

Aszfaltkeverékek közvetett húzószilárdságának modellezése mesterséges intelligencia alkalmazásával

Az újrahasznosított aszfaltot és habosított bitument tartalmazó aszfaltkeverékek közvetett húzószilárdságának előrebecslése lineáris regressziós és a neurális hálózati modellekkel jó szakmai célkitűzés. A kutatások során a véletlenszerű erdő (random forest) és a neurális hálózat (neural network) modell összehasonlításával igazolták a gépi tanulási technikák ilyen irányú hasznosíthatóságát.

Kulcsszavak: habosított bitumen, meleg aszfaltkeverék, neurális hálózat, szupport vektor regresszió (SVR), gépi tanulás

DOI: <https://doi.org/10.24228/KTSZ.2024.4.1>

Ali Saleh¹ – Gáspár László²

¹ Széchenyi István Egyetem, Építész-, Építő- és Közlekedésmérnöki Kar,
Közlekedésépítési és Vízgazdálkodási Tanszék

² Széchenyi István Egyetem, Építész-, Építő- és Közlekedésmérnöki Kar,
Közlekedésépítési és Vízgazdálkodási Tanszék,

KTI Magyar Közlekedéstudományi és Logisztikai Intézet Nonprofit Kft.,
email: gaspar.laszlo@kti.hu

1. BEVEZETÉS

Az útpályaszerkezet egészének hosszú távú teljesítménye az egyes rétegek kölcsönhatásától is nagymértékben függ; ebben a tekintetben a tudományos alapokon nyugvó pályaszerkezet-tervezési módszerek alkalmazása kiemelt szerephez jut [1]. Például, a Superpave módszer, a Bailey-módszer, a Durva adalékanyag hézagát kitöltő módszer (Coarse Aggregate Void Filling, CVAF), a Marshall-módszer és a Kiegyensúlyozott keverési módszer bármelyike érdemlegesen hozzá tud járulni a jó minőségű aszfaltkeverékek előállításához [2], [3].

Az útügyi projektek költségeinek és az üzemanyag-fogyasztásnak a csökkenése, illetve az energiahatékonyság növekedése következtében, a meleg aszfaltkeverék (WMA) és az azal kapcsolatos előnyök iránt az elmúlt években egyre nagyobb érdeklődés nyilvánul meg. A WMA további környezetvédelmi előnyei, különösen a károsanyag-kibocsátás csökkentése terén, jelentős mértékben járulnak hozzá a környezet megóvásához, mind pedig az úton dolgozók egészségéhez. Az alacsonyabb keverégyártási hőmérsékletre irányuló igények kielégítésére újabb technológiák jelentek meg, amelyek közül a habosított bitumen a fenntartható útépítés egyik fontos eleme [4].

A habosított bitumen technológiát elterjedten alkalmazzák alaprétegek stabilizálására. Ennek során előnyös körülmény az alapréteg szilárdságának növelése. Így a rétegvastagság csökkenthető, az vízzáróbb lesz, valamint a szélsőségesen kedvezőtlen időjárási viszonyokkal szemben is nagyobb az ellenállása. A habosított bitumen készítésének elvét 1956-ban Ladis Csanyi professzor dolgozta ki az Iowa Állami Egyetemen [5]. A Mobil Oil későbbi fejlesztései, köztük a tágulási kamra bevezetése, a technológiát tovább finomították.

A habosított bitumen mechanikája a víznek, a levegőnek és a bitumennek a tágulási kamrában való alapos összekeverését jelenti. E technológia döntő fontosságú eleme, hogy a forró bitumenbe kis mennyiségű, hideg vizet fecskendeznek, aminek hatására a kötőanyag eredeti térfogatának mintegy tizenötszörösére tágul [6]. A habosított bitumen jellemzőit, mint a legnagyobb térfogatnövekedési arányt (ER) és a felezési időt (HL) olyan tényezők is befolyásolják, mint a bitumen hőmérséklete, a %-os víztartalom, a légnyomás és a bitumen minősége. Figyelemre méltó, hogy a megnövekedett víztartalom hatására nagyobb lesz a térfogatnövekedési arány, ugyanakkor csökken a felezési idő, a fenntartható útépítés ezen területének megtervezésekor kényes egyensúlyt teremtve.

A környezeti fenntarthatósággal kapcsolatos aggályok kezelése során, egyre nagyobb szerephez jut az újrahasznosított aszfaltanyagok (RAM) felhasználásának optimalizálása. A RAM-nak új aszfaltkeverékekbe történő adagolása nemcsak az anyagköltségek csökkentését szolgálja, hanem a nem megújuló erőforrások megőrzéséhez is érdemlegesen hozzájárul. A National Asphalt Pavement Association (NAPA) által 2018-ban lefolytatott vizsgálat rávilágított arra, hogy az aszfaltkeverékek átlagos RAM %-os aránya az Amerikai Egyesült Államokban folyamatosan növekedett – a 2009-es 15,6%-ról 2018-ra 21,1%-ra. Az egyes tagállamok Állami Aszfaltépítési Szövetségei – 77%-os arányban – hangot adtak azon célkitűzésüknek, hogy az újrahasznosított anyagok közúti hasznosítására irányuló erőfeszítéseiket a továbbiakban is fokozni kívánják [7].

Tanulmányok foglalkoztak a különböző visszanyert aszfalt (RAP) tartalommal rendelkező és habosított bitumen kötőanyagú aszfaltkeverék teljesítményével [8], [9]. A mikrostruktúrákat, különösen pedig a keverék kötőanyaggal való bevonásának hatékonyságát pásztázó elektron-mikroszkóppal (SEM) vizsgálták [10], [11]. Az újrahasznosított aszfaltkeverékekben a levegő hégeloszlásának vizsgálatát SEM és a röntgenszámítógépes tomográfia alkalmazásával végezték el [12], [13].

A laboratóriumi vizsgálatok hatékonyságának növelése érdekében, a kutatók olyan modellezési technikákat alkalmaztak a különböző aszfaltkeverékek optimális bitumentartalmának meghatározására, mint a mesterséges neurális hálózatok [14]. Nevezetesen, a válasz felületi (Response Surface) módszertan alkalmazásával, az újrahasznosított meleg adalékanyagkeverékeknel a legkedvezőbb bitumentartalmat határozták meg.

2. HÁTTÉRINFORMÁCIÓK

2.1. A kötőanyag hatása

Átfogó vizsgálat sorozatot végzett Abreu [15], hogy részletes információkhoz jusson a bitumen minőségének a habosítási folyamatra gyakorolt hatása tekintetében, különösen, ha a habosított bitumen kötőanyagú aszfaltkeverékekben (FBM) azt különböző újrahasznosított aszfalt (RAP) tartalommal is kombinálják. Az eredmények azt mutatták, hogy a RAP-tartalom növekedésével lágyabb bitumentípus alkalmazása válik szükségesé, ami a habosítási folyamatot érdemlegesen javítja.

Arefin [16] a habosított bitumennel készült aszfaltkeverékek (FBM) rövid és hosszú távú öregedési hatásait vizsgálta. A kutatások aláhúzták a kötőanyag-minőség kulcsfontosságú szerepét a keverék öregedési folyamatának befolyásolásában. Ezzel hangsúlyozzák annak a jelentőségét, hogy a kötőanyag minél több tulajdonságát a habosított aszfaltkeverékek tartósságának és teljesítményének értékelése során vegyék figyelembe.

Egy újabb vizsgálatban Kar [17] annak megértésére összpontosított, hogy a bitumen aszfalten- és aromástartalma hogyan befolyásolja a habosítási jellemzőket. Ezeknek az alkotóelemeknek alapos vizsgálatával, a tanulmány értékes információkkal szolgál a bitumen összetétele és a habosítási folyamat közötti bonyolult összefüggéséről, érdemlegesen hozzájárulva a habosított aszfalttechnológiák fejlesztéséhez.

Bairgi [18] és Hasan [19] tanulmányai megkérdőjelezték azokat a hagyományos állításokat, hogy a habosított kötőanyag rugalmassági modulusal mért rugalmas viselkedése a habosított víz mennyiségével közvetlen összefüggésben van. Ez a hagyományos elvárásoktól való eltérés azt sugallja, hogy a habosítási folyamatot befolyásoló tényezők összetett kölcsönhatása bonyolultabb a rugalmassági modulus és a habosított víztartalom közötti közvetlen összefüggésnél.

2.2. A RAP-tartalom hatása

Az újrahasznosított aszfalt (RAP) tartalomnak a habosított bitumen kötőanyagú keverék (FBM) teljesítményére gyakorolt hatását számos vizsgálat tárgyalta. Taziani [20] a 100% RAP-ot és töltőanyagként portlandcementet tartalmazó FBM-mel foglalkozott. Vizsgálatauk során a dinamikus kúszást és a dinamikus modulust határozták meg, összehasonlítva a rostok keverékhez való hozzáadásának hatásával. Az FBM teljesítményében tapasztalt jelentős pozitív változást a rostok és a cement felhasználásának tulajdonították.

Chomicz-Kowalska [21] a habosított bitumen és a bitumenemulzió kötőanyagú aszfaltkeverékeket hasonlított össze. Számos laboratóriumi tömörítési módszert és %-os RAP-arányt vett figyelembe. Az eredmények rávilágítottak arra, hogy ezek a tényezők milyen hatással vannak a vizsgált keverékek tulajdonságaira, hangsúlyozva a RAP-tartalom érdemleges teljesítménybefolyásoló szerepét.

Hou [22] a RAP szemeloszlásának az FBM dinamikus modulusára gyakorolt hatását tanulmányozta alacsony hőmérsékleten (0°C alatt). Kutatásai azt mutatták, hogy a durvább

szemeloszlás alacsony hőmérsékleten az FBM dinamikus modulusát csökkenti. Ez a hatás azonban magasabb hőmérsékleten nem volt érdemleges.

Guatimosim [23] átfogó vizsgálata a hidegen újrahazsnosított, habosított bitumen kötőanyagú aszfaltkeverékek laboratóriumi és helyszíni értékelésére irányult. Eredményeik szerint, a hagyományos keverékekhez képest, viszonylag korán romlás jeleit tapasztalták. Idővel a pályaszerkezet-behajlás csökkent, a réteg merevségének növekedésével, bizonyítva az FBM teljesítményének időben változó jellegét.

2.3. A keverési hőmérséklet hatása

A habosított bitumen kötőanyagú aszfaltkeverékeket környezeti hőmérsékleten terítik el és tömörítik, (ezért gyakran hidegkeveréknek is nevezik azokat), az aszfalt keverési hőmérséklete döntő szerephez jut. Számos tanulmány hangsúlyozta az ásványi anyagok melegítésének jelentőségét a zúalékszemek hatékonyabb bevonása és a kedvezőbb mérnöki jellemzők szempontjából [8]. A kutatások eredményei azt mutatják, hogy a habosított bitumen kötőanyagú aszfaltkeverékek optimális keverési hőmérséklete, az adalékanyag típusától függően, a 13°C és a 23°C közötti tartományba esik. Az ezen tartományt el nem érő hőmérsékletű adalékanyagok gyengébb minőségű, habosított bitumen kötőanyagú aszfaltkeveréket eredményeznek [5].

Sánchez [24] 60% RAP-tartalmú FBM minták készítésekor az adalékanyagok hőmérsékletét 160°C-ig emelte. Eredményei azt mutatták, hogy az ásványi anyag hőmérsékletének 90°C fölé növelése a RAP előregédését eredményezte, ami aztán csökkenti a fáradással szembeni ellenállást is. Ez a tény pedig aláhúzza a keverési hőmérséklet gondos ellenőrzésének fontosságát a habosított bitumen kötőanyagú aszfaltkeverék optimális teljesítményének és hosszú élettartamának biztosítása érdekében.

2.4. A habosított bitumentartalom hatása

A habosított bitumen kötőanyagok kisebb ellenállást mutatnak a nyírási deformációval

szemben, mint a nem habosított változatok. A habosított bitumen tartalmú aszfalt ugyanakkor növeli a fáradási teljesítményt, miközben az aszfalt merevségét csökkenti. Ez a javulás a habosított bitumen kötőanyagú meleg aszfaltkeverékekben a keveréshez és a tömörítéshez szükséges alacsonyabb hőmérsékletnek tulajdonítható, aminek következtében az öregítő hatások csökkennek.


Az újrahasznosított aszfaltburkolat anyagában (RAP) levő öregedett kötőanyag kulcsfontosságú szerepet játszik a lágyabb, meleg keverék kötőanyagának ellensúlyozásában, ezáltal hozzájárulva a RAP-ot és habosított bitumént tartalmazó aszfaltkeverék öregedésének mérsékléséhez. Következésképpen ez a bonyolult kölcsönhatás rámutat a habosított bitumen kötőanyagú aszfaltkeverék alkalmazásának kedvező hatására a fáradással szembeni ellenállás optimalizálása terén, különösen olyan esetekben, amikor újrahasznosított anyagokat, így például RAP-t is használnak [25].

3. AZ ALKALMAZOTT MÓDSZER-TAN

3.1. Az adalékanyag szemeloszlásának és az optimális nedvességtartalomnak a meghatározása

Az ismertetendő vizsgálatok során 2-2 szemeloszlású változatot készítettek 0-25-50-75-100%-nyi újrahasznosításra szánt, tört aszfaltburkolat anyagával; mindegyik

1. ábra: A választott szemeloszlási görbék




szemeloszlás kielégítette a megfelelő DIN szabvány [26] követelményeit (1. ábra). Ezen keverékek maximális térfogatsúlya, rendre, a következőnek adódott: 2,474, 2,468, 2,476, 2,471 és 2,464.

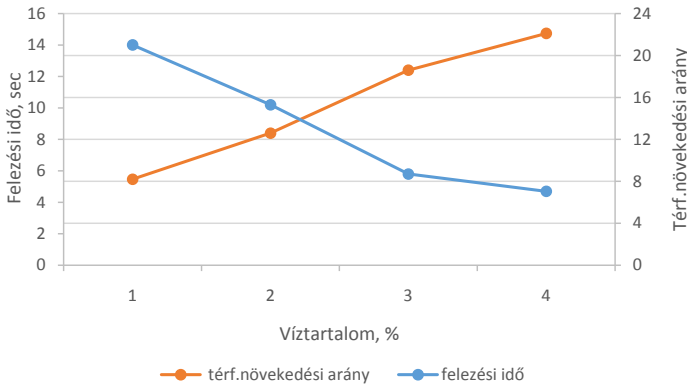
3.2. Optimális nedvességtartalom meghatározása (2., 3., 4. ábra)

A vizsgálathoz választott 70/100 bituméntípusról megállapítottuk, hogy a megfelelő szabvány [27] előírásait kielégíti, valamint alkalmas az útéépítésben adalékanyagok hatékony stabilizálására. A vizsgálathoz felhasznált habosított bitumen optimális tulajdonságai közül kiemelhető a 10,2 sec-os felezési


2. ábra: A B70/100-as bitumen felezési ideje és térfogatváltozási aránya 160°C hőmérsékleten



3. ábra: A B70/100-as bitumen felezési ideje és térfogatváltozási aránya 170°C hőmérsékleten



4. ábra: A B70/100-as bitumen felezési ideje és térfogatváltozási aránya 180°C hőmérsékleten



idő és a 12,6-szeres térfogatnövekedési aránya. Ezeket a kívánt tulajdonságokat 2%-os víztartalommal éri el, 170°C-os bitumen hőmérsékleten. Nevezetesen, ezek a habosított bitumen jellemzők megfelelnek a Wirtgen-csoport által megfogalmazott szabályozás követelményeinek [6], amelyek - a hatékony adalékanyag-stabilizáció érdekében, 15°C-ot meghaladó hőmérsékleten - az eredeti térfogat nyolcszorosának megfelelő minimális tágulási arányt és legalább 6 sec-os felezési időt követelnek meg.


3.3. A habosított bitumen optimalizálása

Az 5. ábra szemlélteti mind a habosított bitumen tartalom (FBC), mind pedig a RAP %-os hatását az aszfaltkeverékek szilárdságára, különböző környezeti körülmények között. Az eredmények azt mutatják, hogy ezek a %-os eltérések a közvetett húzószilárdság (ITS) értékében jelentős különbségekhez vezethetnek, rámutatva az FBC és a RAP %-os arányok gondos megválasztásának fontosságára az aszfaltkeverékek kívánt teljesítményjellemzőinek eléréséhez, különösen a nedves és a száraz körülmények közötti húzószilárdság tekintetében.

A közvetett húzószilárdság (ITS) vizsgálatában a húzószilárdsági arány (TSR) az aszfaltkeverékek termikus repedésállóságának értékeléséhez kritikus paraméternek tekint-

hető. Ez a vizsgálati módszer az anyag húzószilárdságát értékeli, különböző hőmérsékleti feltételek mellett. A TSR a húzószilárdság alacsony és magas hőmérsékleten való arányba állításával történik. A magas TSR azt mutatja, hogy a minta repedéssel szembeni ellenállása hideg időben nagy, míg az alacsony TSR a termikus repedésekkel szembeni érzékenységet jelzi. Tehát a TSR érdemleges segítséget nyújt a különböző hőmérsékleti viszonyoknak ellenálló aszfaltanyagok tervezésében és kiválasztásában, biztosítva az aszfaltburkolatok tartósságát [28].

5. ábra: ITS-értékek, az FBC %, a RAP % és a környezeti viszonyok függvényében



A 6. ábrán a húzószilárdsági arány (TSR) értékei láthatók az újrahasznosított aszfaltgranulátum (RAP) és a habosított bitumen tartalom (FBC) %-os értékeinek különböző kombinációira. A vizsgált TSR-értékek általában elérik vagy meghaladják a 70-et, kivéve egy esetet (RAP 25%, FBC 3,5%), ami arra utal, hogy ez a variáció a termikus repedésekkel szemben érzékeny.


4. GÉPI TANULÁSI MODELLEK

4.1. Szupport vektor regresszió (SVR)

tése érdekében, és a hipersík "testreszabása" a margó maximalizálása érdekében.

A legújabb kutatások során, az SVR algoritmus sokoldalúságát az aszfaltkeverékek különféle tulajdonságainak előrejelzésére is egyre gyakrabban használják. Így, például, az SVR megbízható eredményeket szolgáltató modellnek bizonyult a dinamikus modulus becslésére [29] [30]. Összehasonlító vizsgálatok kimutatták, hogy a meleg aszfaltkeverékek (HMA) dinamikus modulusának előre jelzésében az SVR regresszió a többváltozós regressziós modelleknél sikeresebbnek bizonyul [30]. Ezenkívül az SVR modellek az aszfaltkeverékek nyomvályómélységét és közvetett húzószilárdságát is sikeresen előre becsülték [31] [32]. Lényeges megemlíteni, hogy SVR-modelleket, ígéretes eredménnyel, útpályák állapotának előre jelzésére is fejlesztettek ki [24] [33]. Mindezek az SVR sokoldalúságát és hatékonyságát bizonyítják, az aszfaltkutatás és az útpályaszerkezetek teljesítményének előrebecslése terén.

6. ábra: Húzószilárdsági arány, a RAP% és az FBC% függvényében



4.2. Adam optimalizáló

Az Adam optimalizáló olyan népszerű optimalizáló algoritmus, amelyet neurális hálózatok betanítására alkalmaznak. Az "Adaptive Moment Estimation" rövidítése, és két optimalizálási algoritmus technikáit kombinálja. Az Adam optimalizáló ritka gradiens, "zajos" adatok és a nem stacionárius célfüggvények kezelésének hatékonyságáról ismert. Az Adam minden paraméternél tapasztalható, nagy adaptív tanulási sebessége és lendületes viselkedése a mély neurális hálózatok betanítására különösen alkalmassá teszi [35].

4.3. Véletlenszerű erdő (random forest, RF)

Az együttes (ensemble) megközelítések több tanulási algoritmus szinergiáját hasznosítják, hogy az egyes algoritmusok képességein túlmenően javítsák az előrejelzési teljesítményt [36]. A bagging (Bootstrap Aggregating) olyan gépi tanulási technika, amelyet a modellek stabilitásának és pontosságának növelésére használnak; a bagging aggregáció fejlett iterációja a véletlenszerű erdő (random forest, RF), amelynek során számos döntési fából származó előrejelzést aggregálnak [37].

A random forest komoly előnye a bagging módszerhez képest, hogy minden döntési fa összeállításakor a felosztáshoz szelektíven ki tudja választani a funkciók egy-egy részhalmazát. Ez a funkció jelentősen csökkenti a modell varianciáját, indokolatlan előrejelzési torzítás nélkül. A random forest algoritmusban a végső kimenetet többségi szavazási mechanizmus határozza meg, különösen regressziós vizsgálatok esetében.

A random forest olyan kritikus jellemzők előrebecslésére hatékonyak bizonyult, mint az aszfalt dinamikus modulusa [36], a keréknyomvályúk mélysége [38], a Nemzetközi Egyenetlenségi Index (IRI) [36], az útpályán jelentkező aligátorrepedés [37] és a burkolatfelület csúszásellenállása [40]. Rugalmassága és robusztussága révén, a random forest értékes eszköz az aszfaltkutatásban, emellett az útburkolat tulajdonságainak és teljesítményének értékelése során a pontos előrebecslésekhez és a megalapozott döntésekhez is hozzájárul.

4.4. Bitumenes habosító modell

Három modell készült. Az első modell regressziós feladat a gépi tanulásban, neurális hálózat segítségével az ITS értékét jelzik előre, az FBC és az RAP bemeneti jellemzők alapján. A modell tanulási hurkot alkalmaz, amely iteratív módon finomítja a modellt, amíg a modell nem lesz képes arra, hogy sok új értéket szimuláljon és tanulmányozzon, különböző feltételek mellett.

A második modell az előzőre épült, négy oszlopból (FBC, RAP, száraz ITS és nedves ITS) álló adatkészleten lineáris regressziós elemzést hajt végre.

A harmadik modell a szupport vektor regressziót (SVR) hasznosította a közvetett húzószilárdság (ITS) előrejelzésére, nedves és száraz körülmények között.

Ezt követően a korábbi modellek ellenőrzésére random forest modellek készültek, külön-külön kifejlesztve nedves és száraz viszonyokra. A betanítást követően, a modelleket a tesztkészleten értékelik, és kiszámítják az átlagos négyzetes hibát, hogy az előre becsült teljesítményüket számszerűsítsék.

5. EREDMÉNYEK

5.1. Az ITS befolyásoló paramétereivel való kapcsolata

5.1.1. A habosított bitumen tartalom (FBC) ITS-re gyakorolt hatása

Mechanikai tulajdonságok: a habosított bitumen tartalom az aszfaltkeverék merevségét és rugalmasságát növeli.

Nagyobb teljesítmény: a megfelelően ellenőrzött FBC % az adalékanyagok és a bitumen kötőanyag közötti tapadást javítja. Ez a hatékony tapadás pedig hozzájárulhat a nagyobb közvetett húzószilárdsághoz (ITS), ami jobb repedéssel szembeni ellenálláshoz és az útburkolat teljesítményének javulásához vezet.

5.1.2. Az újrahasznosított aszfaltburkolat (RAP) adagolásának hatása a mechanikai tulajdonságokra

Fenntarthatóság: A RAP aszfaltkeverékekben való alkalmazása egyértelműen fenntartható gyakorlat, mivel az elsődleges nyersanyagok iránti keresletet csökkenti, és az aszfaltgyártással kapcsolatos környezeti hatásokat mérsékeli.

ITS és tartósság: A RAP gondosan megtervezett használata hozzájárul az aszfaltkeverék tartósságának és a terheléssel szembeni ellenállásának növeléséhez, ezáltal javítva a burkolat hosszú távú teljesítményét.


Testreszabás (customizing): Az FBC és a RAP egyidejű alkalmazása az aszfaltkeverék-receptúrák testreszabásához (a megrendelői igények fokozott kielégítéséhez) érdemlegesen hozzájárul, megfelelően a projekt konkrét követelményeinek, figyelembe véve olyan tényezőket, mint az éghajlat, a forgalmi terhelés és az út-pálya szerkezete.

5.2. A gépi tanulási (ML) modellek eredményei

5.2.1. Az első modell


A gépi tanulási regressziós feladat modellje, FBC és RAP bemeneti jellemzőkkel, a közvetett húzószilárdság (ITS) előrejelzésére neurális hálózatot

7. ábra: A betanítási és a validálási veszteség időbeli alakulása (1. modell)

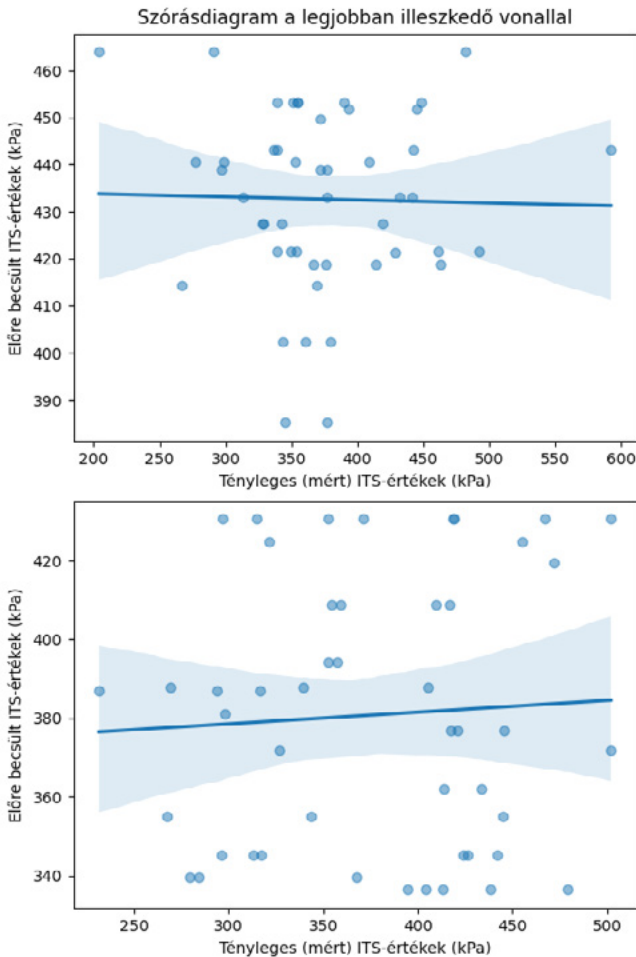


használ. A modell betanítási cikluson megy keresztül, amely iteratív módon finomítja magát, hogy új értékek széles skáláját, különböző körülmények között, szimulálni és tanulmányozni tudjon. Az adatelőkészítési fázisban, a bemeneti jellemzőket X NumPy tömbbe konszolidálják, és az ITS célváltozót y tömbben tárolják. A betanítási hurok (ciklus) magában

8. ábra: Az ITS 3D-s szórásdiagramja, RAP (%) és az FBC (%) függvényében (1. modell)



9. ábra: A betanítási időszak alatti, előre becsült és mért ITS-értékek 2D-s szórás-diagramjai, legjobban illeszkedő függvényekkel (1. modell)



hibaveszteség felhasználásával fejlesztették ki. Ezt követően, szabványosított adatokra, 200 ciklusos betanítást hajtának végre. Majd a tesztadatokra az átlagos négyzetes hibát és az R-négyzetet számítják ki. A betanulási időszak jellemzőinek alakulása, beleértve a betanulási veszteség, a validálási veszteség és az R2 diagramjait, a 7. ábrán látható. A 8. ábra a betanított modellel származó 3D szórásdiagramokat jeleníti meg, ábrázolva a tényleges (mért) és az előre becsült ITS értékek közötti kapcsolatot. A diagramok egyértelművé teszik, hogy a modell adatai mennyire illeszkednek a mérési eredményekhez. A 9. ábra pedig a betanítási folyamat során rögzített 2D szórásdiagramokat mutatja be, amelyek lehetővé teszik a modell előrejelzések időbeli alakulásának és korrekcióinak szemlélését.

foglalja az adatok felosztását betanítási és tesztelési készletekre, a szolgáltatások szabványosítását a StandardScaler segítségével és speciális architektúrájú, neurális hálózat felépítését, Keras API alkalmazásprogramozási felület alkalmazásával.

A neurális hálózat részei: bemeneti réteg 2 neuronnal, rejtett réteg 64 neuronnal és ReLu aktiválással, másik rejtett réteg 32 neuronnal és ReLu aktiválással, valamint kimeneti réteg 1 neuronnal a regresszióhoz. A modellt Adam optimalizálással és az átlagos négyzetes

A 10. ábra a korrelációvizsgálat eredményeit összegezi.

A modell végső alakja a következő:

$$ITS = 0.2939 \cdot FBC + 13.5723 \cdot RAP + 387.4862 \quad (1)$$

Ez az egyenlet kifejezi a neurális hálózatból "tanult", az inputok és az előre becsült ITS közötti összefüggést.

A betanítási folyamat az átlagos négyzetes hiba veszteség függvényét és az Adam opti-

malizálót is hasznosítja. A betanítási folyamat során alkalmazott, legfontosabb egyenletek a következők:

(1) MSE veszteség függvény:

$$\text{MSE} = 1/n \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Az átlagos négyzetes hibát tekintik veszteség függvénynek, ahol n az adatpontok száma, y_i a tényleges (mért) ITS érték és \hat{y}_i az előre becsült ITS érték.

(2) Adam optimalizáló:

Az Adam optimalizáló pontosítja a modell súlyait, a következő egyenletek alkalmazásával: a szabályok aktualizálása minden időbeli lépésben (t):

$$t = t + 1 \quad (3)$$

a gradiens kiszámítása t -edik időbeli lépésben:

$$g_t = \nabla_{\theta} J(\theta_t) \quad (4)$$

az első momentum becslése:

$$m_t = \beta_1 * m_{t-1} + (1 - \beta_1) * g_t \quad (5)$$

a második momentum becslés pontosítása:

$$v_t = \beta_2 * v_{t-1} + (1 - \beta_2) * g_t^2 \quad (6)$$

“zajtól” javított első momentum becslés:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (7)$$

“zajtól” javított, második momentum becslés:

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (8)$$


paraméterek pontosítása:

$$\theta_{t+1} = \theta_t - \alpha * \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad (9)$$

Itt $J(\theta_t)$ a vizsgált θ_t paraméterekre vonatkozó célfüggvény, $\nabla_{\theta} J(\theta_t)$ a célfüggvény gradiense és az ϵ kisértékű állandó, amit azért adnak hozzá, hogy a 0-val való osztást elkerülhessék. Ezeknek az egyenleteknek meghatározó szerepük van a betanítási időszak során a modellparaméterek továbbfejlesztésére annak az érdekében, hogy az átlagos négyzetes hiba

(MSE) veszteséget a lehető legkisebbre szorítsák le, és az ITS értékek előrebecslési pontosságát megnöveljék.

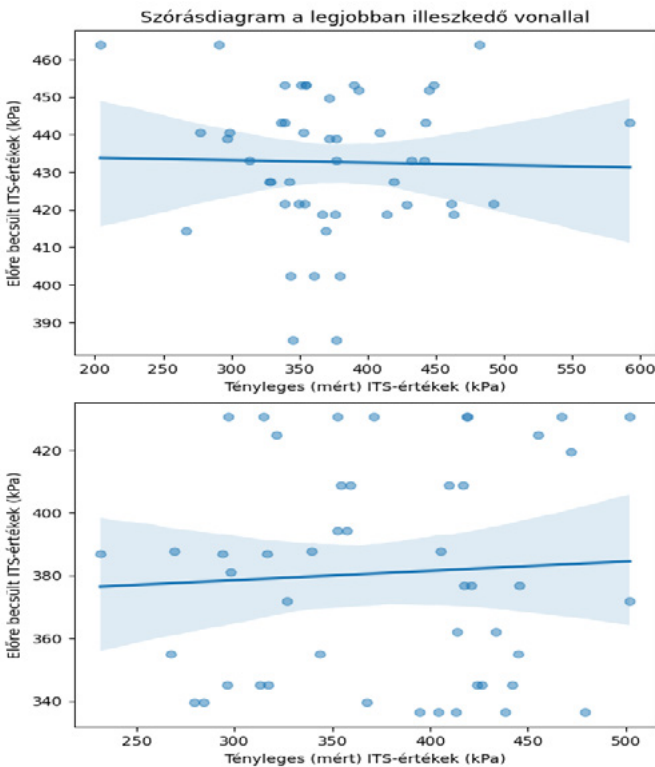
10. ábra: Az ITS-értékek és egyes ható tényezők (FBC%, RAP%) közötti korreláció elemzése (1. modell)



5.2.2. A második modell

A második modell négy oszlopot (FBC, RAP, száraz ITS és nedves ITS) tartalmazó adatkészleten lineáris regressziós elemzést végez. Az adatokat pandas DataFrame szerkezetbe töltöttük be, majd ható jellemzőkre (x) és célváltozókra (y) osztottuk fel. Az adathalmazt, "train_test_split" alkalmazásával, tanítási

11. ábra: A betanítási időszak alatti, előre becsült és mért ITS-értékek 2D-s szórás-diagramjai, legjobban illeszkedő függvényekkel (2. modell)



(80%) és tesztelési (20%) készletekre választottuk szét. Az ábrázolt tényezők konzisztens skálázásának biztosítására a StandardScaler segítségével.

A lineáris regressziós modellt, a scikit-learn LinearRegression osztályának felhasználásával, a betanítási adathalmazon tanítottuk be. Az előre jelzett ITS-értékeket a skálázott tesztkészleten generáltuk. Ez a modell a „száraz ITS” és a „nedves ITS” értéket is külön tekinti az outputok között. A modell teljesítményének vizuális értékeléséhez két szórásdiagramot hoztunk létre (11. ábra). Az első részdiagram a „száraz ITS” szórásdiagramját mutatja be, a pontsorra legjobban illeszkedő egyenessel; a második részdiagram pedig a „nedves ITS” értékekre teszi ugyanezt.

A 12. ábra a 2. modell korrelációvizsgálatának eredményeit összegezi.

A modelleket két rejtett réteggel terveztük, 256 és 128 neuronnal és ReLU aktivációs függvénnyel. Ezeket a modelleket - 0,001 tanulási rátával és az átlagos négyzetes hiba veszteséggel - az Adam optimalizálással állítottuk össze. Az egyes változók egységes formáját a Standard-Scaler segítségével érték el, majd pedig a neurális hálózat modelljeit, a 13. ábrán bemutatott módon, 300 ciklusra betanították.


5.2.3. A harmadik modell

A harmadik modell a közvetett szakítószilárdság (ITS) nedves és száraz körülmények között történő előrejelzésére a szupport vektor

regressziót (SVR) alkalmazza. Az adathalmazra ható tényezőkből (FBC és RAP) és a megfelelő célváltozókból (száraz ITS és száraz ITS) áll. Ezt az adathalmazt ezután felosztottuk tréning (betanítási) és tesztelési (vizsgálati) halmazokra, külön a nedves és külön a száraz körülmények közötti vizsgálatokra. A vizsgált tényezők konzisztens skálázásának biztosítására a StandardScaler segítségével. Két SVR modellt külön-külön, nedves és száraz viszonyokra, betanítottunk, lineáris rendszermagot (kernel-t) alkalmazva.

A betanítást követően, előrebecsléseket hajtottunk végre, a tesztelési adathalmazon, és a modell teljesítményét - nedves és száraz körülmények között - olyan alapvető mérőszámok segítségével értékeltük, mint az R^2 és a korrelációs együtthatók.

12. ábra: Az ITS-értékek és egyes ható tényezők (FBC%, RAP%) közötti korreláció elemzése (2. modell)



A nedves ITS esetében:
 $R^2: 0.712$
 Korreláció: -0.025

A száraz ITS esetében:
 $R^2: 0.780$
 Korreláció: -0.023

Ezzel a modellel a vizsgált tényezők között a következő korrelációs egyenletek születtek:

$$\text{Nedves ITS} = 341.33 - 1.44 \cdot \text{FBC} + 2.81 \cdot \text{RAP}$$

$$\text{Száraz ITS} = 412.30 - 1.48 \cdot \text{FBC} + 2.77 \cdot \text{RAP}$$

Az ellenőrző modellben (a véletlenszerű erdő -

A modellt 300 cikluson keresztül tanítottuk be, 32-es tétel (batch) mérettel; a 14. ábrán bemutatott betanítási folyamat szemlélteti a betanítási (tréning) veszteséget és a validációs veszteséget is.


Az ITS metrika teljesítményét jellemző paraméterek:

random forest - gépi tanulási technikát alkalmazva) szórásdiagramokat generáltunk, hogy mind nedves, mind pedig száraz körülmények között, a véletlenszerű erdő és a neurális hálózat modelljeinek hasznosításával készített előrejelzéseket, a valódi (mért) ITS értékekkel szembeállítva, vizuálisan be lehessen mutatni (15. ábra). Továbbá a nedves és a száraz körülmények közötti, valódi (mért) és előrejelzett


ITS-értékek korrelációs együtthatóinak meghatározására mind a véletlenszerű erdő, mind pedig a neurális hálózat modelleknél korrelációs elemzést is hajtottak végre (16. ábra).

Az általunk választott modell két előrebecslő modellt, nevezetesen a véletlenszerű erdőt és a neurális hálózatot értékeli az ITS értékeknek - az FBC és a RAP jellemzők alapján történő - becslésére, nedves és száraz körülmények között is. A random forest mo-

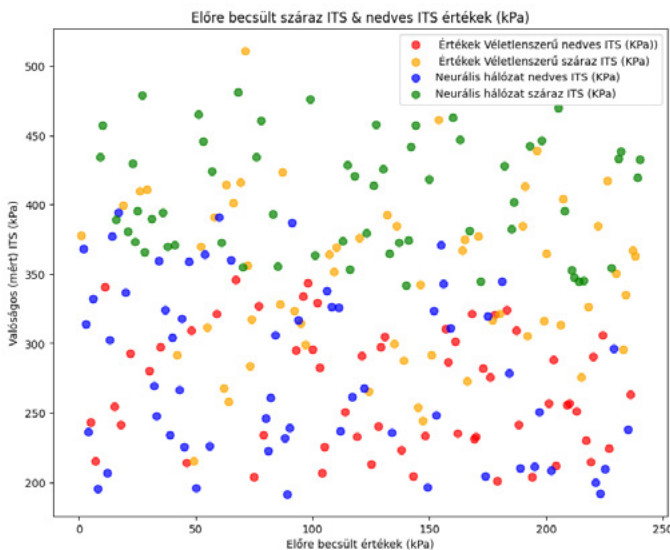
13. ábra: A neurális hálózat betanításának folyamata (2. modell)



14. ábra: A betanítási és a validálási veszteség időbeli alakulása (3. modell)



15. ábra: Az ITS 2D-s szórásdiagramja, a RAP (%) és az FBC (%) függvényében (3. modell)



dellek a scikit-learn random forest regressor segítségével, 100 becsléssel készültek, míg a neurális hálózat modelleket Keras API (Alkalmazásprogramozási Interfész) felhasználásával, a nedves és a száraz körülményekhez is megfelelő architektúrával, fejlesztettük ki.

meglehetősen eltérő viselkedést eredményez. A szárazon vizsgált ITS-nél magasabb, 0,78-as R^2 -érték adódott, mint a nedves viszonyok között nyert 0,71 körüli érték. A vizsgált tényezők között nyert korreláció mindegyik esetben alacsonynak (-0,022 és -0,025 között) adódott.

6. KÖVETKEZTETÉSEK

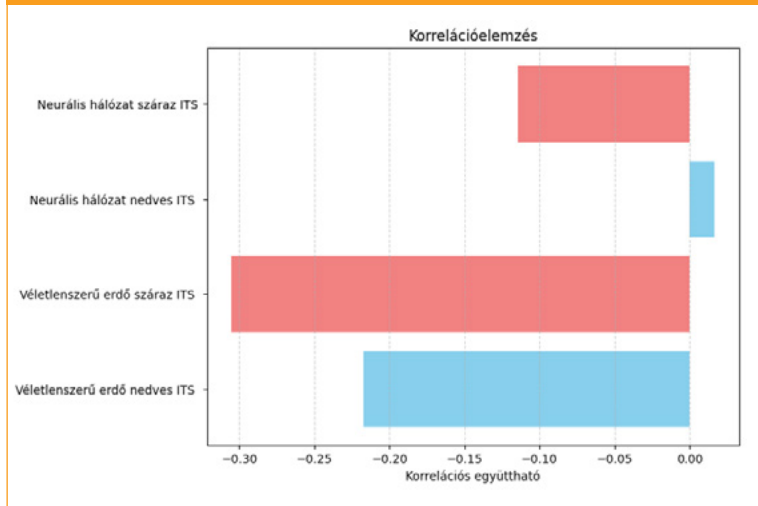
Összefoglalva, az ebben a tanulmányban elvégzett átfogó elemzés rávilágít a habosított bitumentartalom (FBC), az újrahasonosított aszfaltburkolat (RAP) és az aszfaltkeverékek közvetett húzószilárdsága (ITS) közötti bonyolult összefüggésekre. Az FBC kedvező hatása az aszfaltkeverék mechanikai tulajdonságaira és fokozott teljesítményére, a RAP adagolásából származó fenntarthatósági előnyökkel párosulva, együttesen hozzájárulnak az aszfaltburkolatok általános tartósságához és meghibásodásokkal szembeni fokozott ellenállásához.

A kidolgozott modell az ITS és az azt befolyásoló tényezők (FBC és RAP) közötti kapcsolatot sikeresen ($R^2=0,734$) leképezi, azaz az előre becsült adatok a tényleges mért értékekhez jól illeszkednek [41].

A modell teljesítményének különböző körülmények között végzett további elemzése azt mutatta, hogy az ITS metrika nedves és száraz körülmények között

A lineáris regressziós elemzés és a szupport vektor-regressziós (SVR) modellek vizsgálata azt igazolta, hogy az ITS különböző feltételek melletti előrejelzésre ezek hasznos technikának bizonyultak. Ugyanis ezen modellek értékelésével, beleértve a szórásdiagramokat, a korrelációs elemzéseket és az R^2 mérőszámait, bemutattuk ezeknek a megközelítéseknek a hatékonyságát az aszfaltkeverékek komplex tulajdonságainak jellemzésében.

16. ábra: Korrelációelemzés a négy vizsgált esetben (3. modell)



A véletlenszerű erdő (random forest) és a neurális hálózati modellek összehasonlítása bemutatta a gépi tanulási (ML) technikák sokoldalúságát az ITS száraz és nedves viszonyok közötti értékeinek hatékony előrejelzésében.

FELHASZNÁLT IRODALOM

- L. Gáspár and Zs. Bencze, "Long-Life Pavements - European and American Perspectives". NBM&CW (New Building Materials & Construction World) 24 (3), 122-135, 2018
- T. Baghaee Moghaddam and H. Baaj, "Application of compressible packing model for optimization of asphalt concrete mix design," Constr Build Mater, vol. 159, 530-539, 2018, DOI: <https://doi.org/m42t>
- S. B. Cooper, L. N. Mohammad, S. Kabir, and W. King, "Balanced asphalt mixture design through specification modification: Louisiana's experience," Trans Res Record, National Research Council, vol. 2447, 92-100, 2014. DOI: <https://doi.org/m42v>
- S. S. Kar, A. K. Swamy, D. T. Tiwari, and P. K. Jain, "Impact of low viscosity grade bitumen on foaming characteristics," J of the South Afr Inst of Civil Eng, (60) 2, pp. 40-52, 2018, DOI: <https://doi.org/grwjxq>
- L. H. Csanyi, "Foamed asphalt in bituminous

- paving mixtures," Highw Res Board Bull, 160, 1957.
- G. Wirtgen, "Wirtgen cold recycling technology." Wirtgen GmbH Windhagen, Alemania, 2012.
- B. A. Williams, A. Copeland, and T. C. Ross, "Asphalt pavement industry survey on recycled materials and warm-mix asphalt usage: 2017," 2018.
- S. S. Kar, D. Tiwari, A. K. Swamy, and P. K. Jain, "Impact of binder on properties of foamed bituminous mixtures," Proc of Inst of Civil Eng. Const Mater, (17) 4, 194-204, 2017, DOI: <https://doi.org/m42w>
- M. M. Iwanski, A. Chomicz-Kowalska and K. Maciejewski, "Resistance to moisture-induced damage of half-warm-mix asphalt concrete with foamed bitumen," Mat, (13) 3, 2020, DOI: <https://doi.org/gmqqbw>
- M. Hoy, S. Horpibulsuk and A. Arulrajah, "Strength development of Recycled Asphalt Pavement - Fly ash geopolymers as a road construction material," Constr Build Mater, vol. 117, 209-219, 2016, DOI: <https://doi.org/gqg5ps>
- F. Dong, X. Yu, B. Xu, and T. Wang, "Comparison of high temperature performance and microstructure for foamed WMA and HMA with RAP binder," Constr Build Mater, vol. 134, 594-601, 2017, DOI: <https://doi.org/gqg5ps>

- doi.org/grwjpt
12. J. Li, W. Fu, and H. Zang, "Design Method for Proportion of Cement-Foamed Asphalt Cold Recycled Mixture," *MATEC Web of Conf*, vol. 142, 02002, 2018, DOI: <https://doi.org/grwj3k>
 13. Z. Li, P. Hao, H. Liu, and J. Xu, "Effect of cement on the strength and microcosmic characteristics of cold recycled mixtures using foamed asphalt," *J Clean Prod*, vol. 230, 956–965, 2019, DOI: <https://doi.org/grwjbs>
 14. N. Bala, M. Napiyah, and I. Kamaruddin, "Nanosilica composite asphalt mixtures performance-based design and optimisation using response surface methodology," *Int J of Pav Eng*, 21 (1), 29–40, 2020, DOI: <https://doi.org/m42x>
 15. L. P. F. Abreu, J. R. M. Oliveira, H. M. R. D. Silva, D. Palha, and P. V. Fonseca, "Suitability of different foamed bitumens for warm mix asphalts with increasing recycling rates," *Constr Build Mater*, vol. 142, 342–353, Jul. 2017, DOI: <https://doi.org/grwjpv>
 16. M. S. Arefin, T. Quasem, M. Nazzal, A. R. Abbas, and Y. AbuHassan, "Effect of short-term and long-term ageing on dynamic modulus of foamed warm mix asphalt," *Int J of Pav Eng*, (21) 4 , 524–536, 2020, DOI: <https://doi.org/grwjs7>
 17. S. S. Kar, A. K. Swamy, D. Tiwari, and P. K. Jain, "Impact of Chemical Composition on Foaming Characteristics of Asphalt Binder," *J of Trans Eng, Part B: Pav*, (146) 3, 04020045, 2020, DOI: <https://doi.org/gqj38q>
 18. B. K. Bairgi, U. A. Mannan, and R. A. Tarefder, "Influence of foaming on tribological and rheological characteristics of foamed asphalt," *Constr Build Mater*, vol. 205, 186–195, 2019, DOI: <https://doi.org/grwj36>
 19. M. R. Mohd Hasan, Z. You, H. Yin, L. You, and R. Zhang, "Characterizations of foamed asphalt binders prepared using combinations of physical and chemical foaming agents," *Constr Build Mater*, vol. 204, 94–104, 2019, DOI: <https://doi.org/gqhvmm>
 20. E. A. Taziani, E. Toraldo, F. Giustozzi, and M. Crispino, "Investigation on the combined effect of fibers and cement on the mechanical performance of foamed bitumen mixtures containing 100% RAP," *Adv in Mater Sci and Eng*, vol. 2016, 2016, DOI: <https://doi.org/f9chdk>
 21. A. Chomicz-Kowalska and P. Ramiaczek, "Comparative Evaluation and Modification of Laboratory Compaction Methods of Road Base Mixtures Manufactured in Low-emission CIR Technology with Foamed Bitumen and Bitumen Emulsion," in *Proc Eng*, Elsevier Ltd, 2017, 560–569. DOI: <https://doi.org/gmqqb7>
 22. Y. Hou, Y. Cai, Z. Zang, Z. Qian, and B. Zhao, "Dynamic Characteristics of Warm Mix Foamed Asphalt Mixture in Seasonal Frozen Area," *Adv in Mater Sci and Eng*, vol. 2019, DOI: <https://doi.org/grwjrd>
 23. F. V. Guatimosim, K. L. Vasconcelos, L. L. B. Bernucci, and K. J. Jenkins, "Laboratory and field evaluation of cold recycling mixture with foamed asphalt," *Road Mater and Pav Des*, (19) 2, 385–399, 2018, DOI: <https://doi.org/gghvk3>
 24. N. Karballaezadeh, D. Mohammadzadeh S, S. Shamshirband, P. Hajikhodaverdikhan, A. Mosavi, and K. wing Chau, "Prediction of remaining service life of pavement using an optimized support vector machine (case study of Semnan–Firuzkuh road)," *Eng Appl of Comp Fluid Mech*, (13) 1, 188–198, 2019, DOI: <https://doi.org/m43f>
 25. T. Gandhi, W. Rogers, and S. Amir Khanian, "Laboratory evaluation of warm mix asphalt ageing characteristics," *Int J of Pav Eng*, (11) 2, 133–142, 2010, DOI: <https://doi.org/fb9gtx>
 26. ASTM D692-00 "Standard Specification for Course Aggregate for Bituminous Paving Mixtures", 2004, 2 p.
 27. EN 12591 "Bitumen and bituminous binders—Specifications for paving grade bitumens", 2009, 36 p.
 28. F. Kamran, M. Basavarajappa, N. Bala, and L. Hashemian, "Performance evaluation of stabilized base course using asphalt emulsion and asphaltene derived from Alberta oil sands," in *Trans Res Rec* vol. 2675, no. 10, SAGE Publications Ltd, 2021, 764–775. DOI: <https://doi.org/m43m>
 29. V. Vapnik, *The nature of statistical learning theory*. Springer science & business media, 1999. ISBN 978-1-4419-3160-3
 30. K. Gopalakrishnan, A. M. Asce, and S. Kim, "Support Vector Machines Approach to HMA

- Stiffness Prediction”, J of Eng Mech (137) 2 DOI: <https://doi.org/drkkbd3>
31. M. Maalouf, N. Khoury, and T. B. Trafalis, “Support vector regression to predict asphalt mix performance,” Int J Numer Anal Methods Geomech, (32) 16, 1989–1996, 2008, DOI: <https://doi.org/c4kk5g>
 32. Y. Zhao, K. Zhang, Y. Zhang, Y. Luo, and S. Wang, “Prediction of air voids of asphalt layers by intelligent algorithm,” Constr Build Mater, vol. 317, p. 125908, 2022. DOI: <https://doi.org/m43x>
 33. M. Nazemi and A. Heidaripناه, “Support vector machine to predict the indirect tensile strength of foamed bitumen-stabilised base course materials,” Road Mater and Pav Des, (17) 3, 768–778, 2016, DOI: <https://doi.org/m43z>
 34. H. Ziari, M. Maghrebi, J. Ayoubinejad, and S. T. Waller, “Prediction of pavement performance: Application of support vector regression with different kernels,” Transp Res Rec, vol. 2589, 135–145, 2016, DOI: <https://doi.org/gnrfzf>
 35. Y. Huang, “Advances in artificial neural networks - Methodological development and application,” Alg, (2) 3, 973–1007, 2009. DOI: <https://doi.org/ctbcq2>
 36. H. Gong, Y. Sun, X. Shu, and B. Huang, “Use of random forests regression for predicting IRI of asphalt pavements,” Constr Build Mater, vol. 189, 890–897, 2018, DOI: <https://doi.org/gk88dm>
 37. A. Fathi, M. Mazari, M. Saghafi, A. Hosseini, and S. Kumar, “Parametric Study of Pavement Deterioration Using Machine Learning Algorithms.” Int Airf and Highw Pav Conf 2019, 12 p. DOI: <https://doi.org/gnrfzk>
 38. D. Daneshvar and A. Behnood, “Estimation of the dynamic modulus of asphalt concretes using random forests algorithm,” Int J of Pav Eng, (23) 2, 250–260, 2022, DOI: <https://doi.org/gg6rkg>
 39. H. Gong, Y. Sun, W. Hu, P. A. Polaczyk, and B. Huang, “Investigating impacts of asphalt mixture properties on pavement performance using LTPP data through random forests,” Constr Build Mater, vol. 204, 203–212, 2019, DOI: <https://doi.org/m433>
 40. Y. Zhan, J. Q. Li, C. Liu, K. C. P. Wang, D. M. Pittenger, and Z. Musharraf, “Effect of aggregate properties on asphalt pavement friction based on random forest analysis,” Constr Build Mater, vol. 292, 2021, DOI: <https://doi.org/grtkz5>
 41. A. Saleh, Gáspár L., “Különböző újrahazsnóított aszfalt (RAP) tartalmú, habosított beton kötőanyagú aszfaltkeverékek közvetett húzószilárdságának modellezése”, Útügyi Lapok 12. évf. 19. szám 12 p. 2024. június, DOI: <https://doi.org/m75q>



Modelling the Indirect Tensile Strength of Asphalt Mixtures with the Use of Artificial Intelligence

Keywords: foamed bitumen; warm mix asphalt; neural network; Support Vector Regression (SVR); Machine learning

The authors estimate the indirect tensile strength of asphalt mixtures containing recycled asphalt and foamed bitumen using linear regression and neural network models. By comparing the random forest and the neural network model, the applicability of machine learning techniques in this field was proven. In the course of the research work, three models were developed, which are able with a high R^2 value to predict the relationship between the ITS (wet and dry) value and two factors affecting it, namely the foamed bitumen content and the Reclaimed Asphalt Pavement (%).



Modellierung der indirekten Zugfestigkeit von Asphaltmischungen mit Hilfe künstlicher Intelligenz

Schlüsselwörter: Schaumbitumen; warmes Asphaltmischgut; neuronales Netz; Support Vector Regression (SVR); maschinelles Lernen

Die Autoren prognostizieren die indirekte Zugfestigkeit (ITS) von Asphaltmischungen, die Recyclingasphalt und Schaumbitumen enthalten, mit Hilfe linearer Regressions- und neuronaler Netzwerkmodelle. Die Nützlichkeit von Techniken des maschinellen Lernens in diesem Bereich wurde durch den Vergleich von Random-Forest- und neuronalen Netzwerkmodellen nachgewiesen. Im Verlauf ihrer Forschung haben sie drei Modelle entwickelt, um die Beziehung zwischen ITS und zwei ihrer beeinflussenden Faktoren, dem Schaumbitumengehalt und dem Anteil an Recyclingasphalt, unter trockenen und nassen Bedingungen bei einem hohen R^2 -Wert vorherzusagen.