

Kwalifikacja zapisów B-scan z ultradźwiękowej badania szyn kolejowych za pomocą modelu wytrenowanego w trybie głębokiego uczenia

Streszczenie. Artykuł przedstawia konstrukcję, trening i wykorzystanie adaptacyjnego modelu klasyfikacyjnego do eliminacji pozornych wad z zapisów badań ultradźwiękowych szyn kolejowych. Model został zbudowany na bazie wieloletniego archiwum nieprzetworzonych wyników pomiarów diagnostycznych szyn, wzbogaconych o werdykty kwalifikacyjne doświadczonych analityków. Model w postaci wielowarstwowej rekurencyjnej sieci neuronowej wykazuje sprawność kwalifikacyjną porównywalną z wynikami analityków.

Abstract. The paper presents construction, training and application of a classification model for elimination of false defects in the diagnostic ultrasound railway testing results. The model has been built based on measurement data collected for many years. Raw measurement results appended with classification by experienced personnel are used for model training. The resulting system reveals classification accuracy no worse than human verdict. (*Automatic qualification of B-scan traces of ultrasound railway diagnostic measurements by means of a deep learning model*).

Słowa kluczowe: badania nieniszczące, metody ultradźwiękowe, diagnostyka szyn, głębokie uczenie.

Keywords: non-destructive testing, ultrasound, railway diagnostic, deep learning.

Wstęp

Na naszych oczach postępuje gwałtowna transformacja form operacyjnych w tradycyjnych segmentach gospodarki. Nawet dość nowatorskie metody przetwarzania komputerowego znajdują szybką ścieżkę aplikacji w działaniach, które w obrębie swojej domeny były kształtowane przez lata. Niniejszy artykuł przedstawia rezultaty ewaluacji tego rodzaju fuzji – zastosowania relatywnie nowoczesnej metody uczenia maszynowego, klasyfikacji sekwencji czasowych przy użyciu rekurencyjnych „głębokich” sieci neuronowych typu LSTM do przetwarzania wyników nieniszczącej, ultradźwiękowej diagnostyki szyn kolejowych.

Badanie ultradźwiękowe szyn (UT, *ang. ultrasound testing*) jest jedną z podstawowych metod wczesnego wykrywania nieciągłości struktury o potencjale przekształcenia się w defekty niebezpieczne dla bezpieczeństwa ruchu. Prowadzone różnymi środkami technicznymi kończą się werdyktem wydawanego przez doświadczonego operatora. Dzięki relatywnie wczesnemu wdrożeniu półautomatycznych metod ultradźwiękowej diagnostyki, Centrum Diagnostyki PKP PLK dysponuje bogatym archiwum wyników badań, uzupełnionych o ekspercką kwalifikację poszczególnych rozpoznanych defektów rzeczywistych i pozornych. Stanowi to bardzo dobre pole doświadczalne dla metod uczenia maszynowego, bazujących na dużych zbiorach danych.

W artykule przedstawiona jest ewaluacja zastosowania uczenia maszynowego do skonstruowania automatycznego systemu kwalifikacji defektów zarejestrowanych w trakcie badania UT. Przedstawiona jest w zarysie metodologia badania, przetwarzania i gromadzenia wyników oraz charakterystyka obecnie stosowanego procesu kwalifikowania defektów. Następnie problem kwalifikacji przedstawiony jest w ujęciu właściwym dla zastosowania konkretnych technik uczenia maszynowego, mianowicie jako klasyfikacja sekwencji czasowej. Opisany jest nowoczesny model, typowo stosowany w takich zagadnieniach - dwukierunkowa rekurencyjna sieć neuronowa (RNN) z węzłami typu LSTM. Finalną częścią artykułu jest przedstawienie procesu ewaluacji zastosowania sieci LSTM RNN do zbudowania modelu klasyfikacyjnego defektów zarejestrowanych w badaniu UT na podstawie części zbioru danych zgromadzonego przez

Centrum Diagnostyki. Przedstawione rezultaty świadczą o dobrej perspektywie opisanej metody.

Badanie ultradźwiękowe szyn kolejowych

Nieniszcząca diagnostyka szyn kolejowych metodami ultradźwiękowymi przy użyciu specjalizowanego wagonu defektoskopowego, dokonującego pomiarów w trakcie jazdy z prędkością 60km/h jest prowadzona przez Centrum Diagnostyki PKP PLK S.A. od końca lat 80-tych. Obecnie eksploatowana, czwarta generacja systemu pomiarowego umożliwiała badanie każdego toku szynowego przy użyciu dziewięciu niezależnych kanałów ultradźwiękowych o różnych strefach penetracji szyny przez wiązkę fali mechanicznej o częstotliwości od 2 do 5MHz.

Zasadą detekcji jest odbicie się wiązki od reflektora tworzonego przez defekt wewnętrzny. Emiterem i odbiornikiem fali jest przetwornik piezoelektryczny (dwukierunkowy konwerter między odkształceniem mechanicznym a sygnałem elektrycznym). Gdy w szynie występuje defekt, wiązka wyemitowana przez przetwornik odbija się od nieciągłości materiału i wraca do przetwornika, wytwarzając sygnał elektryczny, tzw. echo. Zapis czasowy sygnału z przetwornika to tzw. A-skan. Po obróbce przez obwoły i algorytmy przetwarzania sygnału wykryte echa rejestrowane są w strumieniu danych wyjściowych jako wynikowe rekordy danych pomiarowych. W wyniku przemieszczania się zespołu przetworników wzdłuż szyny w trakcie ruchu pojazdu diagnostycznego tworzy się sekwencja rekordów pomiarowych. Jej wizualizacja to tzw. B-skan. Odpowiedni dobór liczby i kierunkowości wiązek ultradźwiękowych pozwala na detekcję pełnego wachlarza defektów wewnętrznych występujących w szynach kolejowych (ref. [katalog UIC]). W trakcie jazdy z pełną prędkością, kanały są wyzwalone z częstotliwością ok. 6kHz, zapewniając krok pomiarowy rzędu 3mm. Ponieważ defekty zwykle mają rozmiary większe niż 3mm a dodatkowo, wiązka fali ultradźwiękowej ma stożkowy, dywergentny profil, pojedynczy defekt tworzy z reguły na B-skanie rozciągnięty ślad - sekwencję pomiarów.

Kwalifikacja obrazów B-skan

Zasadniczym praktycznym problemem ultradźwiękowej metody diagnostycznej w realizacji szybkiego pojazdu diagnostycznego jest trudność w utrzymaniu odpowiedniej

jakości sprzężenia akustycznego głowic z szyną, wynikająca ze stanu nawierzchni szyny, deformacji i zużycia profilowego, a także dynamiki prowadzenia głowic. W rezultacie przebiegi pomiarowe są obciążone licznymi zaburzeniami, takimi jak duży poziom szumu akustycznego, liczne chwilowe utraty sprzężenia, stałe echa od zużycia profilowego szyny i tym podobne. W wyniku tego bardzo duża liczba śladów widocznych na B-skanie to defekty pozorne. Część z nich daje się łatwo usunąć w procesie automatycznej obróbki danych. Są to przede wszystkim izolowane pozorne echa, powstające w wyniku zakłóceń elektromagnetycznych czy też szumu strukturalnego szyn.

Oprogramowanie analizy wyników stosowane na pojeździe diagnostycznym przeprowadza wstępne uciążenie śladów defektów za pomocą algorytmu klasteryzacji metodą rozrostu ziarna, posługując się rozmytą definicją ciągłości. Algorytm jest sparametryzowany i stosowany z ustawieniami zapewniającymi bezpieczną eliminację dużej części zakłóceń, bez zagrożenia usunięcia śladów rzeczywistych defektów. Ta faza zapewnia wielokrotną redukcję zbioru wyników.

Dalsza obróbka należy do człowieka. Doświadczony operator przegląda przefiltrowaną listę defektów i usuwa charakterystyczne ślady defektów pozornych, bazując na swoim doświadczeniu, wiedzy o warunkach pomiaru, wspomagając się ewentualnie przy tym obrazem szyn z równoległe prowadzonej wideoinspekcji. Przykładami defektów odrzucanych są sekwencje stałych ech odbicia od powierzchni bocznej głowki szyny, związane z często występującym, znacznym zużyciem bocznym szyn na łukach linii lub echa otworów technologicznych i złącz łukowych.

Typowy proces analizy wyników z badania ok. 100km linii może trwać nawet 2h i skutkować eliminacją nawet do 90% pozornych defektów. Wynikiem pracy operatora jest raport badania ze znacznie zredukowaną listą defektów, która stanowi podstawę dokładnej weryfikacji w terenie przez lokalne służby utrzymania linii kolejowych. Należy podkreślić, że większość z nich, to defekty klasy O, czyli przeznaczone do obserwacji, tj. cyklicznego kontrolowania rozwoju defektu w ramach czynności utrzymaniowych.

Oprogramowanie pojazdu diagnostycznego zachowuje w pamięci masowej zarówno oryginalny, „surowy” strumień danych pomiarowych, jak i listę defektów po eliminacji defektów pozornych. Zgromadzone w wieloletniej eksploatacji pojazdu diagnostycznego dane stanowią zatem zbiór wyjściowy bardzo dobrze nadający się do skonstruowania automatycznego modelu klasyfikacyjnego identyfikujące pozorne defekty. Dzięki dostępności końcowych werdyktów, można zastosować nadzorowany tryb uczenia z wartościami oczekiwanymi klasyfikacji zbieżnymi z decyzjami operatora.

Klasyfikacja B-skan w ujęciu uczenia maszynowego

Z punktu widzenia uczenia maszynowego, opisywane zagadnienie to binarna klasyfikacja (dychotomia) obiektów, którymi są sekwencje pomiarów tworzące obrazy B-skan. Matematycznie ujęta nadzorowana konstrukcja modelu klasyfikacyjnego to zadanie minimalizacji oczekiwanego ryzyka błędnej klasyfikacji wyrażonego, jako [1][2]:

$$(1) \quad R|f| = \int_{\mathbf{x} \times Y} V(f(\mathbf{x}), y) p(\mathbf{x}, y) d\mathbf{x} dy$$

W powyższym sformułowaniu wektory \mathbf{x} to elementy przestrzeni cech X obejmujące wszystkie możliwe obrazy B-skan. Cechami są poszczególne próbki sekwencji pomiarów tworzących obraz. Ponieważ pojedynczy pomiar jest sam w sobie zbiorem atrybutów zarejestrowanego echa, próbki są również wartościami wektorowymi. Etykiety

klasyfikacyjne y z przestrzeni możliwych etykiet Y , to wartości numeryczne kodujące werdykt. W rozważanym problemie mamy do czynienia z klasyfikacją binarną, zatem Y jest zbiorem dwuwartościowym. Rodzina funkcji $f: X \rightarrow Y$ wynika z zastosowanego modelu klasyfikacyjnego. W opisywanym badaniu użyte zostały sztuczne sieci neuronowe o gruntownie zbadanych właściwościach uniwersalnego klasyfikatora [3][4]. Dystrybucja $p(\mathbf{x}, y)$ opisuje proces generacji danych dla procesu poszukiwania optymalnego klasyfikatora i reprezentuje kluczowy element procesu uczenia – przygotowanie zbioru trenującego. Ekwiwalentnie może zostać zapisana, jako:

$$(2) \quad p(\mathbf{x}, y) = p(y|\mathbf{x})p(\mathbf{x}),$$

reprezentuje więc zarówno ufność co do poprawności etykietowania (werdyktów) pochodzących z procesu generacji danych (pierwszy czynnik w równaniu 2), jak i reprezentatywność zbioru danych dla całej przestrzeni możliwych klasyfikowanych obiektów (drugi czynnik). W opisywanym problemie bardzo zasadne są dociekania dotyczące jakości danych pochodzących z archiwum pomiarów pojazdu diagnostycznego. Werdykty mogą być obciążone pomyłkami (np. obrazy niektórych rzeczywistych defektów mogły zostać przez operatora odrzucone). Natomiast reprezentatywność dostępnego zbioru danych jest zaświadczona jego rozmiarami. Obecnie dostępne są zapisy z ośmioletniego archiwum danych z wynikami badania ok. 20 tys. km linii rocznie. Całkowicie zasadne jest również pytanie o niestacjonarny charakter procesu pomiarowego rok do roku, związany ze zmieniającym się stanem aparatury pomiarowej, praktyką pomiarową lub profilem obciążenia infrastruktury kolejowej, a co za tym idzie, dystrybucją defektów. W opisywanym badaniu tego rodzaju pytania nie są eksploatowane. Zbiór danych uznany jest za reprezentatywny, a werdykty operatora za poprawne.

Oczywiście faktyczna realizacja procesu uczenia jest dyskretną wersją przepisu podanego w równaniu (1), gdzie całkowanie jest przybliżone sumą po dostępnym zbiorze trenującym.

Funkcja kosztu błędnej klasyfikacji $V(f(\mathbf{x}), y)$ dyktuje dynamikę procesu poszukiwania optymalnego klasyfikatora. Może zawierać składniki regularyzacyjne, promujące rozwiązania o pożądanych cechach wynikające z wiedzy a priori. Np. w opisywanym problemie może być zastosowana asekuracyjnie funkcja wzmacniająca udział w klasyfikacji tzw. *false positives*, czyli etykietowanie niektórych defektów pozornych jako rzeczywiste. W opisywanym badaniu zastosowana została jedna ze standardowych funkcji kosztu, mianowicie binarna krossentropia:


$$(3) \quad H_p(q) = -\frac{1}{N} \sum_{i=1}^N y_i \log(p(y_i)) + (1 - y_i) \log(1 - p(y_i))$$

Klasyfikacja sekwencji czasowych

Obrazy defektów B-skan są ze swej natury sekwencjami czasowymi. Kolejne pomiary powstają w wyniku powtarzania akcji emisji i odbioru fali akustycznej w sukcesywnych, zmiennych interwałach, wynikających z chwilowej prędkości jazdy pomiarowej. Co więcej, za sprawą tego, że wiązka ultradźwiękowa jest rozbieżna, kształt sygnału odbieranego w danym kroku obejmuje scałkowany efekt oddziaływania z częściami reflektora defektu leżącymi przekrojach badanych w pewnej liczbie poprzednich oraz następnych kroków pomiarowych. Między kolejnymi próbkami sygnału tworzącego obraz B-skan istnieją zależności, które nie pozwalają na stosowanie podstawowych modeli takich, jak jednokierunkowe sieci neuronowe, opierających się na założeniu o niezależności

atrybutów. Przetwarzanie sekwencji czasowych realizowane jest za pomocą wielu specyficznych metod, jak choćby ukryte modele Markowa [5], jednak metody te mają swoje ograniczenia w praktyce stosowania, np. rosnący eksponencjalnie koszt stosowania przy próbie modelowania zależności o dużym zasięgu czasowym. W przypadku klasyfikacji defektów w szynach można spodziewać się tego rodzaju zależności. Dość typowo występują długie defekty, związane ze zużyciem mechanicznym lub degradacją korozyjną, występujące lokalnie, ale z relatywnie dużym promieniem zasięgu.

Stosowanie sieci neuronowych do przetwarzania sekwencji czasowych ma długą historię. Pierwotnie używana była technika prezentowania sieci jednokierunkowej sukcesywnych fragmentów sekwencji uzyskiwanych za pomocą przesuwanego okna o ustalonej długości, jednak obecnie dominują w tego typu zastosowaniach struktury zwane rekurencyjnymi sieciami neuronowymi (*RNN*, ang. *Recurrent Neural Networks*). W sieciach takich stosowane są neurony (węzły przetwarzające) z lokalnym sprzężeniem zwrotnym, wprowadzającym uzależnienie wyjścia neuronu nie tylko od bieżących pobudzeń, ale implícite od całej ich historii. W ten sposób model realizowany przez sieć wzbogacany jest o koncept czasu. Sieci RNN wymagają oczywiście specjalnych algorytmów uczenia, takich jak BPTT (ang. *Back Propagation Through Time*). Podczas gdy w jednokierunkowych sieciach jednym z zasadniczych zagadnień doboru modelu jest uzyskanie odpowiedniej generalizacji przez dobór struktury (rozmiaru) sieci – duże sieci mają tendencję do przetrenowania, małe mogą nie mieć odpowiedniej ekspresji - to w przypadku sieci rekurencyjnych dochodzi jeszcze oddziaływanie na efektywny zasięg czasowy modelowanych zależności, objawiające się potrzebą doboru współczynników takich jak czynnik zapominania. Zwiększa to znacznie komplikację zarówno konceptualną jak i obliczeniową stosowania struktur RNN, dlatego ewoluowały one w czasie. Obecnie z dużym powodzeniem stosowane są sieci wykorzystujące węzły LSTM[6] (ang. *Long Term Short Memory*). Struktura takiego węzła przedstawiona jest na rysunku 1.



Rys.1. Struktura węzła przetwarzającego LSTM

Równoległe do zwykłej ścieżki aktywacji (wyjście h_t), węzeł obejmuje też przetwarzania stanu wewnętrznego c_t . Funkcje aktywacji i transformacji stanu wewnętrznego oprócz oczywistej zależności od bieżących pobudzeń x_t , biorą także pod uwagę rekurencyjnie bieżącą aktywację i bieżący stan wewnętrzny. Specyfika struktury LSTM, odzwierciedlona w nazwie, mianowicie potencjał do modelowania zarówno krótkookresowych fluktuacji, jak i długoterminowych trendów jest zrealizowana dzięki dość bogatej strukturze wewnętrznej węzła obejmującej tzw. bramkę zapominania (*FG*), określającą stopniową utratę części stanu wewnętrznego, bramkę wejściową (*IG*), selekcyjującą wpływ pobudzeń zarówno na stan wewnętrzny jak i na aktywację, komponent wzbogacania

stanu wewnętrznego (*SU*) oraz bramkę wyjściową (*OG*), uaktualniającą aktywację. Tego rodzaju struktura potwierdziła swoją skuteczność w wielu problemach przetwarzania sekwencji.

Istotną modyfikacją architektury LSTM jest tzw. sieć dwukierunkowa [7] (ang. *bidirectional LSTM*), w której proces syntezy stanu wewnętrznego w cyklu prezentacji kolejnej próbki sekwencji uwzględnia nie tylko poprzednie próbki („historię”), ale także próbki następne („przyszłość”). Jest to kontraintuicyjne (choć całkowicie realizowalne) w przypadku końcowej eksploatacji modelu ale doskonale zrozumiałe w fazie treningu.

Konstrukcja modelu

Jak nadmieniono w omówieniu równania (1), kluczowym etapem w konstrukcji modelu klasyfikacyjnego jest przygotowanie generatora danych trenujących, a mówiąc bardziej technicznie – przygotowanie zbioru danych do przeprowadzenia treningu modelu w trybie nadzorowanym. W tym celu napisane zostały procedury ekstrakcji z archiwum pojazdu diagnostycznego par trenujących (\mathbf{x}_i, y_i). Sekwencje pomiarów \mathbf{x}_i stanowią opis obrazów B-skan zostały uzyskane z rejestracji pomiarów nieprzetworzonych. Każda próbka takiej sekwencji \mathbf{x}_{ik} jest sama w sobie wektorem komponentów pojedynczego pomiaru i obejmuje: unikalny identyfikator sekwencji nadany przez algorytm rozrostu ziarna, lokalizację pomiaru wzdłuż szyny (z milimetrową dokładnością), głębokość położenia reflektora, który wywołał echo, kanał aparatury, w którym nastąpiła rejestracja, flagę zaniku stałego echa kontrolnego od profilu szyny (świadcząca zazwyczaj o chwilowej utracie sprzężenia akustycznego), amplitudę echa (zazwyczaj świadcząca o rozmiarach reflektora). Komentarza wymaga numer kanału aparatury. Przez cały czas eksploatacji aparatury utrzymywana jest stała konwencja numeracyjna, przypisująca ustalonym numerom przetworniki o ustalonym charakterze wiązki ultradźwiękowej, przeznaczone do wykrywania określonego podzbioru defektów. W związku z tym należy się spodziewać, że atrybut ten może mieć istotny potencjał predykcyjny, jako, że pośrednio koduje typ defektu. Długość sekwencji \mathbf{x}_i jest zmienna i wynika z algorytmu rozrostu ziarna.

Wartości oczekiwanych werdyktów y_i są nadawane w drodze konfrontacji sekwencji ze zbioru „surowego” z sekwencjami po obróbce przez operatora. Te sekwencje które trafiają do zbioru finalnego są opisywane wartością 1 (klasa K1), pozostałe, wartością 0 (klasa K0).

Tak powstały zbiór trenujący obejmuje ok. 1mln sekwencji na jeden rok pomiarów. Należy przy tym podkreślić, że część z sekwencji jest długa, obejmująca kilkaset wektorowych próbek. Problemem tego zbioru jest wielka asymetria obiektów w obu klasach. Udział sekwencji osygnowanych jako rzeczywiste defekty (K1) jest rzędu 2% wszystkich przykładów. Dla takiej asymetrii niezbędna jest jakaś forma symetryzacji procesu trenowania. Możliwymi zabiegami jest dodanie składnika kary w funkcji kosztu $V(f(\mathbf{x}), y)$, penalizującego błędną klasyfikację przykładów klasy K1, zwielokrotnienie ekspozycji przykładów K1 w procesie uczenia, czy też wygenerowanie dodatkowych, sztucznych przykładów K1. Każdy z tych zabiegów odpowiada wprowadzeniu dodatkowego obciążenia indukcyjnego procesu uczenia. W przedstawianym badaniu zdecydowano się na generację nowych przykładów, poprzez wprowadzenie losowych fluktuacji amplitudy i głębokości ech w kopiach istniejących przykładów oraz losowe przedłużanie sekwencji zachowujące ogólną orientację przestrzenną. W odczuciu autorów takie zabiegi są zgodne z aprioryczną wiedzą co do procesu rozrostu

defektów oraz metodologii i charakterystyki ultradźwiękowego procesu diagnostycznego. W wyniku tego zabiegu zbiór danych uczących został zbalansowany do proporcji 40% przykładów klasy K1, 60% klasy K0.

Celem każdego procesu uczenia jest uzyskanie modelu o dobrej generalizacji i osiąga się to rezerwując część danych uczących na tzw. zbiór testowy, wykorzystywany do monitorowania błędów klasyfikacji na danych nie uczestniczących w treningu. W badaniu zastosowano podział w proporcjach 70% danych treningowych, 30% danych testowych.

Trening przeprowadzono przy użyciu biblioteki TensorFlow [8] z nakładką w postaci biblioteki Keras[9]. Oba produkty zrealizowane są jako biblioteki Python (jądro obliczeniowe obejmuje kod natywny). Choć dostępne są bardzo wygodne prekonfigurowane środowiska chmurowe, eksperymenty zostały przeprowadzone na lokalnej instalacji, głównie ze względu na rozmiary danych. Ponieważ API biblioteki Keras zakłada sekwencje o ustalonej długości, przeprowadzony został dodatkowy podział dłuższych sekwencji na unormowane oraz uzupełnienie krótszych sekwencji wartościami neutralnymi. Za pomocą obiektu MinMaxScaler z biblioteki numpy zostały także unormowane zakresy zmiany poszczególnych atrybutów w rekordach pomiarowych. Zasadniczy kod przygotowujący model Bidirectional LSTM do treningu pokazany jest na rysunku 2. Jak widać, zastosowane zostały dwie warstwy z neuronami typu LSTM, przy czym pierwsza z nich – w wariancie dwukierunkowym (50 węzłów). Jako funkcja kosztu została użyta funkcja binarna krosentropy (odpowiednia dla zagadnienia dychotomicznego). Funkcja aktywacyjna zastosowana w warstwie wyjściowej to funkcja logistyczna (z zakresem wartości 0..1).

```

1 model = Sequential()
2 model.add(Bidirectional(LSTM(50, return_sequences=True), \
3 input_shape=(xat.shape[1], 5)))
4 from keras.layers import Bidirectional
5 model.add(LSTM(units=30))
6 model.add(Dense(units=1, activation='sigmoid'))
7 model.compile(loss='binary_crossentropy', \
8 optimizer='adam', metrics=['acc'])

```

Rys.2. Fragment kodu źródłowego ilustrujący przygotowanie modelu do treningu

Proces treningowy obejmował 1000 epok uczenia (1000 cykli przetwarzania kompletnego zbioru treningowego) przy porcji offline (liczbie przykładów po których następuje dostrojenie parametrów modelu) równej 128 próbek. Większy rozmiar porcji offline sprzyja wychwyceniu dłuższych zależności w danych. Zarówno wyniki treningu jak i kontrola na zbiorze testowym ujawniają bardzo dobre perspektywy tego podejścia. Tabela 1 podaje dokładności uzyskane na zbiorze treningowym i testowym, tabela 2 – macierz konfuzji (procent przykładów zaklasyfikowanych błędnie w każdej z klas), wyznaczoną na zbiorze testowym. W macierzy konfuzji widoczny jest pożądaný efekt przewagi fałszywie zaklasyfikowanych pozytywnie przykładów klasy K0 nad fałszywie zaklasyfikowanymi negatywnie przykładami klasy K1. Nie jest to jednak w tym wypadku efekt świadomie zaprojektowany za pomocą dodatkowego obciążenia indukcyjnego.

Tabela 1. Dokładność klasyfikacji na zbiorze treningowym (TRE) i zbiorze testowym (TES)

TRE [%]	TES [%]
95,45	94,34

Tabela 2. Macierz konfuzji wyznaczona na zbiorze testowym

[%]	K0	K1
K0	94,05	5,95
K1	5,23	94,77

Konkluzje

Artykuł podaje rezultaty wstępnych, ewaluacyjnych badań. Wyniki wskazują na duży potencjał obranego sposobu postępowania. Jednak zbudowanie odpornego eksploatacyjnego rozwiązania wymaga dużo więcej wysiłku badawczego. Przede wszystkim dużo więcej zrozumienia wymaga realizacja dystrybucji prawdopodobieństwa danego równaniem (2). W zapisach werdyktów operatorzy są unikalnie identyfikowani. Analiza częstościowa relacji zbiorów danych surowych do zanalizowanych może przynieść pewną wiedzę o rozkładzie prawdopodobieństwa $p(y/x)$. Interesująca może też być zmienność odtwarzanego (ukrytego) modelu klasyfikacji w czasie, tzn. sprawdzanie wydajności modelu skonstruowanego w pewnych latach na danych z innych lat. Perspektywa klasyfikacyjna może też być poszerzona. Werdykty wydawane przez operatorów tworzą więcej klas – defekty rzeczywiste są dzielone na wady do obserwacji i wady do wymiany. W tym artykule świadomie skala problemu została zredukowana do zagadnienia dychotomicznego. Wreszcie możliwy jest cały szereg działań polegających na próbie umiejętnego, uzasadnionego wprowadzenia do procesu uczenia obciążenia indukcyjnego stanowiącego wiedzę a priori, jak np. wspomniane składniki funkcji kosztu nadające priorytet klasie K1 w sensie oddziaływania na proces uczenia oraz przesunięcia punktu równowagi w stronę fałszywych werdyktów pozytywnych.

Autorzy: dr inż. Piotr Gołabek, Wyższa Szkoła Ekonomii i Innowacji w Lublinie, Wydział Transportu i Informatyki, ul. Projektowa 4, 20-209 Lublin, E-mail: Piotr.Golabek@wsei.lublin.pl; mgr inż. Ludwik Madej, Centrum Diagnostyki PKP PLK S.A., ul. Chodakowska 63, 03-816 Warszawa, E-mail: Ludwik.Madej@plk-sa.

LITERATURA

- [1] Duda R., Hart P., Stork D., Pattern Classification, Wiley Interscience, 2000
- [2] Beyerer J., Richter M., Nagel M., Pattern Recognition, Walter De Gruyter, Berlin 2018
- [3] Charu C. A., Data Classification, CRC Press 2015
- [4] Zhang G. P., Neural Networks for Classification, *IEEE Trans. on Systems, Man and Cybernetics*, 30 (2000), n. 4, 451-461
- [5] Lipton C. Z., A Critical Review of Recurrent Neural Networks for Sequence Learning, *ArXiv*, vol. 1506.00019 (2015)
- [6] Hochreiter S., Schmidhuber J., Long Short-Term Memory, *Neural Computation* 9(8) (1997), 1735-1780
- [7] Schuster M., Kuldip K. P., Bidirectional Recurrent Neural Networks, *IEEE Trans. On Signal Processing* 45 (1997), n.11, 2673-2681
- [8] Ramsundar B., Zadeh R. B., Bharath R., TensorFlow for Deep Learning, O'Reilly Media Inc. (2018)
- [9] Gulli A., Pal S., Deep learning with Keras, Packt Publishing (2017)