

ANDRZEJ POŻARYCKI<sup>1)</sup>

## IDENTYFIKACJA LICZBY I GRUBOŚCI WARSTW MODELU NOWEJ NAWIERZCHNI ODCINKA PRÓBNEGO METODAMI SZTUCZNEJ INTELIGENCJI

**STRESZCZENIE.** W artykule przedstawiono zastosowanie jednokierunkowych sztucznych sieci neuronowych (SSN) do ustalania przypuszczalnej liczby i grubości warstw modelu nowej nawierzchni podatnej odcinka próbnego. W zastosowanej metodzie zakłada się, że znane są tylko wyniki pomiarów uzyskane z badań ugięciomierzem FWD na powierzchni warstw asfaltowych wchodzących w skład typowej konstrukcji nawierzchni dla kategorii ruchu KR3. W oparciu o obliczenia symulacyjne ustalono kształt linii wpływu dla wybranych wariantów wzorując się na typowych konstrukcjach nawierzchni podatnych stosowanych w Polsce. Obliczone w ten sposób linie wpływu zostały wykorzystane do nauki sztucznej sieci neuronowej. W konsekwencji, tak wytrenowaną sieć zastosowano do ustalenia liczby i grubości warstw nawierzchni odcinka próbnego. W wyniku konfrontacji uzyskanych wyników z rzeczywistą konstrukcją nawierzchni odcinka próbnego stwierdzono, że uzyskane wyniki mogą być podstawą dalszych obliczeń statycznej identyfikacji modułów sprężystości warstw modelu nawierzchni metodą obliczeń odwrotnych.

**SŁOWA KLUCZOWE:** identyfikacja grubości warstw nawierzchni, obliczenia odwrotne, sztuczne sieci neuronowe w przód.

---

<sup>1)</sup> dr inż. – Zakład Dróg, Ulic i Lotnisk Politechniki Poznańskiej

## 1. SZTUCZNE SIECI NEURONOWE (SSN)

### 1.1. WPROWADZENIE

Metody wykorzystujące sztuczne sieci neuronowe, znajdują uznanie w grupie problemów inżynierskich, dla których klasyczne rozwiązania (np. te z wykorzystaniem równań różniczkowych, czy te które wymagają określania często nieliniowych związków między zmiennymi) wymagają złożonych, numerycznych obliczeń, niejednokrotnie związanych z relatywnie długim procesem obliczeniowym. W ogólnym przypadku obszary zastosowań SSN można sprowadzić do zadań klasyfikacyjnych, analizy skupień, predykcji, zadań związanych z rozpoznawaniem wzorców oraz aproksymacji funkcji. Spośród dostępnej, obszernej literatury światowej, przystępny opis tych zagadnień czytelnik znajdzie w pracach [1], [2]. W Polsce problemy zastosowania SSN szeroko zostały opisane między innymi w pracach [3 - 5]. Ze studiów literatury opisującej SSN [1 - 7] wynika, że poszukiwanie rozwiązań w oparciu o metody sztucznych sieci neuronowych sprowadza się do mapowania zbiorów deklarowanych w warstwie wejściowej i wyjściowej sieci. W przypadku analizy zbiorów w przestrzeni wielowymiarowej najbardziej powszechne, stosowane w wielu dziedzinach nauk inżynierskich, są następujące typy SSN: jednokierunkowe SSN (ang. *Feedforward Neural Network*, FFNN), SSN z radialną funkcją aktywacji (ang. *Radial Basis Function Neural Network*, RBFNN), sieci wykorzystujące kwantyzację wektorową (ang. *Vector Quantization Neural Networks*, VQNN), SSN Hopfielda. Wszystkie powyżej zestawione typy SSN podlegają nauce w tzw. trybie z „nauczycielem”. Oznacza to, że w procesie trenowania sieci, kompletny zbiór danych składa się z wektora wejściowego i wektora wyjściowego. Wektor wyjściowy to  $n$  – elementowy wektor, z poprawnymi odpowiedziami. Odmienną ideę trenowania SSN stosuje się w trybie nauki „bez nauczyciela”. W takich przypadkach mamy do czynienia z sieciami samoorganizującymi się (ang. *Self Organizing Maps*, SOM). Spośród przedstawicieli tej grupy, należy wymienić sieci Kohonena i sieci rezonansowe (ang. *Adaptive Resonance Theory Neural Networks*, ARTNN). Odrębną grupę spośród metod sztucznej inteligencji stanowią automaty komórkowe. Aspekty definicji, klasyfikacji i ich zastosowań można znaleźć między innymi w pracy [8].

### 1.2. WARUNKI PRAKTYCZNEGO WYKORZYSTANIA SSN

Wykorzystanie SSN w rozwiązaniu rzeczywistych problemów, sprowadza się do kilku podstawowych kroków:

- Zaprojektowania struktury SSN oraz powiązania między warstwami.
- Przyjęcia wymiarów wektora danych wejściowych i ustalenia liczby neuronów w warstwie wejściowej. Analogiczne kroki dotyczą warstwy wyjściowej. W naukach inżynierskich ten krok wymaga poprawnej definicji i znajomości badanego zjawiska.
- Dobrania liczby warstw ukrytych i liczby neuronów w poszczególnych warstwach. Pewne podstawy w tym zakresie zostały ujęte w znanym w teorii SSN

twierdzeniem Kołmogorowa [1], [6], [7]. W nawiązaniu do tego twierdzenia, przy „N” wejściach zakłada się (N+1) neuronów w warstwie ukrytej. Należy jednak pamiętać, że twierdzenie Kołmogorowa dowodzi możliwości aproksymacji funkcji wielu zmiennych. W rzeczywistym eksperymencie, liczba warstw, jak i neuronów w warstwie ukrytej może się znacznie różnić od tej, uzyskanej dzięki teorii Kołmogorowa [7]. W praktyce oznacza to konieczność testowania wielu wariantów przy założeniu, że dysponuje się wiarygodnym zbiorem danych wejściowych.

Podczas pracy z zadaniami, w których wykorzystuje się SSN warto pamiętać, że:

- Dla większości problemów inżynierskich brakuje jednoznacznych metod ustalania liczby neuronów w warstwach ukrytych. Najczęściej dobór tej liczby ma charakter doświadczalny.
- W fazie ustalania liczby iteracji (epok) dominują metody eksperymentalne. Obserwując zmiany na wykresie błędu (np. RMSE) można skutecznie ustalić ten parametr. Zbyt mała liczba iteracji powoduje „niedouczenie sieci”, przy zbyt dużej liczbie wzrasta ryzyko „przeuczenia” sieci.
- W doborze liczby neuronów dominują dwa nurty. W pierwszym zakłada się liczbę neuronów równą średniej geometrycznej liczby wejść i wyjść sieci. W trakcie obserwacji zachowania się sieci dokonuje się stopniowej redukcji. Drugi nurt zakłada, architekturę bez warstw ukrytych i stopniowe zwiększanie liczby neuronów.
- Kierując się koniecznością zminimalizowania ryzyka osiągnięcia minimum lokalnego zakładanej funkcji celu, stosuje się zasadę powtarzania obliczeń. Każde nowe obliczenia zaczyna się z innym pseudolosowym zbiorem wag (tzw. inicjalizacja, metoda „multistartu”).


### 1.3. MATEMATYCZNE ASPEKTY JEDNOKIERUNKOWEJ SSN, TRENOWANIE SIECI, KRYTERIA STOPU

W pracy przyjęto zasadę, że poprzez termin SSN, będzie się rozumieć jednokierunkową, wielowarstwową sztuczną sieć neuronową. W ogólnym przypadku SSN rozważa się jako strukturę jednostkowych elementów powiązanych ze sobą wagami. W przestrzeni 2D takie powiązanie ma interpretację geometryczną, którą przedstawiono na rysunku 1.

Poszukiwane wartości  $y_i$  dla przedstawionej na rysunku 1 struktury SSN obliczane są według zależności (1):

$$\hat{y}_i = \sigma \left[ \sum_{j=1}^3 w_{ji}^2 \sigma \left( \sum_{k=1}^K w_{kj}^1 x_k + b_j^1 \right) + b_j^2 \right]. \quad (1)$$

Równanie (1) stanowi przykład nieliniowego mapowania  $x \rightarrow \hat{y}$ , które w zwartej formie można wyrazić w postaci  $\hat{y} = g(\theta, x)$ . Wielkość  $\theta$  stanowi wektor wag, dla których poszukuje się wartości  $\theta = (w_{kj}^1, b_j^1, w_{ji}^2, b_j^2)$ .



Rys. 1. Przykład interpretacji geometrycznej struktury jednokierunkowej wielowarstwowej SSN (od lewej) wraz z powszechnie używaną w strukturach SSN sigmoidalną funkcją aktywacji  
 Fig. 1. Example of geometric interpretation of feedforward multilayered ANN structure (from left) with sigmoid activation function commonly used in ANN structures

Proces poszukiwania wartości wag, w teorii SSN nazywa się nauką (trenowaniem) sieci. Funkcja celu w przypadku analizowanej struktury jednokierunkowej SSN, trenowanej w oparciu o zestaw par danych typu  $(x_i, y_i)_{i=1}^N$ , może być wyrażona w postaci błędu RMSE danego zależnością (2). Poprzez poprawnie dobrane wartości wektora  $\theta$  rozumie się takie wartości, które minimalizują sumę MSE, czyli  $\hat{\theta} = \arg \min_{\theta} V_N(\theta)$ :

$$RMSE(\theta) = \sqrt{MSE} = \sqrt{V_n(\theta)} = \sqrt{\frac{1}{N} \sum_{i=1}^N [y_i - g(\theta, x_i)]^2}. \quad (2)$$

Do minimalizacji wykorzystuje się iteracyjne algorytmy optymalizacyjne (treningowe). W oparciu o studia literaturowe [1], [3], [6], [7] w pracy zdecydowano się wykorzystać algorytm Levenberga - Marquardta. Algorytm treningowy, zaczynając od wartości początkowych  $\theta^0$ , sukcesywnie obniża wartość MSE aktualizując wartości danego układu wag w kierunku ujemnego gradientu funkcji błędu w danym punkcie, np. zgodnie z zależnością (3):

$$\theta^{i+1} = \theta^i - \mu \cdot R \cdot \frac{d^2 V_N(\theta)}{d\theta^2}. \quad (3)$$

Podstawienie do zależności (3)  $\mu = 1$  oraz  $R = (H + e^{\lambda} I)^{-1}$ , gdzie  $H$  to odpowiednia część Hessianu funkcji  $V_N(\theta)$ ,  $I$  – macierz diagonalna, uzyskuje się możliwość sterowania procesem nauki za pomocą parametru  $\lambda$ . W każdej iteracji algorytm próbuje znaleźć taką wartość  $\lambda \pm \Delta\lambda$ , która zmniejszy sumę MSE. Proces minimalizacji uznaje się za zakończony, jeśli jeden z warunków (4) jest spełniony:

$$\begin{aligned} & \bullet \lambda > 10\Delta\lambda + \text{Max}[s], \text{ gdzie } s \text{ to największa wartość } H, \\ & \bullet \frac{V_N(\theta^i) - V_N(\theta^{i+1})}{V_N(\theta^i)} < 10^{-6}. \end{aligned} \quad (4)$$

Warto podkreślić [6], że jeśli wartości w warstwie wyjściowej SSN można wyrazić w zakresie od 0 do 1, to korzystnie jest zastosować sigmoidalną funkcję aktywacji. Uzyskuje się pewność, że podczas nauki SSN nie przekroczy się pożądanego zakresu (nauka sieci „podąża” we właściwym kierunku).

## 2. PRZEGLĄD LITERATURY OPISUJĄCEJ ZASTOSOWANIE SSN W IDENTYFIKACJI PARAMETRÓW KONSTRUKCJI NAWIERZCHNI DROGOWYCH

Powszechnie wiadomo, że w obszarze obliczeń związanych ze statyczną identyfikacją parametrów sprężystych warstw nawierzchni podatnych nie można w sposób jednoznaczny, korzystając z pomiarów przemieszczeń, ustalić jednocześnie wartości modułów sprężystości i grubości warstw [9]. Jeden z tych parametrów należy ustalić niezależnie np. grubość warstw, metodą próbek odwiercanych z nawierzchni. W obliczeniach przedstawionych w pracy [9] dowodzi się, że jednakowe wartości przemieszczeń można uzyskać dla dwóch konstrukcji różniących się np. grubościami

podbudowy oraz modułami podłoża, gdy pozostałe parametry są ustalone. W pracy [10] za najbardziej rozpowszechnione na świecie struktury SNN uznaje się sieci Hopfielda, sieci rezonansowe (ART), sieci samoorganizujące się (SOFM), sieci propagacji wstecznej (BPNN), sieci ze sprzężeniem zwrotnym (FBNN), sieci z radialną funkcją aktywacji (RBF), sieci realizujące regresję uogólnioną (GRNN). W oparciu o cytowane wnioski w pracy [10], stwierdza się, że sieci BPNN są najczęściej wykorzystywane w rozwiązywaniu zagadnień inżynierii lądowej.

Na świecie zagadnienie wykorzystania SSN w identyfikacji takich parametrów jak grubość warstw nawierzchni, moduł sztywności, sprężystości, czy próby ustalenia linii wpływowych od obciążenia są przedstawiane między innymi w pracach [10 - 13]. Dowodzi się w nich, że metody te stanowią interesującą alternatywę wobec np. konieczności odwiercania próbek z nawierzchni, ustalania wybranych właściwości w oparciu o stosowne badania laboratoryjne lub terenowe. Problem jednak, który towarzyszy stosowaniu tych metod często sprowadza się do trudności uogólnienia uzyskanych wyników na „szerszą” populację aniżeli tą wykorzystaną w eksperymentach numerycznych. Za główną jednak barierę szerszych zastosowań uznaje się powszechny brak wiarygodnych wyników badań rzeczywistych nawierzchni [10]. W pewnych obszarach działalności naukowej ograniczeniem będzie też fakt, że rozwiązanie z natury SNN, jest rozwiązaniem typu „czarna skrzynka”, nie uzyskuje się związku między zmiennymi. Jeśli taki aspekt jest ważny, SNN nie są poprawnym wyborem.

W pracy [11] podkreśla się przydatność SNN (tzw. „miękkich technik komputerowych”), szczególnie w przezwyciężaniu słabości algorytmów stosowanych w obliczeniach odwrotnych w zadaniach statycznej i dynamicznej identyfikacji parametrów nawierzchni (np. takich jak zbieżność, dokładność czy maksymalna liczba warstw w modelu). Zostały tam przedstawione rezultaty badań identyfikacji opartej o SSN i linie wpływu obliczone dla numerycznych modeli nawierzchni. Potrzebę tworzenia modeli SNN wyjaśnia się faktem, że np. zmienność grubości w nawierzchniach nie zawsze może być ustalona na podstawie próbek odwierconych z nawierzchni. Ważną uwagą zawartą w pracy [11] jest fakt, że w warstwie wyjścia nie zaleca się stosować wielu elementów jednocześnie. Takie postępowanie na skutek zwiększania liczby zmiennych, najczęściej związanych z sobą w sposób nieliniowy, nie zapewnia poprawnych wyników.

W pracy [14] przytacza się rezultaty eksperymentu, w którym SSN została wytrenowana w oparciu o 9500 obliczonych linii wpływu. Zwraca się uwagę na ostrożną interpretację wyników SNN szczególnie w odniesieniu do linii wpływu obliczonych na podstawie modeli nawierzchni. Proponuje się koncepcję wprowadzania „szumu” do poszczególnych wartości obliczanych przemieszczeń, które tworzą linię wpływu lub wykonywanie obliczeń przy wykorzystaniu nieliniowych modeli obliczeniowych.

W pracy [12] autorzy podali efektywność obliczeniową wykorzystanej SSN w kontekście liczby neuronów w warstwach ukrytych. Stwierdzono, że w przypadku 4 warstw ukrytych i 8 neuronów w każdej warstwie, otrzymuje się najniższą wartość błędu średniokwadratowego. W pracy [15] omówione zostały zagadnienia predykcji grubości warstw asfaltowych odcinka próbnego z wykorzystaniem jednokierunkowej SSN.

W [15] autorzy przedstawiają przypadek sieci wytrenowanej i weryfikowanej oparty na wynikach uzyskanych z pomiarów ugięciomierzem FWD na odcinku próbnym. W pracy [16] podjęto próbę ustalenia umownego rodzaju nawierzchni z wykorzystaniem sieci wykorzystującej kwantyzację wektorową (ang. *Vector Quantization Neural Network*, VQNN) i opisano przypadek trenowania SSN przy wykorzystaniu bazy danych zawierającej około 2500 teoretycznych linii wpływu będących symulacją pomiarów wykonanych ugięciomierzem FWD.

### 3. SFORMUŁOWANIE PROBLEMU, CEL PRACY I ZAŁOŻENIA

Z przeglądu dostępnej literatury, przedstawionego powyżej, nie można stwierdzić, że istnieje określony typ SSN przeznaczony ściśle do analiz konstrukcji nawierzchni drogowych. Najczęściej wykorzystuje się jednokierunkowe, wielowarstwowe SSN, przy czym do trenowania powszechnie używa się algorytmu propagacji wstecznej.

W artykule podjęto próbę zastosowania jednokierunkowej SSN, kierując się koniecznością uzyskania parametrów, które są niezbędne w standardowej procedurze statycznej identyfikacji modułów sprężystości (sztywności) warstw modeli nawierzchni opisywanej między innymi w [9]. Analiza wyników obliczonych metodą SSN została przeprowadzona przy założeniu, że znane są tylko linie wpływu będące symulacją pomiarów ugięciomierzem FWD i warunki brzegowe, dla których zostały obliczone. Przygotowano bazę danych, w której uwzględniono linie wpływowe obliczone dla 51 modelowych przekrojów poprzecznych nowej nawierzchni odcinka próbnego. Przekroje utworzono przy zachowaniu zasady, że należy uwzględnić poszczególne etapy budowy warstw asfaltowych nawierzchni odcinka próbnego. W pracy podjęto próbę zweryfikowania tezy, że w oparciu o wiele teoretycznych linii wpływu powstałych na skutek obciążenia wielu różnych modeli nawierzchni w umownych warunkach, istnieje możliwość wnioskowania o liczbie i grubości warstw nowej nawierzchni odcinka próbnego, wykorzystując jednokierunkową sztuczną sieć neuronową (SSN).

W podstawowym założeniu dotyczącym weryfikacji wytrenowanej SSN przyjmuje się zasadę, że nie będzie się rozważać „zdolności” ekstrapolacyjnych SSN. Oznacza to, że wykorzystana zostanie tylko te badania ugięciomierzem FWD na odcinku próbnym, które spełniają warunki sformułowane na potrzeby zbioru trenującego.

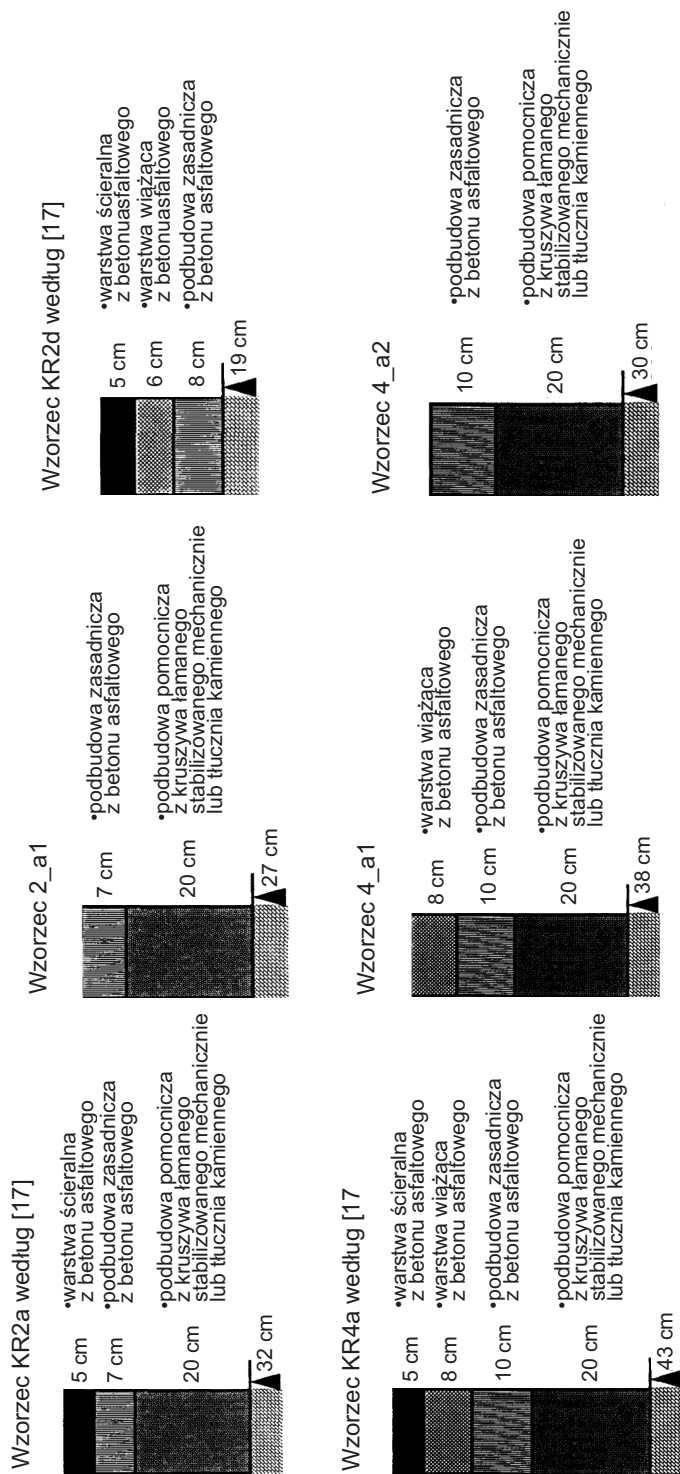
### 4. TECHNIKA PRZYGOTOWANIA ZBIORÓW UCZĄCYCH SNN

#### 4.1. PRZEKROJE POPRZECZNE NAWIERZCHNI WZORCOWYCH

Przyjęto, że zbiór do trenowania SSN będą stanowić teoretyczne linie wpływu uzyskane z obliczeń przemieszczeń pionowych dla modelu nawierzchni.

Wyjściowym wzorcem nawierzchni wykorzystanym do obliczeń linii wpływu od obciążenia statycznego są typowe nawierzchnie drogowe proponowane w rozporządzeniu [17]. Spośród wszystkich przedstawionych tam rozwiązań, brane są pod






Rys. 2. Przykładowe wzorce modeli nawierzchni wraz z grubościami warstw uwzględnione w obliczeniach teoretycznej linii wpływu  
 Fig. 2. Sample patterns of pavement's models with layers thickness used in calculations of theoretical deflection basins



uwagę tylko nawierzchnie przeznaczone dla kategorii ruchu KR2, KR3, KR4. O takim wyborze zdecydował fakt, że wytrenowana SSN ma być weryfikowana w oparciu o parametry nawierzchni podatnej dla kategorii ruchu KR3, którą wykonano na odcinku doświadczalnym opisanym między innymi w pracy [18]. Zgodnie z treścią przedstawioną w pracy [4], reprezentatywny zbiór jest podstawowym warunkiem uzyskania poprawnych wartości w oparciu o wyuczoną SSN. Oznacza to, że zbiór uczący w ogólnym przypadku powinien zawierać informacje o każdym typie nawierzchni, który może wystąpić w przewidywanych warunkach. Podczas budowy odcinka próbnego opisanego w pracach [15], [18], pomiary ugięciomierzem FWD wykonane zostały na powierzchni poszczególnych warstw asfaltowych. Z tego powodu w obliczeniach linii wpływowych, oprócz podstawowych rozwiązań przedstawionych w rozporządzeniu [17], obliczone zostały linie wpływu dla cząstkowych przekrojów poprzecznych. Przykładowe grubości i układy warstw nawierzchni przyjętych w obliczeniach symulacyjnych linii wpływowych przedstawiono na rys. 2.

## 4.2. OBLICZENIA TEORETYCZNEJ LINII WPŁYWU

Poszczególne linie wpływu obliczane były przy założeniu, że parametry warstw modelowanych nawierzchni są znane. Schemat przyjętego modelu obliczeniowego nawierzchni w oparciu o prace [9], [19] przedstawiono na rys. 3.



Rys. 3. Model nawierzchni drogowej wykorzystany w pracy  
Fig. 3. Model of road pavement used in this paper

Zgodnie z opisem przedstawionym między innymi w [9] oraz [19] przemieszczenia pionowe dowolnego punktu modelu nawierzchni, dla znanej funkcji naprężeń  $\Phi$  wyraża się wzorem (5):

$$w(r, z) = \frac{1}{2G} \left[ (2 - 2\nu) \nabla^2 \Phi - \frac{\partial^2 \Phi}{\partial z^2} \right], \quad (5)$$

gdzie:

$\nabla^2$  – Laplasjan,

$\Phi$  – funkcja naprężeń.

Do przedstawienia całkowitej postaci wzoru na przemieszczenie pionowe w warstwie o skończonej grubości wykorzystano funkcję naprężeń  $\Phi$  w postaci wyrażonej zależnością (6). Szczegółowe aspekty wyboru przedstawionej funkcji naprężeń i założeń towarzyszących takiemu rozwiązaniu można znaleźć między innymi w pracach [9], [19]:

$$\Phi(r, z) = G \int_0^\infty \left( \begin{array}{l} A_n \cdot \sinh(kz) + B_n \cosh(kz) + \\ + C_n \cdot kz \cdot \sinh(kz) + D_n \cdot kz \cdot \cosh(kz) \end{array} \right) \frac{J_0(kz)}{k^2} dk, \quad (6)$$

gdzie:

$G$  – moduł ścinania

$\nu$  – współczynnik Poissona,

$z, r, n$  – rzędna, odcięta i liczba warstw w przyjętym modelu (rys. 3),

$k$  – parametr całkowania.

$A_n, B_n, C_n, D_n$  – funkcje zmiennej  $k$ , wyznaczone z układu równań sformułowanych na podstawie warunków brzegowych, (w ogólnym przypadku według [19] mamy do rozwiązania  $N = 4 \cdot (n - 1) + 2$  równań ze względu na współczynniki  $A, B, C, D$ ),

$J_0$  – funkcja Bessela pierwszego rodzaju, rzędu zero.

Biorąc powyższe pod uwagę, przemieszczenia pionowe na powierzchni górnej warstwy modelu nawierzchni, obliczono według zależności (7):

$$w(r, z) = \frac{1}{2} \int_0^\infty \left( \begin{array}{l} -A_n \cdot \sinh(kz) - B_n \cosh(kz) + \\ + C_n [(2 - 4\nu) \cdot \cosh(kz) - kz \cdot \sinh(kz)] + \\ D_n [(2 - 4\nu) \cdot \sinh(kz) - kz \cdot \cosh(kz)] \end{array} \right) J_0(kr) dk. \quad (7)$$

Zbiór uczący dla SSN testowanych w tej pracy, przygotowano z uwzględnieniem linii wpływu obliczonych dla dwóch skrajnych warunków współpracy na styku sąsiednich warstw w modelu nawierzchni. Warunki te zostały szczegółowo opisane w monografii [19], a ich treść wyrażona jest zależnościami (8) i (9):

- dla warunku pełnej współpracy, gdzie zakłada się, że przemieszczenia poziome i naprężenia tnące są sobie równe:

$$u_i = u_{i+1} \quad \text{oraz} \quad \tau_i = \tau_{i+1}, \quad (8)$$

- dla warunku pełnego poślizgu, w którym zakłada się, że naprężenia tnące na styku sąsiednich warstw są równe 0:

$$\tau_i = 0 \quad \text{oraz} \quad \tau_{i+1} = 0. \quad (9)$$

W obliczeniach symulacyjnych na potrzeby zbioru trenującego przyjęto zasadę, że będą brane pod uwagę tylko warianty połączeń międzywarstwowych przedstawionych na rys. 4.



Oznaczenia:

~~~~~ pełna szczepność  
 - - - - - pełen poślizg

Rys. 4. Warianty połączeń międzywarstwowych w modelach nawierzchni uwzględnionych w zbiorze trenującym SSN

Fig. 4. Interlayer bonding versions in pavements models used for SSN training

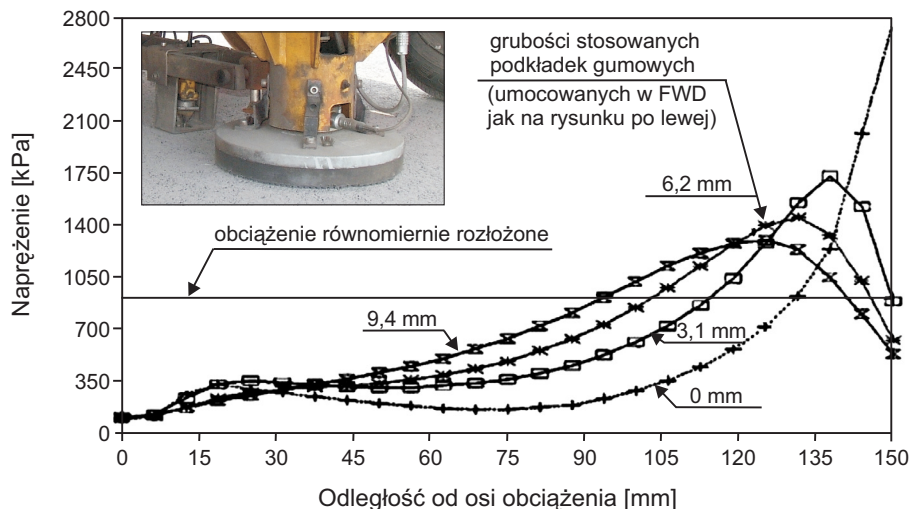
Biorąc pod uwagę, że obliczone wartości przemieszczeń zostaną wykorzystane do oceny nawierzchni poddanej badaniom ugięciomierzem FWD, wykorzystano model nawierzchni obciążony płytą w kształcie koła o średnicy 30 cm. Założenie upraszczające, o rozkładzie naprężeń pod płytą przekazującą obciążenie w ugięciomierzu FWD, przyjęto w oparciu o analizę wniosków zawartych w pracy [20]. zilustrowane przykłady ukazujące wpływ wybranych właściwości podkładki gumowej (przyklejonej do płyty obciążającej w ugięciomierzu FWD) na rozkład naprężeń pod płytą przedstawiono na rys. 5.

Mając na uwadze wnioski autorów pracy [20] przyjęto, że kompozytowa budowa płyty obciążającej w wykorzystanym ugięciomierzu FWD stanowi układ, który generuje rozkład naprężeń zbliżony do obciążenia równomiernie rozłożonego. Ostatecznie uwzględniono obciążenie modelu nawierzchni płytą podatną przy równomiernym nacisku o stałej wartości  $q$ . Postać całkowitą dla takiego obciążenia modelu nawierzchni, według [19], wyraża zależność (10):

$$q(r) = a \cdot q_{sr} \cdot \int_0^{\infty} J_0(kr) \cdot J_1(ka) dk, \quad (10)$$

gdzie:

$q_{sr}$  – obciążenie równomiernie rozłożone równe  $\frac{P}{\pi \cdot a^2}$ .



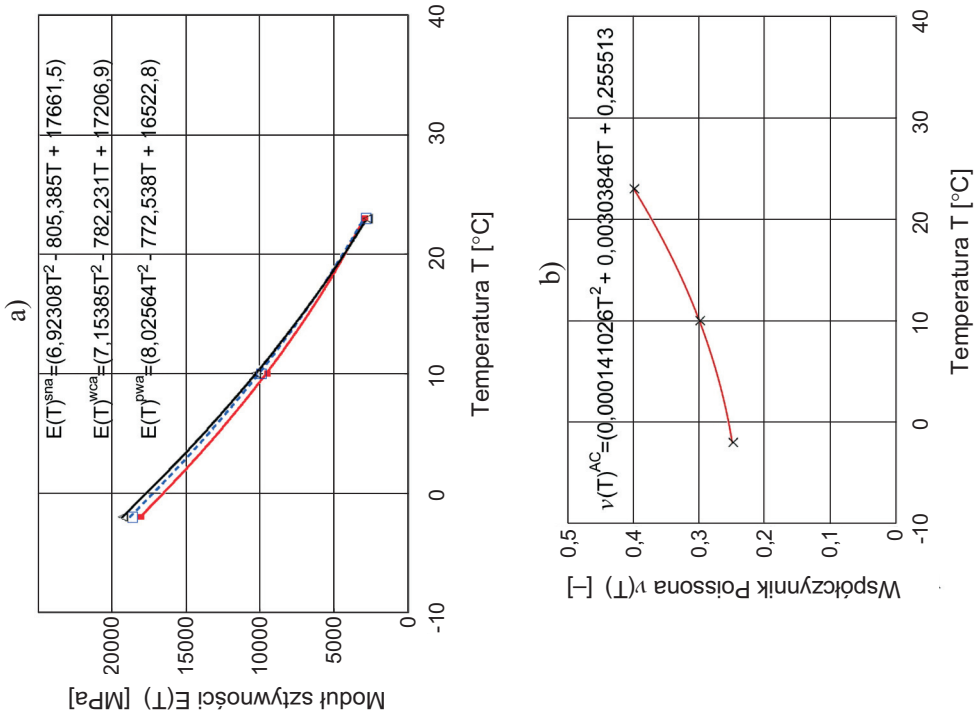
Rys. 5. Wpływ grubości podkładki gumowej mocowanej do płyty obciążającej w ugięciomierzach FWD na rozkład naprężeń pod płytą według [20]

Fig. 5. Influence of thickness of rubber pad fastened to loading plate in FWD on the stress distribution under the plate [20]

### 4.3. PARAMETRY OBLICZENIOWE MATERIAŁÓW W WARSTWACH MODELU NAWIERZCHNI

Moduły sprężystości (sztywności) materiałów poszczególnych warstw modelu nawierzchni przyjęto zgodnie z rozporządzeniem [17]. Na rys. 6 przedstawiono postać matematyczną funkcji opisujących zależność modułów sztywności MMA i współczynnika Poissona od temperatury.

Pozostałe wartości parametrów warstw modelu nawierzchni zestawione zostały w tabelicy 1. W zbiorze uczącym SSN, uwzględnione zostały również linie wpływu, które obliczono przy założeniu, że podłoże w modelu może mieć wartość modułu mniejszą niż 100 MPa (czyli wartość wymaganą w rozporządzeniu [17]). Wynika to z faktu, że typowa konstrukcja nawierzchni odcinka doświadczalnego została wykonana tylko na zagęszczonym podłożu z gruntu rodzimego. Z tego powodu założono zmienność wartości modułów sprężystości w obliczeniach symulacyjnych. Założenia mają charakter modelowy i dotyczą tylko opisanych tu warunków.



Rys. 6. Wartości modułu sztywności (a) i współczynnika Poissona (b) w funkcji temperatury warstw asfaltowych zgodnie z rozporządzeniem [17]  
 Fig. 6. Values of stiffness modulus (a) and Poisson ratio (b) as a function of temperature of asphalt concrete layers [17]

Tablica 1. Parametry warstw wykorzystane w obliczeniach teoretycznej linii wpływu [17]  
 Table 1. Parameters of layers used for theoretical deflection basins calculations [17]

| Warstwa                                              | Moduł sprężystości (sztywności) <i>E</i> oraz współczynnik Poissona <i>ν</i> |              |                     |              |                     |              |
|------------------------------------------------------|------------------------------------------------------------------------------|--------------|---------------------|--------------|---------------------|--------------|
|                                                      | w temperaturze -2°C                                                          |              | w temperaturze 10°C |              | w temperaturze 23°C |              |
|                                                      | <i>E</i> [MPa]                                                               | <i>ν</i> [-] | <i>E</i> [MPa]      | <i>ν</i> [-] | <i>E</i> [MPa]      | <i>ν</i> [-] |
| Podłoże                                              | 30÷90                                                                        | 0,30         | 30÷90               | 0,30         | 30÷90               | 0,30         |
| Kruszywo łamane stabilizowane mechanicznie (KLSM)    | 400                                                                          | 0,30         | 400                 | 0,30         | 400                 | 0,30         |
| Kruszywo naturalne stabilizowane mechanicznie (KNSM) | 200                                                                          | 0,30         | 200                 | 0,30         | 200                 | 0,30         |
| Chudy beton niespękany                               | 12900                                                                        | 0,20         | 12900               | 0,20         | 12900               | 0,20         |
| Chudy beton spękany                                  | 400                                                                          | 0,30         | 400                 | 0,30         | 400                 | 0,30         |
| Stabilizacja cementem niespękana                     | 4500                                                                         | 0,25         | 4500                | 0,25         | 4500                | 0,25         |
| Stabilizacja cementem spękana                        | 300                                                                          | 0,30         | 300                 | 0,30         | 300                 | 0,30         |
| Piasek otoczony asfaltem do warstwy podbudowy        | 12700                                                                        | 0,25         | 6800                | 0,30         | 2400                | 0,40         |

#### 4.4. ELEMENTY ZBIORÓW TRENINGOWYCH W ARCHITEKTURZE SSN

Wybór elementów zbioru uczącego dla danego typu SSN zależy od użytkownika. Przy założeniu, że trenowanie SSN będzie realizowane w trybie „z nauczycielem”, potrzebny jest zbiór dwuelementowy. Przyjęto, że pierwszy element zbioru uczącego (wejście SSN) stanowią:

- wartości przemieszczeń składające się na linię wpływu od zadanego obciążenia,
- wartość zadanego obciążenia w modelu nawierzchni odcinka próbnego,
- temperatura pakietu warstw bitumicznych (w połowie grubości tego pakietu).

Drugi element zbioru uczącego (wyjście SSN) to wektor poprawnych odpowiedzi:

- jednoelementowy wektor z liczbą warstw analizowanej nawierzchni (przypadek omówiony w punkcie 5.2.1),
- $n$ -elementowy wektor z grubościami poszczególnych warstw modelu analizowanej nawierzchni (przypadek omówiony w punkcie 5.2.2).

#### 4.5. PROCEDURA TWORZENIA ZBIORÓW TRENINGOWYCH – PODSUMOWANIE

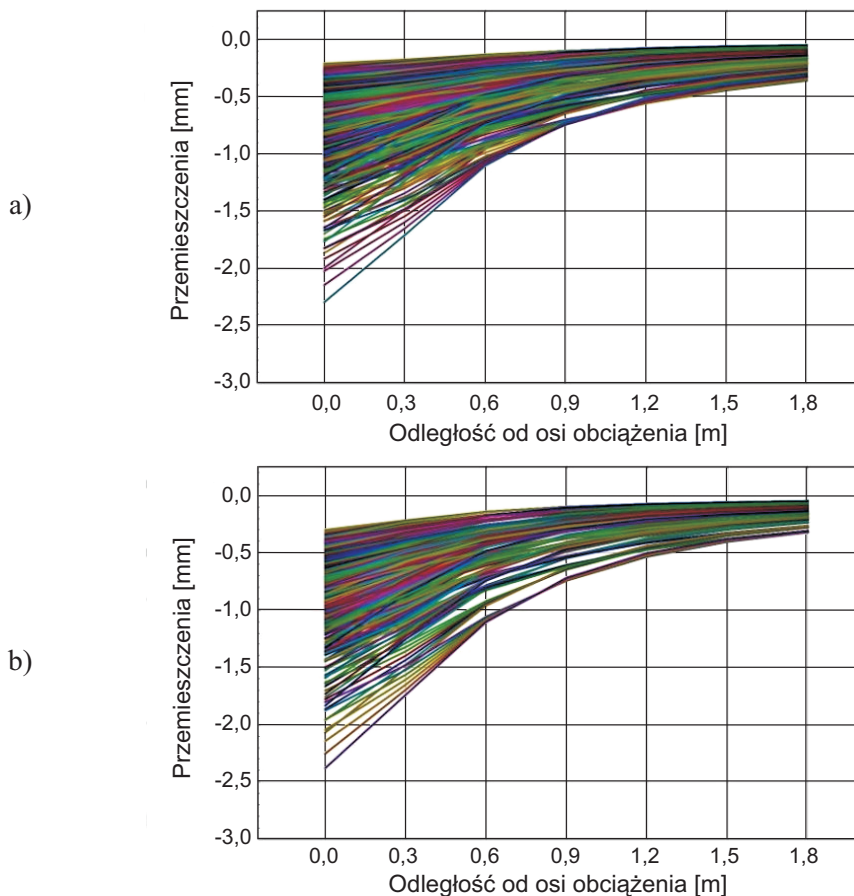
Procedurę do obliczania teoretycznych linii wpływu zapisano w kodzie środowiska obliczeniowego Mathematica v8. Funkcję przemieszczeń  $w(r, z)$  daną zależnością (7) rozwiązywano numerycznie. W wyniku szeregu prób, stwierdzono, że poprawne wyniki uzyskuje dla tzw. złożonej kwadratury całkowania metodą Gaussa-Kronroda. Kierując się koniecznością uzyskania stabilnego rozwiązania w każdych warunkach, przedział całkowania podzielono na 80 podprzedziałów, przyjmując granice całkowania dla zmiennej  $k$  w przedziale od 0 do 1.

Schemat algorytmu i szczegółowe wartości uwzględnione w procedurze tworzenia bazy danych zestawiono w kilku punktach poniżej:

1. Wybierz wzorzec modelu nawierzchni,
2. Utwórz  $N = 4(n - 1) + 2$  równań umożliwiających ustalenie postaci współczynników  $A_n, B_n, C_n, D_n$  w funkcji parametru  $k$ , na potrzeby zależności (7),
3. Dla danego modelu nawierzchni odcinka próbnego przyjmuj, że:
  - 3.1. Moduły sztywności warstw asfaltowych obliczone są dla temperatur  $T = (-2, 2, 6, 10, 14, 18, 22) ^\circ\text{C}$ ,
  - 3.2. Wartości obciążenia w modelu są równe  $P = (27,2; 35,0; 42,5; 50,0; 57,5)$  kN,
  - 3.3. Moduły sprężystości podłoża stanowią zbiór wartości  $E \approx E_{v2} = \langle 30 \div 90 \rangle$  MPa (z krokiem co 15 MPa),
  - 3.4. Powiązanie poszczególnych warstw modelu odpowiada trzem przypadkom zilustrowanym na rys. 4,
  - 3.5. Wariant modelu nawierzchni odcinka próbnego musi się składać przynajmniej z jednej warstwy asfaltowej (założenie o nawierzchni twardej ulepszonej).

4. Oblicz przemieszczenia na powierzchni najwyższej usytuowanej warstwy modelu dla kolejnych wzorców nawierzchni odcinka próbnego, zgodnie ze wzorem (7) w odległości od obciążenia  $r = (0; 0,3; 0,6; 0,9; 1,2; 1,5; 1,8)$  m,
5. Po obliczeniu wszystkich wartości przemieszczeń składających się na linię wpływu dla danych warunków zestawionych w punkcie 3, wybierz kolejny wzorec.

Na potrzeby tej pracy do zbioru uczącego SSN przygotowano łącznie 26 775 wzorcowych linii wpływu. Wobec powyższych uwzględnione zostały modele nawierzchni 3, 4 i 5-warstwowej. Przykłady obliczonych linii wpływu w uproszczonej postaci (sprowadzonej do punktów pomiarowych odpowiadających punktom pomiarowym w ugięciomierzu FWD) przedstawione zostały na rys. 7.



Rys. 7. Uproszczona przykładowa postać zbiorów obliczonych linii wpływu w przypadku warunków brzegowych: a) dla przekroju KR3a (według rys. 8), b) dla przekroju 3a\_2 (według rys. 8)

Fig. 7. Simplified sample form of calculated deflection basins sets for boundary conditions used in this paper: a) for cross section KR3a (according to Fig. 8), b) for cross section 3a\_2 (according to Fig. 8)



## 5. WERYFIKACJA UZYSKANYCH WYNIKÓW

### 5.1. RZECZYWISTE WARTOŚCI UGIĘĆ NAWIERZCHNI ODCINKA PRÓBNEGO

Wytrenowana sieć musi być poddana procesowi weryfikacji. Poprawność zwracanych rozwiązań oceniono w oparciu o wyniki pomiarów ugięciomierzem FWD na nowej nawierzchni odcinka próbnego.

Pomiary ugięciomierzem FWD, na poszczególnych fragmentach odcinka doświadczalnego wykonano w odległości co 1 m [15]. Pomiar w jednym miejscu wykonano 6-krotnie. W przypadku pomiarów ugięciomierzem FWD na warstwie ścieralnej uzyskano zbiór wyników umożliwiających konstrukcję linii wpływowych w ilości 60 sztuk. Dla pomiarów na warstwie wiążącej licznosc przygotowanego zbioru wynosiła 212 sztuk. Na podstawie wyników pomiarów FWD na warstwie podbudowy opracowano 222 linie wpływu. Pomiarów dokonano w słoneczne dni i przy bezdeszczowej pogodzie. Dodatkowe warunki wykonania pomiarów opisane zostały na rys. 8.

W nawiązaniu do wartości modułów sztywności przedstawionych na rys. 6 należy zauważyć, że wykorzystanie w procesie weryfikacji SSN wyników badań ugięciomierzem FWD na powierzchni warstwy ścieralnej wymaga ustalenia modułu sztywności warstwy ścieralnej poprzez ekstrapolację. Z tego względu, zgodnie z założeniami opisanymi w punkcie 3 artykułu, pomija się weryfikację wytrenowanej SSN w oparciu o wyniki pomiarów na warstwie ścieralnej odcinka próbnego.


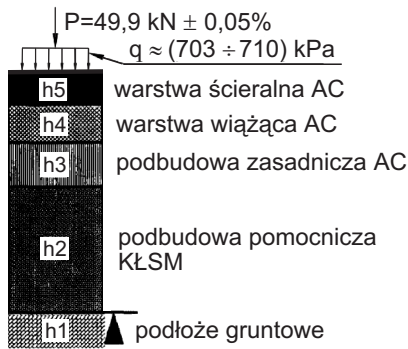
### 5.2. WYNIKI OBLICZEŃ PRZY WYKORZYSTANIU JEDNOKIERUNKOWEJ SSN

#### 5.2.1. Założenia ogólne

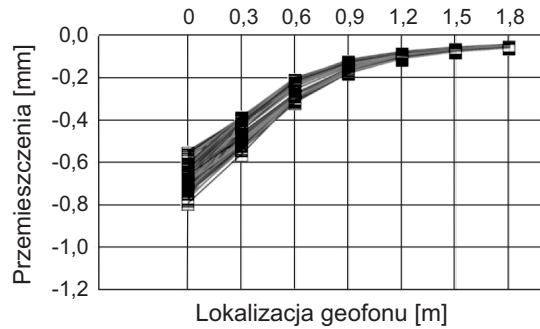
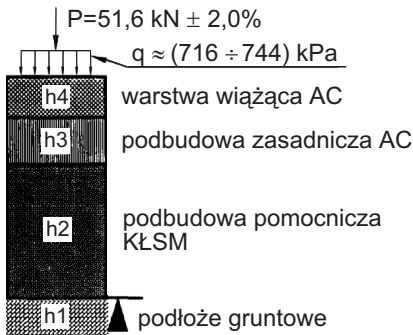
W strategii obliczeń przyjęto, że punktem wyjścia będzie SSN bez warstwy ukrytej, ale na wyjściu będzie neuron z sigmoidalną funkcją aktywacji. W dalszej kolejności liczba neuronów w pojedynczej warstwie ukrytej będzie konsekwentnie zwiększana według schematu: 1, 2, 3, 6, 9 neuronów. Ze względu na rozmiar wektora wejściowego, eksperyment ograniczono tylko do jednej warstwy ukrytej. Zastosowano metodę multi-startu z pseudolosowym doбором wag. Na rysunku 9 przywołano typowy kształt krzywej RMSE uzyskiwany w obliczeniach. Wynika z niego, że dla powyżej 20 iteracji uzyskuje się już znikomy spadek wartości RMSE. Dalsza kontynuacja trenowania SSN zwiększa już tylko ryzyko przeuczenia sieci.

#### 5.2.2. Poszukiwanie liczby warstw modelu analizowanej nawierzchni

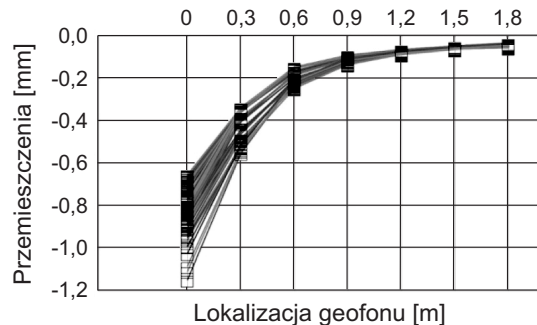
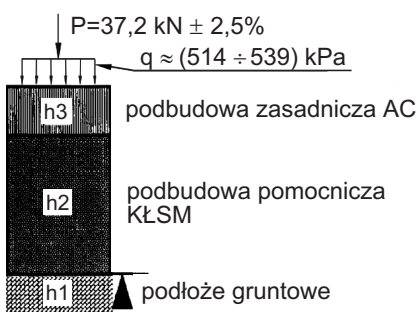
W ogólnym przypadku, liczba warstw w analizowanych modelach nawierzchni odcinka próbnego (wzorcach) należy do przedziału  $\langle 2 \div 5 \rangle$ . Mając to na uwadze, uogólniony schemat architektury testowanych sieci przedstawiono na rys. 10.



a) pomiary FWD na powierzchni warstwy ścieralnej,  $T_{asf}=30^{\circ}\text{C}$  (przekrój KR3a)




b) pomiary FWD na powierzchni warstwy wiążącej,  $T_{asf}=18^{\circ}\text{C}$  (przekrój 3a\_1)




c) pomiary FWD na powierzchni warstwy podbudowy,  $T_{asf}=16^{\circ}\text{C}$  (przekrój 3a\_2)

Rys. 8. Wyniki pomiarów ugięciomierzem FWD na powierzchni poszczególnych warstw asfaltowych nawierzchni odcinka próbnego  
 Fig. 8. The results of FWD measurements at the surface of particular layers of pavement in test section



Rys. 9. Typowy kształt krzywej RMSE uzyskiwanej w obliczeniach metodą SSN  
 Fig. 9. Typical form of RMSE curve obtained in calculations using ANN

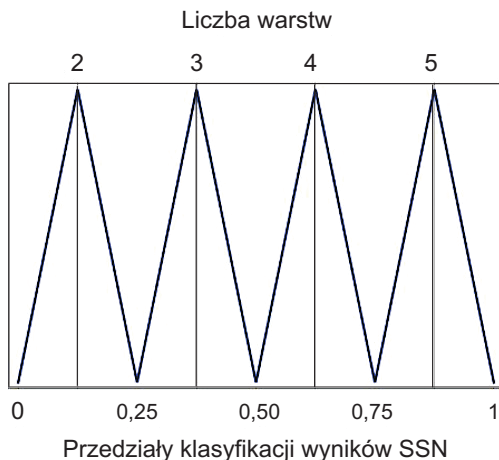


- T – temperatura mierzona w połowie pakietu warstw asfaltowych,  
 q – naprężenie pod płytą ugięciomierza FWD,  
 D0 ÷ D6 – przemieszczenia uzyskane z pomiarów ugięciomierzem FWD w odległości od osi obciążenia {0, 30, 60, 90, 120, 150, 180} cm,  
 $\Sigma\sigma$  – symbole pojedynczych neuronów z nieliniową (tu sigmoidalną) funkcją aktywacji,  
 $\hat{n}$  – poszukiwana liczba warstw modelu.

Rys. 10. Uogólniony schemat architektury SSN testowanej w procedurze ustalania liczby warstw modelu nawierzchni odcinka próbnego

Fig. 10. The general scheme of ANN architecture tested in procedure of identification of the number of layers in the model of pavement in test section

Ze względu na nieliniową charakterystykę neuronu na wyjściu, poszukiwaną liczbę warstw modelu wyrażono w skali wartości funkcji sigmoidalnej. Koncepcję zasady skalowania przyjęto na wzór tworzenia funkcji przynależności dla zmiennych rozmytych. Ilustrację tej koncepcji przedstawiono na rys. 11. Dla przykładu, wartość 0,52 zwrócona przez wytrenowaną SSN wskazuje na model 4-warstwowy.



Rys. 11. Zasada ustalania liczby warstw na podstawie wyników zwracanych przez wytrenowaną SSN

Fig. 11. The rule to determine the number of layers on the basis of results given by trained ANN

Deklaracja w wektorze wejściowym wytrenowanej SSN, zbioru weryfikującego skutkuje uzyskaniem na wyjściu sieci, wektora 1-elementowego. Wartość ta wskazuje na zidentyfikowaną liczbę warstw modelu nowej nawierzchni odcinka próbnego. Szczegółowe zestawienie uzyskanych wyników identyfikacji liczby warstw dla trenowanych w pracy SSN przedstawiono w tabelicy 2.

Tablica 2. Szczegółowe wyniki identyfikacji liczby warstw nawierzchni  
Table 2. Detailed results of identification of number of pavement layers

| Pomiar FWD na powierzchni warstwy:                                         | Liczba neuronów ukrytej warstwy SSN |   |   |   |   |   | Rzeczywista liczba warstw nawierzchni odcinka próbnego |
|----------------------------------------------------------------------------|-------------------------------------|---|---|---|---|---|--------------------------------------------------------|
|                                                                            | 0                                   | 1 | 2 | 3 | 6 | 9 |                                                        |
| Liczba warstw nawierzchni odcinka próbnego ustalona oparciu o wyuczoną SSN |                                     |   |   |   |   |   |                                                        |
| Podbudowy (BA)                                                             | 3                                   | 3 | 3 | 3 | 3 | 3 | 3                                                      |
| Wiążącej (BA)                                                              | 4                                   | 3 | 3 | 3 | 3 | 3 | 4                                                      |


Uzyskane histogramy dla wybranych przypadków zestawiono na rysunku 12.

Jedna warstwa ukryta (9 neuronów)


Jedna warstwa ukryta (3 neurony)

Brak warstwy ukrytej (wyjście nieliniowe)

a) przypadek pomiarów ugięciomierzem FWD na warstwie podbudowy z betonu asfaltowego



b) przypadek pomiarów ugięciomierzem FWD na warstwie wiążącej z betonu asfaltowego

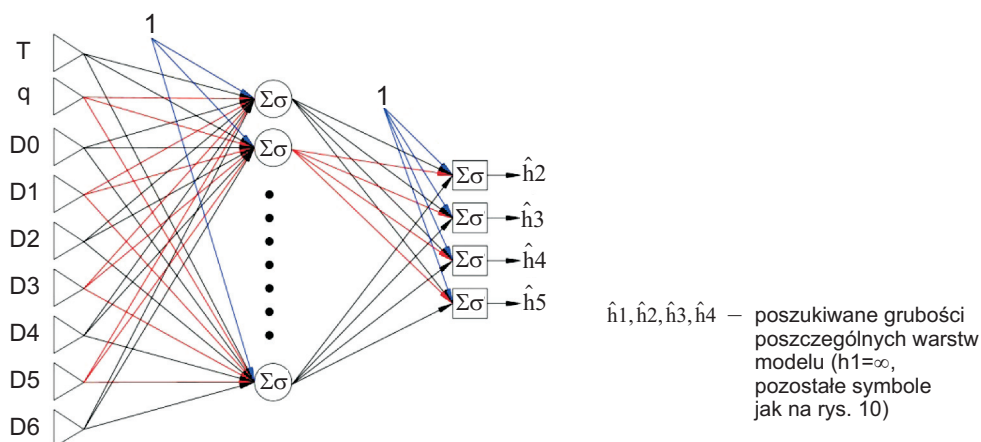


Rys. 12. Przykłady wybranych histogramów, zbudowanych w oparciu o wyniki identyfikacji liczby warstw nawierzchni przy wykorzystaniu wytrenowanych SSN

Fig. 12. Selected histograms showing results of identification of the number of pavement layers obtained with trained ANN

### 5.2.3. Ustalanie grubości warstw modelu analizowanej nawierzchni

W procedurze ustalania grubości warstw modelu nowej nawierzchni odcinka próbnego wykorzystano podobne warianty architektury SSN jak w przypadku przedstawionym w poprzednim akapicie. Różnica sprowadza się do innej postaci wektora wyjściowego, co zostało pokazane na rysunku 13.



Rys. 13. Ogólna postać SSN wykorzystana do ustalenia grubości warstw modelu nawierzchni  
 Fig. 13. General form of ANN used to determine the thickness of layers in pavement model

W tabelicy 3 przedstawiono szczegółowe wyniki identyfikacji grubości warstwy pomocniczej z kruszywa łamanego stabilizowanego mechanicznie. Zgodnie z oznaczeniami na rysunku 8 jest to warstwa  $h_2$  o średniej grubości równej 20 cm.

Tablica 3. Wyniki identyfikacji grubości warstwy  $h_2$   
 Table 3. Results of identification of  $h_2$  layer thickness

| Pomiar FWD na warstwie | Liczba neuronów w ukrytej warstwie SSN |      |      |      |      |                   |      |      |      |      |
|------------------------|----------------------------------------|------|------|------|------|-------------------|------|------|------|------|
|                        | 0                                      | 1    | 3    | 6    | 9    | 0                 | 1    | 3    | 6    | 9    |
|                        | Średnia grubość warstwy $h_2$          |      |      |      |      | Błąd względny [%] |      |      |      |      |
| Podbudowy              | 26,3                                   | 16,5 | 14,9 | 14,7 | 14,6 | 23,9              | 21,2 | 34,2 | 36,0 | 36,9 |
| Wiążącej               | 18,7                                   | 17,5 | 17,1 | 17,0 | 17,0 | 6,9               | 14,3 | 16,9 | 17,6 | 17,6 |

Wyniki szczegółowej identyfikacji grubości warstwy podbudowy zasadniczej z betonu asfaltowego zestawiono w tabelicy 4. Zgodnie z opisem na rysunku 8 jest to warstwa  $h_3$ . Średnia zmierzona grubość tej warstwy wynosi 6,7 cm.

Tablica 4. Wyniki identyfikacji grubości warstwy h3  
Table 4. Results of identification of h3 layer thickness

| Pomiar FWD<br>na warstwie | Liczba neuronów w ukrytej warstwie SSN |     |     |     |     |                   |      |      |      |      |
|---------------------------|----------------------------------------|-----|-----|-----|-----|-------------------|------|------|------|------|
|                           | 0                                      | 1   | 3   | 6   | 9   | 0                 | 1    | 3    | 6    | 9    |
|                           | Średnia grubość warstwy h3             |     |     |     |     | Błąd względny [%] |      |      |      |      |
| Podbudowy                 | 5,8                                    | 7,0 | 5,4 | 5,2 | 5,1 | 15,5              | 4,3  | 24,1 | 28,8 | 31,4 |
| Wiążącej                  | 8,2                                    | 8,5 | 8,0 | 7,8 | 7,8 | 18,3              | 21,2 | 16,2 | 14,1 | 14,1 |

Średnia zmierzona grubość warstwy h4 (warstwa wiążąca) jest równa 4,8 cm. Wyniki identyfikacji tej grubości w zależności od miejsca pomiarów ugięciomierzem FWD przedstawiono w tablicy 5.

Tablica 5. Wyniki identyfikacji grubości warstwy h4  
Table 5. Results of identification of h4 layer thickness

| Pomiar FWD<br>na warstwie | Liczba neuronów w ukrytej warstwie SSN |     |     |     |     |                   |       |       |       |       |
|---------------------------|----------------------------------------|-----|-----|-----|-----|-------------------|-------|-------|-------|-------|
|                           | 0                                      | 1   | 3   | 6   | 9   | 0                 | 1     | 3     | 6     | 9     |
|                           | Średnia grubość warstwy h4             |     |     |     |     | Błąd względny [%] |       |       |       |       |
| Wiążącej                  | 2,1                                    | 2,3 | 2,1 | 2,0 | 2,0 | 128,6             | 108,7 | 128,6 | 140,0 | 140,0 |

Histogramy zbudowane w oparciu o rezultaty obliczeń dla sztucznej sieci neuronowej o konfiguracji 9 + 1 + 4 zestawiono na rysunku 14.

## 6. DYSKUSJA WYNIKÓW

### 6.1. UWAGI OGÓLNE

Deklarując w warstwie wejściowej SSN zbiór  $n$  – wektorów w postaci  $(T, q, D_0, D_1, D_2, D_3, D_4, D_5, D_6)$ , w warstwie wynikowej sztucznej sieci uzyskuje się  $n$  – wartości. W zależności od konfiguracji SSN można uzyskać poszukiwane wartości określonych parametrów. Szczegóły omówiono poniżej.


### 6.2. PRZYPUSZCZALNA LICZBA WARSTW NAWIERZCHNI ODCINKA PRÓBNEGO

Zgodnie z przedstawioną na rysunku 10 architekturą SSN wartości w warstwie wynikowej wskazują na liczbę warstw modelu nawierzchni. Poddając analizie szereg histogramów (np. na rys. 12), zbudowanych w oparciu o te wartości można zauważyć, że w każdym analizowanym przypadku poprawnie rozpoznaną liczbę warstw uzyskuje się dla SSN bez warstwy ukrytej, ale z nieliniową funkcją aktywacji na wyjściu sieci.

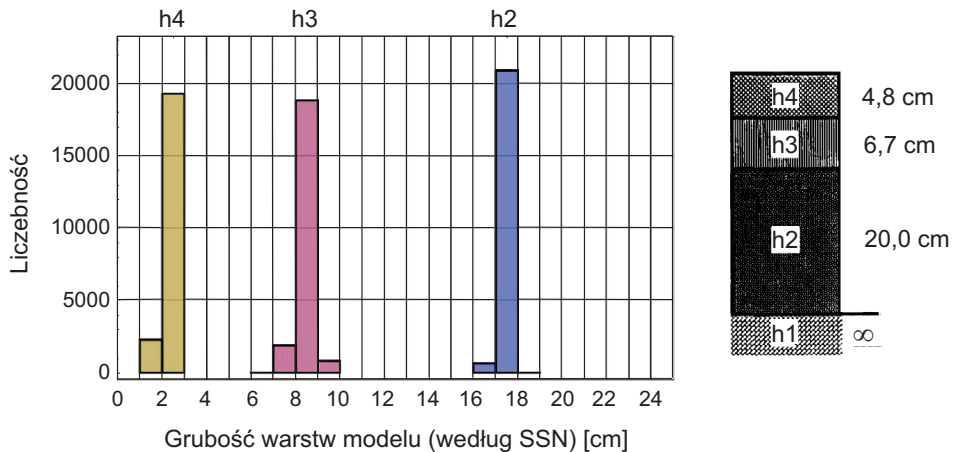


Rozkłady grubości warstw obliczonych przy wykorzystaniu wytrenowanej sieci SSN      Rzeczywiste średnie grubości warstw nawierzchni odcinka próbnego

a) dla przypadku pomiarów ugięciomierzem FWD na warstwie podbudowy z betonu asfaltowego



b) dla przypadku pomiarów ugięciomierzem FWD na warstwie wiążącej z betonu asfaltowego



Rys. 14. Grubości warstw obliczone w oparciu o wytrenowaną SSN (od lewej)

Fig. 14. Thickness of layers calculated using trained ANN (from left)

### 6.3. PRZYPUSZCZALNA GRUBOŚĆ WARSTW

W wyniku przeprowadzonej identyfikacji grubości poszczególnych warstw nawierzchni odcinka próbnego stwierdzono, że przedstawiona w artykule metoda ma następujące własności:

- możliwe do zaakceptowania wyniki uzyskano przy wykorzystaniu konfiguracji SSN z jednym neuronem w warstwie ukrytej,
- błąd względny identyfikacji grubości podbudowy pomocniczej z kruszywa łamanego stabilizowanego mechanicznie, w zależności od lokalizacji płaszczyzny pomiarów ugięciomierzem FWD, waha się w granicach  $14 \div 21\%$ ,
- poprawna identyfikacja grubości poszczególnych warstw asfaltowych zlokalizowanych poniżej płaszczyzny pomiarów ugięciomierzem FWD jest silnie uzależniona od przyjętych założeń. Jeżeli identyfikacji poddano grubość pojedynczej warstwy z betonu asfaltowego, uzyskano względny błąd oszacowania mniejszy od 10%. W przeciwnym wypadku przedstawiona metoda nie gwarantuje poprawnych wyników identyfikacji. Warto tu jednak zauważyć pewną prawidłowość. Zamiast szukać grubości poszczególnych warstw z betonu asfaltowego zlokalizowanych poniżej płaszczyzny pomiarów ugięciomierzem FWD, można poszukiwać łącznej grubości pakietu warstw asfaltowych. Wyniki takiej interpretacji zestawiono w tablicy 6.

Tablica 6. Identyfikacja łącznej grubości pakietu warstw asfaltowych nawierzchni odcinka próbnego

Table 6. Identification of total thickness of asphalt concrete layers of test section pavement

| Pomiar FWD na warstwie | Liczba neuronów w ukrytej warstwie SSN |      |      |     |     |                   |     |      |      |      |
|------------------------|----------------------------------------|------|------|-----|-----|-------------------|-----|------|------|------|
|                        | 0                                      | 1    | 3    | 6   | 9   | 0                 | 1   | 3    | 6    | 9    |
|                        | Łączna grubość warstw (h3+h4)          |      |      |     |     | Błąd względny [%] |     |      |      |      |
| Podbudowy              | 5,8                                    | 7,0  | 5,4  | 5,2 | 5,1 | 15,5              | 4,3 | 24,1 | 28,8 | 31,4 |
| Wiążącej               | 10,3                                   | 10,8 | 10,1 | 9,8 | 9,8 | 11,6              | 6,5 | 13,9 | 17,3 | 17,3 |

- stwierdzono bardzo duży błąd identyfikacji grubości warstwy wiążącej w sytuacji, gdy analizie poddano model nawierzchni czterowarstwowej (przypadek 2 warstw z betonu asfaltowego). Z analizy uzyskanych wyników dla modelu trójwarstwowego, można również zauważyć, że wartość błędu identyfikacji grubości warstwy asfaltowej znacznie wzrasta dla liczby neuronów w warstwie ukrytej SSN większej od 1. Przyniesione powyżej czynniki wymagają dalszych analiz, które w przekonaniu autora należy rozpocząć od przygotowania bazy teoretycznych linii wpływu, obliczonych w oparciu o modele nawierzchni uwzględniające w szczególności nieliniową charakterystykę materiału wykorzystanego do budowy warstwy podbudowy pomocniczej.

## 7. PODSUMOWANIE I WNIOSKI KOŃCOWE

Opisana metoda sprowadza się do wykorzystania bazy danych, w której umieszczono teoretyczne linie wpływu będące symulacją pomiarów ugięciomierzem FWD. Zaletą przedstawionej metody jest wykorzystanie bazy danych teoretycznych linii wpływu obliczonych przy wykorzystaniu relatywnie prostych modeli znanych z mechaniki nawierzchni podatnych, ale z uwzględnieniem różnych warunków powiązania między warstwami użytymi do jej budowy. Zasoby tak utworzonej bazy wykorzystano do wytrenowania jednokierunkowej SSN. Wyuczoną sieć zweryfikowano w oparciu o wyniki pomiarów ugięciomierzem FWD nawierzchni odcinka próbnego. Weryfikacja dotyczyła zdolności SSN do rozpoznania rodzaju i grubości poszczególnych warstw nawierzchni odcinka próbnego. Analizie poddano przypadki, w których pomiary ugięciomierzem FWD wykonano na powierzchni warstw podbudowy i wiążącej z betonem asfaltowego. Przeprowadzony eksperyment o charakterze badawczo-analitycznym pozwolił stwierdzić, że:

- w obu analizowanych przypadkach poprawnie została zidentyfikowana liczba warstw nawierzchni,
- względna wartość błędu identyfikacji grubości warstwy podbudowy pomocniczej z kruszywa łamanego stabilizowanego mechanicznie, w analizowanych przypadkach była mniejsza od 21%,
- poprawna identyfikacja grubości warstw z betonu asfaltowego, w świetle przedstawionej metody, okazała się możliwa tylko przy założeniu, że identyfikacji podlega grubość pakietu warstw asfaltowych, a nie grubości pojedynczych warstw z betonu asfaltowego; przy takim założeniu, wartość błędu względnego uzyskano niższą od 10%.
- pomimo, że część uzyskanych wyników można uznać za poprawne, sformułowanie ogólniejszych wniosków wymaga dalszych analiz; w pracy poddano analizie tylko jeden typ sieci (na podstawie przedstawionej literatury, najczęściej wykorzystywany do tego typu zadań), dlatego kolejne kroki powinny dotyczyć zarówno próby wykorzystania innych typów sieci neuronowych, jak i modeli nawierzchni, w których uwzględni się przynajmniej nieliniową charakterystykę materiału do warstwy podbudowy pomocniczej analizowanego odcinka testowego (kruszywo łamane stabilizowane mechanicznie).

Przedstawiona w pracy metoda rozpoznawania wybranych parametrów warstw nawierzchni odcinka próbnego jest zadaniem modelowym. Należy jednak podkreślić, że wyniki obliczeń porównano z wynikami badań na rzeczywistym odcinku nawierzchni. Zdaniem autora uzyskane w ten sposób parametry nawierzchni można wykorzystać w połączeniu ze standardową procedurą identyfikacji modułów sprężystości warstw nawierzchni.

**BIBLIOGRAFIA**

- [1] *Bishop C.M.*: Neural Networks for pattern recognition. Oxford University Press, Oxford 1995
- [2] *Duda R.O., Hart P.E., Stork D.G.*: Pattern classification. 2<sup>nd</sup> ed, John Wiley & Sons, New York 2001
- [3] *Osowski S.*: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2006
- [4] *Tadeusiewicz R.*: Sieci neuronowe. Akademicka Oficyna Wydawnicza RM, wyd. 2, Warszawa 1993
- [5] *Żurada J., Barski M., Jędruch W.*: Sztuczne sieci neuronowe, podstawy teorii i zastosowania. Wydawnictwo naukowe PWN, Warszawa 1996
- [6] Wolfram Research Incorporation, Neural Networks 1.1.1. Dokumentacja pakietu komputerowego
- [7] *Józefowicz K.*: SSN. Leszno 2009, <http://elektrotechnika.ip.pwz.edu.pl>
- [8] *Wolfram S.*: Articles on Cellular Automata. <http://www.stephenwolfram.com>
- [9] Szydło A.: Statyczna identyfikacja parametrów modeli nawierzchni lotniskowych. Prace naukowe Instytutu Inżynierii Politechniki Wrocławskiej, 45, Wrocław 1995
- [10] *Kim S., Gopalakrishnan K., Ceylan H.*: Neural Networks Application in Pavement Infrastructure Materials. Springer-Verlag Berlin Heidelberg 2009, Intel. & Soft Comp. in Infra. Sys. Eng., SCI 259, 47 - 66
- [11] *Pekcan O., Tutumluer E., Thompson M.*: Nondestructive pavement evaluation using ILLI-PAVE based ANN models. Research Report FHWA-ICT-08-022, Illinois 2008
- [12] *Saltan M., Tigdemir M., Karasahin M.*: ANN Application for Flexible Pavement Thickness Modeling. Turkish J. Eng. Env. Sci, **26**, 2002, 243 - 248
- [13] *Sharma S., Das A.*: Backcalculation of pavement layer parameters using Artificial Neural Networks. Can. J. Civ. Eng. **35**, 2008, 57 - 66
- [14] *Bredenhann S.J., van de Ven M.F.C.*: Application of ANN in the back-calculation of flexible pavement layer moduli from deflection measurements. Proc. of the 8<sup>th</sup> CAPSA'04, South Africa, Sun City 2004, 12 - 16
- [15] *Pożarycki A., Bartkowiak M.*: Zastosowanie SSN w identyfikacji grubości warstw asfaltowych w nawierzchniach podatnych. Archiwum Instytutu Inżynierii Lądowej Politechniki Poznańskiej, 9, Poznań 2011
- [16] *Pożarycki A., Grabowski W.*: Assessing the test section pavement structure using VQNN. 5<sup>th</sup> Int. Conf. Bit. Mix.& Pavements, Greece, Thessaloniki, June 2011
- [17] RMTiGM z dnia 2 marca 1999 r. w sprawie warunków technicznych, jakim powinny odpowiadać drogi publiczne i ich usytuowanie. Dz. U. nr 43 z 1999 r., poz. 430 z późn. zm.

- [18] *Grabowski W., Pożarycki A.*: Badania propagacji spękań wielkowymiarowych próbek nawierzchni asfaltowych podanych wielokrotnie powtarzalnym obciążeniom w warunkach laboratoryjnych. III Międzynarodowa Konferencja „Nowoczesne Technologie w budownictwie drogowym”, Poznań 2005
- [19] *Firlej S.*: Mechanika nawierzchni drogowej. Wydawnictwo Petit s.c., Politechnika Lubelska, Lublin 2007
- [20] *Boddapati K.M., Nazarian B.*: Effects of Pavement - Falling Weight Deflectometer Interaction on Measured Pavement Response, Nondestructive Testing of Pavements and Backcalculation of Moduli (Second Volume). ASTM STP 1198, American Society of Testing and Materials, Philadelphia 1994, 326 - 340

## IDENTIFICATION OF NUMBER AND THICKNESS OF NEW TEST SECTION PAVEMENT MODEL LAYERS USING ARTIFICIAL INTELLIGENCE METHODS

### Abstract

The paper presents methodology based on feedforward Artificial Neural Networks (ANN) techniques to estimate the most probable number and thickness of new test section flexible pavement layers. There is a consideration in the described method that only results from FWD measurements on surface of each asphalt concrete layer are known. Based on pavement mechanics theory and making a reference to typical flexible pavements used in Poland, the deflection basins were calculated. Theoretically determined deflection basins were used to train ANN. Finally an artificial neural network approach is used to estimate the wanted parameters of analyzed test section pavement layers. Comparing the ANN's results with the real test section pavement construction it was found that parameters obtained with ANN can be used for further standard backcalculation procedure.

### Keywords

Backcalculation, feedforward artificial neural networks, pavement layers thickness identification.

