



ANDRZEJ POŻARYCKI

Politechnika Poznańska
andrzej.pozarycki@put.
poznan.pl



TOMASZ GARBOWSKI

Politechnika Poznańska
tomasz.garbowski@put.
poznan.pl

Automatyzacja inwentaryzacji uszkodzeń nawierzchni jezdni z wykorzystaniem sztucznych sieci neuronowych

Zadanie identyfikacji makroskopowych uszkodzeń nawierzchni jezdni to obszar zagadnień związanych z rozpoznaniem wzorca na obrazie cyfrowym. Prawidłowo rozpoznany stan nawierzchni przy wykorzystaniu metod fotorejestracji [20] [25] wymaga stosowania relatywnie szerokiego horyzontu zabiegów numerycznych, które stanowią podstawę do rozstrzygnięcia o rodzaju czy stopniu szkodli-

wości uszkodzenia na podstawie obrazu cyfrowego powierzchni jezdni. W zautomatyzowanej procedurze identyfikacji uszkodzeń nawierzchni należy się liczyć z grupą wątpliwych przypadków, które będą wymagać dodatkowych informacji. Identyfikacja makrotekstury dostarczy zmiennych do algorytmu, który może być wykorzystany do podjęcia decyzji o granicach łat, czy zmianie rodzaju warstwy ścieralnej. Pomocne przy tych zagadnieniach są doświadczenia opisane w pracy [7], które wskazują na udany eksperyment, gdzie potwierdziła się dobra korelacja między parametrem makrotekstury oznaczonym metodą fotografii stereoskopowych, a badaniami nawierzchni w terenie. Metodę identyfikacji wybojów opisano w pracy [12]. Podział fotografowanego obszaru powierzchni jezdni na te z uszkodzeniami i bez, okazał się bardzo skuteczny w połączeniu z grupą przekształceń geometrycznych i morfologicznych obrazu. Testy przedstawione w pracy [14] wykazały, że w przypadku identyfikacji wybojów najlepsza techniką jest transformata *curvelet*. Transformacja *ridgelet* dominuje w zadaniu wykrywania spękań na obrazie cyfrowym, a metoda transformacji falkowej okazała się najmniej efektywna. Najbardziej powszechne aktualnie podstawy wizualnej inwentaryzacji w Polsce zebrane zostały w opracowaniach [21][22]. Rozwój technik obliczeniowych analizowany chociażby w oparciu o prace [3], [11], [15], [17], [19], [23] pozwala przypuszczać, że standardowe techniki wizualnej inwentaryzacji zostaną wyparte na rzecz rozwoju automatycznych procedur identyfikacji. Potwierdzona zgodność między wynikami standardowo przeprowadzonej wizualnej inwentaryzacji, a wynikami zautomatyzowanych procedur technik fotorejestracji [2], [1] [4] utwierdza tylko w przekonaniu, że tempo tych zmian będzie zależeć głównie od tempa wypracowania systematycznych procedur zautomatyzowanej inwentaryzacji.

Wizualna inwentaryzacja uszkodzeń nawierzchni jezdni

Przykład szczegółowych zasad wizualnej inwentaryzacji można znaleźć między innymi w pracach [21], [22] (wytyczne SOSN). Podstawą metody jest ocena punktowa dla odcinków o długości 100 m wyrażona wzorem (1).

$$P_{ij} = a \cdot \left(\frac{X}{b}\right)^c \cdot f \quad (1)$$

w którym:

P_{ij} – liczba punktów dla uszkodzenia „i” przy stopniu szkodliwości „j”, X – zakres uszkodzeń (m, m²), a, b, c – współczynniki punktacji uszkodzeń, f – współczynnik natężenia ruchu.

Klasyfikację stanu technicznego według tych dokumentów dokonuje się w oparciu o dwa wskaźniki. Pierwszy to wskaźnik stanu spękań, a drugi to wskaźnik stanu powierzchni (2).
Wskaźnik stanu spękań Wskaźnik stanu powierzchni

$$n = \max\left(1 - \frac{P1}{100,0}\right) \quad n = \max\left(1 - \frac{P2}{100,0}\right) \quad (2)$$

w których:

$P1 = 0,9 \cdot P_{ij,\max}^n + 0,1 \cdot P_{ij}^n$ – liczba punktów przy założeniu, że brane są pod uwagę wyłącznie spękania siatkowe, pojedyncze, łaty i wyboje,


$P2 = 0,9 \cdot P_{ij,\max}^p + 0,1 \cdot P_{ij}^p$ – brane są pod uwagę tylko uszkodzenia w postaci łat, wybojów, ubytków ziaren i lepiszcza.

Warunki brzegowe

Przy założeniu, że do dyspozycji jest zasób zdjęć ortogonalnych nawierzchni jezdni zgromadzony w ramach prac [13], użytkownik otrzymuje zbiór obrazów cyfrowych o wymiarach 1500 × 1080 pikseli i rozdzielczości 96 ppi (*pixels per inch*). Biorąc pod uwagę geometryczną charakterystykę wykorzystanego w pracy [13] systemu fotorejestracji, pojedynczy piksel obejmuje powierzchnię jezdni o wymiarach 1,5 × 1,5 mm. Jednak prawidłowo zarejestrowany obraz ortogonalny powierzchni jezdni w warunkach rzeczywistych, który można jednoznacznie skwantyfikować, musi być wsparty szeregiem warunków brzegowych. Można wyróżnić kilka przypadków, które


należy wziąć pod uwagę pracując nad automatyzacją procedur analizy ortogonalnych obrazów cyfrowych:

- w przypadku obrazów ortogonalnych nawierzchni należy dążyć do korzystania z urządzeń, które rejestrują obraz w warunkach sztucznego oświetlenia,
- w przypadku, gdy zachodzi konieczność rozróżnienia łąty od np. powierzchni wilgotnej, można wykorzystać algorytmy wykrywania krawędzi. Krawędzie łąt w większości dadzą się opisać regularną figurą geometryczną, przez co zastosowanie np. metody *Canny*'ego do wykrycia krawędzi w obu przypadkach wskaże jednoznacznie odpowiedź (fot. 1.)



Fot. 1. Przykład działania algorytmu do wykrywania krawędzi w przypadku obrazu, a) ze śladem od mokrej powierzchni jezdni, b) z łątą

- z uwagi na różne rodzaje uszkodzeń przypisane do poszczególnych nawierzchni, weryfikację materiału wykorzystanego do warstw ścieralnych (dla dróg krajowych / wojewódzkich / powiatowych / gminnych o nawierzchni twardej ulepszonej będą to w większości warstwy ścieralne wykonane z: mieszanek mineralno-asfaltowych, betonów cementowych oraz kostki betonowej ścieralnej, fot. 2.), można przeprowadzić w oparciu o jedną z szeroko opisywanych w literaturze technik analizy makrotekstury na obrazach cyfrowych
- zjawisko wypływania asfaltu na powierzchnię jezdni, tzw. „pocenie się nawierzchni” może skutecznie zakłócić wyniki analiz ilościowych, dlatego również w takim przypadku należy się liczyć z koniecznością adaptacji jednej z technik analizy makrotekstury.



Fot. 2. Przykłady wzorcowych tekstur powierzchni warstw ścieralnych, a) beton asfaltowy, b) beton cementowy, c) kostka betonowa

Podstawy struktury sztucznych sieci neuronowych wybranej do identyfikacji uszkodzeń nawierzchni


Spośród dostępnej, obszernej literatury przystępny opis zagadnień związanych z metodą sztucznych sieci neuronowych (ssn), czytelnik znajdzie w klasycznych już pracach [1] [6] [24]. W artykule, ssn będzie nazywać się w skrócie sieciami neuronowymi, mając za każdym razem na myśli sztuczną sieć neuronową, a nie jej biologiczny wzorzec. Sieci neuronowe tworzą grupę algorytmów numerycznych, które dla pewnego zbioru danych $(x_i, y_i), i = 1 \dots N$, stanowiących argumenty i wartości nieznannej funkcji $y = f(x)$, wykorzystuje się do jej estymacji. Implementację algorytmu opartego na ssn w zadaniu identyfikacji uszkodzeń nawierzchni jezdni, można sprowadzić do trzech podstawowych kroków. Pierwszy oznacza konieczność doboru typu i architektury sieci adekwatnej do danych opisujących modelowane zjawisko. W drugim kroku sieć neuronową poddaje się procesowi nauki. Trzeci krok to testowanie i weryfikacja wyuczonej sieci na dodatkowych danych z tego samego źródła (np. dane wygenerowane numerycznie) bądź innych źródeł (np. dane z eksperymentu). W artykule skierowano przede wszystkim uwagę na rozwiązania, które mają zastosowanie w zadaniach klasyfikacyjnych.

Punktem wyjścia dla złożonych struktur ssn jest konstrukcja pojedynczego neuronu (rys. 1), wewnątrz którego przeprowadzane są proste wyrażenie algebraiczne w postaci (3).

$$a = f(n) = \left(\sum_{i=1}^N w_i p_i + b \right) \quad (3)$$

w której:


a – wartość perceptronu, f – funkcja aktywacji, p_i – skalar na wejściu, w_i – waga, b – składowa stała (bias), N – liczba parametrów na wejściu.



Rys. 1. Podstawowa struktura ssn, a) neuron, b) sztuczny neuron [4]

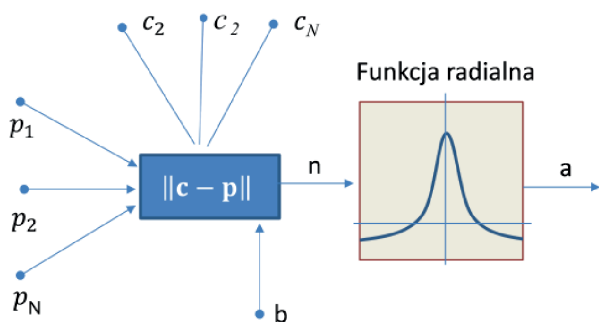
Właściwościami pojedynczych neuronów steruje się poprzez selekcję funkcji aktywacji. Stosując skokową funkcję (rys. 2.) otrzymuje się typowy model tzw. perceptronu, a wykorzystanie funkcji liniowej prowadzi do cech filtra, dlatego często w literaturze strukturę taką nazywa się liniowym filtrem adaptacyjnym (*Adaline*).

Znając zasadę formuły obliczeniowej dla sztucznego neuronu, można budo-



Rys. 2. Powszechnie stosowane funkcje aktywacji f a) skokowa, b) liniowa, c) nieliniowa

wać złożone struktury ssn poprzez zmienny dobór liczby parametrów na wejściu, liczby neuronów, kształtu funkcji aktywacji, wprowadzenie parametru czasu czy czynnika rekurencji. Takie uogólnienia prowadzą do struktur sieci wielowarstwowych, dla których zbudowano również wiele algorytmów do ich trenowania (algorytm propagacji wstecznej, *Lavenberga-Marquardta*, itp.). Ważną grupą sieci, które można wykorzystywać do zadań klasyfikacji to sztuczne sieci oparte o funkcje radialne (*Radial Basis Function Neural Networks – /RBFNN/*). Schemat pojedynczego neuronu można przedstawić jak na rysunku 3, a jego wartość wyraża się wzorem (4).



Rys. 3. Model neuronu sieci z radialną funkcją aktywacji (radbas)

$$a = \text{radbas}(n) = e^{-n^2} = e^{-b^2 \|c-p\|^2} \quad (4)$$

w którym:

c – wektor wartości wag (tzw. wartości centrum funkcji radialnej), p – parametry wejściowe sieci.

W większości zastosowań [5] do budowy sieci *RBFNN* wykorzystuje się specjalny element liniowy. To prowadzi bezpośrednio do postaci sztucznej sieci neuronowej uogól-

nionej regresji (*Generalized Regression Neural Network – /GRNN/*). Jako funkcje radialne w tego typu sieciach często wykorzystuje się funkcje Gaussa, które mają dodatkowy parametr zwany *spread* – rozpiętość funkcji radialnej. Oprócz parametru rozpiętości w sieciach *GRNN* należy jeszcze ustalić położenie funkcji radialnych, ich ilość oraz obliczyć wagi na warstwie wyjściowej. Najczęściej ilość funkcji radialnych równa jest ilości wzorców uczących a ich osie symetrii pokrywają się z położeniem każdego wzorca uczącego w przestrzeni parametrów. Poprzez zastosowanie liniowych funkcji aktywacji w warstwie wyjściowej proces uczenia takich sieci sprowadzony jest do rozwiązania prostego systemu równań liniowych.


Do zadań identyfikacji uszkodzeń nawierzchni jezdni wykorzystano zbiory uczące o dużej liczebności (kilkaset tysięcy zdjęć ortogonalnych nawierzchni). Dodatkowo wiele przykładów różnych zastosowań [8] [9] dowodzi, że sieć neuronowa z wykorzystaniem funkcji radialnych Gaussa jest niezawodna w obszarze estymacji wieloparametrycznej funkcji. Ostatecznie podjęto decyzję, że w opisanym tu hybrydowym systemie identyfikacji uszkodzeń nawierzchni wykorzystana zostanie sieć *GRNN*.

Numeryczne aspekty identyfikacji i klasyfikacji uszkodzeń nawierzchni

Identyfikacja uszkodzeń, przy założeniu zautomatyzowanych procedur obliczeniowych jest możliwa poprzez zastosowanie opisu matematycznego związanego w znacznej mierze z dziedziną przekształceń morfologicznych.

Identyfikacja uszkodzeń


Przy korzystaniu z możliwości ssn kluczową rolę pełnią zbiory treningowe, które w kontekście zastosowań w drogownictwie zostały częściowo opisane między innymi w pracy [16]. W zadaniu identyfikacji obiektów utrwalonych na obrazie cyfrowym, każdy z nich musi być w sposób miarodajny reprezentowany w zbiorze uczącym sieci neuronowej. Przy założeniu, że wzorce mają postać obrazu binarnego, identyfikację uszkodzeń w oparciu o obraz fragmentu powierzchni jezdni zarejestrowany np. w modelu RGB należy poprzedzić serią przekształceń, które w sposób systematyczny zostały omówione w pracach [17][19]. Możliwą ścieżkę zadań umożliwiających praktyczną realizację tych zagadnień przedstawiono na rysunku 4.



Rys. 4. Elementy ścieżki binaryzacji obrazu pierwotnego: a) obraz pierwotny (wejściowy), b) efekt przekształceń morfologicznych, c) skutek przekształceń algebraicznych, d) rezultat przekształceń geometrycznych e) wynikowy obraz binarny (do porównywania z wzorcem ssn)

Generowanie wzorców i klasyfikacja uszkodzeń

Rola wyuczonej ssn w prezentowanych obszarach sprowadza się właściwie do typowego zadania klasyfikacyjnego. W pracy wykorzystano klasyfikację uszkodzeń nawierzchni jezdni zainspirowaną częściowo podziałem wprowadzonym w wytycznych SOSN [21][22]. Poszczególne rodzaje uszkodzeń przypisano do 5 klas wzorcowych, a ich postać binarną zestawiono na rysunku 5. Klasy wzorców pogrupowano według zasady: Klasa I – spękania poprzeczne, Klasa II – spękania podłużne, Klasa III – spękania siatkowe, Klasa IV – łaty, Klasa V – wyboje / ubytki / wykruszenia.



Rys. 5. Przykładowe wzorce uszkodzeń dla klas na potrzeby zbiorów uczących ssn


Parametry wzorców przedstawionych na rysunku 5 zestawiono w tabeli 1.

Tabela 1. Przykładowe wartości numerycznych parametrów wzorców

Klasa	I	II	III	IV	V
Maksymalna liczba pikseli w linii pionowej	2	9	33	74	41
Maksymalna liczba pikseli w linii poziomej	17	2	41	59	45
Pole powierzchni uszkodzenia [piksel]	200	120	1435	3711	1863
Szerokość uszkodzenia [piksel]	100	49	100	70	65
Długość uszkodzenia [piksel]	22	60	100	81	66
Odchylenie standardowe liczby pikseli w liniach pionowych, [-]	0,00	1,79	4,84	28,38	16,41
Odchylenie standardowe liczby pikseli w liniach poziomych, [-]	4,53	0,98	9,13	19,07	17,29

Próba usystematyzowania kroków niezbędnych do przeprowadzenia pełnej identyfikacji uszkodzeń wraz z klasyfikacją przedstawia się następująco:

- wczytanie ortogonalnego obrazu cyfrowego nawierzchni do aplikacji komputerowej,
- rozpoznanie krawędzi i obiektów na wczytanym zdjęciu, poprzez zastosowanie operacji algebraicznych, geometrycznych oraz morfologicznych [17] [19] wraz z podziałem na podobszary robocze (rys. 6a),
- wygładzenie i redukcja szumów na otrzymanych obrazach wynikowych,
- binaryzacja obrazu i ponowne wykorzystanie filtrów wygładzających,
- podział obrazu binarnego na podobszary robocze (rys. 6b),
- analiza właściwości wyselekcjonowanych podobszarów (tabela 1),



Rys. 6. Podział obrazu cyfrowego na podobszary robocze, a) obraz pierwotny (wejściowy), b) obraz binarny

- klasyfikacja uszkodzenia z wykorzystaniem sztucznej sieci neuronowej typu GRNN,
- wyznaczenie wskaźnika stanu nawierzchni jezdni DI (w zależności o potrzeb mogą to być również wskaźniki stanu spękań lub stanu powierzchni wprowadzone w wytycznych SOSN [21][22]).

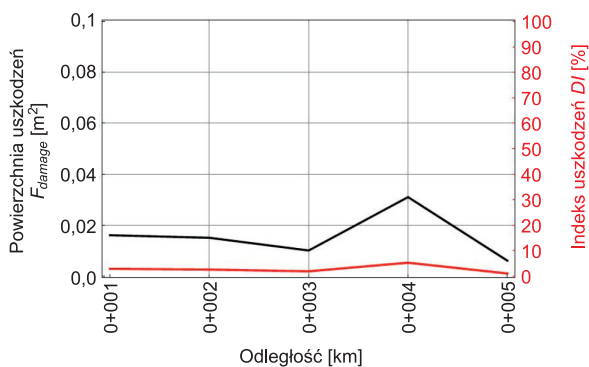

Ocena stanu nawierzchni odcinka drogi w oparciu o serię ortogonalnych obrazów powierzchni jezdni o nawierzchni bitumicznej (przykłady)

Zakłada się, że dla zachowania w tej pracy równowagi pomiędzy czytelnością, a prezentacją funkcjonalności rozwiązania, ocena dotyczy nawierzchni jezdni o długości 10 m (w ogólnym przypadku mamy ocenę dla każdego fotografowanego obszaru powierzchni jezdni). Zakłada się również, że ocenie podlega wyłącznie obraz o szerokości 90 cm, obejmujący umowny obszar śladu lewego koła. Takie teoretyczne podejście do identyfikacji uszkodzeń wyklucza szereg dodatkowych zadań, których opis wykracza poza ramy tego artykułu. Należy tu jednocześnie podkreślić, że w pełni praktyczna ocena stanu technicznego nawierzchni (taka, która da się porównać np. do wyników wizualnej inwentaryzacji realizowanej zgodnie z wytycznymi SOSN) wymaga dostosowania parametrów obszaru objętego fotorejestracją do wymagań ujętych w wytycznych SOSN, co w porównaniu do prezentowanej metody sprowadza się do kilku dodatkowych zabiegów technicznych (przycięcie, lokalizacja, selekcja itp.), które w tym artykule pominięto. W zamian, wykorzystano indeks uszkodzeń obowiązujący tylko dla analizowanego wycinka pasa ruchu. Zakres uszkodzenia analizowanego odcinka wyrażono wielkością zdefiniowaną w postaci wzoru (5).

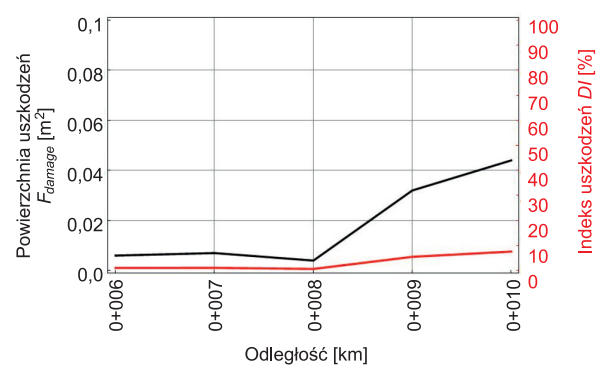
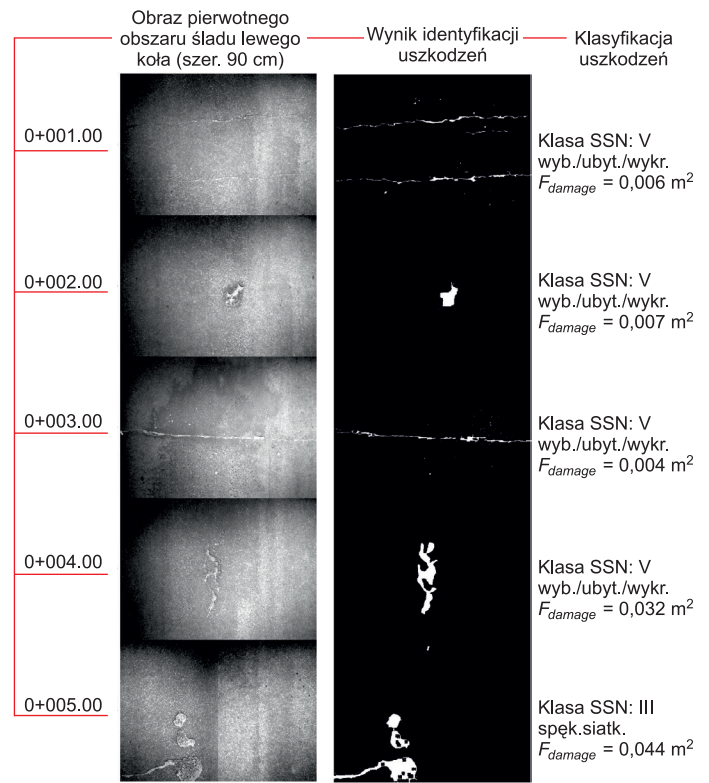
$$DI_{90L} = 100 \times \frac{F_{damage}}{F_{image}} [\%] \quad (5)$$

w którym:

DI_{90L} – umowny indeks uszkodzeń na umownej szerokości pasa ruchu o szerokości 90 cm w obszarze śladu lewego koła, F_{damage} – pole powierzchni spękań / wybojów / ubytków / wykruszeń [m^2], F_{image} – pole powierzchni jezdni objęte obrazem cyfrowym [m^2].



Rys. 7. Ilustracja umownych wartości uszkodzeń dla odcinka o długości 5 m (przykład 1.)



Rys. 8. Ilustracja umownych wartości uszkodzeń dla odcinka o długości 5 m (przykład 2.)

Dyskusja

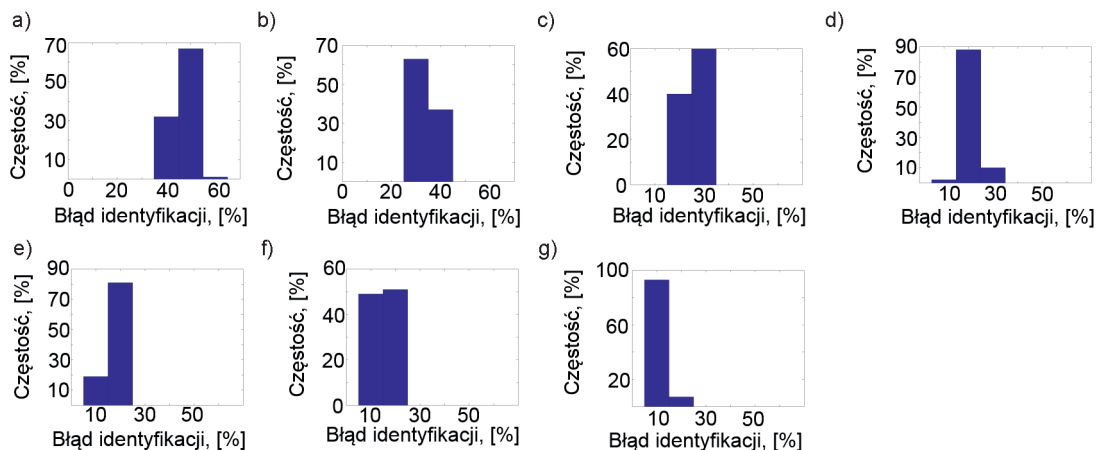
W przedstawionym eksperymencie wykorzystano obrazy cyfrowe fragmentów powierzchni jezdni wykonane w ramach prac [13]. Wykorzystany mobilny system pomiarowy łączący funkcje zapisu współrzędnych GPS i możliwości fotorejestracji ortogonalnych obrazów nawierzchni jezdni [18], pozwolił na testowanie algorytmów działających w oparciu o technikę sieci neuronowych i przekształceń morfologicznych. Skuteczność klasyfikacji uszkodzeń (rysunki 7 i 8) przeanalizowano pod kątem minimalnej liczby wzorców uszkodzeń w zbiorze treningowym ssn. Uwzględniono 7 przypadków, włączając kolejno w proces nauki sieci neuronowej (20, 50, 100, 200, 500, 1000, 2000) x 5 klas wzorców uczących. Poprzez błędną klasyfikację rozumie się przypadek niewłaściwego przypisania uszkodzenia z obrazu binarnego do danej klasy (przyjętej zgodnie z rysunkiem 6). Proces klasyfikacji uszkodzeń powtarzano wielokrotnie (150 razy). Tym sposobem ocenę skuteczności klasyfikacji metodą ssn sprowadzo-

no do analizy histogramów zbioru wartości błędnej bądź poprawnej klasyfikacji (umowny błąd identyfikacji klas). W zależności od liczby wzorców umowny błąd identyfikacji klasy uszkodzenia przedstawiono na rysunku 9.

Z histogramów zaprezentowanych na rysunku 9 wynika, że przy zbiorze liczącym 2000 wariantów 5-elementowych zbiorów z wzorcami uszkodzeń w sieci GRNN, ponad 95% przypadków identyfikacji uszkodzeń uznano na prawidłową. Przyjmując powszechnie akceptowane standardy inżynierskiego zakresu niepewności uzyskany wynik należy uznać za satysfakcjonujący.

Podsumowanie

Prezentowaną w pracy metodę przetestowano na obrazach cyfrowych wykonanych w ramach pomiarów na sieci ulic w mieście. Zbiór kilku tysięcy ortogonalnych obrazów powierzchni jezdni pozwolił na testowanie wielu wariantów zdarzających się w praktyce. W przekonaniu autorów przed-



Rys. 9. Histogramy błędu identyfikacji uszkodzeń dla różnej ilości wzorców uczących, a) 20×5 klas, b) 50×5 klas, c) 100×5 klas, d) 200×5 klas, e) 500×5 klas, f) 1000×5 klas, g) 2000×5 klas

stawione w artykule podejście, to duży krok w kierunku poprawy jakości w systemach zarządzania nawierzchniami. Stały dopływ informacji w ramach zautomatyzowanej procedury wizualnej inwentaryzacji stanu technicznego nawierzchni jezdni w zasobach baz danych pozwoli określić nie tylko „statyczną informację”, ale wprowadzony czynnik czasu pozwoli na określanie dynamiki zmian stanu technicznego nawierzchni, przez co reakcja służb technicznych może być bardziej skuteczna zarówno w doborze zabiegów utrzymaniowych, jak i kształtowaniu samej polityki utrzymaniowej.

Wykorzystanie „geometrycznie” nieskomplikowanych sieci neuronowych typu GRNN pozwala na szybką i poprawną klasyfikację uszkodzeń w oparciu o wyuczony system. Do poprawnego działania procedury klasyfikacji potrzebne są dwa główne składniki: (a) możliwie duży i różnorodny zbiór uczący oraz (b) efektywny i niezawodny system binaryzacji zbiorów uczących. W celu poprawy skuteczności klasyfikacji sztucznych sieci można „douceć” sieć, wykorzystując dodatkowe parametry geometryczne wzorców lub włączając do procesu uczenia dodatkowe (trudne do zidentyfikowania) wzorce. Alternatywną metodą wykazującą dużą skuteczność w zagadnieniach klasyfikacji jest technika oparta na algorytmach wykorzystujących procesy Gaussa [10], która oprócz sklasyfikowania danego uszkodzenia określa również stopień pewności (lub niepewności) dokonanego wyboru.

Bibliografia

- [1] C.M. Bishop, *Neural Networks for pattern recognition*, Oxford University Press, Oxford 1995.
- [2] R. Birken, G. Schirner, M. Wang, *VOTERS: Design of a Mobile Multi-Modal Multi-Sensor System*, SensorKDD'12 Proceedings of the Sixth International Workshop on Knowledge Discovery from Sensor Data, 2012.
- [3] S.A. Chien, H.B. Mortensen, *Automating Image Processing for Scientific Data Analysis of a Large Image Database*, IEEE Transactions On Pattern Analysis And Machine Intelligence, Vol. 18, No. 8, 1996.
- [4] G.D. Cline, M.Y. Shahin, J.A. Burkhalter, *Automated Data Collection For Pavement Condition Index Survey*, http://www.ltrc.lsu.edu/TRB_82/TRB2003-000175.pdf
- [5] H. Demuth, M. Beale, *Neural Network Toolbox For Use with Matlab, User's Guide, Version 3*
- [6] R.O. Duda, P.E. Hart, D.G. Stork, *Pattern classification*, 2nd ed, John Wiley & Sons, New York 2001.

- [7] A.E. Gendy, A. Shalaby, M. Saleh, W. Flintsch, *Stereo-vision applications to reconstruct the 3D texture of pavement surface*, International Journal of Pavement Engineering, Vol. 12, No. 3, 2011.
- [8] T. Garbowski, G. Maier, G. Novati, *On calibration of orthotropic elastic-plastic constitutive models for paper foils by biaxial tests and inverse analyses*, Structural and Multidisciplinary Optimization, Vol.46 (1), pp. 111-128, 2012
- [9] T. Garbowski, G. Maier, G. Novati, *Diagnosis of concrete dams by flat-jack tests and inverse analyses based on proper orthogonal decomposition*, Journal of Mechanics of Materials and Structures, Vol. 6 (1-4), pp. 181-202, 2011
- [10] T. Garbowski, *Stochastic model reduction applied to inverse analysis*. Proceedings of the VI International Conference on Adaptive Modeling and Simulation ADMOS 2013, Eds. J.P. Moitinho de Almeida, P. Díez, C. Tiago, N. Parés, CIMNE Barcelona, pp. 291-300, 2013
- [11] A. Knitter-Piatkowska, T. Garbowski, A. Garstecki, *Damage Detection through wavelet transform and inverse analysis*, 8th European Solid Mechanics Conference ESMC2012, Graz, Austria, July 9-13, 2012
- [12] C. Koch, I. Brilakis, *Pothole detection in asphalt pavement images*, Advanced Engineering Informatics, No. 25, 2011.
- [13] Lehman + Partner, *Obrazy powierzchni jezdni dla wybranych odcinków ulic w Poznaniu*, Poznań 2009.
- [14] F.M. Nejad, H. Zakeri, *A comparison of multi-resolution methods for detection and isolation of pavement distress*, Expert Systems with Applications, No. 38, 2011.
- [15] F.M. Nejad, H. Zakeri, *An expert system based on wavelet transform and radon neural network for pavement distress classification*, Expert Systems with Applications, No. 38, 2011.
- [16] A. Pożarycki, *Identyfikacja liczby i grubości warstw modelu nowej nawierzchni odcinka próbnego metodami sztucznej inteligencji*, Drogi i Mosty nr 2, Warszawa
- [17] A. Pożarycki, P. Rydzewski, *Cyfrowe przetwarzanie makroskopowych obrazów jezdni drogowych*, Drogi i Mosty – Roads And Bridges No. 11, 2012.
- [18] A. Pożarycki, P. Rydzewski, *Elementy przekształceń obrazów cyfrowych w bazach danych systemów zarządzania nawierzchniami bitumicznymi*, Zeszyty Naukowe Politechniki Rzeszowskiej, Nr 283, 2012.
- [19] A. Pożarycki, P. Rydzewski, *Przekształcenia obrazów cyfrowych w drogownictwie*, Drogownictwo, Nr 6, 2012.
- [20] M. Staniek, *Diagnostyka nawierzchni drogowej z wykorzystaniem pomiarów stereoskopowych*, Zeszyty Naukowe Politechniki Rzeszowskiej, Nr 283, 2012.
- [21] System Oceny Stanu Nawierzchni SOSN, Wytyczne stosowania – Załącznik A, Zasady ciągłego obmiaru uszkodzeń i oceny stanu nawierzchni bitumicznych metodą oceny wizualnej w systemie oceny stanu nawierzchni SOSN, GDDP, Warszawa, 2002.
- [22] System Oceny Stanu Nawierzchni SOSN, Wytyczne stosowania – Załącznik E, Katalog typowych uszkodzeń nawierzchni bitumicznych dla potrzeb ciągłego obmiaru uszkodzeń metodą oceny wizualnej w systemie oceny stanu nawierzchni SOSN, GDDP, Warszawa, 2002.
- [23] D.H. Tim, J.M. McQueen, *A study of manual vs. automated pavement condition surveys*, Highway Research Center, Auburn University, Alabama, April 2004.
- [24] R. Tadeusiewicz, *Sieci neuronowe*, Wyd. 2, Warszawa, Akademicka Oficyna Wydaw. RM, 1993.
- [25] K.C.P. Wang, O. Smadi, *Automated Imaging Technologies for Pavement Distress Surveys*, Transportation Research Circular, No. E-C156, 2011. ■