

MAŁGORZATA LINEK¹⁾PIOTR NITA²⁾

NEURAL NETWORKS IN DIAGNOSTICS OF CONCRETE AIRFIELD PAVEMENTS

SIECI NEURONOWE W DIAGNOSTYCE BETONOWYCH NAWIERZCHNI LOTNISKOWYCH

STRESZCZENIE. W dziedzinie utrzymania betonowych nawierzchni lotniskowych występuje wiele złożonych problemów trudnych do identyfikacji tradycyjnymi metodami diagnostycznymi. Do ich zrozumienia i rozwiązania mogą okazać się przydatne sztuczne sieci neuronowe. W pracy przedstawiono istotę sieci, jak również zakreślono obszary możliwych ich zastosowań do analizy zjawisk zachodzących w warstwie jezdnej nawierzchni lotniskowej i jej podbudowie na etapie użytkowania. Przedstawiono koncepcję zastosowania tego narzędzia w prognozowaniu napraw, ustaleniu przyczyn zaistniałych zjawisk oraz prognozy diagnostycznej związanej z dalszym procesem utrzymania i użytkowania. Celem pracy była aplikacja metody SSN do modelowania procesów utrzymaniowych, w tym przewidywania równości nawierzchni. Opracowano model neuronowy przeznaczony do oceny równości nawierzchni na podstawie danych uzyskanych z rzeczywistych odcinków nawierzchni. Przedstawiono metodykę badawczą i uzyskane wyniki terenowe. Zaprojektowano strukturę sieci i zweryfikowano uzyskany model neuronowy. Sformułowano wniosek dotyczący przydatności modelowania neuronowego do prognozowania równości nawierzchni. Zaproponowana metodyka może stanowić uzupełnienie w stosowanej diagnostyce nawierzchni.

SŁOWA KLUCZOWE: diagnostyka nawierzchni betonowych, nawierzchnie betonowe, nawierzchnie lotniskowe, równość nawierzchni, sztuczne sieci neuronowe.

ABSTRACT. Concrete airfield pavement maintenance encompasses many complex problems, which are difficult to identify using traditional diagnostic methods. Artificial neural networks may prove useful in understanding and solving of such problems. The article presents the nature of neural networks and the possible fields of their application in analysis of processes occurring in airfield surface layers and base layers during service. The presented concepts include the use of neural networks in repair prediction, identification of causes of the observed phenomena and diagnostic predictions for future maintenance and service. The aim of the work is to apply artificial neural networks to modeling of maintenance processes, including prediction of pavement evenness. A neural network model was prepared for assessment of pavement evenness based on data obtained from real pavement sections. Research methodology and the obtained field results were described. The structure of the neural network was designed and verified. Conclusions were formulated regarding suitability of neural modeling for pavement evenness prediction. The proposed methodology may complement the methods currently used in pavement diagnostics.

KEYWORDS: airfield pavements, artificial neural networks, concrete pavement diagnostics, concrete pavements, pavement evenness.

DOI: 10.7409/rabdim.022.005

¹⁾ Politechnika Świętokrzyska, Wydział Budownictwa i Architektury, Katedra Inżynierii Komunikacyjnej, al. Tysiąclecia Państwa Polskiego 7, 25-314 Kielce; linekm@tu.kielce.pl (✉)

²⁾ Instytut Techniczny Wojsk Lotniczych, Zakład Lotniskowy, ul. Księcia Bolesława 6, 01-494 Warszawa; piotr.nita@itwl.pl

1. WSTĘP

Skuteczne rozwiązywanie problemów występujących w procesie eksploatacji i utrzymania betonowych nawierzchni lotniskowych już obecnie wymaga wykorzystania metod i narzędzi stosowanych w innych dyscyplinach. Dotyczy to problemów, które są słabo rozpoznawalne tradycyjnymi metodami, korzystającymi z gotowych i nieskomplikowanych algorytmów. W rozwiązaniu tych problemów – w opracowaniach [1, 2] – z zakresu tradycyjnej diagnostyki wykorzystywano podejście eksperckie. Zastosowanie systemu eksperckiego jednak jest dość problematyczne, wymaga bowiem bardzo dobrej znajomości przedmiotu opracowania, a przede wszystkim dużej wiedzy praktycznej, wspartej wycuciem hierarchii poszczególnych atrybutów. Konieczna jest w tym przypadku umiejętność przedstawienia ich w języku zrozumiałym dla stosowanych narzędzi analitycznych i dość długiego okresu testowania. Zasadniczym czynnikiem powodzenia rozwiązań technicznych związanych z wykorzystaniem sieci neuronowych jest odpowiednio liczna i wiarygodna baza danych wyrażająca istotę rozpatrywanych problemów. Istnieje potrzeba opanowania zasad zastosowania pewnych systemów, które nawet w najprostszej formie mogą działać na podobieństwo mózgu człowieka. Warto uzmysłowić sobie, że w mózgu ludzkim znajduje się 1011 neuronów, które w istocie mogą być zidentyfikowane jako proste procesory. Pomiędzy nimi występuje około 1014 połączeń, zwanych synapsami. Dlatego biologiczna sieć neuronowa przetwarza informacje równolegle, w przeciwieństwie do najdoskonalszych komputerów, które przetwarzanie informacji realizują w sekwencyjnym wykonywaniu kolejnych czynności zgodnych z odpowiednimi algorytmami. Ta nadzwyczajna zdolność ludzkiego umysłu, wyróżniającego się gromadzeniem, przetwarzaniem i odzyskiwaniem informacji, skłoniła McCullocha i Pittsa do opracowania w latach czterdziestych ubiegłego wieku matematycznego modelu neuronu [3, 4]. W naszym kraju z tej dziedziny znane są m. in. prace [5-10]. Dostępność ukierunkowanej literatury pozwala na podanie w niniejszej publikacji jedynie bardzo syntetycznego przedstawienia proponowanej problematyki. Zgodnie z tytułem niniejszej publikacji, autorzy pragną zwrócić uwagę na obszar budownictwa komunikacyjnego, ze szczególnym akcentem położonym na utrzymanie lotniskowych nawierzchni betonowych i możliwość wykorzystania tych sieci do rozwiązywania wybranych problemów dotyczących tego obszaru. Jednocześnie należy zauważyć, że w dziedzinie budownictwa ogólnego – kubaturowego – zakres wykorzystania sztucznych sieci neuronowych (SSN) jest już znaczny. Sieci neuronowe znalazły zastosowanie do analizy zagadnień z obszaru między innymi: fizyki i dynamiki budowli, mechaniki konstrukcji i materiałów. W zakresie wykorzystania modelowania SSN do

1. INTRODUCTION

Effective solution of problems encountered during the use and maintenance of concrete airfield pavements may require application of methods and tools from other disciplines. This is the case for problems that are difficult to describe using traditional methods, which apply existing and simple algorithms. The elements of traditional pavement diagnostics adopted to solution of such complex problems in papers [1, 2] included the use of expert assessment. However, application of an expertise-based system is relatively problematic, as it requires very good knowledge of the subject, vast practical experience and a sense of hierarchy of relevant attributes. In this case it is necessary to represent the attributes in a manner comprehensible for the analytical tools and allow a considerable period of time for testing. In technical solutions based on neural networks, the essential factor is the use of a sufficiently large and reliable database, reflecting the nature of the analyzed problems. It is necessary to learn how to apply certain systems that even in their simplest form may resemble the functioning of human brain. It is noteworthy that human brain contains 1011 neurons, which may be seen as simple processors. They are connected by 1014 links, known as synapses. Therefore, a biological neural network processes information concurrently, in contrast to state-of-the-art computers, which process information in sequences determined by respective algorithms. This extraordinary characteristic of human mind, which is capable of collecting, processing and retrieving information, inspired McCulloch and Pitts to develop a mathematical model of neuron in the 1940s [3, 4]. In Poland well-known works in this field include [5-10]. Since specialized literature is available, only a concise description of the subject will be given in this paper. As stated in the title, the authors wish to concentrate on transport engineering, with particular focus on maintenance of concrete airfield pavements and possibility of application of neural networks in solutions of chosen problems in this field. It should also be noted that the scope of application of artificial neural networks (ANN) in general civil engineering – residential, commercial and industrial structures – has already grown significantly. Neural networks are being applied in such fields as structural and material mechanics as well as structural physics and dynamics. In application of ANN for evaluation of parameters of pavement in terms of bearing capacity, the authors of [11] proposed prediction of elasticity modulus and modulus of subgrade reaction for the generated loading based on test data collected over 20 years.

oceny parametrów użytkowych nawierzchni w kontekście nośności nawierzchni autorzy pracy [11] zaproponowali prognozowanie wartości modułów sprężystości oraz współczynnika reakcji podłoża dla generowanego obciążenia na podstawie danych gromadzonych doświadczalnie przez 20 lat.

Przyczyny uzasadniające konieczność zastosowania sieci neuronowych w systemach zarządzania nawierzchnią sprecyzowali m. in. autorzy [12]. Zwrócono uwagę m.in. na wybór odpowiedniej strategii utrzymania nawierzchni – konieczność doboru grupy czynników reprezentujących warunki drogowe przez zagęszczenie i poziom nasilenia każdego rodzaju uszkodzenia. Stan drogi nie jest zatem ściśle zdefiniowany w ujęciu strategii, określanej nie tylko na podstawie danych statystycznych. W pracy [13] przedstawiono możliwość wykorzystania SSN do określania aktualnego stanu nawierzchni i prognozowania jego zmian w kontekście konieczności projektowania prac konserwacyjnych lub wyboru dalszej strategii utrzymania takich obiektów. Natomiast w pracy [14] określono sposób przewidywania wskaźniki *IRI* w oparciu o wyniki uzyskane z rejestracji obrazów nawierzchni. Zagadnieniom związanym z zastosowaniem SSN do rekomendowania wybranych odcinków dróg do programu konserwacji poświęcone były również prace [12, 15, 16].

2. ISTOTA SIECI NEURONOWYCH

Opis podstawowych cech sieci neuronowych wymaga odniesień do różnych dziedzin: matematyki (wykorzystującej głównie nieliniowe układy dynamiczne), informatyki i biocybernetyki. Istotną cechą sieci neuronowych jest ich zdolność uogólniania oraz równoległego przetwarzania informacji. W praktyce oznacza to, że sieci neuronowe nie wymagają opracowania odpowiednich programów, lecz uczą się na pewnym zbiorze przykładów opisujących badane zjawisko. Jest to tzw. ciąg uczący, który składa się z pewnej liczby sekwencji sygnałów wejściowych i wyjściowych, uzyskanych z obserwacji i eksperymentów. Jeśli dostępna jest odpowiednia liczba wiarygodnych przykładów, np. obserwacji związanych z trwałością nawierzchni betonowych, wykorzystanie sieci neuronowych jest całkowicie uzasadnione.

Tworząc strukturę sieci i jej zdolność do uczenia się, mamy na uwadze wymieniane wcześniej pojęcia, takie jak neurony i synapsy. W praktyce używa się częściej pojęć „jednostka” i „połączenie”. Sztuczny neuron jest elementarnym procesorem otrzymującym wiele sygnałów wejściowych i generującym jeden sygnał wyjściowy. Każdy z sygnałów wejściowych mnożony jest przez współczynnik wagi przypisany danemu wejściu. Tak przetworzone sygnały są w neuronie sumowane. Suma ta jest pomocniczym sygnałem wewnętrznym – nazywanym sygnałem łącznym, który w istocie jest

Reasons for usage of neural networks in pavement management systems were specified by the authors of [12]. The publication mentions the need for selection of appropriate maintenance strategy – determination of a group of factors representing road conditions. Therefore, pavement condition is not unambiguously expressed in a strategy that is not based solely on statistical data. Article [13] presents the possibility of application of ANN for determination of current pavement condition and prediction of its changes in the context of planning of necessary repairs or selection of further maintenance strategy. Article [14] describes the manner of prediction of *IRI* based on results obtained from pavement imaging. Problems of usage of ANN for recommending chosen road sections for maintenance and repair were described also in [12, 15, 16].

2. THE NATURE OF NEURAL NETWORKS

Description of the basic properties of a neural network combines terms from various fields: mathematics (mainly nonlinear dynamical systems), information technology and biocybernetics. An important property of neural networks is their ability to generalize information and process it concurrently. In practice it means that neural networks do not require development of appropriate programs, as they learn on a given set of examples that describe the analyzed phenomenon: a so-called training dataset, which consists of a number of inputs and related outputs obtained from observations and experiments. If an adequate number of reliable samples is available, e.g. observations of condition and service life of concrete pavements, application of neural networks is well-founded.

The structure of the network is created with such terms as neurons and synapses in mind, but in practice they are often described as “nodes” and “connections”. A single artificial neuron is an elementary processor that receives multiple inputs and generates one output. Each input signal is multiplied by weight assigned to the given input. After applying the weights, the inputs are summed in the neuron. This weighted sum is the aggregate signal, or the stimulation signal of the given neuron. It may be presented as in (1) below.

$$\varphi = \sum_{i=1}^m (w_i \cdot u_i) + b = w^T \cdot u + b, \quad (1)$$

where:

w – vector of weights,

u – vector of input signals,

m – number of inputs of the neuron,

sygnałem pobudzenia neuronu. Sygnał ten można przedstawić w postaci zależności (1).

$$\varphi = \sum_{i=1}^m (w_i \cdot u_i) + b = w^T \cdot u + b, \quad (1)$$

gdzie:

w – wektor współczynników wag,

u – wektor sygnałów wejściowych,

m – liczba wejść neuronu,

b – wielkość progowa niezależna od sygnałów wejściowych,

(\cdot) – iloczyn skalarny.

W wielu sieciach sygnał pobudzenia zostaje przetworzony na sygnał wyjściowy przez zastosowanie odpowiednio dobranej tzw. funkcji aktywacji. Jest to więc jednostka, do której prowadzi m wejść i z której wychodzi tylko jeden sygnał. Struktura ta utworzona została przez blok sumowania i blok aktywacji. Graficzną interpretację przedstawiono na Rys. 1.

Potencjał neuronu można przedstawić w postaci:

$$V = \sum w_j \cdot u_j. \quad (2)$$

Funkcja aktywacji decyduje o charakterze neuronu: w przypadku, gdy funkcja jest nieliniowa, neuron jest również nieliniowy. Najczęściej występującym jej rodzajem jest krzywa sigmoidalna opisana zależnością (3), która służy do opisu wielu zjawisk występujących w zastosowaniach technicznych.

$$y = \frac{1}{1 + \exp(-\beta\varphi)}, \quad (3)$$

gdzie:

β – jest zadany parametrem funkcji.

Funkcja aktywacji może być funkcją liniową, wówczas: $y = k \cdot \varphi$. Sieć mająca taką funkcję jest również siecią liniową. Sieci nieliniowe w porównaniu z sieciami liniowymi mogą rozwiązywać szerszą klasę zadań, a proces ich uczenia przebiega szybciej. Wyróżnia się w strukturach sieci jednokierunkowe, które nie mają sprzężeń zwrotnych (feedforward), i sieci ze sprzężeniami zwrotnymi zwane często sieciami rekurencyjnymi (Hopfielda). Sieci bez sprzężeń zwrotnych w praktycznych zastosowaniach wykorzystywane są częściej. Neurony w tych sieciach tworzą warstwę wejściową, warstwę ukryte i warstwę wyjściową (Rys. 2). Warstwa wejściowa przyjmuje sygnały zewnętrzne, warstwa wyjściowa wyprowadza przetworzone wyniki. Warstwy te pozwalają na komunikowanie się sieci z otoczeniem. W sieciach nieliniowych wprowadza się jedną lub dwie warstwy ukryte. Liczba neuronów w warstwie wejściowej równa się liczbie wprowadzanych wielkości wejściowych, liczba neuronów w warstwie wyjściowej odpowiada liczbie poszukiwanych rozwiązań. Liczba warstw ukrytych

b – constant bias, independent of input signals,

(\cdot) – scalar product.

In many networks the stimulation signal is processed into output using an appropriately chosen activation function. Neuron is therefore a unit that takes in m inputs and produces one output signal. Its structure may be described as consisting of a summation block and an activation block, as shown in Fig. 1.

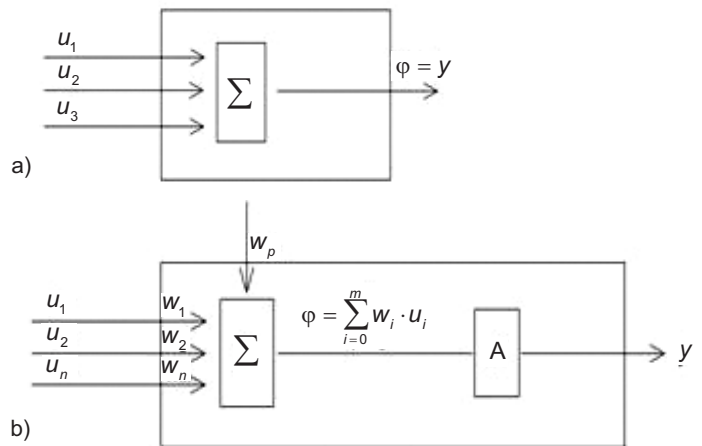


Fig. 1. Models of artificial neurons: a) linear, b) nonlinear; A – activation block, Σ – summation block, $u = \{u_1, u_2, \dots, u_n\}$ – input vectors, $w = \{w_1, w_2, \dots, w_n\}$ – synaptic weight vectors, w_p – general vector of weights

Rys. 1. Modele sztucznych neuronów: a) neuron liniowy, b) neuron nieliniowy; A – blok aktywacji, Σ – blok sumowania, $u = \{u_1, u_2, \dots, u_n\}$ – wektory wejścia, $w = \{w_1, w_2, \dots, w_n\}$ – wektory wag synaptycznych, w_p – wektor ogólny wag

The potential of a neuron may be expressed as:

$$V = \sum w_j \cdot u_j. \quad (2)$$

The activation function determines the character of the neuron: when it is nonlinear, the neuron is nonlinear as well. The most commonly used type of activation function is the sigmoidal curve given in formula (3), which serves for description of many phenomena in technical applications.

$$y = \frac{1}{1 + \exp(-\beta\varphi)}, \quad (3)$$

where:

β – is the predefined parameter of the function.

Activation function may also be linear, then: $y = k \cdot \varphi$. Network with such activation function will also be linear. Nonlinear networks learn faster and are capable of solving a greater range of problems than linear networks. In terms of structure, networks are divided into feedforward

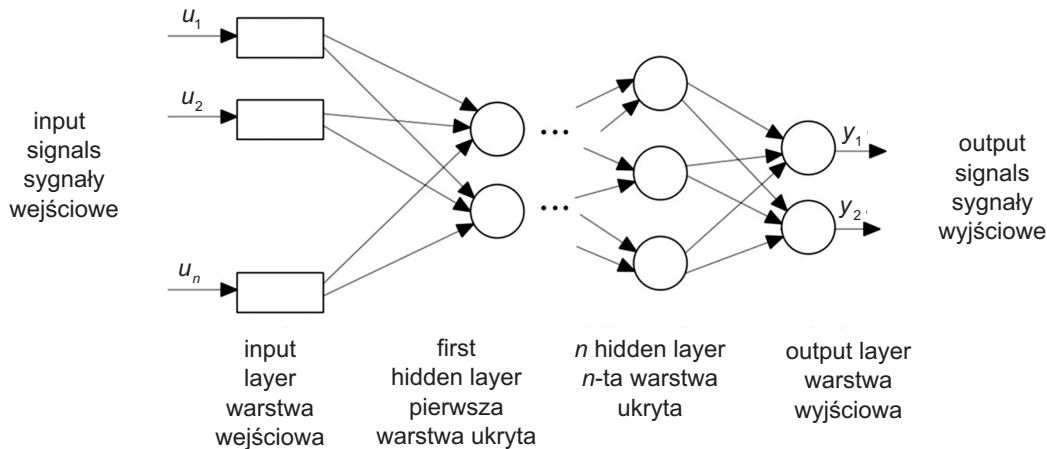


Fig. 2. Structure of a feedforward network
Rys. 2. Struktura sieci jednokierunkowej

w strukturze oraz liczba neuronów znajdujących się w każdej z warstw nie jest regulowana ścisłymi zasadami; decydujące w tym zakresie jest doświadczenie użytkownika sieci.

W działaniu sieci neuronowych wyróżnia się dwa etapy, tj. uczenie sieci i wykorzystanie nagromadzonej wiedzy. Poprawnie skonstruowana sieć może ułatwić grupowanie sygnałów na odpowiednie klasy. Uczenie sieci polega na przyjęciu danych wejściowych i przyporządkowaniu im tzw. współczynników wag oraz wartości progowych na wejściu każdego neuronu. W kolejnym etapie ma miejsce proces iteracji; założone wagi ulegają zmianom według przyjętych zasad. Następnie sygnał wyjściowy neuronu porównywany jest z odpowiednim wzorcem. Ewentualna różnica na tym etapie wymaga korekty współczynnika wag i wartości progowych, które łącznie stanowią pamięć danego neuronu. Dla sieci wielowarstwowych najczęściej stosowaną metodą uczenia jest tzw. metoda wstecznej propagacji błędów. Istotą tej metody jest zmiana współczynników wag, w której wykorzystuje się zasadę największego spadku błędów uczenia. Etap wykorzystania nagromadzonej wiedzy jest nazywany dość często etapem predykcji, od którego po wprowadzeniu pojedynczych lub pewnych grup danych można oczekiwać uzyskania poprawnego rozwiązania. W opisie procesu należy podać: dane wejściowe, liczbę neuronów w warstwie ukrytej i wynik na wyjściu (zapis ten może mieć postać np. 6-9-1). Jednocześnie należy określić dokładność odwzorowania i stałą uczenia. Parametr ten ma istotny wpływ na stabilność procesu i szybkość procesu uczenia. Przyjęcie małej wartości współczynnika uczenia znacząco wydłuża ten proces. Natomiast zbyt duża wartość tego współczynnika powoduje, że algorytm może stać się mało stabilny i nie jest na ogół w stanie osiągnąć optymalnego punktu w przestrzeni wag. Problem ten związany jest z istnieniem minimów lokalnych. Działaniem, które pozwala uniknąć występowania minimów lokalnych jest nadanie każdej wadze $w_{j,i}$ stanu pewnej bezwładności, czyli momentu. Parametr momentu dobiera

networks (without cycles or loops) or recurrent networks. Feedforward networks are used more frequently in practical applications. In such a network, the nodes are arranged into an input layer, possibly a number of hidden layers and an output layer (Fig. 2). The input layer takes in external signals, while the output layer yields the processed results. These layers enable communication of the network with the environment. Nonlinear networks often contain one or two hidden layers. The number of nodes in the input layer is equal to the number of introduced inputs, and the number of nodes in the output layer is equal to the number of solutions. The number of hidden layers and the number of nodes in these layers are not governed by strict rules; in this case, the experience of the user is decisive.

Two stages may be distinguished in functioning of every neural network: training and usage of the accumulated knowledge. A properly structured network may facilitate grouping of signals into appropriate classes. Network training consists in determination of input data and assigning weights and bias to every node. Another stage involves iterations, during which the original weights are subjected to modifications according to pre-adopted rules. The output of the node is compared to a known correct value. If a difference is observed, it entails corrections to input weights and bias, which constitute the memory of the given neuron. For layered networks, the most common training method is the so-called error backpropagation. Weights are changed according to the principle of gradient descent of training error. At the stage of usage of the accumulated knowledge, which is often called the prediction stage, it may be expected that after providing new input a correct solution will be obtained. Description of the process should include: inputs, number of neurons in the hidden layer and output (e.g. 6-9-1). Prediction accuracy and learning rate

się z przedziału 0-1. Pewne dane liczbowe znajdować się mogą w warstwach ukrytych układu konstrukcyjnego. Dane te mogą pochodzić z wcześniej wykonanych ekspertyz, danych archiwalnych, a nawet zmiennych lingwistycznych. Informacje te muszą być przetwarzane na dane liczbowe, a wówczas zachodzi może potrzeba transformacji danych: począwszy od prostego zbioru, a skończywszy na wykorzystaniu elementów teorii zbiorów rozmytych.

Istnieje zatem możliwość wykorzystania sztucznych sieci neuronowych w dotychczasowej działalności inżynierskiej związanej z diagnostyką skomplikowanych układów konstrukcyjnych nawierzchni betonowych na lotniskach i drogach. Następujące etapy analizy zagadnień budowy i utrzymania betonowych nawierzchni lotniskowych i drogowych mogą być zrealizowane z zastosowaniem sztucznych sieci neuronowych:

1. Predykcja, w której przewiduje się zachowanie układu konstrukcyjnego nawierzchni na podstawie przykładów wcześniejszych zachowań. Etap ten może być rozszerzony o prognozę napraw i zabiegów utrzymaniowych oraz analizę struktur materiałowych.
2. Klasyfikacja, która polega na rozpoznaniu cech materiałowych układów lub ich reprezentatywnych parametrów. W zakresie zagadnień tego etapu można wyróżnić diagnostykę techniczną wraz z zespołem innych wskaźników, które odzwierciedlają stan techniczny nawierzchni, głównie: nośność, równość i szorstkość. Klasyfikacja zagadnień może uwzględniać kryteria uzupełniające, takie jak: ocenę występujących uszkodzeń czy wytrzymałość warstwy kontaktowej w strefie narażonej na oddziaływanie kół samolotu na nawierzchnię podczas lądowania.
3. Kojarzenie danych – prowadzi do oceny powiązań występujących w analizowanych zagadnieniach i zachowaniach konstrukcji.
4. Analiza danych – umożliwia wykrywanie zależności pomiędzy określonymi zdarzeniami a ich tendencjami rozwojowymi.
5. Filtracja sygnałów – pozwala na eliminację sygnałów mało istotnych w zbiorze informacji.
6. Optymalizacja rozwiązań, polegająca na doborze odpowiedniego rodzaju sieci neuronowych, które przybliżą rozwiązanie analizowanych problemów.

3. WYKORZYSTANIE SZTUCZNYCH SIECI NEURONOWYCH W RAMACH OCENY STANU KONSTRUKCYJNEGO NAWIERZCHNI

Obszarem analizy jest konstrukcja nawierzchni, która składa się z odpowiednich warstw, a elementarny jej układ stanowią:

should also be determined. Learning rate has considerable impact on stability and speed of the process. If the adopted value of learning rate is too low, the process will be significantly longer. If the value is too high, training stability may be low and determination of the optimum point in the space of weights may prove impossible. This problem is related to occurrence of local minima. Influence of local minima may be mitigated by assigning a certain “inertia”, referred to as “momentum”, to the weights $w_{j,i}$. The values of the momentum parameter are assumed in the range from 0 to 1. Certain numerical data may be contained in the hidden layers of the structure. They may come from earlier expert assessments, archives or even linguistic variables. Such information should be processed into numerical values, which may entail the need for data transformation, with possibilities ranging from simple sets to fuzzy set theory.

Therefore, it is possible to apply neural networks in engineering analyses and actions concerning diagnostics of complex structural systems of concrete airfield and road pavements. The following stages of construction and maintenance of concrete airfield and road pavements may be realized using neural networks:

1. Prediction of performance of the pavement structure based on examples of previous performance. This stage may be broadened to include analysis of material structure and prediction of repairs and maintenance actions.
2. Classification, which consists in determination of material properties or their representative parameters. This stage includes technical diagnostics based on a set of parameters that reflect the technical condition of the pavement, primarily: bearing capacity, evenness and surface friction. Classification of problems may be based on auxiliary criteria, such as: assessment of existing distress or strength of surface layer in the zone subjected to impact of aircraft wheels during landing.
3. Data association – results in evaluation of connections between the analyzed problems and performance of the structure.
4. Data analysis – enables detection of relationships between specific occurrences and their development tendencies.
5. Signal filtering – enables elimination of signals whose importance in the dataset is limited.
6. Solution optimization, consisting in choice of adequate type of neural networks that better approximate the solutions of the analyzed problems.

- konstrukcja nośna nawierzchni, stanowi zespół warstw współpracujących ze sobą w sposób, który umożliwia redystrybucję obciążeń i bezpieczne przeniesienie ich na podłoże gruntowe,
- warstwa konstrukcyjna jezdna, na której odbywa się bezpośrednio ruch statków powietrznych,
- warstwa podbudowy, niżej położona warstwa konstrukcyjna stanowiąca podparcie zasadniczej warstwy konstrukcyjnej na całej powierzchni płyty zasadniczej,
- podłoże gruntowe, warstwa naturalnego lub ulepszanego gruntu, na które przekazywane jest obciążenie z warstw konstrukcyjnych położonych wyżej.

Fragment funkcjonalnego elementu nawierzchni lotniskowej (EFL) przeznaczony do spełniania przewidzianej w projekcie, określonej funkcji technicznej i ruchowej stanowi np. droga startowa, droga kołowania, płaszczyzna postoju samolotów itp.

Techniczna niezawodność nawierzchni lotniskowych to natomiast zdolność nawierzchni do spełnienia przewidzianych zadań w założonym czasie eksploatacji z zachowaniem zasad bezpieczeństwa wykonywania operacji lotniczych i określonym prawdopodobieństwem, że nie wystąpi żaden ze stanów granicznych całego systemu nawierzchni lotniskowych lub jednego z EFL.

W praktyce budowy betonowych nawierzchni lotniskowych i drogowych wykorzystanie sieci neuronowych w wielokryterialnym aspekcie nie jest szczegółowo rozpoznane. Jednak występujące zagadnienia, głównie eksploatacyjne, mogą być oceniane i analizowane przy pomocy tego narzędzia w zaproponowanych dwóch segmentach. Pierwszy z nich dotyczy modelowania nośności nawierzchni, a drugi – równości nawierzchni.

Założono, że sygnałami wejściowymi w segmencie pierwszym – w postaci binarnej (zero-jedynkowej, gdzie zero utożsamiane jest z wynikiem błędnym, a jedynka z pozytywnym) – powinny być:

- zmiany temperatury nawierzchni w stosunku do temperatury ułożenia betonu T_o ,
- zmiany temperatury układanej mieszanki betonowej T_b ,
- temperatura warstwy, na której układana jest mieszanka betonowa T_p ,
- temperatura otoczenia T_k .

W całokształcie analizowanych zagadnień segmentu pierwszego należy uwzględnić:

- rodzaj i stan podbudowy pod nawierzchnią T_d ,
- rodzaj warstwy pośredniej – warstwy poślizgowej T_c ,

3. APPLICATION OF ARTIFICIAL NEURAL NETWORKS IN ASSESSMENT OF PAVEMENT CONDITION

The analysis encompasses a layered pavement structure, whose elementary system consists of:

- structural layers of the pavement, which function as a system that enables safe distribution of loads onto the subgrade,
- surface layer, which is loaded directly by aircraft tires,
- base course, which provides even support to the surface layer below its entire area,
- subgrade – natural or improved soil, onto which loading is transferred from the above layers.

Airfield is divided into airfield functional elements (AFE) – areas dedicated to specific technical or traffic functions, such as aprons, taxiways etc.

Technical reliability of airfield pavements is the capacity of the structure to fulfill the planned functions in the assumed service life, in accordance with the principles of safety of air operations and with a given probability that no limit state of the entire pavement system or any of its AFEs will occur.

Application of neural networks in multi-criteria analysis of concrete airfield and road pavements has not yet been studied in detail. However, the related problems may be evaluated and analyzed using this tool within the two proposed segments. The first segment encompasses modeling of bearing capacity of the pavement and the second segment – modeling of its evenness.

For the first segment, it was assumed that the input signals in binary form (with zero corresponding to unsatisfactory value and one corresponding to satisfactory value) should be as follows:

- changes in pavement temperature relative to the temperature at which the concrete was placed T_o ,
- changes in temperature of placed concrete mixture T_b ,
- temperature of the layer on which the concrete mixture is placed T_p ,
- ambient temperature T_k .

The entire scope of the first segment should also include:

- type and condition of the base course T_d ,
- type of interlayer under the concrete slab T_c ,
- type and condition of the surface layer T_n ,
- load transfer between slabs (independent or connected slabs) T_w ,

- rodzaj i stan warstwy konstrukcyjnej nawierzchni T_n ,
- połączenia pomiędzy płytami lub ich brak (płyty swobodne lub współpracujące) T_w ,
- rodzaj i stan szczelin rozszerzania i ich rozmieszczenie S_r ,
- rodzaj i stan szczelin skurczowych i ich rozmieszczenie S_s ,
- sposób wyrównania naprężeń po zarysowaniu płyty w niskich temperaturach R_n ,
- sposób wyrównania naprężeń po deformacji płyty w wysokich i niskich temperaturach R_w .

Jako sygnały wyjściowe dla segmentu pierwszego, w postaci binarnej, rozpatrzono:

- nośność nawierzchni obciążonej samolotem obliczeniowym V_n ,
- nośność nawierzchni obciążonej samolotem o wyższej liczbie ACN niż projektowana V_w ,
- sumaryczna liczba operacji lotniczych przewidziana do wykonania na tej nawierzchni w okresie jej technicznej żywotności E_o ,
- roczna rzeczywista liczba operacji lotniczych wykonywana na tej nawierzchni E_r .

W odniesieniu do sygnałów wyjściowych w binarnej postaci można oczekiwać określenia:

- stanu wyteżenia płyty po jej dopuszczalnej deformacji w niskich temperaturach,
- stanu wyteżenia płyty po jej dopuszczalnej deformacji w wysokich temperaturach,
- stanu wyczerpania rezerwy eksploatacyjnej nawierzchni, w oparciu o analizę liczby operacji i ilości przewożonych ładunków na każdym etapie eksploatacji nawierzchni.

Sygnałami wejściowymi w segmencie drugim – w postaci binarnej – były:

- zmiana temperatury nawierzchni w stosunku do temperatury ułożenia betonu T_o ,
- zmiany temperatury układanej mieszanki betonowej T_b ,
- temperatura warstwy, na której układana jest mieszanka betonowa T_p ,
- temperatura otoczenia T_k ,
- temperatura warstwy w czasie pielęgnacji T_{pp} ,
- rodzaj i sposób pielęgnacji T_{rsp} ,

W całości analizowanych zagadnień segmentu drugiego należy uwzględnić:

- rodzaj i stan podbudowy pod nawierzchnią T_d ,
- rodzaj warstwy pośredniej – warstwy poślizgowej T_c ,
- rodzaj i stan warstwy konstrukcyjnej nawierzchni T_n ,
- połączenia pomiędzy płytami lub ich brak (płyty swobodne lub współpracujące) T_w ,

- type, arrangement and condition of expansion joints S_r ,
- type, arrangement and condition of contraction joints S_s ,
- manner of stress distribution after crack initiation at low temperatures R_n ,
- manner of stress distribution after slab deformation at high and low temperatures R_w .

The following output signals (in binary form) were considered for the first segment:

- bearing capacity of pavement loaded with standard design aircraft V_n ,
- bearing capacity of pavement loaded with aircraft with ACN number greater than the design value V_w ,
- total number of aircraft operations assumed to be performed on the pavement within its technical service life E_o ,
- real number of aircraft operations performed on the pavement annually E_r .

It may be expected that the output signals in binary form will enable determination of:

- ratio of stress state vs. strength for slab after its permissible deformation at low temperatures,
- ratio of stress state vs. strength for slab after its permissible deformation at high temperatures,
- proportion of pavement life used, based on the analysis of the number of operations and the quantity of freight transported.

The following output signals (in binary form) were considered for the second segment:

- changes in pavement temperature relative to the temperature at which the concrete was placed T_o ,
- changes in temperature of placed concrete mixture T_b ,
- temperature of the layer on which the concrete mixture is placed T_p ,
- ambient temperature T_k ,
- temperature of the layer during curing T_{pp} ,
- types of curing techniques T_{rsp} ,

The entire scope of the second segment should also include:

- type and condition of the base course T_d ,
- type of interlayer under the concrete slab T_c ,
- type and condition of the surface layer T_n ,
- load transfer between slabs (independent or connected slabs) T_w ,
- type, arrangement and condition of expansion joints S_r ,
- type, arrangement and condition of contraction joints S_s ,

- rodzaj i stan szczelin rozszerzania i ich rozmieszczenie S_r ,
- rodzaj i stan szczelin skurczowych i ich rozmieszczenie S_s ,
- sposób wykończenia nawierzchni R_s .

Jako sygnały wyjściowe dla segmentu drugiego, w postaci binarnej, rozpatrzono:

- równość nawierzchni obciążonej samolotem obliczeniowym V_{rm} ,
- równość nawierzchni obciążonej samolotem o wyższej liczbie ACN niż projektowana V_{rw} ,
- sumaryczna liczba operacji lotniczych przewidziana do wykonania na tej nawierzchni w okresie eksploatacji E_o ,
- roczna rzeczywista liczba operacji lotniczych wykonywana na tej nawierzchni E_r .

W odniesieniu do sygnałów wyjściowych w binarnej postaci można oczekiwać określenia:

- stanu równości płyty w początkowym okresie użytkowania,
- stanu równości płyty w dowolnym okresie, w oparciu o analizę stanu nawierzchni i liczbę operacji.

4. WYKORZYSTANIE SIECI NEURONOWYCH W PRAKTYCZNYCH ZASTOSOWANIACH DIAGNOSTYKI TECHNICZNEJ NAWIERZCHNI W SEGMENTIE DRUGIM

4.1. ZASADNOŚĆ WYKORZYSTANIA SIECI NEURONOWYCH

Obecnie istnieje duża liczba gotowych aplikacji sztucznych sieci neuronowych, również w budownictwie ogólnym. Wykorzystanie tego narzędzia w budownictwie nawierzchni lotniskowych czy drogowych jest dotychczas rzadkością [17, 18]. Uważa się jednak, że wykorzystanie tego narzędzia do analizy zagadnień związanych z diagnostyką techniczną tych obiektów jest możliwe i uzasadnione. Analizując zasadność wykorzystywania sieci neuronowych w rozpatrywanym zagadnieniu należy sprawdzić, czy danego problemu nie można rozwiązać metodami algorytmicznymi. Jeżeli istnieją metody algorytmiczne i są one dobrze oprogramowane, wówczas stosowanie sieci neuronowych może stanowić alternatywę i uzupełnienie tradycyjnych rozwiązań. W praktyce diagnostyki nawierzchni lotniskowych ustalenie zależności pomiędzy np. ilością wykonanych operacji lotniczych a średnią liczbą uszkodzeń nawierzchni (w postaci zarysowania lub pęknięcia) w określonym okresie eksploatacji nawierzchni, można określić z wykorzystaniem sieci neuronowej. Decyzja o wykorzystaniu sieci neuronowych zapada najczęściej po ustaleniu relacji przyczynowo-skutkowych analizowanego zjawiska.

- type of surface finish R_s .

The following output signals (in binary form) were considered for the second segment:

- evenness of pavement loaded with standard design aircraft V_{rm} ,
- evenness of pavement loaded with aircraft with ACN number greater than the design value V_{rw} ,
- total number of aircraft operations assumed to be performed on the pavement during its service E_o ,
- real number of aircraft operations performed on the pavement annually E_r .

It may be expected that the output signals in binary form will enable determination of:

- state of evenness in the initial period of service,
- state of evenness after any given period, based on the analysis of pavement condition and the number of operations.

4. NEURAL NETWORKS IN PRACTICAL APPLICATIONS IN THE SECOND (EVENNESS-RELATED) SEGMENT

4.1. PLAUSIBILITY OF USE OF NEURAL NETWORKS

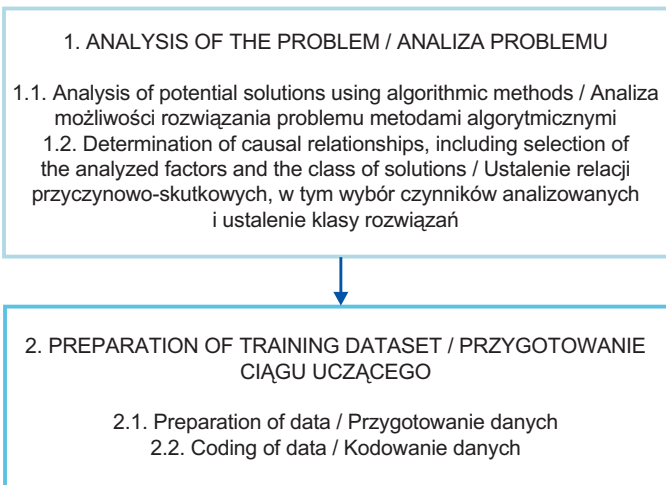
There is a considerable number of available applications of artificial neural networks, also in residential, commercial and industrial construction. Use of this tool in analysis of road and airfield pavements has been very rare so far [17, 18]. However, use of ANN in technical diagnostics of such pavement structures may also be feasible and justified. When analyzing plausibility of usage of neural networks in a given application, one should consider whether the problem may be solved using algorithmic methods. If there are well-programmed algorithmic methods already available, then usage of ANN may be treated as an alternative and complementary solution. Artificial neural networks may be used in practical diagnostics of airfield pavements for determination of various relationships, e.g. the average number of pavement cracks vs. number of aircraft operation in a given period. The decision to apply ANN to a given problem is most often based on earlier determination of causal relationships in the analyzed phenomenon. In the decision process concerning the use of neural networks, the following factors should be taken into account:

1. Significance of the phenomenon – neural network enables determination of significance of the observed phenomenon, given that the model is provided with sufficient number of examples. Practically, for example, if

W procesie decyzyjnym dotyczącym wyboru do analizy sieci neuronowych należy uwzględnić następujące czynniki:

1. Istotność występującego zjawiska – sieć neuronowa umożliwia określenie znaczenia występującego zjawiska, pod warunkiem wprowadzenia do sieci odpowiednio dużej liczby przykładów. W praktyce oznacza to, że gdy ustalono dla przykładu n parametrów wejściowych dla zaistnienia niekorzystnego stanu, to w wybranych przypadkach można wprowadzić ograniczenie do $n - 1$ wejść, w sytuacji, gdy nie jest znana wartość jednego z parametrów.
2. Większa liczba wprowadzonych wielkości i odpowiedzi wymaga większej liczby przykładów. Dla znalezienia zależności pomiędzy większą liczbą czynników sieć potrzebuje bardziej rozbudowanych ciągów uczących. Przygotowując ciąg uczący, należy zgromadzić odpowiednią liczbę wiarygodnych przykładów. Odpowiednia liczba przykładów nie jest pojęciem jednoznacznym. W sieci dotyczącej betonowych nawierzchni lotniskowych, jeżeli wprowadzimy do niej np. tylko trzy wielkości: czas eksploatacji nawierzchni liczony w latach, rodzaj betonu, procent płyt wymagających wymiany, to wymaganą liczbą przykładów można określić na kilkadziesiąt. Dodając jednak do wymienionych danych obciążenie całkowite i rodzaj podbudowy, ciąg uczący należy zwiększyć nawet do kilkuset przykładów.

Niezależnie od konkretnego zastosowania, tworzenie sieci wymaga wielu działań, których obrazem jest przykładowy blok sekwencji przedstawiony na Rys. 3. Pewne kroki sekwencji mają tylko charakter iteracyjny, niezbędny w celu uzyskania poprawnych wyników, i muszą być powtarzane wielokrotnie.



n input signals were determined as resulting in unsatisfactory condition, in chosen cases the number may be limited to $n - 1$, if one of them is unknown.

2. The greater the number of inputs and outputs, the greater the required number of training examples. In order to determine relationships between a greater number of factors, the network needs larger training sets. A training set should consist of an adequate number of reliable examples. "Adequate number" is not an explicit term. In the case of a network dedicated to concrete airfield pavements, if it takes in only three inputs, such as service to date (in years), concrete type and proportion of slabs requiring replacement, the required number of examples may be below hundred. However, if more inputs are added, such as type of base course and total loading, the required number of examples may grow to several hundred.

Regardless of the specific application, creation of neural network requires many actions, which are pictured in block sequence presented in Fig. 3. Some steps are of iterative character and should be repeated multiple times in order to provide correct results.

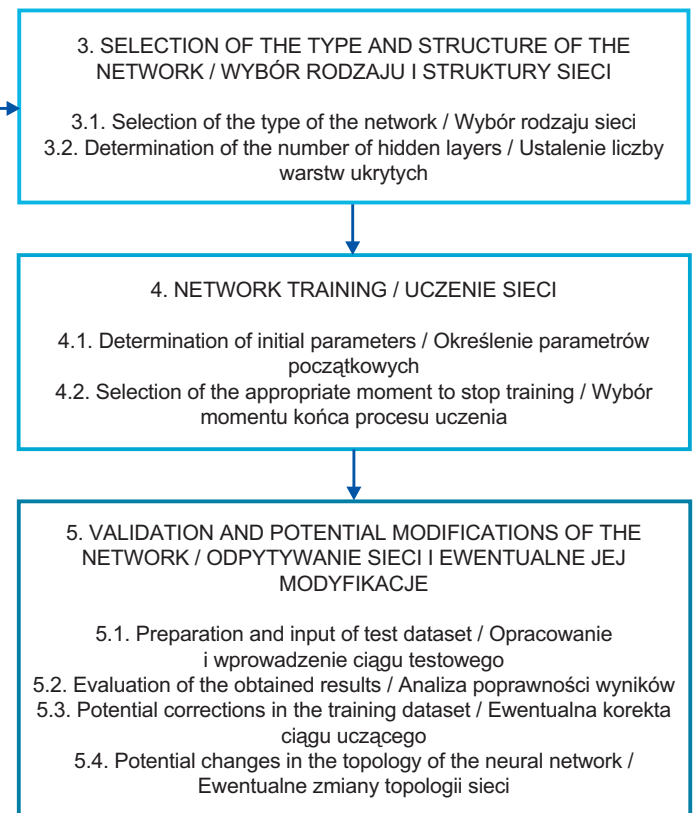


Fig. 3. Stages of creation of neural networks for assessment of airfield pavements
Rys. 3. Etapy tworzenia sieci neuronowych na potrzeby oceny nawierzchni lotniskowych

4.2. ISTOTA BADAŃ RÓWNOŚCI NAWIERZCHNI

Zdolność eksploatacyjna nawierzchni lotniskowej utożsamiana jest z możliwością wykonywania operacji lotniczych, w kontekście których pojawienie się znacznych nierówności może powodować konieczność wyłączenia obiektu lub jego fragmentu z użytkowania. Aspekty równości nawierzchni betonowych poruszono m.in. w pracach [19-24].

Wpływ nierówności nawierzchni na komfort i bezpieczeństwo użytkowników, jako funkcja długości, częstotliwości i amplitud fal w profilu drogi w ujęciu prędkości poruszających się pojazdów, jest przyjmowana jako wyznacznik trwałości konstrukcji. Pomiar równości służy również jako kryterium oceny jakości robót i procesu technologicznego obiektu lotniskowego. Czynnikiem potęgującym nierówności na nawierzchniach betonowych są również pojawiające się uskoki w szczelinach dylatacyjnych, które mogą wskazywać na zmiany podparcia płyt w warstwach niżej leżących, co jest szczególnie istotne w przypadku płyt niewspółpracujących.

Ocena równości nawierzchni wg [25, 26] powinna odnosić się do górnej warstwy nawierzchni. Zalecenia w [25] jednoznacznie ograniczają poziom akceptowalny do pojedynczych nierówności rzędu 2,5-3,0 cm występujących w odległości powyżej 45 m. Jednocześnie sprecyzowano zakresy akceptowanych i dopuszczalnych nierówności oraz granicę nadmiernych nierówności w zależności od wysokości i długości nierówności.

4.3. DANE DO WYZNACZENIA SIECI

Warstwę wejściową w opracowanym modelu stanowiły wybrane dane zgromadzone w badaniach terenowych – pomiary równości. Badania polowe wykonywane były na drodze startowej eksploatowanego lotniska wg zaleceń [27]. Liczba elementów tej warstwy zdeterminowana była liczbą danych wejściowych, które brano pod uwagę przy rozwiązywaniu zadania. Z uwagi na dostępną bazę danych pozyskanych w latach poprzednich, warstwę wejściową ciągu ograniczono do sześciu sygnałów. Obejmowała ona następujące dane: temperaturę otoczenia w czasie pomiaru T_k , rodzaj i stan warstwy konstrukcyjnej nawierzchni T_n , połączenie pomiędzy płytami lub ich brak (płyty swobodne lub współpracujące) T_w , rodzaj i stan szczelin rozszerzania oraz ich rozmieszczenie S_r , rodzaj i stan szczelin skurczowych oraz ich rozmieszczenie S_s , sposób wykończenia nawierzchni R_s . Warstwa wejściowa została opisana zależnością (4):

$$X = \{T_o, T_n, T_w, S_r, S_s, R_s\}. \quad (4)$$

Za sygnał wyjściowy przyjęto równość nawierzchni obciążonej samolotem obliczeniowym V_m w analizowanym okresie użytkowania konstrukcji.

4.2. PAVEMENT EVENNESS CONTROL

Functional capacity of an airfield pavement is associated with potential for realization of aircraft operations. Therefore, occurrence of considerable profile roughness may result in closure of the pavement or its parts. The issues of roughness of concrete pavements were described in many works, including [19-24].

The effect of pavement roughness on the comfort and safety of users – determined as a function of length, frequency and amplitudes of waves along the profile at a given vehicle speed – may be also treated as a measure of structure's life. Evenness measurements serve as a criterion for assessment of quality of construction works and technical processes. The factor that contributes to an increase in roughness in the case of concrete pavements is the possibility of joint faulting, potentially indicating a change in support provided by lower layers of the structure, which is of particular importance in pavements with independent slabs.

Pavement evenness assessment according to [25, 26] should encompass the surface layer of the pavement. Guidelines given in [25] explicitly limit the acceptable level to isolated irregularities of 2.5-3.0 cm, occurring at least 45 m from each other. Document [25] also defines the acceptable and tolerable ranges of irregularities, as well as the unacceptable limit value, depending on the height and length of the bump.

4.3. DATA FOR NETWORK DESIGN

The input layer in the developed model consisted of chosen data collected in field inspections – evenness measurements. Field inspections were performed on runway of an operational airfield, according to the guidelines [27]. The number of nodes in this layer was determined by the number of input data values considered in the solution of this problem. Due to the scope of data obtained in the past years, the input layer was limited to six signals. It included the following inputs: ambient temperature during inspection T_k , type and condition of surface layer T_n , load transfer between slabs (independent or connected slabs) T_w , type, arrangement and condition of expansion joints S_r , type, arrangement and condition of contraction joints S_s and type of surface finish R_s . The input layer may be expressed as given in formula (4):

$$X = \{T_o, T_n, T_w, S_r, S_s, R_s\}. \quad (4)$$

The output signal was the evenness of pavement loaded with design aircraft V_m in the analyzed service period.

4.4. UCZENIE, TESTOWANIE I WERYFIKACJA MODELU

Analizy SSN wykorzystano do opracowania modelu regresyjnego (wg autorskiego programu), w którym na wyjściu oczekiwano podania konkretnej wartości liczbowej utożsamianej z przewidywaną wartością równości nawierzchni. Dobór wielkości parametrów modelu, w postaci stałej uczenia α , momentum η oraz liczby neuronów L_n wykazał, że mają one istotny wpływ na wielkość uzyskiwanego odwzorowania równości nawierzchni przez SSN (Tabl. 1).

Table 1. Coefficients of pavement evenness accuracy determined for α and η (values marked in red are significant at $p < 0.05$)

Tablica 1. Współczynniki odwzorowania równości nawierzchni wyznaczone dla poszczególnych zmiennych α i η (oznaczone kolorem czerwonym współczynniki są istotne z $p < 0,05$)

Variable / Zmienna	Minimum / Wartość minimalna	\bar{X}	Maximum / Wartość maksymalna	SD	Δy_{sr}
η	0.01	0.4628	0.9	0.1825	0.0215
α	0.01	0.0500	0.9	0.0132	0.0035

Wpływ zróżnicowania wartości α i η na wielkość generowanego błędu równości nawierzchni Δy_{sr} , przy założonych 5 neuronach w warstwie ukrytej, przedstawiono na Rys. 4. Na podstawie analizy uzyskanych wyników stwierdzono, że najniższe wartości generowanego błędu rejestrowano dla stałej uczenia na poziomie 0,02 oraz momentum w przedziale od 0,4 do 0,6.

4.4. MODEL TRAINING, TESTING AND VERIFICATION

ANN analyses were used for development of a regression model (according to the authors' own program), in which the expected output is a numerical value expressing the predicted pavement evenness. Modifications to model parameters, i.e. the learning rate α , momentum η and the number of neurons L_n have shown that they have a significant influence on the value of pavement evenness given by the ANN (Table 1).

The effect of various values of α and η on the generated error of pavement evenness Δy_{sr} , after adopting 5 neurons in the hidden layer, is presented in Fig. 4. Based on the analysis of the obtained results, it was determined that the lowest values of error were registered for the learning rate of about 0.02 and momentum in the range from 0.4 to 0.6.

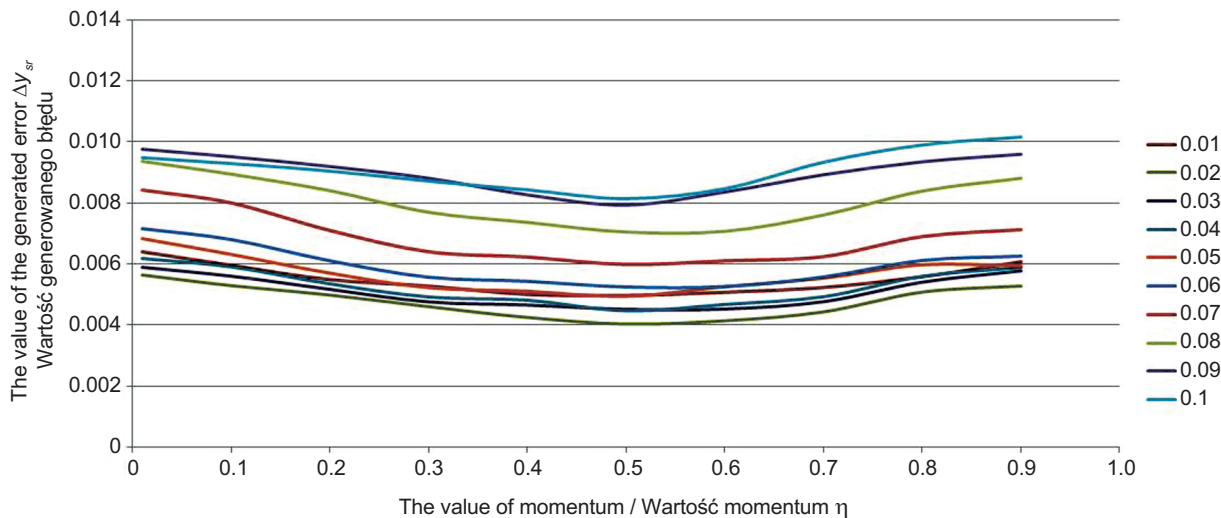


Fig. 4. Influence of various values of α and η on the generated error of pavement evenness Δy_{sr} , with 5 neurons in the hidden layer
Rys. 4. Wpływ zróżnicowanej wartości α i η na wielkość generowanego błędu Δy_{sr} , przy założonych 5 neuronach w warstwie ukrytej dla cechy równość nawierzchni

Przebiegi uczenia sieci o zróżnicowanych liczbach neuronów (od 3 do 15) w warstwie ukrytej oraz założonych poziomach stałej uczenia ($\alpha = 0,02$) i momentum ($\eta = 0,5$) zestawiono na Rys. 5. Na podstawie uzyskanych wyników stwierdzono, że

Learning curves for networks with variable number of neurons in the hidden layer (from 3 to 15) at the adopted learning rate ($\alpha = 0.02$) and momentum ($\eta = 0.5$) are shown in Fig. 5. Based on the obtained results, it was observed that

dla założonej liczby iteracji minimalne wartości Δy_{sr} wynoszą 0,0205, a maksymalne 0,1707. Przebiegi uczenia sieci o zróżnicowanych liczbach neuronów w warstwie ukrytej wskazują, iż dla liczby iteracji powyżej $0,64 \cdot 10^6$ wartości Δy_{sr} stabilizują się na poziomie poniżej 0,025.

for the assumed number of iterations the minimum value of Δy_{sr} was 0.0205 and the maximum value of Δy_{sr} was 0.1707. Learning curves for networks with various numbers of neurons in the hidden layer show that for the number of iterations greater than $0.64 \cdot 10^6$ the values of Δy_{sr} stabilize at a level below 0.025.

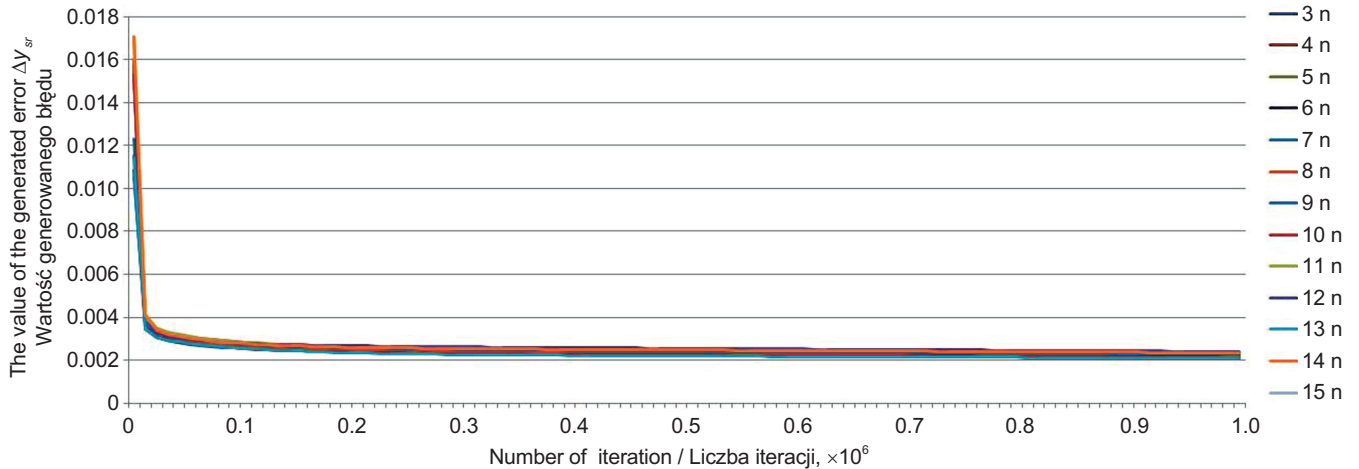


Fig. 5. Learning curves of artificial neural networks with varying number of neurons (3-15) in the hidden layer, for $\alpha = 0.02$ and $\eta = 0.5$
Rys. 5. Przebieg procesu uczenia sztucznych sieci neuronowych o zróżnicowanej liczbie neuronów (3-15) w warstwie ukrytej, przy $\alpha = 0,02$ i $\eta = 0,5$

Na podstawie uzyskanych wyników z analiz SSN stwierdzono istotny wpływ liczby neuronów na wartość generowanego błędu Δy_{sr} (Tabl. 2) i przyjęto, jako najlepiej odwzorowującą, sieć o strukturze 6-4-1. Pierwsza cyfra oznacza liczbę wejść (6), kolejną liczbę neuronów w warstwie ukrytej (4), a ostatnia oznacza jedno wyjście utożsamiane z przewidywaną wartością szorstkości nawierzchni. W kolejnym kroku badawczym ze zbioru danych terenowych (15000), których nie wykorzystywano do uczenia sieci, losowo wytypowano 20% i przeznaczono do testowania wyuczonej sieci. Graficzne zestawienie danych wyznaczonych na etapie testowania przez wyuczoną sieć przedstawiono na Rys. 6.

Based on the results, the effect of the number of neurons on the value of error Δy_{sr} (Table 2) was considered significant. The 6-4-1 structure was adopted as the most advantageous; the first digit reflecting the number of inputs (6), the second digit signifying the number of neurons in the hidden layer (4), and the last – a single output, that is the predicted pavement roughness. In the next step, 20% of the field data (15000) that had not been used in training, were randomly chosen and used in testing of the trained network. The data provided by the trained network during testing is presented graphically in Fig. 6.

Table 2. The influence of the number of neurons (3-15) in the hidden layer on the accuracy of pavement evenness prediction for momentum of 0.5, learning rate of 0.02 and $\varepsilon = 0.01$

Tablica 2. Wpływ liczby neuronów (3-15) w warstwie ukrytej na dokładność odwzorowania równości nawierzchni przy stałej wartości momentum 0,5, stałej uczenia 0,02 oraz $\varepsilon = 0,01$

No. of neurons Liczba neuronów	Percentage of positive events Procent zdarzeń pozytywnych	Δy_{sr}	No. of neurons Liczba neuronów	Percentage of positive events Procent zdarzeń pozytywnych	Δy_{sr}
3	100	0.0214	10	99.4	0.0212
4	100	0.0205	11	99.0	0.0237
5	100	0.0214	12	98.6	0.0239
6	100	0.0225	13	98.3	0.0208
7	100	0.0224	14	97.9	0.0234
8	100	0.0220	15	97.5	0.0218
9	100	0.0228			

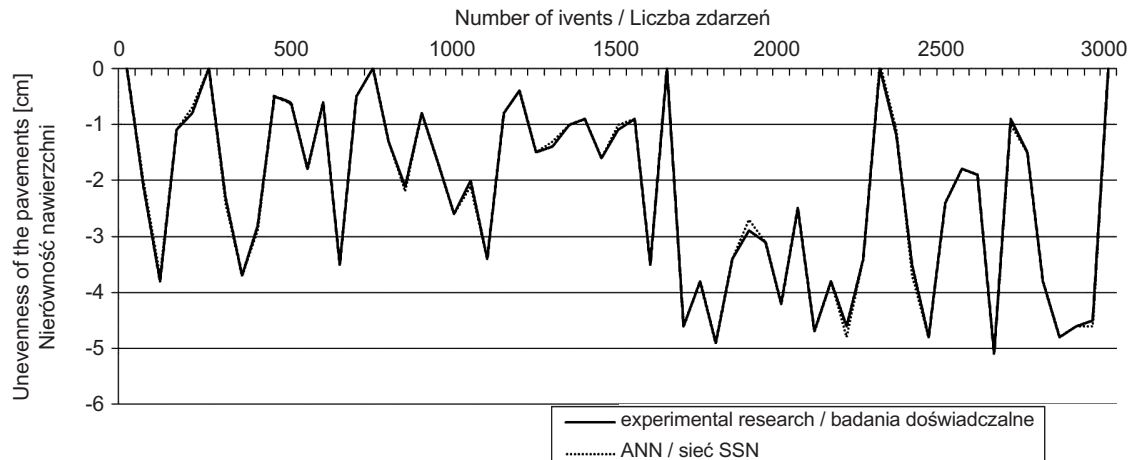


Fig. 6. The results of testing of the artificial neural network with the 6-4-1 structure
Rys. 6. Przebieg procesu testowania sztucznej sieci neuronowej o strukturze 6-4-1

Na podstawie uzyskanych charakterystyk (Rys. 6) stwierdzono, że testowanie modelu sztucznej sieci neuronowej odzwierciedla wartości wyznaczone przez sieć. Uzyskaną średnią dokładność powyżej 95% uznano za bardzo wysoką. Wyznaczona wartość średnia współczynnika determinacji wynosi 96,88%. Następnie wyuczoną i przetestowaną sieć SSN o strukturze 6-4-1 przeznaczono do weryfikacji doświadczalnej. Zgromadzone dane z 20% badań terenowych, które nie były wykorzystywane do uczenia sieci ani testowania, poddano weryfikacji – graficzne zestawienie danych wyznaczonych na etapie weryfikacji modelu przez wyuczoną sieć przedstawiono na Rys. 7.

Based on the obtained characteristics (Fig. 6), it was observed that testing of the ANN provided good results. The obtained average accuracy of over 95% is considered very high. The average coefficient of determination is 96.88%. The trained and tested ANN of the 6-4-1 structure was then subjected to verification. Another portion of 20% of field data – that had not been used in training and testing – was used for verification. A graphical representation of the data obtained from the trained network during verification is shown in Fig. 7.




Fig. 7. The results of verification of the artificial neural network with the 6-4-1 structure
Rys. 7. Przebieg weryfikacji modelu sztucznej sieci neuronowej o strukturze 6-4-1

Uzyskana pojedyncza dokładność wartości powyżej 99% jest bardzo wysoka. Wartość średnia współczynnika determinacji określona dla analizowanych przypadków wynosi 99,61%. Zbieżność pomiędzy wynikami uzyskanymi z rzeczywistych pomiarów i wynikami wyznaczonymi na etapie weryfikacji modelu przedstawiono na Rys. 8.

The obtained accuracy of over 99% is very high. The average coefficient of determination for the cases analyzed during verification is 99.61%. A comparison between the results from real measurements and the values obtained from the model during its verification is shown in Fig. 8.



Fig. 8. Comparison of real and predicted evenness results

Rys. 8. Zbieżność wyników rzeczywistych i modelowanych przez sieć dla równości

4.5. WPŁYW DANYCH Z LAT POPRZEDNICH NA UZYSKIWANE WYNIKI BIEŻĄCEJ RÓWNOŚCI

Z uwagi na istotny wpływ zmian równości nawierzchni na przestrzeni lat uwzględniono związek między pomiarami poprzedzającymi a uzyskanymi wynikami aktualnej równości nawierzchni w roku analizy. Na etapie badawczym przyjęto odpowiednio rozszerzenie wektora wejściowego o wyniki uzyskane w okresie poprzedzającym. W tym celu przyjęto zakres oddziaływania zróżnicowanych wyników z 2 i 4 lat poprzedzających. Dla każdego z dwóch okresów modelowanie równości wykonywane było z zachowaniem takich samych procedur badawczych i kryteriów oceny. Na podstawie uzyskanych wyników możliwa była przekrojowa ocena zmian równości i wpływu danych z pomiarów w latach poprzednich na stan aktualny (Rys. 9).

Stwierdzono, że istnieje możliwość wiarygodnej oceny badanego parametru niezależnie od przyjętego zakresu oddziaływania danych poprzedzających, przy założeniu wykorzystania stałej uczenia na poziomie 0,02, momentum na poziomie 0,50 lub 0,51 oraz jednej warstwy ukrytej z neuronami w liczbie od 3 do 4. Dla analizowanego zbioru aktualnych danych optymalne założenia obejmują stałą uczenia na poziomie 0,02, momentum równe 0,50 i 4 neurony w warstwie ukrytej. Natomiast w przypadku analizy z uwzględnieniem lat poprzedzających (Tabl. 3) wykazano, że możliwe jest uzyskanie wyższych zbieżności wyników rzeczywistych i modelowanych przez sieć oraz niższych poziomów generowanych błędów.

Wykorzystanie modelowania SSN przy diagnostyce nawierzchni pod kątem oceny równości może mieć istotne znaczenie, szczególnie w kontekście planowanej eksploatacji konstrukcji i możliwości planowania odcinków wymagających poprawy cech eksploatacyjnych z odpowiednim wyprzedzeniem.

4.5. INFLUENCE OF THE RESULTS FROM PAST YEARS ON THE OBTAINED RESULTS OF CURRENT EVENNESS

Due to a significant relationship between evenness changes over the past years and its current values, previous measurements were taken into account in the analyses of the current pavement evenness. The input vector was modified to include the evenness result from a previous period as well. Two lengths of previous periods were assumed: 2 years and 4 years. For each of the adopted periods, evenness modeling was performed using the same research procedures and assessment criteria. The obtained results enabled broader evaluation of changes in evenness and influence of values from past years on the current condition of the pavement (Fig. 9).




Fig. 9. A schematic of modeling of the period of influence of evenness in the year of analysis V_m and in previous years: in 2 past years V_{m-2} and in 4 past years V_{m-4}

Rys. 9. Schemat modelowania zakresu oddziaływania równości w roku analizy V_m oraz w latach poprzednich: w okresie 2 lat poprzedzających V_{m-2} i 4 lat poprzedzających V_{m-4}

It was observed that reliable evaluation of the analyzed parameter was possible regardless of the assumed period of influence of previously obtained results, adopting the learning rate of 0.02, momentum of 0.50 or 0.51 and one hidden layer consisting of 3 or 4 neurons. For the analyzed set of current data, the optimum parameters were: learning rate of 0.02, momentum equal to 0.50 and 4 neurons in the hidden layer. In the case of analysis taking into account the past data as well (Table 3) it was demonstrated that it is

Table 3. The impact of the adopted period of influence of previous results taken into account on the generated error of pavement evenness Δy_{sr} during training (U), testing (T) and verification (W) of the network, for learning rate of 0.02 and $\varepsilon = 0.01$

Tablica. 3. Wpływ przyjętego zakresu oddziaływań danych poprzedzających na wartość generowanego błędu Δy_{sr} na etapie uczenia sieci (U), testowania sieci (T) i weryfikacji sieci (W) dla równości nawierzchni przy jednakowej wartości stałej uczenia 0,02 oraz $\varepsilon = 0,01$

Period of influence Zakres oddziaływania	Momentum	Number of neurons Liczba neuronów	Δy_{sr-U}	Δy_{sr-T}	Δy_{sr-W}
V_{rn}	0.50	4	0.0205	0.0015	0.0012
V_{rn-2}	0.51	4	0.0194	0.0011	0.0012
V_{rn-4}	0.50	3	0.0178	0.0009	0.0008

5. PODSUMOWANIE I WNIOSKI

W rezultacie przeprowadzonych badań wskazano alternatywą (uzupełniającą) metodę określania stanu technicznego nawierzchni lotniskowych w stosunku do metod stosowanych obecnie. Proponowana metoda wykorzystania SSN w diagnostyce nawierzchni lotniskowych jest w stanie podwyższyć wiarygodność oceny zdolności eksploatacyjnej obiektów komunikacyjnych. Metoda ta może być pomocna w globalnym planowaniu modernizacji i remontów obiektów lotniskowych, których cechy konstrukcyjne i materiałowe są porównywalne. Wykorzystanie SSN nie musi ograniczać się tylko do określania ilości i zakresu robót, ale daje możliwość uwzględnienia specyfiki obiektu oraz wnikania w kompozytową strukturę wbudowywanych materiałów i warstw konstrukcyjnych. Zastosowanie w praktyce budownictwa lotniskowego sieci neuronowych może ułatwić między innymi dobór odpowiednio wyspecjalizowanych wykonawców oraz racjonalne wykorzystanie środków rzeczowych i finansowych. Z przeprowadzonych analiz nie wynika jednoznacznie możliwość uwzględnienia niektórych czynników, które mają wpływ na stan techniczny nawierzchni lotniskowych, m.in.: wpływy środowiska naturalnego, błędy w projektowaniu i wykonawstwie, niewłaściwa eksploatacja i inne zdarzenia losowe. Dostrzega się również wpływ wielu wzajemnie powiązanych czynników, które mogą decydować o stanie technicznym nawierzchni w wymiarze wielokryterialnym. Przedstawiona koncepcja wykorzystania SSN jest w stanie podwyższyć wiarygodność oceny technicznej nawierzchni lotniskowych, nie eliminując klasycznych metod diagnostyki, wymaga to jednak gruntownej znajomości związków przyczynowo-skutkowych występujących w analizowanym problemie.

BIBLIOGRAFIA / REFERENCES

- [1] Bahuch H., Bahuch M.: Sieci neuronowe jako narzędzie rozwiązywania problemów z zakresu dróg kolejowych. Problemy Kolejnictwa, **124**, 1997, 35-62

possible to obtain better agreement between the modeled and real results, with lower generated error.

Application of ANN in pavement evenness diagnostics may be of considerable importance, especially in the context of determination of remaining service life and early identification of sections requiring improvement of functional properties.

5. SUMMARY AND CONCLUSIONS

In result of performed investigation an alternative (complementary) method for determination of technical state of airfield pavements is proposed. The outlined application of ANN in airfield pavement diagnostics may improve reliability of assessment of remaining functional capacity of transport structures. The method may facilitate global planning of upgrades and repairs of airfield structures of comparable structural and material properties. The use of ANN does not necessarily have to be limited to determination of the scope of required works. It also enables taking into account the specificity of a given pavement and analysis of the composite structure of layers and materials used. Application of neural networks in airfield construction may facilitate selection of specialized contractors and more rational management of physical and financial assets. The performed analyses do not unambiguously imply possibility of including such factors as: the impact of natural environment, design and construction faults, incorrect usage or other random circumstances. It was also noted that many interconnected factors may influence the technical condition of the pavement in a multi-criteria manner. The presented concept of application of ANN may improve reliability of technical assessment of airfield pavements, while not being mutually exclusive with application of classic diagnostic methods. However, the approach requires good knowledge of causal relationships occurring in the analyzed problems.

- [2] *Błażejowski K., Szustakowski J.*: Neuronowa metoda interpretacji wyników badań grubości warstw nawierzchni z penetroradaru. *Drogownictwo*, **51**, 9, 1996
- [3] *McCulloch W.S., Pitts W.*: A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, **5**, 1943, 115-133, DOI: 10.1007/BF02478259
- [4] *Sand A., Saka M.P.*: Prediction of ultimate shear strength of reinforced concrete deep beams using neural networks. *Journal of Structural Engineering*, **127**, 7, 2001, DOI: 10.1061/(ASCE)0733-9445(2001)127:7(818)
- [5] *Osowski S.*: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2006
- [6] *Tadeusiewicz R.*: Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa, 1993
- [7] *Tadeusiewicz R., Gonciarz T., Borowik B., Leper B.*: Odkrywanie sieci neuronowych przy użyciu programów C#. Polska Akademia Umiejętności, Kraków, 2007
- [8] *Waszczyszyn Z., Ziemiański L.*: Neural networks in mechanics of structures and materials - new results and prospects of applications. *Computers and Structures*, **79**, 22-25, 2001, 2261-2276, DOI: 10.1016/S0045-7949(01)00083-9
- [9] *Waszczyszyn Z.*: Zastosowanie sztucznych sieci neuronowych w inżynierii lądowej. XLI Konferencja Naukowa KILiW PAN i KN PZITB, Krynica, 1995
- [10] *Hola J., Schabowicz K.*: New technique of nondestructive assessment of concrete strength using artificial intelligence. *NDT&E International*, **38**, 4, 2005, 251-259, DOI: 10.1016/j.ndteint.2004.08.002
- [11] *Bayrak M.B., Ceylan H.*: Neural Network-Based Approach for Analysis of Rigid Pavement Systems Using Deflection Data. *Transportation Research Record*, **2068**, 1, 2008, 61-70, DOI: 10.3141/2068-07
- [12] *Alsugair A.M., Al-Qudrah A.A.*: Artificial Neural Network Approach for Pavement Maintenance. *Journal of Computing in Civil Engineering*, **12**, 4, 1998, 249-255 DOI: 10.1061/(ASCE)0887-3801(1998)12:4(249)
- [13] *Sundin S., Braban-Ledoux C.*: Artificial Intelligence-Based Decision Support Technologies in Pavement Management. *Computer-Aided Civil and Infrastructure Engineering*, **16**, 2, 2001, 143-157, DOI: 10.1111/0885-9507.00220
- [14] *Lin J.D., Yau J.T., Hsiao L.H.*: Correlation analysis between international roughness index (IRI) and pavement distress by neural network. 82nd Annual Meeting of the Transportation Research Board, Washington, DC, USA, 2003, https://www.researchgate.net/publication/228848218_Correlation_analysis_between_international_roughness_index_IRI_and_pavement_distress_by_neural_network (30.01.2022)
- [15] *Abdelrahim A.M., George K.P.*: Artificial neural network for enhancing selection of pavement maintenance strategy. *Transport Research Record*, **1699**, 1, 2000, 16-22, DOI: 10.3141/1699-03,
- [16] *Domitrović J., Dragovan H., Rukavina T., Dimter S.*: Application of an Artificial Neural Network in Pavement Management System, *Tehnički vjesnik - Technical Gazette*, **25**, Suppl. 2, 2018, 466-473, DOI: 10.17559/TV-20150608121810
- [17] *Linek M.*: Neural Model of Projecting Compressive Strength of Cement Concrete Intended for Airfield Pavements. XV International Conference on Durability of Building Materials and Components, Barcelona, 2020
- [18] *Linek M.*: Neural model of projecting flexural strength of cement concrete intended for airfield pavements. IOP Conference Series: Materials Science and Engineering, **664**, 2019, 012013, DOI: 10.1088/1757-899X/664/1/012013
- [19] *Glinicki M.A.*: Inżynieria betonowych nawierzchni drogowych. PWN, Warszawa, 2019
- [20] *Glinicki M.A.*: Materiałowe aspekty równości nawierzchni betonowej. *Drogownictwo*, **75**, 4, 2020, 99-108
- [21] *Nita P.*: Budowa i utrzymanie nawierzchni lotniskowych. WKiŁ, Warszawa, 2008
- [22] *Szpinek S.*: Badania równości nawierzchni lotniskowych. *Drogownictwo*, **79**, 6, 2014, 183-191
- [23] *Szydło A.*: Nawierzchnie drogowe z betonu cementowego. Polski Cement, Kraków, 2004
- [24] *Wesołowski M., Pietruszewski P., Poświata A., Kowalska D.*: Ocena równości nawierzchni lotniskowych w aspekcie obowiązujących dokumentów normatywnych. *Przegląd Komunikacyjny*, **12**, 2018, 24-29
- [25] *Dziennik Urzędowy Urzędu Lotnictwa Cywilnego*, poz. 41, z dnia 2 lipca 2021 r. w sprawie ogłoszenia tekstu Załącznika 14, tomu I do Konwencji o międzynarodowym lotnictwie cywilnym
- [26] *PN-EN 13036-5:2020* Cechy powierzchniowe nawierzchni drogowych i lotniskowych. Metody badań. Określenie wskaźników nierówności podłużnej
- [27] *NO-17-A502:2015* Nawierzchnie lotniskowe – Badanie równości