Aszfalt felületi hőmérsékletének meghatározása időjárási adatok alapján

Koch Domonkos[1,*]

[1] doktorandusz, Budapest Műszaki és Gazdaságtudományi Egyetem, Út- és Vasútépítési Tanszék
[*] felelős szerző

e-mail: koch.domonkos@emk.bme.hu

Kézirat benyújtva: 2026.06.20.
Kézirat elfogadva: 2026.07.17.

© *Koch D.*

Absztrakt

A burkolat hőmérséklete kulcsfontosságú az útépítésben, mind a pályaszerkezet méretezése, mind az útüzemeltetés területén. A burkolat felszínének hőmérsékletéből meghatározható a mélységi hőmérséklet, ami a méretezésben, valamint a behajlásméréseknél fontos paraméter. A felszíni hőmérséklet az üzemeltető mérnökségek számára kiemelt jelentőséggel bír a téli üzem során, mivel indikátorként használják a megelőző síkosságmentesítés megkezdéséhez. A magyar országos közúthálózaton mintegy 400 db meteorológiai állomás helyezkedik el, ami azt jelenti, hogy 80 km úthálózat hőmérsékleti állapotát jellemzi egyetlen mérőállomás. Ezek a mérőállomások az úthőmérséklet mellett számos egyéb időjárási adatot is gyűjtenek, mint a levegő hőmérséklete, relatív páratartalom, szélsebesség stb. Jelen cikk időjárási adatokon alapuló regressziós modelleket vizsgál a felületi hőmérséklet előrejelzésére. A magyarországi meteorológiai állomások adatait használva 24 különböző modellt tanítottam be. A legjobb (Matérn 5/2 GPR) modell 10 perces gyakoriságú adatok segítségével RMSE = 2,33 °C pontosságot ért el, míg az órás inputok alkalmazásával a modell pontossága RMSE = 2,24 °C-ra javult, ami a statisztikai zaj csökkentésével magyarázható. A nappali és éjszakai adatsor szétválasztásával optimalizált modell nem javított a pontosságon, viszont a számítást minimálisan bonyolította, így a végső modell a 24 órás összesített adatokon tanult. A cikk alátámasztja, hogy négy időjárási input (levegőhőmérséklet, napsugárzás, annak változása, vízfilmvastagság) elegendő ennek eléréséhez. Az egyéb időjárást jellemző paraméterek, mint a relatív páratartalom, szélsebesség,

csapadékintenzitás nem javították a modell pontosságát. Az egyszerűbb modellek (pl. lineáris regressziós modell, RMSE = 2,88 °C) is hasonló globális pontosságot mutattak, azonban szélsőséges hőmérsékletek esetén az átlagos hibájuk jelentősen megnőtt, 40 °C felett RMSE > 4,5 °C értéket vett fel. Ezért a komplexebb modell alkalmazása mérnöki szempontból javasolt a nagyobb számítási igénye mellett is. A bemutatott regressziós modell segítségével három mért és egy számított időjárási adat alapján meghatározható a burkolat felszíni hőmérséklete. Ez az eszköz lehetőséget ad arra, hogy olyan helyszíneken is ismert legyen a burkolat hőmérséklete, ahol nincs vagy attól távol helyezkedik el mérőállomás, esetleg burkolatfelújítás után nem került helyreállításra vagy egyéb okból üzemszünet áll fenn. Egy hosszú távú élettartam monitoring esetében ez fontos információ lehet, ennek hazai kidolgozásáig és alkalmazásáig a cikkben bemutatott modell hatékony segítséget nyújthat a téli üzemeltetés során a közutak kezelői számára, ami növeli a forgalombiztonságot.

***Kulcsszavak:** aszfalthőmérséklet, gépi tanulás, regressziós modellek, hőmérséklet-előrejelzés, időjárási adatok*

DOI: https://doi.org/10.24228/KTSZ.2026.5.2

1. BEVEZETÉS

A tervezők, a kivitelezők és az útüzemeltetők egyaránt érdekeltek a burkolatok hőmérsékletének megismerésében. A tervezők a valós hőmérséklet-eloszlást kívánják figyelembe venni az aszfaltrétegek vastagságának meghatározásakor, mivel az aszfalt merevsége hőmérséklet-függő. A technológusok célja az előírásoknak leginkább megfelelő, optimális keverékösszetétel (receptúra) megtervezése. Az útüzemeltetők feladata a burkolat minél hosszabb élettartamának biztosítása, amelynek során a meteorológiai hatásokkal szembeni ellenállóképességet a tervezési és építési fázisban határozzák meg. A burkolaton belüli hőáram vizsgálata a pályaszerkezet viselkedésének jobb megértése érdekében szükséges (Ureczky et al., 2008). Pethő (2008) a disszertációjában feltárta az aszfalt alsó szálában ébredő megnyúlás és a réteg, valamint a léghőmérséklet kapcsolatát, amik között szoros összefüggést talált ($R^2 = 0,99$ és $R^2 = 0,84$). A burkolathoz kapcsolódó üzemeltetési tevékenységeket az időjárási körülmények és az aszfaltburkolat hőmérséklete nagymértékben befolyásolja. A romlási folyamatokat (nyomvályúsodás, fáradás és hőmérsékleti repedés) a hőmérséklet éppúgy meghatározza, mint a téli üzemeltetési feladatokat, hiszen a megelőző sózás is egy adott hőmérsékleti küszöbhöz kötött. A burkolat-hőmérséklet modellezése így a mérnöki gyakorlat szempontjából kiemelkedő fontosságú kutatási terület. Mivel a burkolat hőmérséklete minden időjárási körülménnyel összefügg, észszerű feltételezni, hogy a felületi hőmérséklet meteorológiai adatok alapján visszaállítható. Az időjárási adatok, különösen a léghőmérséklet mérése könnyű feladat, így javasolt felhasználni az aszfalt hőmérsékletének meghatározásához (Herceg et al., 2020). A klímaváltozás következtében a jövő útépítő mérnökeinek új kihívásokkal kell szembenézniük, ha a tervezési és karbantartási peremfeltételek a növekvő hőmérséklet miatt megváltoznak. Ez akkor is fontos szempont, ha a bitumenek igénybevételi tartománya hőmérséklet szempontjából nem fog nőni (Herceg et al., 2022). A probléma kezelésének első lépése a hőmérséklet robusztus modellekkel történő, megbízható meghatározása.

Az ezen a területen elért első eredmények az 1950-es és 1960-as évekre nyúlnak vissza (Barber, 1957; Rumney et al., 1969). A Long-term Pavement Performance Program (LTPP)

fejlettebb modelleket dolgozott ki (Mohseni, 1998), amelyek Észak-Amerika összes régióját lefedték, de kizárólag a szélsőértékekre fókuszáltak. Később más kutatók is fejlesztettek új modelleket (Dierfenderfer et al., 2006; Khan et al., 2019), követve ugyanezeket az elveket és célkitűzéseket. Ezek mind regressziós modelleknek tekinthetők. A másik fő eljárás a hőmérlegegyenlet megoldása (Solaimanian et al., 1993). Ennek során a burkolat felületén egy negyedfokú energiamegmaradási egyenletet írnak fel és oldanak meg. Magyarországon gyűjtött úthőmérsékleti adatsor reprodukálására elfogadható eredménnyel igazolták az energia-egyensúlyi egyenletet (Cho et al., 2022). Ennek ellenére ezt a módszert gyakran éri az a kritika, hogy bár a konvekciós hőcsere kiszámításához figyelembe veszi a szélsebességet, az alkalmazott empirikus képlet a legmagasabb felületi hőmérsékletet paradox módon 4,5 m/s szélsebesség mellett adja meg, amire nincs fizikai magyarázat, valamint korlátos abban az értelemben, hogy az ipari gyakorlatban keveset vizsgált anyagparaméterekkel dolgozik (emissziós tényező, albedo, abszorpcitás), valamint numerikus megoldás nem egyszerű feladat gyakorló mérnökök számára.

A regressziós modellek jól használhatók a hőmérséklet becslésére, mert empirikus jellegüknél fogva fizikailag könnyen értelmezhetők, és lokális körülményekre, megfelelő számú bemenő adat esetén könnyen taníthatók. Napjainkban is jelennek meg újabb modellek, ezek többnyire neurális hálókat vagy komplex regressziós modelleket alkalmaznak. Huang és társai 2,21 °C pontosságot értek el gépi tanulási technikával (Huang et al. 2024), míg az XGBoost komplex modell alkalmasnak bizonyult valós idejű hőmérséklet becslésre is (Kebede et al, 2024).

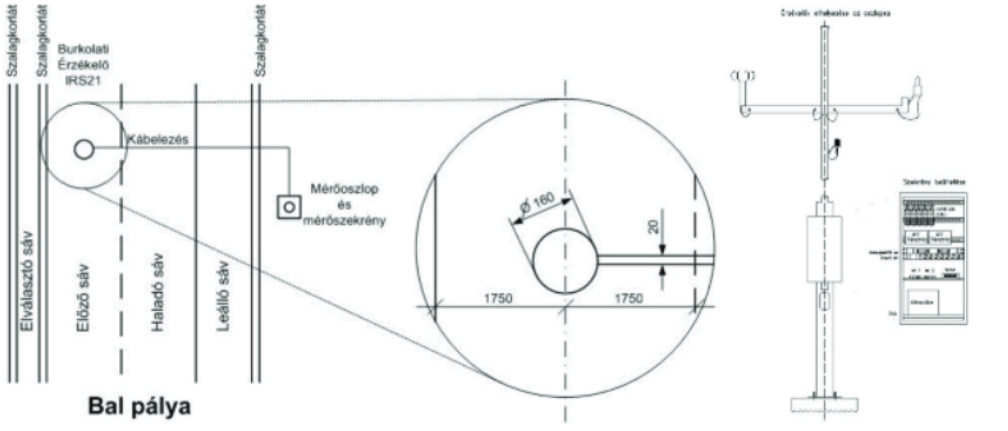
Jelen cikkben egy új regressziós modellt mutatok be, amelyet magyarországi meteorológiai adatok alapján fejlesztettem ki. A cél nem csupán a szélsőértékek (minimum és maximum), hanem a közbenső értékek és a napi ingadozás meghatározása is. A modell pontosságának igazolására statisztikai elemzéseket végeztem.

2. MÓDSZERTAN

2. 1. Adatgyűjtés

Magyarország országos közúthálózata több mint 32 700 km hosszú, mely magába foglalja az autópályákat, autóutakat és főutakat. Ezen a hálózaton számos elektronikai berendezés található a forgalomszámlálás, a súlymérés, illetve az időjárási adatok gyűjtése céljából. A hálózaton több mint 400 meteorológiai állomás üzemel. Az *1. ábra* egy tipikus hazai útmeteorológiai állomás elrendezését mutatja be.

Egy ilyen állomás általában burkolatba épített szenzort, mérőoszlopot, vezérlőszekrényt és kábelezést tartalmaz. A burkolati szenzor a felületi hőmérséklet mellett két opcionális mélységi



1. ábra: Egy meteorológiai állomás általános felépítése (Forrás: saját szerkesztés, Sagemcom Magyarország Kft.)

szenzorral képes mérni a burkolat mélyebb rétegeinek a hőmérsékletét, valamint a sókoncentrációt, a fagyáspontot és a vízfilmvastagságot. Az oszlopon további érzékelők kapnak helyet: tipikusan egy levegőhőmérséklet- és páratartalom-mérő eszköz. A levegő hőmérsékletét platina ellenállás-hőmérővel, a relatív páratartalmat pedig kondenzátoros elven mérik. A csapadék típusát, intenzitását és mennyiségét egy 24 GHz-es Doppler-radar rögzíti, amely képes azonosítani a csapadékszemcsék méretét és sebességét. A szél sebességét és irányát négy, kereszt alakban, egymással szemben elhelyezett ultrahangos jeladó méri. Tízperces felbontásban összesen 32 különböző adat rögzíthető. Az állomás mérési tartománya -40 °C és +70 °C között van, ami kielégítőnek tekinthető, mivel a valaha mért szélsőséges értékek soha nem lépték túl ezeket a határokat. A kutatás során több millió adatot gyűjtöttem be 26 magyarországi (kizárólag autópályákon elhelyezett) állomásról. A *2. ábra* mutatja az állomások elhelyezkedését és az adatok időkeretét.

A legtöbb, időjárási adatokon alapuló tanulmány rávilágított arra, hogy a levegő hőmérséklete mellett a napsugárzásnak van a legnagyobb hatása az aszfalt felületi hőmérsékletére. A telepített állomások azonban nem rendelkeznek a napsugárzás mérésére alkalmas eszközzel. Az adatbázis kiegészítése érdekében a DNV céghez tartozó Solcasttól szereztem be globálsugárzási (besugárzási) adatokat a pontos helyszínekre vonatkozóan, majd kiszámítottam a globálsugárzás megváltozását.

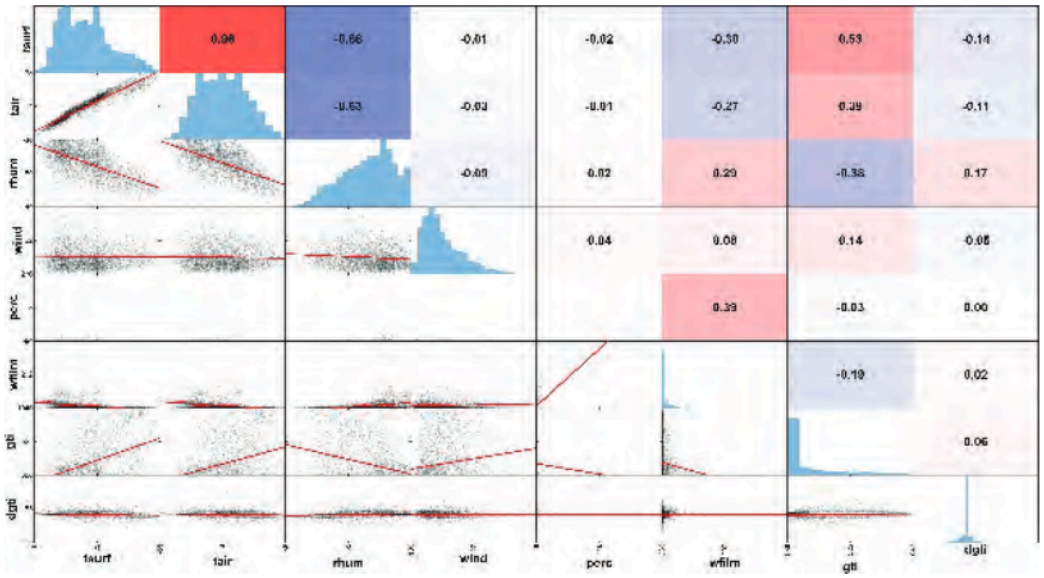
A részletes elemzéshez egyetlen állomást (M4 214+030 km) választottam ki, amely 3 éves (2022-2024) adatbázissal rendelkezett. A begyűjtött 38 adatfajtából a korábbi tanulmányok és a mérnöki megfontolások alapján csupán 7 prediktort választottam ki:

- *tair* – levegőhőmérséklet, °C,
- *gti* – globálsugárzás, W/m^2,
- *dgti* – globálsugárzás változása, W/m^2,
- *rhum* – relatív páratartalom, %,
- *perc* – csapadékintenzitás, mm/h,
- *wfilm* – vízfilmvastagság, µm
- *wind* – szélsebesség, km/h.

A globálsugárzás változásának (*dgti*) bevonása szokatlan tényező lehet. A levegő és a burkolat maximális hőmérséklete a besugárzási csúcs után jelentkezik, ami időkésést (time lag) okoz. A sugárzás amplitúdója azonban a csúcs után is magas marad, ami a „túllövés" veszélyét rejti magában. A *dgti* bevezetése lehetővé teszi, hogy a modellek érzékeljék a változást és a várható jövőbeli tendenciát. A többi adatot a redundancia (pl. diffúz sugárzás), az irrelevancia (pl. szélirány) vagy az adatok folytonosságának hiánya miatt zártam ki. A legjobb prediktorok megtalálása érdekében Pearson-korrelációval keresztkorrelációs vizsgálatot végeztem, amelyet a *3. ábra* mutat be.



2. ábra: Adatgyűjtésbe bevont hazai meteorológiai állomások (Forrás: saját szerkesztés)



3. ábra: Prediktorok keresztkorrelációs mátrixa (Forrás: saját szerkesztés)

Bár az előzetes keresztkorrelációs teszt arra utalt, hogy egyes prediktoroknak kisebb (*wfilm, perc, dgti*), míg másoknak nagyobb (*rhum*) a hatása, a tanítás során mind a hét prediktort felhasználtam. Az adatbázist felosztottam: az első két év (2022-2023) adatait használtam a tanításhoz, a harmadik év adatait pedig a teszteléshez.

2. 2. Modelltípusok

Összesen 24 különböző modelltípust tanítottam és teszteltem.

Lineáris modellek: Ezek a legköltséghatékonyabb és legegyszerűbb modellek. Az együtthatókat a legkisebb négyzetek módszerével számítottam ki. Az interakciós és lépésenkénti (stepwise) regressziós modellek képesek megragadni két független változó együttes hatását a függő változóra, míg a robusztus lineáris regresszió a kiugró értékek kezelését optimalizálja.

Döntési fa modellek (finom, közepes, durva): Erőteljes gépi tanulási algoritmusok, amelyek fa-szerű struktúrával számítják ki az eredményt, minimalizálva az átlagos négyzetes hibát.

Support Vector Machine (SVM) modellek (lineáris, négyzetes, köbös, finom/közepes/durva Gauss): Nem paraméteres optimalizáló eszközök (Vapnik, 1995).

Gauss-folyamat alapú regressziós modellek (GPR) (racionális négyzetes, négyzetes exponenciális, Matérn 5/2, exponenciális): Nem paraméteres, felügyelt tanulási technikák valószínűségi problémák megoldására. A modellek közötti különbséget az alkalmazott kernel (mag) függvények jelentik (Rasmussen et al., 2006).

Fa-együttesek (Ensembles): Döntési fa modelleket fognak össze a pontosság növelése érdekében. A „Boosted" modell az előző fára építve korrigálja a hibákat, míg a „Bagged" modell független fákat használ, és átlagolja az eredményeket.

Neurális hálózatok (szűk, közepes, széles, kétrétegű, háromrétegű): Az emberi agy működése ihlette őket. A bemeneti és kimeneti rétegek között több rejtett, összekapcsolt réteg tanulja meg a mintázatokat a kimenet előrejelzése érdekében.

2. 3. Modellkonfiguráció

Két modellkonfigurációt tanítottam, teszteltem és hasonlítottam össze. A *24 órás* (teljes napos) modellek esetében a teljes adatbázist egyben használtam fel. A *nappali-éjszakai* modelleknél az adatbázist a sugárzás (*gti*) alapján bontottam ketté: ahol *gti* = 0, azt éjszakának tekintettem. Ennek a feltételezésnek az volt az alapja, hogy

éjszaka a sugárzás nulla, viszont a többi időjárási változó olyan széles kombinációkat vehet fel, ami ronthatja a *24 órás* modellek tanítási hatékonyságát. Az elvárás az volt, hogy a különválasztott *nappali és éjszakai modellek* együttesen felülmúlják a *24 órás modellt*.

A legjobb matematikai modell és konfiguráció kiválasztása után a pontosságot az adatsűrűség függvényében is megvizsgáltam. Az eredeti 10 perces adatsort úgy alakítottam át, hogy a 10 perces értékeket 1 órás átlagokká számoltam át.

2. 4. Statisztikai tesztek

A 3 éves adatsorból az első két év szolgált tanító adatként (105 122 megfigyelés prediktoronként), míg a harmadik évet (52 704 megfigyelés) független tesztadatként különítettem el.

A tanított modellekre és a tesztadatokra meghatároztam az RMSE, a MAE és az R^2 értékeket. Two one-sided test (TOST) vizsgálatot végeztem annak alátámasztására, hogy a becsült értékek statisztikailag azonosnak tekinthetők-e a mért értékekkel (Schuirmann, 1987). A varianciaanalízis (ANOVA) helyett azért választottam ezt, mert az ANOVA nagyszámú megfigyelés esetén a legapróbb hibákra is túlzottan érzékeny. Mivel a TOST az útépítési gyakorlatban ritkábban használt módszer, az alábbiakban röviden ismertetem.

A TOST a nullhipotézist vizsgálja két átlag, a vizsgált populáció (μ_T) és a referenciapopuláció (μ_R) közötti különbség hiányára. A hipotézis szerint $\Theta_1 < \mu_T - \mu_R < \Theta_2$, ahol a $[\Theta_1, \Theta_2]$ egy olyan „ekvivalencia intervallum", amelyen belül a különbség olyan kicsi, hogy a két érték egyenlőnek tekinthető. Feltételezzük, hogy az adathalmaz statisztikai értelemben kiegyenlített, vagyis az intervallum szimmetrikus a nullára ($\Theta_1 = -\Theta_2$). Az intervallumhipotézist két egyoldalas hipotézisre kell bontani:

$H_{01}: \mu_T - \mu_R \leq \Theta_1$ és $H_{11}: \mu_T - \mu_R > \Theta_1$

$H_{02}: \mu_T - \mu_R \geq \Theta_2$ és $H_{12}: \mu_T - \mu_R < \Theta_2$

A μ_T és μ_R ekvivalenciája csak akkor jelenthető ki, ha mind H_{01}, mind H_{02} elutasításra kerül két egyoldali t-próbával:

$$t_1 = \frac{\bar{d} + \theta_1}{se} \geq t_{1-\alpha}$$

és

$$t_2 = \frac{\bar{d} + \theta_2}{se} \leq t_{1-\alpha}$$

A számításhoz d az eltérések átlaga, se a különbségek standard hibája és α a szignifikanciaszint értéke. A szenzorok mérési pontosságából kiindulva $\alpha = 0{,}05$, $\theta_1 = -0{,}2$, és $\theta_2 = 0{,}2$ értékekkel számoltam.

A prediktorok számának minimalizálása érdekében elemeztem azok hatását az RMSE-re. A maradékhibákat szintén megvizsgáltam: kiszámítottam az eloszlást, és Bland-Altman tesztet is lefuttattam (Bland et al., 1986).

3. EREDMÉNYEK

3. 1. Alapmodell tanítása

Az alapértelmezett modelltanítás a 24 órás, nagy felbontású (10 perces) adatsoron történt. Az eredményeket az *1. táblázat* tartalmazza.

A modelleket a tesztelés utáni RMSE értékek alapján rendeztem sorba. Csupán a köbös SVM modell eredménye tekinthető rossznak, az összes többi modell pontossága szűk tartományban mozog. Az R^2 értékek egyenletesen magasak. Az elvárásoknak megfelelően a hosszabb tanítási idő és a robusztusabb modellek pontosabb eredményt hoztak, de a betanítási idő és a modellméret nem egyenesen arányos a pontossággal, hiszen a legegyszerűbb modellek (lineáris regresszió, finom fa modell) is elfogadható eredményt nyújtottak. A hibamutatók a tesztelés során – a várakozásoknak megfelelően – enyhén romlottak (átlagos „túltanulási" hiba: 0,38 °C).

A globális pontosság egy kivételtől eltekintve mindegyik modell esetében megfelelő volt (Dickinson, 1978). Az egyszerűbb modellek, bár nagyságrendekkel kevesebb számítási kapacitást igényelnek, pontosságuk csak a középső hőmérsékleti tartományban állítható párhuzamba a komplexebb modellekkel. A Matern 5/2 GPR modell és a legegyszerűbb, lineáris regressziós modell összehasonlítását mutatja a *4. ábra*. Jól látható, hogy 40 °C fok fellett az átlagos négyzetes hiba a lineáris

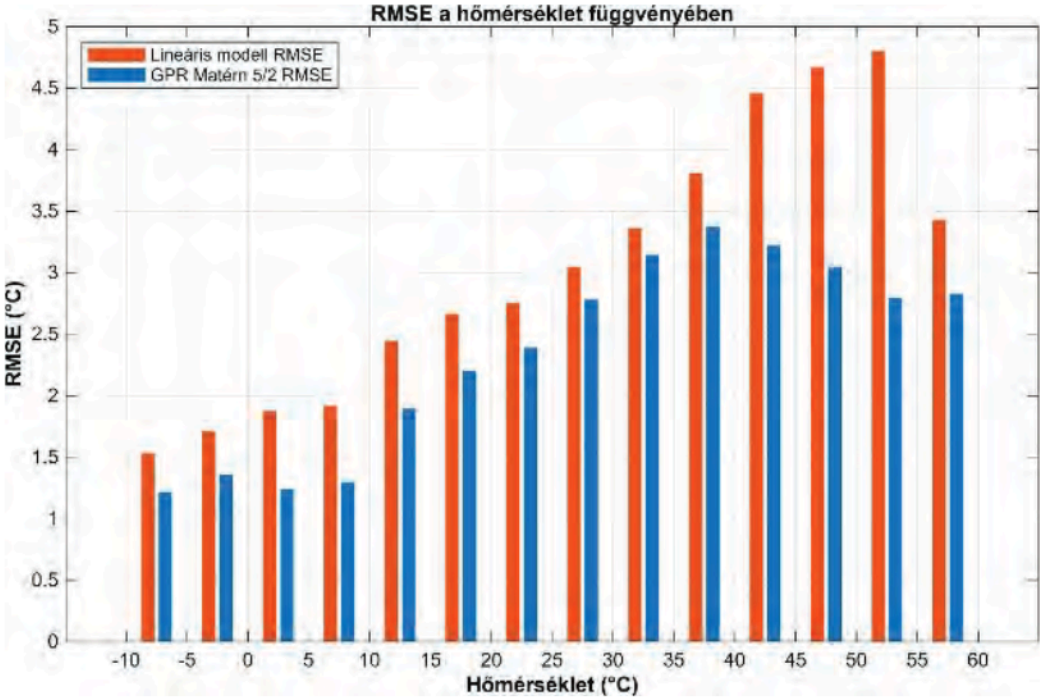
modell esetében jelentősen megnő, meghaladja a 4,5 °C-t is. Alacsony hőmérsékletek esetén a modellek hibája alacsonyabb, azonban itt is a lineáris modell pontossága relatíve leromlik, a GPR modellhez képest az RMSE több mint 50%-kal nagyobb. Ezért az egyszerűbb modellek alkalmazása nem javasolt.

3. 2. Nappali-éjszakai modell

A nappali és éjszakai modellek tanításához az adatsort a *gti* érték alapján szétválasztottam. Ugyanazokat a modellstruktúrákat alkalmaztam, a végeredmény kiszámításához pedig összefűztem a nappali és éjszakai becsült halmazokat. A legjobb modelleket a *2. táblázat* hasonlítja össze a 24 órás alapmodellekkel.

Modell csoport	Modell típus	Tanítási idő (s)	Tanítás			Teszt		
			RMSE (°C)	MAE (°C)	R^2	RMSE (°C)	MAE (°C)	R^2
GPR	Matern 5/2	28 812	1,98	1,36	0,98	2,33	1,64	0,97
neurális háló	széles	50 017	2,03	1,41	0,98	2,35	1,68	0,97
SVM	közepes	6 976	2,10	1,45	0,98	2,37	1,67	0,97
GPR	racionális négyzetes	65 607	1,92	1,30	0,98	2,38	1,67	0,97
neurális háló	közepes	48 646	2,16	1,51	0,97	2,38	1,72	0,97
neurális háló	háromrétegű	50 877	2,21	1,56	0,97	2,39	1,71	0,97
GPR	négyzetes exponenciális	19 927	2,12	1,47	0,97	2,40	1,71	0,97
GPR	exponenciális	47 999	1,71	1,08	0,98	2,48	1,75	0,96
neurális háló	kétrétegű	50 367	2,19	1,53	0,97	2,49	1,80	0,96
neurális háló	keskeny	48 222	2,26	1,59	0,97	2,52	1,82	0,96
Fa-együttes	Bagged	7 890	1,74	1,16	0,98	2,52	1,77	0,96
SVM	durva	7 768	2,39	1,68	0,97	2,63	1,90	0,96
Fa-együttes	Boosted	7 803	2,52	1,76	0,96	2,67	1,96	0,96
Fa	durva	79	2,13	1,45	0,97	2,70	1,90	0,96
SVM	négyzetes	2 207	2,49	1,74	0,97	2,73	1,98	0,96
lineáris	Stepwise	278	2,50	1,77	0,96	2,78	2,03	0,96
lineáris	Interactions	16	2,50	1,77	0,96	2,78	2,03	0,96
Fa	közepes	73	2,06	1,36	0,98	2,83	1,98	0,95
SVM	lineáris	824	2,69	1,94	0,96	2,86	2,14	0,95
lineáris	robosztus	16	2,74	1,93	0,96	2,86	2,12	0,95
SVM	finom	5 977	2,35	1,46	0,97	2,87	1,92	0,95
lineáris	lineáris	13	2,67	1,96	0,96	2,88	2,19	0,95
Fa	finom	56	2,11	1,34	0,98	3,01	2,09	0,95
SVM	köbös	11 338	6,12	4,27	0,79	7,33	3,96	0,69

1. táblázat: A 24 órás, 10 perces felbontású adatokon tanított modellek teszt eredményei (Forrás: saját szerkesztés)



4. ábra: A hibák hőmérséklet függése (Forrás: saját szerkesztés)

Modell csoport	Modell típus	RMSE (°C)		MAE (°C)		R^2	
		24h	N-É	24h	N-É	24h	N-É
GPR	Matern 5/2	2,33	2,34	1,64	1,65	0,97	0,97
Neurális háló	széles	2,35	2,39	1,68	1,69	0,97	0,97
SVM	közepes	2,37	2,39	1,67	1,68	0,97	0,97
GPR	racionális négyzetes	2,38	2,33	1,67	1,65	0,97	0,97
Neurális háló	háromrétegű	2,39	2,48	1,71	1,77	0,97	0,96
GPR	négyzetes exponenciális	2,40	2,41	1,71	1,71	0,97	0,97
GPR	exponenciális	2,48	2,42	1,75	1,72	0,96	0,97

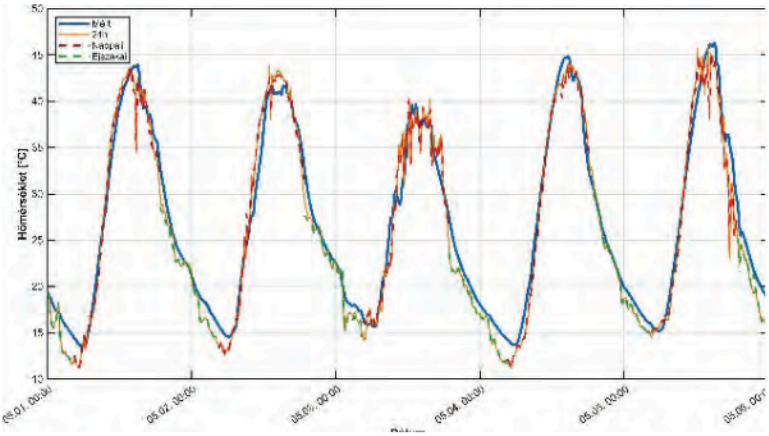
2. táblázat: A 24 órás és a nappali-éjszakai modell összehasonlítása (Forrás: saját szerkesztés)

A nappali-éjszakai modell eredményei csupán elhanyagolható különbséget mutattak (ΔRMSE < 0,1 °C) a 24 órás modellekhez képest. Noha a rangsor némileg változott, ugyanazok a modellstruktúrák hozták a legjobb eredményeket. Az *5. ábra* a mért és becsült hőmérsékleteket mutatja. Nincs vizuális különbség a két konfiguráció között, bár mindkettő zajos maradt, ami a GPR modellezés sajátos hátrányának tekinthető.

3. 3. Two one-sided test

Az eredmények alapján a Matern 5/2 kernelfüggvényt alkalmazó, Gauss-folyamat alapú, regressziós modell (GPR) bizonyult a legjobb modellnek. A TOST elemzés célja annak igazolása volt, hogy a becsült értékek a mért értékekkel statisztikai értelemben egyenértékűek, azaz a köztük lévő hiba az előre definiált [-0,2; 0,2] tartományon belül marad. Mivel $p_{TOST} = 0{,}0013 < 0{,}05$, a nullhipotézist elvetettem, így a modellt sikeresnek minősítem. Ez az eredmény statisztikai szempontból megerősíti, hogy a becslési

hibák biztonsággal a szenzorok pontossági határain belül helyezkednek el. Bár a 90%-os konfidenciaintervallum [-0,186; -0,153] szisztematikus alulbecslésre utal, ennek mértéke elhanyagolható, és teljesíti az elvárt kritériumokat.



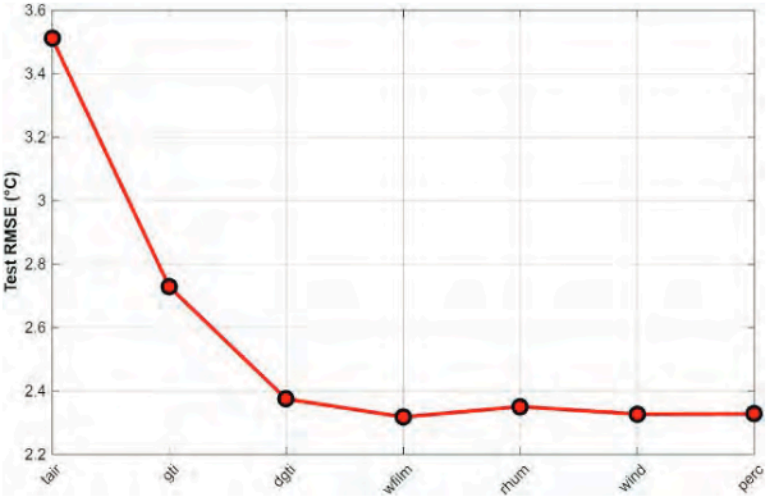
5. ábra: A 24 órás és nappali-éjszakai modellek összehasonlítása (Forrás: saját szerkesztés)

3. 4. A prediktorok hatása

A legpontosabb modellt (Matern 5/2 GPR) a bemeneti változóinak optimalizálása érdekében egy szekvenciális, előrehaladó változóbevonási eljárás keretében hétszer tanítottam újra. A vizsgálat célja annak számszerűsítése volt, hogy az egyes környezeti tényezők integrálása milyen mértékben képes javítani a modell globális pontosságát, amit az átlagos négyzetes hibával jellemeztem (RMSE).

A *6. ábra* azt mutatja, hogy a prediktorok számának növelésével a pontosság nem lineárisan javul. Kezdetben, a levegő-hőmérséklet (*tair*), a sugárzási adatok (*gti*, *dgti*) bevonásával drasztikusan csökken az RMSE, míg a negyedik változó, a vízfilmvastagság (*wfilm*) bevonása után a hibagörbe stagnál, a további változók hozzáadásával a pontosság állandósul a 2,30–2,35 °C közötti sávban.

Ez rámutat arra, hogy a keresztkorreláció hasznos, de nem tökéletes becslőeszköz a komplex gépi tanulási modellek esetében. A korrelációs elemzésben a relatív páratartalom (*rhum*) erős korrelációt mutatott a felületi hőmérséklettel, míg a vízfilmvastagság vagy a sugárzásváltozás hatása elhanyagolható volt. A modelltanításnál viszont épp az ellenkezője bizonyosodott be: a modell képes volt feltárni azokat a nemlineáris összefüggéseket és interakciókat, amelyeket a klasszikus korreláció elfedett.

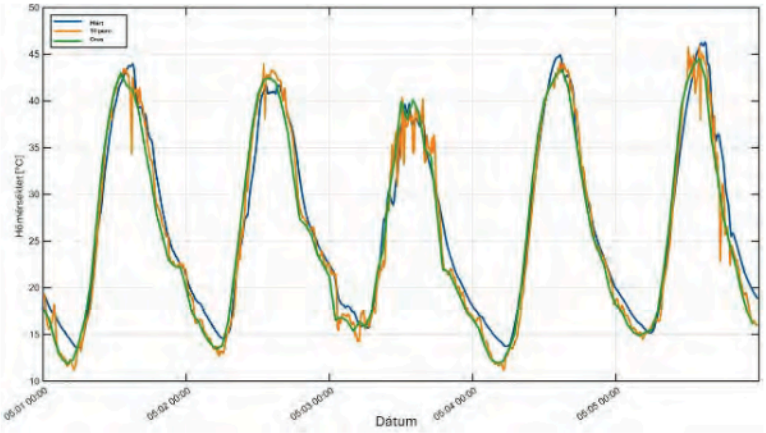


6. ábra: Prediktorok hatása a modell pontosságra (Forrás: saját szerkesztés)

Az eredmények fizikai értelmezése helytálló: a felszíni hőmérséklet makrotrendjét a levegő hőmérséklete és a közvetlen besugárzás alakítja. A sugárzás változása által a modell képes figyelembe venni nemcsak a napi csúcsokat, hanem az égbolt időszakos borultságát is, míg a vízfilm jelentléte a felületet érő nemlineáris hűtő vagy pufferelő hatásokat kezeli.

3. 5. Adatsűrűség

A GPR modellek egyik legnagyobb korlátja a mintaszámmal nagymértékben növekvő számítási komplexitás $O(n^3)$, ahol n a tanító adatok száma. Az *1. táblázat* szerint a legnagyobb felbontás mellett a GPR modell tanítása 28 812 másodpercig (≈ 8 óra) tartott, ami rendkívül nagy számítási igényt jelentett az egyszerűbb modellekkel összehasonlítva. A hatékonyság növelése érdekében a modellt újratanítottam egy csökkentett adatsűrűségű, 1 órás átlagokra aggregált halmazon, ami a megfigyelések számát 105 122-ről 17 520-ra csökkentette. A tanítási idő 832 másodpercre (≈ 0,2 óra) esett vissza, ami 97%-os időmegtakarítást jelent. Ez ugyan több, mint ami a komplexitás és adatpontok közötti köbös összefüggés alapján várható, azonban a modell tanítása rendelkezik olyan fix költségekkel (pl. mátrix invertálás, hiperparaméterek numerikus optimalizációja), ami megnöveli a számítási igényt.



7. ábra: A 10 perces és az órás felbontású modellek összehasonlítása (Forrás: saját szerkesztés)

A Matern 5/2 GPR modell ezen felbontás mellett kiváló, tesztelt RMSE = 2,24 °C pontosságot ért el, ami azt jelzi, hogy a nagy felbontású 10 perces adat finoman „túltanította" az eredeti modellt. Az órás felbontás a statisztikai zaj csökkentését jelentette, amit a *7. ábra* is mutat. A narancssárga vonal, ami a 10 perces felbontáson tanult tüskés, zajos, különösen a csúcsok közelében, míg a zöld, órás felbontású modell kisimítja a bemenő adatok lokális fluktuációját és kimenet oszcillálását, ezáltal sokkal stabilabban képes a valós hőmérséklet becslésére.

A TOST elemzés itt is megerősítette a modell érvényességét ($p_{TOSTh} = 0,02 < 0,05$). Ez statisztikailag bizonyítja, hogy az órás modell becslési hibája a szigorú konfidencia-intervallumon belül marad [-0,19; -0,11], vagyis az adatok aggregálása nem okozott információ-veszteséget, a modell megbízható maradt.

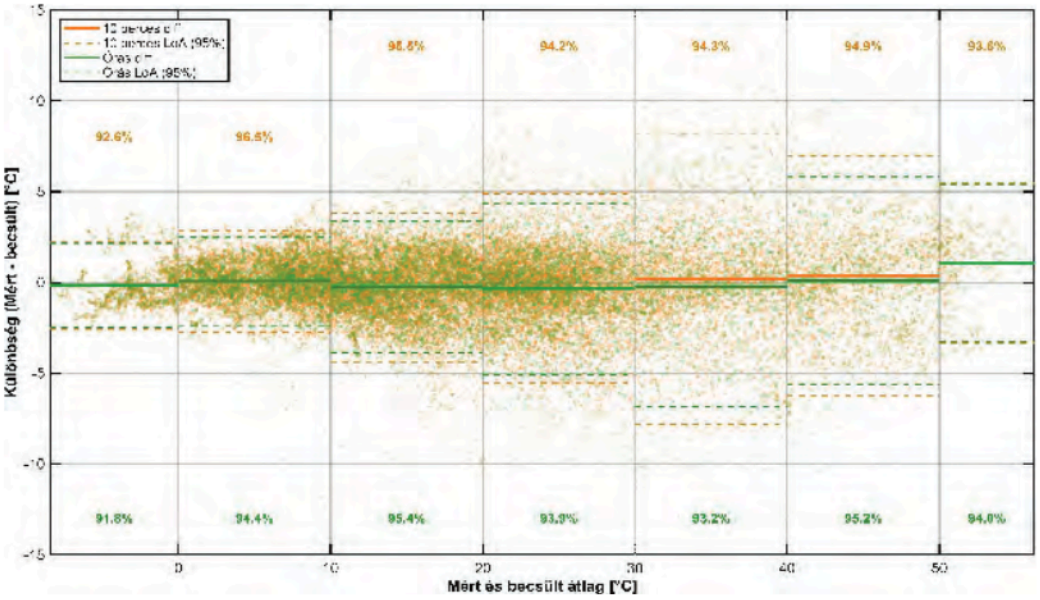
3. 6. Bland-Altman teszt

A modell gyakorlati alkalmazhatóságának igazolására intervallumonkénti Bland-Altman elemzést végeztem. A módszer lényege, hogy a teljes mérési tartományt 10 °C-os osztályokra bontva vizsgáltam a becsült és mért értékek különbségét az átlaguk függvényében. A *8. ábra* diagramja alapján a szigorú elvárást – miszerint a mérési pontok legalább 95%-ának a statisztikai egyetértési határokon (Limits of Agreement, LoA) belül kell elhelyezkednie – mindkét modell esetében két középső hőmérsékleti osztály teljesítette maradéktalanul (a 10 perces modell a 0–10 °C és 10–20 °C sávokban 96,5 % és 95,5 %-os értéket, míg az órás modell a 10–20 °C és a 40–50 °C sávokban 95,4% és 95,2%-ot ért el). Fontos azonban kiemelni, hogy a többi tartományban is rendkívül közel voltak a határhoz (a legalacsonyabb érték is 91,8% feletti), ami igazolja, hogy a modellek lokális predikciós képessége a teljes működési tartományban stabil. A torzítás a legtöbb intervallumon a nullavonal közvetlen közelében ingadozik, a hibák eloszlása körül normál jelleget mutat. Nagyobb hibákat a magasabb (30–40 °C) hőmérsékleti tartományokban azonosítottam.

Közlekedésbiztonsági szempontból a modellek pont a legkritikusabb (minimum és +10 °C közötti) tartományban a legpontosabbak, ami optimális viselkedésnek tekinthető. A modell megbízhatósága a téli üzemeltetés szempontjából éppen a legrelevánsabb hőmérsékleti tartományban a legnagyobb, ami az alkalmazhatóságot jelentősen növeli.

Az órás adatsűrűség alkalmazása jelentősen (97%-kal) csökkentette a számítási időt, miközben az RMSE = 2,24°C-ra javult.

Az intervallumokra bontott Bland-Altman tesztek szerint a modell a biztonság szempontjából kritikus, alacsonyabb hőmérsékleti tartományokban teljesít a legpontosabban.



8. ábra: Az intervallumokra bontott Bland-Altman teszt eredményei (Forrás: saját szerkesztés)

4. EREDMÉNYEK ÉRTÉKELÉSE

A cikk regressziós modellek betanítását és tesztelését mutatta be. Az eredmények rávilágítottak, hogy ezek hatékony eszközök a burkolat-hőmérséklet előrejelzésére (23 modell pontossága 0,7 °C-on belül volt). A kiemelt eredmények a következők:

A regressziós modellek pontosan jelzik előre az aszfalt felületi hőmérsékletét. A legjobb a Matern 5/2 GPR volt (RMSE = 2,33 °C).

A *nappali-éjszakai* modellkonfiguráció nem növelte a pontosságot, de megemelte a számítási költséget.

A TOST elemzés statisztikailag igazolta, hogy a becsült adathalmaz azonos a mért adatokkal.

Négy prediktor bevonása (*tair, gti, dgti, wfilm*) elegendő a maximális pontosság eléréséhez.

5. ÖSSZEFOGLALÁS

A regressziós modellek rendkívül hasznosak az útépítő és üzemeltető mérnökök számára. A telepített útmeteorológiai állomások adataival a modellek könnyen taníthatók, és megfelelő pontosság (RMSE ≈ 2,5 °C) érhető el. A modellek akkor nyújtják a legjobb előrejelzéseket, amikor arra a közlekedésbiztonság szempontjából a legnagyobb szükség van (0 °C közelében). Az eljárás jól alkalmazható akkor is, ha egy útfelújítás során a beépített szenzorok ideiglenesen nem képesek adatot szolgáltatni. A kutatás rávilágított, hogy a Matern 5/2 GPR egy robusztus és precíz modell, amelynél a maximális pontosság eléréséhez elegendőek az órás felbontású adatok. A kutatás következő lépése a burkolat mélységi hőmérséklet-eloszlásának előrejelzése lehet.

FELHASZNÁLT IRODALOM

Barber, E.S. (1957) Calculation of Maximum Pavement Temperatures From Weather Reports. HRB, National Research Council, Washington D.C., pp. 1-8. URL: http://onlinepubs.trb.org/Onlinepubs/hrbbulletin/168/168-001.pdf

Bland, J. M., Altman D. G. (1986) Statistical methods for assessing agreement between two methods of clinical measurement. Lancet, pp. 307–310. DOI: https://doi.org/10.1016/S0140-6736(86)90837-8

Cho, S., Tóth, Cs. (2022) Temperature estimation method of asphalt pavement in Hungary. FACTA UNIVERSITATIS, Architechture and Civil Engineering, 20(3), pp. 203–212. DOI: https://doi.org/10.2298/FUACE220213016C

Dickinson, J. E. (1978) A method for calculating the temperature gradients in asphaltic concrete pavement structures based on climatic data. Austrian Road Research, 8(4), pp. 16-34.

Dierfenderer, B. K., Al-Qadi, I. L., Dierfenderfer S. D. (2006) Model to predict pavement temperature profile: development and validation. Journal of Transportation Engineering, 132(2), pp. 162-167. DOI: https://doi.org/10.1061/(ASCE)0733-947X(2006)132:2(162)

Herceg, A., Primusz, P., Kalicz, P., Gribovszki, Z. (2020) A klimatikus jellemzők hatásai az útpályaszerkezetre: A pályaszerkezet hőmérsékletek számítása. Útügyi Lapok, 8(14). DOI: https://doi.org/10.36246/UL.2020.2.02

Herceg, A., Tóth, Cs., Primusz, P., Kalicz, P., Gribovszki, Z. (2022) Hazai bitumenek viselkedési fokozatának meghatározása egy soproni tesztparcella meteorológiai adatai alapján. Közlekedéstudományi Szemle, 72(1), pp. 32-47. DOI: https://doi.org/10.24228/KTSZ.2022.1.3

Huang, Y., Nojumi, M. M., Ansari, S., Hashemian, L., Bayat, A. (2024) Multi-depth temperature prediction using machine learning for pavement sections. Journal of Applied Remote Sensoring, 18(1). DOI: https://doi.org/10.1117/1.JRS.18.014517

Kebede, Y. B., Yang, MD., Huang, Ch. W. (2024) Real-time pavement temperature prediction through ensemble machine learning. Engineering Applications of Artificial Intelligence, 135, 108870. DOI: https://doi.org/10.1016/j.engappai.2024.108870

Khan, Z. H., Md Islam, R., Tarefder, R. A. (2019) Determining asphalt surface temperature using weather parameters. Journal of Traffic and Transportation Engineering, 6(6), pp. 577–588. DOI: https://doi.org/10.1016/j.jtte.2018.04.005

Mohseni, A. (1998) LTPP Seasonal Asphalt Concrete (AC) Pavement Temperature Models. FHWA Reports, pp. 1-72. URL: https://rosap.ntl.bts.gov/view/dot/40378

Pethő, L. (2008) A hőmérséklet eloszlás alakulása az aszfalt burkolatú pályaszerkezetekben és ennek hatása a pályaszerkezeti rétegek méretezésére, technológiai tervezésére. PhD értekezés. Budapesti Műszaki és Gazdaságtudományi Egyetem. URL: https://repozitorium.omikk.bme.hu/items/1ab9a912-e4a7-447d-85b2-e91859efa49a

Rasmussen, C. E., Williams, C. K. I. (2006) Gaussian Processes for Machine Learning. Cambridge, MA, The MIT Press. DOI: https://doi.org/10.7551/mitpress/3206.001.0001

Rumney, T. N., Jimenez, R. A. (1969) Pavement Temperatures in the Southwest. Highway Reasearch Record 361, HRB, National Research Council, Washington D.C., pp. 1-13. URL: http://hdl.handle.net/10150/566372

Solaimanian, M., Kennedy, T. W. (1993) Predicting Maximum Pavement Surface temperature Using Maximum Air Temperature and Hourly Solar Radiation. Transportation Research Record, 1417, pp. 1-11. URL: http://onlinepubs.trb.org/Onlinepubs/trr/1993/1417/1417-001.pdf

Schuirmann, D.J. (1987) A comparison of the Two One-Sided Tests Procedure and the Power Approach for assessing the equivalence of average bioavailability. Journal of Pharmacokinetics and Biopharmaceutics 15, pp. 657–680. DOI: https://doi.org/10.1007/BF01068419

Ureczky, J., Tóth, Cs. (2008) A hőmérséklet teherbírásra gyakorolt hatásának vizsgálata. Közúti és mélyépítési szemle, 58(3-4), pp. 9-14. URL: https://szemle.pms2000.hu/docs/2008_3_4.pdf

Vapnik, V. N. (1995) The Nature of Statistical Learning Theory. Springer, New York. DOI: http://dx.doi.org/10.1007/978-1-4757-2440-0



Determining the Surface Temperature of Asphalt based on Weather Data

Keywords: pavement temperature, machine learning, regression models, temperature forecasting, weather data

Pavement temperature has a key importance in road construction, both in the design of the pavement structure and in road maintenance. The in-depth temperature can be determined from the pavement surface temperature, which is an important parameter in design and for deflection measurements. Surface temperature has particular importance to road maintenance engineers during winter operations, as it serves as an indicator for when to begin preventive de-icing. There are approximately 400 weather stations located along the Hungarian national highway network, meaning that a single measuring station characterizes the temperature conditions of 80 km of the road network. In addition to road surface temperature, these stations also collect a variety of other weather data, such as air temperature, relative humidity, wind speed, etc. This article examines regression models based on weather data for predicting surface temperature. Using data from meteorological stations in Hungary, I trained 24 different models. The best model (Matern 5/2 GPR) achieved an accuracy of RMSE = 2.33 °C using data at 10-minute intervals, while using hourly inputs improved the model's accuracy to RMSE = 2.24 °C, which can be explained by a reduction in statistical noise. The model optimized by separating the daytime and nighttime data sets did not improve accuracy but did slightly complicate the calculations; therefore, the final model was trained on the aggregated 24-hour data. The article confirms that four meteorological inputs (air temperature, solar radiation, its variation, and water film thickness) are sufficient to achieve this. Other meteorological parameters, such as relative humidity, wind speed, and precipitation intensity, did not improve the model's accuracy. Simpler models (e.g., a linear regression model, RMSE = 2.88 °C) also showed similar overall accuracy; however, their average error increased significantly under extreme temperatures, reaching an RMSE > 4.5 °C above 40 °C. Therefore, from an engineering perspective, the use of the more complex model is recommended, despite its higher computational demands. Using the presented regression model, the surface temperature of the pavement can be determined based on three measured and one calculated weather data point. This tool makes it possible to determine the pavement temperature even at locations where there is no weather station or where it is located far away, or where the station has not been restored after pavement rehabilitation, or where it is otherwise out of service. In the context of long-term monitoring, this can be important information; until a domestic solution is developed and implemented, the model presented in this article can provide effective assistance to public road operators during winter operations, thereby enhancing traffic safety.