

Predikce únavové životnosti asfaltového betonu pomocí neuronových sítí



Ing. Jakub Houlík
ČVUT v Praze
Fakulta stavební
Katedra silničních staveb



doc. Ing. Václav Nežerka, Ph.D.
ČVUT v Praze
Fakulta stavební
Katedra fyziky



doc. Ing. Jan Valentin, Ph.D.
ČVUT v Praze
Fakulta stavební
Katedra silničních staveb

Životnost asfaltového betonu (AC) je výrazně ovlivněna jeho odolností vůči únavě. Tradiční metody hodnocení únavové životnosti jsou časově náročné a vyžadují značné množství zdrojů, přičemž dosavadní aplikace umělých neuronových sítí (ANN) neuváděly detailní popis svých architektur, ani nevyužívaly rozsáhlé datové soubory. Naše studie využívá ANN k predikci únavové životnosti AC, přičemž se zaměřuje na úroveň přetvoření, obsah pojiva, mezerovitost a pracuje s datovým souborem o 245 zkušebních tělesech. Pro zvýšení predikční schopnosti ANN jsme optimalizovali hyperparametry a jako ztrátovou funkci použili střední kvadratickou logaritmickou chybu. Naše výsledky ukazují zlepšenou přesnost predikce únavové životnosti, přičemž zvláštní význam byl přisuzován obsahu pojiva. Tento přístup posouvá možnosti a transparentnost aplikace ANN při predikci únavové životnosti AC.

Klíčová slova: asfaltový beton, únavová životnost, obsah pojiva, mezerovitost, strojové učení

The fatigue life of asphalt concrete (AC) is significantly influenced by its fatigue resistance. Traditional methods for fatigue life assessment are time-consuming and resource-intensive, and previous applications of artificial neuron networks (ANN) have not provided a detailed description of their architectures or used large datasets. Our study uses ANN to predict the fatigue life of AC, focusing on the level of strain, binder content, void content, and working with a dataset of 245 test specimens. To increase the predictive ability of the ANN, we optimized the hyperparameters and used the root mean square logarithmic error as the loss function. Our results show improved accuracy of fatigue life prediction, with special importance being attributed to the binder content. This approach advances the possibilities and transparency of the application of ANN in predicting the fatigue life of AC.

Keywords: asphalt concrete, fatigue life, binder content, voids, machine learning

ÚVOD

Únavová životnost asfaltového betonu je klíčovým parametrem, který zásadním způsobem ovlivňuje náklady na údržbu [2]. Z tohoto důvodu by měl AC odolávat cyklickému zatížení těžkou silniční dopravou v různých klimatických podmínkách a zvládat kumulativní poškození bez nadměrného vzniku trhlin [3, 4]. Hlavním faktorem degradace AC a omezené schopnosti odolávat opakovaným tahovým napětím je stárnutí asfaltového pojiva způsobené oxidací [5, 6]. K porušení dochází, když materiál již nedokáže odolávat aplikovanému tahovému namáhání [7]. Nízké teploty způsobují zvýšenou křehkost materiálu a v přípa-

dě mrazu dochází k otevírání trhlin vlivem ledu [8], zatímco vysoké teploty činí asfaltová pojiva viskóznějšími a náchylnějšími k tečení [9].

Odolnost vůči únavě je ovlivněna několika faktory, zejména obsahem pojiva [8], obsahem vzduchových dutin [10, 11], velikostí přetvoření [12, 13] a provozní teplotou [14, 13]. Únavová odolnost se obvykle hodnotí pomocí různých laboratorních metod, z nichž nejčastější jsou čtyřbodový ohybový test (4PB), polokruhový ohybový test a nepřímý tahový test. Čtyřbodový ohybový test zkoumá chování materiálu při únavě za ohybového

zatížení a stanovuje únavovou životnost, tuhost a pevnost [15, 16, 17, 18]. Polokruhový ohybový test, který je podobného charakteru, umožňuje navíc hodnocení lomové houževnatosti [19, 20]. Nepřímý tahový test spočívá v aplikaci opakovaného tahového zatížení na válcové vzorky AC prostřednictvím diametrálního stlačení a měří počet cyklů do porušení (N_f) nebo akumulované přetvoření při konstantní frekvenci a amplitudě zatížení [21, 18, 22].

Porozumění vztahům mezi únavovou životností asfaltového betonu, jeho složením, klimatickými podmínkami a rychlostí zatížení je klíčové pro správný návrh směsi, avšak rozsáhlé testování je časově náročné. Standardizované testovací postupy vyžadují 14–42 dní na přípravu vzorků a jejich řádné vysušení [23], přičemž samotný test trvá od několika hodin až po několik dní v závislosti na úrovni a frekvenci zatěžování. Přestože standardizované testovací metody poskytují cenné informace, jsou náročné na čas. Využitím modelů strojového učení (ML) a již nasbíraných dat lze únavovou životnost AC predikovat i v situacích, kdy není možné provádět časově náročné testy.

Řada studií se podrobně zabývala různými aspekty, jako jsou základní mechanismy a strategie pro omezení negativních vlivů, přičemž zdůrazňují složité interakce mezi složkami asfaltového betonu a vliv vnějších faktorů, jako je stárnutí a klimatické podmínky, na jeho únavové chování [3, 2, 24, 25]. Nedávné studie zaměřené na návrh směsí s využitím strojového učení [26, 27, 28] vytvořily základ pro vývoj modelů, které integrují širší škálu proměnných pro predikci únavové životnosti.

Přestože některé klíčové faktory, jako typ asfaltu a kameniva, byly označeny za významné, náš model se zaměřuje na obsah pojiva (%) a mezerovitost (%), které jsou konzistentně uváděny v literatuře jako klíčové pro dlouhou životnost asfaltových povrchů, jak identifikoval [29]. Vyloučení typu asfaltu a kameniva bylo záměrným rozhodnutím vzhledem k velké variabilitě těchto materiálů, což by vyžadovalo rozsáhlý testovací program přesahující rozsah této studie.

METODIKA

Metodologie naší studie zahrnovala použití ANN k predikci N_f asfaltového betonu. Naše predikce byly založeny na existujících datových souborech získaných výhradně během 4PB

testů prováděných při konstantním přetvoření. Tento přístup byl zvolen, protože je široce používán v oboru, což zajišťuje dostupnost rozsáhlého a robustního datového souboru pro trénování a validaci modelu.

SBĚR DAT

Data použitá pro trénink a testování modelu byla získána ze čtyř vybraných recenzovaných vědeckých publikací, které byly zvoleny díky konzistentní metodice testování (4PB, 20 °C, 10 Hz), což zajišťuje srovnatelnost dat navzdory omezenému počtu zdrojů. Tyto publikace poskytly klíčové parametry, jako je obsah pojiva (%), mezerovitost (%), zatěžovací přetvoření (ϵ), teplota testu, frekvence zatížení (f) a počet cyklů do porušení (N_f).

Náš datový soubor zahrnuje výhradně vzorky podrobené testům 4PB při teplotách 20 °C a 70 °C (21,1 °C). Analýza zahrnovala celkem 245 vzorků (tab. 1). Pro poskytnutí komplexního přehledu o datech extrahovaných z literatury obsahuje tabulka také položky, které nesplňují naše výběrová kritéria, označené jako „Ne“. Přestože tyto vzorky nebyly zahrnuty do finálního datového souboru pro modelování, jejich uvedení v tabulce zdůrazňuje úplný rozsah našeho sběru dat a usnadňuje možnost budoucích meta-analýz nebo alternativních modelovacích přístupů, kde by mohly být tyto vzorky relevantní.

Vzorky v analyzovaných studiích byly připraveny a testovány v laboratorních podmínkách, avšak mezi jednotlivými studiemi se mírně lišily, což přispělo k variabilitě datového souboru. Autoři [30] použili kamenivo s maximální jmenovitou velikostí

tab. 1 Souhrn dat dostupných ze studií poskytujících data únavových vlastností asfaltových směsí

Zdroj	Obsah pojiva (%)	Mezerovitost (%)	ϵ ($\times 10^{-6}$)	Teplota (°C)	f (Hz)	N_f ($\times 10^3$)	Počet vzorků	Použito pro model
[30]	4,0–6,0	1,3–7,7	500–1000	20	10	4–1588	22	Yes
[31]	4,7–6,5	1,2–12,8	115–800	20	10	3–19500	115	Yes
[32]	4,7–6,7	4,0–4,1	400–1000	20	10	1–152	38	Yes
[33]	4,2–5,2	3,9–11,3	100–500	4,4; 21,1; 37,8	10	2–700	229	Yes ^a
[34]	N/A	N/A	400–1000	20	10	5–490	32	No ^b
[35]	3,7–6,3	2,1–4,3	N/A	10	10	N/A	5	No ^c
[36]	5,1	4,0	N/A	20; 30	3; 5; 8; 10	N/A	40	No ^c
[37]	4,0–6,0	1,2–8,9	150–300	19	10	14–1472	30	No ^c
[38]	N/A	3,4–4,7	N/A	20	10	0–3365	72	No ^c
[8]	3,8–4,2	4,0–6,2	N/A	N/A	N/A	149–1958	12	No ^b
[39]	6,3–12,0	2,9–23,8	N/A	5; 15; 25; 35	10	N/A	96	No ^c
[40]	N/A	N/A	300–1000	20	10	3–446	5	No ^b
[41]	5,0–5,5	7,0	600	25	10	83–117	4	No ^d
[42]	4,0–7,0	2,2–6,2	500–1500	5	N/A	0–37	54	No ^d
[43]	4,2–5,2	3,4–10,0	75–200	20	10	3–676	21	No ^c
[44]	6,5–6,6	6,0	202–1032	7; 13; 20	10	1–230	38	No ^c
[45]	5,8–7,3	3,5–4,5	75–500	25	10	0–43900	24	No ^c
Pro modelování	4–6,7	1,2–12,8	115–1000	20	10	0–19500	245 ^e	—

^a Pouze data získaná při 70 °F

^b Chybějící informace o obsahu pojiva, mezerovitosti nebo teplotě.

^c Jiná měřicí metoda než 4PB.

^d Jiná testovací teplota než 20 °C/70 °F

^e Pouze vzorky testované při 70 °F od [33] byly použity, aby byl zajištěn soulad s námi zvolenými teplotními parametry.

zrna 19 mm a testovali dva typy pojiva: PG 64-22 a PG 76-22. Autoři [32] hodnotili tři druhy směsí: asfaltový beton, hutněný asfaltový makadam a směsí s mastixovým asfaltem. Do směsí zahrnuli čtyři typy pojiv, včetně modifikací se styren-butadien-styrenem (SBS) a etylen-acetátem, přičemž cílili na obsah vzduchových dutin 4 %. Autoři [31] rovněž použili granitové kamenivo s maximální jmenovitou velikostí zrna 19 mm a zkoumali tři druhy asfaltových pojiv: 10/20, 35/50 a SBS 50/70. Podobně autoři [33] použili kamenivo se stejnou maximální jmenovitou velikostí 19 mm a testovali tři druhy asfaltových pojiv: PG 58-28, PG 64-22 a PG 76-16.

Původní rozložení hodnot N_f vykazovalo výraznou šikmost způsobenou především dlouhým „ocasem“ dat N_f (obr. 1 a 2). Abychom tuto šikmost odstranili a zajistili vhodnost datového souboru pro detekci odlehklých hodnot, aplikovali jsme Box-Coxovu transformaci. Tato metoda normalizuje data nalezením optimálního transformačního parametru λ [46; 47]:

$$N_f^{BC}(\lambda) = \frac{N_f^\lambda - 1}{\lambda}$$


kde λ je transformační koeficient. Optimální hodnota λ pro náš datový soubor byla určena jako $\lambda = -0,09$. Pro zhodnocení účinku normalizace jsme provedli Shapiro-Wilkův test [48] a analyzovali Q-Q grafy, přičemž jsme porovnali původní data, logaritmičsky transformovaná data a data transformovaná metodou Box-Cox (obr. 1). Původní data vykazovala výraznou šikmost, což se projevilo v Q-Q grafu i v histogramu s dlouhým „ocasem“. Logaritmičská transformace sice šikmost snížila, ale zcela normality nedosáhla, což potvrzují přetrvávající odchylky v Q-Q grafu a nízká hodnota p ve Shapiro-Wilkově testu. Box-Coxova transformace s $\lambda = -0,09$ poskytla nejvíce normalizované rozložení, které se těsně přiblížilo teoretické normální linii v Q-Q grafu a vytvořilo histogram s minimální šikmostí.

Po transformaci dat jsme použili prahovou hodnotu Z-skóre 3,0 k detekci potenciálních odlehklých hodnot. Tato prahová hodnota byla zvolena na základě doporučení [49] a [50], aby byla v souladu s běžně přijímanými postupy. Z-skóre bylo vypočteno podle vzorce:

$$Z = \frac{N_{f,i} - \mu}{\sigma}$$

kde $N_{f,i}$ představuje jednotlivý datový bod, μ je průměr a σ je směrodatná odchylka transformovaného datového souboru.

Je důležité poznamenat, že žádný datový bod nepřekročil prahovou hodnotu Z-skóre, což naznačuje, že v transformovaném



obr. 1 Q-Q grafy (vlevo) a histogramy rozložení (vpravo) pro datový soubor N_f před a po transformacích porovnávající dataset s teoretickým normálním rozložením

datovém souboru nebyly přítomny žádné odlehklé hodnoty. Původní datový soubor tak byl zachován bez další filtrace, což umožnilo využít všechna dostupná data pro trénování a vyhodnocení modelu.

Konečné rozložení a statistiky sesbíraných dat jsou shrnuty v tab. 2, zatímco párové grafy s rozloženími jednotlivých parametrů jsou zobrazeny na obr. 2. Rozložení N_f (obr. 2) odhaluje výraznou šikmost, přičemž většina hodnot je koncentrována pod $0,2 \times 10^6$, s dlouhým „ocasem“ směřujícím k vyšším hodnotám únavové životnosti. Je také zřejmé, že jednotlivé parametry jsou na sobě nezávislé (nízké hodnoty korelačního koeficientu ρ) a že N_f klesá s nárůstem ε .

Tabulka 2 obsahuje podrobné statistiky pro obsah pojiva, mezerovitost, ε a N_f , včetně minimálních a maximálních hodnot, prvního kvartilu (Q1), třetího kvartilu (Q3), průměru, směrodatné odchylky a mediánu, což poskytuje ucelený přehled o datovém souboru.

tab. 2 Statistiky sesbíraného datového souboru zahrnující obsah pojiva (%), mezerovitost (%), $\varepsilon (\times 10^{-6})$ a $N_f (\times 10^3)$

	Obsah pojiva	Mezerovitost	ε	N_f
	(%)	(%)	$\times 10^{-6}$	$\times 10^3$
Minimum	4	1,2	115	0,8
Q1	4,7	4	200	15,4
Q3	6,4	6,6	750	255
Maximum	6,7	12,8	1000	19500
μ	5,4	5,9	426	1136
σ	0,84	2,85	263	3075
Medián	5,2	5,6	375	67,6

UMĚLÉ NEURONOVÉ SÍTĚ (ANN)

ANN jsou vysoce efektivní při zpracování tabulárních numerických dat, což z nich činí ideální nástroj pro predikci únavové životnosti. Model rozděljuje váhy jednotlivým vstupním proměnným a kombinuje je prostřednictvím několika skrytých vrstev za účelem generování výstupu (obr. 3). Tyto váhy jsou iterativně upravovány na základě validačních dat, což postupně zlepšuje přesnost modelu.

Predikční model jsme vyvinuli pomocí Sequential modelu z knihovny Keras ve verzi 2.12.0rc1. Před samotným trénováním byla data normalizována pomocí funkce MinMaxScaler z modulu sklearn.preprocessing, která škáluje vstupní proměnné do intervalu od 0 do 1. Sequential model byl nakonfigurován s následujícími hyperparametry: počet skrytých vrstev (n_h), počet neuronů v každé skryté vrstvě ($n_{neur,h}$), aktivační funkce a optimalizační algoritmus (tab. 3). Tyto hyperparametry byly systematicky variovány minimalizací vybrané ztrátové funkce během trénování, přičemž jako primární metrika pro vyhodnocení prediktivní schopnosti modelu sloužil koeficient determinace (R^2). Koeficient determinace R^2 je definován jako:

$$R^2 = 1 - \frac{\sum_{i=1}^n (N_{f,i} - \hat{N}_{f,i})^2}{\sum_{i=1}^n (N_{f,i} - \bar{N}_f)^2}$$

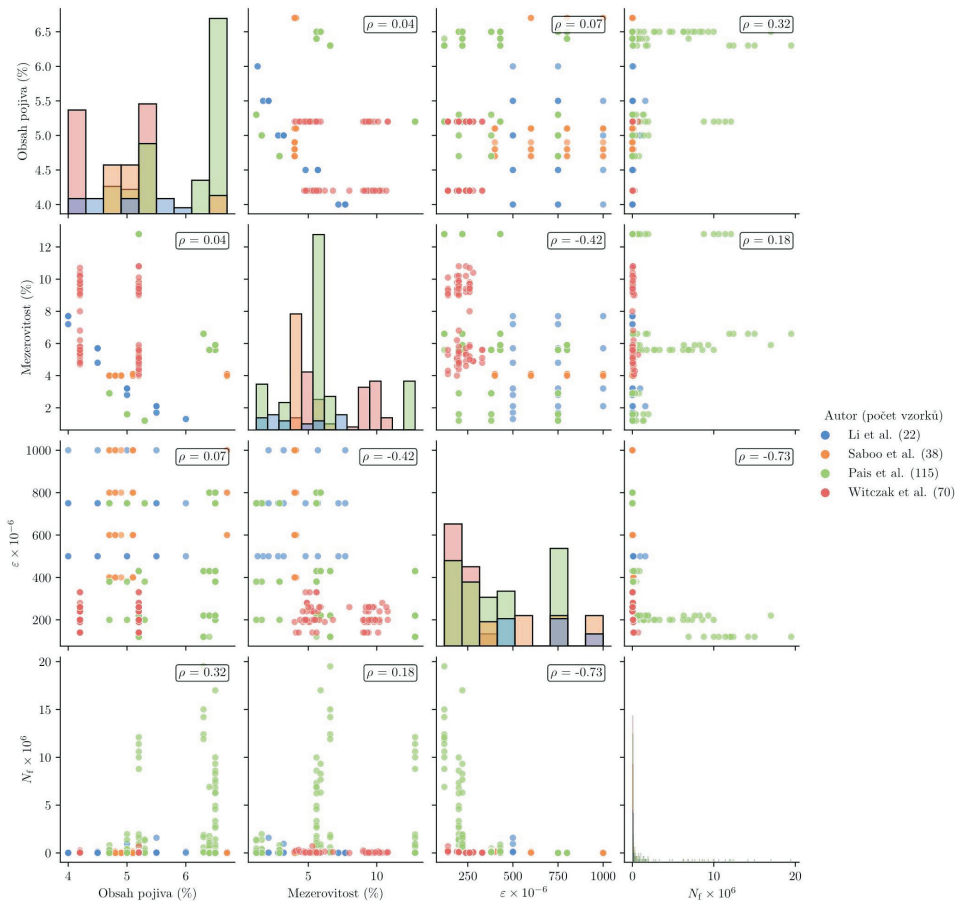
kde $N_{f,i}$ představuje naměřenou výstupní hodnotu, $\hat{N}_{f,i}$ je predikce modelu, $\bar{N}_f$ je průměr hodnot $N_{f,i}$ a n je počet vzorků.

Kromě R^2 jsme pro hodnocení výkonu modelu dále použili upravený koeficient determinace R^2_{adj} a scatter index (SI). Upravený R^2_{adj} zohledňuje počet prediktorů p v modelu a je definován jako:


$$R^2_{adj} = 1 - \frac{(1 - R^2)(n - 1)}{n - p - 1}$$

a pomáhá posoudit, jak dobře se model generalizuje, aniž by docházelo k přeučení. Scatter index (SI) ukazuje, jak se chyby modelu porovnávají s celkovým měřítkem datového souboru, a je definován jako:

$$SI = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (N_{f,i} - \hat{N}_{f,i})^2}}{\frac{1}{n} \sum_{i=1}^n N_{f,i}}$$



obr. 2 Párové bodové grafy a rozložení sesbíraných dat, rozdělené podle jednotlivých studií, ukazují vzájemné vztahy mezi sledovanými parametry. Rozložení N_f vykazuje výraznou koncentraci hodnot pod $0,2 \times 10^6$ a dlouhý „ocas“ reprezentující vyšší hodnoty únavové životnosti. Pro všechny párové vztahy jsou uvedeny Spearmanovy korelační koeficienty (ρ), které zdůrazňují monotónní asociace mezi jednotlivými parametry



obr. 3 Schéma architektury umělé neuronové sítě (ANN) použité pro modelování, znázorňující parametry sítě

kde číselník představuje kořen střední kvadratické chyby (RMSE) a jmenovatel průměr naměřených dat.

Během trénování jsme se zaměřili na minimalizaci ztrátové funkce, přičemž jsme vždy ukládali verzi modelu, která dosáhla nejnižší hodnoty ztráty pro validační data. Tato verze modelu představuje nejpresnější predikce, avšak bez známek přeučení. Vzhledem k širokému rozptylu dat N_f , která jsou obvykle reprezentována na logaritmické škále, aby bylo možné zachytit jejich

rozsah, jsme použili dvě odlišné ztrátové funkce: (1) střední kvadratická chyba L_{MSE} , definovaná jako

$$L_{MSE}(N_f, \hat{N}_f) = \frac{1}{n} \sum_{i=1}^n (N_{f,i} - \hat{N}_{f,i})^2$$

a (2) střední kvadratická logaritmická chyba L_{MSLE} , definovaná jako

$$L_{MSLE}(N_f, \hat{N}_f) = \frac{1}{n} \sum_{i=1}^n (\log(N_{f,i} + 1) - \log(\hat{N}_{f,i} + 1))^2$$

Tato strategická volba měla za cíl optimalizovat naše modely s ohledem na logaritmickou povahu variability únavové životnosti. Použití obou ztrátových funkcí L_{MSE} a L_{MSLE} nám umožnilo jemně doladit citlivost modelu na rozsah dat.

Model ANN byl trénován po 200 000 epoch při použití L_{MSE} respektive 100 000 epoch při použití L_{MSLE} , aby bylo zajištěno dostatečné množství iterací potřebných pro efektivní proces učení.

tab.3 Testované hyperparametry během vývoje modelu a hodnoty vybrané pro finální model

Hyperparametr	Testované parametry	Vybrané hodnoty
Ztrátová funkce	L_{MSE} , L_{MSLE}	Obě
Optimalizační algoritmus	Adam; Nadam; RMSprop	RMSprop
Aktivační funkce	ReLU; Linear; Sigmoid	ReLU
n_h	1; 2; 3; 4	2
$n_{neur,h}$	10; 50; 100; 150; 200	200

Pro zajištění robustnosti a spolehlivosti našeho modelu ANN jsme rozdělili datový soubor na testovací sadu (25 %) a trénovací sadu (75 %). Z těchto 75 % trénovací části bylo dále vyčleněno 20 % pro validaci a 80 % pro samotné trénování. Kromě toho jsme na trénovací sadě použili přístup čtyřnásobné křížové validace, implementovaný pomocí třídy `sklearn.model_selection.KFold`. V každém cyklu křížové validace byla jedna část (fold) použita pro validaci, zatímco zbývající tři části sloužily k trénování. Tento proces byl opakován pro všechny části, což minimalizovalo riziko přeučení modelu na specifické podmnožiny dat a zajistilo důkladné hodnocení modelu. Čtyřnásobnou křížovou validaci jsme zvolili jako kompromis mezi výpočetní efektivitou a zachováním dostatečného množství dat v každé části. Před samotným rozdělením dat funkcí `KFold` byla data náhodně promíchána, čímž byla zajištěna rovnoměrná a náhodná distribuce dat mezi jednotlivé části.

Modelování a následné trénování bylo prováděno na notebooku Dell XPS 9870 s následujícími specifikacemi: procesor Intel(R) Core(TM) i7-8550U CPU (1,80 GHz), 16 GB RAM, pevný disk PM981 NVMe Samsung SSD a operační sys-


tém Windows 11. Kód byl vyvíjen v jazyce Python, verze 3.10.14. Na tomto hardwaru trvalo trénování jednoho modelu pro 200 tisíc epoch přibližně 1 až 1,5 hodiny, v závislosti na složitosti modelu a konkrétním nastavení hyperparametrů.

VÝSLEDKY A DISKUSE


1 Hyperparametry

Před laděním hyperparametrů ANN jsme otestovali více konfigurací a zjistili, že ReLU konzistentně poskytuje lepší výkon. Zatímco ReLU snižuje problém mizejícího gradientu, může trpět jevem známým jako „mrtvé ReLU“, kdy se neurony stávají neaktivními v důsledku velkých záporných vah nebo posunů. Proto jsme ReLU spojili s optimalizačním algoritmem RMSprop.

Na základě těchto poznatků jsme provedli podrobnou analýzu za účelem stanovení optimálního nastavení počtu skrytých vrstev a počtu neuronů ve vrstvě. Tyto konfigurace jsme testovali ve vztahu k oběma ztrátovým funkcím, L_{MSE} a L_{MSLE} (obr. 4 a 5). Analýza ukázala, že struktura s $n_h=2$ a $n_{neur,h}=200$ dosáhla nejvyšší hodnoty průměrného koeficientu determinace $\bar{R}^2$, vypoč-



obr. 4 Variace výkonu modelu, měřená hodnotou (průměrný koeficient determinace napříč různými částmi křížové validace), v závislosti na počtu skrytých vrstev n_h (vlevo) a počtu neuronů na vrstvu $n_{neur,h}$ (vpravo) při použití ztrátové funkce L_{MSE} , optimalizátoru RMSprop a aktivační funkce ReLU




obr. 5 Variace výkonu modelu, měřená hodnotou (průměrný koeficient determinace napříč různými částmi křížové validace), v závislosti na počtu skrytých vrstev n_h (vlevo) a počtu neuronů na vrstvu $n_{neur,h}$ (vpravo) při použití ztrátové funkce L_{MSLE} , optimalizátoru RMSprop a aktivační funkce ReLU

teného jako průměr hodnot R^2 ze všech čtyř částí křížové validace.

Další hodnocení různých aktivačních funkcí v rámci této konfigurace potvrdilo, že ReLU byla nejlepší volbou. Lineární aktivační funkce vedly k omezené přesnosti predikcí, zatímco sigmoid poskytoval výsledky blízké 0, což naznačovalo nedostatečný výkon modelu. Tento výsledek zdůrazňuje výhodu ReLU ve vypořádání se s nelinearitami v hlubokých sítích, což je klíčové pro efektivní predikci únavové životnosti.

Při porovnávání efektivity různých optimalizačních algoritmů byl jejich vliv méně výrazný, avšak optimalizátor RMSprop při použití aktivační funkce ReLU konzistentně poskytoval lepší výkon jak pro L_{MSE} , tak pro L_{MSLE} (obr. 6). RMSprop upravuje rychlost učení pomocí klouzavého průměru druhých mocnin gradientů, což zajišťuje stabilitu v prostředích s šumem tím, že vyhlazuje aktualizace [51]. Optimalizátor Adam adaptivně upravuje rychlost učení pomocí úpravy vah [52; 53]. Na druhou stranu Nadam, který integruje Nesterovův moment do struktury optimalizátoru Adam, urychluje aktualizace modelu [16]. Tento přístup však může někdy vést k „přestřelení“ minimálních nebo optimálních hodnot, případně k problémům se stabilizací na složitých, nerovnoměrných površích ztrátové funkce. Ačkoli Nadam může přinést rychlejší konvergenci, jeho agresivní aktualizací strategie může způsobit nestabilitu a nižší hodnoty R^2 , zejména při práci s nerovnoměrnými distribucemi dat nebo odlehilými hodnotami.




obr. 6 Výkon modelu, měřený hodnotou (průměrný koeficient determinace napříč různými částmi křížové validace), v závislosti na použitých aktivačních funkcích a optimalizátorech při použití ztrátových funkcí L_{MSE} (vlevo) a L_{MSLE} (vpravo). Pro oba modely byla použita konfigurace $n_h=2$ a $n_{neur,h}=200$

2 Přesnost modelu

Konvergence během trénování byla efektivněji dosažena při použití L_{MSE} (obr. 7). Tato hladší konvergence vyplývá z linearity L_{MSE} , která zjednodušuje optimalizaci vah modelu. Naopak L_{MSLE} , která do výpočtu ztrátové funkce zavádí logaritmickou transformaci, přinesla větší výzvy v oblasti konvergence. Nelineární škálování v L_{MSLE} komplikuje optimalizační proces, protože nerovnoměrně upravuje přírůstky jednotlivých chyb, což komplikuje přesné doladění vah modelu.


Při hodnocení modelů výhradně na testovacích datech dosáhla lineární ztrátová funkce vyšší hodnoty $R^2=0,967$ než logaritmická ztrátová funkce s $R^2=0,86$. Hodnoty R^2_{adj} byly podobné hodnotám běžného R^2 , což naznačuje, že přidání dalších predik-



obr. 7 Grafy konvergence trénování znázorňující průběh trénovacího procesu během 200 000 epoch pro L_{MSE} (vlevo) a 100 000 epoch pro L_{MSLE} (vpravo)

torů nezpůsobilo výrazné nadhodnocení koeficientu determinace. Naopak scatter index se mezi oběma přístupy významně lišil: dosáhl hodnoty 0,926 pro L_{MSLE} a pouze 0,503 pro L_{MSE} . Tento rozdíl odráží tendenci logaritmické ztrátové funkce lépe zachycovat vzorky s nízkými hodnotami N_f , což je v souladu s výsledky studií uvádějících nižší rozsahy únavové životnosti. Na druhou stranu lineární ztrátová funkce lépe odpovídá pozorováním s vysokými hodnotami N_f . Z tohoto důvodu je L_{MSLE} výhodná při charakterizaci rozložení únavové životnosti na nižším konci spektra, přestože L_{MSE} může poskytovat vyšší hodnotu R^2 při analýze celého datového souboru.

ANN byly úspěšně použity k predikci únavových vlastností asfaltového betonu i dalšími autory. Studie [2] představila model ANN, který dosáhl $R^2=0,93$ pro celý datový soubor, přičemž využíval jednoduchou architekturu s pozoruhodnou predikční přesností. Tato studie však čerpala data výhradně z reportu [33] a zaměřila se na predikci ε na základě hodnot N_f . Model byl vyvinut v prostředí MATLAB jako třívrstvá dopředná neuronová síť s jednou skrytou vrstvou a aktivační funkcí sigmoid. Využíval čtyři vstupní parametry: poměr tuhosti při určitém počtu cyklů, počáteční tuhost, dobu odpočinku a počet cyklů, pro predikci ε .



obr. 8 Porovnání skutečných a predikovaných hodnot pro testovací datovou sadu při použití L_{MSE} (vlevo) a L_{MSLE} (vpravo); uvedené metriky zahrnují R^2 , R^2_{adj} a SI , který je hodnocen jak pro celou testovací datovou sadu, tak pro jednotlivé studie zvlášť v legendě

Další studie, kterou představili [3], zkoumala použití ANN k predikci únavových vlastností se zaměřením na obsah vzduchových dutin (mezerovitost) a dutin vyplněných asfaltem, přičemž dosáhla vysoké predikční přesnosti (R^2 až 0,97). Jejich datový soubor však zahrnoval směsi pryžového asfaltového betonu obsahující recyklovaný asfalt a byl méně složitý s nižší variabilitou ve srovnání s naším datovým souborem. Zatímco


jejich výsledky zdůrazňují potenciál ANN pro predikci únavové životnosti, snížená variabilita v jejich datech mohla přispět k vysoké přesnosti.

Studie [24] navíc porovnávala tradiční regresní modely pro predikci únavových cyklů asfaltu, přičemž dosáhla nejvyšší hodnoty $R^2=0,78$. Vztah mezi počáteční tuhostí a únavovými vlastnostmi asfaltových směsí zkoumali [25], přičemž jejich hodnoty R^2 se pohybovaly v rozmezí od 0,30 do 0,86 v závislosti na použitých datových souborech.

Studie [42] se zabývá konstrukcí ANN pro predikci N_f , přičemž jejich práce explicitně popisuje klíčové vstupy, včetně obsahu asfaltu (4 %, 5,5 % a 7 %), úrovní mezerovitosti (2,16–6,22 %) a úrovní přetvoření ($500\text{--}1\,500 \times 10^{-6}$), stejně jako podmínky testování, například test únavy 4PB prováděný při 5 °C v režimu řízeného přetvoření. Jejich model ANN s třívrstvou dopřednou strukturou a jednou skrytou vrstvou dosáhl vysoké predikční přesnosti $R^2=0,91$. Studie však byla založena na omezeném datovém souboru pouze 27 vzorků, což může omezit obecnou použitelnost jejich závěrů.


PRAKTICKÉ VÝSLEDKY

Další analýza zahrnovala generování grafů částečné závislosti (obr. 9 a 10) a (obr. 11 a 12) pro zkoumání vztahů mezi vstupními parametry a predikovanými hodnotami N_f u obou modelů. Tyto grafy byly vytvořeny s důsledným respektováním rozptylu vstupních dat, aby se zabránilo extrapolaci, která by mohla vést k nespolehlivým výsledkům. Datové body vstupů jsou označeny bílými trojúhelníkovými značkami. Predikce byly provedeny při dvou úrovních přetvoření, 200×10^{-6} a 400×10^{-6} . Výsledky ukazují, že nižší mezerovitost (ideálně pod 3 %) koreluje s delší únavovou životností. Podobně bylo zjištěno, že zvýšení obsahu pojiva prodlužuje únavovou životnost, přičemž modely založené na L_{MSE} naznačují, že vysoké úrovně obsahu pojiva (nad 5,5 %) mohou zmírnit nepříznivé účinky vysokého obsahu vzduchových dutin.



obr. 9 Grafy částečné závislosti vytvořené pomocí kalibrovaného modelu trénovaného s L_{MSE} , znázorňující vztah mezi vstupními parametry a predikovanými hodnotami N_f při dvou úrovních přetvoření (graf vlevo a vpravo). Datové body ležící uvnitř konvexního obalu naměřeného datového souboru jsou zobrazeny jako bílé trojúhelníkové značky


Oba modely se shodují, že vyšší mezerovitost v kombinaci s nižším obsahem pojiva vede k asfaltovému betonu s horší úna-




obr. 10 Grafy částečné závislosti vytvořené pomocí kalibrovaného modelu trénovaného s L_{MSE} , znázorňující vztah mezi vstupními parametry a predikovanými hodnotami N_f při dvou úrovních přetvoření (graf vlevo a vpravo). Datové body ležící uvnitř konvexního obalu naměřeného datového souboru jsou zobrazeny jako bílé trojúhelníkové značky

vovou životností. Tyto poznatky naznačují, že odolný AC by měl obsahovat alespoň 5,5 % asfaltového pojiva. Zároveň modely ukazují, že vyšší obsah vzduchových dutin by mohl být výhodný při kombinaci s vysokým obsahem pojiva. Tato situace však přesahuje rozsah vstupních dat, což vede k extrapolaci modelů v této oblasti, a proto se jedná o nespolehlivé výsledky, které je nutné dále experimentálně ověřit.

Tyto závěry odpovídají trendům popsáným v [43], kde byly zaznamenány vyšší hodnoty N_f při zvýšení obsahu pojiva z 4,2 % na 5,2 %. Autoři rovněž zjistili, že zvýšení mezerovitosti z 4,5 % na 9,5 % vedlo k relativně podobné průměrné únavové životnosti, avšak s vyšší variabilitou. Data ze studie [43] jsme do našich modelů nezahrnuli kvůli rozdílu v metodách testování, avšak kvalitativní trendy, které autoři identifikovali, poskytují cenný kontext pro ověření vztahů odhalených našimi predikcemi. Tento jev byl také analyzován v [54], kde autoři ve svém numerickém modelu prokázali, že AB vzorky se stejným obsahem vzduchových dutin mohou vykazovat odlišnou únavovou životnost kvůli nerovnoměrnému rozložení vzduchových dutin.



obr. 11 2D čárové grafy představující výseky grafů částečné závislosti pro $\varepsilon = 200 \times 10^{-6}$ uvnitř konvexního obalu naměřených dat, znázorňující vztah mezi dvěma vstupními parametry a predikovanými hodnotami N_f ; model byl trénován pomocí ztrátové funkce L_{MSE}



obr. 12 2D čárové grafy představující výseky grafů částečné závislosti pro $\varepsilon = 200 \times 10^{-6}$ uvnitř konvexního obalu naměřených dat, znázorňující vztah mezi dvěma vstupními parametry a predikovanými hodnotami N_f ; model byl trénován pomocí ztrátové funkce L_{MSLE}

Naše výsledky rovněž odpovídají zjištěním [42], podle kterých N_f roste s obsahem pojiva, zatímco vliv mezerovitosti je méně výrazný.

ZÁVĚR

Studie využila ANN k predikci únavové životnosti asfaltového betonu, se zaměřením na vliv úrovně přetvoření, obsahu pojiva a mezerovitosti. S využitím rozsáhlého datového souboru jsme přizpůsobili modely ANN tak, aby reflektovaly široký rozsah dat únavové životnosti, která jsou typicky reprezentována na logaritmické škále. Strategické použití ztrátových funkcí střední kvadratické chyby (L_{MSE}) a střední kvadratické logaritmické chyby (L_{MSLE}) umožnilo jemně doladit citlivost modelu na rozsah dat a vyrovnat se s logaritmickým rozložením únavové životnosti.

Díky důkladné optimalizaci hyperparametrů jsme zjistili, že architektura modelu se dvěma skrytými vrstvami obsahujícími

200 neuronů poskytuje nejlepší predikční schopnost. Aktivační funkce ReLU se ukázala jako optimální a optimalizátor RM-Sprop jako nejstabilnější.

Naše analýza ukázala, že L_{MSLE} dosáhla vyšší hodnoty R^2 na testovacích datech, což naznačuje silnější celkovou shodu s pozorováními při vysokých hodnotách N_f . Naopak L_{MSLE} vykazovala výrazně nižší scatter index v oblasti nízkých hodnot N_f , čímž lépe zachovala relativní chybu predikce mezi nižšími hodnotami únavové životnosti. Tato zjištění zdůrazňují, že L_{MSLE} je efektivnější pro heterogenní datové soubory s výraznou variabilitou v nižších rozsazích únavové životnosti, zatímco L_{MSE} je vhodnější, pokud je kladen důraz na výkon v oblasti vyšších hodnot N_f .

Podrobná analýza vyvinutých modelů odhalila klíčové poznatky o vztazích mezi mikrostrukturními parametry asfaltového betonu a jeho únavovou životností. Nižší obsah vzduchových dutin a vyšší obsah pojiva vyústily v AC s prodlouženou únavovou životností. Naopak vysoký obsah vzduchových dutin a nízký obsah pojiva výrazně snižovaly únavovou životnost, což zdůrazňuje potřebu dosažení kritické rovnováhy pro trvanlivý AC. Tato zjištění potvrzují význam optimalizace obsahu pojiva a mezerovitosti při návrhu směsí AC pro zlepšení trvanlivosti vozovek a snížení nákladů na jejich údržbu.

Tento výzkum nejen ukazuje schopnosti ANN při predikci únavové životnosti AC, ale také vytváří základ pro využití rozsáhlejších datových souborů v budoucích snahách o tvorbu predikčního modelu. Nabízí cenné poznatky o vztahu mezi základními vlastnostmi AC a jeho životností, což otevírá cestu pro informovanější a efektivnější inženýrské postupy při návrhu vozovek.

Tato práce byla podpořena Grantovou agenturou České republiky (č. 22-04047K).

ZDROJE

- VALENTIN, J, J TREJBAL, V NEŽERKA, T VALENTOVÁ, P VABKOVÁ a P TICHÁ. A comprehensive study on adhesion between modified bituminous binders and mineral aggregates. *Construction and Building Materials*. 2021, 305, 124686. Dostupné z: [doi:10.1016/j.conbuildmat.2021.124686](https://doi.org/10.1016/j.conbuildmat.2021.124686)
- ISIED, Mayzan M a Mena I SOULIMAN. Integrated predictive artificial neural network fatigue endurance limit model for asphalt concrete pavements. *Canadian Journal of Civil Engineering*. 2019, 46, 114–123. Dostupné z: [doi:10.1139/cjce-2018-0051](https://doi.org/10.1139/cjce-2018-0051)
- XIAO, Feipeng, Serji AMIRKHANIAN a C Hsein JUANG. Prediction of Fatigue Life of Rubberized Asphalt Concrete Mixtures Containing Reclaimed Asphalt Pavement Using Artificial Neural Networks. *Journal of Materials in Civil Engineering*. 2009, 21, 253–261. Dostupné z: [doi:10.1061/\(asce\)0899-1561\(2009\)21:6\(253\)](https://doi.org/10.1061/(asce)0899-1561(2009)21:6(253))
- SHI, Bin, Qiao DONG, Xueqin CHEN, Xingyu GU, Xiang WANG a Shiao YAN. A comprehensive review on the fatigue resistance of recycled asphalt materials: Influential factors, correlations and improvements. *Construction and Building Materials*. 2023, 384, 131435. Dostupné z: [doi:10.1016/j.conbuildmat.2023.131435](https://doi.org/10.1016/j.conbuildmat.2023.131435)
- BELL, Chris A, Dan SOSNOVSKE a J A WIEDER. Aging: binder validation: binder validation. *Strategic Highway Research Program*, National Research Council Washington, 1994.
- SREEDHAR, Shashwath a Erdem COLERI. The effect of long-term aging on fatigue cracking resistance of asphalt mixtures. *International Journal of Pavement Engineering*. 2020, 23, 308–320. Dostupné z: [doi:10.1080/10298436.2020.1745206](https://doi.org/10.1080/10298436.2020.1745206)
- BESKOU, Niki D, Stephanos V TSINOPOULOS a George D HATZIGEORGIOU. Fatigue cracking failure criterion for flexible pavements under moving vehicles. *Soil Dynamics and Earthquake Engineering*. 2016, 90, 476–479. Dostupné z: [doi:10.1016/j.soildyn.2016.09.019](https://doi.org/10.1016/j.soildyn.2016.09.019)
- MABZKA, Eryk a Piotr MABKIEWICZ. Asphalt Mixtures Fatigue Life Considering Various Environmental Impacts. *Materials*. 2023, 16, 966. Dostupné z: [doi:10.3390/ma16030966](https://doi.org/10.3390/ma16030966)
- MORENO-NAVARRO, Fernando, Miguel SOL-SÁNCHEZ, Gema GARCÍA-TRAVÉ a Mtextordfeminine Carmen RUBIO-GÁMEZ. Fatigue cracking in asphalt mixtures: the effects of ageing and temperature: the effects of ageing and temperature. *Road Materials and Pavement Design*. 2017, 19, 561–570. Dostupné z: [doi:10.1080/14680629.2018.1418717](https://doi.org/10.1080/14680629.2018.1418717)
- ENRÍQUEZ-LEÓN, Alexis Jair, Thiago Delgado DE SOUZA, Francisco Thiago Sacramento ARAGÃO, Delson BRAZ, André Maués Brabo PEREIRA a Liebert Parreiras NOGUEIRA. Determination of the air void content of asphalt concrete mixtures using artificial intelligence techniques to segment micro-CT images. *International Journal of Pavement*

- Engineering. 2021, 23, 3973–3982. Dostupné z: [doi:10.1080/10298436.2021.1931197](https://doi.org/10.1080/10298436.2021.1931197)
- [11] PRATICÒ, F. G. a A. MORO. Measurement of air void content in hot mix asphalts: Method and core diameter dependence: Method and core diameter dependence. Construction and Building Materials. 2012, 26, 344–349. Dostupné z: [doi:10.1016/j.conbuildmat.2011.06.032](https://doi.org/10.1016/j.conbuildmat.2011.06.032)
- [12] LIAO, Min-Chih, Jian-Shiuh CHEN a Ko-Wan TSOU. Fatigue Characteristics of Bitumen-Filler Mastics and Asphalt Mixtures. Journal of Materials in Civil Engineering. 2012, 24, 916–923. Dostupné z: [doi:10.1061/\(asce\)mt.1943-5533.0000450](https://doi.org/10.1061/(asce)mt.1943-5533.0000450)
- [13] ZHANG, Yang, Jinglin ZHANG, Tao MA, Haonan QI a Conglin CHEN. Predicting asphalt mixture fatigue life via four-point bending tests based on viscoelastic continuum damage mechanics. Case Studies in Construction Materials. 2023, 19, e02671. Dostupné z: [doi:10.1016/j.cscm.2023.e02671](https://doi.org/10.1016/j.cscm.2023.e02671)
- [14] YANG, Kai, Hongjun CUI, Xinwei MA a Minqing ZHU. Understanding and characterizing the fatigue cracking resistance of asphalt binder at intermediate temperature: A literature review: A literature review. Construction and Building Materials. 2023, 407, 133432. Dostupné z: [doi:10.1016/j.conbuildmat.2023.133432](https://doi.org/10.1016/j.conbuildmat.2023.133432)
- [15] CHENG, Huailei, Jianing LIU, Lijun SUN, Liping LIU a Yining ZHANG. Fatigue behaviours of asphalt mixture at different temperatures in four-point bending and indirect tensile fatigue tests. Construction and Building Materials. 2021, 273, 121675. Dostupné z: [doi:10.1016/j.conbuildmat.2020.121675](https://doi.org/10.1016/j.conbuildmat.2020.121675)
- [16] CHENG, Weiwei, Xiaochun YANG, Bin WANG a Wei WANG. Unbiased quasi-hyperbolic nesterov-gradient momentum-based optimizers for accelerating convergence. World Wide Web. 2022, 26, 1323–1344. Dostupné z: [doi:10.1007/s11280-022-01086-3](https://doi.org/10.1007/s11280-022-01086-3)
- [17] CHENG, Huailei, Lijun SUN, Yuhong WANG, Liping LIU a Xingyu CHEN. Fatigue test setups and analysis methods for asphalt mixture: A state-of-the-art review: A state-of-the-art review. Journal of Road Engineering. 2022, 2, 279–308. Dostupné z: [doi:10.1016/j.jreng.2022.11.002](https://doi.org/10.1016/j.jreng.2022.11.002)
- [18] SUDARSANAN, Nithin a Youngsoo Richard KIM. A critical review of the fatigue life prediction of asphalt mixtures and pavements. Journal of Traffic and Transportation Engineering (English Edition). 2022, 9, 808–835. Dostupné z: [doi:10.1016/j.jtte.2022.05.003](https://doi.org/10.1016/j.jtte.2022.05.003)
- [19] SAHA, Gourab a Krishna Prapoorna BILIGIRI. Fracture damage evaluation of asphalt mixtures using Semi-Circular Bending test based on fracture energy approach. Engineering Fracture Mechanics. 2015, 142, 154–169. Dostupné z: [doi:10.1016/j.engfracmech.2015.06.009](https://doi.org/10.1016/j.engfracmech.2015.06.009)
- [20] ZIELINSKI, Piotr. The use of the semi-circular bending method to assess the intermediate-temperature fracture toughness of asphalt concrete mixes with reclaimed asphalt shingles. Road Materials and Pavement Design. 2023, 25, 81–98. Dostupné z: [doi:10.1080/14680629.2023.2194432](https://doi.org/10.1080/14680629.2023.2194432)
- [21] NGUYEN, Manh Tuan, Hyun Jong LEE a Jongeun BAEK. Fatigue Analysis of Asphalt Concrete under Indirect Tensile Mode of Loading Using Crack Images. Journal of Testing and Evaluation. 2012, 41, 104589. Dostupné z: [doi:10.1520/jte104589](https://doi.org/10.1520/jte104589)
- [22] VISHNU, T B. Laboratory investigation on the fatigue performance of asphalt mixes reinforced with human hair fiber in pavement application. Materials Today: Proceedings. 2023. Dostupné z: [doi:10.1016/j.matpr.2023.01.070](https://doi.org/10.1016/j.matpr.2023.01.070)
- [23] CEN, EN 12697-24: 2018; Bituminous Mixtures—Test Methods—Part 24: Resistance to Fatigue: 2018; Bituminous Mixtures—Test Methods—Part 24: Resistance to Fatigue. European Standard. 2018.
- [24] WANG, Zhichao, Donghai LIU, Bin HU, Chongzheng ZHU a Wenbo LUO. An improved regression model to predict fatigue life of asphalt mixes incorporating low to moderate RAP contents. Construction and Building Materials. 2023, 374, 130904. Dostupné z: [doi:10.1016/j.conbuildmat.2023.130904](https://doi.org/10.1016/j.conbuildmat.2023.130904)
- [25] LUNDSTROM, Robert, Hervé Di BENEDETTO a Ulf ISABSSON. Influence of Asphalt Mixture Stiffness on Fatigue Failure. Journal of Materials in Civil Engineering. 2004, 16, 516–525. Dostupné z: [doi:10.1061/\(asce\)0899-1561\(2004\)16:6\(516\)](https://doi.org/10.1061/(asce)0899-1561(2004)16:6(516))
- [26] CHEN, Jie a Yongming LIU. Fatigue modeling using neural networks: A comprehensive review: A comprehensive review. Fatigue & Fracture of Engineering Materials & Structures. 2022, 45, 945–979. Dostupné z: [doi:10.1111/ffe.13640](https://doi.org/10.1111/ffe.13640)
- [27] HOODA, Rohit, Vedant JOSHI a Manan SHAH. A comprehensive review of approaches to detect fatigue using machine learning techniques. Chronic Diseases and Translational Medicine. 2022, 8, 26–35. Dostupné z: [doi:10.1016/j.cdtm.2021.07.002](https://doi.org/10.1016/j.cdtm.2021.07.002)
- [28] LIAN, Zhengheng, Minjie LI a Wencong LU. Fatigue life prediction of aluminum alloy via knowledge-based machine learning. International Journal of Fatigue. 2022, 157, 106716. Dostupné z: [doi:10.1016/j.ijfatigue.2021.106716](https://doi.org/10.1016/j.ijfatigue.2021.106716)
- [29] ALNAQBI, Ali Juma, Waleed ZEIADA, Ghazi AL-KHATEEB, Abdulmalek ABTTAN a Muamer ABUZWIDAH. Predictive models for flexible pavement fatigue cracking based on machine learning. Transportation Engineering. 2024, 16, 100243. Dostupné z: [doi:10.1016/j.treng.2024.100243](https://doi.org/10.1016/j.treng.2024.100243)
- [30] LI, Qiang, Hyun Jong LEE a Tae Woo KIM. A simple fatigue performance model of asphalt mixtures based on fracture energy. Construction and Building Materials. 2012, 27, 605–611. Dostupné z: [doi:10.1016/j.conbuildmat.2011.07.001](https://doi.org/10.1016/j.conbuildmat.2011.07.001)
- [31] PAIS, Jorge, Paulo PEREIRA a Luís PICADO-SANTOS. Variability of laboratory fatigue life of asphalt mixes using four point bending test results. Department of Civil Engineering, University of Minho, Portugal. , IPJ. 2002, 1(2).
- [32] SABOO, Nikhil, Bhaskar Pratim DAS a Praveen KUMAR. New phenomenological approach for modeling fatigue life of asphalt mixes. Construction and Building Materials. 2016, 121, 134–142. Dostupné z: [doi:10.1016/j.conbuildmat.2016.05.147](https://doi.org/10.1016/j.conbuildmat.2016.05.147)
- [33] WITCZAK, Matthew, Michael MAMLOUK, Mena SOULIMAN a Waleed ZEIADA. Validating an Endurance Limit for Hot-Mix Asphalt (HMA) Pavements: Laboratory Experiment and Algorithm Development (project no. NCHRP 9-44 A: Laboratory Experiment and Algorithm Development (project no. NCHRP 9-44 A. 2013.
- [34] AMERI, Mahmoud, Shams NOWBAKHT, Mohammad MOLAYEM a Mohammad H MIRABIMOGHADDAM. A study on fatigue modeling of hot mix asphalt mixtures based on the viscoelastic continuum damage properties of asphalt binder. Construction and Building Materials. Elsevier BV, 2016, 106, 243–252. Dostupné z: [doi:10.1016/j.conbuildmat.2015.12.066](https://doi.org/10.1016/j.conbuildmat.2015.12.066)
- [35] BAŃKOWSKI, Wojciech. Evaluation of Fatigue Life of Asphalt Concrete Mixtures with Reclaimed Asphalt Pavement. Applied Sciences. 2018, 8, 469. Dostupné z: [doi:10.3390/app8030469](https://doi.org/10.3390/app8030469)
- [36] GHAZI G. AL-KHATEEB, Khalid A Ghuzlan. The combined effect of loading frequency, temperature, and stress level on the fatigue life of asphalt paving mixtures using the IDT test configuration. International Journal of Fatigue. 2014, 59, 254–261. Dostupné z: [doi:10.1016/j.ijfatigue.2013.08.011](https://doi.org/10.1016/j.ijfatigue.2013.08.011)
- [37] HARVEY, John T, John A DEABON, Bor-Wen TSAI a Carl L MONISMITH. Fatigue performance of asphalt concrete mixes and its relationship to asphalt concrete pavement performance in California. University of California Berkeley, Institute of Transportation Studies, 1995.
- [38] LV, Songtao, Ziyang WANG, Xuan ZHU, Jiang YUAN a Xinghai PENG. Research on strength and fatigue properties of asphalt mixture with different gradation curves. Construction and Building Materials. 2023, 364, 129872. Dostupné z: [doi:10.1016/j.conbuildmat.2022.129872](https://doi.org/10.1016/j.conbuildmat.2022.129872)
- [39] PAKHOLAK, Raman, Andrzej PLEWA a Władysław GARDZIEJCZYK. Influence of Type of Modified Binder on Stiffness and Rutting Resistance of Low-Noise Asphalt Mixtures. Materials. 2021, 14, 2884. Dostupné z: [doi:10.3390/ma14112884](https://doi.org/10.3390/ma14112884)
- [40] SHEN, Shihui a Xin LU. Energy Based Laboratory Fatigue Failure Criteria for Asphalt Materials. Journal of Testing and Evaluation. 2011, 39, 313–320. Dostupné z: [doi:10.1520/jte103088](https://doi.org/10.1520/jte103088)
- [41] SHU, Xiang, Baoshan HUANG a Dragon VUKOSAVLJEVIC. Laboratory evaluation of fatigue characteristics of recycled

- asphalt mixture. Construction and Building Materials. 2008, 22, 1323–1330. Dostupné z: [doi:10.1016/j.conbuildmat.2007.04.019](https://doi.org/10.1016/j.conbuildmat.2007.04.019)
- [42] YAN, Chuanqi, Rui GAO a Weidong HUANG. Asphalt Mixture Fatigue Life Prediction Model Based on Neural Network. American Society of Civil Engineers, 2018. Dostupné z: [doi:10.1061/9780784480915.136](https://doi.org/10.1061/9780784480915.136)
- [43] ZEIADA, W. A., K. E. KALOUSH, B. S. UNDERWOOD a M. S. MAMLOUK. Effect of Air Voids and Asphalt Content on Fatigue Damage Using the Viscoelastic Continuum Damage Analysis. American Society of Civil Engineers, 2013. Dostupné z: [doi:10.1061/9780784413005.094](https://doi.org/10.1061/9780784413005.094)
- [44] ZHANG, Jun, Mohammadreza SABOURI, Murthy N GUDDATI a Y Richard KIM. Development of a failure criterion for asphalt mixtures under fatigue loading. Road Materials and Pavement Design. 2013, 14, 1–15. Dostupné z: [doi:10.1080/14680629.2013.812843](https://doi.org/10.1080/14680629.2013.812843)
- [45] ZHOU, Fujie, Walaa MOGAWER, Hongsheng LI, Adrian ANDRIESCU a Audrey COPELAND. Evaluation of Fatigue Tests for Characterizing Asphalt Binders. Journal of Materials in Civil Engineering. 2013, 25, 610–617. Dostupné z: [doi:10.1061/\(asce\)mt.1943-5533.0000625](https://doi.org/10.1061/(asce)mt.1943-5533.0000625)
- [46] BOX, G. E. P. a D. R. COX. An analysis of transformations. (With discussion). Journal of the Royal Statistical Society. Series B. Methodological. 1964, 26, 211–252.
- [47] SAKIA, R. M. The Box-Cox transformation technique: A review: A review. The Statistician. 1992, 41, 169. Dostupné z: [doi:10.2307/2348250](https://doi.org/10.2307/2348250)
- [48] SHAPIRO, S. S. a M. B. WILK. An Analysis of Variance Test for Normality (Complete Samples). Biometrika. 1965, 591. Dostupné z: [doi:10.2307/2333709](https://doi.org/10.2307/2333709)
- [49] VARUN CHANDOLA, VIPIN KUMAR, Arindam Banerjee. Anomaly detection: A survey: A survey. ABM Computing Surveys (CSUR). 2009, 41, 1–58. Dostupné z: [doi:10.1145/1541880.1541882](https://doi.org/10.1145/1541880.1541882)
- [50] SEO, Songwon. A Review and Comparison of Methods for Detecting Outliers in Univariate Data Sets. <https://d-scholarship.pitt.edu/7948/1/Seo.pdf>. 2006. Dostupné také z: <https://d-scholarship.pitt.edu/7948/>
- [51] PENG, Yuan-Long a Wei-Po LEE. Practical guidelines for resolving the loss divergence caused by the root-mean-squared propagation optimizer. Applied Soft Computing. 2024, 153, 111335. Dostupné z: [doi:10.1016/j.asoc.2024.111335](https://doi.org/10.1016/j.asoc.2024.111335)
- [52] JENTZEN, Arnulf a Adrian RIEKERT. Convergence analysis for gradient flows in the training of artificial neural networks with ReLU activation. Journal of Mathematical Analysis and Applications. 2023, 517, 126601. Dostupné z: [doi:10.1016/j.jmaa.2022.126601](https://doi.org/10.1016/j.jmaa.2022.126601)
- [53] KINGMA, Diederik P a Jimmy BA. Adam: A Method for Stochastic Optimization: A Method for Stochastic Optimization. 2015. Dostupné také z: <http://arxiv.org/abs/1412.6980>
- [54] MA, Tao, Yao ZHANG, Deyu ZHANG, Jinhai YAN a Qin YE. Influences by air voids on fatigue life of asphalt mixture based on discrete element method. Construction and Building Materials. 2016, 126, 785–799. Dostupné z: [doi:10.1016/j.conbuildmat.2016.09.045](https://doi.org/10.1016/j.conbuildmat.2016.09.045)

Lektorský komentář

Článek se zabývá problematikou únavových parametrů asfaltového betonu (AC). Na rozdíl od běžně používaných metod laboratorního zkoušení únavových vlastností, které jsou velmi časově náročné, je aplikována metoda umělých neuronových sítí na rozsáhlý datový soubor. Studie je zaměřena na předpověď únavové životnosti asfaltových betonů s orientací na úroveň přetvoření, obsah pojiva a mezerovitost. Výsledky ukazují přesnější předpověď únavové životnosti, přičemž zásadní roli hraje množství asfaltového pojiva. Důkladnou optimalizací hyperparametrů se zjistilo, že struktura modelu se dvěma vrstvami obsahujícími 200 neuronů má nejlepší predikční schopnost.

Vysoce sofistikovaný článek o modelech nachází zásadní poznatky o vztazích mezi parametry asfaltového betonu a jeho únavovou životností. S ohledem na vysoký vědecký potenciál článku doporučuji jeho publikaci v prestižním zahraničním časopise.

Prof. Dr. Ing. Michal Varaus, Vysoké učení technické v Brně, Fakulta stavební