



Sposób i układ wykorzystujący sztuczne sieci neuronowe do pomiaru oraz klasyfikacji stanu nawierzchni drogowej

Przedmiotem wynalazku jest sposób i układ wykorzystujący sztuczne sieci neuronowe do pomiaru oraz klasyfikacji stanu nawierzchni asfaltowej. Zautomatyzowany system pozwala na identyfikację dróg o niezadowalającym stanie technicznym oraz występujących na nich śladów zużycia takich jak np. pęknięcia czy łaty.

Taki system pozwoli na usprawnienie procesów związanych z zarządzaniem majątkiem drogowym oraz na identyfikację odcinków dróg o niezadowalającym stanie nawierzchni. Ze względu na podjętą tematykę przedstawione rozwiązanie wpisuje się w obszar dyscypliny: Nauki o Zarządzaniu i Jakości.

Z opisu zgłoszenia patentowego [PL392320A](#) znane jest urządzenie pomiarowe zainstalowane na pojeździe, które wykorzystuje głowicę pomiarową wyposażoną w dalmierze laserowe oraz układ IMU. Urządzenie zbiera również dane geolokacyjne pojazdu, a także wyposażone jest w kamerę wizyjną oraz aparat fotograficzny. Urządzenie wykorzystuje metodę trójwymiarowego skaningu laserowego. Zarejestrowane dane analizowane są po zakończeniu pomiarów na stanowisku analitycznym. Układ złożony jest ze skonfigurowanych przestrzennie dalmierzy laserowych – minimum dwóch. Dalmierze połączone są z enkoderem. Enkoder połączony jest z układem IMU, kamerą wizyjną, aparatem fotograficznym, pulpitem sterującym, monitorem oraz konwerterem poziomów napięć. Układ geolokacji satelitarnej połączony jest z konwerterem napięć. Droga głowicy pomiarowej odwzorowana jest poprzez mechaniczne sprzężenie jednego z kół pojazdu z enkoderem.

Z opisu patentowego [CN101451337B](#) znane jest urządzenie wykorzystujące kamerę CCD umieszczoną na wysięgniku za pojazdem, kamera umieszczona jest prostopadle do nawierzchni drogowej. Urządzenie wykorzystuje obwód wykrywania prędkości pojazdu, który dynamicznie dostosowuje częstotliwość fotografowania nawierzchni.

Z opisu patentowego [US10953887B2](#) znany jest system monitorowania stanu nawierzchni drogi, po której poruszają się wiele pojazdów. System ten składa się z centralnego modułu przetwarzania, czterech czujników dowolnego typu (np. czujniki prędkości obrotowej) dla każdego z kół pojazdu. System ten wykorzystuje również dostępne w pojeździe czujniki. Na podstawie danych system określa współczynnik tarcia dla jednej z 3 klas. Gdzie klasa 3 oznacza wysoki współczynnik tarcia, a 1 niski współczynnik tarcia.

Z opisu patentowego [US10086842B2](#) znane jest urządzenie do estymacji stanu nawierzchni drogowej. Estymacja odbywa się na podstawie drgań przyłożonych do powierzchni styku opony z podłożem. Urządzenie umieszczone jest na każdym z kół pojazdu. Urządzenie reaguje na drgania w kierunku stycznym do opony generując energię elektryczną, możliwym jest zastosowanie czujnika przyspieszenia innego typu.

Z opisu zgłoszenia patentowego [CN101487222A](#) znany jest system pomiarowy wykorzystujący wiązkę laserową do detekcji stanu nawierzchni drogowej. Urządzenie pomiarowe składa się

z nadajników oraz odbiorników laserowych, kamer o wysokiej rozdzielczości oraz źródeł światła, które zapewniają odpowiednie doświetlenie obrazu z kamer.

5 Z opisu zgłoszenia patentowego US2018189576A1 znany jest układ pomiarowy, który jest w stanie klasyfikować cechy nawierzchni drogowej. Układ ten wyposażony jest kamerę wizyjną, układ GPS, jednostkę IMU oraz jednostkę przetwarzającą dane. Jednostka IMU oraz kamera wizyjna synchronizowane są ze sobą w celu wykonania procesów związanych z wizualną odometrią. Układ klasyfikuje cechy nawierzchni na podstawie danych z kamery oraz jej kątów Eulera.

10 Z opisu zgłoszenia patentowego D2US2014207411A1 znana jest metoda pomiaru cech nawierzchni oraz podłużnego profilu drogi. Metoda ta wykorzystuje czujniki 3d oraz IMU zamontowane na pojeździe. Czujnik IMU wykorzystywany jest do estymacji kątów Eulera, a dokładnie do kąta pitch.

15 Z opisu zgłoszenia patentowego US2019154442A1 znane jest rozwiązanie do stereoskopowego skanowania powierzchni. Rozwiązanie to wykorzystuje diody LED o określonej częstotliwości, enkodery kół, układ GPS, IMU oraz urządzenia do robienia zdjęć stereoskopowych, w który skład mogą wchodzić szybkie kamery ze skanowaniem liniowym. Dane z IMU są wykorzystywane do uzupełniania danych przechwytywanych przez urządzenia do przechwytywania obrazu w celu skorygowania nieprawidłowości nawierzchni i uzyskania dokładniejszych szacunków 3D.

20 Z opisu zgłoszenia patentowego US2019073762A1 znane jest rozwiązanie do skanowania miejsc z wykorzystaniem maszyny roboczej oraz kamery. Rozwiązanie to korzysta z kamery, układu IMU oraz modułu GPS. Nawigacja pojazdu bazuje na IMU oraz układzie GPS. W jednym z przykładów wykonania IMU wykorzystywane jest do pozyskiwania ogólnych danych statystycznych takich jak: przyspieszenia szczytowe, średnie przyspieszenie, odchylenie standardowe przyspieszenia czy gęstość widmowa mocy.

25 Z artykułu An IMU-based traffic and road condition monitoring system znane jest rozwiązanie wykorzystujące mikrokontroler oraz moduł IMU do monitorowania ruchu drogowego oraz stanu nawierzchni drogowej. Urządzenie komunikuje się z odbiornikiem poprzez zastosowanie technologii Bluetooth. Urządzenie zamontowane jest w przedniej części pojazdu.

30 Z artykułu Road Surface Classification with Images Captured From Low-cost Camera - Road Traversing Knowledge (RTK) Dataset znane jest rozwiązanie wykorzystujące kamerę wizyjną oraz model konwolucyjnej sieci neuronowej w celu klasyfikacji stanu nawierzchni.

35 Znane jest również z artykułu Real-Time Classification of Road Type and Condition in Passenger Vehicles rozwiązanie wykorzystujące pojedynczy układ IMU zamontowany przy siedzeniu pasażera. Układ wykorzystuje model losowego lasu decyzyjnego w celu klasyfikacji stanu nawierzchni. System ten składa się z komputera pomiarowego, modułu interfejsu, jednostki IMU oraz odbiornika GPS.

W artykule Squeeze-and-Excitation Networks - <https://arxiv.org/pdf/1709.01507.pdf> - przedstawiono rozwiązanie, w którym centralnym elementem konstrukcyjnym neuronowych sieci konwolucyjnych (CNN) jest operator konwolucji, który umożliwia sieciom konstruowanie cech informacyjnych poprzez łączenie informacji przestrzennych i kanałowych w lokalnych polach recepcyjnych w każdej warstwie. Szeroki zakres wczesniejszych badań badał

przestrzenny komponent tej relacji, starając się wzmocnić zdolność reprezentacyjną sieci CNN poprzez poprawę jakości kodowania przestrzennego w całej hierarchii cech. W tej pracy skupiono się na relacji kanałowej i zaproponowano nową jednostkę architektoniczną, którą nazywamy blokiem "ściśnięcia i ekscytacji" (SE), który adaptacyjnie rekalkuluje odpowiedzi na cechy kanału poprzez jawne modelowanie współzależności między kanałami. Pokazano, że te bloki mogą być ułożone razem, aby stworzyć architekturę SENet, która generalizuje się niezwykle efektywnie w różnych zestawach danych. Ponadto wykazano, że bloki SE przynoszą znaczącą poprawę wydajności dla istniejących najnowocześniejszych CNN przy niewielkich dodatkowych kosztach obliczeniowych. Modele i kod są dostępne na stronie <https://github.com/hujie-frank/SENet>.

10

Problemem technicznym do rozwiązania jest automatyczna klasyfikacja stanu asfaltowej nawierzchni drogowej.

Przedmiotem wynalazku jest sposób i układ wykorzystujący sztuczne sieci neuronowe do pomiaru oraz klasyfikacji stanu nawierzchni drogowej. Istotą sposobu pomiaru wykorzystujący sztuczne sieci neuronowe do klasyfikacji stanu nawierzchni drogowej, w którym jednostki do nawigacji inercyjnej wysyłają do jednostki przetwarzającej dane wyposażonej w akcelerator sztucznej inteligencji jest to, że do znajdującej się w jednostce przetwarzającej dane sztucznej sieci neuronowej wyposażonej w dwie gałęzie dostarczane są dane z jednostek do nawigacji inercyjnej, ułożonych w konfiguracji diagonalnej wewnątrz pojazdu oraz dane te przetwarzane są przez sieć w oknach o wymiarze nie mniej niż sto próbek, dane z jednostek do nawigacji inercyjnej przesyła się do osobnych identycznych gałęzi, gdzie w pojedynczej gałęzi wykorzystuje się blok ET o hiperparametrach G_L nie mniej niż sześć, G_W nie mniej niż pięćdziesiąt oraz C_w nie mniej niż sześć, a następnie połączone dane z obu gałęzi przetwarza się przez blok BRSE o parametrze SE_n nie mniej niż sześć. Następnie wykorzystując zbiór warstw konwolucyjji, normalizacji oraz funkcji aktywacji w postaci tangensa hiperbolicznego, do określenia przynależności przetworzonych danych do jeden z przynajmniej dwóch klas wykorzystuje się dwie warstwy neuronów, w pierwszej z nich liczba neuronów wynosi nie mniej niż szesnaście, zaś w drugiej jest równa liczbie klas.

Istotą układ pomiarowy wykorzystujący sztuczne sieci neuronowe do klasyfikacji stanu nawierzchni drogowej, posiadający jednostki do nawigacji inercyjnej, które połączone są z jednostką przetwarzającą dane, do której podłączona jest kamera skierowana w stronę ruchu pojazdu oraz do jednostki przetwarzającej dane wyposażona w akcelerator sztucznej inteligencji podłączony jest moduł nawigacji satelitarnej jest to, że jednostki do nawigacji inercyjnej, ułożone są w konfiguracji diagonalnej wewnątrz pojazdu.

35

Korzystnym skutkiem zastosowania wynalazku jest usprawnienie procesu zarządzania majątkiem drogowym, poprzez automatyczną detekcję stanu nawierzchni uzupełnioną informacją

o występujących uszkodzeniach. Urządzenie jest układem wyposażony we własne źródło zasilania i pozwala na montaż wewnątrz pojazdu.

Przedmiot wynalazku w przykładzie wykonania jest uwidoczniony na rysunku, na którym poszczególne figury przedstawiają:

- 5 fig. 1 – schemat połączeniowy systemu,
- fig. 2 – układ elementów systemu wewnątrz pojazdu według wynalazku,
- fig. 3 – układ elementów systemu wewnątrz pojazdu dla jednostek do nawigacji inercyjnej ułożonych w tej samej osi,
- 10 fig. 4 – wykres korelacji krzyżowej dla jednostek do nawigacji inercyjnej ułożonych wzdłuż tej samej osi oraz dla jednostek do nawigacji inercyjnej w ułożeniu diagonalnym,
- fig. 5 – struktura sieci neuronowej z uwzględnieniem wymiaru danych,
- fig. 6 – Zmiana funkcji straty na epokę,
- fig. 7 – Zmiana dokładności na epokę,
- 15 fig. 8 – Zestaw danych IMU1 – przyspieszenie,
- fig. 9 – Zestaw danych IMU1 – przyspieszenie kątowe,
- fig. 10 – Zestaw danych IMU2 – przyspieszenie,
- fig. 11 – Zestaw danych IMU2 – przyspieszenie kątowe.

20 Układ pomiarowy w przykładzie wykonania składa się z dwóch modułów IMU1 i IMU2 oraz kamery wizyjnej, która połączona jest z jednostką przetwarzającą dane wyposażoną w akcelerator sztucznej inteligencji 1. Moduł nawigacji satelitarnej 3 również połączony jest z jednostką przetwarzającą dane 1. Ułożenie jednostek do nawigacji inercyjnej IMU1 i IMU2 wewnątrz pojazdu 4 jest diagonalne, oznacza to, że jednostki do nawigacji inercyjnej zlokalizowane są po przeciwnych

25 stronach pojazdu najbliżej kół na płaskiej powierzchni podłogi. Pierwsza jednostka do nawigacji inercyjnej IMU1 znajduje się z lewej strony pojazdu przy tylnej kanapie zaś druga jednostka do nawigacji inercyjnej IMU2 znajduje się z prawej strony pojazdu w przedniej części pojazdu. Obie jednostki do nawigacji inercyjnej IMU1 i IMU2 zamontowane są równoległe do nawierzchni drogowej. Kamera wizyjna 2 umieszczona jest przy przedniej szybie samochodu w osi pojazdu 4.

30 Drugi przykład wykonania wynalazku posiada taki sam układ z tym, że kamerą 2 jest kamera 3D.

Sposób, wykorzystujący sztuczne sieci neuronowe, pomiaru oraz klasyfikacji stanu nawierzchni drogowej z wykorzystaniem układu pomiarowego polega na tym, że dane z jednostek do nawigacji inercyjnej IMU1 i IMU2 - akceleracja oraz wskazania żyroskopu na osiach x, y, z oraz dane z modułu

35 nawigacji satelitarnej 3 rejestrowane są w pamięci jednostki przetwarzającej dane 1 wyposażonej w akcelerator AI. Kamera 2 wizyjna lub kamera głęboka przesyła obraz lub chmurę punktów do jednostki przetwarzającej dane 1. Jednostka przetwarzająca dane 1 odpowiedzialna jest za detekcję uszkodzeń nawierzchni na podstawie danych z kamery 2. W pamięci jednostki przetwarzającej dane 1 zapisywane są informacje odnośnie rodzaju uszkodzenia (np. pęknięcie, dziura, łata) skorelowane z miejscem

wystąpienia na podstawie danych z modułu nawigacji satelitarnej 3. Zastosowanie dwóch jednostek do nawigacji inercyjnej IMU1 i IMU2 w ułożeniu diagonalnym pozwoliło na zwiększenie dokładności klasyfikacji nawierzchni asfaltowej. Zebrane przez urządzenie dane analizowane są w postprocessingu. Dla danych z jednostek do nawigacji inercyjnej IMU1 i IMU2 przez model sieci neuronowej przypisywana jest jedna z trzech klas. Klasa I – oznacza bardzo dobry stan nawierzchni asfaltowej, klasa II – oznacza średni stan nawierzchni asfaltowej, zaś klasa III – oznacza zły stan nawierzchni asfaltowej.

Z wykorzystaniem układu według wynalazku dokonano pomiarów na odcinku drogi o długości 15km, który uwzględniał nawierzchnię drogową o stanie bardzo dobrym, średnim oraz złym. Pomiar ten nie był wykorzystany jako część zestawu przeznaczonego do nauki, ani zestawu testowego. Posłużył on jako zestaw walidacyjny, w celu sprawdzenia dokładności sieci na nieznanym zestawie danych. Dane z pomiaru wykorzystane zostały również do porównania dokładności innych rozwiązań względem modelu sztucznej sieci neuronowej. W modelu sztucznej sieci neuronowej (fig. 5) wykorzystane zostały następujące bloki: Enkoder bloku transformatora – *ET*, Blok resztkowy z modułem ściskania i ekscytacji – *BRSE*, Blok *KNA*.

Enkoder bloku transformatora składa się z dwóch warstw z połączeniami resztkowymi, pierwsza składa się z bloku atencji wielogłowicowej oraz warstwy sumującej i normalizującej. W drugiej warstwie znajduje się sprzężenie do przodu i ponownie warstwa sumowania i normalizacji. Samouważność jest elementem atencji wielogłowicowej. Obliczana jest ona poprzez rzutowanie wartości wejściowych na trzy macierze utworzone w procesie uczenia się, są to W^Q , W^K , W^V . Przetwarzane wartości to Q , K , V . Mechanizm uwagi oblicza wagi, które określają względne znaczenie każdej wartości w danym szeregu – K , dla danej wartości wyjściowej Q . Otrzymane wagi są mnożone przez dane wejściowe V . Samouważność przedstawiona została za pomocą równania 1 według [Attention Is All You Need](#).

$$A(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_K}}\right) \quad [1]$$

gdzie:

- 25 Q – macierz zawierająca wartości wejściowe (pytanie);
- K – macierz zawierająca wartości odpowiadające tym z Q (klucz);
- T – transpozycja;
- V – wartość atencji (związek pozostałych wartości wejściowych z danym elementem z Q);
- $\sqrt{d_k}$ – wartość zapobiegająca skrajniej zbieżności gradientu do 0, indeks k jest wymiarem K .

30 Zastosowany blok *ET* opisany jest jako funkcja, która jako argumenty przyjmuje hiperparametry poszczególnych warstw równanie [2]:

$$ET(G_L, G_W, C_W) \quad [2]$$

gdzie:

- 35 G_L – liczba głowic w warstwie atencji wielogłowicowej *AT*;
- G_W – wymiar pojedynczej głowicy;
- C_W – liczba filtrów w warstwie konwolucji jednowymiarowej.

Blok *BRSE* został sparymetryzowany ze względu na hiperparametry dla określonych warstw, w taki sposób, że:

$$BRSE(SE_n)$$

gdzie:

5 SE_n – liczba neuronów w bloku ściskania i ekscytacji;

Moduł ściskania i ekscytacji według Squeeze-and-Excitation Networks odpowiada za rekalkibrację cech. Wykorzystanie tego modułu jest możliwe dla dowolnej transformacji odwzorowującej wartości wejściowe X na U takie, że $U \in R^{(W \times C)}$, gdzie $W \times C$ jest wymiarem danych wejściowych.

10 Cechy U w pierwszej kolejności trafiają do deskryptora, który odpowiada za ich agregację wzdłuż wybranego wymiaru. Deskryptor tworzy globalne osadzenie funkcji dystrybucji kanału. Dane po agregacji służą jako dane wejściowe dla mechanizmu samo-bramkowego (warstwy gęsto połączonych neuronów). Mechanizm ten odpowiada za stworzenie zestawu wag, które będą wykorzystywane do modulowania wartości dla każdego kanału.

15 Blok *KNA* składa się z następujących po sobie warstwach: warstwa konwolucyjna, warstwa normalizacyjna oraz funkcji aktywacji.

Dane wejściowe w postaci macierzy x trafiają do modelu (fig. 5) jako zsynchronizowane przebiegi czasowe informacji z IMU1 oraz IMU2 i analizowane są w oknach, które składają się ze stu próbek. Dane x są dzielone ze względu na czujnik i trafiają do jeden z dwóch gałęzi. Dane wejściowe do gałęzi zostały oznaczone jako x_b . Dane z każdego czujnika trafiają do osobnych identycznych gałęzi wykorzystujących bloki *ET*, która składają się z dwóch zbiorów warstw: warstwa uwagi *WA* oraz warstwa sprzężenia w przód *SP*. *WA* przetwarza dane x_b przy wykorzystaniu uwagi wielogłowicowej, która składa się z sześciu głowic G_L o wymiarze głowicy G_W równym sto, a następnie dane przechodzą przez warstwę normalizacyjną w wyniku czego otrzymywane są dane x_{WA_1} . W *WA* zastosowane zostało połączenie resztkowe, dlatego $x_{WA} = x_{WA_1} + x_b$ ze względu na element. Dane wyjściowe z *WA* - x_{WA} trafiają do *SP* gdzie przechodzą przez warstwę konwolucji jednowymiarowej o liczbie filtrów C_w równej sześć oraz o rozmiarze jądra równym jeden, a następnie przez funkcję aktywacji w postaci tangensa hiperbolicznego i ponownie przez warstwę konwolucji jednowymiarowej o liczbie filtrów równej ostatniemu wymiarowi danych wyjściowych i rozmiarze jądra 1 i warstwę normalizacji w wyniku czego otrzymywane są dane x_{SP_1} . Ponownie zastosowane jest połączenie resztkowe także $x_{SP} = x_{SP_1} + x_{WA}$. Dane z obu gałęzi są rozszerzane o jeden wymiar i łączone ze sobą - x_{AB} , w wyniku czego ostatni wymiar tensora jest równy dwa. Dane trafiają do bloku *BRSE*, gdzie przechodzą dwa razy przez zbiór warstw konwolucji dwuwymiarowej o liczbie filtrów równej jeden oraz rozmiarze jądra jeden na jeden, warstwę normalizacji wsadowej oraz funkcję aktywacji w postaci tangensa hiperbolicznego, w wyniku czego otrzymywany jest tensor x_{BR} . W dalszej kolejności dane trafiają do warstwy globalnego uśredniania według liczby przebiegów czasowych. Dane te przechodzą przez dwie warstwy neuronów gęstopołączonych o ilości neuronów kolejno: $\frac{SE_n}{3}$ z funkcją aktywacji ReLu oraz SE_n z sigmoidalną

funkcją aktywacji, gdzie SE_n jest równe sześć. W wyniku operacji otrzymywany jest wektor x_{SE} przez który mnożony jest tensor x_{BR} , a następnie dodawany jest tensor x_{AB} , z czego otrzymywane jest $x_{BRSE} = x_{SE} \cdot x_{BR} + x_{AB}$. Tensor x_{BRSE} przechodzi przez warstwę konwolucji dwuwymiarowej o ilości filtrów 1 oraz rozmiarze jądra trzy na trzy, warstwę normalizacji wsadowej oraz funkcję aktywacji w postaci tangensa hiperbolicznego w kolejnym kroku następuje zamiana danych na wektor, dane te przetwarzane zostają przez dwie warstwy neuronów gęsto-połączonych, gdzie pierwsza warstwa składa się z 32 neuronów z funkcją aktywacji w postaci tangensa hiperbolicznego, zaś druga warstwa składa się z 3 neuronów z funkcją aktywacji softmax, z których wartością wyjściową jest prawdopodobieństwo przynależności danych wejściowych do jednej z 3 klas. Do odpowiedniego działania modelu wymagany jest proces nauki modelu. Sieć została wytrenowana na specjalnie utworzonym do tego celu zestawie danych. Wykorzystane zostały trzy pojazdy wyposażone w napęd na przednie koła. Dane (wskazania IMU1 i IMU2) zbierane były na zróżnicowanych odcinkach drogowych, a klasy nadawane były poprzez wizualną ocenę nawierzchni. Łączna ilość próbek w zestawie danych wynosiła 461738 (fig. 8, fig. 9, fig. 10, fig. 11). W celu nauki modelu, zestaw danych został podzielony na zestaw przeznaczony do nauki oraz zestaw testowy. Do nauki jako optymalizator został zastosowany algorytm ADAM z następującymi parametrami: $\alpha = 0,001$; $\beta_1 = 0,9$, $\beta_2 = 0,999$; $\epsilon = 10^{-8}$, jako funkcję straty przyjęto rzadką kategorię entropię krzyżową (softmax). W procesie nauki, docelowa liczba epok wynosiła 100, jednak do końcowego modelu zastosowane zostały wagi z epoki 31, ze względu na brak zmniejszenia wartości funkcji straty dla zestawu walidacyjnego przez kolejne 20 epok.

Ocena nauki modelu sieci neuronowej bazuje na metrykach w postaci: wartość funkcji straty oraz dokładność, w obu przypadkach dla zestawu przeznaczony do nauki oraz zestawu testowego. Podczas nauki wartość funkcji straty została zminimalizowana, dla zestawu przeznaczony do nauki wartość funkcji straty wynosiła 0,2436, a dla zestawu testowego 0,4591 (fig. 6). W przypadku dokładność dla zestawu przeznaczony do nauki oraz zestawu testowego, kolejno zostały osiągnięte następujące wartości 0,9105 oraz 0,8398 (fig. 7). Opisany proces przywrócenia wag pozwala na uniknięcie zjawiska przeuczenia sieci (nadmiernego „przyzwyczajania się” modelu do zestawu danych przeznaczony do nauki).

W celu porównania wyników dokonano pomiarów z układem jednostek do nawigacji inercyjnej umieszczonych na tej samej osi - jednostki rozmieszczone z przodu tylnej kanapy w sąsiedztwie kół (fig. 3). Jednostki do nawigacji inercyjnej były zamocowane w tym samym pojeździe 4, a badania przeprowadzone były na tym samym odcinku drogi i z zastosowaniem struktury sieci neuronowej.

W celu potwierdzenia przewagi diagonalnego układu jednostek do nawigacji inercyjnej nad pojedynczą jednostką do nawigacji inercyjnej wykorzystano model losowego lasu decyzyjnego ($\eta = 0,3$; $\gamma = 0$, maksymalna głębokość = 6). Model wykazał niższą dokładność dla zbioru walidacyjnego przy użyciu danych z pojedynczej jednostki do nawigacji inercyjnej. Zarówno dla pojedynczej jednostki do nawigacji inercyjnej umieszczonego z przodu pojazdu - fig. 2 IMU2 jak i pojedynczej jednostki do nawigacji inercyjnej umieszczonego z tyłu - fig. 2 IMU1 model losowego lasu decyzyjnego wykazał dokładność 0,68. Przy zastosowaniu dwóch jednostek do nawigacji inercyjnej ułożonych w układzie

diagonalnym – fig. 2 IMU1, IMU2, osiągnięta dokładność wyniosła 0,71. Dokładność zdefiniowana jest jako zdolność modelu do klasyfikowania danych wejściowych jako przynależne do klasy prawdziwej.

Wykonane pomiary dla ułożenia jednostek do nawigacji inercyjnej na w tej samej osi wykazały występowanie zależności pomiędzy odczytami z tych jednostek. W celu określenia zależności zastosowano metodę korelacji krzyżowej. Każde wskazanie jednostki zostało porównane z odpowiednim wskazaniem drugiej jednostki. Wartość została znormalizowana dla całego zbioru danych. Korelację krzyżową z przesunięciem czasowym od -25 do 25 próbek (ok. -1s do 1s) dla rozmieszczenia jednostek do nawigacji inercyjnej dla jednej osi pojazdu oraz dla układu diagonalnego przedstawiono na fig. 4.

Przeprowadzone badania wykazały występowanie korelacji pomiędzy danymi z jednostek do nawigacji inercyjnej położonych w tej samej osi. Najwyższe współczynniki korelacji wystąpiły dla wartości A_y , G_x , G_y i G_z . W przypadku układu diagonalnego największa korelacja wystąpiła dla G_z . Ze względu na występowanie korelacji między wskazaniami jednostek do nawigacji inercyjnej umieszczonych w tej samej osi wybrano diagonalne ułożenie jednostek do nawigacji inercyjnej.

Dla układu diagonalnego przeprowadzone zostały pomiary w tym samym pojeździe 4 i na tym samym odcinku drogi. Przeprowadzona została analiza dokładności klasyfikacji stanu nawierzchni odcinka drogowego. Do analizy wykorzystano model losowego lasu decyzyjnego, model drzewa ze wzmocnionym gradientem ($n_{est} = 100$; maksymalna głębokość = 6) oraz model sztucznej sieci neuronowej. Dane porównawcze przedstawiono w tabeli. Model sztucznej sieci neuronowej charakteryzuje się największą dokładnością spośród przedstawionych metod i osiągnął dokładność na poziomie 0,77.

Tabela – porównanie wyników dla modelu losowego lasu decyzyjnego, modelu drzewa ze wzmocnionym gradientem oraz modelu sztucznej sieci neuronowej dla układu według wynalazku.

		Stan nawierzchni			Dokładność	Średnia	Średnia ważona
		Dobry	Średni	Zły			
Losowy las decyzyjny	Precyzja	0,77	0,62	1,00	0,71	0,80	0,74
	Czułość	0,64	0,80	0,65		0,70	0,71
	F1-score	0,70	0,70	0,79		0,73	0,71
Drzewo ze wzmocnionym gradientem	Precyzja	0,73	0,66	0,94	0,72	0,78	0,73
	Czułość	0,74	0,71	0,69		0,71	0,72
	F1-score	0,73	0,68	0,80		0,74	0,72
Sztuczna sieć neuronowa	Precyzja	0,79	0,71	1,00	0,77	0,82	0,78
	Czułość	0,80	0,78	0,61		0,73	0,77
	F1-score	0,79	0,74	0,75		0,76	0,77

Diagonalne ułożenie czujników pozwala na uzyskanie większej ilości nieskorelowanych danych niż w przypadku zastosowania jednego czujnika, a także 2 czujników umieszczonych na jednej osi.

RZECZNIK PATENTOWY
Maciej Nowicki
 mgr inż. Maciej Nowicki
 Nr wp. 3476

Wykaz oznaczeń:

IMU1	pierwsza jednostka do nawigacji inercyjnej
IMU2	druga jednostka do nawigacji inercyjnej
1	Jednostka przetwarzająca dane wyposażona w akcelerator AI
2	Kamera wizyjna lub kamera głęboka
3	Moduł nawigacji satelitarnej
4	Pojazd
Ax	Wskazania akcelerometru dla osi x
Ay	Wskazania akcelerometru dla osi y
Az	Wskazania akcelerometru dla osi z
Gx	Wskazanie żyroskopu dla osi x
Gy	Wskazanie żyroskopu dla osi y
Gz	Wskazanie żyroskopu dla osi z
AWG	Atencja wielogłowicowa
WN	Warstwa normalizacyjna
K1D	Konwolucja jednowymiarowy
K2D	Konwolucja dwuwymiarowy
FA	Funkcja aktywacji
U	Warstwa uśredniająca
NG	Warstwa neuronów gęstopołączonych
ZW	Zamiana danych na wektor