

*Krystyna Kuźniar***Sztuczne sieci neuronowe w inżynierii sejsmicznej****Wstęp**

Jednym z intensywnie rozwijających się obszarów zainteresowania w badaniach nad metodami tzw. sztucznej inteligencji są sztuczne sieci neuronowe (SSN). Sieci neuronowe wykorzystuje się w wielu, różniących się od siebie, dziedzinach nauki, np. w naukach technicznych, fizyce, medycynie, ekonomii, geologii. Wynika to z faktu, że ich właściwości pozwalają na skuteczne przetwarzanie i analizę danych, a także na wykorzystanie SSN do rozwiązywania problemów prognozowania, klasyfikacji i sterowania.

Sztuczne sieci neuronowe modelują działanie centralnego systemu nerwowego organizmów żywych. Pozwala to na podejmowanie problemów, w rozwiązywaniu których trudne lub wręcz niemożliwe jest zastosowanie tzw. metod klasycznych (w tym np. metody elementów skończonych), chociażby tzw. zadań odwrotnych dotyczących modelowania zależności nieliniowych z dużą liczbą zmiennych niezależnych.

Sztuczne sieci neuronowe mają zdolność uczenia się, adaptacji oraz uogólniania (właściwości generalizacyjne). Pozwalają na wykorzystanie bazy już istniejących wyników badań doświadczalnych, analizowanych danych z obliczeń lub danych prognozowanych.

Niniejszy artykuł dotyczy zastosowania sieci neuronowych w rozwiązywaniu wybranych problemów z zakresu inżynierii sejsmicznej i parasejsmicznej. Sieci neuronowe mogą być szczególnie przydatne ze względu na charakter zjawisk typu sejsmicznego, a więc losowość ich występowania i trudności z ich precyzyjnym przewidywaniem. Ponadto, w praktyce tego typu dane są zwykle niekompletne lub „zaszumione”, stąd trudności z ich wykorzystywaniem w konwencjonalnych analizach dynamicznych. Dodatkowo, oddziaływania, pochodzące od drgań podłoża gruntowego, dotyczą rzeczywistych obiektów budowlanych, a więc konstrukcji bardzo złożonych i trudnych do tradycyjnego modelowania.

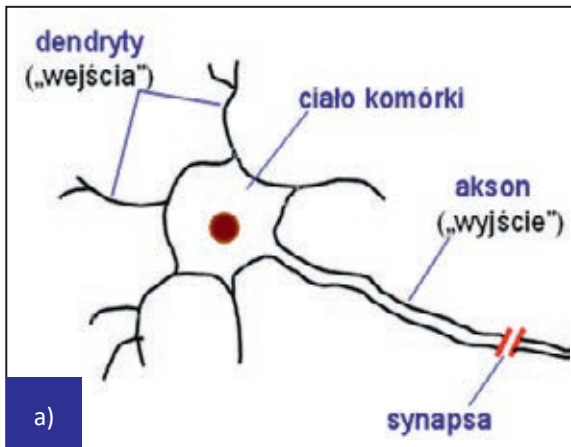
Idea i projektowanie sztucznych sieci neuronowych

Teoria sztucznych sieci neuronowych różnego typu budzi zainteresowanie wielu badaczy (Bishop 1995, Bishop 2006, Duch i in. 2000, Haykin 1999, Jang i in. 1997, Korbicz i in. 1994, Masters 1996, Osowski 2006, Rutkowski 2006, Tadeusiewicz 1993, Waszczyszyn 2010).

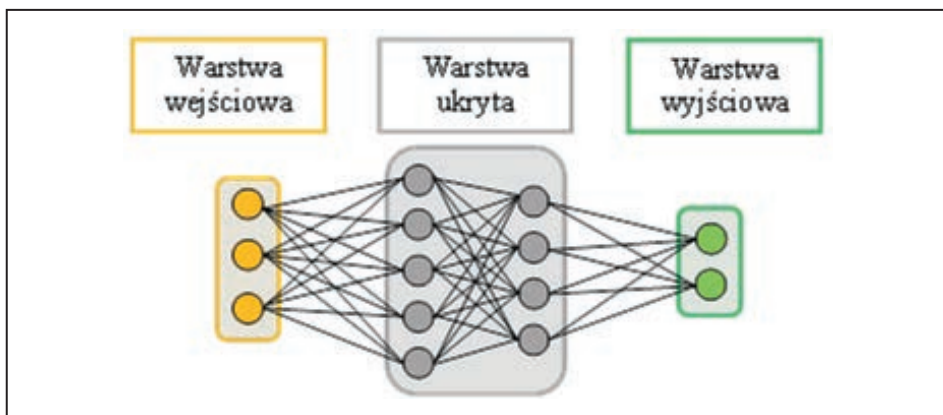
Sztuczna sieć neuronowa (SSN) w uproszczony sposób odwzorowuje działanie biologicznego układu nerwowego, który jest bardzo złożoną strukturą. Zbudowany jest z komórek nerwowych – neuronów (rys. 1a) połączonych w sieć. Biologiczny neuron można traktować jako specyficzny przetwornik sygnałów o modelu pokazanym na rys. 1b (Korbicz i in. 1994).

Analogicznie, jak to jest w biologicznych sieciach neuronowych, podstawowymi elementami, z których zbudowane są sztuczne sieci neuronowe, są sztuczne neurony. Sposób połączenia neuronów między sobą i model ich wzajemnej współpracy decyduje o typie sieci, a z każdym rodzajem sztucznej sieci neuronowej wiąże się odpowiednia metoda jej uczenia.

Najczęściej stosowanymi sieciami w zagadnieniach inżynierskich, w tym w inżynierii sejsmicznej, są sieci jednokierunkowe warstwowe. Warstwowa budowa tego typu sieci polega na ułożeniu (uporządkowaniu) neuronów w kolejnych warstwach: warstwie wejściowej, warstwach ukrytych (jednej lub kilku) i warstwie wyjściowej. Każdy neuron jest połączony z neuronami warstwy sąsiednich, ale nie łączy się z neuronami warstwy, której jest składnikiem (rys. 2).



Rys. 1. Schemat budowy biologicznej komórki neuronowej (a) i jej model (b) wg (Korbicz i in. 1994)



Rys. 2. Schemat budowy sieci jednokierunkowej warstwowej

Projektowanie i weryfikacja aproksymacyjnej dokładności sieci neuronowych odbywa się przy użyciu odpowiednio dobranych i wystarczająco licznych zbiorów tzw. wzorców, czyli par wektorów wejście/wyjście o znanych składowych. Najlepszym źródłem takich danych są badania eksperymentalne w skali naturalnej. Wzorce przygotowane numerycznie (np. za pomocą metody elementów skończonych) często są zbyt „idealne” i sieć nie ma możliwości nauczenia się rzeczywistych, „zaszumionych” relacji. Uczenie (trenowanie) sieci neuronowej, tzn. obliczenie wartości parametrów sieci przy zastosowaniu określonej metody (algorytmu) uczenia, jest bardzo istotnym procesem. Następnym krokiem jest testowanie sieci. Z całego zbioru wzorców wydziela się (np. losowo) podzbiór uczący, podzbiór walidujący i podzbiór testujący. Podzbiór walidujący wykorzystywany jest na etapie uczenia do projektowania struktury sieci – służy do sprawdzania jakości przyjmowanych wariantów sieci. Stąd zbiór wzorców uczących i zbiór wzorców walidujących często rozpatruje się łącznie. W celu sprawdzenia właściwości generalizacyjnych nauczona sieć podlega testowaniu z użyciem zbioru testującego, a więc wzorców, których sieć „nie widziała” na etapie uczenia.

Do oceny dokładności aproksymacji neuronowej wykorzystuje się różne miary błędów. Przykładem jest błąd średniokwadratowy sieci (uczenia, walidacji, testowania). Jednak wartość błędu średniokwadratowego nie pozwala na porównywanie wyników uzyskanych na podstawie danych o różnych skalach (np. wyrażonych w różnych jednostkach) – jest to tzw. bezwzględna miara błędu (Masters 1996). Zatem w praktyce, poza błędami średniokwadratowymi, do oceny dokładności odwzorowania neuronowego stosuje się również błędy względne: pojedynczych wzorców, średnie, maksymalne. Często wykorzystywane są też miary statystyczne, np. współczynnik korelacji liniowej i błąd standardowy resztkowy. Innym bardzo przydatnym narzędziem oszacowania dokładności uzyskanych rezultatów obliczeń, jest tzw. procent sukcesu (z j. ang. *Success Ratio*) w funkcji błędu względnego. Podaje on jaki procent wzorców uzyskano z prognozowania neuronowego z błędem nie większym niż założony błąd względny.

Do czynników, które istotnie wpływają na właściwości aproksymacyjne sieci neuronowej, należy zaliczyć: liczebność (w stosunku do łącznej liczby parametrów proponowanej sieci) i reprezentatywność zbioru uczącego, architekturę sieci (w tym

np. liczbę warstw ukrytych i liczbę neuronów w warstwie ukrytej), złożoność analizowanego problemu.

Wstrząsy sejsmiczne i parasejsmiczne


Ruch podłoża gruntowego zaliczany jest do szczególnych oddziaływań dynamicznych na konstrukcję budowlaną. W tym przypadku źródło drgań znajduje się poza konstrukcją. Wstrząsy dochodzą do obiektu na skutek propagacji drgań w ośrodku gruntowym. Drgania podłoża stanowią tzw. wymuszenie kinematyczne, które wywołuje obciążenie konstrukcji budowlanej siłami bezwładności.

Źródła tego typu drgań mogą być naturalne, a więc niezależne od człowieka, oraz mogą być bezpośrednim lub pośrednim skutkiem działalności człowieka. W pierwszym przypadku mówimy o drganiach sejsmicznych, których źródłem są trzęsienia ziemi (wstrząsy typu tektonicznego), a drugi przypadek dotyczy tzw. drgań parasejsmicznych.

Niektóre z wymuszeń parasejsmicznych, jak np. ruch pojazdów drogowych lub kolejowych, wybuchy przemysłowe, podziemne eksplozje nuklearne, odstrzały materiału wybuchowego w kamieniołomach, praca kafarów, mogą być przez człowieka w mniejszym lub większym stopniu kontrolowane, a nawet istnieje możliwość sterowania tymi zjawiskami.

Zupełnie inny charakter mają wstrząsy pochodzenia górniczego, które towarzyszą podziemnej eksploatacji złóż. Wstrząsy górnicze są skutkiem pęknięcia skał nad wyrobiskami górniczymi. Zjawisko to występuje samorzutnie w twardych skałach nadkładowych w sposób gwałtowny z wydzieleniem ogromnych ilości energii, na skutek zachwiania naturalnego stanu równowagi skał. Do powierzchni terenu propagują się fale sejsmiczne, które z kolei wzbudzają drgania obiektów budowlanych. Mimo tego, że wstrząsy te są ściśle związane z działalnością ludzką, ich wzbudzenie odbywa się losowo, niezależnie od woli człowieka, zupełnie poza kontrolą, podobnie jak w przypadku trzęsień ziemi. Wstrząsy pochodzenia górniczego charakteryzują się zdecydowanie większą intensywnością niż inne źródła drgań parasejsmicznych. Ich energie mogą dochodzić nawet do 10^{10} J, przy czym ze względu na oddziaływanie tych wstrząsów na powierzchni terenu, jako wstrząsy wysokoenergetyczne (silne i bardzo silne) traktuje się wstrząsy już o energii nie mniejszej niż 10^6 J (Kuźniar i in. 2010).

Przebiegi drgań powierzchniowych wzbudzone trzęsieniami ziemi oraz wstrząsami górniczymi wykazują pewne podobieństwa i różnice (Zembały 2004). Parametrem wyraźnie różnym jest czas trwania intensywnej fazy przebiegów drgań. W przypadku trzęsień ziemi faza ta trwa 20 s, a nawet więcej. W przypadku wstrząsów górniczych zwykle nie dłużej niż 2,5 s. Wyraźną różnicę w czasach trwania trzęsień ziemi i wstrząsów górniczych widać nawet w przypadku drgań powierzchniowych o zbliżonych wartościach maksymalnych przyśpieszeń. Tymczasem czas trwania fazy silnych wstrząsów ma znaczący wpływ na wystąpienie zniszczeń w obiektach budowlanych. Inną cechą różniącą wstrząsy pochodzenia górniczego i trzęsienia ziemi jest zasięg ich występowania: wstrząsy górnicze – obszar od kilku do kilkunastu kilometrów, trzęsienia ziemia – nawet do kilkuset kilometrów. Z kolei dominujące częstotliwości drgań powierzchniowych od trzęsień ziemi są dużo niższe niż od wstrząsów górniczych (Maciąg 2002).



Rys. 3. Przebiegi przyspieszeń poziomych drgań powierzchniowych od: a) trzęsienia ziemi El Centro (NISEE); b) wstrząsu górniczego (o energii $8,4 \cdot 10^8$ J i odległości epicentralnej 614 m) w Legnicko-Głogowskim Okręgu Miedziowym


Na rys. 3 ukazano przykładowe przebiegi drgań powierzchniowych, których źródłem były: trzęsienie ziemi El Centro (rys. 3a) oraz wstrząs górniczy w Legnicko-Głogowskim Okręgu Miedziowym (LGOM) o energii $8,4 \cdot 10^8$ J i odległości epicentralnej 614 m (rys. 3b).

Przykłady zastosowania sieci neuronowych

Wyznaczanie magnitudy wstrząsu

Magnituda jest parametrem charakteryzującym wstrząs typu sejsmicznego. Magnitudę wstrząsów w skali Richtera definiuje się, jako logarytm o podstawie 10 z maksymalnej wartości przemieszczeń gruntu podanych w mikrometrach, zmierzonych standardowym sejsmografem Wooda-Andersona w odległości 100 km od epicentrum (Chmielewski, Zembaty 1998). W praktyce do wyznaczenia magnitudy potrzebna jest informacja o odległości epicentralnej, tłumieniu, amplitudzie przemieszczeń drgań gruntu. Natomiast w prostej sieci neuronowej proponowanej przez Niewiadomskiego (2002), tę informację zawiera w sposób pośredni wektor wejścia. Składa się on z dwóch elementów (X_1, X_2), które otrzymuje się przez odpowiednią obróbkę zarejestrowanych przebiegów prędkości drgań (Niewiadomski 2002), por. rys. 4.

Sieć o strukturze 2-2-1, do uczenia której wykorzystano 30 wzorców, bardzo dobrze wylicza magnitudy wstrząsów. W zbiorze testującym (50 wzorców) różnice w wartościach wyznaczonych tradycyjnie (metodą spektralną) i neuronowo nie przekraczają 0,2.



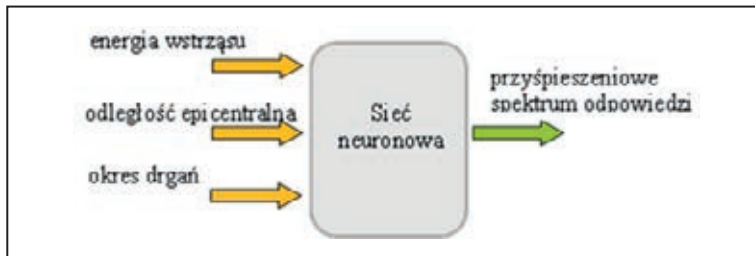
Rys. 4. Sztuczna sieć neuronowa do wyznaczenia magnitudy wg (Niewiadomski 2002)

Wyznaczanie spektrów odpowiedzi od przebiegów drgań gruntu wywołanych wstrząsami górniczymi

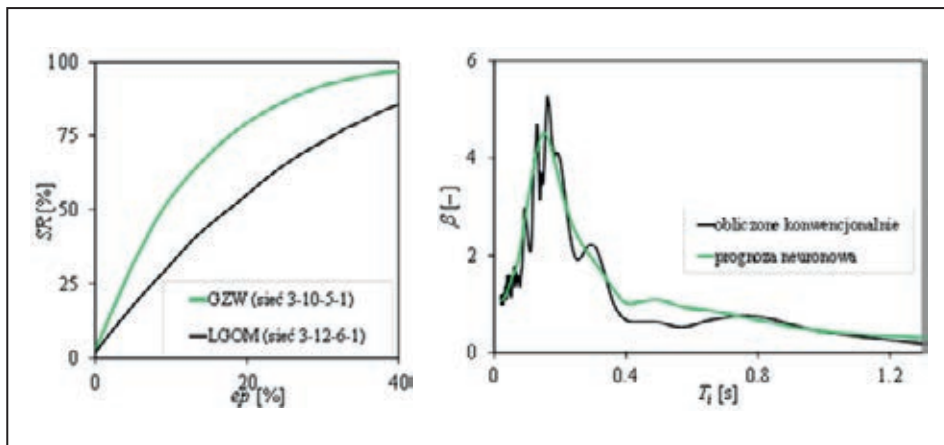
Ideą spektrum odpowiedzi jest przyjęcie modelu obiektu w postaci oscylatora, którego drgania wymuszane są ruchem podłoża. Jest to funkcja podająca maksymalne wartości odpowiedzi (przyśpieszenia, prędkości, przemieszczenia) oscylatorów na tego typu wymuszenie, w zależności od okresów drgań własnych oscylatorów (ewentualnie częstotliwości drgań własnych oscylatorów) oraz założonego tłumienia (Chmielewski, Zembaty 1998). Zatem spektrum odpowiedzi zawiera informacje o wymuszeniu kinematycznym.

Na rys. 5 schematycznie przedstawiono propozycję wykorzystania sieci neuronowych do prognozowania kolejnych wartości bezwymiarowych przyśpieszeniowych spektrów odpowiedzi od przebiegów drgań gruntu pochodzenia górniczego na podstawie podstawowych parametrów wstrząsów górniczych: energii wstrząsu górniczego i odległości epicentralnej (Kuźniar 2013).

Weryfikacji przydatności sieci dokonano za pomocą danych doświadczalnych z regionu Górnośląskiego Zagłębia Węglowego (GZW) i Legnicko-Głogowskiego Okręgu Miedziowego (LGOM). Ze względu na różny charakter drgań powierzchniowych w tych regionach górniczych, powstała odrębna sieć neuronowa dla każdego z nich.



Rys. 5. Sztuczna sieć neuronowa do wyznaczania wartości przyśpieszeniowego spektrum odpowiedzi




Rys. 6. a) Procent sukcesu SR w funkcji błędnej względnej ep neuronowej prognozy spektrów odpowiedzi β w GZW i LGOM; b) Przykładowe porównanie spektrów β policzonych konwencjonalnie i wyznaczonych neuronowo (region LGOM)

W przypadku każdego z regionów, bezwymiarowe przyspieszeniowe spektra odpowiedzi (β) od przebiegów drgań gruntu obliczone za pomocą sieci neuronowej na podstawie energii wstrząsów i odległości epicentralnych są bardzo bliskie spektrom wyznaczonym w sposób konwencjonalny, por. rys. 6.

Przekazywanie drgań z podłoża na budynek

Podczas przekazywania drgań pochodzenia sejsmicznego lub parasejsmicznego z gruntu na konstrukcję budowlaną występuje wzajemne oddziaływanie. Zjawisko to nazywane jest interakcją dynamiczną. Powstające jednocześnie drgania gruntu obok budynku i drgania fundamentu budynku są zwykle zasadniczo różne (Kuźniar i in. 2010). Tymczasem to przebiegi drgań fundamentów pozwalają na dokładniejszą ocenę szkodliwości drgań dla budynków (Maciąg 2005). Zatem w przypadku, kiedy mierzone są tylko drgania gruntu (co jest częstym przypadkiem w praktyce), potrzebne jest prognozowanie drgań fundamentów budynków na podstawie drgań gruntu.

Sztuczne sieci neuronowe mogą być z sukcesem wykorzystywane do prognozowania redukcji maksymalnych wartości drgań (prędkości i przyspieszeń składowych oraz wypadkowych) przy ich przekazywaniu z gruntu na fundament budynku (Kuźniar, Chudyba 2012; Kuźniar 2013). Tak więc stosunek odpowiednich maksymalnych wartości drgań fundamentu budynku i gruntu obok budynku jest w tym przypadku wyjściem z sieci neuronowej. Natomiast w skład wektora wejścia wchodzi parametry wstrząsu górniczego oraz parametry drgań gruntu. Pod uwagę brane były różne kombinacje parametrów wejściowych sieci i różna ich liczba: energia wstrząsu, odległość epicentralna, maksymalna wartość (amplituda) drgań gruntu (przyspieszeń albo prędkości), parametr opisujący kierunek drgań, współrzędne sejsmologiczne wstrząsu górniczego w lokalnym układzie odniesienia, dominująca częstotliwość przyspieszeń drgań gruntu. Wzorce uczące, walidujące i testujące oraz ocena przydatności proponowanych sieci neuronowych bazowała na wynikach badań doświadczalnych w regionie LGOM dotyczących typowych na tym terenie budynków mieszkalnych: dwunastokondygnacyjnych i pięciokondygnacyjnych.



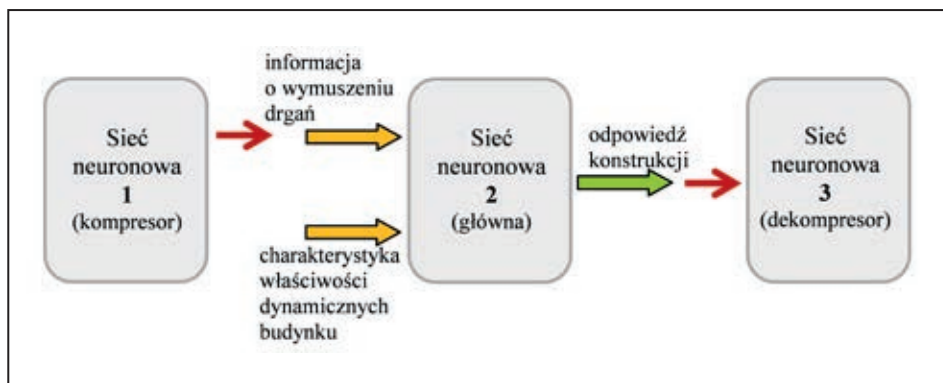
Rys. 7. Bezwymiarowe przyspieszeniowe spektrum odpowiedzi od drgań fundamentu budynku 5-cio kondygnacyjnego

Innym skutecznym, pełniejszym sposobem neuronowego prognozowania przekazywania drgań z podłoża na budynek jest odwzorowanie spektrów odpowiedzi od przebiegów drgań zarejestrowanych na gruncie przed budynkiem w odpowiednie spektra od występujących w tym samym czasie drgań fundamentu budynku (Kuźniar 2013, Kuźniar i in. 2010). W tym przypadku zaproponowano sześćelementowy wektor wejścia sieci neuronowej $x = \{\beta_g(f_{i-2}), \beta_g(f_{i-1}), \beta_g(f_i), \beta_g(f_{i+1}), \beta_g(f_{i+2}), f_i\}$, a wartość $\beta_g(f_i)$ jako wyjście z sieci neuronowej; gdzie: $f_{i-2}, f_{i-1}, f_i, f_{i+1}, f_{i+2}$ – kolejne częstotliwości drgań, β_g, β_f – bezwymiarowe przyśpieszenia spektra odpowiedzi odpowiednio od drgań gruntu i fundamentu budynku. Na rys. 7 porównano jedno z uzyskanych neuronowo spektrów odpowiedzi od przebiegów drgań fundamentu budynku pięciokondygnacyjnego z odpowiadającym mu spektrum wyliczonym konwencjonalnie na podstawie pomierzonego przebiegu przyśpieszeń drgań.


Symulacja odpowiedzi budynku na wymuszenia typu sejsmicznego

W szczegółowej analizie dynamicznej budynków podlegających oddziaływaniom (wymuszeniom) typu sejsmicznego niezbędne jest wyznaczenie odpowiedzi konstrukcji – określenie rzeczywistych przebiegów przemieszczeń, prędkości lub przyśpieszeń drgań wybranych kondygnacji. Również w tym celu możliwe jest wykorzystanie sieci neuronowych, co pokazano w pracy *Sieci neuronowe w analizie drgań budynków wywołanych wstrząsami parasejsmicznymi i sejsmicznymi* (Kuźniar, Waszczyszyn 2003). W książce tej zaproponowano wykorzystanie zespołu sieci neuronowych do symulacji pełnych przebiegów (w dziedzinie czasu) przemieszczeń drgań ostatniej kondygnacji budynków 5-cio kondygnacyjnych, poddanych wymuszeniu kinematycznemu, którego źródłem była eksploatacja pobliskiej kopalni odkrywkowej (kamieniołomu). Sieci neuronowe z powodzeniem zastąpiły analizę równań ruchu.

Z uwagi na duży rozmiar zbiorów danych opisujących poszczególne, pełne przebiegi wymuszeń i odpowiedzi budynków, dane te przetworzono. Każdy z przebiegów drgań skompresowano z użyciem sieci neuronowych specjalnego typu – replikatora. Następnie tak otrzymane wektory o małej liczbie elementów użyto do uczenia i testowania tzw. sieci głównej, która symuluje transformację wektora wejścia – skompresowane wymuszenie drgań, w wektor wyjścia – skompresowaną



Rys. 8. Schemat zespołu sieci neuronowych do symulacji odpowiedzi dynamicznej budynku




Rys. 9. Porównanie przykładowego przebiegu przemieszczeń drgań ostatniej kondygnacji budynku otrzymanego doświadczalnie z pomiarów *in situ* i z symulacji neuronowej wg (Kuźniar, Waszczyszyn 2003)

odpowiedź budynku. Wektor wejścia zawiera również informację o właściwościach dynamicznych budynku. Kolejnym krokiem jest dekompresja wektora wyjścia z sieci głównej. W tym celu również wykorzystano sieci neuronowe. Na rys. 8 schematycznie przedstawiono ideę wykorzystania sieci neuronowych do symulacji odpowiedzi dynamicznej budynku, a na rys. 9 przykładowy wynik symulacji neuronowej przebiegu przemieszczeń drgań z większymi amplitudami (a więc takimi, które mają istotne znaczenie w analizie dynamicznej konstrukcji) ostatniej kondygnacji budynku.

Aktywne sterowanie konstrukcji

Ze względu na zdolność sieci neuronowych do aproksymowania dowolnych nieliniowości, podejmowane są próby wykorzystania ich w aktywnym sterowaniu układów nieliniowych. Idea układu sterowania z regulatorem neuronowym sprowadza się do odwzorowania aktualnego sterowania $u(k)$ i aktualnego stanu obiektu $y(k)$ w następny stan obiektu $y(k+1)$ (Faravelli, Venini 1995). Zasadniczym problemem jest opracowanie odpowiedniej strategii (sposobu) uczenia regulatora neuronowego. Ale w pierwszym kroku budowany jest neuronowy emulator obiektu, którego zadaniem jest pełne odwzorowanie specyfiki zachowania obiektu rzeczywistego. Neuronowy emulator tworzony jest niezależnie od neuronowego regulatora. Proces



Rys. 10. Przykładowy wynik testowania sieci neuronowej do prognozowania kolejnych kroków odpowiedzi budynku na wymuszenie typu parasejsmicznego wg (Kuźniar 2013)

uczenia emulatora neuronowego jest praktycznie procesem identyfikacji i odbywa się *off-line*. W drugim etapie neuronowy regulator uczy się sterować emulatorem obiektu. Następnie taki regulator wykorzystuje się do sterowania rzeczywistym obiektem w trybie *on-line* (Faravelli, Venini 1995).

Sieć neuronową (jako emulator obiektu) zastosowano do prognozowania przemieszczenia w danej chwili czasu wybranej kondygnacji budynku poddanego wymuszeniom parasejsmicznym na podstawie informacji o wymuszeniu z chwili poprzedniej (przemieszczenie fundamentu) i odpowiedzi tej kondygnacji obiektu z trzech kroków czasowych wstecz (Kuźniar 2013). Taka struktura emulatora neuronowego konstrukcji jest bardzo przydatna w aktywnym sterowaniu obiektów budowlanych poddawanych obciążeniom dynamicznym (a więc zmieniającym się w czasie), w tym – typu sejsmicznego oraz parasejsmicznego.

Na rysunku 10 pokazano jeden z wyników testowania sieci proponowanej do prognozowania kolejnego kroku czasowego odpowiedzi obiektu na podstawie wymuszenia oraz odpowiedzi z kroków poprzednich widać, że nawet tak prosty emulator pozwala na bardzo dokładne przewidywanie zachowania konstrukcji w kolejnych krokach czasowych.

Neuronowe układy diagnostyczne do szacowania uszkodzeń

Neuronowe układy diagnostyczne mogą być wykorzystywane do wykrywania uszkodzeń konstrukcji i rozpoznawania ich lokalizacji. Wykorzystanie takich układów do prognozowania uszkodzeń konstrukcji poddanych trzęsieniom ziemi proponują autorzy wielu prac, np. Wu i in. (1992).

Standardowy sposób wykorzystania sztucznych sieci neuronowych w diagnostyce sprowadza się do budowy neuronowego klasyfikatora stanów obiektu, który można traktować jako funkcję zebranych i aktualnych danych pomiarowych. Zatem problem ten można traktować jako neuronowe rozpoznawanie pewnego typu obrazów, za które uważa się stany obiektu – normalny albo uszkodzony. W przypadku stwierdzenia stanu uszkodzonego, dalszym celem jest wskazanie rodzaju uszkodzenia oraz podanie jego lokalizacji.

W artykule *Use of neural networks in detection of structural damage* (Wu i in. 1992) do oceny uszkodzeń konstrukcji wykorzystano odpowiedź konstrukcji na rzeczywiste wymuszenia sejsmiczne i fakt, że zmiany w odpowiedzi dynamicznej obiektu oraz zmiany w jego charakterystykach dynamicznych są następstwem różnych uszkodzeń. Konstrukcją jest rama płaska o trzech kondygnacjach ze sztywnymi ryglami oraz odkształcalnymi słupami. Odpowiedź konstrukcji wyznaczana była metodą elementów skończonych, a uszkodzenie modelowane poprzez redukcję sztywności uszkodzonej kondygnacji (redukcja 100% oznacza całkowite uszkodzenie, a 0% brak uszkodzenia). Każdy akcelerogram w poziomie najwyższej kondygnacji przekształcano szybką transformacją Fouriera (FFT) w spektrum Fouriera, które stanowiło wektor wejścia sieci neuronowej. Wartości wyjściowe sieci posłużyły do oceny poziomu uszkodzeń słupów pierwszej, drugiej i trzeciej kondygnacji, przy czym: wartość 0,0 odpowiada 100% uszkodzenia, wartość 1,0 odpowiada 0% uszkodzenia, wartość 0,25 odpowiada 75% uszkodzenia itd.

Zdolności prognozowania uszkodzeń z użyciem sieci są bardzo dobre dla trzeciej kondygnacji, ale dają nie najlepsze oszacowania dla kondygnacji pierwszej

i drugiej (Wu i in. 1992). Wydaje się, że tę dokładność można byłoby poprawić poprzez zastosowanie bardziej różnorodnej informacji wejściowej, nie tylko samego spektrum Fouriera, ale np. częstotliwości drgań własnych, postaci drgań itp.

Uwagi końcowe

Przedstawione wyniki badań i analiz różnego typu problemów występujących w wyniku oddziaływań pochodzenia sejsmicznego (trzęsień ziemi, wstrząsów górniczych) ukazują, że te problemy można z sukcesem rozwiązywać, wykorzystując sztuczne sieci neuronowe. Prawdopodobnie zaprojektowane sieci neuronowe mogą być wygodnym narzędziem obliczeniowym w inżynierii sejsmicznej, o dokładności wystarczającej w praktyce.

W artykule omówiono tylko pewne wybrane przykłady zastosowania sieci neuronowych w inżynierii sejsmicznej i parasejsmicznej. W literaturze można znaleźć ich dużo więcej, a zainteresowanie w tej dziedzinie ciągle wzrasta. Obliczenia z użyciem sieci neuronowych mogą być traktowane jako propozycja alternatywna (konkurencyjna) do klasycznych metod obliczeniowych.

Bibliografia

- Bishop C.M., 1995. *Neural Networks for Pattern Recognition*. University Press, Oxford.
- Bishop C.M., 2006. *Pattern Recognition and Machine Learning*. Springer, Heidelberg.
- Chmielewski T., Zembaty Z., 1998. *Podstawy dynamiki budowli*. Arkady, Warszawa.
- Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R. (red. tomu), 2000. *Sieci neuronowe*, tom 6 monografii: *Biocybernetyka i inżynieria biomedyczna 2000*. Akademicka Oficyna Wydawnicza Exit, Warszawa.
- Faravelli L., Venini P., 1995. A neural network based device for structural control. [in:] *Proc. 10th European Conference on Earthquake Engineering*, G. Duma, A.A. Balkema, Rotterdam–Brookfield, 2775–2780.
- Haykin S., 1999. *Neural networks – a compressive foundation*, 2nd. ed. Prentice-Hall, Upper Saddle River, NY.
- <http://nisee.berkeley.edu>
- Jang J.-S., Sun Ch.-T., Mizutani E., 1997. *Neuro-fuzzy and soft computing. A computational approach to learning and machine intelligence*. Prentice Hall Intern. Inc., Upper Saddle River, NY.
- Korbicz J., Obuchowicz A., Uciński D., 1994. *Sztuczne sieci neuronowe – podstawy i zastosowania*. Akademicka Oficyna Wydawnicza PLJ, Warszawa.
- Kuźniar K., 2013. Sieci neuronowe w analizie drgań budynków wywołanych wstrząsami parasejsmicznymi i sejsmicznymi. Wydawnictwo Politechniki Krakowskiej, Kraków.
- Kuźniar K., Chudyba Ł., 2012. Neural Networks for the Analysis of Mine-Induced Vibrations Transmission from Ground to Building Foundation. [in:] *Communications in Computer and Information Science 311, Engineering Applications of Neural Networks*. Springer-Verlag Berlin Heidelberg, 162–171.
- Kuźniar K., Maciąg E., Tatara T., 2010. Prognozowanie spektrów odpowiedzi drgań fundamentów budynków od wstrząsów górniczych z zastosowaniem sieci neuronowych. *Prace Naukowe GIG. Górnictwo i Środowisko*, 4 (4), 50–64.

- Kuźniar K., Waszczyszyn Z., 2003. Neural simulation of dynamic response of prefabricated buildings subjected to paraseismic excitations. *Computers and Structures*, 81, 2353–2360.
- Maciąg E., 2002. *Drgania powierzchniowe w LGOM i ich oddziaływanie na zabudowę*. XXV Zimowa Szkoła Mechaniki Górotworu, Kraków, 395–410.
- Maciąg E., 2005. Ocena szkodliwości drgań budynków od wstrząsów górniczych na podstawie drgań ich fundamentów czy drgań gruntu? *Inżynieria i Budownictwo*, 12, 670–677.
- Masters T., 1996. *Sieci neuronowe w praktyce. Programowanie w języku C++*. Wydawnictwa Naukowo-Techniczne, Warszawa.
- Niewiadomski J., 2002. Magnitude and Neural Networks. [in:] H. Ogasawara, T. Yanagidani, M. Ando (eds.), *Seismogenic Process Monitoring*. Balkema, Tokyo, 355–363.
- Osowski S., 2006. *Sieci neuronowe do przetwarzania informacji*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- Rutkowski L., 2006. *Metody i techniki sztucznej inteligencji*. Wyd. Nauk. PWN, Warszawa.
- Tadeusiewicz R., 1993. *Sieci neuronowe*. Akademicka Oficyna Wydawnicza RM, Warszawa.
- Waszczyszyn Z., 2010. Advances of Soft Computing in Engineering. *CISM Courses and Lectures*, 512, Springer, Wien-New York.
- Wu X., Ghaboussi J., Garret J.H. Jr., 1992. Use of neural networks in detection of structural damage. *Computers and Structures*, 42 (4), 649–659.
- Zembały Z., 2004. Rockburst induced ground motion – a comparative study. *Soil Dynamics and Earthquake Engineering*, 24, 11–23.

Artificial neural networks in earthquake engineering

Abstract

The paper deals with the application of artificial neural networks in solving some problems concerning seismic and paraseismic engineering. Briefly discussed are: forecasting of seismic parameters as well as parameters of surface vibrations, prediction of the transmission of ground vibrations to building foundation vibrations, simulation of building response to seismic-type excitation, active control of building vibrations, the idea of diagnostic systems for the assessment of damage of buildings subjected to earthquakes.

Key words: neural networks, earthquakes, mining rockbursts, mine-induced vibrations

Krystyna Kuźniar
Pedagogical University of Cracow
Institute of Technology
ul. Podchorążych 2
30–084 Kraków, Poland