



SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE

Stavebná fakulta
Katedra vodného hospodárstva krajiny

Meno a priezvisko:

Ing. Barbora Považanová

Autoreferát dizertačnej práce:

Aplikácia metód strojového učenia pri výpočte referenčnej evapotranspirácie

na získanie akademického titulu „doktor“ („**philosophiae doctor**“, v skratke „PhD.“)

v doktorandskom študijnom odbore **6.1.11 krajinárstvo**

v študijnom programe **krajinárstvo**

denná forma štúdia

Bratislava 2025



Dizertačná práca bola vypracovaná na Katedre vodného hospodárstva krajiny Stavebnej fakulty Slovenskej technickej univerzity v Bratislave

Predkladateľ **Ing. Barbora Považanová**
Katedra vodného hospodárstva krajiny
Stavebná fakulta STU
Radlinského 11
810 05 Bratislava

Školiteľ prof. Ing. Milan Čistý, PhD.
Katedra vodného hospodárstva krajiny
Stavebná fakulta STU

Autoreferát bol rozoslaný dňa 27.5.2025

Obhajoba dizertačnej práce sa bude konať dňa 27.8.2025

o 9:00 h na Katedre vodného hospodárstva krajiny Stavebnej fakulty STU v Bratislave,
Radlinského 11.

prof. Ing. Stanislav Unčík, PhD.
dekan fakulty

Obsah

Obsah	1
Abstrakt.....	2
Abstract.....	3
1. Úvod.....	1
2. Ciele dizertačnej práce	2
3. Metódy	3
3.1. Empirické rovnice pre výpočet ETo	3
3.1.1. FAO-56 Penman-Monteith	3
3.1.2. Hargreaves-Samani	3
3.1.3. Makkink.....	4
3.1.4. McGuinness -Bordne	4
3.1.5. Blaney – Criddle	5
3.2. Modely strojového učenia pre výpočet ETo	5
3.2.1. Viacnásobná lineárna regresia (MLR)	5
3.2.2. Regularizovaná lineárna regresia (LASSO).....	6
3.2.3. Support vector regression (SVR)	6
3.2.4. Random forest.....	6
3.2.5. CatBoost	7
3.2.6. H2o autoML.....	7
4. Výsledky práce a diskusia	9
4.1. Výpočet referenčnej evapotranspirácie rovnicou FAO.....	9

Abstrakt

Presné stanovenie referenčnej evapotranspirácie (ET_o) je kľúčovým faktorom v hydrológii, poľnohospodárstve aj v manažmente vodných zdrojov. Tradične používaná metóda FAO-56 (Penman-Monteith) síce poskytuje presné výsledky, no jej aplikácia je často obmedzená nedostupnosťou potrebných meteorologických údajov. Táto dizertačná práca sa preto zameriava na identifikáciu alternatívnych metód výpočtu ET_o, ktoré nevyžadujú spoplatnené dáta a minimalizujú počet vstupných premenných bez zníženia presnosti výsledkov. V práci boli analyzované dve hlavné skupiny prístupov: empirické rovnice a modely strojového učenia. Medzi empirickými metódami dosiahli najlepšie výsledky rovnice Hargreaves-Samani a Makkink, avšak ich presnosť je podmienená správnou lokálnou kalibráciou. Modely strojového učenia, najmä CatBoost, Random Forest a H2o AutoML, prekonal tieto tradičné prístupy a dosiahli presnosť porovnateľnú s FAO-56, pričom si vystačili s minimálnym množstvom vstupných údajov. Kľúčovým prvkom úspešnosti modelov bolo využitie feature engineering-u, čiže predstavenie nových, odvodených premenných ako vstupov do modelov, kde najvýznamnejšiu úlohu zohrala slnečná radiácia pri bezoblačnom nebi (R_{so}). Táto premenná, vypočítaná výlučne na základe teploty, juliánskeho dňa a zemepisnej šírky, výrazne prispela k zovšeobecniteľnosti modelov a umožnila spoľahlivé predikcie ET_o aj v oblastiach s obmedzenou dostupnosťou meteorologických údajov. Výsledky tejto práce ukazujú, že pri správnom výbere metód je možné dosiahnuť vysokú presnosť výpočtu ET_o aj v podmienkach s minimálnymi dostupnými meranými údajmi. Vyvinuté postupy predstavujú inovatívny a prakticky využiteľný prístup pre hydrologické modelovanie, návrh zavlažovacích systémov a klimatické analýzy, čím otvárajú nové možnosti pre efektívne riadenie vodných zdrojov v meniacich sa klimatických podmienkach.

Abstract

The accurate determination of reference evapotranspiration (ET_o) is a key factor in hydrology, agriculture, and water resource management. While the traditionally used FAO-56 (Penman-Monteith) method provides precise results, its application is often limited by the unavailability of necessary meteorological input data. This dissertation focuses on identifying alternative ET_o calculation methods that do not require measured (and often paid) data and minimize the number of input variables without compromising accuracy. Two main approaches were analyzed: empirical equations and machine learning models. Among the empirical methods, the Hargreaves-Samani and Makkink equations achieved the best results, but their accuracy highly depends on proper local calibration. Machine learning models, particularly CatBoost, Random Forest, and H2o AutoML, outperformed these traditional approaches and achieved accuracy comparable to FAO-56 while requiring significantly fewer input variables. A key factor in the success of the models was the use of feature engineering, introducing new, derived variables as model inputs. The most influential variable was clear-sky solar radiation (R_{so}), calculated solely based on temperature, Julian day, and latitude. This variable significantly improved the generalizability of the models and enabled reliable ET_o predictions even in areas with limited meteorological data availability. The results of this study demonstrate that, with the appropriate choice of methods, high-accuracy ET_o calculations can be achieved even in data-scarce conditions. The developed methodologies offer an innovative and practically applicable approach for hydrological modelling, irrigation system design, and climate analysis, opening new possibilities for efficient water resource management in changing climatic conditions.

1. Úvod

Evapotranspirácia predstavuje jeden z kľúčových procesov hydrologického cyklu, ktorý významne ovplyvňuje bilanciu vody v krajine. Ide o kombinovaný proces výparu vody z povrchu pôdy (evaporácia) a straty vody prostredníctvom rastlín (transpirácia). Presné určenie evapotranspirácie je nevyhnutné pre efektívne hospodárenie s vodnými zdrojmi, návrh zavlažovacích systémov, agrotechnické plánovanie aj klimatické analýzy. V tejto práci sa zameriavame konkrétne na výpočet referenčnej evapotranspirácie (ET_o), ktorá je najrozšírenejšie používaným konceptom pri výpočtoch, nakoľko má presne zadefinovaný výpočet a charakteristiku plochy výparu.

Štandardnou metódou výpočtu ET_o je rovnice FAO-56 Penman-Monteith, ktorá síce poskytuje vysokú presnosť výsledkov, no jej použitie je často obmedzené nedostupnosťou viacerých meraných meteorologických údajov. V mnohých oblastiach sveta – vrátane niektorých častí Slovenska – nie je možné zabezpečiť kontinuálne merania potrebných veličín, ako je radiácia, vlhkosť vzduchu či rýchlosť vetra.

Z uvedeného dôvodu sa táto dizertačná práca venuje hľadaniu alternatívnych výpočtových metód ET_o, ktoré sú menej náročné na vstupné dáta. Porovnávame tradičné empirické rovnice (napr. Hargreaves-Samani, Makkink) s modernými modelmi strojového učenia (napr. Random Forest, CatBoost, H2O AutoML), pričom referenčným základom na hodnotenie presnosti je výstup z metódy FAO-56.

Osobitná pozornosť je venovaná technikám feature engineering-u, teda vytváraniu nových, vypočítaných alebo odvodených vstupných premenných. Výsledky ukazujú, že niektoré modely strojového učenia dokážu dosiahnuť porovnateľnú presnosť s referenčnou metódou FAO aj pri použití obmedzeného počtu základných vstupov. Práca tak poskytuje praktický a efektívny návod na výpočet ET_o aj v podmienkach obmedzeného množstva údajov.

2. Ciele dizertačnej práce

Cieľom tejto záverečnej práce je preskúmanie alternatívnych metód výpočtu referenčnej evapotranspirácie, ktoré minimalizujú požiadavky na vstupné meteorologické dáta, ktoré sú často na mnohých územiach nedostupné alebo spoplatnené. Navrhnuté metódy by sa zároveň presnosťou mali približovať referenčnej metóde FAO (rovnica Penman-Monteith). Aby bol tento cieľ práce naplnený, autorka si kladie nasledujúce čiastkové ciele:

- Preskúmanie teoretických základov evapotranspirácie: popísanie fyzikálnych procesov transpirácie, evaporácie, definovanie viacerých konceptov evapotranspirácie a faktorov, ktoré ju ovplyvňujú.
- Podrobná analýza metódy FAO 56: metodologický postup výpočtu rovnice FAO, popis vstupných premenných a spôsobu ich výpočtu, výhody a nevýhody tejto metódy.
- Porovnanie alternatívnych empirických rovníc: analyzovanie a vyhodnotenie presnosti často používaných empirických rovníc Hargreaves – Samani, Makkink, Blaney – Criddle, McGuinness – Bordne, spôsob výpočtu a popis vstupných premenných.
- Aplikácia metód strojového učenia na výpočet referenčnej evapotranspirácie: implementácia a porovnanie viacerých skupín modelov strojového učenia (boostovacie, ansámblové, automatizované, regresné), hľadanie modelu dosahujúceho najvyššiu presnosť pri minimálnom množstve vstupných údajov.
- Optimalizácia výpočtu pomocou metód feature engineering-u: pridanie odvodených premenných do výpočtu, analýza ich vplyvu na presnosť modelu.
- Testovanie zovšeobecniteľnosti modelov: natréňovanie modelov na sade údajov z jednej meteorologickej stanice (Košice) a aplikovanie modelu na údaje ďalších dvoch staníc v odlišných lokalitách (Hurbanovo, Poprad).

3. Metódy

3.1. Empirické rovnice pre výpočet ETo

Nakoľko je priame meranie evapotranspirácie nákladné na vybavenie, obsluhu a čas, bolo vyvinuté veľké množstvo empirických rovníc, ktoré evapotranspiráciu počítajú zo štandardne meraných meteorologických údajov, prípadne doplnených údajmi o polohe záujmového územia a dňom juliánskeho kalendára.

Empirické rovnice však často vyžadujú lokálne kalibrácie, čo ovplyvňuje ich presnosť a zovšeobecniteľnosť. Takisto je testovanie metód a hľadanie tej najvhodnejšej pre záujmové územie časovo náročné, napriek tomu je však často potrebné mať údaje o evapotranspirácii dostupné v krátkom čase.

3.1.1.FAO-56 Penman-Monteith

Metóda FAO (Penman-Monteith) je celosvetovo zaužívaná metóda, ktorá je odporúčaná ako výhradná metóda pre výpočet referenčnej evapotranspirácie (Allen et al., 1998).

Formulácia rovnice FAO Penman-Monteith je zobrazená v (3.1).

$$E_{To} = 0,408 * \frac{\Delta * (R_n - G) + \gamma * \frac{900}{T + 273} * u_2 * (e_s - e_a)}{\Delta + \gamma * (1 + 0,34 * u_2)} \quad (3.1)$$

ETo je referenčná evapotranspirácia [mm deň⁻¹],

R_n je radiačná bilancia (net radiation) [MJ m⁻² deň⁻¹],

G intenzita toku tepla do pôdy cez jej povrch, pre denné hodnoty uvažujeme G=0 MJ m⁻² deň⁻¹,

T priemerná denná teplota vo výške 2 m nad povrchom [°C],

u₂ je rýchlosť vetra 2 m nad povrchom [m s⁻¹],

e_s parciálny tlak nasýtených vodných pár [Pa],

e_a parciálny tlak vodných pár [Pa],

e_s-e_a je deficit tlaku vodných pár vo vzduchu [kPa],

Δ sklon krivky tlaku vodných pár [kPa °C⁻¹],

γ psychrometrická konštanta [kPa °C⁻¹].

3.1.2.Hargreaves-Samani

Rovnica Hargreaves-Samani (Hargreaves, Samani, 1985) je radiačná metóda výpočtu referenčnej evapotranspirácie, ktorá je odporúčaná

v prípade, že jedinými dostupnými meranými údajmi sú maximálna (T_{max}) a minimálna teplota (T_{min}) (Allen et al., 1998).

Rovnica pre výpočet referenčnej evapotranspirácie metódou Hargreaves-Samani je uvedená v (3.2).

$$E_{to} = 0,0023 * (T_{max} - T_{min})^{0,5} * (T_{mean} + 17,8) * R_a \quad (3.2)$$

E_{to} je referenčná evapotranspirácia [mm deň⁻¹],

T_{max} je maximálna denná teplota [°C],

T_{min} je minimálna denná teplota [°C],

T_{mean} je priemerná denná teplota [°C]

R_a je extraterestriálna radiácia [MJ m⁻² deň⁻¹]

3.1.3. Makkink

Ďalšou radiačnou metódou, ktorú sme použili v tejto práci je rovnica Makkink (1957). Táto metóda je vhodná do vlhkých a chladných oblastí, horšie výsledky dosahuje v suchých a teplých oblastiach (Efthimiou et al., 2013).

Formulácia rovnice výpočtu referenčnej evapotranspirácie metódou Makkink je uvedená v (3.3).

$$E_{to} = 0,61 * \frac{\Delta}{\Delta + \gamma} * \frac{R_s}{\lambda} - 0,12 \quad (3.3)$$

E_{to} je referenčná evapotranspirácia [mm deň⁻¹],

Δ je sklon čiary nasýtených vodných pár [kPa °C⁻¹],

γ je psychrometrická konštanta [kPa °C⁻¹],

λ je latentné teplo vyparovania [MJ kg⁻¹],

R_s je slnečná (globálna) radiácia [MJ m⁻² deň⁻¹].

3.1.4. McGuinness -Bordne

Rovnica McGuinness-Bordne (McGuinness, Bordne, 1972) je radiačnou metódou výpočtu potenciálnej evapotranspirácie. Napriek tomu, že sa jedná o metódu výpočtu potenciálnej a nie referenčnej evapotranspirácie, je možné ju použiť, pretože tieto dva koncepty majú silný korelačný vzťah. Rovnica McGuinness-Bordne je uvedená v (3.4).

$$E_p = \frac{R_a}{\lambda * \rho} * \frac{T_a + 5}{68} \quad (3.4)$$

E_p je potenciálna evapotranspirácia [mm deň⁻¹],

R_a je extraterestriálna radiácia [MJ m⁻² day⁻¹],

λ je skupenské (latentné) teplo vyparovania = 2.45 MJ kg⁻¹,

ρ je hustota vody = 1000 kg m⁻³,
 T_a je priemerná denná teplota [°C].

3.1.5. Blaney – Criddle

Rovnica Blaney-Criddle (Blaney, Criddle, 1950) slúži na výpočet potenciálnej evapotranspirácie. Je to metóda vhodná pre oblasti, v ktorých je výrazný nedostatok meraných údajov, keďže využíva iba priemernú teplotu. Rovnica Blaney-Criddle poskytuje presné výsledky evapotranspirácie pre mierne klimatické pásmo, avšak je menej presná v extrémnych klimatických podmienkach (Zhan, Lin Shelp, 2009). Pôvodná formulácia metódy Blaney-Criddle je uvedená v (3.5).

$$E_p = p * (0,46 * T_{mean} + 8,13) \quad (3.5)$$

p je percentuálny podiel slnečného svitu pre každý mesiac,
 T_{mean} je priemerná teplota [°C].

3.2. Modely strojového učenia pre výpočet ETo

Metódy strojového učenia predstavujú vhodnú alternatívu v prípade, že nie sú dostupné potrebné merané premenné pre výpočet metódou FAO, prípadne nemajú vyhovujúcu kvalitu (výpadky, nekonzistentné metódy merania atď.). Modely strojového učenia sú schopné učiť sa a identifikovať závislosti medzi vstupnými a výstupnými premennými na základe rôznych algoritmov. Jedná sa preto o komplexnejšie metódy ako empirické rovnice pre výpočet evapotranspirácie.

Výber modelov v tejto práci bol realizovaný na základe dvoch teórií. Podľa „no free lunch theorem“, ktorá hovorí o tom, že nie je možné dopredu určiť, ktorý z modelov ML bude najvhodnejší, je potrebné preskúmať vhodnosť viacerých typov ML modelov. Boli preto zvolené principiálne a algoritmicky rozdielne modely, reprezentujúce viacero konceptov.

Takisto bolo snahou zahrnúť jednoduchšie aj komplexnejšie modely, aby bolo možné posúdiť (princíp Occamovej britvy), či je použitie zložitejších modelov nutné a dosahuje lepšie výsledky ako jednoduchšie modely.

3.2.1. Viacnásobná lineárna regresia (MLR)

Nakoľko je v praxi často dostupných viacero nezávislých premenných, ktoré môžu prispieť k výpočtu závislej premennej, používa sa namiesto jednoduchej lineárnej regresie viacnásobná lineárna regresia (multiple linear regression – MLR). Rozšíriť jednoduchú regresiu je možné

pridaním vplyvov jednotlivých prediktorov (3.6). Výhodou tejto metódy je, že výsledné koeficienty sú ľahko interpretovateľné.

$$Y = \beta_0 + \beta_1 * X_1 + \beta_2 * X_2 + \dots + \beta_p * X_p + \varepsilon \quad (3.6)$$

Y je závislá premenná,

$X_1, X_2, \dots, X_p$ sú nezávislé premenné,

β_0 je intercept,

$\beta_1, \beta_2, \dots, \beta_p$ sú koeficienty pre jednotlivé nezávislé premenné.

3.2.2.Regularizovaná lineárna regresia (LASSO)

LASSO (Least Absolute Shrinkage Operator) je regularizačná metóda. Funguje na princípe znižovania počtu a veľkosti koeficientov menej dôležitých nezávislých premenných (zmenšovania ich váhy vo výpočte). Rovnica výpočtu je rovnaká ako (3.6) s dodatkom (3.7). Oproti MLR vedie LASSO väčšinou k jednoduchšiemu modelom, k zníženiu šumu v dátach a zlepšeniu zovšeobeciteľnosti.

$$\sum |\beta_i| \leq \lambda \quad (3.7)$$

λ je ladiaci parameter, ktorý ovplyvňuje mieru znižovania koeficientov nezávislých premenných.

3.2.3.Support vector regression (SVR)

Support vector regression je regresná forma algoritmu Support vector machine (SVM), vyvinutého Cortes a Vapnik (1995). Patrí medzi kernelové (jadrové) metódy. SVR rieši problémy nelineárnej regresie pomocou tzv. kernelového triku. Tento prístup spočíva v tom, že údaje sa premietnu do vyššej dimenzie, kde sa problém stáva lineárnym a teda jednoduchším na riešenie. V tejto práci bolo použité RBF jadro.

Ďalšou dôležitou vlastnosťou SVR je zavedenie hranice tolerovanej chyby, označenej ako ϵ (epsilon). Tolerančná zóna sa označuje ako ϵ -trubica (ϵ -tube) Táto hranica umožňuje algoritmu ignorovať malé odchýlky – teda chyby v predikcii, ktoré sú menšie ako stanovené ϵ . Tým sa znižuje riziko preučenia (pretrénovania) modelu, pretože model sa nesnaží prispôbiť každému bodu v tréningových dátach.

3.2.4.Random forest

Random forest (RF) je ansámblová metóda typu bagging (bootstrap aggregating) kombinujúca viacero rozhodovacích stromov. Regresný strom predstavuje model predikcie numerických hodnôt založený na

postupnom rozdeľovaní dátového priestoru. Algoritmus vytvára hierarchickú štruktúru, kde každý uzol reprezentuje rozhodnutie založené na hodnote vstupnej premennej a vetvy reprezentujú výsledné rozdelenie dát. Koncové uzly, tzv. listy, obsahujú predikovanú hodnotu (Liaw, Wiener, 2015; Feng et al., 2017).

Náhodné lesy sú ansámblovou metódou založenou na agregácii predikcií z viacerých regresných stromov. Konkrétne, algoritmus konštruuje paralelne množinu regresných stromov a výsledná predikcia je určená ako priemer individuálnych predikcií týchto stromov.

3.2.5.CatBoost

CatBoost (Gradient boosting with categorical features support) je ansámblový model typu boosting. Princíp týchto modelov je ten, že modely sú vytvárané postupne. Každý nový model je trénovaný na dátach, kde predchádzajúce modely urobili chyby. Väčšia váha je prikladaná nesprávne vypočítaným vzorkám a menšia správne vypočítaným. Každý ďalší model sa viac zameriava na chyby svojich predchodcov a ich nápravu. Výhodou je veľmi dobré implicitné (default) nastavenie parametrov, čo uľahčuje prácu bežného užívateľa, ktorý nemusí pracne hľadať rôzne parametre pre optimálne fungovanie modelu.

3.2.6.H2o autoML

V roku 2020 platforma H2O.ai vydala najnovšiu verziu softvéru H2O AutoML (LeDell, Poirer, 2020). Jedná sa o nástroj (framework), ktorý automatizuje proces strojového učenia. Zahŕňa súbor rôznych modelov a algoritmov ML (gradient boosting, lineárne modely, deep learning a.i.), ktoré sa testujú, kalibrujú a vyladujú, aby bolo možné nájsť najvhodnejší model pre daný problém či súbor vstupných údajov. Takisto automaticky vyberá vstupné premenné zo súboru (feature selection). Výstupom je najlepší model, vyhodnotený na základe zvolenej metriky (metrika je automaticky volená na základe riešenej úlohy, či už ide o klasifikačné úlohy, regresné úlohy...). Typ úlohy sa identifikuje na základe charakteru cieľovej premennej vo vstupných dátach, t.j., či sa jedná o kategorickú premennú (klasifikácia) alebo numerickú (regresia). Je však možné typ úlohy nastaviť manuálne, ak je opodstatnený predpoklad, že automatická detekcia bude nejednoznačná. S nástupom veľkých jazykových modelov (LLM) je predpoklad, že táto oblasť prejde veľmi rýchlym procesom vývoja a celkom sa zmenia spôsoby aplikácie strojového učenia a charakter profesií súvisiacich s analýzou údajov.

3.3.Feature engineering

Pri zložitých regresných a klasifikačných úlohách s veľkým množstvom vstupných údajov zohráva kľúčovú úlohu kvalita vstupných premenných, ktorá ovplyvňuje predikčnú schopnosť modelu (Kuhn, Johnson, 2019). Feature engineering je pojem, ktorý v súčasnej dobe nemá vyhovujúci slovenský ekvivalent, preto je v tejto práci používaný v angličtine.

Feature engineering je proces vytvárania nových odvodených veličín (features) zo „surových“ veličín (raw data = nespracované údaje). Snahou je vytvoriť vstupné premenné generujúce presnejšie výsledky modelov strojového učenia ako použitie „surových“ vstupných premenných. Jedná sa o vytváranie nových premenných z dostupných údajov, napríklad pomermi, rozdielmi alebo inými matematickými transformáciami existujúcich premenných (Heaton, 2016). Takto odvodené údaje buď doplnia alebo nahradia „surové“ vstupné údaje.

Vytváranie takýchto premenných je často časovo náročné a vyžaduje dobré znalosti danej problematiky, nakoľko nie všetky odvodené premenné sú schopné model zlepšiť.

Feature engineering je perspektívnou súčasťou strojového učenia, najmä pri práci s nedostatočným množstvom údajov, avšak jeho využitie pre výpočet referenčnej evapotranspirácie je veľmi ojedinelé. Za hlavný prínos tejto práce autori považujú práve poukázanie na význam využívania odvodených premenných pri výpočte referenčnej evapotranspirácie, ako alternatívnej metódy k výpočtu pomocou rovnice Penman-Monteith (FAO56).

V tejto práci boli, okrem „surových“ údajov, použité nasledujúce premenné (features):

1. Evapotranspirácia vypočítaná rovnicou Hargreaves-Samani (HS_ETo) (3.2)
2. Evapotranspirácia vypočítaná rovnicou McGuinness-Bordne (MGS_PE) (3.4)
3. Parciálny tlak nasýtených vodných pár (es)
4. Slnečná radiácia pri bezoblačnom nebi (Rso)

4. Výsledky práce a diskusia

Ako cieľové hodnoty referenčnej evapotranspirácie boli použité výsledky rovnice FAO (Penman-Monteith) v stanici Košice. S týmito výsledkami boli najskôr porovnávané výsledky empirických rovníc Hargreaves-Samani, Blaney-Criddle, McGuinness-Bordne a Makkink. Následne bola referenčná evapotranspirácia vypočítaná modelmi strojového učenia pri rôznych kombináciách vstupných parametrov a tieto výsledky boli opäť porovnané s výsledkami metódy FAO. Cieľom je nájsť optimálnu metódu, ktorá kombinuje jednoduchosť použitia, minimum vstupných údajov a presnosť výsledku. Všetky výpočty aj porovnania výsledkov boli realizované v programovacom jazyku R.

4.1. Výpočet referenčnej evapotranspirácie rovnicou FAO

V prvom kroku bola referenčná evapotranspirácia pre stanicu Košice vypočítaná porovnávacou (benchmark) metódou FAO (Penman-Monteith) funkciami z balíka FAO56 (Ahani, Nadoushani, 2023).


Funkciou `ETo_FPM()` boli vypočítané denné hodnoty referenčnej evapotranspirácie pre obdobie 1.1.1951 - 30.4.2020. Denné priemery referenčnej evapotranspirácie (ročný priebeh) sú zobrazené na Obr. 4.1. Základné štatistiky vypočítaných hodnôt sú v

Tab. 4.1.

Tab. 4.1 Základné štatistické charakteristiky ETo v stanici Košice (vypočítané metódou FAO)

Charakteristika	Mean	SD	Min	Max
<i>ETo [mm]</i>	2.5	1.9	0	7.3

Vypočítané hodnoty referenčnej evapotranspirácie metódou FAO pre stanicu Košice sú ďalej v práci používané ako porovnávacie hodnoty pri hodnotení alternatívnych metód výpočtu referenčnej evapotranspirácie, nakoľko je metóda FAO celosvetovo uznávanou metódou výpočtu a je možné jej výsledky považovať za správne.



Obr. 4.1 Ročný priebeh referenčnej evapotranspirácie v stanici Košice

4.2. Výpočet referenčnej evapotranspirácie empirickými rovnicami


Cieľom tejto kapitoly bolo zistiť, či empirické rovnice, ktorých použitie je veľmi jednoduché a priamočiare, poskytujú výsledky porovnateľné s referenčnou metódou výpočtu evapotranspirácie, FAO. Empirické rovnice, použité v tejto práci, boli zvolené na základe malého počtu vyžadovaných vstupných premenných, nakoľko cieľom práce je priniesť také alternatívy FAO metódy, ktoré nevyžadujú často nedostupné merané údaje.

Nespochybniteľnou výhodou empirických rovníc je jednoduchosť ich použitia, keďže sa jedná o veľmi priamočiare vzorce, do ktorých stačí dosadiť vstupné údaje. Nevýhodou je to, že empirické rovnice často vyžadujú lokálne kalibrácie, čo ovplyvňuje ich presnosť a zovšeobecniteľnosť. Takisto je testovanie metód a hľadanie tej najvhodnejšej pre záujmové územie časovo náročné. Empirickými rovnicami použitými v tejto práci sú Hargreaves-Samani, Blaney-Cridde, Makkink a McGuinness-Bordne. Všetkými 4 rovnicami boli vypočítané hodnoty dennej evapotranspirácie pre obdobie 1951 – 2020 pre vstupné hodnoty zo stanice Košice. Výsledky boli porovnané s referenčnou evapotranspiráciou vypočítanou rovnicou FAO a vyhodnotené na základe troch štatistických ukazovateľov: PBIAS, RMSE a R2. Výsledky sú uvedené v

Tab. 4.2. a na Obr. 4.2.

Tab. 4.2 Výsledky porovnania empirických rovníc a metódy FAO

Rovnica	Premenné	RMSE	PBIAS %	R2
HargreavesSamani	Tmax, Tmin	0.73	3.4	0.86
McGuinnessBordne	Tmax, Tmin	0.86	-6	0.86
BlaneyCriddle	Tmax, Tmin, n	1.3	-29.8	0.84
Makkink	Tmax, Tmin, n	1.04	51	0.96



Obr. 4.2 Výsledky porovnania empirických rovníc a metódy FAO

Najlepšie výsledky dosiahla na základe všetkých hodnotiacich metrík rovnica Hargreaves-Samani. Táto rovnica využíva ako vstupné údaje iba minimálnu a maximálnu dennú teplotu, čo predstavuje veľkú výhodu oproti rovnici FAO. Avšak vo svojom výpočte (3.2) využíva aj extraterestriálnu radiáciu, čo výrazne zlepšuje presnosť výsledkov. Táto rovnica dosiahla lepšie výsledky ako rovnice využívajúce údaje o slnečnom svite (Blaney-Criddle a Makkink). Je ju preto možné použiť aj v prípade, že takéto údaje nie sú na území dostupné.

4.3. Výpočet evapotranspirácie modelmi strojového učenia

V práci bolo použitých 6 algoritmov (modelov) strojového učenia pre výpočet referenčnej evapotranspirácie v stanici Košice. Tieto modely boli použité pre výpočet referenčnej evapotranspirácie. Vstupnými údajmi boli rôzne kombinácie klimatických premenných v stanici Košice. Modelované hodnoty boli porovnané s hodnotami vypočítanými rovnicou FAO.

4.3.1. Použitie „surových“ vstupných údajov

V tejto kapitole je popísané testovanie rôznych kombinácií nasledujúcich vstupných premenných v modeloch strojového učenia pre výpočet referenčnej evapotranspirácie:

- maximálna denná teplota T_{max} ,
- minimálna denná teplota T_{min} ,
- počet hodín slnečného svitu n_{sun} ,
- priemerná relatívna vlhkosť vzduchu RH ,
- rýchlosť vetra vo výške 6 metrov $wind$,
- miera oblačnosti $clouds$,
- denný úhrn zrážok $prec$,
- globálna radiácia rad ,

Cieľom je porovnať vplyv jednotlivých klimatických premenných a ich kombinácií pri stanovení evapotranspirácie a vytvoriť modely využívajúce čo najmenší počet meraných vstupných údajov pri zachovaní presnosti výsledkov. Ako porovnávacie údaje sú použité výsledky rovnice FAO. Výsledky modelov s dvomi a tromi vstupnými premennými sú prezentované v Tab. 4.3.

Tab. 4.3 Výsledky modelov s dvomi a tromi základnými premennými

Model č.	Počet vstupov	Vstupy	Model ML	RMSE	PBIAS %	R2
1	2	Tmin, Tmax	MLR	0.963	0.5	0.748
			LASSO	0.935	-0.4	0.762
			catboost	0.910	-0.6	0.774
			RF	0.915	-0.5	0.772
			SVR	0.915	-2.1	0.774
			h2o	0.910	0.8	0.774
2	3	Tmin, Tmax, n_sun	MLR	0.789	0.8	0.831
			LASSO	0.751	-0.2	0.846
			catboost	0.692	-0.4	0.870
			RF	0.697	-0.5	0.868
			SVR	0.700	1.0	0.869
			h2o	0.693	1.0	0.869
3	3	Tmin, Tmax, RH	MLR	0.877	0.9	0.792
			LASSO	0.840	-0.3	0.808
			catboost	0.796	-0.3	0.827
			RF	0.799	-0.4	0.826
			SVR	0.797	-0.7	0.828
			h2o	0.796	-0.7	0.827
4	3	Tmin, Tmax, wind	MLR	0.933	0.5	0.764
			LASSO	0.905	-0.5	0.777
			catboost	0.863	-0.7	0.797
			RF	0.868	-0.7	0.795
			SVR	0.865	-1.5	0.797
			h2o	0.864	-0.3	0.797
5	3	Tmin, Tmax, clouds	MLR	0.952	0.5	0.755
			LASSO	0.903	-0.5	0.778
			catboost	0.872	-0.6	0.793
			RF	0.877	-0.7	0.790
			SVR	0.878	-1.0	0.792
			h2o	0.873	-1.2	0.793

Model č.1 s dvomi základnými vstupmi slúžil ako porovnávaci na posúdenie, akou mierou prispajú jednotlivé klimatické premenné k zlepšeniu výsledkov. Pridaním každej z premenných sa výsledky zlepšili. K najvýraznejšiemu zlepšeniu došlo pridaním premennej *n_sun*, t.j. počtu hodín slnečného svitu za deň. K najmenšiemu zlepšeniu prispela premenná *clouds* v modeli č.5, t.j. oblačnosť.

Najlepšie výsledky pri všetkých kombináciách premenných dosiahol model automatizovaného strojového učenia H2o. Najslabšie výsledky dosiahol model MLR. Je možné zhodnotiť, že pri výpočte referenčnej evapotranspirácie má zmysel použitie komplexnejšieho modelu autoML

H2o oproti jednoduchším regresným modelom. Takisto je možné konštatovať, že nelineárne modely (SVR, RF, CatBoost, autoML) dosiahli lepšie výsledky ako lineárne modely (MLR, LASSO).

Ďalšou časťou analýzy bolo posúdenie, nakoľko k zlepšeniu výsledkov modelov prispieva vyšší počet vstupných premenných. V Tab. 4.4 sú uvedené výsledky modelov so 4, 5 a 6 vstupnými premennými.

Tab. 4.4 Výsledky modelov s viacerými vstupnými premennými

Model č.	Počet vstupov	Vstupy	Model ML	RMSE	PBIAS %	R2
6	4	Tmin, Tmax, n_sun,RH	MLR	0.780	0.9	0.835
			LASSO	0.730	-0.1	0.855
			catboost	0.655	-0.3	0.883
			RF	0.659	-0.4	0.882
			SVR	0.660	0.8	0.883
			h2o	0.657	1.7	0.883
7	5	Tmin, Tmax, n_sun, RH, wind	MLR	0.779	0.9	0.836
			LASSO	0.722	-0.1	0.858
			catboost	0.651	-0.4	0.885
			RF	0.652	-0.5	0.884
			SVR	0.653	0.5	0.885
			h2o	0.651	-1.1	0.885
8	6	Tmin, Tmax, n_sun,RH, wind, clouds	MLR	0.703	1	0.866
			LASSO	0.657	0	0.882
			catboost	0.593	-0.2	0.904
			RF	0.595	-0.4	0.904
			SVR	0.587	0.7	0.907
			h2o	0.589	-0.1	0.906

S každou pridanou premennou sa výsledky zlepšili. Najlepšie výsledky dosiahol model č.8 so 6 premennými. Je teda možné konštatovať, že pridávaním viacerých premenných je možné prispieť k zlepšeniu výsledkov modelu ML. V prípade veľkého množstva vstupov je už však na zváženie, či nemôže dochádzať k pretrénovaniu modelu, čím sa výrazne znižuje jeho zovšeobecniteľnosť. Aj v modeloch s väčším počtom vstupných údajov dosahovali najlepšie výsledky nelineárne modely, najmä model automatizovaného strojového učenia H2o.

4.3.2. Použitie odvodených premenných (feature engineering)

Pre zlepšenie modelu je možné, zadať aj ďalšie premenné, vypočítané alebo inak odvodené (feature engineering). Tento prvok prístupu aplikácie strojového učenia na výpočet *ETo* je originálnym prínosom tejto práce. Pridaním ďalších údajov je možné modely podporiť v presnosti a efektívnosti výpočtu a umožniť im využiť nové vzťahy medzi premennými pre vytvorenie kvalitnejšieho modelu.

Rôzne kombinácie týchto veličín boli v modeloch strojového učenia použité ako vstupné údaje pre výpočet referenčnej evapotranspirácie. Výsledky boli porovnané s hodnotami referenčnej evapotranspirácie vypočítanej metódou FAO.

Pridaním každej premennej sa výsledky modelu zlepšili. K najvýraznejšiemu zlepšeniu došlo pridaním premennej *Rso*. K najmenšiemu zlepšeniu prispela kategorická premenná *month*. V modeli č. 7 bolo použitých všetkých 7 premenných, avšak došlo len k minimálnemu zlepšeniu oproti modelu č. 5, v ktorom je použitá iba premenná *Rso*.

Dôležitým poznatkom je, že pridaním odvodených premenných došlo k výraznejšiemu zlepšeniu ako pridávaním základných klimatických veličín v Tab. 4.3. Je možné konštatovať, že využitie odvodených premenných, najmä slnečnej radiácie pri bezoblačnom nebi (*Rso*), je pre výpočet referenčnej evapotranspirácie prínosné. Zároveň boli všetky odvodené premenné vypočítané len na základe maximálnej a minimálnej teploty, čo sú obvykle merané veličiny. Dostupnosť týchto údajov je ďalšou veľkou výhodou použitia navrhnutých premenných. Výpočty v tejto tabuľke sú tak isto presnejšie ako boli výsledky pomocou štandardných empirických rovníc (Tab. 4.2)

Tab. 4.5 Výsledky modelov s využitím odvodených premenných

Model č.	Počet vstupov	Vstupy	Model ML	RMSE	PBIAS %	R2
1	2	Tmax, Tmin	MLR	0.963	0.5	0.748
			LASSO	0.935	-0.4	0.762
			CatBoost	0.91	-0.6	0.774
			RF	0.915	-0.5	0.772
			SVR	0.915	-2.1	0.774
			h2o	0.91	0	0.774
2	3	Tmax, Tmin, HS_Eto	MLR	0.704	-0.5	0.867
			LASSO	0.636	-0.5	0.892
			CatBoost	0.485	-0.1	0.937
			RF	0.492	-0.1	0.935
			SVR	0.471	-0.6	0.941
			h2o	0.478	-0.1	0.939
3	3	Tmax, Tmin, MGB_PE	MLR	0.604	-0.1	0.902
			LASSO	0.526	-0.2	0.926
			CatBoost	0.484	-0.1	0.937
			RF	0.484	-0.2	0.937
			SVR	0.478	-0.6	0.939
			h2o	0.481	1.2	0.938
4	3	Tmax, Tmin, es	MLR	0.942	-0.4	0.762
			LASSO	0.922	-0.7	0.772
			CatBoost	0.915	-0.6	0.776
			RF	0.919	-0.6	0.774
			SVR	0.92	-2.1	0.775
			h2o	0.915	-1.2	0.776
5	3	Tmax, Tmin, Rso	MLR	0.616	0.7	0.897
			LASSO	0.477	-0.2	0.938
			CatBoost	0.472	-0.2	0.939
			RF	0.478	-0.1	0.938
			SVR	0.474	-0.7	0.939
			h2o	0.470	-0.3	0.940
6	3	Tmax, Tmin, month	MLR	0.606	0.3	0.902
			LASSO	0.522	-0.1	0.927
			CatBoost	0.522	-0.1	0.927
			RF	1.557	-0.4	0.792
			SVR	0.518	-1.3	0.928
			h2o	0.52	-0.7	0.928
7	7	Tmax, Tmin, HS_Eto, MGB_PE, es, Rso, month	MLR	0.536	-0.1	0.923
			LASSO	0.467	-0.1	0.942
			CatBoost	0.471	-0.1	0.941
			ranger	1.055	-0.3	0.901
			SVR	0.468	-0.8	0.941
			h2o	0.468	1.3	0.942

4.3.3. Zovšeobecniteľnosť modelov strojového učenia

Modely strojového učenia musia byť tréňované a testované na podobných údajoch. Ak by však model natrénovaný na jednej sade údajov bol schopný uspokojivo modelovať údaje pre iné územie, predstavovalo by to určitý benefit. Takáto schopnosť sa označuje ako zovšeobecniteľnosť modelov. Cieľom tejto kapitoly je overiť, nakoľko sú modely predstavené v predchádzajúcej kapitole schopné zovšeobecnenia.

Modely boli natrénované na údajoch zo stanice Košice. Následne boli použité pre výpočet referenčnej evapotranspirácie v staniách Hurbanovo a Poprad v testovacom období. Tieto stanice sa všetky nachádzajú na Slovensku, avšak v rozdielnych nadmorských výškach, čo môže výrazne ovplyvniť klimatické a ďalšie premenné ovplyvňujúce evapotranspiráciu.

Ako vstupy do modelov bola použitá kombinácia maximálnej a minimálnej dennej teploty a odvodená premenná R_{so} (slnečná radiácia pri bezoblačnom nebi). Cieľom bolo vybrať kombináciu vyžadujúcu čo najmenší počet meraných premenných, v tomto prípade len teplotu (jediná meraná veličina potrebná aj pre výpočet R_{so}). Výsledky modelov sú uvedené v Tab. 4.6. Pre porovnanie je uvedený model č.1, ktorý bol natrénovaný a aj následne otestovaný na údajoch stanice Košice.

Z výsledkov je zjavné, že aj modely č. 2 a 3, ktoré boli natrénované na inej sade údajov poskytujú veľmi dobré výsledky. Toto je možné prisúdiť použitiu premennej R_{so} , ktorej výpočet zohľadňuje nadmorskú výšku aj geografickú šírku. Vďaka použitiu tejto premennej je možné výsledky adaptovať na údaje z rôzne umiestnených staníc. Použitie tejto premennej ako vstupného údaju pre výpočet evapotranspirácie považujeme za jeden z hlavných prínosov tejto práce. Je možné konštatovať, že napriek tomu, že v práci boli realizované iba bodové výpočty ET_o (v klimatických staniách) je veľký predpoklad k tomu, že takto bodovo natrénované modely bude možné použiť v budúcich prácach aj na plošné výpočty ET_o , t.j. určovanie ET_o pre väčšie oblasti (napríklad väčšie poľnohospodársky využívané oblasti).

Tab. 4.6 Vyhodnotenie zovšeobecniteľnosti modelov strojového učenia

Model č.	Vstupy	Údaje	Model	RMSE	PBIAS %	R2
1	Rso, Tmin, Tmax	Trénovacie: Košice	MLR	0.616	0.7	0.897
			LASSO	0.477	-0.2	0.938
		Testovacie: Košice	catboost	0.472	-0.2	0.939
			RF	0.478	-0.1	0.938
			SVR	0.474	-0.7	0.939
			h2o	0.470	-0.3	0.940
2	Rso, Tmin, Tmax	Trénovacie: Košice	MLR	0.636	0.2	0.904
			LASSO	0.456	0.4	0.949
		Testovacie: Hurbanovo	catboost	0.454	0.2	0.949
			RF	0.462	0.3	0.948
			SVR	0.443	0.1	0.952
			h2o	0.452	0.3	0.950
3	Rso, Tmin, Tmax	Trénovacie: Košice	MLR	0.580	4.2	0.904
			LASSO	0.450	0.8	0.941
		Testovacie: Poprad	catboost	0.455	0.3	0.939
			RF	0.463	-0.6	0.937
			SVR	0.459	-0.5	0.938
			h2o	0.452	0.1	0.940

5. Záver

Cieľom tejto práce bolo analyzovať a porovnať rôzne metódy výpočtu referenčnej evapotranspirácie (ET_o) s dôrazom na výber metód, ktoré nevyžadujú spoplatnené údaje a sú realizovateľné aj s obmedzeným množstvom vstupných premenných. Tradičná metóda FAO-56 Penman-Monteith, hoci je považovaná za štandard v oblasti hydrológie a poľnohospodárstva, si vyžaduje viaceré meteorologické vstupné údaje, ktoré nemusia byť vždy dostupné. Preto bolo nevyhnutné preskúmať alternatívne výpočtové metódy, ktoré môžu zabezpečiť presné a spoľahlivé odhady ET_o aj v lokalitách s obmedzenou dostupnosťou údajov. V práci boli vyhodnotené dve hlavné skupiny metód: empirické rovnice a modely strojového učenia.

Medzi testovanými empirickými rovnicami dosiahli najlepšie výsledky metódy Hargreaves-Samani a Makkink, ktoré poskytli uspokojivé výsledky aj pri minimálnom množstve vstupných údajov. Napriek jednoduchosti týchto rovníc ich presnosť do veľkej miery závisí od lokálnych podmienok, čo môže v niektorých prípadoch vyžadovať kalibráciu, ktorá môže ďalej znižovať ich spoľahlivosť a zovšeobecniteľnosť.

V rámci testovania modelov strojového učenia dosiahli nelineárne modely (CatBoost, SVR, Random forest, AutoML H2o) lepšie výsledky ako jednoduchšie regresné (lineárne) modely (LASSO, MLR). Modely strojového učenia prekonal tradičné empirické rovnice a dokonca sa približovali presnosti metódy FAO-56, pričom si vystačili s menším množstvom vstupných premenných. Najlepšie výsledky dosahoval model automatizovaného strojového učenia H2o, ktorý zároveň nevyžaduje počiatočné kalibrácie hyperparametrov, ako ostatné modely. Okrem presnosti je teda výhodou tohto modelu aj jednoduchosť a univerzálnosť jeho použitia.

Dôležitou súčasťou práce a hlavným vedeckým prínosom bolo odvodenie nových premenných z pôvodných vstupných údajov a ich následné použitie ako vstupov do modelov strojového učenia (feature engineering). Aby boli zachované nízke nároky na vstupné údaje, všetky odvodené premenné boli vypočítané výhradne na základe teploty ako jedinej meranej veličiny. Odvodenou premennou, ktorá prispela k najvýraznejšiemu zlepšeniu výsledkov bola slnečná radiácia pri bezoblačnom nebi (R_{so}). Táto premenná je počítaná na základe teploty, juliánskeho dňa a zemepisnej šírky.

Pri hodnotení modelov strojového učenia sa môže zdať, že najlepší model je taký, ktorý dosahuje najlepšie hodnotenie na základe štatistických

metriky (napr. RMSE). Avšak pri modeloch, ktoré sú skoro dokonalé (modelované hodnoty sú takmer úplne zhodné s testovacími údajmi), môže dochádzať k pretrénovaniu. To znamená, že model síce s vysokou presnosťou počíta výsledky pre jednu sadu údajov, avšak nie je použiteľný pre inú sadu, t.j. má nedostatočnú zovšeobecniteľnosť.

Zovšeobecniteľnosť bola v tejto práci testovaná tak, že modely boli natréňované na údajoch z jednej meteorologickej stanice a otestované s údajmi z dvoch iných meteorologických staníc v rozdielnych nadmorských výškach. Ako vstupné údaje boli použité iba teploty a odvodená premenná R_{so} . Modely v tomto teste dosiahli výborné výsledky, čo je možné prisúdiť práve použitiu premennej R_{so} . Nakoľko je táto premenná počítaná na základe zemepisnej šírky, pomáha modelu adaptovať sa na rozdielne lokality.

Cieľom tejto práce bolo predstavenie alternatívnych metód výpočtu referenčnej evapotranspirácie so zameraním na metódy, ktoré nevyžadujú spoplatnené údaje a sú realizovateľné s čo najmenším množstvom vstupných premenných. Cieľ tejto práce považujeme za splnený. Táto práca poskytuje metodický základ pre aplikáciu moderných výpočtových metód evapotranspirácie v podmienkach s obmedzenými údajmi. Výsledky môžu byť využité v hydrologických modeloch, poľnohospodárskom plánovaní či vývoji klimatických scenárov, čím prispievajú k efektívnejšiemu manažmentu vodných zdrojov.

Literatúra

AHANI, A. a S. S. M. NADOUSHANI. 2023. *FAO56: Evapotranspiration Based on FAO Penman-Monteith Equation* [online]. [cit. 2025-1-30]. DOI: 10.32614/CRAN.package.FAO56. Dostupné na: <https://cran.r-project.org/web/packages/FAO56/index.html>

ALLEN, R. G., L. S. PEREIRA, D. RAES a M. SMITH. 1998. FAO Irrigation and drainage paper No. 56. *Rome: Food and Agriculture Organization of the United Nations*. **56**(97): e156.

BLANEY, H. F. a W. D. CRIDDLE. 1950. Determining water requirement in irrigated areas from climatological data. *Soil Conservation Service Technical Publication*. Washington DC: US Department of agriculture, **96**: 48.

CORTES, C. 1995. Support-Vector Networks. *Machine Learning*.

EFTHIMIOU, N., S. ALEXANDRIS, C. KARAVITIS a N. MAMASSIS. 2013. Comparative analysis of reference evapotranspiration estimation between various methods and the FAO56 Penman-Monteith procedure. *European Water*. EW Publications, **42**: 19-34.

FENG, Y., Y. PENG, N. CUI, D. GONG a K. ZHANG. 2017. Modeling reference evapotranspiration using extreme learning machine and generalized regression neural network only with temperature data. *Computers and Electronics in Agriculture* [online]. **136**: 71-78 [cit. 2024-6-25]. DOI: 10.1016/j.compag.2017.01.027. ISSN 01681699. Dostupné na: <https://linkinghub.elsevier.com/retrieve/pii/S0168169916306275>

HARGREAVES, G. H. a Z. A. SAMANI. 1985. Reference Crop Evapotranspiration from Temperature. *Applied Engineering in Agriculture* [online]. **1**(2): 96-99 [cit. 2024-5-16]. DOI: 10.13031/2013.26773. ISSN 1943-7838. Dostupné na: <http://elibrary.asabe.org/abstract.asp??JID=3&AID=26773&CID=aeaj1985&v=1&i=2&T=1>

HEATON, J. 2016. An empirical analysis of feature engineering for predictive modeling. In: *SoutheastCon 2016* [online]. IEEE, s. 1-6 [cit. 2025-1-27]. DOI: 10.1109/SECON.2016.7506650. ISBN 978-1-5090-2246-5. Dostupné na: <http://ieeexplore.ieee.org/document/7506650/>

KUHN, M. a K. JOHNSON. 2019. *Feature Engineering and Selection* [online]. Chapman and Hall/CRC [cit. 2025-4-22]. DOI: 10.1201/9781315108230. ISBN 9781315108230.

LEDELL, E. a S. POIRIER. 2020. H2o automl: Scalable automatic machine learning: Scalable automatic machine learning. In: *Proceedings of the AutoML Workshop at ICML*. ICML San Diego, CA, USA, **2020**.

LIAW, A. a M. WIENER. 2015. RandomForest: Breiman and Cutler's random forests for classification and regression: Breiman and Cutler's random forests for classification and regression. *R package version*. **4**(1.1).

MAKKINK,, G. F. 1957. Testing the Penman Formula by Means of Lysimeters. *Journal of the Institution of Water Engineers*. **11**: 277-288.

MCGUINNESS, J. L. a E. F. BORDNE. 1972. *A comparison of lysimeter-derived potential evapotranspiration with computed values*. US Department of Agriculture, (1452). ISSN 0082-9811.

ZHAN, G. a M. LIN SHELP. 2009. Modified Blaney-Criddle method — an empirical approach to estimate potential evaporation using air temperature. In: *Mine Closure 2009: Proceedings of the Fourth International Conference on Mine Closure* [online]. Perth: Australian Centre for Geomechanics, s. 461-471 [cit. 2024-6-3]. DOI: 10.36487/ACG_repo/908_35. Dostupné na: https://papers.acg.uwa.edu.au/p/908_35_Zhan/

Zoznam publikačnej činnosti

ČISTÝ, Milan [60 %] - SOLDÁNOVÁ, Veronika [25 %] - POVAŽANOVÁ, Barbora [15 %]. Irrigation Reservoir Modeling in Catchments without Measurements of Stream Flow. In *ADVCOMP 2019 [elektronický zdroj] : the Thirteenth International Conference on Advanced Engineering Computing and Applications in Sciences. September 22-26, 2019, Porto, Portugal*. 1. vyd. Wilmington, DE : International Academy, Research and Industry Association (IARIA), 2019, USB kľúč, s. 12-18. ISBN 978-1-61208-737-5.

ČISTÝ, Milan [70 %] - POVAŽANOVÁ, Barbora [30 %]. Evaluation of water retention curves by regression and machine learning methods. In *6th World Multidisciplinary Civil Engineering-Architecture-Urban Planning Symposium - WMCAUS 2021 [elektronický zdroj] : 30 August - 3 September 2021, Prague, Czech Republic*. 1. vyd. Bristol : IOP Publishing, 2021, online, [7] s., art. no. 032088. ISSN 1757-8981. V databáze: DOI: 10.1088/1757-899X/1203/3/032088.

Ohlasy:

1. [1] WANG, Junjie - VANAPALLI, Sai. A framework for estimating the matric suction in unsaturated soils using multiple artificial intelligence techniques. In: INTERNATIONAL JOURNAL FOR NUMERICAL AND ANALYTICAL METHODS IN GEOMECHANICS, 2024, Vol. 48, no. 11, pp. 2854-2879. ISSN 0363-9061., Registrované v: SCOPUS, WOS

Ohlas: zahraničný

2. [1] DING, Xun - EL-ZEIN, Abbas. Predicting soil water retention curves using machine learning: A study of model architecture and input variables. In: ENGINEERING APPLICATIONS OF ARTIFICIAL INTELLIGENCE, 2024, vol. 133, no., pp. ISSN 0952-1976., Registrované v: SCOPUS, WOS

Ohlas: zahraničný

ČISTÝ, Milan [55 %] - BAJTEK, Zbyněk [15 %] - ČELÁR, Ľubomír [15 %] - POVAŽANOVÁ, Barbora [15 %]. Analysis and benchmarking of sprinkler irrigation system performance. In *World Multidisciplinary Civil Engineering-Architecture-Urban Planning Symposium WMCAUS 2022 [elektronický zdroj] : Prague, Czech Republic, 5-9 September 2022*. 1. vyd. Melville, USA : AIP Publishing, 2023, online, [7] s., art. no. 090011. ISSN 0094-243X. ISBN 978-0-7354-4663-2. V databáze: DOI: 10.1063/5.0171529 ; SCOPUS: 2-s2.0-85177878051.

Typ výstupu: príspevok z podujatia; Výstup: zahraničný; Registrované v databáze: SCOPUS

POVAŽANOVÁ, Barbora [100 %]. Porovnanie databáz zrážkových údajov pre zvolené územie. In *Zborník príspevkov z 33. konferencie mladých hydroológov, 20. konferencie mladých vodohospodárov, 22. konferencie mladých meteorológov, klimatológov a odborníkov na kvalitu ovzdušia [elektronický zdroj]* : Bratislava, online, 11. november 2021. 1. vyd. Bratislava : Slovenský hydrometeorologický ústav, 2021, USB kľúč, [14] s. ISBN 978-80-99929-30-3.

POVAŽANOVÁ, Barbora [51 %] - ČISTÝ, Milan [49 %]. Comparison of optimization methods for irrigation systems based on suboptimal solutions. In *Proceedings of the 26th International Conference on Circuits, Systems, Communications and Computers. CSCC 2022 [elektronický zdroj]* : 19.-22. July 2022, Chania, Crete Island, Greece. Piscataway : IEEE, 2022, USB kľúč, s. 129-133. ISBN 978-1-6654-8186-1. V databáze: DOI: 10.1109/CSCC55931.2022.00031 ; SCOPUS: 2-s2.0-85147729076. Typ výstupu: príspevok z podujatia; Výstup: zahraničný; Registrované v databáze: SCOPUS

POVAŽANOVÁ, Barbora [100 %]. Vyhodnotenie sucha v povodí Parnej. In *Advances in Architectural, Civil and Environmental Engineering [elektronický zdroj]* : 32nd Annual PhD Student Conference on Applied Mathematics, Building Technology, Geodesy and Cartography, Landscaping, Theory and Environmental Technology of Buildings, Theory and Structures of Buildings, Theory and Structures of Civil Engineering Works, Water Resources Engineering. October 26th 2022, Bratislava, Slovakia. 1. vyd. Bratislava : Spektrum STU, 2022, CD-ROM, s. 187-196. ISBN 978-80-227-5251-0.

Typ výstupu: príspevok z podujatia; Výstup: domáci

POVAŽANOVÁ, Barbora [100 %]. Skúmanie potenciálu strojového učenia pri odhade referenčnej evapotranspirácie FAO. In *Advances in Architectural, Civil and Environmental Engineering (AACEE 2023) [elektronický zdroj]* : 33rd Annual PhD Student Conference on Applied Mathematics, Building Technology, Geodesy and Cartography, Landscaping, Theory and Environmental Technology of Buildings, Theory and Structures of Buildings, Theory and Structures of Civil Engineering Works, Water Resources Engineering. October 25th 2023, Bratislava, Slovakia. 1. vyd. Bratislava : Spektrum STU, 2023, CD-ROM, s. 142-151. ISBN 978-80-227-5378-4.

Typ výstupu: príspevok z podujatia; Výstup: domáci

POVAŽANOVÁ, Barbora [60 %] - ČISTÝ, Milan [40 %]. Data-driven approaches for improved evapotranspiration modelling with limited data. In *Juniorstav 2024 [elektronický zdroj] : proceedings of the 26th International Scientific Conference of Civil Engineering. Brno, ČR, 25. 1. 2024*. 1. vyd. Brno : ECON publishing, 2024, online, [9] s. ISBN 978-80-86433-83-7. V databáze: DOI: 10.13164/juniorstav.2024.24104.

Typ výstupu: príspevok z podujatia; Výstup: zahraničný

POVAŽANOVÁ, Barbora [100 %]. Využitie modelov strojového učenia pri určovaní vodnej hodnoty snehovej pokrývky. In *Advances in Architectural, Civil and Environmental Engineering (AACEE 2024) : 34th Annual PhD Student Conference on Applied Mathematics, Building Technology, Geodesy and Cartography, Landscaping, Theory and Environmental Technology of Buildings, Theory and Structures of Buildings, Theory and Structures of Civil Engineering Works, Water Resources Engineering. October 23rd 2024, Bratislava, Slovakia*. 1. vyd. Bratislava : Spektrum STU, 2024, online, s. 117-125. ISBN 978-80-227-5461-3.

Typ výstupu: príspevok z podujatia; Výstup: domáci

ČISTÝ, Milan [75 %] - POVAŽANOVÁ, Barbora [20 %] - ALEKSIĆ, Milica [5 %]. Evaluation of catchments' similarity by penalization in the context of engineering tasks—a case study of four slovakian catchments. In *Water*. Vol. 13, iss. 20 (2021), online, [18] s., art. no. 2894. ISSN 2073-4441 (2021: 3.530 - IF, Q2 - JCR Best Q, 0.716 - SJR, Q1 - SJR Best Q). V databáze: SCOPUS: 2-s2.0-85119257862 ; DOI: 10.3390/w13202894 ; CC: 000715451800001.

Registrované v databáze: SCOPUS, CC

Ohlasy:

1. [1] SZOLGAY, Ján - MIKLÁNEK, Pavol - VÝLETA, Roman. Interactions of natural and anthropogenic drivers and hydrological processes on local and regional scales: A review of main results of Slovak hydrology from 2019 to 2022. In: *Acta Hydrologica Slovaca*, 2023, vol. 24, iss. 2, pp. 254-265. ISSN 2644-4690., Registrované v: SCOPUS

Ohlas: domáci

ČISTÝ, Milan [30 %] - DANKO, Michal [10 %] - KOHNOVÁ, Silvia [30 %] - POVAŽANOVÁ, Barbora [15 %] - TRIZNA, Andrej [15 %]. Machine Learning Enhanced by Feature Engineering for Estimating Snow Water Equivalent. In *Water*. Vol. 16, iss. 16 (2024), online, [17] s., art. no. 2285. ISSN 2073-4441 (2023). V databáze: CC: 001304643000001 ; SCOPUS: 2-s2.0-85202437494 ; DOI: 10.3390/w16162285.

Typ výstupu: článok; Výstup: zahraničný; Registrované v databáze: CC, SCOPUS

Ohlasy:

- [1] DOS ANJOS, Patrick - COLETI, Jorge Luís - JUNCA, Eduardo - GRILLO, Felipe Fardin - MACHADO, Marcelo Lucas Pereira. Artificial Neural Network-Based Non-Linear Modeling and Simulation of CaO-SiO₂-Al₂O₃-MgO Blast Furnace Slag Viscosity. In: Minerals, 2024, Vol. 14, no. 11, art. no. 1160., Registrované v: SCOPUS, WOS

Ohlas: zahraničný

POVAŽANOVÁ, Barbora [48 %] - ČISTÝ, Milan [48 %] - BAJTEK, Zbyněk [4 %]. Using feature engineering and machine learning in FAO reference evapotranspiration estimation. In *Journal of hydrology and hydromechanics = Vodohospodársky časopis*. Vol. 71, no. 4 (2023), s. 425-438. ISSN 0042-790X (2023). V databáze: DOI: 10.2478/johh-2023-0032 ; SCOPUS: 2-s2.0-85178437292 ; CC: 001104569900009.

Typ výstupu: článok; Výstup: domáci; Registrované v databáze: SCOPUS, CC

Ohlasy:

- [1] PREITE, Luca - VIGNALI, Giuseppe. Artificial intelligence to optimize water consumption in agriculture: A predictive algorithm-based irrigation management system. In: Computers and Electronics in Agriculture, 2024, No. 223, art. no. 109126. ISSN 0168-1699., Registrované v: SCOPUS, WOS

Ohlas: zahraničný

- [1] RATTAYOVA, Viera - GARAJ, Marcel - PARAJKA, Juraj - HLAVCOVA, Kamila. Regional calibration of the Hargreaves model for estimation of reference evapotranspiration. In: JOURNAL OF HYDROLOGY AND HYDROMECHANICS, 2024, Vol. 72, no. 4, pp. 513-521. ISSN 0042-790X., Registrované v: SCOPUS, WOS

Ohlas: zahraničný

- [1] BATHINI, Vijaya - RANI, K. Usha. A Review of Analyzing Different Agricultural Crop Yields Using Artificial Intelligence. In: INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS, 2025, Vol. 16, no. 1, pp. 1278-1290. ISSN 2158-107X., Registrované v: SCOPUS, WOS

Ohlas: zahraničný

ČISTÝ, Milan [70 %] - POVAŽANOVÁ, Barbora [30 %]. Two-dimensional analysis of the irrigation needs in Danubian Lowland in Slovakia. In *Abstracts and Presentation EGU General Assembly 2022 (EGU22) [elektronický zdroj] : EGU sphere - The EGU interactive community platform*. 1. vyd. Göttingen : Copernicus Publications, 2022,

online, [1] s., art. no. EGU22-2295. Dostupné na internete:
<<https://meetingorganizer.copernicus.org/EGU22/EGU22-2295.html>>. V
databáze: DOI: 10.5194/egusphere-egu22-2295.

Typ výstupu: abstrakt z podujatia; Výstup: zahraničný

POVAŽANOVÁ, Barbora [48 %] - ČISTÝ, Milan [48 %] - BAJTEK,
Zbyněk [4 %]. Optimizing temperature-dependent reference
evapotranspiration prediction with machine learning. In *Current problems in
hydrology [elektronický zdroj] : Book of Extended Abstracts and Posters
from the International Conference Current Problems in Hydrology,
organised by the Institute of Hydrology at the occasion of the 70th
Anniversary of the establishment of the Institute of Hydrology SAS and 70
years of SAS. Smolenice, Slovak Republic, 27-29 September 2023*. 1. vyd.
Bratislava : Slovenská akadémia vied, 2023, online, s. 64. ISBN 978-80-
89139-56-9.

Typ výstupu: abstrakt z podujatia; Výstup: domáci