



ANGELIKA G. BATRAKOVA¹⁾
 VLADIMIR V. TROYANOVSKY²⁾
 DMITRY O. BATRAKOV³⁾
 MARYNA O. PILICHEVA⁴⁾
 NATALIIA S. SKRYPNYK⁵⁾

PREDICTION OF THE ROAD PAVEMENT CONDITION INDEX USING STOCHASTIC MODELS

PROGNOZOWANIE WSKAŹNIKA STANU NAWIERZCHNI DROGOWYCH Z ZASTOSOWANIEM MODELI STOCHASTYCZNYCH

STRESZCZENIE. W artykule omówiono modele matematyczne prognozowania stanu sieci drogowej z zastosowaniem tzw. łańcuchów Markowa. Dane do obliczeń elementów macierzy przejścia pomiędzy stanami są uzyskiwane na podstawie oceny wizualnej oraz w wyniku pomiarów instrumentalnych. Zalecane jest przygotowanie zestawów danych w postaci tablic systemu zarządzania stanem nawierzchni drogowej sporządzanych na podstawie reprezentatywnej próby odcinków pomiarowych. Macierze przejścia pomiędzy stanami są tworzone w przedziałach czasu o długości jednego roku. W artykule przedstawiono także procedurę tworzenia macierzy przejścia na podstawie częściowo niepełnych zestawów danych, w których wykorzystano informacje o wcześniejszym stanie nawierzchni oraz wyniki pomiarów instrumentalnych, pozwalających na skorygowanie prognozowanych wartości. Uzyskana ostatecznie macierz uwzględnia nie tylko prawdopodobieństwo, lecz również prędkość przejścia pomiędzy stanami. Ponadto możliwe jest także przetwarzanie danych wejściowych z odpowiednich baz lub ich wykorzystanie przy zastosowaniu innego oprogramowania.

SŁOWA KLUCZOWE: łańcuchy Markowa, modele stochastyczne, wskaźnik stanu nawierzchni.

ABSTRACT. Mathematical models for prediction of road network condition based on the so-called Markov chains are presented in this article. The data for calculation of elements of the transition matrix from one condition to another are taken from visual evaluation as well as from instrumental reading. It is recommended to prepare data sets in the form of pavement management system data tables based on a representative sample of measuring sections. Discrete time intervals – of one year – are used when constructing the model of transition matrices. The procedure of forming Markov transition matrix with partially complete data sets is proposed also in paper. The basis of this procedure is information on the previous condition of the structure and the results of the instrumental evaluation, which enables correction of the predicted values. The final matrix takes into account not only the probability, but also the speed of transition from one condition to another. It is also possible to work with the initial data using appropriate databases or other software.

KEYWORDS: Markov chains, pavement condition index, stochastic models.

DOI: 10.7409/rabdim.020.015

¹⁾ Kharkiv National Automobile and Highway University, Road-Construction Faculty, Department of Highway Design, Geodesy and Land Management, 25 Yaroslava Mudroho St., Kharkiv, Ukraine, 61002; batrakova@khadi.kharkov.ua

²⁾ Kharkiv National Automobile and Highway University Kharkiv, Road-Construction Faculty, Department of Highway Design, Geodesy and Land Management, Kharkiv, Ukraine; rp@khadi.kharkov.ua

³⁾ V. Karazin National University, Radiophysics Biomedical Electronics and Computer Systems Faculty, Department of Theoretical Radiophysics, 4 Svobody Sq., Kharkiv, Ukraine, 61022; batrakov@karazin.ua

⁴⁾ O.M. Beketov National University of Urban Economy in Kharkiv, Department of Land Administration and Geoinformation Systems, 17 Marshal Bazhanov St., Kharkiv, Ukraine, 61002; maryna.pilicheva@gmail.com

⁵⁾ Kharkiv National Automobile and Highway University, Department of Foreign Languages, Kharkiv, Ukraine; Rff_bat5@yahoo.com

1. WSTĘP

We wcześniej opublikowanym artykule autorzy przedstawili wyniki w zakresie prognozowania degradacji nawierzchni z zastosowaniem modeli dynamicznych [1]. Podstawę takiego podejścia stanowi monitoring danych pozyskanych z impulsowych georadarów GPR [2-6] oraz dalsze przetwarzanie sygnałów oparte na zaproponowanych algorytmach [7]. Problemy przetwarzania sygnałów odbitych od nawierzchni drogowych o cienkich górnych warstwach [8, 9] są tematem oddzielnego opracowania. Niemniej jednak, dla inżyniera drogowego (będącego ostatecznym użytkownikiem wyników diagnostycznych) problem dużej wagi stanowi również pozyskanie informacji obejmujących:

- obecność i charakter uszkodzeń, w tym wad niewidocznych na powierzchni (spękań, utraty szepności itp.);
- niedopuszczalną wilgotność podbudowy oraz podbudowy pomocniczej;
- ocenę wskaźnika zagęszczenia poszczególnych warstw.

Wyniki te z kolei potrzebne są inżynierowi do zaplanowania dalszych działań mających na celu prawidłową eksploatację i naprawy na sieci drogowej. Współczesne środki techniczne nie pozwalają na uzyskanie wszystkich niezbędnych informacji o bieżącym stanie sieci drogowej - nawet przy jej względnie małej łącznej długości. W związku z tym stosuje się często modele oparte na niepełnych zestawach danych. Aby umożliwić dalsze zastosowanie uzyskanych wyników w praktyce, niezbędne jest zastosowanie odpowiednich metod prognozowania i optymalizacji utrzymania oraz napraw. Wśród metod prognozowania wyróżnić można kilka głównych kategorii: analizy z zastosowaniem łańcuchów Markowa; metody prognozowania ekonometrycznego; metody oparte na teorii niezawodności [10-15]. Metody optymalizacji eksploatacji, napraw i remontów nawierzchni drogowych są rozwijane w kilku kierunkach: wykorzystanie nowoczesnych metod badawczych (sieci neuronowe, logika rozmyta), rozwój metod klasycznych (prewencyjne utrzymanie dróg itp.) [16-20]. Podstawę wszelkich metod prognozowania w takiej czy innej formie stanowią dane o początkowym oraz obecnym stanie nawierzchni drogowej. Oczywiście bardziej kompletne informacje o stanie nawierzchni umożliwiają dokonanie dokładniejszych prognoz dalszej degradacji oraz pozostałego czasu eksploatacji.

Niestety, istniejące technologie badań nieniszczących nie pozwalają na ciągły monitoring całej sieci drogowej. W związku z tym konieczne jest zastosowanie dodatkowych modeli do uzyskania wyników o znaczeniu praktycznym. Jednym ze skutecznych narzędzi w tym zakresie jest prognozowanie stochastyczne z zastosowaniem macierzy przejścia Markowa.

1. INTRODUCTION

Previously, the authors presented results in the field of forecasting of road pavement deterioration processes involving dynamic models [1]. The basis of this approach is monitoring of data obtained from pulsed ground penetrating radars [2-6] and further signal processing based on the algorithms proposed [7]. The issues of processing signals reflected from road pavements with thin upper layers [8, 9] were discussed separately. However, for a road engineer (who is the end user of diagnostic results) a problem of considerable importance is also the need to obtain information concerning:

- the presence and nature of faults, including subsurface defects (cracks, delamination, etc.),
- unacceptable moisture content in the base and subbase layers,
- assessment of compaction degree of different layers.

In turn, these results are necessary for a road engineer to plan further activities for the maintenance, repair and rehabilitation of the road network. Modern technical means do not enable obtaining all the necessary information about the current condition of the road network, even of a relatively small total length. Therefore, models based on incomplete data sets are commonly used. For further practical application of the results obtained, it is necessary to involve the appropriate methods of condition prediction and optimizing maintenance and repair. Several main areas can be outlined among the methods of forecasting: analysis using Markov chains; econometric forecasting methods; methods based on the theory of reliability [10-15]. The methods of optimization of repair, maintenance and rehabilitation are also developed in several directions: involving modern computer technologies (neural networks, fuzzy logic) and improving classical approaches (preventive maintenance and other) [16-20]. The basis of all forecasting methods in one form or another is the data on the initial and current condition of road pavement. Naturally, more complete information on the condition of the pavement enables making a more accurate prediction of the further deterioration and pavement life.

Unfortunately, the existing technologies of non-destructive control do not enable monitoring of the entire network of highways in a continuous mode. Consequently, additional models have to be employed to obtain practical results. One of the effective tools for solving such tasks is the stochastic prediction method based on Markov transition matrices. These matrices make it possible to formalize forecasting procedures basing on the apparatus of linear

Wykorzystanie narzędzi algebry liniowej pozwala na sformalizowanie procedury prognozowania oraz dalszą optymalizację kosztów napraw i utrzymania sieci drogowej. Bez wątpienia bezpośrednie zastosowanie takiego aparatu matematycznego musi być dobrze uzasadnione oraz sformułowane jako jeden algorytm.

Jako że niemożliwe jest opisanie w jednym artykule wszystkich szczegółów przedstawionego podejścia, celem niniejszego artykułu jest połączenie metody łańcuchów Markowa z zaproponowanymi wcześniej algorytmami oceny bieżącego stanu nawierzchni opartymi na pomiarach georadarów impulsowymi GPR. Nadrzędnym celem tej pracy jest jednak poprawa modeli przewidywania stanu degradacji nawierzchni w skali całej sieci drogowej oraz optymalizacja kosztów utrzymania i napraw dróg.

2. PROGNOZOWANIE STANU NAWIERZCHNI DROGOWEJ Z ZASTOSOWANIEM MODELI STOCHASTYCZNYCH

2.1. UWAGI OGÓLNE

Jako że problemy związane z użyciem georadarów impulsowych w ocenie aktualnego stanu nawierzchni drogowych rozpatrywano wcześniej [4-9], w niniejszym artykule autorzy skupiają się na rozwiązaniu problemu prognozowania stanu sieci drogowej z zastosowaniem modeli probabilistycznych (stochastycznych). Modele takie mają umożliwić prognozowanie prawdopodobieństwa, że nawierzchnia znajdzie się w danym stanie w danym momencie w przyszłości. Pośród modeli probabilistycznych łańcuchy Markowa [21] wyróżniają się jako efektywne i dogodne narzędzie do zarządzania drogami na poziomie sieci. Przy rozwiązywaniu zadań związanych z prognozowaniem, najczęściej pojawiają się trzy możliwości:

- dostępne są wszystkie dane o stanie wszystkich odcinków sieci z poprzedniego okresu, a wymagana jest krótkoterminowa prognoza (na przyszły rok);
- kompletne zestawy danych z wszystkich lat poprzedniego okresu z systemów zarządzania stanem nawierzchni (PMS) są dostępne tylko dla niektórych odcinków, a konieczne jest przygotowanie prognozy w średnim terminie czyli na 3-5 lat (przypadek częściowo niepełnych danych),
- zestawy danych PMS są niekompletne (nie obejmują wszystkich lat zeszłego okresu), a do tego dostępne są zaledwie dla niektórych odcinków sieci (w tym przypadku mówić można o znacząco niekompletnych danych), a wymagana jest prognoza długoterminowa (5-10 lat)..

algebra and to further optimize the costs of repair and maintenance of the road network. It is clear that direct application of such mathematical apparatus must be well-grounded and formulated as a single algorithm. However, it is impossible to reflect all the details in one paper.

Therefore, the task of this paper is to combine the previously proposed algorithms for assessing the current condition of pavements based on using pulsed ground penetrating radars with the method of Markov transition matrices. The ultimate aim of the work is to improve network-level models of pavement distress prediction and to optimize the cost of repair and maintenance of the road network.

2. PREDICTION OF ROAD PAVEMENT CONDITION USING STOCHASTIC MODELS

2.1. GENEAL REMARKS

Since the issues related to the use of pulsed ground penetrating radars for assessment of the current condition of road pavements were considered earlier [4-9], in this paper the authors focus on solving the problem of prediction of condition of the road network using probabilistic (stochastic) models. Such models are intended to predict the probability that the pavement will be in a certain condition at a given moment in the future. Among probabilistic models, Markov chains [21] are effective and convenient for managing roads at the network level. When solving the task of forecasting, three situations are the most common:

- all the data about the condition of all network sections for the previous period are available, and a short-term forecast is required (for the next year),
- a complete data set of pavement management system (PMS) is available only for a part of the sections for all years of the previous period and it is necessary to give a medium-term forecast, ie for 3-5 years (in this case they may be referred to as partially complete data sets),
- there are incomplete PMS data sets (not covering all the years of the previous period) and only for a part of the sections (in this case they may be referred to as substantially incomplete data sets) and a long-term forecast is required (5-10 years).

Since creation of a universal algorithm for constructing of an accurate forecast seems impossible, various schemes are used to make predictions more exact in different situations. Due to the limited volume, the first two cases are considered in this paper. The last case will be considered separately in a future publication.

Ponieważ stworzenie jednego uniwersalnego algorytmu dokładnej prognozy dla wszystkich ww. wypadków zdaje się niemożliwe, w różnych sytuacjach stosuje się różne schematy mające zwiększyć dokładność prognozy. Ze względu na ograniczoną objętość tekstu, w niniejszym artykule rozpatrzone zostaną dwa pierwsze przypadki. Ostatni przypadek omówiony zostanie osobno w późniejszej publikacji autorów.

2.2. MACIERZE PRZEJŚCIA MARKOWA ORAZ PROGNOZOWANIE NA PODSTAWIE KOMPLETNYCH I CZĘŚCIOWO NIEPEŁNYCH DANYCH

Na wstępie rozpatrzymy ogólny schemat zastosowania macierzy przejścia Markowa. Załóżmy, że stan nawierzchni może przyjąć jedną z pięciu wartości („pięć” to doskonały stan, „jeden” – najgorszy). Celem zastosowania aparatu algebry liniowej, wprowadzamy pojęcie macierzy przejścia, której elementy stanowią prawdopodobieństwa $P_{i,j}$ przejścia odcinka ze stanu j do stanu i . Znaczenie i zastosowanie macierzy zobrazowane jest w Tabl. 1.

W Tabl. 1 moment początkowy oznaczony jest jako t_1 , a prawdopodobieństwo wykrycia odcinka drogi w stanie j w tym momencie oznaczone jest $P_j(t_1)$ – górny wiersz. Analogicznie, prawdopodobieństwo wykrycia odcinka w tym samym stanie w chwili t_2 jest oznaczone $P_j(t_2)$ – kolumna po prawej. Prawdopodobieństwo przejścia odcinka ze stanu 1 do stanu 2 w przedziale czasu $\Delta t = t_2 - t_1$ jest oznaczone jako $P_{2,1}$. Prawdopodobieństwo, że odcinek pozostanie w swoim początkowym stanie, to $P_{1,1}$. Należy podkreślić, że w tym wypadku pierwszy indeks odpowiada stanowi końcowemu, zaś drugi indeks – stanowi początkowemu. W praktyce dogodnie jest wybranie takiego interwału obserwacji Δt , aby w tym czasie stan odcinka mógł ulec zmianie o co najwyżej jeden poziom. Przyjmijmy zatem interwał obserwacji długości jednego roku. Oczywiście jest, że w takim wypadku:

$$P_{1,1} + P_{2,1} = 1. \quad (1)$$

W konsekwencji otrzymujemy następujące zależności:

$$\begin{cases} P_1(t_2) = P_{1,1} \cdot P_1(t_1) + 0 \cdot P_2(t_1), \\ P_2(t_2) = P_{2,1} \cdot P_1(t_1) + P_{2,2} \cdot P_2(t_1). \end{cases} \quad (2)$$

Wartość $P_{1,2} = 0$ odzwierciedla fakt, że odcinek nie może samoistnie przejść ze stanu gorszego do lepszego, jeśli w rozpatrywanym okresie nie wykonano na nim żadnych prac naprawczych. Wyniki przedstawione w Tabl. 1 można wówczas związłej przedstawić w następującej postaci:

$$P_i(t_2) = P_{i,j} \cdot P_j(t_1), \quad i, j = 1 \dots 5. \quad (3)$$

Przyjęto konwencję pomijającą znak sumowania dla powtarzających się indeksów, to jest $P_{i,j} \cdot P_j(t_1) \equiv \sum_j P_{i,j} \cdot P_j(t_1)$.

2.2. MARKOV TRANSITION MATRICES AND PREDICTION WITH COMPLETE AND PARTIALLY COMPLETE DATA SETS

First, let us briefly consider the general scheme of using Markov transition matrices. Let us suppose that the pavement condition can take on five values from one to five (five is excellent condition, one is the worst). In order to further use the apparatus of linear algebra, we introduce the concept of a transition matrix, whose elements are the probabilities $P_{i,j}$ of transition of a section from condition with index j to condition with index i . The meaning of its introduction and use is explained in Table 1.

Table 1. Transition matrix and condition vector
Tablica 1. Macierz przejść i wektor stanu

Initial condition Stan początkowy					Calculation of the condition vector Obliczenie wektora stanu	Final condition Stan końcowy	
$P_1(t_1)$	$P_2(t_1)$	$P_3(t_1)$	$P_4(t_1)$	$P_5(t_1)$			
$P_{1,1}$	0	0	0	0	=	$\sum_{j=1}^5 P_{1,j} P_j(t_1)$	= $P_1(t_2)$
$P_{2,1}$	$P_{2,2}$	0	0	0		$\sum_{j=1}^5 P_{2,j} P_j(t_1)$	= $P_2(t_2)$
$P_{3,1}$	$P_{3,2}$	$P_{3,3}$	0	0		$\sum_{j=1}^5 P_{3,j} P_j(t_1)$	= $P_3(t_2)$
$P_{4,1}$	$P_{4,2}$	$P_{4,3}$	$P_{4,4}$	0		$\sum_{j=1}^5 P_{4,j} P_j(t_1)$	= $P_4(t_2)$
$P_{5,1}$	$P_{5,2}$	$P_{5,3}$	$P_{5,4}$	$P_{5,5}$		$\sum_{j=1}^5 P_{5,j} P_j(t_1)$	= $P_5(t_2)$

In Table 1, the initial moment of time is denoted as t_1 , and the probability of detection of a section of the road in condition j at this moment is denoted as $P_j(t_1)$ – the row at the top. Accordingly, the probability of detecting a section in the same condition at the point of time t_2 is indicated by $P_j(t_2)$ – the column on the right. The probability of transition of the section from condition 1 to condition 2, for example, for a period of time $\Delta t = t_2 - t_1$ is indicated by $P_{2,1}$. The probability that the section remains in its former condition will be $P_{1,1}$. It should be emphasized that in this case the first index corresponds to the final condition, and the second index corresponds to the initial one. In practice, it is convenient to choose such an observation interval Δt in which the indicator of section condition could change by one level only. Therefore, let us take one year as the observation interval. It is clear that in this case:

$$P_{1,1} + P_{2,1} = 1. \quad (1)$$

Podobnie jak w pracach [21, 27], wprowadzone zostaje również pojęcie wektora stanu odcinka nawierzchni $\mathbf{P}(t_k)$. Elementami wektora są prawdopodobieństwa stwierdzenia dla danego odcinka odpowiadających im stanów w chwili t_k , co pozwala zapisać ostatnią zależność w jeszcze zwięźlejszej postaci:

$$\mathbf{P}(t_2) = \mathbf{P}_T \cdot \mathbf{P}(t_1) \quad (4)$$

gdzie: \mathbf{P}_T – macierz przejścia, której elementy stanowią prawdopodobieństwa przejścia odcinka z jednego do drugiego stanu. W przypadku ogólnym macierz ta ma formę:

$$\mathbf{P}_T = \begin{pmatrix} P_{1,1} & 0 & 0 & 0 & 0 \\ P_{2,1} & P_{2,2} & 0 & 0 & 0 \\ P_{3,1} & P_{3,2} & P_{3,3} & 0 & 0 \\ P_{4,1} & P_{4,2} & P_{4,3} & P_{4,4} & 0 \\ P_{5,1} & P_{5,2} & P_{5,3} & P_{5,4} & 1 \end{pmatrix}. \quad (5)$$

Wartość „1” w prawym dolnym rogu odzwierciedla fakt, że odcinek znajdujący się w najgorszym stanie może jedynie w tym stanie pozostać – o ile nie zostaną przeprowadzone prace naprawcze.

O łatwości i efektywności użycia tak sformalizowanego działania matematycznego stanowi również fakt, że wystarczy przeprowadzić mnożenie wektora stanu początkowego przez macierz przejścia dwukrotnie, aby uzyskać stan odcinka po czasie $2 \cdot \Delta t$ (zakładając, że prawdopodobieństwa stanów początkowych dla tego odcinka są znane):

$$P_i(t_3) = P_{i,j} \cdot P_j(t_2) = P_{i,j} \cdot P_{i,j} \cdot P_j(t_1) = P_{i,j}^2 \cdot P_j(t_1), \quad (6)$$

albo w zwięźlejszej postaci:

$$\mathbf{P}(t_3) = \mathbf{P}_T^2 \cdot \mathbf{P}(t_1). \quad (7)$$

Oczywiste jest, że zastosowanie takiej procedury jest zasadne wyłącznie w przypadku, gdy dostępny jest kompletny zestaw danych o stanie wszystkich odcinków drogowych oraz gdy przebieg (prędkość) procesu degradacji nawierzchni nie zmienia się w czasie. Takie procesy określa się mianem procesów stacjonarnych. W ogólnym przypadku prędkość degradacji konstrukcji nawierzchni jest zależna od czasu, a więc zastosowanie ostatniego równania bez wzięcia tego faktu pod uwagę stanowi błąd. Konieczne jest zatem stosowanie w modelu konstrukcji (wyliczenia elementów) macierzy przejść takich interwałów czasowych, w obrębie których proces staje się stacjonarny. Alternatywę stanowi algorytm korekty według modeli dynamicznych [1].

Formalne rozwiązanie rozpatrywanego zadania dotyczącego prognozy stanu degradacji nawierzchni w przypadku dysponowania kompletnym zestawem danych wejściowych nie naręcza zasadniczych trudności matematycznych. W praktyce

Consequently, we come to the following set of relations:

$$\begin{cases} P_1(t_2) = P_{1,1} \cdot P_1(t_1) + 0 \cdot P_2(t_1), \\ P_2(t_2) = P_{2,1} \cdot P_1(t_1) + P_{2,2} \cdot P_2(t_1). \end{cases} \quad (2)$$

Value $P_{1,2} = 0$ reflects the obvious fact that the section could not spontaneously transit from a worse condition to a better one if no repair work was carried out at the section during the considered period of time. Then the results of Table 1 can be compactly rewritten in the following form:

$$P_i(t_2) = P_{i,j} \cdot P_j(t_1), \quad i, j = 1 \dots 5. \quad (3)$$

It implicitly assumes summation by repeated indices, that is $P_{i,j} \cdot P_j(t_1) \equiv \sum P_{i,j} \cdot P_j(t_1)$. Following the works [21, 27], the concept of vector of road section condition $\mathbf{P}(t_k)$ is also introduced. The components of this vector are the probabilities of finding this section in the corresponding conditions at the time instant t_k , which enables writing the last relation in an even more compact form:

$$\mathbf{P}(t_2) = \mathbf{P}_T \cdot \mathbf{P}(t_1) \quad (4)$$

where: \mathbf{P}_T – transition matrix, the elements of which are the probabilities of the section transition from one condition to another. In general case, this matrix has the form:

$$\mathbf{P}_T = \begin{pmatrix} P_{1,1} & 0 & 0 & 0 & 0 \\ P_{2,1} & P_{2,2} & 0 & 0 & 0 \\ P_{3,1} & P_{3,2} & P_{3,3} & 0 & 0 \\ P_{4,1} & P_{4,2} & P_{4,3} & P_{4,4} & 0 \\ P_{5,1} & P_{5,2} & P_{5,3} & P_{5,4} & 1 \end{pmatrix}. \quad (5)$$

Number “1” in the lower right corner reflects the fact that the section in the lowest (worst possible) condition can only remain in this condition in the absence of repair work.

Convenience and efficiency of such a formalized apparatus lie also in the fact that it is sufficient to apply the operation of multiplying the initial condition vector by the transition matrix twice to find the condition of the section after $2 \cdot \Delta t$ (assuming that the probabilities of the initial conditions of the section are known):

$$P_i(t_3) = P_{i,j} \cdot P_j(t_2) = P_{i,j} \cdot P_{i,j} \cdot P_j(t_1) = P_{i,j}^2 \cdot P_j(t_1), \quad (6)$$

or in a compact form:

$$\mathbf{P}(t_3) = \mathbf{P}_T^2 \cdot \mathbf{P}(t_1). \quad (7)$$

It is obvious that the application of such a procedure is valid only in the case when there is a complete data set on the condition of all road sections and the course (speed) of the process of pavement deterioration does not change with time. Such processes are called stationary. In a general case, the speed of structure deterioration depends on time and the application of the last relation without taking

natomiast najczęściej z różnych powodów dostępne są albo niekompletne dane dla wszystkich odcinków (częściowo niepełne dane), albo dane nie tylko niekompletne, lecz ponadto obejmujące zaledwie niektóre odcinki (znacząco niekompletne dane). Rozpatrzmy algorytm wyliczenia elementów macierzy przejść w przypadku dysponowania zestawem częściowo niepełnych danych.

2.3. WYZNACZENIE MACIERZY PRZEJŚCIA DLA PROCESÓW STACJONARNYCH PRZY CZĘŚCIOWO NIEPEŁNYCH ZESTAWACH DANYCH

Zaproponowano dotąd kilka metod [21-25] konstruowania macierzy przejścia przy założeniu, że rozpatrywane są procesy stacjonarne. Można wyróżnić spośród nich optymalne metody regresji [23] oraz metodę proporcji [25]. W pierwszym przypadku wykorzystuje się optymalizację nieliniową w celu minimalizacji sumy wartości bezwzględnych różnic między wartościami krzywej regresji, stanowiącej najlepszą aproksymację danych rzeczywistych, a wynikami prognoz określonych z zastosowaniem macierzy przejścia. Taki schemat działań może zostać przedstawiony za pomocą poniższego modelu matematycznego:

$$\Psi = \sum_{m=1}^M |J(t_m) - J(t_m, P_{m-1,m})| \rightarrow \min, \quad (8)$$

gdzie:

Ψ – funkcja celu,

$J(t_m)$ – wskaźnik stanu nawierzchni w okresie t_m według modelu regresji,

$J(t_m, P_{m-1,m})$ – wskaźnik stanu nawierzchni w tym samym okresie, lecz według modelu Markowa.

Model ten zakłada dostępność danych o stanie wszystkich (lub większości) odcinków oraz o czynnościach naprawczych podjętych w minionych okresach. Ponieważ informacje te w wielu przypadkach nie są dostępne w bazach danych w kompletnej postaci, zalecane jest użycie metody proporcji. Zastosowanie tej metody oparte jest na poniższym stosunku elementów macierzy przejść:

$$P_{i,j} = \frac{n_{i,j}}{n_j}, \quad (9)$$

gdzie:

$n_{i,j}$ – liczba odcinków, które przeszły ze stanu j do stanu i w danym okresie,

n_j – liczba odcinków, które były w stanie j na początku danego okresu.

Metoda ta jest skuteczna również w przypadku, gdy znane są dane z pomiarów na wszystkich odcinkach na początku oraz

this factor into account is incorrect. Therefore, it is necessary to use such time intervals in the model of construction (calculation of elements) of transition matrices, during which the process goes stationary. An alternative is the algorithm for making adjustments in accordance with dynamic models [1].

The formal solution of the considered task of forecasting of pavement deterioration with using complete data sets does not pose fundamental mathematical difficulties. In practice, however, most often there are either incomplete data for all sections (partially complete data sets) or data that are not only incomplete, but also cover only a part of the sections (substantially incomplete data) available for various reasons. Let us consider the algorithm for calculating the elements of Markov transition matrix for the case of partially complete data sets.

2.3. OBTAINING TRANSITION MATRICES FOR STATIONARY PROCESSES WITH PARTIALLY COMPLETE DATA SETS

Several methods were previously proposed [21-25] to construct transition matrices in the framework of the stationary process. The method of regression optimization [23] and the method of proportions [25] can be distinguished among them. The regression optimization method involves the use of functional non-linear optimization to minimize the sum of the absolute values of the difference between the regression curve that best approximates the actual data and the prediction results for Markov transition matrices. Such a scheme can be represented by the following mathematical model:

$$\Psi = \sum_{m=1}^M |J(t_m) - J(t_m, P_{m-1,m})| \rightarrow \min, \quad (8)$$

where:

Ψ – the objective function,

$J(t_m)$ – the condition index in the period t_m in accordance with the regression model,

$J(t_m, P_{m-1,m})$ – the condition index in the same period, but in accordance with Markov model.

This model assumes availability of information on the condition of all or most of the sections and on the repair activities carried out in previous periods. Since this information is in many cases absent in the databases in full form, it is advisable to apply the method of proportions. The application of this method is based on the following ratio for the elements of the transition matrix:

$$P_{i,j} = \frac{n_{i,j}}{n_j}, \quad (9)$$

na końcu poprzedniego okresu, tj. tylko z poprzedniego roku, nie zaś z całej dotychczasowej eksploatacji. W takim wypadku przydatnym narzędziem mogą być tablice danych o stanie odcinków pochodzące z systemu PMS. Tablice te mogą być przygotowane dla poszczególnych rodzajów uszkodzeń (ze-stawienia uszkodzeń) jak i dla wskaźnika stanu nawierzchni.

Przykładowe zastosowanie tej metody obrazują Tabl. 2 i 3, opracowane na podstawie przetworzonych danych z sytemu PMS dla istniejącej drogi publicznej. Należy podkreślić, że stany odpowiadają następującej skali: doskonały (najlepszy) stan to 5, dobry to 4 itd.

Table 2. The total Markov transition matrix corresponding to the change in pavement evenness

Tablica 2. Wynikowa macierz przejść odzwierciedlająca zmiany równości nawierzchni

Initial condition [points] Stan początkowy [punkty]					Final condition [points] Stan końcowy [punkty]
5	4	3	2	1	
0.820	0.000	0.000	0.000	0.000	5
0.180	0.641	0.000	0.000	0.000	4
0.000	0.359	0.464	0.000	0.000	3
0.000	0.000	0.536	0.795	0.000	2
0.000	0.000	0.000	0.205	1.000	1

Wartości elementów macierzy przejścia dla wskaźników zespolonych (takich jak wskaźnik stanu nawierzchni) odzwierciedlają uśredniony wpływ poszczególnych cząstkowych miar określających stan techniczny i użytkowy (Tabl. 3). Mogą one zatem różnić się od wartości elementów macierzy przejścia dla cząstkowych wskaźników stanu nawierzchni (Tabl. 2). Jak wspomniano powyżej, opisane podejście właściwe jest dla procesów stacjonarnych lub w wąskich przedziałach czasowych.

Aby zastosować powyższą metodę, konieczne jest pozyskanie kompletnych danych z ostatniego rocznego okresu dla wszystkich odcinków bądź dla znacznej ich części. Metoda ta umożliwia oczywiście konstrukcję odpowiedniej zależności regresyjnej i pozyskanie prognozy na dłuższy okres (np. 5 lat), jeśli dostępne są kompletne zestawy danych z dłuższego okresu wstecz. Niemniej jednak, w wielu przypadkach pozyskanie takich kompletnych zestawów danych jest niemożliwe ze względu na ograniczenia techniczne. W dalszej części artykułu zostanie zatem opisana proponowana metoda rozwiązania tego problemu na podstawie opracowanych wcześniej modeli dynamicznych [1].

where:

$n_{i,j}$ – the number of sections transited from the j -condition to the i -condition during the given period of time,

n_j – the number of sections that were in the j -condition at the beginning of the period.

This method is also effective in the case when the survey data for all sections at the beginning and at the end of the previous period are known, that is, only for the previous year, and not for the entire previous service life. In this case, the data tables from PMS on the condition of the sections can be a convenient tool. These tables can be made both for individual types of distress (statement of defects) and for the condition index.

An example of the application of this method is illustrated in Tables 2 and 3 obtained from the results of PMS data processing on a real public road. It is necessary to emphasize that the condition indices correspond to the following scale: excellent (the best) condition has index 5, good has index 4, and so on.

Table 3. Total Markov transition matrix corresponding to the change in the condition index

Tablica 3. Wynikowa macierz przejść odzwierciedlająca zmiany wskaźnika stanu

Initial condition [points] Stan początkowy [punkty]					Final condition [points] Stan końcowy [punkty]
5	4	3	2	1	
0.80	0.00	0.00	0.00	0.00	5
0.20	0.61	0.00	0.00	0.00	4
0.00	0.39	0.44	0.00	0.00	3
0.00	0.00	0.56	0.80	0.00	2
0.00	0.00	0.00	0.20	1.00	1

The values of the elements of the transition matrix for integral measures (such as the Pavement Condition Index) reflect the averaged characteristic for all the individual indicators determining the technical and operational condition (Table 3). Therefore, they may differ from the values of the elements of the transition matrix for partial indicators of the condition (Table 2). As mentioned above, the described approach is valid for stationary processes or for narrow time intervals.

In order to use this method, it is necessary to obtain complete survey data either for all sections or for a significant part of them for the previous one year period. Naturally,

3. PROPONOWANY MODEL PROGNOZOWANIA

Podstawę rozwiązania problemu prognozowania stanu sieci drogowej stanowią opisane powyżej zmodyfikowane modele stochastyczne oparte na tzw. łańcuchach Markowa. Należy podkreślić, że niemal we wszystkich przeanalizowanych pracach model matematyczny w postaci łańcuchów Markowa stosowany jest do prognozowania prawdopodobieństwa występowania danego stanu sieci drogowej w przypadku, kiedy dostępne są tylko niekompletne zestawy standardowych danych („stwierdzonych optycznie” uszkodzeń, stanowiących podstawę obliczeń wskaźnika stanu nawierzchni *PCI*, ang. Pavement Condition Index). Nie bierze się pod uwagę jednak faktu, że degradacja na pewnym fragmencie odcinka może postępować szybciej niż wskazuje na to podstawowy model. W takim przypadku wyniki pomiarów georadarem umożliwiają nie tylko uzupełnienie istniejących danych o nowe parametry stanu nawierzchni, lecz również udoskonalenie modelu dzięki wstępnemu zastosowaniu do takich odcinków dynamicznego modelu adaptacyjnego. Możliwość tę zobrazuje poniższy przykład.

Załóżmy, że znane są aktualne wyniki pomiarów georadarem stanu pewnej liczby odcinków. Umożliwia to przejście bezpośrednio do procedury optymalizacji wskaźników *i* – w razie konieczności – zastosowanie dynamicznego modelu adaptacyjnego [1] do prognozowania ich stanu (jeśli ich prędkość degradacji nie jest zgodna z podstawowym modelem regresyjnym). Uzyskane w ten sposób nowe dane powinny zostać uwzględnione w schemacie prognozowania stanu sieci drogowej. W niniejszym artykule proponuje się, aby włączyć do modelu sieci drogowej wyniki z dynamicznego modelu adaptacyjnego w postaci osobnego (dodatkowego) składnika.

Jak wspomniano powyżej, jeśli na niektórych fragmentach sieci proces degradacji postępuje zgodnie z podstawowym modelem regresyjnym, można wówczas zastosować do opisu jego przebiegu macierz przejść opartą na ww. modelu. W takim wypadku wektor stanu nawierzchni w danym momencie $\mathbf{P}(t_1)$ występujący we wzorze (4) może być zapisany jako suma dwóch składników:

$$\mathbf{P}_j(t_1) = \mathbf{V}(t_1) + \mathbf{P}_{j,V}(t_1), \quad (10)$$

gdzie pierwsza składowa stanowi wynik oceny (w odpowiednich jednostkach) według dynamicznego modelu adaptacyjnego, zaś drugi składnik stanowi wynik oceny opartej na podstawowym modelu regresyjnym. Indeks *V* w wyrażeniu $\mathbf{P}_{j,V}(t_1)$ występującym w (10) ma podkreślić, że prawdopodobieństwo stwierdzenia odcinków o zakładanym stanie nawierzchni zostało wyliczone zgodnie ze schematem przedstawionym w [1], w którym podstawowy model regresyjny

this method enables constructing of an appropriate regression dependence and obtaining a longer-term forecast (for example, for 5 years) if complete data sets for a longer period are available. However, due to limited technical capabilities, obtaining of such complete data sets is impossible in many cases. Therefore, we will further consider the proposed improved method of solving this task based on previously developed dynamic models [1].

3. PROPOSED PREDICTION MODEL

Modified stochastic models with Markov chains method considered above are used as the basis to solve the task of predicting the network condition. It should be emphasized that in almost all the works, Markov chains apparatus is used to predict the probability of finding road network in a given condition when only incomplete standard data sets (“visible” defects that are the basis for calculating the Pavement Condition Index - *PCI*) are available. It does not take into account the fact that the degradation process of a local fragment of a section may be faster than it is stipulated by the basic model. In this case, the results of GPR surveys make it possible not only to supplement the existing data sets with new indicators, but also to significantly improve the network model with the help of preliminary application of a dynamic adaptive model to these sections. This can be illustrated as follows.

Let us suppose that the results of GPR surveys of the current condition of a certain number of road sections are known. This makes it possible to go directly to the procedure of measure optimization and apply a dynamic adaptive model [1] to predict their condition if necessary (if the degradation speed of their condition does not correspond to the basic regression model). Then new information should be included in the network condition prediction scheme. The results of application of the dynamic adaptive model are now proposed to be included in the network model as a separate addend (summand).

As mentioned above, if in some parts of the network the degradation process progresses in accordance with the basic regression model, then the transition matrix based on this model can be used. In this case, the network condition vector at a given time $\mathbf{P}(t_1)$, appearing in (4) can be written as the sum of two summands:

$$\mathbf{P}_j(t_1) = \mathbf{V}(t_1) + \mathbf{P}_{j,V}(t_1), \quad (10)$$

where the first summand is the result of the evaluation (in corresponding units) according to the dynamic adaptive model, and the second summand is the result of the evaluation based on the basic regression model. The *V* index in

stosowany jest wyłącznie do tych odcinków, na których pomiary georadarem wykazują zgodność z nim procesu degradacji. Ogólny schemat prognozowania powinien być zatem przedstawiony w postaci następującej zależności:

$$\mathbf{P}(t_2) = \mathbf{P}_{T,D} \times [\mathbf{V}(t_1) + \mathbf{P}_{j,V}(t_1)], \quad (11)$$

gdzie dodatkowy indeks D w oznaczeniu macierzy przejść $\mathbf{P}_{T,D}$ odzwierciedla fakt, że pod uwagę zostały wzięte również dane pozyskane z dynamicznego modelu adaptacyjnego.

Ta korelacja może zostać zapisana z wyszczególnieniem operacji wykonanych na podstawie dynamicznego modelu adaptacyjnego:

$$\mathbf{P}(t_2) = \hat{\mathbf{L}}_D \times \mathbf{V}(t_1) + \mathbf{P}'_T \times \mathbf{P}_{j,V}(t_1), \quad (12)$$

gdzie:

$\hat{\mathbf{L}}_D \times \mathbf{V}(t_1)$ – wynik zastosowania dynamicznego modelu adaptacyjnego do odcinków sieci drogowej, na których dokonano pomiarów,

\mathbf{P}'_T – wyjściowa macierz przejść z uwzględnieniem poprawek.

Zaproponowana procedura zintegrowanego zastosowania powyższych modeli (dynamicznego i regresyjnego Markov'a) znacznie zwiększa dokładność i rzetelność prognoz.

4. WYNIKI I ICH OMÓWIENIE

Z punktu widzenia inżyniera drogowego ostatecznym celem oceny i prognozowania stanu sieci drogowej jest optymalizacja przydziału środków finansowych na prace utrzymaniowe i naprawcze. Istotnym zadaniem jest również przewidywanie stanu nawierzchni po naprawach. Jeśli dostępne środki są ograniczone, zadania te stanowią podstawę prewencyjnej strategii utrzymania dróg [26, 27]. W niniejszym artykule przedstawiony został algorytm konstrukcji krótkoterminowej prognozy przy dostępności kompletnych lub częściowo kompletnych zestawów danych na stosunkowo niewielkiej sieci dróg. W przypadku Ukrainy może to być na przykład sieć drogowa na poziomie jednego rejonu. Podczas opracowywania algorytmu wykorzystano dane pomiarowe z dróg w rejonie charkowskim. Pod uwagę wzięto wyniki wcześniejszych badań, bieżące problemy utrzymaniowe i naprawcze [28], różnorodne aspekty zastosowania impulsowych georadarów [29-36], jak również rozwiązania problemów diagnostycznych z uwzględnieniem aktualnych właściwości nawierzchni, np. równości [37]. Podstawowe kroki algorytmu są następujące:

1. Dane początkowe do celów prognozowania stanu sieci drogowej bez uwzględnienia prac naprawczych są wynikiem oceny wizualnej i instrumentalnej. Przy ograniczonych funduszach wykonanie pomiarów instrumentalnych na całej sieci

in the component $\mathbf{P}_{j,V}(t_1)$ of equation (10) accents the fact that the probability of finding sections in the given condition was calculated taking into account that, according to the scheme presented in [1], where the basic regression model is applied only to those sections for which the GPR survey shows that the degradation process goes in compliance with this model.

$$\mathbf{P}(t_2) = \mathbf{P}_{T,D} \times [\mathbf{V}(t_1) + \mathbf{P}_{j,V}(t_1)], \quad (11)$$

where the additional index D in the transition matrix symbol $\mathbf{P}_{T,D}$ reflects the fact that the data obtained using the dynamic adaptive model are taken into account.

This correlation can be written with explicitly specifying the prediction operations using the dynamic adaptive model:

$$\mathbf{P}(t_2) = \hat{\mathbf{L}}_D \times \mathbf{V}(t_1) + \mathbf{P}'_T \times \mathbf{P}_{j,V}(t_1), \quad (12)$$

where:

$\hat{\mathbf{L}}_D \times \mathbf{V}(t_1)$ – the result of applying the dynamic adaptive prediction model to the surveyed road sections,

\mathbf{P}'_T – the result of the adjustment of the initial transition matrix.

The proposed procedure of the integrated application of both dynamic and Markov models significantly increases the accuracy and reliability of forecast estimates.

4. RESULTS AND DISCUSSION

From the point of view of the road engineer, the ultimate goal of assessing and forecasting of the condition of the road network is to optimize the allocation of financial resources for maintenance and repair work. The task of predicting the condition of the road network after repairs is also relevant. When the available resources are limited, these tasks are the foundation of the preventive maintenance strategy [26, 27]. An algorithm concerning the construction of short-term forecasts in the presence of complete or partially complete data sets for a relatively small network of highways was presented in this paper. In the case of Ukraine, this may be a road network at the level of one region. Data from road surveys in the Kharkiv region were used in the development of the algorithm. The results of previous research were taken into account, encompassing the current maintenance and repair problems [28], various aspects of usage of pulsed ground penetrating radars [29-36] as well as solving of diagnostic tasks considering the current properties of pavements, e.g. roughness [37]. The key stages of the algorithm are as follows:

było niemożliwe. Przedstawiona jest więc propozycja utworzenia reprezentatywnej próby odcinków. Pomiarów należy dokonywać na wybranych w tym celu odcinkach, tak aby określić ich stan a następnie uogólnić i rozszerzyć na stan całej sieci drogowej.

2. Reprezentatywna próba odcinków tworzona jest w następujący sposób:

a) Drogi składające się na sieć grupowane są na kategorie, a następnie w obrębie kategorii dzielone są na odcinki, po uwzględnieniu następujących kryteriów:

- projektu nawierzchni;
- historii utrzymania,
- natężenia ruchu,
- warunków eksploatacji (klimatycznych, gruntowo-geologicznych, hydrologicznych).

Z kolei każdy odcinek dzielony jest na mniejsze segmenty w celu ułatwienia wizji lokalnej. Wartości parametrów określających stan nawierzchni powinny być zbliżone na długości całego segmentu.

b) Na podstawie przeprowadzonej oceny instrumentalnej i wizualnej wyliczany jest średni wskaźnik stanu nawierzchni dla odcinka:

$$J_{av,i} = \frac{\sum_{k=1}^{K_i} j_k \cdot l_k}{L_i}, \quad (13)$$

gdzie:

$J_{av,i}$ – średni wskaźnik stanu nawierzchni,

i – numer odcinka,

j_k – wskaźnik stanu segmentu,

l_k – długość segmentu [km],

k – numer segmentu,

K_i – łączna liczba segmentów w i -tym odcinku,

L_i – całkowita długość i -tego odcinka [km].

c) Uzyskane dane (wskaźniki stanu) są przetwarzane dla odcinków jednej części j ; określane jest ich odchylenie standardowe:

$$\sigma_j = \sqrt{\frac{\sum_{i=1}^n (J_{i,k}^j - \bar{J}^j)^2}{n-1}}, \quad (14)$$

gdzie:

J_i^j – wartości wskaźnika stanu nawierzchni na lokalnym i -tym odcinku jego j -tej części,

\bar{J}^j – wartość średnia wskaźnika stanu nawierzchni dla wszystkich zbadanych odcinków lokalnych j -tej części,

1. The initial data for forecasting of road network condition without carrying out any repair works are the results of visual and instrumental assessment. Under limited funding, an instrumental assessment of the condition of the entire road network is impossible. Therefore, a procedure of forming a representative sample of sections is proposed. Surveys should be carried out at these sites in order to determine their condition and project this condition onto the entire road network.

2. The formation of a representative sample of sections is performed in the following sequence:

a) The roads that form the network are grouped into categories. The roads are divided into sections within the same category based on:

- road pavement design,
- maintenance history,
- traffic intensity,
- operating conditions (climatic, soil-geological, hydrological).

In turn each section is divided into smaller segments for easy inspection. The values of the indicators determining the pavement condition should be similar over an entire given segment.

b) Based on the results of the performed instrumental and visual assessment, the average index of the section condition is calculated:

$$J_{av,i} = \frac{\sum_{k=1}^{K_i} j_k \cdot l_k}{L_i}, \quad (13)$$

where:

$J_{av,i}$ – the average condition index,

i – the section number,

j_k – the condition index of the segment,

l_k – the segment length [km],

k – the segment number;

K_i – the total number of segments on the i^{th} section,

L_i – the total length of the i^{th} section [km].

c) The obtained data (condition indices) are processed for the sections of one j part and their mean-squared deviation is estimated:

$$\sigma_j = \sqrt{\frac{\sum_{i=1}^n (J_{i,k}^j - \bar{J}^j)^2}{n-1}}, \quad (14)$$

where:

n – łączna liczba lokalnych odcinków zbadanych w j -tej części.

d) Przedział ufności określany jest na podstawie n znanych pomiarów z zastosowaniem testu t-Studenta t_{Stud} przy założeniu, że błąd wartości średniej nie przekracza $\pm\mu_j^{Stud}$ ($\mu_j^{Stud} = 0,1 \cdot \bar{J}^j$):

$$t_{Stud} = \frac{\mu_j^{Stud} \cdot \sqrt{n}}{\sigma_j}, \quad (15)$$

e) Na podstawie t_{Stud} i n wyznaczany jest poziom ufności. Akceptowalna wartość współczynnika ufności to $P = 0,95$.

f) W przypadku uzyskania niższej wartości współczynnika ufności określa się minimalną liczbę odcinków w próbie gwarantującą wymaganą dokładność dla danego błędu:

$$n_{min} = \frac{\sigma_j^2 \cdot 1,65^2}{(\mu_j^{Stud})^2}. \quad (16)$$

3. Ocenę stanu odcinków przeprowadza się na podstawie wyników uzyskanych z pomiarów instrumentalnych, danych z systemu PMS, oceny wizualnej oraz z badania georadarem. Wskaźnik stanu nawierzchni *PCI* stosowany jest jako miernik charakteryzujący techniczny i użytkowy stan odcinka drogi. Dopuszczalne jest również użycie wskaźnika *TCI* (ang. Technical Condition Index) [28]. *TCI* wylicza się na podstawie ugięć sprężystych pod zadaniem obciążeniem, jak również obliczonych naprężeń rozciągających na spodzie górnej warstwy oraz naprężeń ścinających w podłożu. Wskaźnik wynosi 0 dla najgorszego możliwego stanu, a 100 dla najlepszego. Ze względu na ograniczenia w objętości niniejszego artykułu, autorzy mają nadzieję przedstawić zagadnienia związane z użyciem *TCI* w odrębnej publikacji.

Łączny (sumaryczny) wskaźnik stanu odcinka nawierzchni jest wyliczany na podstawie wartości cząstkowych wskaźników stanu określonych podczas wizji lokalnej (Tabl. 4):

$$J_{\Sigma} = \frac{\sum_{i=1}^I J_i}{I}, \quad (17)$$

gdzie:

I – łączna liczba cząstkowych wskaźników stanu,

J_i – cząstkowy wskaźnik stanu.

4. Uzyskane wartości wskaźnika stanu dla reprezentatywnej próby odcinków przenoszone są na całą sieć drogową. W ten sposób początkowy stan sieci zostaje określony na podstawie wyników pomiarów jako długość odcinków znajdujących się w jednym z pięciu możliwych stanów nawierzchni wg klasyfikacji *PCI*.

J_i^j – the values of the pavement condition index on the local i -section of the j -part

\bar{J}^j – the average value of the pavement condition index for all examined local sections of the j -part,

n – the total number of local sections surveyed at the j -part.

d) The confidence interval is determined based on n of known measurements by the Student t-test t_{Stud} , provided that the error of the mean value does not go beyond $\pm\mu_j^{Stud}$ ($\mu_j^{Stud} = 0,1 \cdot \bar{J}^j$):

$$t_{Stud} = \frac{\mu_j^{Stud} \cdot \sqrt{n}}{\sigma_j}, \quad (15)$$

e) On the basis of the values of t_{Stud} and n , the confidence level is determined. The value of the confidence level $P = 0,95$ is acceptable.

f) In the case of a smaller value of the confidence level, the minimum number of sample sections guaranteeing the required accuracy for a given measurement error is calculated:

$$n_{min} = \frac{\sigma_j^2 \cdot 1,65^2}{(\mu_j^{Stud})^2}. \quad (16)$$

3. Assessment of the condition of sections is carried out according to the results of instrumental measurements, PMS data, visual assessment or GPR survey of road pavements. The Pavement Condition Index *PCI* is used as an indicator characterizing the technical-maintenance condition of a road section. Use of the Technical Condition Index *TCI*, considered in [28], is also allowed. *TCI* is calculated based on measurements of elastic deflection under the reference load, as well as calculations of tensile stresses at the bottom of the upper layer and shear stresses in the subgrade. This index equals 0 for the worst possible condition and 100 for the best condition. Due to the limited size of the paper, the authors hope to consider the issues related to the use of *TCI* in the next publication.

The total (summary) index of the road section condition is calculated on the basis of the values of partial condition indices established according to the results of the survey (Table 4):

$$J_{\Sigma} = \frac{\sum_{i=1}^I J_i}{I}, \quad (17)$$

where:

I – the total number of partial condition indices,

J_i – partial condition indices.

Table 4. Corrections of reducing partial condition indicators
 Tablica 4. Korekcja cząstkowych wskaźników stanu

Indicators of pavement condition Miary stanu nawierzchni	Correction / Korekta ΔN_i
Relative area of potholes, destruction J_{n_p} Powierzchnia wybojów i ubytków	area less than 3% / powierzchnia poniżej 3%: $\Delta N_p = 20 \cdot S_p$
	area from 3% to 10% / powierzchnia od 3% do 10%: $\Delta N_p = 60 + 4 \cdot S_p$
	area more than 10% / powierzchnia powyżej 10%: $\Delta N_p = 100$
Relative area of sections with cracks J_{n_c} Powierzchnia odcinków spękanych	area less than 20% / powierzchnia poniżej 20%: $\Delta N_c = 2.5 \cdot S_c$
	area from 20% to 70% / powierzchnia od 20% do 70%: $\Delta N_c = 50 + 0.5 \cdot (S_c - 20)$
	area more than 70% / powierzchnia powyżej 70%: $\Delta N_c = 82$
Rutting, cross-sectional distortion J_{n_r} Koleiny, zaburzenia równości w przekroju poprzecznym	with rut depth less than 10 mm / głębokość koleiny poniżej 10 mm: $\Delta N_r = 0.5 \cdot h_r$
	with rut depth from 10 mm to 30 mm / głębokość koleiny od 10 mm do 30 mm: $\Delta N_r = 5 + 0.8 \cdot h_r$
	with rut depth from 30 mm to 45 mm / głębokość koleiny od 30 mm do 45 mm: $\Delta N_r = 29 + 0.9 \cdot h_r$
	with rut depth more than 45 mm / głębokość koleiny powyżej 45 mm: $\Delta N_r = 92$
Transverse waves, shifts J_{n_v} Nierówności poprzeczne, uskoki	small / małe: $\Delta N_v = 10$
	moderate / średnie: $\Delta N_v = 30$
	critical, exceeding normative values / krytyczne, przekraczające wartości normatywne: $\Delta N_v = 60$
Quality of patching work $J_{n_{rep}}$ Jakość łat	high / wysoka: $\Delta N_{rep} = 5$
	average / średnia: $\Delta N_{rep} = 10$
	low / niska: $\Delta N_{rep} = 20$
Roadside Condition $J_{roadside}$ Stan pobocza	satisfactory / zadowolający: $\Delta N_{roadside} = 10$
	unsatisfactory / niezadowolający: $\Delta N_{roadside} = 20$
Providing drainage J_6 Drenaż	partially provided / częściowo zapewniony: $\Delta N_6 = 20 - 50$
	not provided / niezapewniony: $\Delta N_6 = 70$
Condition of engineering arrangement J_{eng} Stan oprzyrządowania inżynierskiego	satisfactory / zadowolający: $\Delta N_{eng} = 30$
	unsatisfactory / niezadowolający: $\Delta N_{eng} = 70$
Condition of bridge structures J_{bridge} Stan obiektów mostowych	limited normal / ograniczony normalny: $\Delta N_{bridge} = 10$
	satisfactory / zadowolający: $\Delta N_{bridge} = 10 - 50$
	non-serviceable / uniemożliwiający eksploatację: $\Delta N_{bridge} = 80$

5. Macierz przejść Markowa – przedstawiona we wzorze (5) – tworzona jest na podstawie danych systemu zarządzania PMS dotyczących stanu nawierzchni odcinków drogowych w poprzednich okresach (minimalny okres uwzględniany to 3 lata). Elementy macierzy przejść są wyliczane przy pomocy wzoru (9).

6. Określany jest stan sieci drogowej po upływie pewnego przedziału czasowego (zalecane przyjęcie jednego roku), zgodnie ze wzorem (4). W wyniku przeprowadzonych obliczeń ustalana jest po roku objętym prognozą długość odcinków sieci drogowej znajdujących się w doskonałym (PCI powyżej 85), dobrym ($PCI = 70-85$), zadowolającym ($PCI = 55-70$), niezadowolającym ($PCI = 40-55$) oraz nieakceptowalnym (PCI poniżej 40) stanie, przy założeniu, że w tym czasie nie zostaną wykonane żadne prace naprawcze nawierzchni.

4. The obtained values of the condition index of the representative sample of sections are projected onto the entire road network. Thus, the initial condition of the road network is formed according to the results of the survey – described as the length of network sections that are in one of the five possible conditions in the PCI classification.

5. Markov transition matrix (5) is constructed on the basis of the data (PMS data) concerning the condition of the sections in the previous periods (the minimum period is 3 years). The elements of the transition matrix are calculated using formula (9).

6. The condition of the network is calculated after a certain time interval (it is advisable to assume 1 year) using formula (4). The result of the calculation is the length of the road network sections that are in excellent (PCI over 85),

7. Niezbędne jest wyliczenie wskaźnika stanu po działaniach naprawczych dla odcinków, na których w okresie prognozy (jednego roku) planowane są takie działania. Obliczenie wskaźnika stanu po działaniach naprawczych oparte jest na założeniu, że usunięcie uszkodzeń z różnych grup (Tabl. 4) może zostać uwzględnione poprzez wprowadzenie dodatniej korekty do odpowiedniego cząstkowego wskaźnika stanu. Proponowany jest zatem następujący schemat szacowania stanu odcinków po przeprowadzeniu prac naprawczych i utrzymaniowych:

a) Na podstawie przedstawionych w Tabl. 4 ujemnych korekcyj wskaźnika stanu nawierzchni, proponowany jest wzór umożliwiający wyliczenie dodatniej korekcyj w stosunku do aktualnego cząstkowego wskaźnika stanu J_i , z uwzględnieniem i -tego parametru (typu uszkodzenia):

$$\Delta N_+ = 45 \cdot \left(\frac{\sum_{i=1}^I \Delta N_i}{\sum_{i=1}^I \Delta N_{i, \max}} \right) \cdot k_j, \quad (18)$$

gdzie:

ΔN_+ – łączna korekta, znak + odzwierciedla wzrost wskaźnika stanu po naprawach,

ΔN_i – aktualna wartość korekty ujemnej pochodzącej od i -tego typu uszkodzeń, określona w Tabl.,

$\Delta N_{i, \max}$ – maksymalna możliwa wartość korekty ujemnej pochodzącej od i -tego typu uszkodzeń, określona w Tabl. 4,

I – łączna liczba stwierdzonych typów uszkodzeń,

k_j – współczynnik normalizacyjny wg typów przeprowadzonych prac.

Wartości współczynników normalizacyjnych należy przyjmować na podstawie Tabl. 5.

Maksymalny możliwy przyrost wskaźnika stanu nawierzchni po naprawach wynosi 45. Podejście zaproponowane we wzorze (18) zapewnia elastyczność w ocenie przeprowadzonych prac, zależnie od rodzaju i skali uszkodzeń, pozwalając na dopasowanie początkowego i końcowego stanu odcinka.

b) Wskaźnik stanu odcinków sieci, na których planowane są naprawy, wyliczany jest za pomocą wzoru (13), a następnie klasyfikowany jako należący do jednego z pięciu możliwych przedziałów.

8. Prognozowany stan sieci drogowej wyliczany jest ponownie, tj. dla każdego z pięciu poszczególnych stanów sieci drogowej określone są długości znajdujących się w nim odcinków niepoddanych naprawom, a następnie są one sumowane

good ($PCI = 70-85$), satisfactory ($PCI = 55-70$), unsatisfactory ($PCI = 40-55$) or failed (PCI below 40) condition for the predicted year of operation, provided that no repairs were carried out on the road network.

7. It is necessary to calculate the condition index after the repair activities for the sections where the repair is planned in the forecast period (1 year). The calculation of the condition index after repair activities is based on the assumption that elimination of defects of various groups (Table 4) during the repair process can be taken into account by introducing positive correction to the initial partial condition index. Therefore, the following scheme for assessing the condition of sections after carrying out repair work is offered:

a) On the basis of the estimates in Table 4 for corrections reducing the road condition index, the following formula is offered to calculate the positive correction to the current partial condition index J_i , taking into account the presence of the i^{th} indicator:

$$\Delta N_+ = 45 \cdot \left(\frac{\sum_{i=1}^I \Delta N_i}{\sum_{i=1}^I \Delta N_{i, \max}} \right) \cdot k_j, \quad (18)$$

where:

ΔN_+ – the total correction, the + sign reflects the increase in the condition index after repairs,

ΔN_i – the current value of the reducing correction from the i^{th} type of defects, determined from Table 4,

$\Delta N_{i, \max}$ – the maximum possible value of the reducing correction from the i^{th} type of defects, determined from Table 4,

I – the total number of present defects,

k_j – the normalization coefficient by the types of the work performed.

The values of the normalization coefficient should be assumed based on Table 5.

The maximum possible increment of the condition index after repair is 45. The approach proposed in formula (18) provides flexibility to evaluate the work performed, depending on the type of measures and the number of defects, thereby fulfilling the task of matching the initial condition with the final condition of the road section.

b) The condition index of the network sections on which the repair work is planned is calculated using (13), and the condition is assessed (as one of the five possible conditions).

z długościami odcinków, które znajdują się w tym samym zakresie stanu po naprawie. Korekty związane z lokalnym zastosowaniem modelu dynamicznego [1] są wprowadzane w przypadku stwierdzenia odcinków z odchyleniami od podstawowego modelu regresyjnego. W ramach obliczeń dokonanych przez autorów, opartych na wynikach badań z lat 2016-2018 porównano prognozowane wartości z rzeczywistymi danymi z wizji lokalnych, tak aby skorygować stosowany model dynamiczny. Ze względu na ograniczoną objętość artykułu autorzy zamierzają szczegółowo opisać tę procedurę w przyszłej publikacji.

9. Średni wskaźnik stanu nawierzchni dla sieci jest wyliczany z uwzględnieniem dokonanych napraw:

$$\bar{J} = \frac{\sum_{j=1}^m J_j \cdot L_j}{L}, \quad (19)$$

gdzie:

- \bar{J} – łączna liczba cząstkowych wskaźników stanu,
- m – liczba stanów, w których znajdują się odcinki,
- J_j – średni wskaźnik stanu odcinków dla j -tego stanu,
- L_j – długość odcinków sieci znajdujących się w j -tym stanie [km],
- L – łączna długość sieci.

Table 5. Values of the normalization coefficient k_j for different types of roadworks
 Tablica 5. Wartości współczynnika normalizacyjnego k_j w przypadku różnych rodzajów wykonanych prac drogowych

Type of roadwork / Rodzaj prac	k_j
Placement of chip seal and other surface treatments to increase surface friction, improve the evenness of pavements and level the transverse profile Powierzchniowe utrwalenia i inne zabiegi powierzchniowe mające poprawić szorstkość oraz równość poprzeczną i podłużną nawierzchni	0.9
Repair and restoration of worn-out upper layers of cement concrete, asphalt concrete and other pavements, including the technology of regeneration and profiling Naprawa zużytych górnych warstw z betonu cementowego, betonu asfaltowego i innych, w tym technologia regeneracji i profilowania	1.0
Placement of thin layers of emulsion-mineral materials and asphalt concrete mixtures over existing pavement Przykrycie istniejącej nawierzchni cienką warstwą mieszanki mineralno-emulsyjnej lub betonu asfaltowego	0.8
Pointing and sealing cracks and joints on the pavements Wypełnienie i uszczelnienie spęknięć i szczelin	0.5
Upgrading of the profile of crushed stone and gravel-improved pavements with addition of up to 50% of the thickness of new materials Profilowanie nawierzchni z kruszywa łamanego lub żwirowego, z możliwością zwiększenia grubości o max. 50% materiałem nowym	0.9
Restoration of the profile and strengthening individual sections of the carriageway of crushed stone, gravel and dirt roads with the addition of local road-building materials: crushed stone, gravel, slag or stone siftings, etc. – up to 500 m ³ per 1 km Profilowanie i przebudowa dróg z kruszyw oraz dróg gruntowych z wykorzystaniem dostępnych lokalnie materiałów: kruszyw łamanych, żwirowych, żużla lub wysiewek, itp. – do 500 m ³ na kilometr jezdni	1.0

8. The predicted condition of the road network is calculated again; for each of the five conditions the estimates of the length of road sections where no repairs were carried out are summed with the length of the road sections that fall into this condition class after the repairs. The correction involving the dynamic model of the local level [1] is carried out if sections with deviations from the base regression model are present. In the authors' practical calculations, for the three years 2016-2018 of observations the predicted values were compared with the real data sets from surveys of respective sections to correct the dynamic model used. Due to the limited size of the paper, the authors hope to describe this procedure in detail in a future publication.

9. The average network condition index is calculated taking into account the repair activities carried out:

$$\bar{J} = \frac{\sum_{j=1}^m J_j \cdot L_j}{L}, \quad (19)$$

where:

- \bar{J} – the average network condition index,
- m – the number of conditions of the network sections,
- J_j – the average index of the sections condition in the j^{th} condition,
- L_j – the length of the network sections in the j^{th} condition [km],
- L – the total network length.

Obliczenia prognozowanych wartości wskaźnika stanu sieci drogowej mogą być wykonane w arkuszach kalkulacyjnych Microsoft Excel, Libre Office Calc lub podobnym oprogramowaniu. Rys. 1 przedstawia wyniki ocen stanu odcinków drogowych z uwzględnieniem prognozy opartej na danych z trzech lat, tj. od 2014 r. do 2016 r. [1] oraz ich korekty opartej na rzeczywistych pomiarach wykonanych w 2017 r.

Partial index 1 – evenness of pavement Wskaźnik cząstkowy 1 – równość nawierzchni						
Condition of sections [points] Stan odcinków [punkty]	5	4	3	2	1	Total number of sections in 2017 Łączna liczba odcinków w 2017 r.
5	195	0	0	0	0	195
4	10	381	0	0	0	391
3	0	15	75	0	0	90
2	0	0	22	35	0	57
1	0	0	0	9	7	16
Total number of sections in 2016 Łączna liczba odcinków w 2016 r.	205	396	97	44	7	749

Partial index 2 – rutting Wskaźnik cząstkowy 2 – koleiny						
Condition of sections [points] Stan odcinków [punkty]	5	4	3	2	1	Total number of sections in 2017 Łączna liczba odcinków w 2017 r.
5	209	0	0	0	0	209
4	6	387	0	0	0	393
3	0	13	74	0	0	87
2	0	0	16	35	0	51
1	0	0	0	6	3	9
Total number of sections in 2016 Łączna liczba odcinków w 2016 r.	215	400	90	41	3	749

Calculations of the predicted values of the condition index can be performed using Microsoft Excel, Libre Office Calc or similar spreadsheet software. Fig. 1 shows the results of assessment of the condition of sections, taking into account the forecast based on data for the 3 years (2014-2016) [1] and their correction based on the results of actual measurements in 2017.

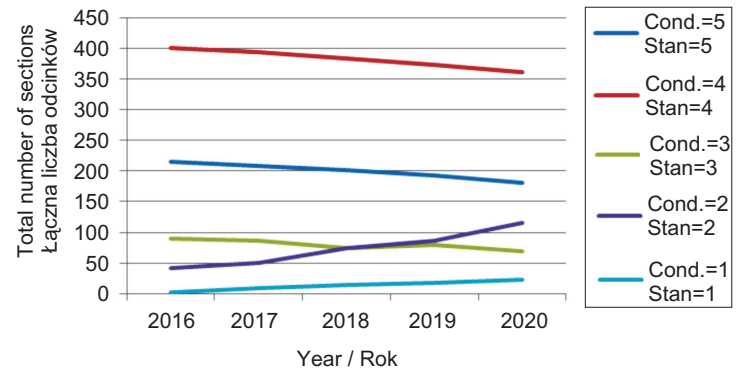



Fig. 1. Example data on road section transitions according to chosen partial condition indices (1 – evenness of pavement, 2 – rutting)
Rys. 1. Przykładowe dane przejścia odcinków drogowych do innej klasy stanu sieci drogowej na podstawie wybranych wskaźników cząstkowych (1 – równość nawierzchni, 2 – koleiny)

Rys. 2 przedstawia przykładowe dane początkowe (2014-2016, „TCI rzeczywiste”), prognozę (2017-2018, „TCI prognoza”) oraz rzeczywiste wartości (2017-2018, „TCI rzeczywiste”) uzyskane podczas oceny stanu nawierzchni odcinka drogi w rejonie charkowskim. Jak widać, istnieje dobra korelacja między rzeczywistymi danymi uzyskanymi podczas wizji lokalnej oraz ich wcześniejszymi prognozami. Lekki wzrost wskaźników można wytłumaczyć zwiększeniem nakładów finansowych w roku 2016.

Fig. 2 illustrates an example of initial data (2014-2016 TCI Actual), forecast (2017-2018 TCI Forecast) and real results (2017-2018 TCI Actual) of the assessment of the condition of a road section in the Kharkov region. One can see that the actual data obtained in the survey correlate well with the forecast results and a slight increase in the indicators is explained by increased in funding in 2016.

Summary / Podsumowanie					
Section No 3, 31+800-36+800; total length 5 km Odcinek nr 3, 31+800-36+800; łączna długość 5 km					
Indicators Wskaźniki	Years / Lata				
	Real Rzeczywiste			Prediction Prognoza	
	2014	2015	2016	2017	2018
<i>TCI</i> actual / rzeczywisty	85	82	78	75	68
<i>TCI</i> forecast / prognoza				73	67
Forecast after repair Prognoza po naprawach				91	89
Budget [euro/km of the lane] Budżet [euro/km pasa ruchu]	1200	1200	3000	1200	1200

a)



b)

Fig. 2. Data (a) and surveys (b) concerning the road section condition in the Kharkov region
Rys. 2. Dane (a) oraz pomiary (b) dotyczące stanu odcinka drogi w rejonie charkowskim

5. WNIOSKI

Modele stochastyczne wykorzystujące metodę łańcuchów Markowa zostały zaadaptowane do prognozowania stanu sieci drogowej. Danymi początkowymi do obliczeń macierzy przejścia stanu są wyniki oceny wizualnej oraz instrumentalnej. Zalecane jest użycie zestawów danych w postaci tablic danych systemu zarządzania stanem nawierzchni (PMS) opartych na reprezentatywnej próbie odcinków. W metodzie macierzy przejścia wykorzystuje się przedziały czasowe o długości jednego roku. Do obliczenia elementów macierzy przejścia, w przypadku dostępności kompletnych danych o stanie odcinków dróg, mogą zostać użyte standardowe metody statystyczne. Przedstawiono również procedurę tworzenia macierzy przejścia z użyciem częściowo kompletnych zestawów danych. Podstawę tej procedury stanowią informacje o wcześniejszym stanie nawierzchni oraz wyniki oceny instrumentalnej, umożliwiające korektę prognozowanych wartości. Wynikowa macierz uwzględnia nie tylko prawdopodobieństwo, lecz również prędkość przejścia odcinków z jednego stanu do drugiego.

Przedstawiono problem optymalizacji stanu sieci dróg oraz ogólny schemat jego rozwiązania. Obliczenia zmian wskaźnika stanu nawierzchni po przeprowadzonych działaniach naprawczych oparte są na założeniu, że eliminacja uszkodzeń różnego typu może zostać odzwierciedlona przez wprowadzenie dodatniej korekty do wskaźnika stanu.

5. CONCLUSIONS

Stochastic forecasting models based on Markov chains have been adapted to predict the condition of the road network. The initial data for calculating the matrix elements of transition of sections from one condition to another are the results of both visual and instrumental evaluation. Data sets in the form of PMS data tables based on a representative sample of sections are recommended. The transition matrix model uses discrete time intervals of one year. Standard methods of statistical processing can be used to calculate transition matrices with complete data sets on the condition of network sections. The procedure of forming the transition matrix with partially complete data sets has been also presented. The basis of this procedure is the information on the previous condition of the structure and the results of the instrumental evaluation, which corrects the predicted values. The final matrix takes into account not only the probability, but also the speed of transition of sections from one condition to another.

The statement of problem and a general scheme for solving the task of optimizing the transport and operational condition of the road network using the network condition index has been developed. Calculation of the road network condition index after carrying out repair activities is based on the assumption that elimination of defects of various types in the process can be reflected by positive correction to the initial partial condition index.

Zadanie optymalizacji stanu nawierzchni oparte jest na zależnościach określających maksymalne bądź minimalne długości odcinków znajdujących się w poszczególnych stanach po wykonaniu napraw. Uwzględniono również możliwość obróbki danych w odpowiednim oprogramowaniu.

BIBLIOGRAFIA / REFERENCES

- [1] *Batrakova A.G., Batrakov D.O., Antyufeyeva M.S.*: Pavement deterioration model based on GPR datasets. *Roads and Bridges - Drogi i Mosty*, **17**, 1, 2018, 55-71, DOI: 10.7409/rabdim.018.004
- [2] *Jol H.M.* (Ed.): *Ground penetrating radar: theory and applications*. Elsevier Science, Amsterdam, 2009, 508 p.
- [3] *Sudyka J., Krysiński L.*: Radar technique application in structural analysis and identification of interlayer bonding. *International Journal of Pavement Research and Technology*, **4**, 3, 2011, 176-184
- [4] *Evans R.D.*: *Optimising Ground Penetrating Radar (GPR) to Assess Pavements*. A dissertation thesis submitted in partial fulfillment of the requirements for the award of the degree Doctor of Engineering at Loughborough University, 2009, 219 p.
- [5] *Zieliński A., Mazurkiewicz E., Łyskowski M., Wieczorek D.*: Use of GPR method for investigation of the mass movements development on the basis of the landslide in Kałków. *Roads and Bridges - Drogi i Mosty*, **15**, 1, 2016, 61-70, DOI: 10.7409/rabdim.016.004
- [6] *Lachowicz J., Rucka M.*: Numerical modeling of GPR field in damage detection of a reinforced concrete footbridge. *Diagnostyka*, **17**, 2, 2016, 3-8
- [7] *Pochanin G.P., Masalov S.A., Ruban V.P., Kholod P.V., Batrakov D.O., Batrakova A.G., Urdzik S.N., Pochanin O.G.*: Advances in Short Range Distance and Permittivity Ground Penetrating Radar Measurements for Road Surface Surveying, in: *Advanced Ultrawideband Radar: Signals, Targets and Applications*. CRC Press - Taylor & Francis Group, London, 2016, 20-65
- [8] *Batrakov D.O., Antyufeyeva M.S., Antyufeyev A.V., Batrakova A.G.*: UWB signal processing during thin layers thickness assessment. 2016 IEEE Radar Methods and Systems Workshop, September 27-28, 2016, Kyiv, Ukraine, 36-39
- [9] *Batrakov D.O., Batrakova A.G.*: Combined GPR data analysis technique for diagnostics of structures with thin near-surface layers. *Diagnostyka*, **19**, 3, 2018, 11-20, DOI: 10.29354/diag/91489
- [10] *Moavebzadeh F.*: Stochastic Model for Prediction of Pavement Performance. *Transportation Research Record*, **575**, 1976, 56-72
- [11] *Madanat S., Karlaftis M.G., McCarthy P.S.*: Probabilistic Infrastructure Deterioration Models with Panel Data. *Journal of Infrastructure Systems*, **3**, 1, 1997, 4-9
- [12] *Gharaibeh N.G., Darter M.I.*: Probabilistic Analysis of Highway Pavement Life for Illinois. *Transportation Research Record*, **1823**, 2002, 111-120
- [13] *Madanat S., Bulusu S., Mahmoud A.*: Estimation of Infrastructure Distress Initiation and Progression Models. *Journal of Infrastructure Systems*, **1**, 3, 1995, 146-150
- [14] *Sas W., Gluchowski A.*: Rutting prediction for stabilized soils based on the cyclic CBR test. *Roads and Bridges - Drogi i Mosty*, **12**, 4, 2013, 411-423, DOI: 10.7409/rabdim.013.026
- [15] *Kobayashi K., Do M., Han D.*: Estimation of Markovian transition probabilities for pavement deterioration forecasting. *KSCE Journal of Civil Engineering*, **14**, 3, 2010, 343-351
- [16] *Marović I., Androjić I., Jajac N., Hanák T.*: Urban Road Infrastructure Maintenance Planning with Application of Neural Networks. *Complexity*, vol. **2018**, 2018, Article ID 5160417, 10 p.
- [17] *Moazami D., Behbahani H., Muniandy R.*: Pavement rehabilitation and maintenance prioritization of urban roads using fuzzy logic. *Expert Systems with Applications*, **38**, 10, 2011, 12869-12879
- [18] *Wang F., Zhang Z., Machemehl R.*: Decision-making problem for managing pavement maintenance and rehabilitation projects. *Transportation Research Record: Journal of the Transportation Research Board*, **1853**, 2003, 21-28
- [19] *Zimmerman K., Peshkin D.*: Issues in integrating pavement management and preventive maintenance. *Transportation Research Record: Journal of the Transportation Research Board*, **1889**, 2004, 13-20
- [20] *Sołowczuk A., Gardas P., Schab M.*: Efficiency repair and maintainance works at bus bays and bus stops. *Roads and Bridges - Drogi i Mosty*, **13**, 2, 2014, 157-166, DOI: 10.7409/rabdim.014.011
- [21] *Tjan A., Pitaloka D.*: Future prediction of pavement condition using Markov probability transition matrix. *Proceedings of the Eastern Asia Society for Transportation Studies*, **5**, 2005, 772-782
- [22] *Butt A.A., Shahin M.Y., Carpenter S.H., Carnahan J.V.*: Application of Markov Process to Pavement Management Systems at Network Level. *Proceedings of The Third International Conference on Managing Pavements*, San Antonio, Texas, May 22-26, 1994, 89-100

- [23] Madanat S., Mishalami R., Ibrahim W.H.: Estimation of Infrastructure Transition Probabilities from Condition Rating Data. *Journal of Infrastructure Systems*, **1**, 2, 1995, 120-125
- [24] Bulusu S., Sinha K.C.: Comparison of Methodologies to Predict Bridge Deterioration. *Transportation Research Record*, **1597**, 1997, 34-42
- [25] Garcia J.J., Costello S.B., Snaith M.S.: Derivation of Transition Probability Matrices for Pavement Deterioration Modeling. *Journal of Transportation Engineering*, **132**, 2, 2006, 141-161
- [26] Brown E.R.: Preventive Maintenance of Asphalt Concrete Pavements. *Transportation Research Record*, **1205**, 1988, 6-11
- [27] Sebaaly P.E., Hajj E.Y.: Effectiveness of preventive maintenance of asphalt pavements. *Proceedings of 6th Euroasphalt and Eurobitume Congress*, 1-3 June 2016, Prague, Czech Republic, 1-9
- [28] Batrakova A.G.: Assessment of road pavements condition with the georadar technologies. *KhNADU Ed.*, Kharkiv, 2013, 152 p. (in Russian)
- [29] Batrakov D.O., Batrakova A.G., Golovin D.V.: Numerical simulation of UWB impulse response of plane layered media with 2D inclusion. *Proceedings of The 6th International Conference on Ultrawideband and Ultrashort Impulse Signals (UWBUSIS)*, 17-21 Sept. 2012, Sevastopol, 153-155, DOI: 10.1109/UWBUSIS.2012.6379763
- [30] Batrakov D.O., Zhuk N.P.: Method for testing of layer-non-homogeneous dielectrics using numerical solution of reverse problem dialing with dissipation in polarization parameters domain. *Defektoskopiya (Russian Journal of Nondestructive Testing)*, **6**, 1994, 82-87
- [31] Sudyka J., Krysiński L.: Evaluation of Homogeneity of Thickness of New Asphalt Layers Using GPR. *IOP Conference Series Materials Science and Engineering "Resilient and Safe Road Infrastructure"*, 8-9 May 2018, Kielce, **356**, 1, 2018, 1-10, DOI: 10.1088/1757-899X/356/1/012025
- [32] Saarenketo T.: Electrical Properties of Road Materials and Subgrade Soils and the Use of Ground Penetrating Radar in Traffic Infrastructure Surveys, Faculty of Science, Department of Geosciences, University of Oulu, Academic dissertation, 2006, 125 p.
- [33] Krysiński L., Sudyka J.: Typology of reflections in the assessment of the interlayer bonding condition of the bituminous pavement by the use of an impulse high-frequency ground-penetrating radar. *Nondestructive Testing and Evaluation*, **27**, 3, 2012, 219-227
- [34] Tarefder R.A., Ahmed M.U.: Ground penetrating radar for measuring thickness of an unbound layer of a pavement. *Advances in Intelligent Systems and Computing*, **598**, 2018, 160-167
- [35] Batrakov D.O., Antyufeyeva M.S., Antyufeyev A.V., Batrakova A.G.: Inverse problems and UWB signals in biomedical engineering and remote sensing. *Proceedings of The 8th International Conference on Ultrawideband and Ultrashort Impulse Signals*, 5-11 September 2016, Odessa, Ukraine, 148-151
- [36] Batrakov D.O.: Quality and efficiency of information monitoring at radio wave testing of inhomogeneous dielectric layers by using a multifrequency method. *Defektoskopiya*, **8**, 1998, 68-76
- [37] Zhuck N.P., Batrakov D.O.: Determination of Electrophysical Properties of a Layered Structure With a Statistically Rough Surface via an Inversion Method. *Physical Review B*, **51**, 23, 1995, 17073-17080