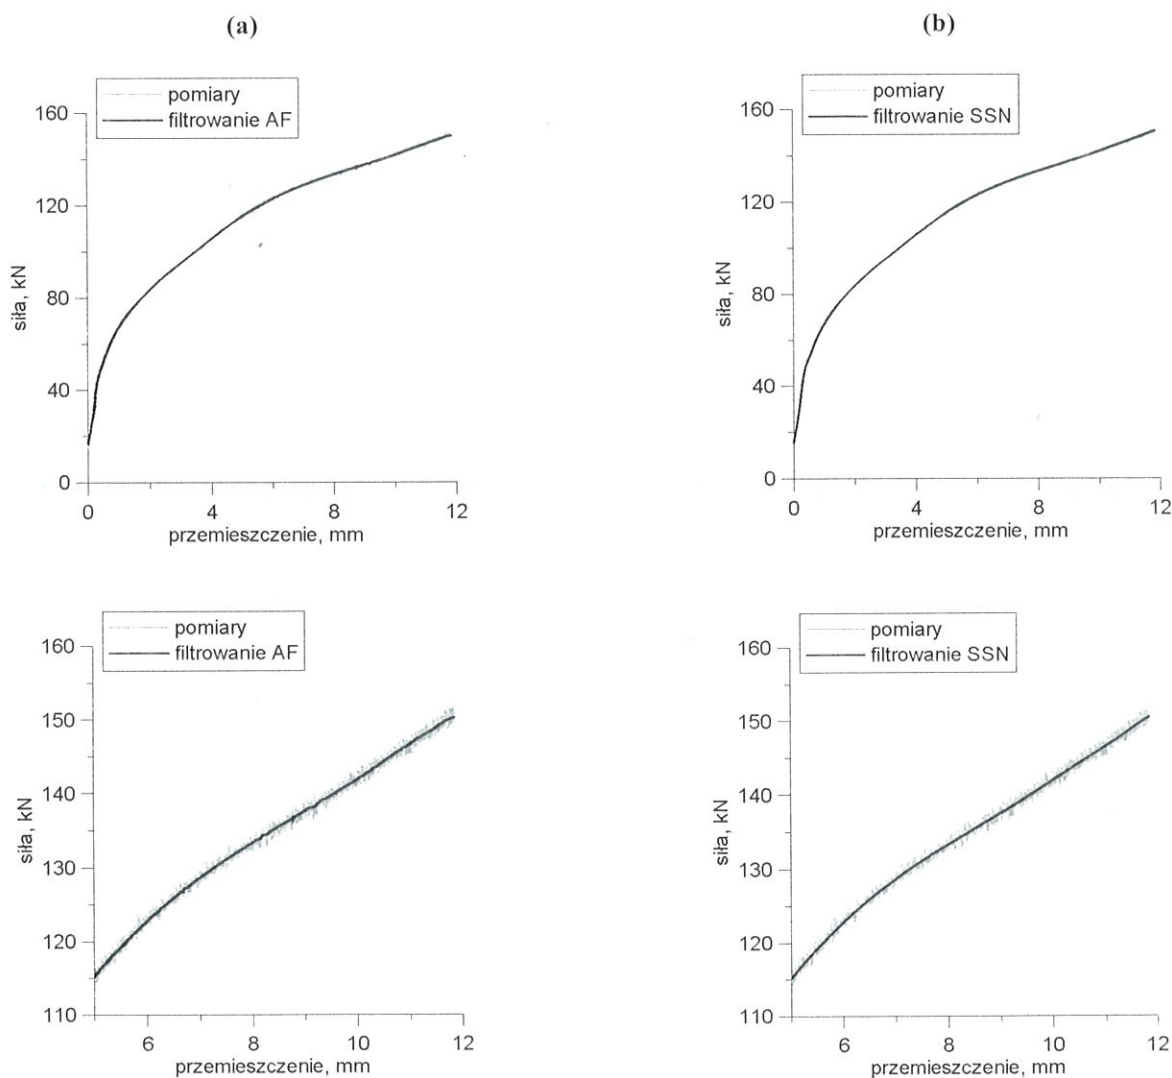
Na rysunkach 3-7 przedstawiono krzywe doświadczalne: siła spęczenia – przemieszczenie, wraz z wynikami filtrowania metodą fałek oraz metodą sztucznych sieci neuronowych typu RBF.

W ramach niniejszej pracy analizie poddano również wyniki pomiarów (naprężenie – odkształcenie) z próby spęczenia stali austenitycznej, przeprowadzonej w temperaturze 1150°C i prędkości odkształcenia 0,1 s⁻¹. Wyniki pomiarów zakłóconych szumem pomiarowym odfiltrowano przy wykorzystaniu sieci neuronowych (Kusiak i in., 2001) i porównano z wynikami filtrowania z wykorzystaniem analizy falkowej. Na rysunku 8 przedstawiono wyniki filtrowania metodą fałek oraz sztucznych sieci neuronowych typu MLP. Wejście sieci neuronowej stanowiło odkształcenie logarytmiczne, natomiast wyjściem sieci było naprężenie.

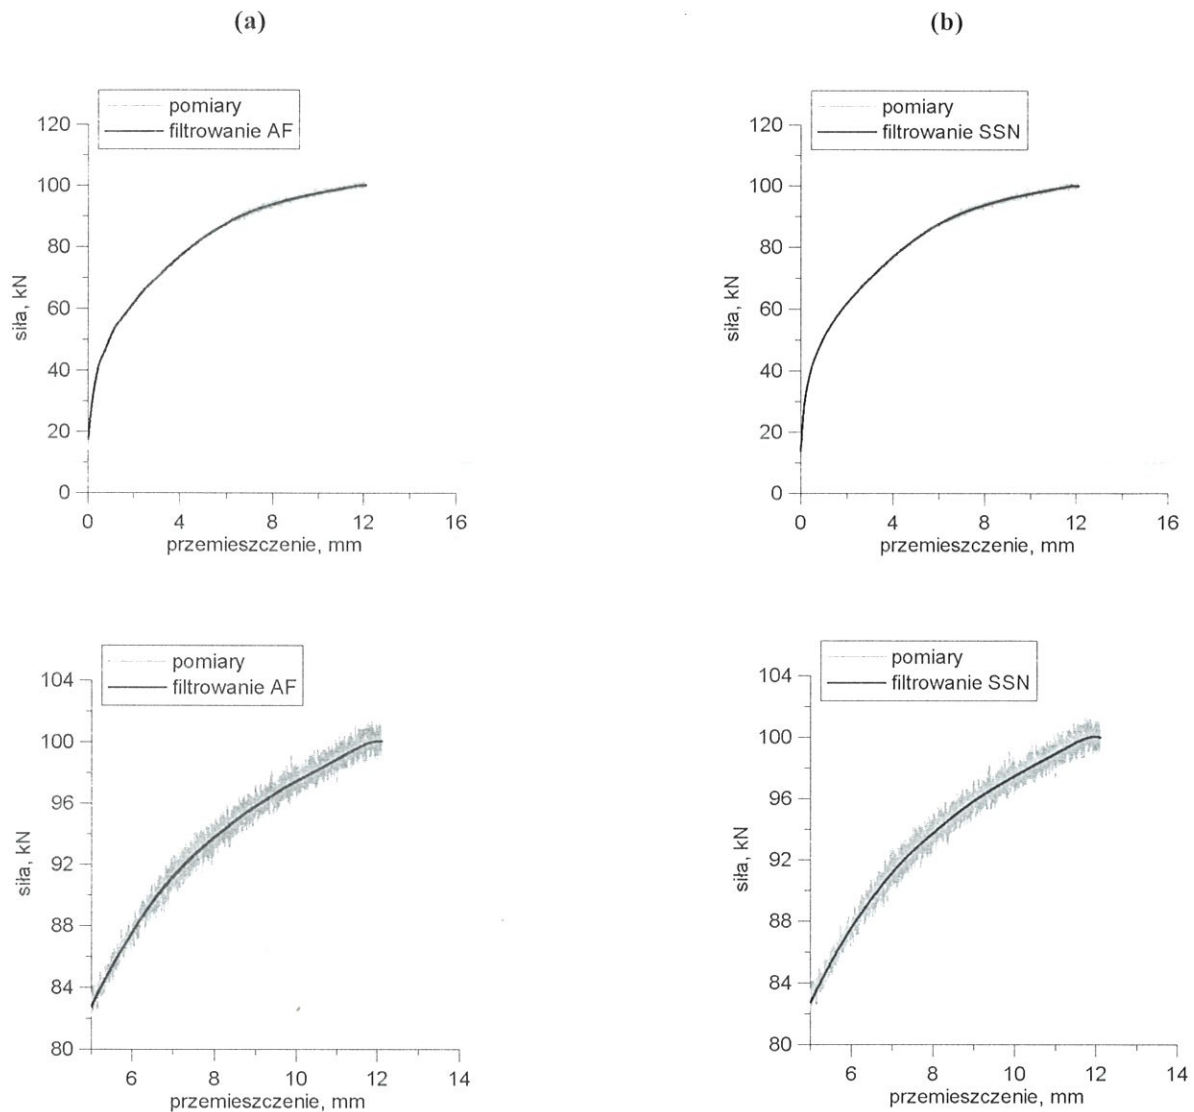
Analizując rysunki 3-8 można zauważyć, iż sieci neuronowe odznaczają się wyraźną tendencją do uogólniania podczas filtrowania krzywych pomiarowych.

Właściwość ta pozwala na łatwiejszą ocenę wizualną uzyskanego wyniku. Analiza falkowa natomiast wykazuje mniejszą tendencję uogólniania. Odfiltrowany sygnał podąża za trendem postępowania pomiarów. Na obecnym etapie trudno jest jednak ocenić, które z przedstawionych narzędzi jest lepsze do filtrowania krzywych pomiarowych z uwagi na brak jednoznacznych narzędzi do oceny błędu filtrowania. W tabelicy 2 przedstawiono współczynniki korelacji pomiędzy danymi pomiarowymi i wynikami filtrowania obydwu metod, przy czym współczynniki korelacji, które miały wyższe wartości w porównaniu z alternatywną metodą, zostały wyróżnione.

Wyższe wartości współczynników korelacji można zinterpretować w ten sposób, że analizowana metoda filtrowania w większym stopniu podążała za trendem wyników pomiarowych dla danego zbioru danych. Różnice w wartościach współczynników korelacji badanych metod są jednak znikome. Wskazane są zatem dalsze badania w zakresie metodologii oceny jakości filtrowania



Rysunek 3. Wyniki filtrowania danych pomiarowych przy zastosowaniu: (a) – analizy falkowej oraz (b) – sztucznych sieci neuronowych ($T = 800^{\circ}\text{C}$, $\dot{\epsilon} = 0,1 \text{ s}^{-1}$).



Rysunek 4. Wyniki filtrowania danych pomiarowych przy zastosowaniu: (a) – analizy falkowej oraz (b) – sztucznych sieci neuronowych ($T = 950^{\circ}\text{C}$, $\dot{\epsilon} = 0,1\text{s}^{-1}$).

Tabela 2. Współczynniki korelacji pomiędzy danymi pomiarowymi a wynikami filtrowania metodą analizy falkowej (AF) i sieci neuronowych (SSN).

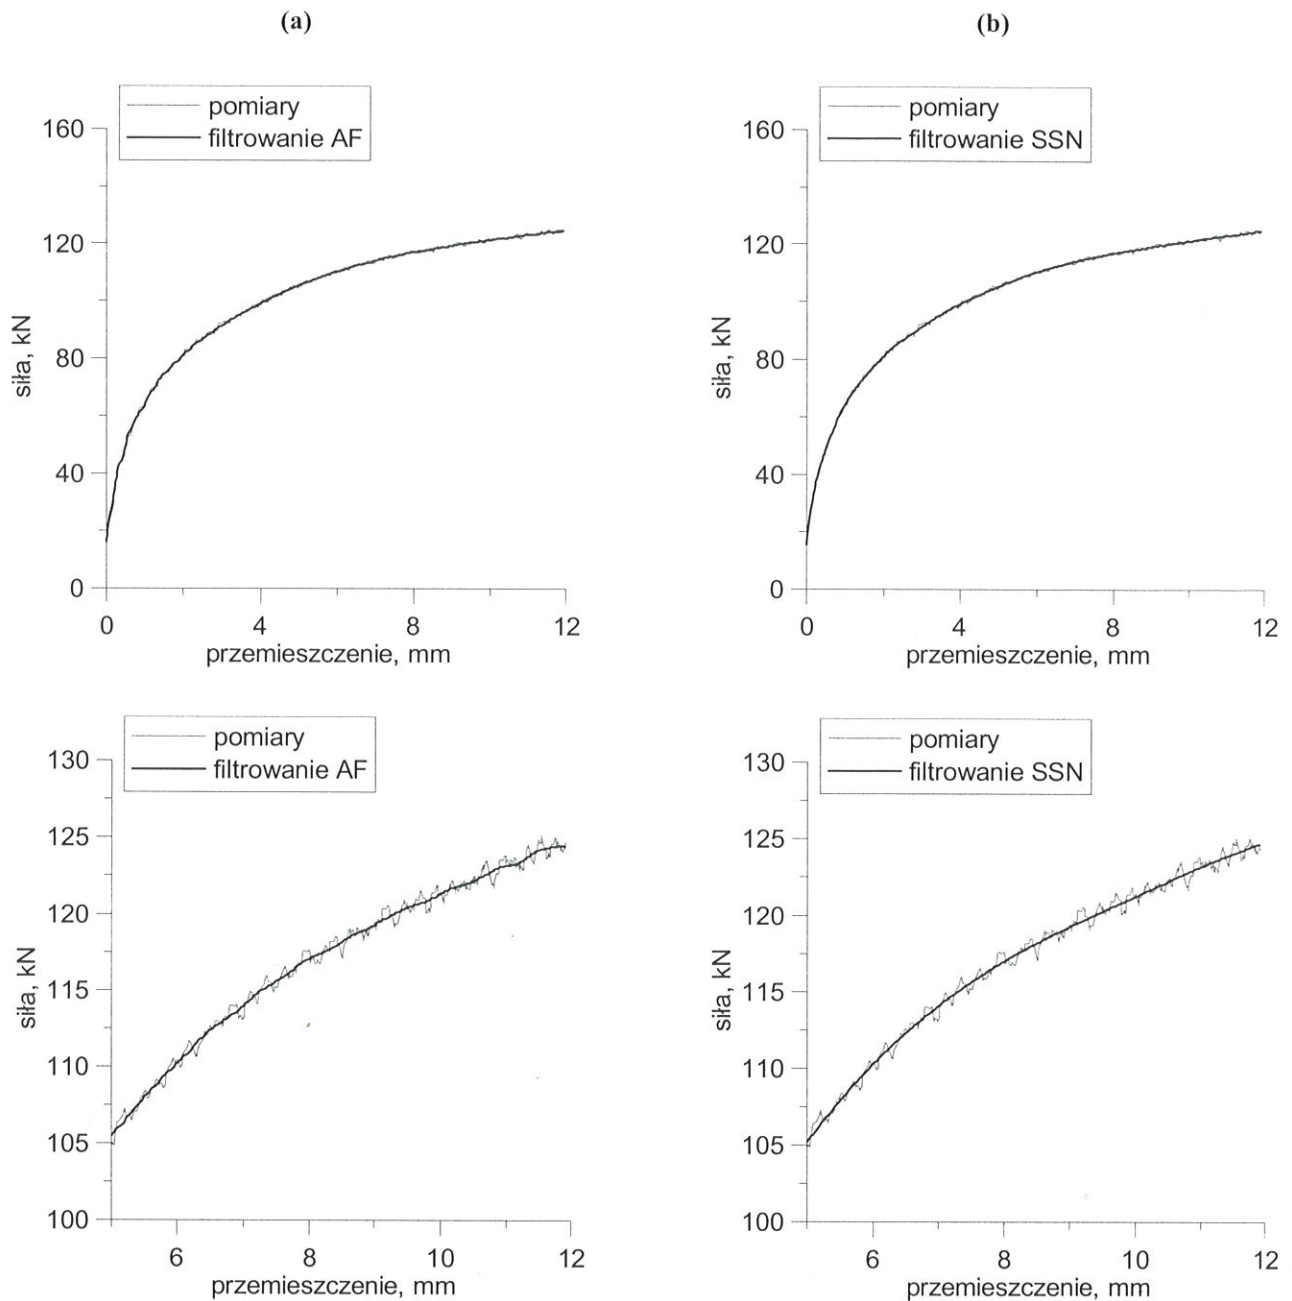
Temperatura, $^{\circ}\text{C}$	Prędkość odkształcenia, s^{-1}	Współczynnik korelacji – AF	Współczynnik korelacji – SSN
800	0,1	0,999836	0,999821
950	0,1	0,999453	0,999520
950	1	0,999677	0,999744
950	10	0,999825	0,998939
1100	10	0,999586	0,999623
1150	0,1	0,979595	0,976195

nia zastosowanych metod. Niemniej jednak, mimo iż na obecnym etapie trudno jednoznacznie określić, która z rozważanych metod charakteryzowała się większą skutecznością, uzyskane wyniki potwierdzają użyteczność obu metod w filtrowaniu danych pomiarowych z próby spęczania metali.

4. PODSUMOWANIE

Niniejsza praca stanowi próbę analizy danych pomiarowych prób spęczania obarczonych różnego rodzaju szumami pomiarowymi. Do filtrowania wykorzystano nowoczesne narzędzia, do których zaliczyć





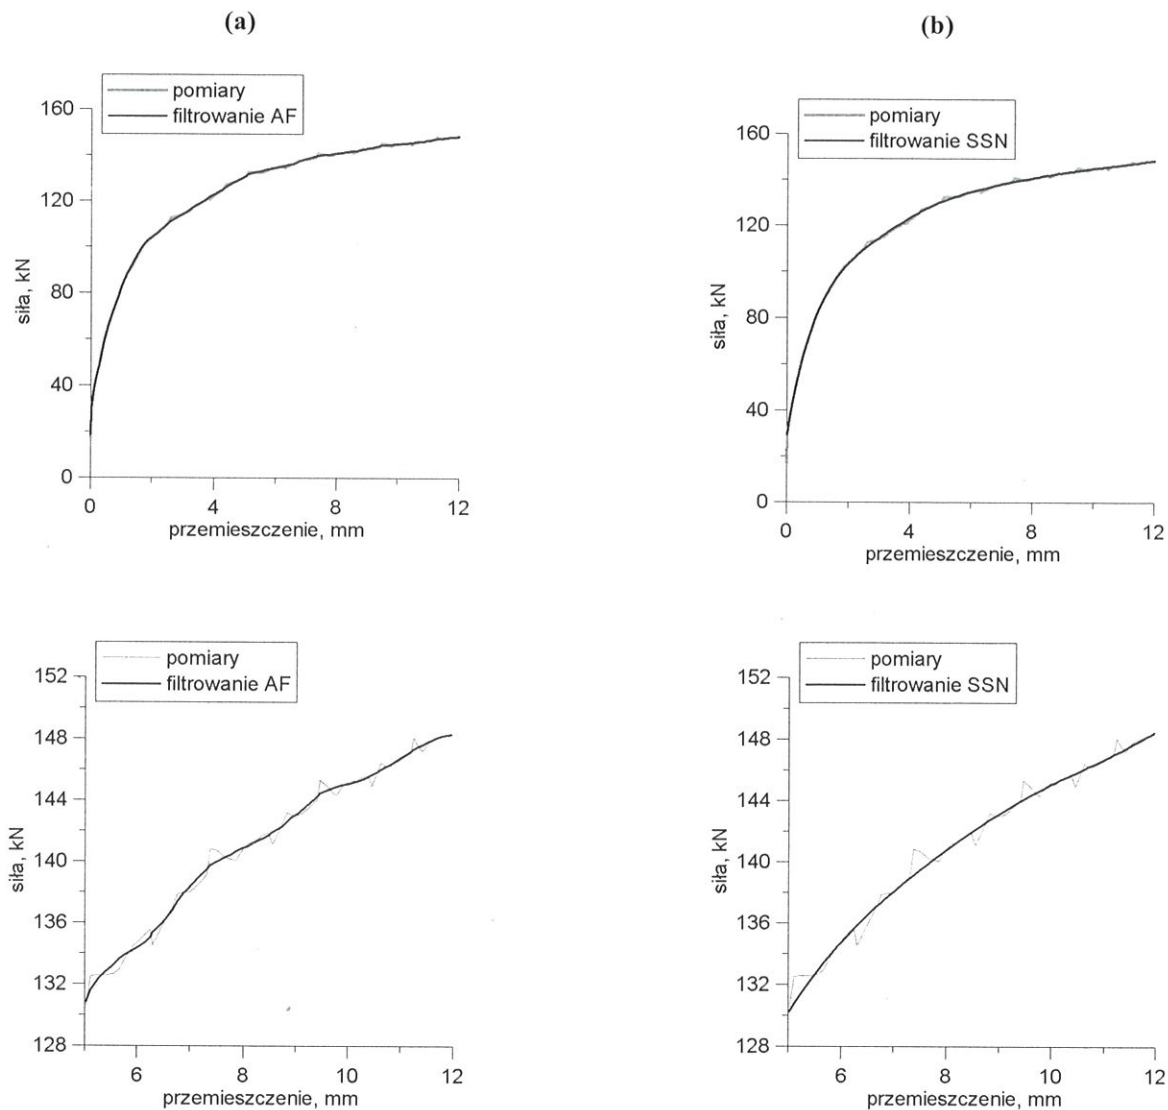
Rysunek 5. Wyniki filtrowania danych pomiarowych przy zastosowaniu: (a) – analizy falkowej oraz (b) – sztucznych sieci neuronowych ($T = 950^{\circ}\text{C}$, $\dot{\epsilon} = 1 \text{ s}^{-1}$).

można analizę falkową oraz sztuczne sieci neuronowe. Przedstawione na rysunkach 3-8 wyniki filtrowania dowodzą, że analiza falkowa oraz sztuczne sieci neuronowe charakteryzują się dużą skutecznością filtrowania danych pomiarowych obciążonych sygnałem zakłócającym w postaci szumu pomiarowego. Analiza danych dotyczyła pomiarów przeprowadzonych w próbie spęczania dla różnych materiałów (stal austenityczna, stal do pracy w niskich temperaturach) i dla różnych wartości temperatury i prędkości odkształcenia. W każdym z rozważanych przypadków badane metody okazały się efektywnymi narzędziami filtrowania danych. Odfiltrowane w ten sposób dane mogą być użyteczne do wykorzystania w obliczeniach analizy

odwrotnej, mającej na celu optymalne dopasowanie modelu matematycznego opisującego krzywą umocnienia odkształcanego metalu.

Uzyskane wyniki potwierdzają przydatność obu technik do filtrowania danych pomiarowych i stanowią kolejny przykład możliwości wykorzystania sztucznych sieci neuronowych do rozwiązywania złożonych problemów z dziedziny inżynierii materiałowej. Filtrowanie danych pomiarowych z wykorzystaniem omówionych metod jest bardziej obiektywne w stosunku do klasycznych metod filtrowania, wymagających subiektywnego założenia wartości pewnych parametrów od których uzależniony jest efekt końcowy filtrowania.

Kierunki dalszych badań winny być skierowane w



Rysunek 6. Wyniki filtrowania danych pomiarowych przy zastosowaniu: (a) - analizy falkowej oraz (b) - sztucznych sieci neuronowych ($T = 950^{\circ}\text{C}$, $\dot{\epsilon} = 10 \text{ s}^{-1}$).

stronę oceny błędów filtrowania. Odfiltrowane dane pomiarowe mogą być następnie wykorzystane w analizie odwrotnej, celem wyznaczenia optymalnych parametrów opisujących model odkształcanego materiału na podstawie wyników z prób plastometrycznych.

Uwaga końcowa: Praca wykonana w ramach działalności statutowej AGH Nr 11.11.110.317. Autorzy dziękują dr Danucie Szelidze za udostępnienie wyników badań plastometrycznych na potrzeby niniejszej pracy.

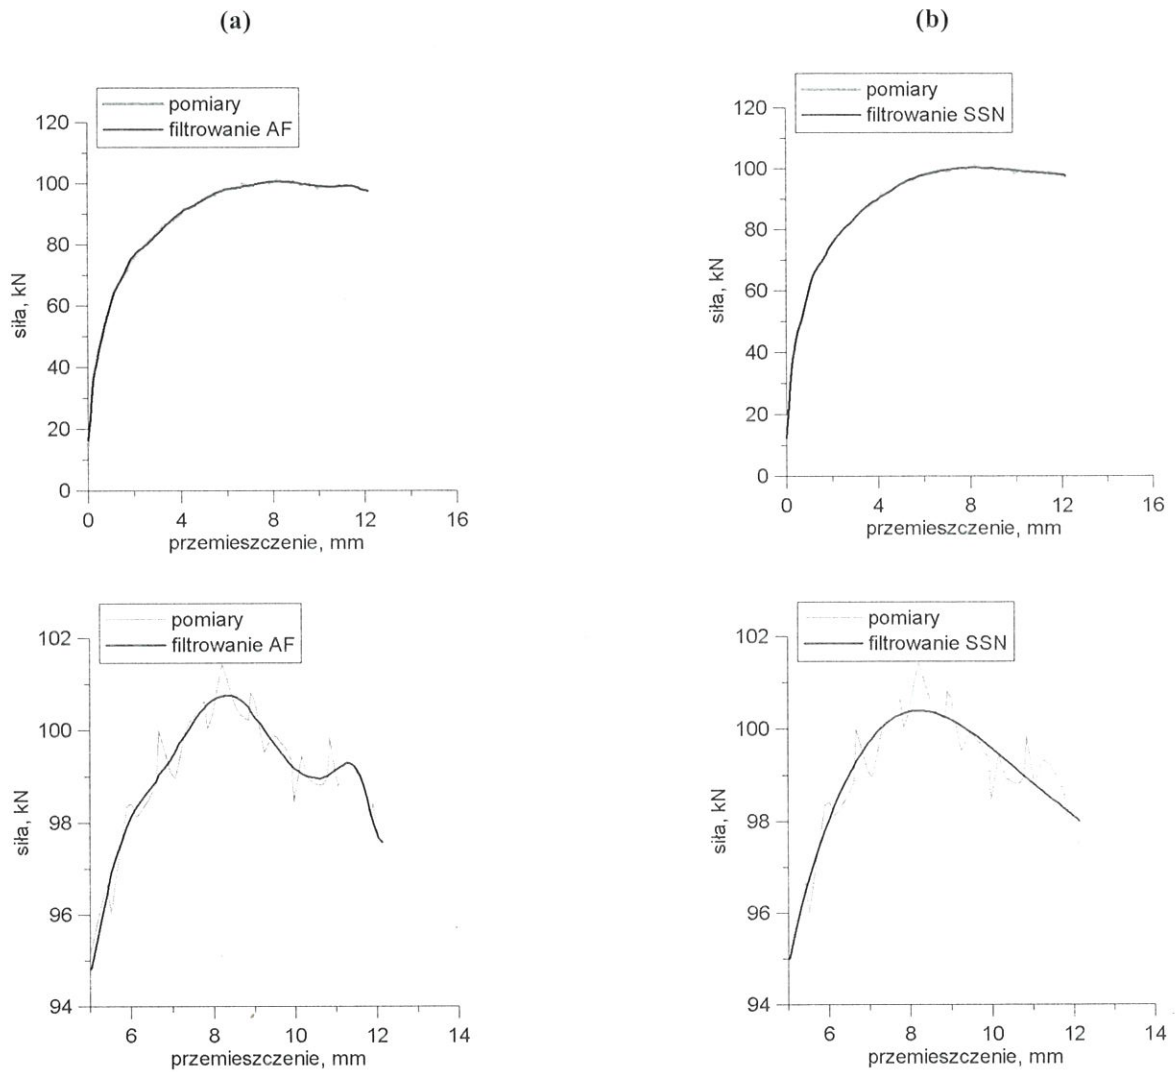
LITERATURA

Białasiewicz, J. T., 2000, Falki i aproksymacje, WNT, Warszawa.
 He T. X., 1998, Short Time Fourier Transform, Integral Wavelet Transform, and Wavelet Functions Associated with Splines, Journal of Mathematical Analysis and Applications, 224, 182-200.


Kusiak, J., Pietrzyk, M., Gawąd, J., Roberts, C.M., Wajda, W., 2001, Filtrowanie danych pomiarowych z wykorzystaniem sztucznych sieci neuronowych, Mat. Konf. Informatyka w Technologii Metali KomPlasTech' 2001, eds, Grosman F., Piela A., Kusiak J., Pietrzyk M., Korbielów, 65-70.
 Masters, T., 1996, Sieci neuronowe w praktyce, WNT, Warszawa.
 Mehrotra, K., Mohan, C.K., Ranka, S., 1997, Elements of Artificial Neural Networks, MIT Press, London.
 Montgomery, D.C., Johnson, L.A., 1976, Forecasting and Time Series Analysis. McGraw-Hill Book Company, New York.
 Osowski, S., 1996, Sieci neuronowe, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
 Tadeusiewicz, R., 1993, Sieci neuronowe, Akad. Ofic. Wyd. RM, Warszawa.
 Żurada, J., Barski, M., Jędruch, W., 1996, Sztuczne sieci neuronowe, PWN, Warszawa.

Artykuł otrzymano 17 marca 2004 r.





Rysunek 7. Wyniki filtrowania danych pomiarowych przy zastosowaniu: (a) - analizy falkowej oraz (b) - sztucznych sieci neuronowych ($T = 1100^{\circ}\text{C}$, $\dot{\epsilon} = 0,1 \text{ s}^{-1}$).



Rysunek 8. Wyniki filtrowania danych pomiarowych przy zastosowaniu: (a) - analizy falkowej oraz (b) - sztucznych sieci neuronowych ($T = 1150^{\circ}\text{C}$, $\dot{\epsilon} = 0,1 \text{ s}^{-1}$).