

mgr inż. Jacek Sudyka^{1*)}

ORCID: 0000-0002-4360-2365

dr hab. inż. Grzegorz Mazurek, prof. PŚk²⁾

ORCID: 0000-0002-9735-1725

dr hab. inż. Przemysław Buczyński, prof. PŚk²⁾

ORCID: 0000-0003-0798-8093

Data-driven prediction of asphalt pavement temperature profiles

Predykcja rozkładu temperatury w nawierzchniach asfaltowych metodami data-driven

DOI: 10.15199/33.2025.12.15

Abstract. Reliable knowledge of the temperature distribution within asphalt pavements is essential for maintenance and structural diagnosis. To forecast the asphalt layers temperature the recurrent neural networks (RNN, including LSTM and BiLSTM) and gradient-boosted decision trees (XGBoost) have been used based on a multi-month field dataset (March – October) with multi-depth temperature measurements and meteorological variables. RNNs captured both diurnal fluctuations and seasonal trends with high predictive accuracy. While the classical XGBoost setup was slightly less precise, it offered very short training times and greater interpretability; its depth-generalized experimental variant enabled interpolation across the full depth range with an error of $\sim 0,97^{\circ}\text{C}$ ($R^2 \approx 0,988$). The findings support hybridization (RNN + XGBoost) to combine temporal-pattern extraction with efficient regression on static features (e.g., depth, time-of-day).

Keywords: asphalt pavement; temperature distribution; machine learning; RNN; LSTM; BiLSTM; XGBoost; interpolation; temperature correction; FWD; TSD.

Streszczenie. Utrzymanie i diagnostyka nawierzchni asfaltowych wymagają wiarygodnej informacji o rozkładzie temperatury w czasie i w głąb konstrukcji. Do prognozowania temperatury warstw asfaltowych zastosowano rekurencyjne sieci neuronowe (RNN, w tym LSTM i BiLSTM) oraz gradientowe modele drzew decyzyjnych (XGBoost) na podstawie wielomiesięcznych danych terenowych (marzec – październik) obejmujących pomiary na wielu głębokościach oraz parametry meteorologiczne. Modele RNN wiernie odwzorowały zarówno wahania dobowe, jak i sezonowe. XGBoost, choć w wariacie klasycznym nieco mniej precyzyjny, zapewnił bardzo krótki czas obliczeń i większą interpretowalność; jego wariant eksperymentalny z uogólnieniem po głębokości umożliwił interpolację temperatury w całym zakresie badanych głębokości z błędem rzędu $\sim 0,97^{\circ}\text{C}$ ($R^2 \approx 0,988$). Wyniki wskazują na zasadność hybrydyzacji podejść (RNN + XGBoost), łączącej identyfikację wzorców czasowych z efektywną regresją po cechach statycznych (m.in. głębokość, pora doby).

Słowa kluczowe: nawierzchnia asfaltowa; rozkład temperatury; uczenie maszynowe; RNN; LSTM; BiLSTM; XGBoost; interpolacja; korekcja temperaturowa; FWD; TSD.

Development of the road network and increasing requirements regarding its reliability mean that pavement structural diagnostics is gaining in importance. One of the key factors influencing the durability and safety of asphalt use is the temperature of asphalt layers. High temperature causes a loss of mixture stiffness and an increase in permanent deformations, whereas low temperature promotes the formation of shrinkage and fatigue cracks. Under winter conditions, surface temperature is the main factor determining road icing, which has a direct impact on traffic safety. Therefore, accurate knowledge of how temperature changes over time and at different depths is necessary for assessing the technical condition of the pavement and for planning maintenance treatments.

In practice, pavement bearing capacity is assessed using TSD (*Traffic Speed Deflectometer*) and FWD (*Falling Weight Deflectometer*) deflectometers, which record pavement deflection generated under a moving load. The magnitude of

rozwój sieci drogowej i rosnące wymagania dotyczące jej niezawodności powodują, że diagnostyka konstrukcji nawierzchni zyskuje na znaczeniu. Jednym z kluczowych czynników wpływających na trwałość i bezpieczeństwo użytkowania asfaltu jest temperatura warstw asfaltowych. Wysoka temperatura powoduje utratę sztywności mieszanki i wzrost odkształceń trwałych, natomiast niska sprzyja powstawaniu pęknięć skurczowych i zmęzeniowych. W warunkach zimowych temperatura powierzchni jest głównym czynnikiem decydującym o oblodzeniu drogi, co ma bezpośredni wpływ na bezpieczeństwo ruchu. W związku z tym dokładne poznanie, jak zmienia się temperatura w czasie i na różnej głębokości, jest niezbędne do oceny stanu technicznego nawierzchni oraz planowania zabiegów utrzymaniowych.

W praktyce ocena nośności nawierzchni odbywa się za pomocą ugięciomierzy typu TSD (*Traffic Speed Deflectometer*) i FWD (*Falling Weight Deflectometer*), które rejestrują ugięcie nawierzchni generowane pod wpływem przemieszczającego się obciążenia. Wielkość odkształcenia zależy nie tylko od rodzaju konstrukcji, lecz także od temperatury warstwy asfaltowej. Brak korekty do temperatury odniesienia może pro-

¹⁾ Instytut Badawczy Dróg i Mostów, Zakład Diagnostyki Nawierzchni

²⁾ Politechnika Świętokrzyska, Wydział Budownictwa i Architektury

*) Correspondence address: jacek.sudyka@ibdim.edu.pl

deformation depends not only on the type of structure but also on the temperature of the asphalt layer. A lack of correction to the reference temperature may lead to errors in assessing the condition of the road network at the network-level indicator scale. Precise prediction of the pavement temperature distribution thus makes it possible both to correctly recalculate deflection and to better plan maintenance treatments.

The physical models used so far to predict temperature were based on heat conduction equations and required the introduction of many input data, which limits their usefulness in practice. Simple regression models relied on a linear relationship between pavement surface temperature and air temperature, wind speed or precipitation, but they did not take into account the long thermal memory of the asphalt layer and the nonlinearity of the occurring changes. **In recent years, there has been increasing interest in the use of data-mining and machine-learning methods for modelling engineering processes.** Recurrent neural networks (RNN – *Recurrent Neural Network*), especially their LSTM (*Long Short-Term Memory*) and GRU (*Gated Recurrent Unit*) variants, are capable of learning long-term dependencies and better reproducing the dynamics of temperature changes than statistical models. At the same time, regression decision-tree models such as RF (*Random Forest*) are being developed, which combine interpretability with the ability to model nonlinear relationships. In recent years, hybrid models have also appeared, combining elements of physics with machine learning.

This paper presents the application of recurrent neural networks and a regression decision-tree model to predict the temperature distribution in the cross-section of a road pavement structure. The models were calibrated on the basis of data from field temperature measurements carried out at a specially prepared test site. Over the course of a year, pavement temperature was recorded at various depths together with other meteorological data. The aim of the analysis was to compare the accuracy of both approaches and to assess their usefulness in the diagnostics of the road network, in particular in the context of deflection correction.

Review of methods

Prediction of temperature in asphalt pavement structures has traditionally been based on physical models of heat conduction and energy balance, which, under appropriately defined boundary conditions, ensure accuracy of description [1 – 4]. In practice, however, their usefulness is limited by input parameters (including albedo, heat-absorption coefficients) and sensitivity to meteorological variability, which hinders calibration and operational application. Widely used empirical formulas (e.g., BELLS) remain simple but provide moderate accuracy and require further optimisation [5 – 6].

The increasing availability of field data favours a data-driven approach. Preliminary attempts based on multiple regression did not capture the thermal inertia and nonlinearity of the process [6 – 9]. Recurrent neural networks (RNN), especially LSTM and their bidirectional variants (BiLSTM),

wadzić do błędów w ocenie stanu sieci drogowej na poziomie wskaźnikowym. Precyzyjna prognoza rozkładu temperatury nawierzchni umożliwia zatem zarówno prawidłowe przeliczenie ugięcia, jak i lepsze planowanie zabiegów utrzymaniowych.

Dotychczas stosowane modele fizyczne przewidujące temperaturę bazowały na równaniach przewodnictwa cieplnego i wymagały wprowadzenia wielu danych wejściowych, co ogranicza ich użyteczność w praktyce. Proste modele regresyjne korzystały z linearnej zależności między temperaturą nawierzchni a temperaturą powietrza, prędkością wiatru czy opadami, ale nie uwzględniały długiej pamięci cieplnej warstwy asfaltowej i nieliniowości zachodzących zmian. **W ostatnich latach zwiększa się zainteresowanie wykorzystaniem metod data-mining i uczenia maszynowego do modelowania procesów inżynierskich.** Rekurencyjne sieci neuronowe (RNN – *Recurrent Neural Network*), zwłaszcza ich odmiany LSTM (*Long Short-Term Memory*) i GRU (*Gated Recurrent Unit*), potrafią uczyć się długoterminowych zależności i lepiej odwzorować dynamikę zmian temperatury niż modele statystyczne. Jednocześnie rozwijane są regresyjne modele drzew decyzyjnych, takie jak RF (*Random Forest*), które łączą interpretowalność z możliwością modelowania nieliniowych zależności. W ostatnich latach pojawiły się również modele hybrydowe, łączące elementy fizyki z uczeniem maszynowym.

W artykule przedstawiono zastosowanie rekurencyjnych sieci neuronowych oraz regresyjnego modelu drzew decyzyjnych do prognozowania rozkładu temperatury w przekroju konstrukcji nawierzchni drogowej. Modele kalibrowano na podstawie danych z terenowych pomiarów temperatury wykonywanych na specjalnie przygotowanym stanowisku badawczym. W ciągu roku rejestrowano temperaturę nawierzchni na różnej głębokości oraz inne dane meteorologiczne. Celem analizy było porównanie dokładności obu podejść i ocena ich przydatności w diagnostyce sieci drogowej, zwłaszcza w kontekście korekty ugięcia.

Przegląd metod

Prognozowanie temperatury w konstrukcjach asfaltowych tradycyjnie bazuje na modelach fizycznych przewodnictwa cieplnego i bilansu energii, które przy odpowiednio zdefiniowanych warunkach brzegowych zapewniają wierność opisu [1 – 4]. W praktyce ich użyteczność ograniczają jednak parametry wejściowe (m.in. albedo, współczynniki przejmowania ciepła) i wrażliwość na zmienność meteorologiczną, co utrudnia kalibrację i zastosowania operacyjne. Powszechnie stosowane formuły empiryczne (np. BELLS) pozostają proste, lecz dają umiarkowaną dokładność i wymagają dalszej optymalizacji [5 – 6].

Zwiększająca się dostępność danych terenowych sprzyja podejściu data-driven. Wstępne próby oparte na regresji wielorakiej nie uchwyciły bezwładności cieplnej i nieliniowości procesu [6 – 9]. Rekurencyjne sieci neuronowe (RNN), zwłaszcza LSTM i ich odmiany dwukierunkowe (BiLSTM), pozwalają uczyć się długoterminowych zależności i popraw-

make it possible to learn long-term dependencies and correctly reproduce diurnal and seasonal fluctuations; however, they require continuous, normalised time series and longer training [4, 14, 15, 20, 21]. At the same time, tree-based models have been developed: random forests and gradient boosting (GBM, XGBoost), which combine strong approximation capability with interpretability and short training time [10 – 12]. In road applications it has been shown that boosted trees can outperform classical procedures for temperature correction of asphalt layers and that machine learning represents a valuable alternative to empirical schemes in the context of FWD/TSD [5, 13]. Table-based models must be “given memory” through feature engineering (lags, time encoding) in order to emulate sequence processing. More recent work explores hybrid approaches: physics-informed neural networks (PINN) integrate heat-conduction equations with data, enabling simultaneous estimation of material parameters and temperature distribution [16]; other solutions combine neural and tree-based components or incorporate classical correction formulas as inputs, achieving improved accuracy over single methods [17, 18]. Despite progress, many studies rely on short campaigns and specific local conditions, which highlights the need for systematic comparisons on longer, field-based time series and evaluation of model usefulness in practice (e.g., FWD/TSD deflection normalisation). The review in [6] emphasises the lack of analyses based on long, consistent measurement sequences and diverse climatic and structural conditions, which limits the comparability of results. Likewise, the study [13] demonstrated the advantage of boosted trees over the empirical BELLS3 in estimating layer temperature for FWD/TSD correction, but it concerned a single location and did not include systematic confrontation with sequence models. In light of these observations, the present article fills the identified gap by a direct comparison of RNN and XGBoost on year-long field data and discussion of implementation implications.

The collected sources demonstrate that machine-learning methods, both recurrent neural networks and tree ensembles, significantly outperform classical regression models in predicting asphalt-layer temperatures and thereby in FWD/TSD temperature correction. Most existing studies, however, rely on data from short experiments and seldom account for local climatic conditions and pavement characteristics. There is a lack of models calibrated on long-term meteorological data and continuous field temperature measurements. No systematic comparison of RNN and tree-based model performance on such data has been conducted, and thus it remains unclear which technique better handles local climate variability, which features are most important, and how this translates into correction accuracy. The purpose of this paper is to fill this gap. It employs and compares recurrent neural networks and tree-based models (random forest, gradient boosting) based on year-long meteorological monitoring and field measurements, simultaneously assessing their usefulness for evaluating the structural condition of road pavements.

nie odtwarzać wahań dobowe oraz sezonowe; wymagają jednak ciągłych, znormalizowanych szeregów czasowych i dłuższego treningu [4, 14, 15, 20, 21]. Jednocześnie rozwijano modele drzewiaste: lasy losowe i wzmacnianie gradientowe (GBM, XGBoost), które łączą dużą siłę aproksymacyjną z interpretowalnością i krótkim czasem uczenia [10 – 12]. W zastosowaniach drogowych wykazano, że boosted trees mogą przewyższać klasyczne procedury korekcyjne temperatury warstw asfaltowych, a uczenie maszynowe stanowi wartościową alternatywę dla schematów empirycznych w kontekście FWD/TSD [5, 13]. Modelom tablicowym trzeba „dopisać pamięć” przez inżynierię cech (łagi, kodowanie czasu), aby emulować przetwarzanie sekwencji. Nowsze prace eksplorują podejścia hybrydowe: fizycznie informowane sieci neuronowe (PINN) integrują równania przewodnictwa cieplnego z danymi, umożliwiając jednocześnie szacowanie parametrów materiałowych i rozkładu temperatury [16]; inne rozwiązania łączą komponenty neuronowe i drzewiaste bądź włączają klasyczne formuły korekcyjne jako wejścia, uzyskując zysk dokładności względem pojedynczych metod [17, 18]. Mimo postępów, wiele badań bazuje na krótkich kampaniach i specyficznych warunkach lokalnych, co podkreśla potrzebę systematycznych porównań na dłuższych, terenowych szeregach czasowych oraz oceny przydatności modeli w praktyce (np. normalizacja ugięć FWD/TSD). Przegląd w [6] akcentuje niedostatek analiz opartych na długich, spójnych ciągach pomiarowych oraz na zróżnicowanych warunkach klimatycznych i konstrukcyjnych, co ogranicza porównywalność wniosków. Z kolei praca [13] wykazała przewagę boosted trees nad empirycznym BELLS3 w szacowaniu temperatury warstw w przypadku korekcji FWD/TSD, lecz dotyczyła pojedynczej lokalizacji i nie obejmowała systematycznej konfrontacji z modelami sekwencyjnymi. W świetle tych obserwacji artykuł wypełnia zidentyfikowaną lukę przez bezpośrednie porównanie RNN i XGBoost na rocznych danych terenowych oraz omówienie implikacji wdrożeniowych.

Zebrane źródła dowodzą, że metody uczenia maszynowego, zarówno rekurencyjne sieci neuronowe, jak i ensemble drzew znacznie przewyższają klasyczne modele regresyjne w prognozowaniu temperatury warstw asfaltowych i tym samym w korekcji ugięć FWD/TSD. Większość dotychczasowych badań opiera się jednak na danych z krótkotrwałych eksperymentów i rzadko uwzględnia lokalne warunki klimatyczne oraz specyfikę nawierzchni. Brakuje modeli kalibrowanych na długoterminowych danych meteorologicznych i na ciągłych, terenowych pomiarach temperatury. Nie przeprowadzono systematycznego porównania efektywności RNN i modeli drzewiastych na takich danych, dlatego nie wiadomo, która technika lepiej radzi sobie z lokalną zmiennością klimatu, jakie cechy są najważniejsze i jak przekłada się to na dokładność korekcji ugięć. Artykuł ma na celu wypełnienie tej luki. Wykorzystuje i porównuje rekurencyjne sieci neuronowe oraz modele oparte na drzewach (random forest, gradient boosting) bazujących na danych z rocznego monitoringu meteorologicznego i pomiarów terenowych, oceniając jednocześnie ich przydatność do diagnostyki nośności nawierzchni sieci drogowych.

Data description and dataset preparation

Description of the test site. The data for the analysis came from a specially prepared test site comprising a network of sensors installed in a new asphalt pavement structure and a meteorological station. Temperature measurements were performed using platinum resistance thermometers Pt100 of class A (in accordance with IEC 60751), placed at the target depths of the profile (0, 2, 6, 10, 16, 22 cm). The sensors were installed during the construction of each new pavement layer by means of a narrow cut. The pavement structure had the following layer arrangement: mechanically stabilised crushed aggregate (auxiliary base course); base course of asphalt concrete BA 25 with 35/50 asphalt; binder course AC16W with DE 30B asphalt and wearing course SMA 12 with a thickness of 4 cm with OL30B asphalt. The test section was prepared as a segment closed to traffic, which limited the risk of cable damage and sensor displacement. In this way, the influence of accelerated material ageing processes and local damage, which affect the thermal properties of the pavement, was also minimised. Closing the tested section to traffic and using a homogeneous structure made it possible to eliminate undesirable disturbances, so that the recorded temperature profiles reflected mainly meteorological conditions and the thermal inertia of the layer system. The data were collected from March to October, which yielded 10 531 observations at 30-minute intervals. Temperature was recorded at six points in the asphalt-layer profile: at the surface (0 cm) and at depths of 2, 6, 10, 16 and 22 cm. In addition, wind speed and direction, relative humidity, air temperature at different heights, dew point, daily precipitation and extreme daily temperature values were recorded. Each record therefore contained both meteorological variables and temperature in the asphalt layers. The arrangement of the probes in successive layers made it possible to reconstruct the vertical temperature profile and analyse heat exchange between layers. The obtained data served as the basic input dataset for building machine learning models. The values of the predicted temperatures at depth were treated as dependent variables. In turn, the predictors were environmental variables: pavement surface temperature and humidity. All data were synchronised using the assigned time-interval step. The analysed input dataset had the character of a time series – each observation was recorded at a specific moment, and the input variables showed dependence on the diurnal and seasonal (temporal) cycle.

Before modelling was undertaken, a data quality analysis was carried out. The initial assessment of the dataset structure indicated strong correlation of the temperature at depths of 2, 6, 10, 16 and 22 cm with the temperature read at the surface ($h = 0$ cm) and with humidity. The remaining features showed a weaker correlation relationship. Reducing the number of input features was very important, since one of the aims of developing an effective model was the possibility of using easily available environmental data. Therefore, forecasting the temperature at a given depth required the use of direct features that are easy to obtain over

Opis danych i przygotowanie zbioru

Opis stanowiska badawczego. Dane do analizy pochodziły z specjalnie przygotowanego stanowiska badawczego, obejmującego sieć czujników zainstalowanych w nowej konstrukcji nawierzchni asfaltowej oraz stację meteorologiczną. Pomiar temperatury realizowano termometrami platynowymi Pt100 rezystancyjnymi klasy A (zgodnie z normą IEC 60751), umieszczonymi na docelowej głębokości profilu (0, 2, 6, 10, 16, 22 cm). Czujniki wprowadzano podczas wbudowywania każdej nowej warstwy konstrukcji nawierzchni przez wąskie nacięcie. Konstrukcja nawierzchni miała następujący układ warstw: kruszywo łamane stabilizowane mechanicznie (warstwa podbudowy pomocniczej); podbudowa z betonu asfaltowego BA 25 z asfaltem 35/50; warstwa wiążąca AC16W z asfaltem DE 30B oraz warstwa ścieralna SMA 12 o grubości 4 cm z asfaltem OL30B. Stanowisko badawcze przygotowano jako odcinek wyłączony z ruchu, co ograniczyło ryzyko uszkodzeń przewodów i przemieszczeń czujników. W ten sposób zminimalizowano również wpływ procesów przyspieszonego starzenia materiału i uszkodzeń lokalnych, które oddziałują na właściwości termiczne nawierzchni. Wyłączenie badanego odcinka z ruchu oraz zastosowanie jednorodnej konstrukcji pozwoliło wyeliminować niepożądane zakłócenia, dzięki czemu rejestrowane profile temperatury odzwierciedlały głównie warunki meteorologiczne oraz bezwładność cieplną układu warstw. Dane zbierano w okresie od marca do października, co dało 10 531 obserwacji w 30-minutowych odstępach. Rejestrowano temperaturę w sześciu punktach profilu warstw asfaltowych: na powierzchni (0 cm) oraz na głębokości 2, 6, 10, 16 i 22 cm. Dodatkowo zapisywano prędkość i kierunek wiatru, wilgotność względną, temperaturę powietrza na różnych wysokościach, punkt rosy, dobowy opad oraz ekstremalne wartości temperatury dobowej. Każdy rekord zawierał zatem zarówno zmienne meteorologiczne, jak i temperaturę w warstwach asfaltowych. Rozmieszczenie sond w kolejnych warstwach umożliwiło odtworzenie pionowego profilu temperatury i analizę wymiany ciepła między warstwami. Uzyskane dane posłużyły jako podstawowy zbiór wejściowy do budowy modeli uczenia maszynowego. Wartości prognozowanych temperatur na głębokości miały charakter zmiennych zależnych. Natomiast rolę predyktorów stanowiły zmienne o charakterze środowiskowym: temperatura powierzchni nawierzchni oraz wilgotność. Wszystkie dane zostały zsynchronizowane przez przypisany krok interwału czasowego. Analizowany zbiór wejściowy miał charakter szeregu czasowego – każda obserwacja była rejestrowana w określonym momencie, a zmienne wejściowe wykazywały zależność od cyklu dobowego oraz sezonowego (czasowego).

Zanim przystąpiono do modelowania, wykonano analizę jakości zbioru danych. Wstępna ocena struktury zbioru wskazała na silne skorelowanie temperatury na głębokości: 2, 6, 10, 16 i 22 cm z temperaturą odczytaną na powierzchni ($h = 0$ cm) i wilgotnością. Pozostałe cechy wykazywały mniejszy związek korelacyjny. Redukcja ilości cech wejściowych miała bardzo duże znaczenie, gdyż jednym z celów opracowania skutecznego modelu była możliwość zagospodarowania łatwo dostępnych danych środowiskowych. Zatem

the period from several to several dozen hours back from the measurement.

Data were also checked in terms of the number of valid observations, outliers and redundancy (Table 1). Outliers were determined on the basis of the 95 percent confidence interval for the mean. Redundancy of features (predictors) was assessed using Pearson statistics in the same way as in principal component analysis. Most meteorological variables (wind speed, wind direction, humidity, air temperature) had about 93% valid observations and few outliers. The data describing rainfall contained about 15.5% outliers, which suggests that intense precipitation occurred rarely and had an incidental character.

Table 1. Data quality check report

Tabela 1. Raport sprawdzenia jakości danych

Variable/Zmienna	Scale type/Typ skali	Number of valid/ Nr ważnych	% N	Number of outliers/ Liczba odstających	Percentage of outliers/ Procent odstających	Variable quality/ Jakość zmiennej
Wind speed/Prędkość wiatru	quantitative/iłoścowy	9814	93,2	1	0,01	outlying/odstające
Wind direction/Kierunek wiatru	quantitative/iłoścowy	9814	93,2	0	0	OK
Humidity/Wilgotność	quantitative/iłoścowy	9814	93,2	0	0	OK
Temp_300cm	quantitative/iłoścowy	9814	93,2	0	0	redundant/nadmiarowe
Temp_20cm	quantitative/iłoścowy	9814	93,2	0	0	redundant/nadmiarowe
Temp_0cm	quantitative/iłoścowy	9814	93,2	0	0	OK
Dewpoint/Punkt rosy	quantitative/iłoścowy	9814	93,2	0	0	OK
Rainfall/Opad	quantitative/iłoścowy	9814	93,2	1518	15,5	outlying/odstające
P4_22 cm	quantitative/iłoścowy	10531	100	0	0	OK
P4_16cm	quantitative/iłoścowy	10531	100	0	0	redundant/nadmiarowe
P4_10cm	quantitative/iłoścowy	10531	100	0	0	redundant/nadmiarowe
P4_6cm	quantitative/iłoścowy	10531	100	0	0	redundant/nadmiarowe
P4_2cm	quantitative/iłoścowy	10531	100	0	0	redundant/nadmiarowe

The designation P4 is the identifier of the measurement point. It is a suffix to which the depth of the measurement probe location was assigned. Some pavement temperature readings, including predictors in the dataset, were characterised by missing data. Their amount was about 6.8%, which can be regarded as an acceptable level. Nevertheless, machine learning models such as RNN (and its variants such as LSTM, GRU) require continuous, sequential input data [20]; otherwise, missing data will disturb the temporal order and increase the risk of overfitting. Since the number of gaps was small, the Kalman filter [19, 21], which is effective for time series, was used to fill them. After filling gaps in the input dataset with the Kalman filter, resulting from the elimination of outliers of the nature of reading errors, all numerical variables were normalised.

Thanks to the standardisation performed, the filling in of data and the selection of predictors, a consistent dataset was prepared, which was used to train recurrent neural network models and gradient random trees. The choice of filtering and feature selection techniques was made in the context of earlier studies from the literature [17].

prognozowanie temperatury na danej głębokości wymagało zastosowania cech bezpośrednich, łatwych do pozyskania w okresie pomiaru od kilku do kilkunastu godzin wstecz.

Dokonano również sprawdzenia danych pod kątem liczby ważnych obserwacji, wartości odstających i nadmiarowości (tabela 1). Wartości odstające określono na podstawie 95-procentowego przedziału ufności w przypadku średniej. Natomiast redundancję cech (predyktorów) oceniano statystyką Pearsona w taki sam sposób jak w przypadku analizy składowych głównych. Większość zmiennych meteorologicznych (prędkość wiatru, kierunek wiatru, wilgotność, temperatura powietrza) miała ok. 93% ważnych obserwacji i niewiele wartości odstających. Dane opisujące opad deszczu zawierały

ok. 15,5% wartości odstających, co sugeruje, że intensywne opady występowały rzadko i miały charakter incydentalny.

Oznaczenie P4 to identyfikator punktu pomiarowego. Jest to sufiks, do którego została przypisana głębokość umiejscowienia sondy pomiarowej. Niektóre odczyty temperatury w nawierzchni, w tym predyktory w zbiorze danych, odznaczały się brakiem danych. Ich ilość wynosiła ok. 6,8%, co można uznać za poziom akceptowalny. Niemniej jednak modele uczenia maszynowego, takie jak RNN (i jego warianty jak LSTM, GRU), wymagają ciągłych, sekwencyjnych danych wejściowych [20], w przeciwnym razie braki danych zaburzają kolejność czasową oraz zwiększają ryzyko przeuczenia. W związku z tym, że liczba braków była niewielka, zastosowano do ich uzupełnienia filtr Kalmana [19, 21] skuteczny przy szeregach czasowych. Po wypełnieniu luk w zbiorze wejściowym filtrem Kalmana, będących efektem eliminacji wartości odstających o charakterze błędów odczytu, wszystkie zmienne numeryczne zostały znormalizowane.

Dzięki przeprowadzonej standaryzacji, uzupełnieniu danych i selekcji predyktorów przygotowano spójny zbiór, który posłużył do trenowania modeli rekurencyjnych sieci neuronowych i gradientowych drzew losowych. Wyboru technik filtracji i selekcji cech dokonano w kontekście wcześniejszych badań z literatury [17].

Architecture and parameters of the selected models

The project was based on two models: recurrent neural networks (RNN) with LSTM layers and gradient-boosted decision-tree models (XGBoost). The first of these was used for processing time sequences, and the second for analysing tabular data with delays (lags). The architecture of the models, the data-preparation process, the learning parameters and the results on test datasets are discussed in detail. As predictors, the following variables were used:

- pavement surface temperature on the asphalt pavement,
- air humidity.

In turn, the sought values (dependent variables) were the temperatures at defined pavement depths: 2, 6, 10, 16 and 22 cm. Interpolation at depths between measurement points requires linear interpolation. The final form of the model included the variable depth, allowing temperature interpolation at any depth. All models were evaluated using four metrics: coefficient of determination (R^2); root mean square error (RMSE); mean absolute percentage error (MAPE); and mean absolute error (MAE).

Recurrent neural networks (RNN/LSTM) are suited for analysing time series, because in each step they update a hidden state which carries information from previous observations. The LSTM architecture applied in the project enables the model to learn long-term dependencies by using gating mechanisms that control the flow of information. Data preparation consisted of creating sequences of 3 h (6 samples) composed of the values of pavement surface temperature (temp_0 cm) and humidity, and in normalising input variables.

Two baseline architectures were built in the initial trials: MODEL1 (a single LSTM layer, 256 neurons) and MODEL2 (a system with two LSTM layers with dropout regularisation). Both variants confirmed the usefulness of the sequential approach for reproducing diurnal and seasonal fluctuations, with MODEL2 bringing a moderate improvement in quality compared with MODEL1 (a gain of several percentage points of R^2 and an RMSE reduction of approx. 1°C). Due to the compromise between fidelity of reproduction and complexity, the bidirectional architecture MODEL3 was adopted as the reference model for further analyses. The comparison of model characteristics is shown in Table 2.

The model described as MODEL3 introduces bidirectional LSTM (BiLSTM), which process the sequence both in the direction of increasing and decreasing time. The results from both directions are concatenated and passed to dense layers.

Architektura i parametry wybranych modeli

Projekt bazował na dwóch modelach: rekurencyjnych sieciach neuronowych (RNN) z warstwami LSTM oraz gradientowych modelach drzew decyzyjnych (XGBoost). Pierwszy z nich wykorzystano do przetwarzania sekwencji czasowych, drugi do analizy danych tabelowych z opóźnieniami (lagami). Szczegółowo omówiono architekturę modeli, proces przygotowania danych, parametry uczenia oraz wyniki na zbiorach testowych. W rezultacie jako predyktory stanowiły zbiór zmiennych:

- temperatura powierzchni na nawierzchni asfaltowej;
- wilgotność powietrza.

Natomiast wartościami poszukiwanymi (zmienne zależne) była temperatura na zdefiniowanej głębokości nawierzchni: 2, 6, 10, 16 i 22 cm. Interpolacja na głębokości pomiędzy punktami pomiarowymi wymaga interpolacji liniowej. Ostatnia postać modelu uwzględniała zmienną głębokość pozwalającą na interpolację temperatury na dowolnej głębokości. Wszystkie modele oceniano za pomocą czterech metryk: współczynnika determinacji (R^2); pierwiastka błędu średniokwadratowego (RMSE); średniego procentowego błędu prognozy (MAPE); średniego błędu bezwzględnego (MAE).

Rekurencyjne sieci neuronowe (RNN/LSTM) są przystosowane do analizy szeregów czasowych, ponieważ w każdym kroku aktualizują ukryty stan, który przenosi informację z poprzednich obserwacji. Zastosowana w projekcie architektura LSTM umożliwia modelowi uczenie się długoterminowych zależności, wykorzystując mechanizmy bramkujące, które kontrolują przepływ informacji. Przygotowanie danych polegało na utworzeniu sekwencji o długości 3 h (6 próbek) złożonych z wartości temperatury powierzchni (temp_0 cm) i wilgotności oraz na normalizacji zmiennych wejściowych.

W ramach wstępnych prób zbudowano dwie architektury odniesienia: MODEL1 (pojedyncza warstwa LSTM, 256 neuronów) oraz MODEL2 (układ z dwiema warstwami LSTM z regularyzacją dropout). Oba warianty potwierdziły przydatność podejścia sekwencyjnego do odwzorowania wahań dobowych i sezonowych, przy czym MODEL2 przyniósł umiarkowany wzrost jakości w porównaniu z MODEL1 (zysk rzędu kilku punktów procentowych R^2 i redukcja RMSE o ok. 1°C). Ze względu na kompromis między wiernością odwzorowania a złożonością, jako model referencyjny do dalszych analiz przyjęto architekturę dwukierunkową MODEL3. Porównanie charakterystyki modeli przedstawiono w tabeli 2.

Model opisany jako MODEL3 wprowadza dwukierunkowe LSTM (BiLSTM), które przetwarzają sekwencję zarówno w kierunku rosnącej, jak i malejącej osi czasu. Wyniki z obu kierunków są łączone (concatenate) i przekazywane do warstw gęstych. Model zawierał dwie warstwy LSTM (jed-

Table 2. Characteristics of the adopted RNN models

Tabela 2. Charakterystyka przyjętych modeli RNN

Model	Input data (predictors)/ Dane wejściowe (predyktory)	Sequence length (time window)/ Długość sekwencji (okno czasowe)	Output data (predicted variable)/Dane wyjściowe (zmienna prognozowana)
LSTM (MODEL1, MODEL 2)	temp_0 cm, humidity/temp_0 cm, wilgotność	6 steps × 30 min (3 h)/ 6 kroków × 30 min (3 h)	temperature at the given depth h at time t/temperatura na zadanej głębokości h w chwili t
BiLSTM+LSTM (MODEL3)	temp_0 cm, humidity/temp_0 cm, wilgotność	6 steps × 30 min (3 h)/ 6 kroków × 30 min (3 h)	temperature at the given depth h at time t/temperatura na zadanej głębokości h w chwili t

The model included two LSTM layers (one bidirectional: BiLSTM, and one unidirectional: LSTM) and one dense layer, with a total of 682 561 parameters (Table 3). In addition to the bidirectional LSTM layer, which had 512 neurons in total, the model also provided a *batch-normalisation layer ()* aimed at including the normalisation stage to improve learning stability. As a result, additional normalisation of variables and saving of the series of results of this process stored in the *recipe ()* object were avoided. To improve the prediction of temperature change, a second classical LSTM layer (*lstm_14*) with 64 neurons was introduced. Training was carried out with the same settings as before, but thanks to the use of early stopping (*patience* = 30), the number of epochs did not exceed 70 (Figure 1).

The quality of fitting model-based data in MODEL3 to the experimental data did not significantly improve compared to MODEL2. The maximum estimation error was 3.28°C, whereas the fitting quality R^2 was > 0.81, and in most cases > 0.9. The summary results of the fit-quality metrics are presented in Table 4.

Table 3. Final architecture of MODEL3

Tabela 3. Architektura końcowa MODEL3

Layer (type)/ Warstwa (typ)	Output Shape/Kształt wyjścia	Parameters/ Parametry	Trainable/ Podlegające uczeniu
bidirectional_4 (Bidirectional/ Dwukierunkowy)	(none, 6, 512)	530432	Y
batch_normalization_15 (Batch Normalization/Normalizacja wsadowa)	(none, 6, 512)	2048	Y
activation_15 (Activation)	(none, 6, 512)	0	Y
dropout (Dropout/Warstwa odrzućcia)	(none, 256)	0	Y
lstm_14 (LSTM layer/ Warstwa LSTM)	(none, 64)	147712	Y
batch_normalization_14 (Batch Normalization/Normalizacja wsadowa)	(none, 64)	256	Y
activation_14 (Activation/ Aktywacja)	(none, 64)	0	Y
dense_15 (Dense/Warstwa gęsta)	(none, 32)	2080	Y
dense_14 (Dense/Warstwa gęsta)	(none, 1)	33	Y

Total params/liczba parametrów: 682561 (2.60 MB)

Trainable params/Parametry podlegające uczeniu: 681409 (2.60 MB)

Non-trainable params/Parametry niepodlegające uczeniu: 1152 (4.50 KB)

None = batch size/rozmiar partii (batch), 6 = sequence length/długość sekwencji (6 steps/6 kroków × 30 min = 3 h), 512 = number of features/outputs per step after BiLSTM/liczba cech/wyjść na krok po warstwie BiLSTM.

na dwukierunkowa: BiLSTM + jedną jednokierunkową: LSTM) i jedną warstwę gęstą z łączną liczbą parametrów 682 561 (tabela 3). Oprócz dwukierunkowej warstwy LSTM, która sumarycznie miała 512 neuronów, model zapewniał również warstwę typu *batch_normalization ()* mającą na celu uwzględnienie etapu normalizacji w celu poprawy stabilności uczenia. W efekcie można było uniknąć dodatkowej normalizacji zmiennych i zapisu serii wyników tego procesu zgromadzonego w obiekcie *recipe ()*. W celu poprawy prognozy zmiany temperatury wprowadzono drugą klasyczną warstwę LSTM (*lstm_14*) o liczbie neuronów 64. Trening przeprowadzono z analogicznymi ustawieniami jak wcześniej, ale dzięki zastosowaniu wczesnego zatrzymywania (*patience* = 30) liczba epok nie przekroczyła 70 (rysunek 1).

Jakość dopasowania danych modelowych w MODEL3 do eksperymentalnych nie uległa znacznej poprawie w porównaniu do MODEL2. Maksymalny błąd estymacji wyniósł 3,28°C, natomiast jakość dopasowania R^2 była > 0,81, a w większości przypadków > 0,9. Zbiorcze rezultaty metryk jakości dopasowania przedstawiono w tabeli 4.




Fig. 1. RNN model training graph (MODEL3)

Rys. 1. Wykres trenowania modelu RNN (MODEL3)

Table 4. Model fit metrics (test set): MODEL1, MODEL2 and MODEL3

Tabela 4. Metryki dopasowania modeli (zbiór testowy): MODEL1, MODEL2 i MODEL3

Location/ Lokalizacja	MODEL1				MODEL2				MODEL3			
	RMSE [°C]	MAE [°C]	MAPE [%]	R ²	RMSE [°C]	MAE [°C]	MAPE [%]	R ²	RMSE [°C]	MAE [°C]	MAPE [%]	R ²
P4_2 cm	3,63	2,19	11,72	0,88	2,71	1,94	10,56	0,87	3,3	1,69	12,4	0,9
P4_6 cm	3,16	2,1	11,77	0,88	2,41	1,94	10,24	0,91	2,73	1,78	11,71	0,91
P4_10 cm	3,06	2,08	12,48	0,87	2,01	1,95	12,29	0,94	2,74	1,82	15,1	0,9
P4_16 cm	3,12	2,05	11,63	0,84	2,28	1,84	9,76	0,92	2,48	1,63	10,9	0,9
P4_22 cm	3,14	2,23	13,87	0,83	3,38	2,0	11,60	0,89	3,28	1,76	13,34	0,81

RMSE – Root Mean Square Error/błąd średniokwadratowy; MAE – Mean Absolute Error/średni błąd bezwzględny; MAPE – Mean Absolute Percentage Error/średni procentowy błąd bezwzględny; R² – Coefficient of Determination/współczynnik determinacji

The results in Table 4 indicate very good effectiveness of the RNN technique for predicting temperature changes in which the data show dependence on temporal trends. The only advantage of using the bidirectional network MODEL3 was a significant reduction of training time in terms of the number of epochs needed to obtain the final form of the model, compared with MODEL1 and MODEL2. The maximum MAPE error was less than 13.87%. Analysis of the results allowed concluding that the effectiveness of the bidirectional RNN technique in MODEL3 turned out to be the same as in MODEL2. It enabled identifying both diurnal and seasonal temperature fluctuations. The prediction was obtained on the basis of measurements of temperature and humidity from the previous 3 h.

Gradient-boosted decision-tree models XGBoost constitute the second category of applied algorithms. The main idea is to create a sequence of simple trees, each successive one being constructed to predict the residuals generated by the preceding tree [12]. It can be demonstrated that such a procedure of “additive weighted expansion” of trees ultimately allows an excellent fit of predicted values to observed values, even when the nature of the relationship between predictors and the dependent variable is highly complex (e.g., nonlinear). The main advantage of this technique is its reduced sensitivity to missing data and the ability to perform optional data scaling. In the case of a large dataset, omitting this step is convenient, which results from the fact that at any time the results of the output variable (tensor y) can be fully interpreted. Nevertheless, this technique predicts the value of tensor y with respect to the predictors found in the same record. Therefore, the time-sequence structure, as in RNN networks, has no application here. Constructing such a boosted-tree model required additional operations related to data transformation. This consisted of applying additional variables in the form of delays, i.e., *lags*. Constructing lags consists of creating new features that represent the value of a given variable from previous time steps. In the R script this was done using the *dplyr* library and the *lag()* instruction.

Experimental use of RNN and XGBoost techniques for predicting temperature at any depth of the pavement structure. Two experimental models were adopted: E_XGBoost and E_MODEL1, consisting of predicting temperature at the moment $t = 0$ together with an explicitly introduced variable depth (Table 5).

Wyniki w tabeli 4 świadczą o bardzo dobrej skuteczności techniki RNN do prognozowania zmian temperatury, w których dane wykazują zależność od trendów czasowych. Jedyną zaletą stosowania MODEL3 sieci dwukierunkowej było znaczne ograniczenie czasu treningu w postaci liczby epok do uzyskania ostatecznej postaci modelu w stosunku do MODEL1 i MODEL2. Maksymalny błąd MAPE był mniejszy niż 13,87%. Analiza wyników pozwoliła stwierdzić, że skuteczność techniki RNN o charakterze dwukierunkowych w MODEL3 okazała się być taka sama jak w MODEL2. Pozwoliła ona na zidentyfikowanie zarówno wahań dobowych, jak i sezonowego rozkładu temperatury. Prognoza została uzyskana na podstawie pomiaru temperatury i wilgotności z okresu 3 h wstecz.

Gradientowo wzmacniane modele drzew decyzyjnych XGBoost stanowią drugą kategorię zastosowanych algorytmów. Główną ideą jest tworzenie ciągu prostych drzew, z których każde kolejne jest zbudowane do predykcji reszt generowanych przez poprzednie [12]. Można udowodnić, że taka procedura „addytywnego rozwinięcia ważonego” drzew pozwoli na efekcie na doskonałe dopasowanie wartości przewidywanych do wartości obserwowanych, nawet jeśli sama natura relacji pomiędzy predyktorami a zmienną zależną jest bardzo złożona (np. nieliniowa). Główną zaletą stosowania tej techniki jest jej zmniejszona wrażliwość na brakujące dane oraz wykonanie opcjonalnego skalowania danych. W przypadku dużego zbioru danych pominięcie tego etapu jest komfortowe, co wynika z faktu, że w każdej chwili można interpretować w pełni wyniki zmiennej wyjściowej (tensora y). Niemniej jednak jest to technika prognozująca daną wartość tensora y względem predyktorów znajdujących się w tym samym rekordzie. Zatem struktura sekwencji czasowych jak w sieciach RNN nie ma tu zastosowania. Budowa takiego modelu drzew wzmacnianych wymagała dodatkowych zabiegów związanych z transformacją danych. Polegało to na zastosowaniu dodatkowych zmiennych w postaci opóźnień, tzw. *lagów*. Budowanie *lagów* polega na tworzeniu nowych cech, które reprezentują wartość danej zmiennej z poprzednich kroków czasowych. W skrypcie języka R zostało to zrobione za pomocą biblioteki *dplyr* i instrukcji *lag()*.

Eksperymentalne wykorzystanie technik RNN i XGBoost do predykcji temperatury na dowolnej głębokości konstrukcji nawierzchni. Przyjęto dwa eksperymetalne modele: E_XGBoost oraz E_MODEL1 polegające na prognozie temperatury w chwili $t = 0$ wraz ze zmienną głębokość wprowadzoną jawnie (tabela 5).

Table 5. Characteristics of the adopted experimental models

Tabela 5. Charakterystyka przyjętych modeli eksperymentalnych

Model	Input data (predictors)/Dane wejściowe (predyktory)	Sequence length (time window)/Długość sekwencji (okno czasowe)	Output data (predicted variable)/Dane wyjściowe (zmienna prognozowana)
E_XGBoost	temp_0cm humidity, hour_sin, hour_cos, depth (cm)	6 steps (3 h) encoded into tabular features as lags/6 kroków (3 h) zakodowane w cechy tablicowe w postaci „lagów”	temperature at any depth h (0–22 cm) at time t/temperatura na dowolnej głębokości h (0 ÷ 22 cm) w chwili t
E_MODEL1 (RNN + depth + rain)	temp_0cm humidity, hour_sin, hour_cos, depth (cm)	6 steps /6 kroków × 30 min (3 h)	temperature at any depth h (0–22 cm) at time t/temperatura na dowolnej głębokości h (0 ÷ 22 cm) w chwili t

The **E_XGBoost variant** was designed with the aim of improving prediction accuracy and enabling temperature interpolation between sensors. The key modifications included (Table 5):

- introduction of the predictor “depth”: information about depth was added to the feature set, allowing the model to learn the relationship between depth and temperature;
- continuation of time encoding: the variables *hour_sin* and *hour_cos* were retained;
- expansion of the parameter space: by increasing *max_depth* to 100 and reducing *nrounds* to 368, the model could build more complex trees while minimising the risk of overfitting.

Training proceeded analogously to the classical model but required slightly more time due to the higher complexity of the trees in accordance with the learning-process parameters (Table 6). The results exceeded the initial expectations, namely: RMSE amounted to 0.97°C, $R^2 = 0.988$, MAE = 0.67°C, and MAPE = 4.51%, which means that the model reproduced the temperature distribution almost ideally. The results indicated that the model predicted temperature values very well in the variant where the variable depth was treated as a predictor. The fit results of the experimental values to those estimated by the model, broken down by depth, are presented in Figure 2. They confirmed very good reproduction of temperature changes within the pavement profile in the case of $h > 0$ cm. The E_XGBoost model accurately reproduced both diurnal fluctuations and the drift of its variation associated with the daily cycle. It is worth noting that one of the advantages of this technique is the possibility of rapid updating of model weights using a new dataset (batch), which makes it more universal and provides greater ability to generalise the phenomenon of temperature variation in the pavement.

Extended RNN model with depth and rainfall predictor – E_MODEL1.

The use of the E_XGBoost model (Table 5) showed that incorporating depth as a random variable, apart from improving the accuracy of predicting the temperature distribution, also enabled its interpolation within the pavement profile in places where sen-

Wariant E_XGBoost zaprojektowano z myślą o poprawie dokładności i umożliwieniu interpolacji temperatury pomiędzy czujnikami. Kluczowe modyfikacje obejmowały (tabela 5):

- wprowadzenie predyktora „głębokość”: do zbioru cech dodano informację o głębokości, dzięki czemu model mógł uczyć się zależności między głębokością a temperaturą;
- kontynuację kodowania czasu: zachowano zmienne *hour_sin* i *hour_cos*;
- rozbudowanie przestrzeni parametrów: dzięki zwiększeniu *max_depth* do 100 i zmniejszeniu *nrounds* do 368, model mógł budować bardziej złożone drzewa, minimalizując ryzyko przeuczenia.

Trening przebiegał analogicznie jak w modelu klasycznym, ale wymagał nieco więcej czasu ze względu na większą złożoność drzew zgodnie z parametrami procesu uczenia (tabela 6). Rezultaty przerosły oczekiwania początkowe, a mianowicie: RMSE wyniosło 0,97°C, $R^2 = 0,988$, MAE = 0,67°C, a MAPE = 4,51%, co oznacza, że model niemal idealnie odwzorowywał rozkład temperatury. Uzyskane wyniki wskazały, że model bardzo dobrze prognozował wartości temperatury w wariancie, gdzie zmienna głębokość została potraktowana jako predyktor. Rezultaty dopasowania wyników eksperymentalnych do oszacowanych za pomocą modelu, z podziałem na głębokość, przedstawiono na rysunku 2. Potwierdziły one bardzo dobre odwzorowanie zmiany temperatury w przekroju nawierzchni w przypadku $h > 0$ cm. Model E_XGBoost doskonale odzwierciedlił zarówno wahania dobowe, jak również dryf jej zmiany związany z cyklem dobowym. Należy zwrócić uwagę, że jedną z zalet tej techniki jest możliwość szybkiej aktualizacji wag modelu za pomocą nowego zbioru (wsadu), co powoduje, że jest bardziej uniwersalny i wykazuje większą zdolność do uogólnienia zjawiska zmiany temperatury w nawierzchni.

Table 6. Learning parameters of the modified E_XGBoost model

Tabela 6. Parametry procesu uczenia zmodyfikowanego modelu E_XGBoost

nrounds	max_depth	eta	gamma	colsample_bytree	min_child_weight	subsample
368	100	0,05	0	0,8	1	0,8

eta (learning rate) – learning rate/współczynnik uczenia; gamma – minimum loss reduction required to make a tree split/minimalna wymagana redukcja funkcji straty przy podziale węzła drzewa; max_depth – maximum depth of a single tree; maksymalna głębokość pojedynczego drzewa; min_child_weight – minimum sum of instance weights needed in a tree leaf/minimalna suma wag instancji w liściu drzewa; colsample_bytree – fraction of features randomly sampled for each tree/frakcja cech losowo wybieranych przy budowie każdego drzewa; subsample – fraction of training samples used to build each tree/frakcja próbek trenin-
gowych używana do budowy drzewa; nrounds – number of boosting iterations (trees)/liczba iteracji boostingowych (drzew); lambda – L2 regularization term on weights (reduces model variance)/współczynnik regularyzacji L2 na wagach (redukuje wariancję modelu)

Rozszerzony model RNN z predyktorem głębokości i opadu – E_MODEL1.

Zastosowanie modelu E_XGBoost (tabela 5) wskazało, że uwzględnienie głębokości jako zmiennej losowej, oprócz poprawy jakości predykcji rozkładu temperatury pozwoliło również na jej interpolację w przekroju nawierzchni w miejscach, w których czujniki nie zo-

sors were not located. Due to the tabular structure, the model is not able to explicitly process sequence structure, i.e., it cannot distinguish whether successive data in time are random or dependent on input features. Therefore, a further attempt was made to construct an experimental model based this time on the RNN model with the architecture of layers as in MODEL1, designated as E_MODEL1. In this model, implementation of an additional channel in the form

of rainfall and depth was included. Both variables required normalisation. Model preparation included:

- introduction of the predictor “depth” – apart from the sequence of surface temperature and humidity, an input representing depth was introduced to the network; this value was processed by a small dense layer (16 neurons);

- adding the variable „rainfall” – analysis of the heat maps of humidity and surface temperature (Figure 3) showed that the

July decline in temperature was the result of intense rainfall; including rainfall as a predictor allowed better reproduction of this phenomenon;

- integration of two information streams – after processing the sequence through the LSTM layer (256 neurons) and batch normalisation and processing depth, both streams were concatenated and then passed to subsequent dense layers (128 and 1 neuron).

In total, the model contained 304 417 parameters, of which 303 905 were train-




Fig. 2. Comparison of the predicted temperature at different depth with the temperature read from the monitoring system for the E_XGBoost model

Rys. 2. Porównanie prognozowanej temperatury na poszczególnych głębokościach względem temperatury odczytanej z systemu monitoringu dla modelu E_XGBoost

opadów deszczu oraz głębokość. Obie zmienne wymagały normalizacji. Przygotowanie modelu obejmowało:

- wprowadzenie predyktora „głębokość” – oprócz sekwencji temperatury powierzchni i wilgotności, do sieci wprowadzono wejście reprezentujące głębokość; wartość ta była przetwarzana przez niewielką warstwę gęstą (16 neuronów);

- dodanie zmiennej „opad” – analiza heatmapy wilgotności i temperatury powierzchni (rysunek 3) wykazała, że lip-

stały zlokalizowane. Ze względu na tablicową strukturę model nie jest w stanie jawnie przetworzyć struktury sekwencji, czyli nie potrafi rozróżnić, czy kolejne dane w czasie są losowe, czy też zależą od cech wejściowych. W związku z tym podjęto kolejną próbę budowy eksperymentalnego modelu bazującego tym razem na modelu RNN, o architekturze warstw jak w MODEL1 i oznaczono go jako E_MODEL1.

W modelu tym uwzględniono implementację dodatkowego kanału w postaci




Fig. 3. Heatmap of environmental variables: humidity (a) and surface temperature (b)

Rys. 3. Heatmapa zmiennych środowiskowych: wilgotności (a) oraz temperatury na powierzchni (b)

cowy spadek temperatury był wynikiem intensywnych opadów; ujęcie opadów jako predyktora pozwoliło na lepsze odwzorowanie tego zjawiska;

- integrację dwóch strumieni informacji – po przejściu sekwencji przez warstwę LSTM (256 neuronów) i batchnormalization oraz przetworzeniu głębokości oba strumienie łączono za pomocą *concatenate* (), a następnie przekazywano do kolejnych warstw gęstych (128 i 1 neuron).

Łącznie model zawierał 304 417 parametrów, z czego 303 905 ulegało aktu-

able. Training was carried out with early stopping, just as in MODEL1.

The quality of fit in the form of selected metrics of the E_MODEL1 model, after including rainfall, amounted on average to: RMSE = 3.16°C, MAE = 2.18°C, MAPE = 14.5%, $R^2 = 0.855$. The fit metrics therefore did not indicate an improvement in effectiveness compared with MODEL1, but the inclusion of an additional factor in the form of rainfall and depth eliminated the observed anomaly in the July period and made it possible to predict the temperature between the sensors. Moreover, when observing the fit results (Figure 4), it can be assumed that the obtained fit constitutes an averaging of the results of temperature variation with respect to all depths, with slight correction resulting from the adoption of the normalised depth variable for training the RNN model. It should also be noted that the trend of temperature variation captured by the RNN model was reproduced satisfactorily well. The largest individual anomalies of temperature prediction appear in the period when the data were incorrectly processed by the sensor.

In summary, in order to correctly perform temperature interpolation at a high level of precision, it is necessary in the future to apply a hybrid network consisting of an RNN and XGBoost. In this way, a model architecture will be created in which time-series data are first processed by a recurrent network (RNN, e.g., LSTM), and the results (e.g., sequence representations) are passed as features to an XGBoost model. As a result, the RNN network will process successive sequences (e.g., 24 hours of humidity, temperature), generating a representation matrix (embedding). Next, the XGBoost technique, using the representation matrix, will be trained on static features such as pavement depth or time of day.

alizacji. Trening przeprowadzono z wczesnym zatrzymaniem, tak jak w MODEL1.

Jakość dopasowania w postaci wybranych metryk modelu E_MODEL1, po uwzględnieniu opadów deszczu wyniosła średnio: RMSE = 3,16°C, MAE = 2,18°C, MAPE = 14,5%, $R^2 = 0,855$. Metryki dopasowania nie wskazywały zatem na poprawę skuteczności w porównaniu do MODEL1, ale uwzględnienie dodatkowego czynnika w postaci opadów deszczu oraz głębokości wyeliminowało zaobserwowaną anomalię w okresie lipca i umożliwiło predykcję temperatury pomiędzy czujnikami. Ponadto, obserwując wyniki dopasowania (rysunek 4), można przypuszczać, że uzyskane dopasowanie stanowi uśrednienie wyników zmiany temperatury względem wszystkich głębokości z niewielką korektą wynikającą z przyjęcia zmiennej w postaci znormalizowanej głębokości uczenia sieci RNN. Należy również nadmienić, że trend zmiany temperatury ujęty przez model sieci RNN został odwzorowany satysfakcjonująco dobrze. Największe, pojedyncze anomalie prognozy temperatury pojawiają się w okresie, kiedy dane były niewłaściwie przetwarzane przez czujnik

Podsumowując, aby poprawnie dokonać interpolacji temperatury na wysokim poziomie precyzji, należy w przyszłości zastosować sieć hybrydową składającą się z sieci RNN i XGBoost. W ten sposób powstanie architektura modelu, w którym dane czasowe są najpierw przetwarzane przez sieć rekurencyjną (RNN, np. LSTM), a wyniki (np. reprezentacje sekwencji) przekazywane jako cechy do modelu XGBoost. W efekcie sieć RNN będzie przetwarzać kolejne sekwencje (np. 24 godziny wilgotności, temp.), generując macierz reprezentacji (embedding). Następnie technika XGBoost, wykorzystując macierz reprezentacji, będzie trenowana na cechach statycznych, takich jak: głębokość nawierzchni czy pora dnia. W efekcie sieć RNN




Fig. 4. Comparison of temperature prediction results generated by the E_MODEL1 model with experimental results

Rys. 4. Porównanie wyników predykcji temperatury wygenerowanej przez model typu E_MODEL1 z wynikami eksperymentalnymi

Consequently, the RNN network will make it possible to capture temporal patterns present in the dataset, and the XGBoost model will provide high effectiveness and control of static features.

Discussion of the effectiveness of the adopted models

The conducted studies confirmed that data-driven methods enable reliable prediction of the temperature distribution within the asphalt pavement profile in the case of $h > 0$. In the group of sequence models, the bidirectional architecture MODEL3 (BiLSTM) proved to be the reference variant: on the test dataset it faithfully reproduced the diurnal cycle and the seasonal trend, achieving average RMSE = 2.91°C and $R^2 = 0.88$, with the best fit occurring in the intermediate layers (from 6 to 16 cm). The maximum estimation error was 3.28°C, which confirms the usefulness of MODEL3 in an application requiring high temporal fidelity. The initial baseline variants (MODEL1 and MODEL2) justified the choice of the sequential approach, although in terms of compromise between complexity and quality, MODEL3 provided the most stable results.

The table-based XGBoost model constituted a fast and interpretable alternative. The introduction of the depth variable was of key significance: the experimental variant E_XGBoost enabled continuous interpolation at depths $h > 0$ cm with a very small error RMSE $\approx 0.97^\circ\text{C}$, $R^2 \approx 0.988$ (Table 7), reproducing the realistic modulation of amplitude with depth. Such a temperature profile is particularly valuable in FWD/TSD normalisation procedures when no direct temperature measurement is available in the pavement layer at the required depth.

In turn, E_MODEL1 (RNN extended with depth and rainfall) improved resistance to weather episodes and enabled interpolation between sensors, but did not produce a clear increase in basic metrics compared with the baseline MODEL1 (RMSE = 3.16°C, $R^2 = 0.86$). This result suggests (Table 7) that explicit conditioning on depth in the tree-based model is more effective for profile reconstruction than an analogous extension in the RNN when the sequence window is short.

From a practical viewpoint, it is recommended to choose MODEL3 for tasks requiring the highest possible temporal fidelity (e.g., tracking diurnal and seasonal variations), and E_XGBoost wherever speed, ease of integration and reliable interpolation of the profile from 0 to 22 cm are important for temperature correction. **A natural direction for further work is a hybrid model RNN→XGBoost**, in which sequence representations (embeddings) generated by the BiLSTM network feed a boosting model processing static features (depth, time of day). At the same time, cross-location

pozwole na wyłapanie wzorców czasowych istniejących w zbiorze, a model XGBoost zapewni dużą skuteczność i kontrolę cech statycznych.

Dyskusja skuteczności przyjętych modeli

Przeprowadzone badania potwierdziły, że metody typu data-driven pozwalają wiarygodnie prognozować rozkład temperatury w profilu nawierzchni asfaltowej w przypadku $h > 0$. W grupie modeli sekwencyjnych architektura dwukierunkowa MODEL3 (BiLSTM) okazała się wariantem referencyjnym: na zbiorze testowym wiernie odwzorowała cykl dobowy i trend sezonowy, osiągając uśrednione RMSE = 2,91°C i $R^2 = 0,88$, z najlepszym dopasowaniem w warstwach pośrednich (od 6 do 16 cm). Maksymalny błąd estymacji wyniósł 3,28°C, co potwierdza przydatność MODEL3 w zastosowaniu wymagającym dużej wierności czasowej. Wstępne warianty bazowe (MODEL1 i MODEL2) uzasadniły wybór podejścia sekwencyjnego, jednak z punktu widzenia kompromisu między złożonością a jakością to MODEL3 zapewniał najbardziej stabilne wyniki.

Model tablicowy typu XGBoost stanowił szybką i interpretowalną alternatywę. Kluczowe znaczenie miało wprowadzenie informacji o głębokości: wariant eksperymentalny E_XGBoost umożliwił ciągłą interpolację na głębokości $h > 0$ cm z bardzo małym błędem RMSE $\approx 0,97^\circ\text{C}$, $R^2 \approx 0,988$ (tabela 7), odtwarzając realistyczną modulację amplitudy wraz z głębokością. Taki profil temperaturowy jest szczególnie cenny w procedurach normalizacji ugięć FWD/TSD, gdy brak jest bezpośredniego pomiaru temperatury w warstwie konstrukcji nawierzchni na wymaganej głębokości.

Z kolei E_MODEL1 (RNN rozszerzony o głębokość i opad) poprawił odporność na epizody pogodowe oraz umożliwił interpolację między czujnikami, nie przynosząc jednak wyraźnego wzrostu podstawowych metryk względem bazowego MODEL1 (RMSE = 3,16°C, $R^2 = 0,86$). Wynik ten sugeruje (tabela 7), że eksplicytnie uwarunkowanie po głębokości w modelu drzewiastym jest bardziej efektywne w przypadku rekonstrukcji profilu niż analogiczne rozszerzenie w RNN przy krótkim oknie sekwencji.

Z praktycznego punktu widzenia rekomenduje się dobór modelu MODEL3 w zadaniach wymagających możliwie najwyższej wierności czasowej (np. śledzenie zmian dobowych i sezonowych), oraz E_XGBoost wszędzie tam, gdzie liczą się szybkość, prostota integracji i wiarygodna interpolacja profilu od 0 cm do 22 cm na potrzeby korekcji temperaturowej. **Naturalnym kierunkiem dalszych prac jest model hybrydowy RNN→XGBoost**, w którym reprezentacje sekwencji (embeddingi) wytwarzane przez sieć BiLSTM zasilają model boostingowy przetwarzający cechy statyczne (głębokość, po-

Table 7. Summary of average fit metrics (relative to specified depths) obtained for the tested models

Tabela 7. Podsumowanie średnich wartości metryk dopasowania (względem zadanych głębokości) uzyskane w przypadku testowanych modeli

MODEL 3				E_XGBoost				E_MODEL1			
RMSE [°C]	MAE [°C]	MAPE [%]	R ²	RMSE [°C]	MAE [°C]	MAPE [%]	R ²	RMSE [°C]	MAE [°C]	MAPE [%]	R ²
2,91	1,74	12,69	0,88	0,97	0,67	4,51	0,99	3,16	2,18	14,5	0,86

validation (different climates and structural configurations) and analysis of metric stability over longer time horizons are recommended, which will determine the target scalability of the solution in network-level practice.

The juxtaposition of results indicates clear differences between model classes:

- accuracy – in prediction at given points (2 to 22 cm) MODEL3 turned out to be the best, but E_XGBoost achieved even better results due to the introduction of the depth variable and time encoding;

- training and implementation – E_XGBoost trains much faster, requiring only preparation of a table with lags and time encoding. RNNs require sequential data structure, have higher computational demands and are more sensitive to gaps in time series;

- interpretability – E_XGBoost allows assessing the importance of individual variables, whereas RNNs are less transparent. Importance coefficients can help identify key meteorological and technological factors;

- interpolation – E_XGBoost performs excellently in interpolating temperature between sensors. Use of RNNs in the E_MODEL1 variant enables interpolation, but with a larger approximation error.

Conclusions

The analysis showed that recurrent and gradient-boosted models exhibit different strengths: RNNs better reproduce complex temporal dynamics, whereas XGBoost provides speed, interpretability and ease of implementation. The article proposes the concept of a hybrid model combining both techniques – an RNN would generate sequence representations (so-called embeddings), and XGBoost would use them as input features. Such a model could take advantage of the ability of RNNs to capture temporal patterns and of the effectiveness of XGBoost in processing static features, such as depth or time of day. In addition, a hybrid model could successfully incorporate meteorological and engineering predictors (e.g., mix composition, layer thickness) as additional inputs, which would increase its universality and adaptability to different locations. Developing this concept constitutes a natural direction for further work.

The results indicate that MODEL3 – the bidirectional LSTM network – achieved the best results among sequence models. In turn, E_MODEL1 showed that adding predictors in the form of depth and rainfall makes it possible to reduce the influence of temperature anomalies and enables interpolation of temperature with respect to depth. **The calculated RMSE indicates that for depths of 22 and 16 cm the model is statistically unbiased ($ME \approx 0$), whereas closer to the surface positive prediction errors appear due to greater thermal non-stationarity. In this situation it is necessary to take into account factors related to the thermal conductivity of individual layers.**

Very good results were demonstrated by the experimental model E_XGBoost, which was built for prediction and interpolation of temperature at depths up to 22 cm. Thanks to

ra doby). Jednocześnie wskazana jest walidacja międzylokalizacyjna (odmienne klimaty i konstrukcje) oraz analiza stabilności metryk w dłuższych horyzontach czasowych, co przesądzi o docelowej skalowalności rozwiązania w praktyce sieciowej.

Zestawienie wyników wskazuje na wyraźne różnice między klasami modeli:

- dokładność – w prognozie na danych punktach (od 2 do 22 cm) najlepszy okazał się MODEL3, lecz E_XGBoost osiągnął jeszcze lepsze wyniki dzięki wprowadzeniu zmiennej głębokości i kodowaniu czasu;

- trening i implementacja – E_XGBoost trenuje się znacznie szybciej, wymaga jedynie przygotowania tablicy z lagami i kodowaniem czasu. RNN potrzebują sekwencyjnej struktury danych, mają duże wymagania obliczeniowe i są bardziej wrażliwe na braki w szeregach czasowych;

- interpretowalność – E_XGBoost pozwala na ocenę ważności poszczególnych zmiennych, natomiast RNN są mniej transparentne. Współczynniki ważności mogą pomóc w identyfikacji kluczowych czynników meteorologicznych i technologicznych;

- interpolacja – E_XGBoost radzi sobie znakomicie z interpolacją temperatury pomiędzy czujnikami. Wykorzystanie sieci RNN w wariantcie E_MODEL1 umożliwia interpolację, lecz przy większym błędzie aproksymacji.

Wnioski

Analiza wykazała, że modele rekurencyjne i gradientowe wykazują różne mocne strony: RNN lepiej odwzorowują złożoną dynamikę czasową, zaś XGBoost zapewnia szybkość, interpretowalność i łatwość implementacji. W artykule zaproponowano koncepcję modelu hybrydowego łączącego obie techniki – RNN generowałby reprezentacje sekwencji (tzw. embeddingi), a XGBoost wykorzystywał je jako cechy wejściowe. Taki model mógłby korzystać z możliwości RNN w wychwytywaniu wzorców temporalnych oraz z efektywności XGBoost w przetwarzaniu cech statycznych, takich jak głębokość czy pora dnia. Ponadto model hybrydowy z powodzeniem mógłby uwzględniać predyktory meteorologiczne i inżynierskie (np. skład mieszanek, grubość warstw) jako dodatkowe wejścia, co zwiększyłoby uniwersalność i adaptowalność do różnych lokalizacji. Rozwinięcie tej koncepcji stanowi naturalny kierunek dalszych prac.

Wyniki wskazują, że MODEL3 – dwukierunkowa sieć LSTM – osiągnął najlepsze wyniki wśród modeli sekwencyjnych. Z kolei E_MODEL1 wykazał, że dodanie predyktora w postaci głębokości i opadów pozwala na ograniczenie wpływu anomalii temperaturowych oraz umożliwia interpolację temperatury względem głębokości. **Obliczony RMSE wskazuje, że w przypadku głębokości 22 i 16 cm model jest statystycznie nieobciążony ($ME \approx 0$), natomiast bliżej powierzchni występują pozytywne prognozy wynikające z większej niestacjonarności cieplnej. W tej sytuacji konieczne jest uwzględnienie czynników związanych z przewodnością cieplną poszczególnych warstw.**

Bardzo dobre rezultaty wykazał eksperymentalny model E_XGBoost, który został zbudowany do prognozy i interpolacji temperatury na głębokości do 22 cm. Dzięki zastosowa-

the use of the time variable and the 3-hour measurement interval of humidity and surface temperature, a model capable of predicting temperature in the pavement profile across the entire domain of the experiment was obtained.

Recommendations for use in engineering practice:

- model selection – where the highest forecast accuracy is required and appropriate computational infrastructure is available, MODEL3 is recommended. It provides high precision and is able to reproduce both diurnal and seasonal temperature fluctuations. In projects requiring rapid updating or operation on devices with limited computing power, E_XGBoost is a better choice – the model learns quickly and offers the highest interpolation accuracy;

- maintenance applications data-driven models can support FWD/TSD deflection normalisation in real time based on available surface temperature measurements. Winter applications require separate validation on datasets covering the freezing period.

Directions for further research:

- development of a hybrid RNN–XGBoost model – the aim of further studies should be the design and testing of a model that combines sequential RNN processing with the decision function of XGBoost; such a hybrid could improve forecast accuracy while maintaining interpretability and operational speed;

- validation on other sections and in different climatic conditions – most existing studies have been conducted at a single measurement site; it is necessary to collect data from regions with different climatic conditions (e.g., mountainous, coastal areas) and verify how the models scale to new locations; re-tuning of parameters or the use of transfer learning may be required;

- physical use of physics-informed neural networks (PINN) – combining heat-conduction equations with machine learning may further improve the reproduction of physical processes and allow simultaneous estimation of material properties. Conducting PINN research in the context of road pavements may open new perspectives.

Analysis of the fit-quality metrics confirms that prediction bias increases closer to the surface, which has physical justification – the shallower layers display greater radiative amplitude and shorter thermal delay, and a model trained on 3-hour sequences does not fully account for this effect. Further research is planned with an extended sequence window and inclusion of solar radiation as a predictor. Moreover, the dataset does not include the winter period. Observing the promising results, the E_XGBoost model will be supplemented in the near future with additional datasets from that season of the year.

The article carried out analyses comparing RNN with gradient boosting (XGBoost), which showed that RNNs better capture nonlinear relationships and temporal dependencies, although their training is longer and they require larger datasets. In turn, XGBoost is faster and easier to interpret, but for sequence processing it requires additional data in the form of artificial delays. The presented conclusions and recommendations indicate the significant potential of machine

niu zmiennej czasowej oraz 3 h interwału pomiaru wilgotności i temperatury powierzchni uzyskano model zdolny do prognozowania temperatury w przekroju nawierzchni w całym zakresie dziedziny eksperymentu.

Rekomendacje do stosowania w praktyce inżynierskiej:

- wybór modelu – tam, gdzie najważniejsza jest dokładność prognozy i dostępna jest odpowiednia infrastruktura obliczeniowa, rekomenduje się użycie MODEL3. Zapewnia on dużą precyzję i jest w stanie odwzorować zarówno dobowe, jak i sezonowe wahania temperatury. W projektach wymagających szybkiej aktualizacji lub pracy na urządzeniach o ograniczonej mocy obliczeniowej lepszym wyborem będzie E_XGBoost – model szybko się uczy i oferuje najwyższą dokładność interpolacji;

- w zastosowaniach utrzymaniowych modele data-driven mogą wspierać normalizację ugięć FWD/TSD w czasie rzeczywistym na podstawie dostępnego pomiaru temperatury powierzchni. Zastosowania zimowe wymagają osobnej walidacji na zbiorach obejmujących porę mroźną.

Kierunki dalszych badań:

- rozwój hybrydowego modelu RNN–XGBoost – celem dalszych badań powinno być zaprojektowanie i przetestowanie modelu, który połączy sekwencyjne przetwarzanie RNN z funkcją decyzyjną XGBoost, taka hybryda mogłaby poprawić dokładność prognozy, a jednocześnie zachować interpretowalność i szybkość działania;

- walidacja na innych odcinkach i w różnych warunkach klimatycznych – większość dotychczasowych badań była prowadzona na jednym stanowisku pomiarowym, należy zebrać dane z innych regionów o odmiennych warunkach klimatycznych (np. tereny górskie, nadmorskie) i sprawdzić, jak modele skalują się w nowej lokalizacji; konieczne może być ponowne strojenie parametrów lub zastosowanie transfer learningu;

- fizyczne wykorzystanie informowanych sieci neuronowych (PINN) – połączenie równań przewodnictwa cieplnego z uczeniem maszynowym może jeszcze lepiej odwzorować procesy fizyczne i umożliwić jednoczesne szacowanie właściwości materiałowych. Przeprowadzenie badań nad PINN w kontekście nawierzchni drogowych może otworzyć nowe perspektywy.

Analiza metryk jakości dopasowania potwierdza, że obciążenie prognoz zwiększa się bliżej powierzchni, co ma uzasadnienie fizyczne – w płytszych warstwach występuje większa amplituda radiacyjna i krótsze opóźnienie cieplne, a model uczony na sekwencjach 3 h nie uwzględnia w pełni tego efektu. Dalsze badania planuje się z wydłużonym oknem sekwencji i uwzględnieniem nasłonecznienia jako predyktora. Ponadto zbiór danych nie obejmuje okresu zimowego. Obserwując obiecujące rezultaty, model E_XGBoost zostanie w najbliższej przyszłości wsparty dodatkowymi zbiorami danych z tego okresu roku.

W artykule przeprowadzono analizy porównujące RNN z gradientowym boostingiem (XGBoost), które wykazały, że RNN lepiej uchwytyują nieliniowe relacje i zależności czasowe, mimo że ich trening jest dłuższy i wymagają większego zbioru danych. Z kolei XGBoost jest szybszy i łatwiejszy w interpretacji, lecz do przetwarzania sekwencji wymaga do-

learning in predicting temperature within the pavement layer system and its importance for diagnostics and maintenance of road infrastructure. Further research should focus on hybridisation of methods, expansion of the data base and integration of models with traffic and weather management systems.

datkowych danych w postaci sztucznych opóźnień. Przedstawione wnioski i rekomendacje świadczą o dużym potencjale uczenia maszynowego w prognozowaniu temperatury w przekroju warstw nawierzchni i jego znaczeniu dla diagnostyki oraz utrzymania infrastruktury drogowej. Dalsze prace badawcze powinny koncentrować się na hybrydyzacji metod, rozszerzeniu bazy danych i integracji modeli z systemami zarządzania ruchem i pogodą.

Received: 20.07.2025

Revised: 10.10.2025

Published: 23.12.2025

Artykuł wpłynął do redakcji: 20.07.2025 r.

Otrzymano poprawiony po recenzjach: 10.10.2025 r.

Opublikowano: 23.12.2025 r.

Literature

- [1] Xiao Q, Wang XD, Zhou XY, Zhang L, Guan W.: Temperature Correction Method of Deflection Basin and Stress/Strain Response of Asphalt Pavement. In: Chabot, A., Hornych, P., Harvey, J., Loria-Salazar, L. (eds) Accelerated Pavement Testing to Transport Infrastructure Innovation. Lecture Notes in Civil Engineering, vol 96. Springer, Cham. DOI: 10.1007/978-3-030-55236-7_62.
- [2] Gu X, Liang X, Dong Q. Numerical Simulation of Long Term Pavement Temperature Field. Proceedings of GeoShanghai 2018 International Conference: Transportation Geotechnics and Pavement Engineering, Springer. 2018. DOI: 10.1007/978-981-13-0011-0_43
- [3] Zhang N, Wu G, Chen B, Cao C. Numerical Model for Calculating the Unstable State Temperature in Asphalt Pavement Structure. Coatings. 2019. DOI: 10.3390/coatings9040271.
- [4] Bai S, Yang W, Zhang M, Liu D, Li W, Zhou L. Attention-Based BiLSTM Model for Pavement Temperature Prediction of Asphalt Pavement in Winter. Atmosphere. 2022. DOI: 10.3390/atmos13091524.
- [5] Sudyka J, Mechowski T, Harasim P, Graczyk M, Matysek A. Optimisation of BELLS3 model coefficients to increase the precision of asphalt layer temperature calculations in FWD and TSD measurements. Roads and Bridges – Drogi i Mosty. 2024. DOI: 10.7409/rabdim. 024.021.
- [6] Adwan I, Milad A, Memon ZA, Widyatmoko I, Zanuri NA, Memon NA, Yusoff NIM. Asphalt Pavement Temperature Prediction Models: A Review. Applied Sciences. 2021. DOI: 10.3390/app11093794.
- [7] Mansour F, Shahni DR. Pavement structural evaluation based on roughness and surface distress survey using neural network model. Construction and Building Materials. 2019. DOI: 10.1016/j.conbuildmat. 2019.01.142.
- [8] Younos MA, AbdEl Hakim RT, El Badawy SM, Afify HA. Multi-input performance prediction models for flexible pavements using LTPP database. Innovative Infrastructure Solutions. 2020. DOI: 10.1007/s41062-020-0275-3.
- [9] Sun Y, Meng S, Wang M, Mu H, Tang X. Deterioration effect of freeze-thaw on mechanical properties of roadbed clay under unfavorable conditions. Bull Eng Geol Environ. 2021; <https://doi.org/10.1007/s10064-021-02203-8>.
- [10] Breiman L. Random Forests. Machine Learning. 2001. DOI: 10.1023/A: 1010933404324.
- [11] Friedman JH. Greedy Function Approximation: A Gradient Boosting Machine. Annals of Statistics. 2001. DOI: 10.1214/aos/1013203451.
- [12] Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016. DOI: 10.1145/2939672.2939785.
- [13] Sudyka J, Mazurek G. Determination of asphalt layer temperature in FWD and TSD measurements using machine learning. Roads and Bridges – Drogi i Mosty. 2025; <https://doi.org/10.7409/rabdim. 025.015>
- [14] Hochreiter S, Schmidhuber J. Long Short-Term Memory. Neural Computation. 1997. DOI: 10.1162/neco. 1997.9.8.1735.
- [15] Koné A, Es-Sabar A, Do M-T. Application of Machine Learning Models to the Analysis of Skid Resistance Data. Lubricants 2023. DOI: 10.3390/lubricants11080328.
- [16] Dilip DM. Thermal Digital Twins of Asphalt Pavements using Physics-informed Neural Networks Proceedings of the 9th World Congress on Civil, Structural, and Environmental Engineering (CSEE 2024), London, United Kingdom – April 14-16, 2024. DOI: 10.11159/icgre24.157.
- [17] Milad AA, Adwan I, Majeed SA, Memon ZA, Bilema M, Omar HA. Development of a Hybrid Machine Learning Model for Asphalt Pavement Temperature Prediction. IEEE Access. 2021. DOI: 10.1109/ACCESS. 2021.3129979.
- [18] Piryonesi SM, El Diraby TE. Using Machine Learning to Examine Impact of Type of Performance Indicator on Flexible Pavement Deterioration Modeling. Journal of Infrastructure Systems. 2021. DOI: 10.1061/(ASCE)IS. 1943-555X. 0000602.
- [19] Kalman RE. A new approach to linear filtering and prediction problems. Journal of Basic Engineering. 1960. DOI: 10.1115/1.3662552
- [20] Chollet FJ J, Allaire, Matuk K. Deep learning: praca z językiem R i biblioteką Keras. Gliwice: Helion, 2019.
- [21] Park J. et al. Evaluation of statistical gap fillings for continuous energy flux (evapotranspiration) measurements for two different land cover types. Stoch Environ Res Risk Assess. 2015. DOI: 10.1007/s00477-015-1101-x.