

17. O MOŻLIWOŚCIACH ZASTOSOWANIA SZTUCZNYCH SIECI NEURONOWYCH DO PROJEKTOWANIA BETONÓW O NISKIM WSKAŹNIKU WODNO-SPOIWOWYM

1. WPROWADZENIE

Betony wysokowartościowe (BWW) to nowoczesna grupa kompozytów cementowych. Proces kształtowania struktury prowadzący do otrzymania betonu o wysokiej wytrzymałości zwiększa szanse na to, że również inne cechy charakterystyczne (np. mrozoodporność, nasiąkliwość, moduł sprężystości, ścieralność i in.) będą polepszone w stosunku do analogicznych, typowych parametrów betonu zwykłego. Są oczywiście wyjątki od tej zasady, czego przykładem jest zjawisko skurczu (kontrakcji) zaczynu cementowego, tj. zmniejszenia objętości układu wskutek wzajemnego fizykochemicznego oddziaływania składników zaczynu cementowego [10]. Skutki tego zjawiska są szczególnie widoczne w przypadku betonów o wysokich wytrzymałościach, w których – oprócz dobrej jakości kruszywa i cementu – konieczne jest zwykle zastosowanie dużej ilości spoiwa oraz niskiej względnej ilości wody. W przypadku gdy wysokowartościowy beton o wskaźniku 0,30 (stosunku wodno-spoiwowym ω) nie jest właściwie pielęgnowany wodą przed związaniem, może pojawić się w nim od 200 do 300 samistnych mikroodkształceń skurczowych w ciągu pierwszych 24 godzin [1]. Owe mikroodkształcenia prowadzą (przy braku środków zaradczych, np. zbrojenia rozproszonego) do powstania mikrodefektów w postaci bardzo drobnych i licznych rys chaotycznie rozmieszczonych w objętości betonu [1, 8, 9, 12]. To w oczywisty sposób degraduje strukturę i w efekcie obniża m.in. ścieralność oraz szeroko pojętą trwałość betonu. Tak więc znaczenie właściwego doboru oraz zastosowania odpowiednich proporcji składników jest szczególnie ważne. Staranny dobór jakościowy komponentów jest bowiem konieczny do uzyskania pożądanych właściwości betonu, będących rezultatem ukształtowania struktury kompozytu, określonego kompozycją ilościową i stopniem rozdrobnienia poszczególnych składników. Wiodącą właściwością mechaniczną betonu jest wytrzymałość na ściskanie, dlatego powszechnie stosowane są metody projektowania składu o z góry założonej wartości tej cechy. W celu ograniczenia zakresu czasochłonnych i często kosztownych prac laboratoryjnych, potrzebnych do kalibracji modeli stosowanych w poszczególnych metodach, istnieje możliwość wykorzystania sztucznych sieci neuronowych do predykcji dowolnej cechy betonu, jak również świeżej mieszanki. W niniejszym artykule przedstawiono perspektywę (możliwości) zastosowania tego narzędzia do predykcji, np. wytrzymałości BWW o niskim stosunku wodno-spoiwowym.

2. KOMPUTEROWE METODY PROJEKTOWANIA MIESZANKI BETONOWEJ

Przedstawiając aktualny stan wiedzy na temat modelowania struktury betonu, należy nieco przybliżyć wybrane podejścia do analizy tego kompozytu. Pierwszym podejściem jest stosowanie analityczno-doświadczalnych i doświadczalnych metod projektowania składu mieszanki betonowej. Wykorzystuje się tutaj empiryczne zależności pomiędzy składem ilościowym (i niekiedy jakościowym) a takimi cechami, jak wytrzymałość czy konsystencja. Metody te pozwalają zaprojektować beton o zadanych cechach, lecz nie umożliwiają prowadzenia analizy i optymalizacji przestrzennej konfiguracji składników, jak również nie dają możliwości prognozowania zachowania tego kompozytu w konstrukcji (bądź próbie) pod obciążeniem. Drugim podejściem jest modelowanie struktury betonu polegające na budowie układów modelowych, których parametry są dobierane w sposób możliwie najlepiej opisujący ośrodek rzeczywisty. Metody te nadają się szczególnie do adaptacji komputerowej. Wyróżnić tutaj można dwa przykłady, tj. klasyczny model struktury Reniusa oraz jeden z bardziej zaawansowanych modeli opracowany przez Zubelewicza [1]. Modele te pozwalają określić sposób zachowania się kompozytu w konstrukcji pod obciążeniem (m.in. jego odkształcenie, mechanizm zniszczenia), a ponadto umożliwiają również zaprojektowanie składu mieszanki betonowej. Występuje tutaj jednak szereg problemów, z czego najważniejszym jest utrudnione wykorzystanie takich parametrów, jak: klasa cementu, stosunek wodno-spoiwowy czy uziarnienie kruszywa. W pierwszym etapie należy bowiem dokonać sformułowania zależności (zwykle empirycznych) pomiędzy powyższymi parametrami a parametrami modelu mechanicznego. Wymaga to czasochłonnej analizy i badań eksperymentalnych [1, 4, 10, 12]. Metody komputerowe mogą opierać się również na klasycznych równaniach służących do projektowania mieszanki betonowej.

Biorąc pod uwagę powyższą ogólną charakterystykę, do komputerowych metod stosowanych w projektowaniu składu betonu można zaliczyć:

- metody będące komputerową adaptacją metod klasycznych,
- metody bazujące na mechanicznych modelach betonu.

Należy w tym miejscu podkreślić, że liczna grupa modeli mechanicznych betonu nie uwzględnia dostatecznie dobrze niejednorodnej struktury tego kompozytu, traktując go jako ośrodek quasi-jednorodny. Bazują one na wynikach obserwacji doświadczalnych, pozwalających na budowę zazwyczaj złożonych modeli, których matematyczny opis jest uogólnieniem wyniku poznania w granicach obszaru obserwacji [4]. Charakteryzując tę grupę można stwierdzić, że opracowywane na przestrzeni lat modele pozwalają z dobrą zgodnością opisać pracę betonu i żelbetu w elementach konstrukcyjnych. Brak uwzględnienia faktycznej niejednorodności struktury, wynikającej m.in. z obecności kruszywa i pustek powietrznych na poziomie makroskopowym oraz zróżnicowania struktury krystalicznej, uniemożliwia jednak bezpośrednie wykorzystanie tych modeli do projektowania jakościowego i ilościowego mieszanki betonowej. Z kolei modele fizykochemiczne, opisujące przemiany zachodzące w zaczynie cementowym, nie pozwalają na projektowanie składu mieszanki betonowej oraz opisanie zachowania się tego kompozytu w konstrukcji. Stwarzają one jednak możliwość analizy i wyjaśnienia procesów i zjawisk wpływających na strukturę betonu dojrzałego.

Z powodu dużej różnorodności składników współczesnych kompozytów cementowych, wykorzystywanych jednocześnie i w różnych ilościach, związki między tymi

składnikami a właściwościami mechanicznymi materiałów wykraczać mogą poza możliwości prostego opisu inżynierskiego. Modele opisujące właściwości materiałów, zapisane w formie empirycznej, korzystają ze znanych powszechnie zależności matematycznych, obarczonych niekiedy dużymi uproszczeniami. Na przykład: analizując wpływ dodatków popiołowych na wytrzymałość czy trwałość betonu, pomija się na ogół wpływ zmiennej konsystencji mieszanki lub zmiennej zawartości domieszek uplastyczniających, przyjmując, że jest pomijalnie mały [5]. Zagadnienie wyznaczania parametrów betonu komplikuje się w przypadku mnogości parametrów jego składu (różnych właściwości cementu i jego zawartości, różnych właściwości i zawartości domieszek chemicznych, włókien, ziaren kruszywa), warunków wykonania i pielęgnacji, a także agresywnych oddziaływań środowiskowych. Sformułowanie modelu empirycznego w wielowymiarowej przestrzeni parametrów składu i właściwości kompozytu może okazać się zbyt skomplikowane. W takiej sytuacji do obiektywnego rozpoznania związków między składem a właściwościami kompozytu można wykorzystać metody komputerowe, zwane niekiedy metodami sztucznej inteligencji [5]. Zaletą wykorzystania technik komputerowych w postaci sztucznych sieci neuronowych, do rozwiązania tak postawionego problemu jest to, że nie ma konieczności wyprowadzania jawnych zależności matematycznych, bowiem sieci w procesie uczenia przypisują kolejnym zmiennym adekwatne wagi, dążąc do podanego im wzorca (wykreowanego w procesie badań empirycznych).

3. WYKORZYSTANIE SIECI NEURONOWYCH DO PREDYKCJI WYBRANYCH PARAMETRÓW BETONU O NISKIM STOSUNKU WODNO-SPOIWOWYM


Stosowanie metod sztucznej inteligencji, takich jak metody sztucznych sieci neuronowych, wymagają przygotowania odpowiednich baz danych. W odniesieniu do betonu o niskim stosunku wodno-spoiwowym bazę danych stanowi wyselekcjonowany i uporządkowany zestaw informacji na temat tego materiału, technologii, eksploatacji, jego cech i właściwości. Bazę danych zaprezentować można w postaci macierzy złożonej z wierszy i kolumn, które wypełniają nie tylko liczby, ale także charakterystyki jakościowe i nazwy. Istotne jest odpowiednie określenie struktury baz danych oraz analiza danych eksperymentalnych. Podstawowym zadaniem jest uzgodnienie jednolitej formy rejestracji i przekazywania danych. Dane o betonie składają się z danych wejściowych, stanowiących informację o tym, co wiadomo o danym materiale i jego wykonaniu oraz dane wyjściowe dotyczące cech, właściwości, które będą poddawane dalszej analizie i predykcji. Podczas opisu różnych zadań ta sama wielkość może być inaczej rozpoznawana. Przykładem może być wytrzymałość betonu na ściskanie. Przy predykcji tej cechy betonu na podstawie składu ilościowego mieszanki betonowej, wytrzymałość ta może być zmienną wyjściową (tj. szukaną). Z kolei podczas rozważań dotyczących właściwości mechanicznych betonu, po pewnym czasie, może być definiowana jako zmienna wejściowa. W ogólności przykładami zastosowania sztucznych sieci neuronowych w dziedzinie nauk technicznych są:

- aproksymacje, prognozowanie, przewidywanie danych wyjściowych bez konieczności jawnego definiowania związku między tymi danymi;
- klasyfikacje i rozpoznawanie wzorów;
- kojarzenie danych;
- analizy i przetwarzanie danych z ich predykcji.

Sieci neuronowe albo sztuczne sieci neuronowe SSN (ang. *Artificial Neural Networks ANN*) to ogólna nazwa pewnych struktur matematycznych i ich programowych lub sprzętowych modeli realizujących obliczenia lub przetwarzanie sygnałów poprzez rzędy elementów zwanych sztucznymi neuronami (perceptrony). Inspiracją do takiej struktury powstała z poznania budowy naturalnych neuronów i łączących je synaps (nośniki pamięci) oraz całych układów neuronowych, co jest w istocie domeną mózgu. SSN czasami określa się też interdyscyplinarną dziedziną wiedzy, zajmującą się konstrukcją, trenowaniem (uczeniem) i badaniem możliwości tego rodzaju sztucznych sieci. SSN stworzone jako programy komputerowe (np. w programie Statistica sieci neuronowe są jedną z dostępnych opcji) wygenerowano tak, aby przekształcać dane liczbowe w sposób, który jest wzorowany na funkcjonowaniu komórek nerwowych w mózgu. Podstawowym elementem składowym sztucznej sieci neuronowej jest element przetwarzający. Jest on specyficznym modelem rzeczywistych komórek wchodzących w skład układu nerwowego, odpowiedzialnego za przetwarzanie i analizę informacji w organizmie ludzkim. Rzeczywistą komórkę nerwową można traktować jako biologiczny system przetwarzania informacji. Informacje wprowadzone za pośrednictwem wejść (dendrytów) są przetwarzane wewnątrz komórki. Przetworzony sygnał przesyłany jest za pomocą aksonu do kolejnych komórek. W skład każdej sieci neuronowej wchodzi duża liczba elementów, mających zdolność przetwarzania informacji (neuronów), które skojarzone są ze sobą połączeniami o określonych parametrach (wagi), zmieniających się podczas procesu uczenia. Wyróżnia się następujące zasady łączenia neuronów między sobą:

- połączenia neuronów każdy z każdym,
- połączenia między kolejnymi warstwami w sieciach warstwowych,
- połączenia wybranych neuronów, np. z sąsiedztwa.

Współcześnie sieci neuronowe mają budowę warstwową, przy czym wyróżnia się następujące warstwy: wejściową, wyjściową oraz warstwy ukryte [3, 5, 6]. Neuron ma określoną liczbę wejść, do których wprowadzone są dane wejściowe: $x_1, x_2, \dots, x_n$, z połączonymi wagami: $w_1, w_2, \dots, w_n$. Proces zainicjowany przez dane wejściowe odzwierciedlany jest przez dwie podstawowe informacje zachodzące wewnątrz neuronu. Pierwsza polega na wyznaczeniu zagregowanej wartości wejściowej i realizowana jest przy wykorzystaniu funkcji agregującej, zwanej także „funkcją potencjału postsynaptycznego” (*funkcja PSP*). Drugi proces polega na wyznaczeniu wartości wyjściowej neuronu, za której wyznaczenie odpowiedzialna jest funkcja aktywacji (*funkcja przejścia*). Procesy te przedstawić można za pomocą schematu, przedstawionego na rysunku 1.



Rys. 1. Schemat działania modelu sztucznej sieci neuronowej, odzwierciedlający procesy zachodzące wewnątrz neuronu

Fig. 1. Diagram of an artificial neural network model reflecting processes taking place inside the neuron

Elementami składowymi sztucznego neuronu są zatem:

- n sygnałów wejściowych x_i z wagami w_i ,
- jeden sygnał wyjściowy y ,
- pobudzenie e neuronu, które jest sumą ważonych sygnałów wejściowych, wyrażone jako:

$$e = \sum_{i=1}^n w_i \cdot x_i - \theta$$

gdzie:

- θ – wartość progowa,
- funkcja aktywacji (przejścia) $f(e)$.

Szczególnie istotne znaczenie ma funkcja aktywacji, bowiem zagregowana wartość wejściowa neuronu staje się parametrem funkcji aktywacji danego neuronu. Wyróżnia się podstawowe typy tych funkcji: liniową i nieliniową, a do popularnych można zaliczyć: liniową, logistyczną, hiperboliczną, wykładniczą, sinusoidalną oraz równanie Gaussa [6]. Istotne jest też to, że cechą wspólną dowolnych sieci neuronowych jest struktura składająca się z neuronów połączonych ze sobą synapsami. Dalej, z synapsami związane są wagi, czyli pewne wartości liczbowe, których dobór i interpolacja zależy od przyjętego modelu SSN.

Podstawową cechą sieci neuronowych jest ich zdolność samoorganizacji oraz adaptacji do zmieniających się warunków, co wynika wprost z możliwości doboru wag, które mogą zmieniać się w procesie uczenia. Algorytmy SSN są narzędziem postrzeganym jako informatyczne, aczkolwiek uczące się w czasie, bowiem mają one zdolność dostosowania zasobu posiadanej wiedzy do możliwości jej dynamicznej zmiany. Jest to cecha fundamentalna, gdyż zdolność ta determinuje możliwość samouczenia się, co w sposób znaczący przyspiesza wykonywanie obliczeń. Uczenie polega tutaj na zmianach współrzędnych neuronów, w taki sposób, aby dążyły one do wzorca zgodnego ze strukturą analizowanych danych. Wobec tego kalibracja modelu fenomenologicznego (abstrakcyjnego) utworzonego przez sieć polega na adekwatnym doborze wag w procesie uczenia. Istotnym elementem SSN jest proces uczenia sieci. Wyróżnia się dwa podstawowe sposoby nauki:

- uczenie nadzorowane,
- uczenie nienadzorowane.

W trakcie uczenia się niektóre połączenia (wagi między neuronami) nabierają większego znaczenia, a niektóre nie biorą udziału w rozwiązaniu problemu (można by to porównać do zanikających połączeń w mózgu), dlatego istnieje możliwość określenia, które zmienne są istotne do rozwiązania istniejącego problemu [3, 6]. Charakterystyka sieci neuronowej zależy w znacznym stopniu od sposobu połączenia neuronów, czyli tzw. architektury sieci. Ze względu na tę cechę można wyróżnić:

- sieci jednokierunkowe,
- sieci rekurencyjne,
- samoorganizujące się mapy.

W sieciach jednokierunkowych występuje tylko jeden kierunek przepływu sygnałów. Wybrany pojedynczy sygnał przechodzi w takiej sieci przez każdy neuron dokładnie jeden raz w swoim cyklu. Sieci tego typu dzielą się na jednowarstwowe, dwuwarstwowe i wielowarstwowe. Najbardziej efektywnymi sieciami są sieci wielowarstwowe składające się z warstwy wejściowej, warstw ukrytych i warstwy wyjściowej.

Sieci rekurencyjne i samoorganizujące się mapy to w istocie sieci wielokierunkowe, charakteryzujące się m. in. sprzężeniem zwrotnym lub uczące się przez współzawodnictwo. Poniżej przedstawia się wybrane typy sieci neuronowych:

- a) warstwowe sieci liniowe (Adaline/Madaline, Perceptron Wielowarstwowy);
- b) warstwowe sieci nieliniowe:
 - sieci uczone algorytmem wstecznej propagacji błędu (BP),
 - sieci z funkcjami o symetrii kołowej (RBF);
- c) sieci ze sprzężeniem zwrotnym:
 - sieci Hopfielda,
 - sieci z dwukierunkową pamięcią asocjacyjną (BAM);
- d) sieci uczone przez współzawodnictwo:
 - sieci Kohonena (LVQ),
 - sieci samoorganizujące się (SOM);
- e) sieci rezonansowe (ART);
- f) sieci hybrydowe.

Składniki betonu i właściwości powstałego kompozytu analizowano dotychczas między innymi z użyciem następującego oprogramowania [5]:

- uzyskanego za pomocą implementacji sieci FuzzyARTMAP,
- opartego na koncepcji sieci ze wsteczną propagacją błędu BP,
- bazującego na sieciach wykorzystujących połączenia neuronów z innymi neuronami najbliższego sąsiedztwa, metodę najbliższych sąsiadów.

W przypadku rozwiązania z użyciem sieci Fuzzy ARTMAP (sieć rezonansowa) w trybie uczenia pod nadzorem współpracują ze sobą dwa układy oparte na koncepcji ART (ang. *Adaptive Resonance Theory*). Poszczególne układy ART są systemami pracującymi bez nadzoru. Kolejne obserwacje analizowane są równolegle i niezależnie w warstwie wejściowej i wyjściowej. System Fuzzy ARTMAP rozbudowuje oddzielny blok pamięci powiązań pomiędzy kategoriami wejścia i wyjścia, zapamiętując w ten sposób, jakie zestawy danych odpowiadają określonym właściwościom materiału. Jak stwierdzono w pracy [3], za pomocą tego rodzaju sieci, w przypadku danych silnie niejednorodnych (np. z zakresu technologii betonu), uzyskano poprawne rezultaty obliczeń. Ten rodzaj oprogramowania nie jest dostępny dla użytkownika programu Statistica.

Przykładem oprogramowania opartego na koncepcji wstecznej propagacji błędu są jednokierunkowe sieci wielowarstwowe MLP, dostępne jako jedna z opcji programu Statistica. Działanie sieci MLP (perceptron wielowarstwowy ang. *Multilayer Perceptron*) polega na: wprowadzeniu danych wejściowych, wyznaczeniu wartości wyjściowych neuronów ukrytych oraz wyznaczeniu wartości wyjściowej neuronu wyjściowego. Rezultat działania sieci zależy od: wartości wag neuronów ukrytych i wyjściowych oraz struktury sieci. Uczenie sieci jednokierunkowych wykonywane jest z „nauczycielem”. Oznacza to, iż do zbioru uczącego wchodzi wartości wprowadzone jako wejścia sieci wraz z odpowiadającymi im wartościami wyjściowymi. Celem uczenia jest wobec tego wygenerowanie takich wartości określających wagi, dla których wyjścia sieci będą zbliżone z rzeczywistymi wartościami. Proces uczenia ma w efekcie spowodować zmniejszenie błędu sieci, który stanowi zagregowana miara różnic pomiędzy wartościami rzeczywistymi wyjściowymi a obliczonymi [6]. Z uwagi na kierunek przepływu informacji o błędzie, algorytm uczenia tej sieci nazywany jest algorytmem wstecznej propagacji błędu (BP – ang. *Back Propagation*) (tzn. każdy neuron lokalnie zmniejsza swój błąd) i jest najbardziej rozpowszechnionym rozwiązaniem sztucznych sieci neuro-

nowych. Sieci tego typu uczą się raczej powoli i mają tendencję do poprawnego odtwarzania stosunkowo gładkich odwzorowań, pozbawionych nieciągłości, tzn. przy faktycznych nieciągłościach sieci te generują znaczne błędy [3]. W takiej sieci można zidentyfikować przepływ informacji zorientowany od warstwy wejściowej do wyjściowej – transportowana jest informacja niezbędna do obliczenia zmiennych wyjściowych, a od warstwy wyjścia do wejścia przesyłana jest informacja o błędzie wykorzystywanym w trakcie procesu uczenia.

Trzeci rodzaj oprogramowania bazującego na metodzie najbliższych sąsiadów obrazować mogą sieci RBF, dostępne jako jedna z opcji programu Statistica. Sieć RBF (ang. *Radial Basis Function*) o radialnych funkcjach bazowych posiada trzy warstwy: wejściową (neurony liniowe), ukrytą (neurony radialne), wyjściową (neuron liniowy). Uczenie sieci o radialnych funkcjach bazowych składa się z trzech etapów: określenie centrów radialnych, odchyłeń radialnych, wartości warg neuronu warstwy wyjściowej. Etap pierwszy to dobór centrów funkcji bazowych poprzez określenie wartości wag dla każdego neuronu radialnego – są to punkty, dla których wartość wyjściowa neuronu będzie maksymalna. Drugi etap sprowadza się do doboru szerokości funkcji aktywacji – parametru określającego kształt funkcji aktywacji, przechowywanego jako wartość progowa neuronu radialnego. Określenie kształtu (szerokości) funkcji aktywacji odbywa się za pomocą metody najbliższych sąsiadów. Polega ona na tym, że w charakterze przyjmuje się odchylenie standardowe z odległości pomiędzy wektorem wag rozpatrywanego neuronu a wektorami wag najbliższych neuronów radialnych. Liczba uwzględnionych neuronów sąsiedzkich jest wyspecyfikowana w polu edycyjnym. Informacja o szerokości funkcji aktywacji przechowywana jest w postaci wartości progowej neuronu [6]. Sieć RBF charakteryzuje się znacznie prostszą topologią aniżeli sieć MLP. Ponadto sieci tego typu mogą okazać się nadmiernie wrażliwe nawet na nieliczne błędy lub anomalie w danych uczących, dotyczących zmiennych ilościowych i jakościowych, np. mieszanki betonowej.

Dane poddawane analizie, w przypadku korzystania z SSN, dzielone są na następujące zbiory, noszące nazwy:

- zbiór uczący (ok. 70% liczebności przypadków),
- zbiór testowy (ok. 15% liczebności przypadków),
- zbiór walidacyjny (ok. 15% liczebności przypadków).

Taki podział danych sprawia, że sieć neuronowa losuje 85% danych, na których przebiega proces uczenia i korygowanie wag dla wprowadzonych danych wejściowych (np. stosunek wodno-spoiwowy, masa: wody, cementu, mikrokrzemionki, kruszywa, oznaczenie rodziny betonu). Zbiór walidacyjny pozwala natomiast na ocenę (egzamin) prognozowanej wartości, np. wytrzymałości z wartościami, których program się nie uczył ani nie testował.

Opracowanie bazy danych, omówionej powyżej, opartej na parametrach betonu o niskim stosunku wodno-spoiwowym będzie elementem podejmowanym w dalszych rozważaniach autorów niniejszej pracy. Po zbudowaniu bazy danych będzie można przystąpić do określania topologii sieci neuronowej, tj. określenia liczby danych wejściowych i wyjściowych, ustalenia liczby i organizacji neuronów w poszczególnych warstwach, sprecyzowanie funkcji aktywacji i błędu. Autorzy zamierzają wykorzystać SSN do projektowania betonów o niskim wskaźniku wodno-spoiwowym. Badane będą betony, których składniki zmieniać się będą w stosunkowo niewielkim zakresie, ponieważ niewielka zmiana stosunku wodno-spoiwowego, będzie miała znaczący wpływ na

przebieg zmian fazowych w zaczynie cementowym. Zaczyn o ilości wody wynikającej z wodożądności normowej spoiwa jest ośrodkiem, w którym osiągnięto maksymalną szczelność upakowania ziaren fazy stałej [7]. Sytuacja ta odpowiada całkowitemu wypełnieniu przestrzeni międzyziarnowych wodą, zaś grubość warstwy wodnej otoczki na ziarnach osiąga minimalną wartość wynikającą z sił oddziaływania elektrostatycznego. Jeżeli $\omega < \omega_n$, to elektryczne warstwy podwójne otaczające sąsiadujące ze sobą ziarna zaczynają na siebie zachodzić, co uniemożliwia przedostanie się wody pomiędzy ziarna cementu. Dochodzi do powstania wolnych (wypełnionych powietrzem) przestrzeni międzyziarnowych. Konieczne jest zatem stosowanie superlastyfikatorów oraz specjalnych metod zagęszczania. Złożoność owego zagadnienia wpływa na dobór adekwatnej sieci neuronowej. Do dalszej analizy wybiera się jednokierunkowe sieci wielowarstwowe MLP, oparte na algorytmie wstecznej propagacji błędów, ze względu na:

- dostępność w programie Statistica,
- aproksymację globalną tego rodzaju sieci,
- bardziej złożoną topologię aniżeli sieci RBF,
- algorytm uczenia oparty na wstecznej propagacji błędów (charakteryzuje go większa złożoność, aniżeli sieci oparte na metodzie najbliższych sąsiadów).

Dane wejściowe stanowić będą:

- zmienne o charakterze ilościowym (stosunek wodno-spoiwowy, masa: wody, cementu, mikrokrzemionki, kruszywa),
- zmienne o charakterze jakościowym (np. oznaczenie rodziny betonów).

Dane wyjściowe stanowić będą:

- wytrzymałość betonu na ściskanie,
- mrozoodporność,
- nasiąkliwość.

Sieci neuronowe jako narzędzie służące predykcji i określaniu parametrów fizycznych betonu były wykorzystywane między innymi w pracach [2, 3, 5], na przykład do predykcji wytrzymałości betonu na ściskanie, co wskazuje na zasadność podejmowanych rozważań.

4. PODSUMOWANIE

Cechą wyróżniającą spośród innych metod komputerowych jest to, iż sztuczne sieci neuronowe w sposób szczególny generują zależności pomiędzy informacją wejściową a wyjściową. SSN różnią się w istotny sposób od konwencjonalnych programów komputerowych, które można określić jako sekwencyjne [5], czyli aby rozwiązać problem obliczeniowy, należy utworzyć algorytm składający się z zadanego ciągu instrukcji. Są one realizowane, w założonej kolejności, więc w programie takim należy przewidzieć wszystkie ewentualności, na jakie program ma reagować, np. jak silny jest związek pomiędzy stosunkiem wodno-spoiwowym a wytrzymałością betonu na ściskanie, i odpowiednio zlokalizować je w zadanej instrukcji. W działaniu sieci neuronowej można wyodrębnić etap nauki, kiedy sieć gromadzi informacje potrzebne jej do określenia, co i jak ma robić (w etapie tym mieści się również walidacja), oraz etap normalnego działania, podczas którego opierając się na zdobytej wiedzy sieć rozwiązuje konkretne zadania [3, 5, 6].

Pomimo powszechnego stosowania betonu od kilku dziesięcioleci, popularność nowoczesnych kompozytów cementowych stale rośnie. Tendencja ta jest uwarunkowana przede wszystkim ciągłymi pracami badawczymi, mającymi na celu polepszenie ich podstawowych właściwości, co wskazuje między innymi na stosowanie betonów wysokowartościowych. Spośród tej grupy betonów, w niniejszej pracy, podjęto problem opisu wybranych właściwości betonów o niskim stosunku wodno-spoiwowych jako rodziny betonów. Nie ulega wątpliwości, że wytrzymałość jest wiodącą cechą mechaniczną betonu jako materiału budowlanego. Rezultaty badań stwarzają coraz to nowe możliwości zastosowań, a w dotychczas stosowanych rozwiązaniach uzyskuje się dodatkowe korzyści. Należy zaznaczyć, że badania eksperymentalne znacznie wyprzedziły rozważania teoretyczne. Praktyczne spostrzeżenia są niezwykle ważne, jednak pełne zrozumienie istoty procesu kształtowania struktury wymaga wnikliwej analizy teoretycznej tego problemu. Z tego względu należy podkreślić wyższość metod analityczno-doświadczalnych nad doświadczalnymi. Aby jakikolwiek teoretyczny model (matematyczny, geometryczny) mógł być wykorzystany w praktycznym projektowaniu składu mieszanki betonowej, musi zostać poprawnie skalibrowany. Kalibracja jest także niezbędna przy każdorazowej zmianie parametrów wejściowych, jak również wprowadzeniu nowych zmiennych. Proces ten wymaga przeprowadzenia niezbędnych badań laboratoryjnych próbnymi seriami betonów. Te czynności badawcze wymagają najczęściej określonych nakładów czasowych i finansowych.

Na podstawie wstępnych rozważań zawartych w niniejszej pracy można stwierdzić, że wykorzystanie sztucznych sieci neuronowych do predykcji wybranych cech betonu o niskim stosunku wodno-spoiwowym, może okazać się przydatne do opracowania nowej, analityczno-doświadczalnej metody projektowania składu betonów wysokowartościowych i innych nowoczesnych kompozytów cementowych. Wymaga to przede wszystkim obszernych badań laboratoryjnych, które będą wykonywane w ramach dalszych rozważań autorów niniejszej pracy. Stworzenie bazy danych pozwoli na budowę konkretnej sieci neuronowej MLP, opartej na algorytmie wstecznej propagacji błędów.

LITERATURA

- [1] Aitcin P.C., 2000. Trwały wysokowartościowy beton – sztuka i wiedza. Konferencja Beton na progu nowego milenium. Wydawnictwo Polski Cement Kraków.
- [2] Kasperkiewicz J., Alterman D., 2003. Rozpoznawanie właściwości betonu metodami sztucznej inteligencji: Metody diagnozowania betonów i betonów wysokowartościowych na podstawie badań strukturalnych. IPPT PAN Warszawa.
- [3] Kasperkiewicz J., 2004. O możliwościach zastosowań metod sztucznej inteligencji w inżynierii lądowej. Drogi i Mosty 3, 15-36.
- [4] Majewski S., 2003. Mechanika betonu konstrukcyjnego w ujęciu sprężysto-plastycznym. Wydawnictwo Politechniki Śląskiej Gliwice.
- [5] Marks M., 2010. Wykorzystanie metod uczenia maszynowego do rozpoznania związków między składem betonu modyfikowanego dodatkami popiołowymi a jego właściwościami. Drogi i Mosty 3, 39-54.
- [6] Materiały szkoleniowe Statsoft 2010. Analiza danych w programie Statistica, Kraków.

- [7] Mrozik Ł., 2012. Model struktury i wytrzymałość betonu wysokowartościowego. Rozprawa doktorska. Uniwersytet Technologiczno-Przyrodniczy w Bydgoszczy.
- [8] Mrozik Ł., Kaczmarek A., Doering M., 2013. Dodatki mineralne w produkcji wibroprasowanych elementów betonowych. Materiały Budowlane 10, 35-36.
- [9] Mrozik Ł., Kaczmarek A., Doering M., Gajewski J., 2014. Defekty wibroprasowanych elementów betonowych. Materiały budowlane 12, 42-44.
- [10] Sulikowski J., 1981. Cement. Produkcja i zastosowanie. Wydawnictwo Arkady Warszawa.
- [11] Tadeusiewicz R., 1993. Sieci neuronowe. Akademicka Oficyna Wydawnicza Warszawa.
- [12] Zubelewicz A., 1983. Propozycja nowego modelu strukturalnego betonu. Archiwum Inżynierii Lądowej 29(4).

USE OF THE NEURAL NETWORKS TO DESIGN CONCRETE WITH LOW WATER/CEMENT RATIO CEMENT PASTE

Summary. High-quality concrete is a modern group of cement composites. The major mechanical feature of concrete is ultimate compressive strength, so there are widely used designing method with preset value of this feature. There is possible to use artificial neural networks to predict any properties of fresh concrete as well as mixtures. For that reason, often expensive laboratory work - needed to calibrate the models used in the various methods, can be reduced. This paper presents the perspective of use artificial neural networks to predict, for example, ultimate compressive strength concrete with low water/cement ratio cement paste.