



Fakulta životního  
prostředí

# Vyhodnocení hydrologické bilance na nepozorovaných povodích

Eva Melišová

**Školitel:**

prof. Ing. Martin Hanel, Ph.D.

**Školitel specialista:**

Ing. Adam Vizina, Ph.D.

**Oponenti:**

prof. RNDr. Miriam Fendeková, CSc.

Ing. Ladislav Kašpárek, CSc.

Ing. Miroslav Tesař, CSc.

## Prohlášení

„Prohlašuji, že jsem tuto disertační práci vypracovala samostatně pod vedením školitele a uvedla jsem veškerou použitou literaturu a zdroje. Tištěná a elektronická verze práce se doslovně shodují.“

.....  
Eva Melišová

## Poděkování

Tímto bych chtěla poděkovat vedoucímu práce prof. Ing. Martinu Hanelovi, Ph.D. za vedení, rady, trpělivost, připomínky, které jsem dostávala v průběhu řešení a samozřejmě příteli, rodině a kamarádům za podporu.

# Obsah

Obsah	5
Seznam obrázků	6
Seznam tabulek	8
<b>1 Úvod</b>	<b>11</b>
1.1 Úvod do problematiky	11
<b>2 Příspěvky autora</b>	<b>13</b>
<b>3 Literární přehled</b>	<b>15</b>
3.1 Hydrologický cyklus	15
3.2 Hydrologické modelování	19
3.3 Hydrologický model Bilan	24
3.4 Model SoilClim	29
3.5 Dálkový průzkum Země	30
3.6 Časové řady	36
3.7 Random forest	41
3.8 M-denní průtoky a čára překročení	42
3.9 Kriteriaální funkce	42
<b>4 Metodika</b>	<b>45</b>
4.1 Využití půdní vlhkosti v hydrologickém modelování	45
4.2 Odhad výparu pro Českou republiku	52
<b>5 Výsledky</b>	<b>63</b>
5.1 Využití půdní vlhkosti v hydrologickém modelování	63
5.2 Odhad výparu pro Českou republiku	70
<b>6 Diskuze a závěr</b>	<b>81</b>
<b>Literatura</b>	<b>85</b>
<b>7 Přílohy</b>	<b>93</b>
7.1 Výpočet výparu v modelu Bilan	93
7.2 Zájmové území	95
7.3 Pozorovaná data	96
7.4 Satelitní data	102
7.5 Výpar z vodních nádrží	103

# Seznam obrázků

3.1	Hydrologický cyklus (Peláková a kol., 2020).	16
3.2	Poměry velikostí ploch a složek hydrologické bilance mezi oceány a pevninou (Peláková a kol., 2020).	16
3.3	Schéma odtokového procesu, podle normy ČSN 736530, Kulhavý a Kovář (2000).	17
3.4	Výparoměrná stanice Hlasivo: CGI 3000 (vlevo), srovnávací výparoměr (uprostřed), výparoměr EWM (vpravo) Šuhájková et al. (2020).	18
3.5	Hlavní komponenty systému airGR (vlevo) a schéma modelu GR4J (vpravo).	22
3.6	Schéma modelu Bilan.	25
3.7	Schéma modelu SoilClim.	30
3.8	Zdroje elektromagnetického záření rozdělené podle aktivní a pasivní metody (Bernhardt a Schulz, 2015).	32
3.9	Křivky spektrální odrazivosti pro vybrané materiály (Bernhardt a Schulz, 2015).	32
3.10	Rozdíl mezi polární orbitou a geostacionární orbitou (Bernhardt a Schulz, 2015).	33
3.11	Porovnání dat za rok 2017–2018 pro jezero Most, žlutá čára – odvozená data, fialová čára – produkty LST, zelená – teplota vzduchu, modrá čára – teplota vody.	35
3.12	Porovnání dat za rok 2010–2018 pro jezero Most, žlutá čára – odvozená data, červená čára – produkty LST.	35
3.13	Rozdíl mezi reanalýzami, vlevo ERA-Interim, střed ERA5 a vpravo ERA5-Land Lopez (2020).	37
4.1	Hodnocená povodí.	46
4.2	Schéma hodnocených kalibračních strategií.	48
4.3	Rozdělení výparoměrných stanic a vodních nádrží podle nadmořské výšky Beran et al. (2020).	52
4.4	Rozdíl teploty mezi pozorováním a produktem LST za období 2009–2018 pro jezero Most.	55
4.5	Porovnání produktu Land surface temperature (LST) a klimatických dat.	55
4.6	Rozdíl teplot pro všechny nádrže a jednotlivé měsíce (červená linie zobrazuje průměr).	56
4.7	Ukázka stažených dat ERA5-Land na webovém portálu Copernicus CDS.	57
4.8	Ukázka QQ grafu pro lineární model s hodnotou AIC.	59
5.1	Sumarizovaná vstupní data do modelu Bilan (odtoky, půdní vlhkosti, srážkové úhrny a teploty vzduchu).	63
5.2	Výhodnocení expertní kalibrace pro povodí Labe s DBCN 006000. Porovnání pozorovaného a simulovaného odtoku v mm.	64
5.3	Hustota rozdílů RMSE a KGE mezi expertní kalibrací a ostatními kriteriálními funkcemi (OF). Tečkováná čára odpovídá průměru vybraných nejlepších OF, přerušovaná čára odpovídá průměru OF včetně časových řad, a plná čára odpovídá průměru OF, které nebyly vybrány.	65

5.4	Hustota relativních chyb v parametrech Spa (vlevo) a Grd (vpravo) na základě vybraných nejlepších OF (zelená plocha) a nevybraných (červená plocha). Tečkováná čára odpovídá průměru vybraných nejlepších kritériálních funkcí, přerušovaná čára průměru OF zahrnujících časové řady a plná čára průměru OF, které nebyly vybrány. . . . .	66
5.5	Hustota chyb charakteristik odtoku v Q20 (vlevo) a Q80 (vpravo) na základě vybraných nejlepších OF (zelená plocha) a ostatních (červená plocha). Tečkováná čára odpovídá průměru vybraných nejlepších kritériálních funkcí, přerušovaná čára průměru OF zahrnujících časové řady a plná čára průměry OF, které nebyly vybrány. . . . .	67
5.6	Čára překročení pro odtok v relativních hodnotách, pro kalibrační a validační část. Rozdíl odtoku v % (pozorovaný vs modelovaný odtok) a pravděpodobnost dosažení v % .	68
5.7	Vyhodnocení pozorování výparu pro výparoměrné stanice (červeně: stanice Hlasivo) od roku 1957 do 2019. . . . .	70
5.8	Porovnání odvozených teplot vzduchu a korigovaných dat, modré body – produkty LST, zelené body – korigované data. . . . .	71
5.9	Vyhodnocení průměrného denního výparu pro vodní nádrž jezero Most. . . . .	72
5.10	Vyhodnocení výparu pro navrhované vodní nádrže v jednotlivých měsících. . . . .	73
5.11	Porovnání pozorovaných dat (poz) a reanalýzy ERA5-Land pro teplotu (T), radiaci (R) a evapotranspiraci (E). Barvami jsou odlišeny hodnoty pro jednotlivé stanice. . . . .	74
5.12	Vyhodnocení modelů podle kritériálních funkcí (RMSE, R2, MAE, RERR). Barevně jsou odlišeny jednotlivé modely. . . . .	75
5.13	Vyhodnocení modelů podle kritériálních funkcí (RMSE, R2, MAE, RERR). Barevně jsou odlišeny vybrané modely. . . . .	76
5.14	Výpar z vodních nádrží pro vybrané vzorce a jednotlivé měsíce (květen–říjen), modře je výpar na základě lineárních modelů, zeleně: random forest a oranžově ze studie <a href="#">Beran et al. (2020)</a> . . . . .	78
5.15	Vztah výparu a nadmořské výšky na základě odvozených vzorců (modrá: lineární model, zelená random forest a oranžová dle studie <a href="#">Beran et al. (2020)</a> ). . . . .	79
5.16	Průměrné měsíční hodnoty výparu pro vodní nádrž Orlík (modrá: lineární model, zelená random forest, oranžová dle studie <a href="#">Beran et al. (2020)</a> a černá: výpočet dle ČSN v MŘ). 80	
7.1	Rozdělení výparoměrných stanic a vodních nádrží dle klimatického rozdělení dle Quittoví klasifikace <a href="#">Beran et al. (2020)</a> . . . . .	95
7.2	Detailnější rozdělení Quittoví klasifikace podnebí <a href="#">Beran et al. (2020)</a> . . . . .	95
7.3	Pozorovaná data výparu ve stanicích. . . . .	96
7.4	Pozorovaná data teploty vzduchu ve stanicích. . . . .	97
7.5	Pozorovaná data pro teplotu vody ve stanicích. . . . .	98
7.6	Pozorovaná data pro rychlost větru ve stanicích. . . . .	99
7.7	Pozorovaná data pro relativní vlhkost ve stanicích. . . . .	100
7.8	Pozorovaná data globální sluneční radiaci ve stanicích. . . . .	101
7.9	Rozdíl teplot mezi odvozenými teplotami vzduchu a satelitními daty pro vybrané stanice 102	
7.10	Výpar z vodní nádrže Orlík pro vybrané vzorce a jednotlivé měsíce (květen–říjen), modře je výpar na základě lineárních modelů, zeleně: random forest a oranžově ze studie <a href="#">Beran et al. (2020)</a> . . . . .	103

# Seznam tabulek

3.1	Vstupní a výstupní parametry/proměnné modelu Bilan. . . . .	26
4.1	<i>Charakteristiky povodí: <math>\bar{R}</math>-průměrný odtok za rok, <math>\bar{T}</math>-průměrná teplota, <math>\bar{P}</math>-průměrná srážky za rok, <math>\bar{SW}</math>- průměrná půdní vlhkost počítaná z modelu SoilClim. . . . .</i>	47
4.2	Optimální OF jsou označeny tučně. Sloupec časových řad obsahuje časové řady jako odtok a půdní vlhkost (SW). Hydrologická charakteristika sloupce (R) a (SW) je kombinována se statistickými ukazateli jako průměr, IQR, sd a zvolené nastavení (*). . . . .	50
4.3	Charakteristika vodních nádrží a výparoměrných stanic. . . . .	53
4.4	Vyhodnocení prediktorů postupné regrese, hvězdička ukazuje vybrané prediktory. . . . .	61
5.1	Hodnoty kritériálních funkcí kalibrace pro jednotlivá povodí. . . . .	64
5.2	<i>Rozdíl v RMSE a KGE pro všechny skupiny vzhledem k expertní kalibraci. Automatická kalibrace, časová řada + charakteristiky a jenom charakteristiky - kalibrační strategie, které kombinují odtok (R), půdní vlhkost (SW) nebo odtok + půdní vlhkost (R + SW). . . . .</i>	65
5.3	<i>Relativní rozdíl parametrů Spa a Grd modelu Bilan mezi expertní kalibrací a dalšími kalibračními strategiemi. Automatická, časové řady + charakteristiky a pouze charakteristiky jsou kalibrační strategie, které kombinují odtok (R), půdní vlhkost (SW) nebo odtok + půdní vlhkost (R + SW). . . . .</i>	66
5.4	<i>Relativní rozdíl v Q20 a Q80 pro odtok. Automatická, časové řady + charakteristiky a pouze charakteristiky jsou kalibrační strategie, které kombinují odtok (R), půdní vlhkost (SW) nebo odtok + půdní vlhkost (R + SW). . . . .</i>	67
5.5	<i>Nejlepší OF podle kritériálních funkcí (goodness-of-fit GOF), parametrech hydrologického modelu (BP) a ukazatele vysokého a nízkého průtoku (RS). Časové řady, R-charakteristiky a SW-charakteristiky znamenají kombinaci časové řady nebo charakteristiky odtoku (R) a půdní vlhkosti (SW), jejich statistické ukazatele jsou průměr, mezikvartilové rozpětí (IQR) a sd. Zvolené nastavení je označeno (*). . . . .</i>	69
5.6	Výpar v mm/den pro jezero Most na základě jednotlivých vzorců. . . . .	73
5.7	Průměrné hodnoty kritériálních funkcí vybraných modelů. . . . .	75
5.8	Průměrné hodnoty výparu pro vybrané vodní nádrže dle jednotlivých odvozených a vybraných vzorců. . . . .	80



# Seznam zkratek

## Seznam použitých symbolů/zkratek

API	Application Programming Interface
Bilan	Hydrologický model Bilan
CDS	Climate Data Store
CMIP5	Coupled Model Intercomparison Project Phase 5
ČHMÚ	Český hydrometeorologický ústav
ČR	Česká republika
ČSN	Česká státní norma
DBCN	Databázové číslo vodoměrné stanice
DE	Diferenční evoluce
DPZ	Dálkový průzkum Země
EMG	Elektromagnetické záření
ERA	ECMWF Re-Analysis, typ produktu
ENSEMBLES	Evropský projekt ENSEMBLES, scénáře změny klimatu
ECMWF	Evropské centrum pro střednědobou předpověď (European Centre for Medium-Range Weather Forecasts)
EWM	Výparoměr
FDC	Flow Duration Curve, čára překročení
GOF	Goodnes of fit
LM	Lineární model
MŘ	Manipulační řad vodní nádrže
NetCDF	Network Common Data Form
R	Výpočetní prostředí R
OF	Kritériální funkce
RF	Random Forest, Náhodný les
SCE-UA	Shuffled complex evolution
VÚV-TGM	Výzkumný ústav vodohospodářský T. G. Masaryka, v.v.i.
WATERES	Vodohospodářský model WATERES
WMO	Světová meteorologická organizace

## Seznam proměnných/veličin

<i>D</i>	Rosný bod
<i>E</i>	Aktuální výpar
<i>H</i>	Relativní vlhkost vzduchu
<i>LST</i>	Povrchová teplota-satelitní data
<i>nmv</i>	Nadmořská výška
<i>P</i>	Srážkový úhrn
<i>PET</i>	Potenciální evapotranspirace
<i>Q<sub>Ma</sub></i>	Mděnní průtok
<i>R</i>	Odtok
<i>R<sub>a</sub></i>	Sluneční radiace
<i>RM</i>	Modelovaný odtok
<i>RET</i>	Retence
<i>SW</i>	Půdní vlhkost
<i>ST</i>	Povrchová teplota-data reanalýzy klimatu
<i>T</i>	Teplota vzduchu
<i>T<sub>w</sub></i>	Teplota vodní hladiny
<i>W</i>	Rychlost větru
<i>X</i>	Zeměpisná šířka
<i>Z</i>	Zeměpisná délka

## Seznam jednotek

mm	milimetry
m	metr
m <sup>3</sup>	metr krychlový
km <sup>3</sup>	kilometr krychlový
m.s <sup>-1</sup>	metr za sekundu
m n.m.	metrů nad mořem
m <sup>3</sup> .s <sup>-1</sup>	metr krychlový za sekundu
l.s <sup>-1</sup>	litr za sekundu
Pa	Pascal
mm	milimetry
J.m <sup>-2</sup>	Joul na metr čtverečný
W.m <sup>-2</sup>	watt na metr čtverečný

# Úvod

## 1.1 Úvod do problematiky

Vodní hospodářství, vodní režim krajiny a péče o krajinu se stávají důležitým tématem celospolečenských diskuzí a politik nejen v České republice, ale i ve světě (Beran, 2019). Je zcela zřejmé, že se globální i lokální klimatické podmínky mění a budou mít právě dopad na sektor vodního hospodářství, a proto by mu měla být věnována prvotná pozornost.

Nemění se však pouze klimatické podmínky, ale i technika a poznatky, kterých je možné ve vodním hospodářství a konkrétně v hydrologii využít. V posledních letech je významný rozvoj v poskytování informací z dálkového průzkumu Země využitelných ve vodním hospodářství, nejen pro odbornou veřejnost. Další možností je například využití globálně dostupných reanalýz klimatu nebo jiných dostupných datových zdrojů. Nicméně přes vývoj dostupnosti dat i modelovacích prostředků, hydrologie a vodohospodářství trápí stejné základní otázky:

1. Jak využít tyto informace pro odhad/upřesnění vodního režimu krajiny, zejména v měřítku malých povodí (Máca et al., 2016)?
2. Lze tyto informace/modely věrohodně aplikovat na nepozorovaná povodí (Hrachowitz et al., 2013)?
3. Jak významný je dopad probíhající změny klimatu na dílčí složky hydrologické bilance a následného dopadu na vodní hospodářství (Beran et al., 2013).

Disertační práce se snaží částečně na tyto otázky odpovědět, případně ukázat možnosti využití dat, modelovacích nástrojů či použití prostředí R v hydrologii. V rámci hydrologického modelování je nezbytné definovat problém, pro řešení se následně zvolí nástroj (hydrologický model), který dokáže odpovědět na položené otázky.

Hydrologických modelů je celé spektrum a dělí se například podle struktury na modely epizodní a bilanční. Pro zjištění hydrologické bilance se používají modely bilanční, které počítají množství vody v povodí. Mezi nejpřesnější patří fyzikálně orientované modely, které se snaží popsat realitu co nejvěrněji. Jedním z klíčových procesů určujících hydrologickou bilance je výpar (respektive evapotranspirace), který bývá nicméně, zejména kvůli nedostatku dostatečně podrobných/kompletních údajů, v bilančních modelech odhadován pomocí empirických vztahů, např. pomocí metody Oudin et al. (2010), která je také k dispozici v modelu Bilan.

Evapotranspirace (výpar) je významným faktorem celkové hydrologické bilance. Je to rozdíl mezi odtokem, srážkami a změnou zásoby vody v povodí. Velikost aktuální evapotranspirace/výparu je významně ovlivněna teplotou (vzduchu, povrchu) a množstvím dostupné vody a dalšími faktory. Tato voda je k dispozici neustále na vodních plochách, jejichž podíl na celkové rozloze státu činí 2,11 % (v roce 2017). Při úvaze, že se průměrně ze všech vodních ploch vypaří 700 mm/rok je tento výpar roven průměrnému celoročnímu průtoku cca  $37 \text{ m}^3 \cdot \text{s}^{-1}$ , který odpovídá průtoku Berounky v závěrovém profilu. V letních měsících je tato hodnota samozřejmě vyšší, stejně jako význam výparu v celkové bilanci, zejména v obdobích sucha. Výpar z vodních ploch může být odvozen statistickými metodami (ne/lineární regresí, datově orientovanými přístupy jako random forest, neuronové sítě atp.). Aby však bylo možné tyto vztahy odvodit je nutné mít k dispozici pozorování evapotranspirace/výparu z výparoměrných stanic. Dále je možné využít produktů dálkového průzkumu Země (DPZ), které v

současné době také poskytují odhady evapotranspirace/výparu. Nicméně i tyto produkty je nutné vztáhnout ke staničnímu měření.

Dálkový průzkum Země v hydrologii může tedy výrazně přispět k lepšímu pochopení hydrologického cyklu, a to především v oblastech bez podrobného monitoringu. DPZ v hydrologickém modelování může přispět k zpřesnění popisu hydrologických procesů, například dynamiky vlhkosti půdy. Pro zpřesnění hydrologických procesů mohou také sloužit reanalýzy klimatu (simulace komplexních Earth System modelů), které zároveň zohledňují pozorovaná data. Současné reanalýzy zahrnují poměrně rozsáhlé období, např. reanalýza ERA5-Land je v současnosti k dispozici od roku 1951 a obsahuje 50 proměnných, které se dají využít pro různé hydrologické předpovědi.

Pro nalezení částečných odpovědí byly definovány cíle práce níže.

## Cíle práce

- Zpřesnění odhadu složek hydrologické bilance na nepozorovaných povodích, především potenciální evapotranspirace, výparu z vodní hladiny a modelovaného odtoku.
- Vyhodnocení kalibračních strategií modelu Bilan dle různých přístupů:
  - Manuální expertní kalibrace.
  - Automatická kalibrace.
  - Kalibrace pomocí hydrologických charakteristik.
- Vyhodnocení ztráty vody výparem z vodních ploch pomocí statistických metod. Stanovení jednotné empirické rovnice pro území České republiky s využitím reanalyzovaných dat ERA5-Land, dat z dálkového průzkumu Země a porovnání s měřeními daty z výparoměrných stanic v České republice.
- Výpočet hodnot výparu z vodní hladiny pro vybrané vodní nádrže.

## Příspěvky autora

Melišová, E., Vizina, A., Staponites, L. R., Hanel, M. (2020) The Role of Hydrological Signatures in Calibration of Conceptual Hydrological Model. *Water*, 12(12), 3401.

- Stanovení optimální kalibrační strategie v hydrologickém modelování je důležitá pro přesné hodnocení vodní bilance, zejména pro povodí s omezenými pozorováními. V této studii byl hydrologický model Bilan použit k simulaci hydrologické bilance pro 20 povodí z celé České republiky v období 1981–2016. Kalibrační strategie využívající pozorované odtoky a odhadované časové řady půdní vlhkosti byly porovnány se strategiemi používajícími pouze statistiky odtoku a půdní vlhkosti a také kombinaci statistik a časových řad. Kalibrační strategie byly hodnoceny pomocí (GOF, goodness-of-fit), čáry překročení a nejistotu modelu Bilan. Výsledky ukazují, že expertní kalibrace a kalibrace s časovou řadou odtoku jsou obecně preferovány. Na druhou stranu rozšířené kalibrační kritéria zahrnovaly pouze statistiky odtoku nebo vlhkosti půdy, které byly prospěšné pro snížení nejistoty v parametrech hydrologického modelu. Navíc v mnoha případech poskytuje model pouze s hydrologickými statistikami srovnatelnou shodu jako u kalibračních strategií využívajících odtokové časové řady.

*Doktorandka se podílela na kompletní přípravě článku. Příprava dat, nastavení kalibračních strategií a vyhodnocení strategií.*

Beran, A., Fialová, P., Kožín, R., Melišová, E., Blöcher, J., and Bašta, P. (2020) Vzorce pro výpočet výparu z vodní hladiny pro vybrané vodní plochy v ČR. *Souhrnná výzkumná zpráva za rok 2019*.

- Pro odvození výparu byly použity regresní vztahy pro výpočet výparu z volné vodní hladiny na základě závislosti s pozorováními meteorologickými veličinami. Stanovení regresních vztahů s pomocí výparoměrných stanic bylo aplikováno na vodní nádrže v ČR. Stanovení vzorců pro jednotlivé vodní plochy byly vytvářeny s ohledem na shodu (goodness-of-fit), všechny vzorce byly validované na čtyřech vodních nádržích. Druhá část se věnuje porovnáním meteorologických dat s daty dálkového průzkumu Země a jejich implementaci do vzorců pro výpočet výparu z vodní hladiny.

*Doktorandka se podílela na zpracování produktů ERA5-Land a ERA-Interim a jejich porovnáním.*

Beran, A., Fialová, P., Kožín, R., Melišová, E., Blöcher, J., and Bašta, P. (2019a) Odvození vzorců pro výpočet výparu, využití dálkového průzkumu Země pro výpočet výparu. *Souhrnná výzkumná zpráva za rok 2018*.

- Pro výpočet výparu byly vytvořeny vzorce na základě naměřených meteorologických dat z výparoměrné stanice Hlasivo u Tábora. Výběr stanice byl založen na poskytnutí dostatečně dlouhé časové rady od roku 1957 společně s dalšími meteorologickými veličinami. Pozorování ostatních meteorologických veličin společně s výparem dovoluje odvození empirických vztahů. Ve zprávě jsou popsány postupy pro odvození regresních vztahů pro výpočet výparu z volné vodní hladiny s pozorováními meteorologickými veličinami z výparoměrné a meteorologické stanice Hlasivo u Tábora. Následně byly vzorce validované na odlišné časové radě ze stanice Tišice. Druhá část se zabývá porovnáním satelitních dat na s pozorováními daty na referenční lokalitě, nádrž jezero Most a s dalšími vodními nádržemi.

*Doktorandka se podílela na zpracování satelitních dat a jejich aplikaci do vzorců pro výpočet výparu.*

Melišová, E., Hanel, M., Vizina, A. (2017) Evaluation of hydrological balance using soil moisture. *International Multidisciplinary Scientific GeoConference: SGEM*, 17, 261–268.

- V současnosti roste zájem o složku půdní vlhkosti, která může výrazně ovlivnit hydrologický cyklus. V hydrologickém cyklu je půdní vlhkost zdrojem vody pro evapotranspiraci, která ovlivňuje už zmíněný hydrologický cyklus, radiační rovnováhu Země konkrétně v latentním tepelném toku. Půdní vlhkost závisí na množství různých kritérií, např.: srážky, teplota, vegetace, retenční kapacita půdy. Odhadovaná vlhkost půdy je užitečná pro vyhodnocení vodní bilance pomocí hydrologických modelů v pozorovaných a nepozorovaných povodích nebo pro snížení nejistoty v odhadovaných parametrech hydrologického modelu. Cílem této studie bylo zhodnotit tento potenciál. Toho se dosáhne (i) začleněním půdní vlhkosti jako vstupu do hydrologického modelu, (ii) kalibrací hydrologického modelu s respektem na půdní vlhkost (iii) omezením rozsahu příslušného parametru hydrologického modelu na základě odhadů půdní vlhkosti. První dvě strategie jsou testovány v situacích, kdy je k dispozici pozorovaný odtok a kdy jsou k dispozici pouze základní charakteristiky odtoku (průměr, odtokový součinitel). Přidaná hodnota odhadů půdní vlhkosti je hodnocena ve vztahu k predikci v neměřených povodích a snížení nejistoty v odhadovaných parametrech.

*Doktorandka se podílela na komplexní přípravě článku. Příprava dat, nastavení kalibrací a vyhodnocení kalibračních strategií.*

Vizina, A., Vlnas, R., Hanel, M., Kašpárek, L., Melišová, E., Beran, A., Kožin, R., Strnad, F. (2017) Hydrologická bilance a disponibilní vodní zdroje v České republice v době hydrologického sucha. *Vodohospodářské technicko-ekonomické informace*, 60(4), 6–11.

- Článek se zabývá hodnocením hydrologické bilance na celém území České republiky, které bylo rozděleno do 133 mezipovodí za období 1981–2015 v měsíčním časovém kroku. Pro ověření, jak se suchá období chovala, byl použit model hydrologické bilance Bilan, pomocí kterého byly tyto epizody za posledních 35 let vyhodnoceny, a to jak z pohledu jednotlivých zásob vody (sněh, půda, podzemní vody), tak podle jednotlivých toků vody (srážky, evapotranspirace, infiltrace, odtok). Článek dále seznamuje s výsledky disponibilní vody za normálních podmínek a při pětiletém a desetiletém suchu ve dvou variantách. První se zabývá vyhodnocením zdrojové oblasti, ve druhé je vyhodnocení pomocí zjednodušeného modelu vodohospodářské bilance WATERES.

*Doktorandka se podílela na přípravě kalibrací povodí.*

Vizina, A., Hanel, M., Melišová, E. (2014) Analýza propagace sucha pomocí generátoru počasí. *Vodní hospodářství*, 5–11.

- Extrémní hydrologické situace, které lze pozorovat na přelomu 20. a 21. století, jsou reprezentovány rozsáhlými nebo bleskovými povodněmi a déle trvajícím periodami sucha. Z tohoto důvodu je velmi aktuálním tématem řešení dopadů klimatické změny na hydrologický režim. Dopady sucha je možné částečně zmírnit, nicméně k tomu je potřeba lépe pochopit jeho průběh. Ve výzkumu sucha stále existuje řada překážek. Vzhledem k tomu, že neexistuje jednotná definice sucha, není v současné době možné stanovit ani jednotný ukazatel či metodu vyhodnocení sucha. Metody vyhodnocení sucha se vždy odvíjí od použité definice a od podmínek na dané lokalitě. Příspěvek se zabývá problematikou modelování hydrologické bilance, generátoru počasí, kvantifikací a analýzou sucha pro současná a výhledová období. Cílem práce je stanovení vhodného meteorologického indexu pro predikci hydrologického sucha v daném povodí.

*Doktorandka se podílela na generování klimatických scénářů pomocí stochastického generátoru počasí LARS-WG.*

# Literární přehled

V kapitole 3.1 jsou uvedeny základní pojmy osvětlující malý a velký oběh vody, na které navazuje již podrobnější popis srážko-odtokového procesu, základních hydrologických pojmů a veličin, které se v práci využívají. V kapitole 3.2 jsou detailněji popsány poznatky o hydrologickém modelování, základní rozdělení hydrologických modelů, bilanční modely v prostředí R a postupy modelování hydrologické bilance. Kapitola 3.3 popisuje hydrologický model Bilan, který byl v této práci použit, se zaměřením na proces kalibrace, popis kalibračních strategií a možností výpočtu výparu modelem Bilan. Kapitola 3.4 seznamuje s modelem SoilCLim, jehož výstupy byly využity pro kalibraci modelu Bilan pomocí hydrologických podpisů (viz kapitola 4.1). V kapitole 3.5 je uvedena základní definice dálkového průzkumu Země (DPZ), principy DPZ, příklady relevantních produktů DPZ, a popis přístupů k DPZ datům a reanalýzám klimatu pomocí statistických metod. Kapitola 3.6 popisuje přístupy k odhadu trendů pomocí statistických metod, reprezentaci sezónní složky a periodicity, metodu nejmenších čtverců a regresní analýzu, která byla využita pro odhad výparu. Dále se zabývá i metodou Random Forest (RF), která byla také použita pro odhad výparu. Popis RF je uveden v kapitole 3.7 a navazuje na ní kapitola 3.8 s definicí M-denní průtoků a čar překročení. Literární přehled uzavírá kapitola 3.9, která popisuje kritériální funkce.

## 3.1 Hydrologický cyklus

Pojem hydrosféra označuje veškerou vodu na Zemi bez rozdílu skupenství. Nachází se v pěti rezervoárech (viz Obr. 3.1):

- oceánech a mořích,
- atmosféře,
- povrchové vodě,
- podzemní vodě,
- sněhu a ledu.


Pohyb vody mezi oceánem, atmosférou, zemským povrchem a zónami výskytu podzemní vody se nazývá globální hydrologický cyklus, který je ovlivněn energií vyzářenou ze Slunce. Tato energie způsobuje výpar vody buď z oceánu nebo z pevniny, který je přesouván do vyšších vrstev atmosféry, kde dochází ke kondenzaci a vypadávání srážek zpět na pevninu nebo oceán. V rámci hydrologického cyklu rozlišujeme malý a velký oběh vody. Velký hydrologický cyklus se odehrává v systému:

oceán → *atmosféra* → *pevnina* → *atmosféra* → *oceán*.


Mezi pevninou a atmosférou dochází ke složité a mnohokrát se opakující výměně vody, která vede k opětovnému návratu téhož množství vody zpět do oceánu, tím se velký oběh vody uzavře. Malý hydrologický cyklus probíhá v systému:

oceán → *atmosféra* → *oceán nebo pevnina* → *atmosféra* → *pevnina*,

přičemž probíhá převážně nad oceánem (Šobr, 2016). Poměr velikostí ploch a složek hydrologické bilance oceány a pevninou je zobrazen na Obr. 3.2. Základní členy hydrologické bilance tvoří srážkové úhrny (veškerá voda ze vzduchu, která se dostane na zemský povrch), výpar (transpirace,



Obr. 3.1 Hydrologický cyklus (Peláková a a kol., 2020).



Obr. 3.2 Poměry velikostí ploch a složek hydrologické bilance mezi oceány a pevninou (Peláková a a kol., 2020).

evaporace, evapotranspirace), odtok (povrchový, hypodermický a základní odtok) a podzemní odtok (odtok vody z povodí v rámci proudění podzemní vody)(Beran, 2019).

Základní jednotkou v hydrologii je povodí, což je území ze kterého odtéká všechna voda k určitému místu, závěrovému profilu Starý (2005). Povodí je ohraničeno rozvodnicí (hypotetická čára vyznačující geomorfologickou hranici mezi sousedními povodími), které lze rozdělit na orografickou a hydrogeologickou.

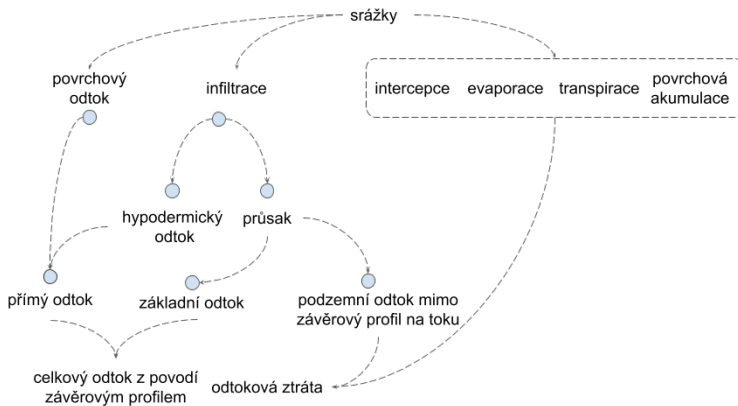
- Orografická rozvodnice vymezuje povodí povrchové vody, probíhá od závěrného profilu po nejvyšších bodech povodí. Prakticky se jedná o hřbetnici, což je hypotetická čára styku dvou přilehlých svahů téhož hřbetu.
- Hydrogeologická rozvodnice ohraničuje povodí podzemních vod, pro jejich určení je však potřeba znát geologické složení podpovrchových vrstev. Pro matematické modelování hydrologické bilance se ideálně kryje s orografickou rozvodnicí, často a v místech se složitější geologickou stavbou může být však její průběh zcela odlišný.

## Srážko-odtokový proces

Srážko-odtokový proces definuje Starý (2005), jako přeměnu atmosférických srážek dopadajících na povodí na odtok vody závěrovým profilem daného povodí, který je ovlivněn klimatickými a geografickými činiteli. Klimatické činitele tvoří meteorologické činitele ovlivňující výpar vody z povodí, t.j.



časový a prostorový průběh spadlé srážky, vlhkost ovzduší, výpar, teplota ovzduší, rychlost a směr větru, atmosferický tlak. Geografické činitele jsou dynamické vlastnosti povodí a určují jakým způsobem se bude časový průběh srážky v daném prostorovém rozložení transformovat do časového průběhu odtoku vody v závěrovém profilu. Mezi geografické činitele patří: plocha, velikost, nadmořská výška, tvar, reliéf, říční síť, hydrogeologické poměry, vegetační pokryv. Srážko-odtokový proces se skládá ze dvou dílčích transformací, (i) hydrologická a (ii) hydraulická transformace. Hydrologická transformace je proces, kdy od srážky jsou odečteny hydrologické ztráty: evapotranspirace, intercepce, ztráta navlháním, infiltrace, povrchová retence. Po odečtení všech ztrát zůstává efektivní intenzita srážky, která odtéká z povodí ve formě plošného povrchového odtoku, při němž se uplatňuje druhá, hydraulická transformace. Mezi další složky odtoku pak patří základní odtok a hypodermický odtok [Melišová \(2015\)](#). Srážko-odtokový proces dle normy ČSN 736530 je ukázán na Obr. 3.3.



Obr. 3.3 Schéma odtokového procesu, podle normy ČSN 736530, [Kulhavý a Kovář \(2000\)](#).

Pro vyjádření vztahu mezi úhrnem srážek  $P$ , úhrnem výparu  $E$  a úhrnem odtoku  $R$  slouží bilanční rovnice (3.1). Rovnice platí pro povodí bez nádrží a pro povodí bez přítoku a odtoku vody ze sousedních povodí. Platnost bilanční rovnice lépe vystihuje rovnice (3.2), kde je doplněn retenční člen  $RET$ . Retenční člen  $RET$  zohledňuje například změnu zásob podzemní vody v uvažovaném povodí.

$$R = P - E \quad (3.1)$$

$$R = P - E \pm RET \quad (3.2)$$

## Srážka

Atmosferické srážky (hydrometeory), patří k základním hydrologickým veličinám, je to soustava vodních částic vzniklé kondenzací či sublimací vodní páry v ovzduší ve stavu kapalném (déšť, mrznoucí déšť, mrholení, mrznoucí mrholení) nebo tuhém (sněžení, sněhové krupky, sněhová zrna, krupky, zmrzlý déšť, kroupy a ledové jehličky) padající nebo vznášející se v atmosféře nebo zdvižené větrem z povrchu země nebo usazené na předmětech na zemi či ve volné atmosféře (rosa, jíní, námraza a

ledovka). Srážky se rozdělují podle skupenství (kapalné, tuhé a smíšené), původu (padající, usazené), délky výskytu (trvalé, občasné a přeháňky) a podle příčiny vzniku (konvenční, cyklonální a orografické) (Sobíšek, 1993).

## Výpar

V publikaci **Kožnarová a Klabzuba (2009)** je výpar definován jako množství vody, které se vypaří do ovzduší z volné hladiny, povrchu půdy, sněhové pokrývky nebo porostů z jednotky plochy za jednotku času. Podle rovnic 3.1, 3.2 má výpar rozhodující vliv na celkovou bilanci. Představuje základní proces, kterým se dostává vodní pára do atmosféry a spolu s radiační bilancí je důležitým faktorem při bilanci tepla zemského povrchu. Rozlišuje se výpar potenciální (maximálně možný) a výpar skutečný (aktuální, efektivní). Potenciální výpar reflektuje meteorologické podmínky pro výpar za dostatečného množství zdroje vody, např.: může být měřen z vodní hladiny, povrchu ledu. Měří se pomocí evaporimetrů, častěji se vypočítává z meteorologických prvků nebo pomocí odvozených modelovaných vztahů (na základě radiační bilance, slunečního svitu, oblačnosti, teploty a vlhkosti vzduchu aj). Výparnost se považuje za druh potenciálního výparu. Výparnost je hodnota výparu naměřená přímo na určitém typu výparoměru. Výpar závisí na teplotě a nadmořské výšce **Storn a Price (1997)**. Výpar skutečný představuje výpar, který se skutečně vypaří do ovzduší z různých povrchů v přírodních podmínkách. Pozoruje se pomocí lyzimetřů a výparoměrů. Může být odvozen empiricky pomocí meteorologických prvků (srážky, odtok, změny obsahu vody v půdě). Výpar se vyjadřuje v jednotkách mm za den, měsíc, či rok. Podle **Kofroňová et al. (2019)** výpočet potenciální evapotranspirace (*PET*) je klíčovým prvkem pro výpočet hydrologické bilance a pro stanovení skutečné evapotranspirace.

Pro odhad průměrného denního výparu lze použít řadu vzorců **Starý (2005)**; **Beran et al. (2019b)**. Výpar z volné hladiny je možné měřit pomocí řady výparoměrů, např. Rónův, Wildův, GGI 3000, výparoměrem Class-A-Pan, EWM výparoměrem a srovnávacím výparoměrem **Starý (2005)**; **Možný (2005)**. Srovnávací výparoměr je v České republice ve stanici Hlasivo v působnosti Výzkumného ústavu vodohospodářského T.G.Masaryka. Přehled výparoměrů je ukázán na Obr. 3.4.



**Obr. 3.4** Výparoměrná stanice Hlasivo: CGI 3000 (vlevo), srovnávací výparoměr (uprostřed), výparoměr EWM (vpravo) **Šuhájková et al. (2020)**.

V práci byla použita data z EWM výparoměrů, která byla poskytnuta ČHMÚ. EWM výparoměr se skládá z výparoměrné nádoby, která má plochu  $3\text{m}^2$ , přístroje pro měření a regulaci hladiny vody. Přístroje pro regulaci jsou umístěny v nerezové nádobě válcovitého tvaru s víkem, které je spojeno s výparoměrnou nádobou, kde se využívá princip spojitých nádob. Hladina vody je měřena plovákovým způsobem. Povrchová teplota vody se měří pomocí snímače, který je umístěn 10 mm pod hladinou vody a zařízení pro přenos naměřených dat. Přístroj má spolehlivé výsledky, automatické měření je přesnější a méně zatížené náhodnými a systematickými chybami, měření je kontinuální, což přispívá

k představě o denním chodu výparu (Možný, 2003). Aktuálním statistickým vyhodnocením trendů výparu na pozorovaných stanicích v České republice se zabývá také studie Možný et al. (2020).

Měření evapotranspirace je možné měřit také pomocí gravitačního monolitického lyzimetru. V současné době jsou poskytovány také hodnoty evaporace a evapotranspirace jako produkty dálkového průzkumu Země.

## Odtok

Odtok je hydrologický pojem vyjadřující objem vody, které odteče za určité časové období z povodí. Celkový odtok je součástí hydrologické bilance a je tvořen povrchovým odtokem, podpovrchovým-hypodermickým odtokem a základním odtokem. Povrchový odtok je část, která stéká přímo po povrchu terénu. Podpovrchový odtok-hypodermický odtok, část odtoku, která se infiltrovala do půdního profilu a není v kontaktu s podzemní vodou. Povrchový a hypodermický odtok probíhá v průběhu srážkového úhrnu nebo bezprostředně po jejím skončení a tvoří tzv. přímý odtok. Podzemní odtok je tvořený vodou, která se infiltrovala do podzemní vody, oproti povrchovému a hypodermickému odtoku je pomalejší. Základní odtok je tvořená přítokem podzemních vod do toku. Hodnota základního odtoku reprezentuje změny zásob podzemních vod. Specifický odtok, kde základní jednotkou je průtok  $Q$ , je množství vody, která odtéká za jednotku času z jednotky plochy povodí, udává se v  $\text{m}^3 \cdot \text{s}^{-1} \cdot \text{km}^2$  nebo  $\text{l} \cdot \text{s}^{-1} \cdot \text{km}^2$ . Slouží pro posouzení vodnosti v povodích nebo v jejich částech. Další měrnou jednotkou je odtok  $V_o$ , je to objem vody  $\text{m}^3$ ,  $\text{km}^3$ , která odtékla z povodí za daný časový úsek (hodina, den, měsíc, rok). Hodnocení průtoků může být například pomocí hydrogramu a čar překročení (Pavelková a Frajer, 2013).

**Hydrogram** – Hydrogram, neboli čára průtoků je jedním z prostředků, jak vyjádřit velikost odtoku a zároveň podává velmi názornou informaci o jeho proměnlivosti (Netopil, 1970; Pavlásek et al., 2006). Jedná se o graf, znázorňující závislost velikosti průtoků (osa y) na čase (osa x).

**Čára překročení** – Čára překročení (FDC – Flow Duration Curve) neboli histogram kumulativních četností, je další ze způsobů, jak graficky vyjádřit variabilitu odtoku. Křivka nám dává informaci o hodnotách průtoků ve sledovaném období, respektive kolikrát za dané období byla určitá hodnota průtoků dosažena či překročena. Z výsledného grafu poté můžeme odečíst hodnotu M-denních průtoků (Netopil, 1970).

## 3.2 Hydrologické modelování

Hydrologický model je zjednodušená reprezentace části hydrologického cyklu. Přesné zaznamenání komplexního hydrologického cyklu není možné, proto hydrologické modely představují zjednodušení pomocí matematického znázornění. Síla hydrologického modelu/modelování tkví v umění vystihnout realitu nebo odpovědět na otázky, na které se modelář ptá. Pro správný chod modelu jsou důležité vstupy – data, které splňují základní požadavky týkající se spolehlivosti, přesnosti a reprezentativnosti, alespoň v míře potřebné pro řešení daného problému (Becker a Serban (1990). Existuje velké množství modelů a správný výběr modelu je nezbytný pro řešení konkrétní problematiky (Jeníček, 2005).

Hydrologické modelování podle Becker a Serban (1990) ovlivňuje zejména:

- poptávka po komplexnějších a spolehlivějších informacích o hydrologických procesech, vlastnostech a o dostupnosti vodních zdrojů (kvantita a kvalita) v prostoru a čase na základě různých časoprostorových a časových měřitek (mikro-, mezo- a makroskopické měřítko), v reálném čase, krátkodobě, dlouhodobě pro historické, současné a výhledové klimatické podmínky;

- rostoucí potřeba zkoumat účinky různých lidských vlivů a dopadů na hydrologický režim a na kvalitu vody, zejména na změny ve využívání půdy, proměnlivost podnebí a změny podnebí a intenzivnější postupy při využívání vody a využívání půdy;
- dostupnost údajů z dálkového průzkumu Země o důležitých hydrologických parametrech a charakteristikách, např.: povrchu půdy, teplota, vlhkost půdy, srážky, evapotranspirace, albedo a další.

## Rozdělení hydrologických modelů

Kapitola popisuje rozdělení modelů podle účelu aplikace, systému, stupně kauzality a podle míry časové a prostorové diskretizace dle [Jeníček \(2005\)](#).

### Rozdělení dle účelu aplikace :

- modely používané v operativní hydrologii: aplikace dat z automatických meteorologických stanic nebo radarů, prioritou je rychlost výpočtu a většinou tvorba krátkodobé předpovědi vodních stavů či průtoků,
- modely aplikované pro návrhovou a projekční činnost: pro posouzení různých technických staveb, výpočet záplavových zón, řešení protipovodňové ochrany aj., je možné také pomocí těchto modelů srážko-odtokový proces,
- modely využívané pro projekční činnost: umožňují další vývoj a výzkum srážko-odtokového procesu a jeho popis.

### Rozdělení podle typu systému dle WMO :

- Elementární: pro menší a středně velké odtokové plochy, v řešeném území je jednoduchá říční síť.
- Komplexní: pro povodí nebo velké odtokové plochy s hydrogeologickou strukturou, říční síť může být rozvětvená jedná se o komplexní systémy.

### Rozdělení podle stupně kauzality :

- Deterministické modely: modely jsou popsány vztahem závislých proměnných (výstupní veličiny) a nezávislých proměnných (vstupní veličiny). Deterministických modelů existuje celé spektrum, které se odlišují fyzikálním přístupem, strukturou a časovou i prostorovou diskretizací. Modely, které jsou založeny na fyzikálním popisu srážko-odtokového procesu a respektují zákon zachování hmoty jsou tzv. *white-box* modely, *grey-box* modely reflektují fyzikální zákony ve zjednodušené formě i empiricky odvozené vztahy a *black-box* modely používají vztahy empirické mezi vstupními a výstupními veličinami.
- Stochastické modely: neobsahují vazbu mezi příčinnou a důsledkem a dělí se na dvě základní skupiny. První skupinou jsou pravděpodobnostní modely, kde jednotlivé veličiny jsou charakterizovány pravděpodobnostním rozdělením, druhou poté modely, které především generují časové řady (extrapolace, ARMA modely aj.).

### Rozdělení podle časové a prostorové diskretizace :

- Časová diskretizace: primárně je určena dle užití modelu, kdy například v operativě se standardně užívá hodinový krok, ale například bilanční modely využívají delšího časového kroku (den, týden, měsíc). Dle časové diskretizace se modely dále dělí na kontinuální (modelují se i víceleté události) a epizodní (modeluje se daná epizoda).

- Prostorová diskretizace:
  - Celistvé modely: někdy také jako *lumped* modely. Parametry charakterizují celé povodí, pro které jsou také připraveny vstupní data. Příkladem je model hydrologické chronologické bilance Bilan.
  - Semi-distribované modely: povodí je rozděleno na elementární odtokové plochy (subpovodí), které mají homogenní odtokové parametry (stejný půdní druh, vegetační pokryv, klima). Jednotlivá subpovodí následně generují odtok.
  - Distribuované modely: modely založené na distribuovaných parametrech, prostor je charakterizován jednotlivými gridy (zpravidla čtvercová síť), které mohou mít různou velikost (od jednotek metrů po km), pro každý grid existují vstupní a výstupní údaje a je v nich provedena parametrizace modelu.

## Bilanční modely

Hydrologické modely jsou v současnosti často mimo standardních grafických uživatelských rozhraní také poskytovány jako R-balíky na úložišti CRAN (<https://cran.r-project.org/>). V Evropě mezi nejpoužívanější patří:

- R-balík: airGR (Coron et al., 2021, 2017),
- R-balík: HBV.IANIGLA (Toum, 2021),
- R-balík: hydromad (Andrews a Guillaume, 2018),
- R-balík: TUWmodel (Viglione a Parajka, 2020),
- R-balík: Bilan (Vizina et al., 2015).

Tyto balíky se dají využívat v programovacím a statistickém prostředí R (R Core Team, 2020), všechny zmíněné modely jsou volně z tohoto úložiště stažitelné. Výhodou je možnost následného vyhodnocení a porovnání jednotlivých modelů či dílčích komponent a zároveň možnost efektivního skriptování a zpracování velkých počtů povodí.

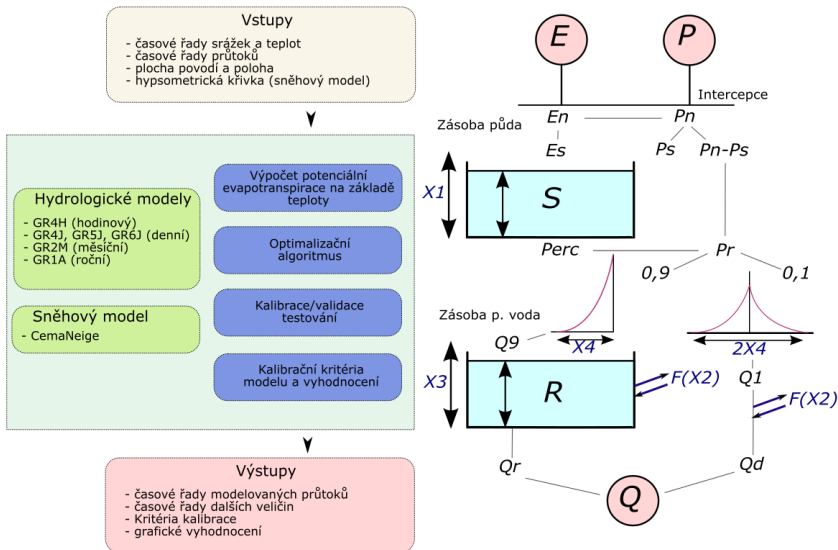
Model airGR umožňuje použití 6 modelů z rodiny GR (GR4H, GR4J, GR5J, GR6J, GR2M, GR1A) a jeden sněhový modul (CemaNeige). Jde o koncepční hydrologické modely vyvinuté výzkumnou skupinou IRSTEA ve Francii. Pracují v hodinovém, denním, měsíčním a ročním časovém kroku (Coron et al., 2017). Na Obr. 3.5 je uvedeno základní schéma konceptu s definováním vstupních dat, výpočetních procesů a výstupů, na obrázku je dále ukázka schéma modelu GR4J.

Model HBV (Hydrologiska Byrans Vattenbalansavdelning) je konceptuální hydrologický model, který je vyvíjen Švédským meteorologickým a hydrologickým institutem (SHMI). Používá se na predikci průtoků ve Švédsku a Norsku. Byl testován v různých geografických podmínkách na povodích ve Švédsku (Seibert, 1997), kde byl přizpůsoben lokálním specifickým požadavkům. V současnosti je široce využíván v povodích s rozmanitými hydroklimatickými podmínkami.

Model HYDROMAD je koncept, který seskupuje dynamické, konceptuální nebo statistické hydrologické modely. Základním vstupem jsou srážkové úhrny a evapotranspirace. U některých modelů jsou použity další vstupy, například teplota vzduchu, vlhkost vzduchu atd. Vstupy jsou ve formě časových řad nejčastěji v denním časovém kroku (Andrews et al., 2011).

Model TUWmodel je konceptuální srážko-odtokový model, následuje strukturu modelu HBV. Model lze částečně označit jako semi-distribovaný model s dvojitým rozvrstvením půdní vrstvy. Model je možné spustit v denním a kratším časovém kroku (Parajka et al., 2007).

Model Bilan je konceptuální srážko-odtokový model, viz kapitola 3.3. Patří mezi modely, které je možné použít ve statistickém prostředí R.



Obr. 3.5 Hlavní komponenty systému airGR (vlevo) a schéma modelu GR4J (vpravo).

Pro vyhodnocení hydrologických modelů lze použít R-balík hydroGOF, který porovnává shodu mezi pozorováními a simulovanými hodnotami, které se používají při kalibraci, validaci a při aplikaci hydrologických modelů. Balík využívá kvantitativní statistiku a grafické znázornění, což znamená vyhodnocení dle kritériálních funkcí (MAE, RMSE, KGE, R2 a jiné) [Mauricio Zambrano-Bigiarini \(2020\)](#).

## Modely využívané v hydrologii

Dalšími hydrologickými modely jsou:

- Hydrologic Engineering Center - Hydrologic Modeling System (HEC-HMS) simuluje kompletní hydrologické procesy v povodí. Software obsahuje mnoho tradičních hydrologických analytických postupů, jako je simulace infiltrace, vyhodnocení pomocí jednotkového hydrogramu atd. Zahnuje postupy pro kontinuální simulaci, včetně evapotranspirace, tání sněhu a započítávání vlhkosti půdy [Halwatura a Najim \(2013\)](#).
- MIKE-SHE je koncepční distribuovaný, případně semi-distribuovaný srážko-odtokový model dánské firmy DHI (Danish Hydraulic Institute). Skládá se z více modelů MIKE11, MIKE21, MIKE3 aj., které simulují jednotlivé fáze odtokového procesu. Model má návaznost geografické informační systémy (GIS) [Jeníček \(2005\)](#).
- Pomocí hydrologického modelu DesQ-MaxQ je možné stanovení návrhových charakteristik povodňových vln v nepozorovaných proflech malých povodí vyvolaných přívalovými dešti a výpočtu ovlivnění maximálních průtoků a objemů povodňových vln změnou charakteristik povodí, model vyvinul prof. Hrádek, [Hrádek a Kuřík \(2001\)](#).

## Postup modelování hydrologické bilance

Hydrologické modely se běžně používají k výpočtu hydrologické bilance povodí, kde vstupem jsou klimatická data nebo veličiny z nich odvozené a výstupem je odtok z povodí, případně další složky hydrologické bilance. Identifikace parametrů modelu, které ovlivňují jednotlivé popisované hydrologické procesy probíhá prostřednictvím kalibrace na základě pozorovaných referenčních hodnot (většinou odtoku). Parametry modelu se zpravidla validují na nezávislých datech. Ve studiích (Hanel et al., 2014; Melišová et al., 2017, 2020) byly použity různé kalibrační strategie. V disertační práci byla použita také kalibrační strategie s využitím hydrologických charakteristik (hydrological signatures). Tento typ kalibrace umožňuje mj. model Bilan 3.3. Zahraniční studie (Tuo et al., 2018) popisuje testování rozdílných kalibračních strategií a kalibrační strategie s využitím hydrologických charakteristik (Addor et al., 2018; Hrachowitz et al., 2014; Shafiq a Tolson, 2015).

Kalibrační strategie ovlivňuje kvalitu výstupu hydrologického modelu. Široce používaná ruční (expertní) kalibrace parametrů je silně ovlivněna zkušenostmi hydrologa, je časově náročná a silně ovlivňuje kvalitu kalibrovaného modelu (Madsen, 2000). Automatická kalibrace je naproti tomu rychlá a výstup simulací modelu je explicitně spojen s hodnotami parametrů v mezích optimalizačních kritérií. Automatická kalibrace hydrologických modelů obvykle využívá k optimalizaci parametrů pozorované časové řady odtoku (průtoku). To však není možné v povodích s omezenými pozorováními. Navíc kvůli ekvifinalitě mohou modely s podobným (dobře shodným) výstupem vycházet z modelů s velmi odlišnými sadami parametrů, a proto nemusí správně simulovat fyzikální procesy (Melišová et al., 2020).

V poslední době řada studií poukázala na to, že spoléhání se pouze na kalibraci hydrologických modelů podle pozorovaného odtoku může vést k nevhodné schematizaci hydrologických procesů a zdůrazňují význam expertních a lokálních znalostí (Hrachowitz et al., 2014; Pfannerstill et al., 2017) anebo vícekritériální kalibrace (Tuo et al., 2018).

Jedním z přístupů k omezení náročnosti kalibrace hydrologického modelu je vyhodnocení hydrologických charakteristik (signatures – obvykle některé dlouhodobé statistiky odtoku, vlhkosti půdy (Melišová et al., 2017), režimu sněhové pokrývky (Tuo et al., 2018)). Jsou odvozeny ze sledovaných nebo simulovaných časových řad (McMillan et al., 2017) s cílem doplnit informace o povodí (Farmer et al., 2003), vyhodnotit kvalitu výstupu modelu (Yilmaz et al., 2008) nebo vylepšit kalibrační techniky (Shafiq a Tolson, 2015). Při výběru reprezentativních hydrologických charakteristik by měla být zohledněna jejich identifikovatelnost, robustnost, konzistence, reprezentativnost a rozlišovací schopnost (McMillan et al., 2017).

Kalibrace hydrologického modelu lze také řešit pomocí čar překročení (FDC – Flow Duration Curve), které mohou napomoci celkovému výslednému hydrogramu (Pokhrel et al., 2012; Westerberg et al., 2011). Ukázalo se například, že správné rovnováhy mezi velmi vysokými a velmi nízkými průtoky lze dosáhnout například pomocí pěti segmentů FDC (Q<sub>2</sub>–Q<sub>5</sub>, Q<sub>5</sub>–Q<sub>20</sub>, Q<sub>20</sub>–Q<sub>70</sub>, Q<sub>70</sub>–Q<sub>95</sub>, Q<sub>95</sub>) a vyhodnocení vhodnosti shody pro každý segment a jeho kombinace do jediné objektivní funkce (Pfannerstill et al., 2014).

V nepozorovaných povodích lze vodní bilanci odhadnout pomocí různých metod, např. extrapolací parametrů hydrologického modelu (Merz a Blöschl, 2004), prostorové blízkosti (Li et al., 2010), odhadu prostorově rozložených proměnných z půdních a dalších geoprostorových datových souborů (Pokhrel et al., 2012), fyzikální podobnosti (Samuel et al., 2011), škálování vztahů (Croke et al., 2004), metodami založenými na regresi (Oudin et al., 2008), hydrologickou podobností (Masih et al., 2010) a využitím charakteristik odtoku (Zhang et al., 2014). Metody využívající reprezentativní hydrologické charakteristiky lze dále rozdělit podle metod predikce na: (i) metody založené na hydrologickém modelování (Biondi a De Luca, 2017; Donnelly et al., 2016) a (ii) metody vícenásobné regrese (Qamar et al., 2016; Visseri a McIntyre, 2016) včetně metod založených na datech, jako

je genetické programování (Havlíček et al., 2013; Heřmanovský et al., 2017) a (iii) na přístupy založené na hydrologické podobnosti (Westerberg et al., 2016).

### 3.3 Hydrologický model Bilan

Hydrologický model Bilan (Tallaksen a Van Lanen, 2004; Vizina et al., 2015) je konceptuální srážko-odtokový model, který se používá pro hodnocení vodní bilance v České republice. U částečně nebo plně konceptuálních modelů nelze některé parametry považovat za fyzicky měřené (nebo měřitelné) veličiny, a je tedy nutné je odhadovat na základě dostupných údajů a informací (Bárdossy, 2007). Struktura modelu je tvořena řadou komponent zásob a sadou jejich vztahů založených na základních principech vodní bilance i jednoduchých matematických konceptech, jako je lineární nádrž. Jeho struktura je podobná hydrologickému modelu HBV (model Hydrologiska Byråns Vattenbalansavdelning) (Seibert, 1997). Vodní bilance je popsána ve třech zónách:

- na zemi,
- v zóně aerace, včetně vegetačního pokryvu,
- v podzemních vodách (Jakubcová et al., 2015).

Vstupní proměnné jsou popsány v Tab. 3.1, v rámci práce byly použity vstupní proměnné srážkové úhrny  $P$  (mm), teploty vzduchu  $T$  ( $^{\circ}\text{C}$ ), odtokové výšky  $R$  (mm) a volitelná časová řada – půdní vlhkost  $SW$  (mm). V modelu jsou jednotlivé komponenty rozděleny na vstupní data, složky vodní bilance a výsledné parametry. Algoritmy použité pro jednotlivé měsíce závisí na podmínkách v konkrétním měsíci. Použitá průměrná měsíční teplota, stejně jako u denního verze modelu rozlišuje zimní a letní podmínky. V měsíčním režimu se celkový odtok (total runoff –  $RM$  (mm)) počítá jako součet přímého odtoku (direct runoff –  $DR$ ), hypodermického odtoku (interflow –  $I$ ) a základního odtoku (baseflow –  $BS$ ) (Vizina et al., 2015). Model je znázorněn na Obr. 3.6, který zobrazuje vstupní data, simulované zásoby a jednotlivé toky. Další podrobnosti viz (Vizina et al., 2010; Machlica et al., 2012; Hanel et al., 2013; Vizina et al., 2018; Melišová et al., 2020, 2017) nebo na webových stránkách bilan.vuv.cz.

Parametry modelu jsou identifikovány (kalibrovány) pomocí shuffled complex evolution (SCE-UA) (Duan et al., 1994) v kombinaci s metodou diferenční evoluce (DE) (Storn a Price, 1997). Algoritmus je stochastický, a proto umožňuje posoudit nejistotu v parametrech modelu opakovanou kalibrací. Standardní kalibrace zahrnuje minimalizaci chyby v simulovaném odtoku ve srovnání s pozorovaným odtokem představovaným hodnotou vybrané kriteriální funkce (OF). Model však umožňuje rozšíření OF tak, aby zohledňoval časové řady dalších proměnných (standardně odhady půdní vlhkosti nebo základního odtoku) nebo dokonce jednotlivé hydrologické charakteristiky, jako je průměr (mean) nebo rozptyl odtoku (sd), indikátory extrémů (mezikvartilové rozpětí IQR).

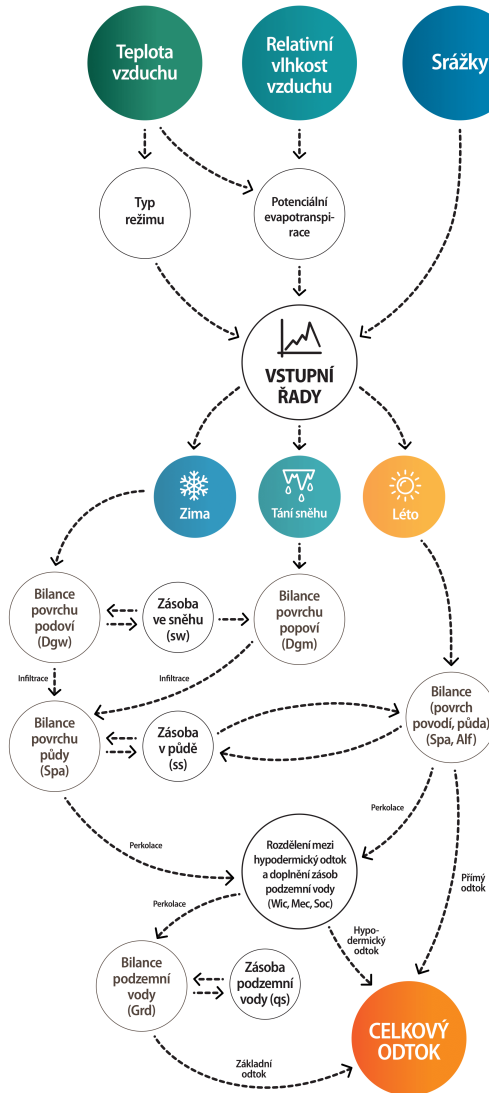
#### Optimalizační algoritmy

Optimalizační algoritmy v modelu Bilan se používají ke kalibraci parametrů modelu a jsou rozděleny na lokální gradientní algoritmus a globální algoritmus. Cílem optimalizace je dosáhnout co nejlepší shody mezi pozorovanými a simulovanými řadami odtoku. Detailní postup je popsán v manuálu pro model Bilan (Kašpárek et al., 2015). V práci je uveden přehled optimalizačních algoritmů pro povodí a pro soustavu povodí dle manuálu modelu Bilan.

#### Lokální gradientní algoritmus (binární vyhledávání)

Kalibrace parametrů probíhá ve dvou krocích, kde lze nastavit výchozí nastavení nezávisle pro každý krok nebo dohromady.





Obr. 3.6 Schéma modelu Bilan.

Tab. 3.1 Vstupní a výstupní parametry/proměnné modelu Bilan.

Vstupní data		Jednotky
Proměnná	Popis	
P	srážky	(mm)
R	odtok (pozorovaný)	(mm)
T	teplota vzduchu	(°C)
H	relativní vlhkost vzduchu	(%)
PET	potenciální evapotranspirace	(mm)
TS	volitelná časová rada	(mm)
<b>Napočítané proměnné</b>		
Fluxes		Popis
PET	potenciální evapotranspirace	(mm)
ET	územní výpar	(mm)
INF	infiltrace do půdy	(mm)
PERC	perkolace z půdní vrstvy	(mm)
I	hypodermický odtok	(mm)
DR	přímý odtok	(mm)
BF	základní odtok (simulovaný)	(mm)
RM	celkový odtok (simulovaný)	(mm)
Stavové proměnné		Popis
SS	zásoba vody v sněhu	(mm)
SW	půdní vlhkost	(mm)
GS	zásoba podzemní vody	(mm)
DS	zásoba pro přímý odtok	(mm)
DEFV	nedostatkové objemy	(mm)
<b>Parametre modelu</b>		
Parametre	Popis	
SPA	kapacita zásoby půdní vlhkosti	
DGM	koeficient mezi teplotou a táním sněhu	
DGW	koeficient dostupnosti vody na povrchu země v zimních podmínkách	
ALF	řídí podíl srážek transformovaných do přímého odtoku	
SOC	distribuce perkolace do mezitoku-interflow a doplňování podzemní vody za letních podmínek	
MEC	distribuce perkolace do mezitoku-interflow a doplňování podzemní vody za podmínek tání sněhu	
WIC	parametr rozděluje perkolaci na hypodermický odtok a na dotaci podzemní vody pro zimní podmínky	
GRD	parametr určující odtok ze zásoby podzemní vody (základní odtok)	

Při klasické optimalizaci se používá střední kvadratická chyba (MSE). Nevýhodou MSE je, že nezaručuje dobrou shodu mezi pozorovanou a simulovanou řadou odtoku v oblasti nízkých průtoků. Pro zlepšení shody byla navržena oprava pomocí střední absolutní procentuální chyby (MAPE). Kritériu MAPE zhoršuje shodu z hlediska průměrného odtoku, proto byl vytvořený optimalizační algoritmus, který kombinuje obě kritéria.

K parametrům ovlivňující průměrný tok patří: Dgm, Spa, Alf a Wic (měsíční typ) a ke kalibraci je zde použito optimalizační kritérium MSE nebo MAE. Parametry ovlivňující rozdělení odtoku Mec, Soc, Grd, Wic (měsíční typ) jsou kalibrovány s využitím MAPE. Tím je zajištěna dobrá shoda mezi průměrným odtokem a nízkými odtoky, které jsou tvořeny převážně základním odtokem.

## Globální algoritmus shuffled complex evolution/differential evolution

Globální algoritmus využívá techniku shuffled complex evolution (SCE-UA) dle (Duan et al., 1994), pro evoluci komplexu se využívá metoda diferenciální evoluce dle (Storn a Price, 1997). Algoritmus zahrnuje uživatelské nastavení:

- diferenciální evoluce (best/1/bin, best/2/bin nebo rand/2/bin),
- počet komplexů NC,
- velikost komplexu M,
- počet promíchání,
- počet generací,
- parametr křížení CR,
- parametr mutace F,
- parametr mutace K,
- velikost ensemble - vypočítán bude ensemble běhů optimalizace.

V článku (Melišová et al., 2020) a disertační práci byla použita kombinace metody SCE-UA s metodou diferenciální evoluce (popis nastavení je uveden v kapitole 3.3).

## Nastavení vah

V modelu je možné nastavit váhy určující do jaké míry je při kalibraci (v optimalizačním kritériu) zohledněn základní a celkový odtok. Tyto váhy jsou v rozmezí 0 a 1. Dále je možné nastavit váhy pro jednotlivé hodnoty odtoku. Hodnoty vah jsou relativní a jejich součet nemusí být jedna. Přiražení vah umožňuje určité úseky zdůraznit nebo potlačit jejich význam. Při nastavení váhy na nulu jsou části časových řad vynechány.

## Nastavení kalibrace pro soustavu povodí

Pokud je připojeno více povodí, optimalizační postup zohledňuje vztahy mezi povodími. Povodí by měla mít nastaven stejný typ modelu a plochy v  $km^2$ . Při optimalizaci parametrů je použitý průměr kritérií ze všech povodí. Při výpočtu tohoto průměru se součet kritérií pro jednotlivá povodí zvyšuje o penalizaci, která je funkcí rozdílů rozdílů modelovaných hodnot odtoku mezi povodím a příslušným větším povodím.

## Výpočet potenciální evapotranspirace v modelu Bilan

Výpočet výparu v modelu Bilan je počítán na základě metody vycházející z vegetačních zón nebo metodou dle Oudina (Kašpárek et al., 2015) pomocí teploty vzduchu a dne v roce.

## Výpočet potenciální evapotranspirace vycházející z vegetační zóny

Tato metoda počítá hodnoty potenciální evapotranspirace na základě sytostního doplňku (pro danou teplotu a vlhkost vzduchu). K tomu se využívá empirických tabulkových hodnot z metodiky (Gidro-meteozdat, 1976), která uvádí měsíční hodnoty potenciální evapotranspirace pro různé vegetační zóny, jež jsou charakterizované různými průměrnými teplotami vzduchu. Výsledná hodnota je interpolována mezi dvěma vegetačními zónami, mezi které spadá dané povodí. Denní hodnoty jsou poté zjišťovány jednoduše jako rovnoměrný podíl z měsíčních, protože rozdíl oproti interpolaci mezi jednotlivými měsíci se zachováním měsíčních průměrů se ukázal jako nevýznamný (Horáček et al., 2009).

## Výpočet evapotranspirace dle Oudina

Hodnotu potenčníální evapotranspirace je možné odhadnout metodou odvozenou Oudinem (Oudin et al., 2010). Vzorec 3.3 byl vybrán z 25 vzorců, které byly testovány ve čtyřech hydrologických modelech na 300 povodí. Vzorec je založený na teplotě  $T$  a mimozemským (terestriálním) slunečním záření  $R_e$ . Vzorec se používá pro výpočet potenčníální evapotranspirace v modelu Bilan za letních a zimních podmínek (Kašpárek et al., 2015):

$$PET(i) = \frac{0.408R_e(T(i) + 5)}{100}. \quad (3.3)$$

## Výpočet výparu z vodních nádrží

Výpar z vodních nádrží je uveden v manipulačních řádech (MŘ). Hodnota výparu je většinou stanovena dle ČSN 75 2405 Vodohospodářská řešení vodních nádrží. V posledních letech se však ukazuje, že tyto hodnoty mohou být v rámci MŘ silně podhodnocené a rozdíly na jednotlivých vodních nádrží mohou dosahovat milióny  $m^3$ .

## Popis kritériálních funkcí modelu Bilan

Informace o kritériálních funkcích jsou uvedeny v manuálu modelu Bilan Kašpárek et al. (2015). Dostupné kritériální funkce jsou následující.

Střední kvadratická chyba (MSE) je průměr čtverců odchylek mezi pozorovanou a simulovanou řadou odtoku:

$$MSE = \frac{1}{n} \sum_{i=1}^n (RM(i) - R(i))^2. \quad (3.4)$$

Střední absolutní chyba (MAE) je vypočtena jako průměr absolutních odchylek mezi pozorovanou a simulovanou řadou odtoku. „Absolutní“ znamená, že záporné hodnoty jsou převedeny na kladné:

$$MAE = \frac{1}{n} \sum_{i=1}^n |RM(i) - R(i)|. \quad (3.5)$$

Střední absolutní procentuální chyba (MAPE) představuje průměr relativních odchylek. „Relativní“ znamená, že každá odchylka je vydělena pozorovanou hodnotou:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|RM(i) - R(i)|}{R(i)}. \quad (3.6)$$

Z této definice vyplývá, že MAPE nelze použít, pokud se vyskytnou nulové hodnoty odtoku.

Použít lze také Nashův-Sutcliffův koeficient (NS) nebo logaritmický Nashův-Sutcliffův koeficient (LNNS):

$$NS = 1 - \frac{\sum_{i=1}^n (RM(i) - R(i))^2}{\sum_{i=1}^n (R(i) - \bar{R})^2}, \quad (3.7)$$

$$LNNS = 1 - \frac{\sum_{i=1}^n (\ln RM(i) - \ln R(i))^2}{\sum_{i=1}^n (\ln R(i) - \overline{\ln R})^2}, \quad (3.8)$$

kde  $\bar{R}$  je průměrný pozorovaný odtok a  $\overline{\ln R}$  je průměr logaritmované řady odtoku:

$$\overline{\ln R} = \frac{1}{n} \sum_{i=1}^n \ln R(i). \quad (3.9)$$

## Využití modelu Bilan

Model Bilan je široce využíván v ČR i ve světě. Příkladem může být např. využití pro návrh metodického postupu který dále umožňuje rámcově kvantifikovat vliv přírodně blízkých retenčních opatření na hydrologický systém povodí. Navržený postup umožňuje stanovit hodnoty parametrů modelu Bilan pro povodí, jehož hydrologický systém je ovlivněn plošnými a liniovými přírodně blízkými retenčními opatřeními (Máca et al., 2016), modelování dopadů změny klimatu (Hanel et al., 2019), pro vyhodnocení hydrologické bilance na 133 povodí třetího řády (Vizina et al., 2017) nebo v rámci systému HAMR (Hydrologie, Agronomie, Meteorologie, Retence) pro více než 1100 útvarů povrchových vod, výsledky hodnocení systému jsou dostupné na webovém portálu ([hamr.chmi.cz](http://hamr.chmi.cz)).

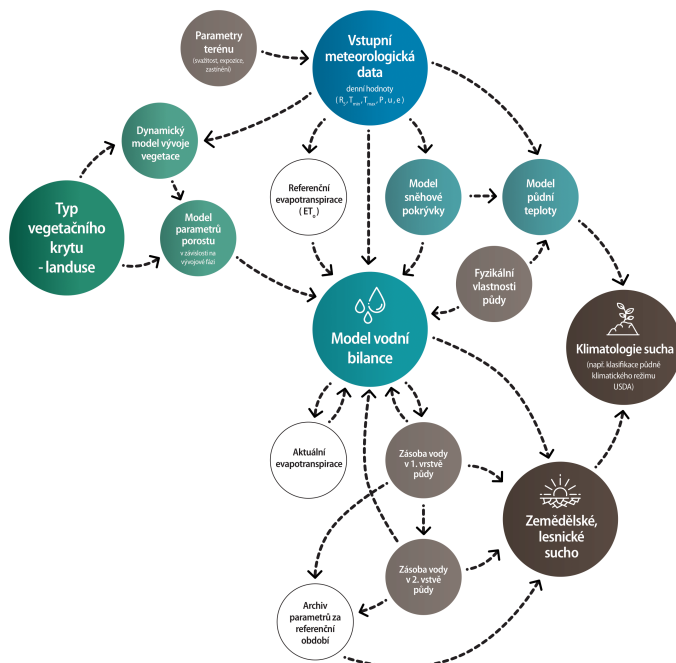
Model Bilan byl použit ve studii Strnad et al. (2017), kde na základě srážek, výparu, celkového a základního odtoku a hydrogeologických rajonů byla pomocí shlukové analýzy provedena regionalizace České republiky z hlediska chování v době sucha. Model Bilan se dá využít při řešení různých hydrologických problémů, např., při simulaci podzemního odtoku. Studie Machlica et al. (2012) popisuje, simulace podzemního odtoku na základě modelu Bilan, FRIER a HBV-light. Práce Vizina et al. (2014) popisuje porovnání modelů Bilan, TUWmodel a GR4J a následné propagace při využití generátorů počasí. Model Bilan byl také použit při hodnocení sucha na vybraných českých a slovenských povodích (Fendeková et al., 2015).

Model Bilan je možné také použít v on-line módu s obdobnou funkcionalitou, aplikace je dostupná na webové adrese [bilan.vuv.cz](http://bilan.vuv.cz).

## 3.4 Model SoilClim

Model SoilClim (Obr. 3.7) byl vyvinut na katedře agrosystémů a bioklimatologie Mendelovy univerzity v Brně. Tento model se používá ke studiu vodní bilance v systému půda–rostlina–atmosféra. SoilClim je složen z několika modulů. Výstupy základního modulu (např. výpočet referenční evapotranspirace) slouží jako vstup do dalších modulů (např. výpočet skutečné evapotranspirace, simulace vlhkosti půdy). Data jsou interpolována do jednotného mřížkového/gridového systému. Půdní profil v modelu SoilClim je rozdělen do dvou vrstev, hloubka povrchové vrstvy je 40 cm (ornice a podorňiční vrstva), další vrstva je 40–100 cm. Model zohledňuje povrchový odtok, retenci, výšku porostu a albedo během sezóny (Hlavinka et al., 2011; Vizina et al., 2018).

Program Intersucho ([intersucho.cz](http://intersucho.cz)) využívá model SoilClim (Hlavinka et al., 2011, 2015; Žalud et al., 2017), který popisuje intenzitu sucha v půdě, dopady na vegetaci, zemědělství a lesy v Česku, Slovensku a ve střední Evropě. Výhodou programu je prezentace výsledků v reálném čase a tím možnost využití v zemědělství, například vytvoření vhodných opatření od využití závlah po extenzifikaci produkce.



Obr. 3.7 Schéma modelu SoilClim.

## 3.5 Dálkový průzkum Země

Obecné definice dálkového průzkumu Země (DPZ):

- Pozorování cíle zařízením odděleným od něj určitou vzdáleností (Barrett a Curtis, 1999).
- Dálkový průzkum je věda o odvozování informací o objektu z měření prováděných ve vzdálenosti od objektu, tj. bez skutečného kontaktu s ním. Nejčastěji měřenou veličinou v současném systému dálkového DPZ je energie vycházející z objektu zájmu (Landgrebe, 2005).
- Dálkový průzkum je způsob získávání informací o zemském povrchu i vodních plochách s využitím snímků pořízených z ptáčích perspektiv, využívá elektromagnetického záření v jednom nebo více intervalech spektra, toto záření je odraženo nebo emitováno ze Země (Campbell a Wynne, 2011).

Využití DPZ se dá uplatnit v oborech, např.: zemědělství, životního prostředí (klimatická změna, hydrologie, oceánografie, lesnictví), doprava, archeologie aj. V současné době existuje mnoho vesmírných agentur/programů, například:

- the China National Space Administration (CNSA),
- the European Space Agency (ESA),

- the Indian Space Research Organization (ISRO),
- the Japan Aerospace Exploration Agency (JAXA),
- the National Aeronautics and Space Administration (NASA),
- the Russian Federal Space Agency (RFSA),

kteřé poskytují data DPZ nebo korigovaná DPZ data.

Data pro Evropu poskytuje např. Evropská kosmická agentura ESA (the European Satellite Agency), která zajišťuje programy, např.: Copernicus Programme, Galileo a jiné [Jean-Yves et al. \(2019\)](#). Program Copernicus poskytuje služby založené na družicovém pozorování Země, na datech in situ, ale i simulace klimatických modelů, reanalýzy klimatu či simulace large-scale hydrologických modelů. Copernicus zaručuje přímý a otevřený přístup k datům, zejména dat z rodiny družic Sentinel. Program zajišťuje základní služby (core services) a navazující služby (downstream services). Data zahrnují tematické oblasti: monitorování území, atmosféra, krizové řízení, bezpečnost, mořské prostředí a změny klimatu. Data jsou dostupná na serveru [copernicus.eu](#), kde je možné vybrat: konkrétní druh dat, časové a prostorové rozlišení, výběr lokality [Copernicus \(2021\)](#); [Juckes \(2018\)](#).

Další organizace, která se podílí monitoringu Země, atmosféry a povrchu oceánu a následnou distribucí produktů je EUMETSAT (European Organisation for the Exploitation of Meteorological Satellites). Provozuje skupinu satelitů na geostacionární oběžné dráze, která je 36 000 km nad rovníkem. Družice METEOSAT -9, -10, -11 jsou nad Evropou a Afrikou, METEOSAT-8 nad Indickým oceánem. Satelity METEOP létají v nižší polární výšce 817 km a poskytují podrobnější informace o atmosféře, oceánech a kontinentech. Družice z rodiny Jason a Sentinel-6 slouží k monitoringu hladin moří. Tyto informace jsou slouží k pochopení předpovídání počasí a monitorování změn klimatu, Sentinel-3 pomáhá určit parametry mořského prostředí, jako jsou fotografie, teplota nebo barva mořského povrchu [Alain et al. \(2018\)](#). EUMETSAT zastupuje osm programů/produktů, v SAF (The Satellite Application Facilities), které poskytují uživatelům provozní data a softwarové produkty. Programy/produkty zahrnují:

1. pozorování oceánu a ledu (OSI SAF),
2. podporu operativní hydrologie a vodního hospodářství (H SAF)
3. monitorování atmosféry (AC SAF)
4. numerickou předpověď počasí (NWP SAF),
5. podporu nowcastingových a krátkodobých prognóz (NWC SAF)
6. analýzy zemského povrchu (LSA SAF).


EUMETSAT je poskytovatelem dat pro organizaci European Centre for Medium-Range Weather Forecasts (ECMWF), která vytváří střednědobé a sezónní numerické předpovědi počasí/klimatu.

### Principy dálkového průzkumu

Výhodami DPZ ([Hofierka, 2003](#)) je, že umožňují sběr velkého množství dat platných pro daný časový moment, případně v pravidelně opakujících se časových periodách (zejména satelitní systémy). Principem ([Hofierka, 2003](#); [Elachi a Van Zyl, 2006](#); [Campbell a Wynne, 2011](#)) je záznam údajů o objektech krajinné sféry bez přímého kontaktu s nimi za pomoci elektromagnetické záření (EMG), které je po odrazu od zkoumaného objektu modifikované.


Existují dva přístupy pozorování, a to pomocí aktivních a pasivních systému 3.8. Aktivní systémy emitují vlastní mikrovlnné záření, které prochází oblaky a zaznamenávají jeho odraz (radar, LiDAR-LADAR). Pasivní systémy zaznamenávají sluneční záření odražené od objektů ve viditelné a infračervené části spektra. Slunce emituje plné spektrum EMG záření na povrch Země dopadá jen

část tohoto spektra. Část tohoto záření je rozptýlená, pohlcena a odražená atmosférou Země. Po dopadu na zemský povrch je část záření pohlcena povrchem a část odražená zpět do atmosféry. Pouze ta část EMG záření, která byla odražená a pronikla zpět do atmosféry, případně až mimo ni je zaznamenávána pasivními systémy.



**Obr. 3.8** Zdroje elektromagnetického záření rozdělené podle aktivní a pasivní metody (Bernhardt a Schulz, 2015).

Množství a vlnová délka odraženého záření závisí především na fyzikálních vlastnostech objektů zemského povrchu. Například voda absorbuje většinu radiace ve viditelné a infračervené části spektra. Naopak písčité půdy bez vegetace odrážejí velkou část záření od viditelné po infračervenou oblast. Odraz záření od vegetace závisí zejména na obsahu chlorofylu. Změny ve zdravotním stavu vegetace jsou obzvláště viditelné v blízké infračervené oblasti spektra. Některé satelity snímají i dlouhovlnné infračervené (tepelné) vyzařování povrchu Země viz Obr. 3.9.




**Obr. 3.9** Křivky spektrální odrazivosti pro vybrané materiály (Bernhardt a Schulz, 2015).

Satelitní snímače jsou obvykle multispektrální systémy, snímají najednou několik částí spektra (spektrální kanály), některé systémy obsahují i panchromatický kanál, který pokrývá velký rozsah



vlnové délky (viditelnou a blízkou infračervenou část spektra), obvykle s vyšším prostorovým rozlišením. Satelity mají různé orbity (dráhy). Geostacionární satelity jsou vzdáleny od zemského povrchu (obvykle 36 000 km), což jim umožňuje udržovat relativně "statickou" polohu nad určitou částí zemského povrchu. Polární orbitální dráha umožňuje postupným obětem Země ve formě pásů pokrýt celý zemský povrch v pravidelných časových periodách procházet a snímat stejné území (Obr. 3.10).



Obr. 3.10 Rozdíl mezi polární orbitou a geostacionární orbitou (Bernhardt a Schulz, 2015).

Pro využití dat z DPZ je důležité rozlišení, rozděluje se na:

- prostorové (velikost pixelů, určuje využitelnost pro různé mapové měřítka),
- spektrální (jde o spektrální rozsah EMG záření, které příslušný kanál zaznamenává, vlastnosti vegetace se dají dobře pozorovat v úzkém pásmu mezi červenou a blízkou infračervenou částí spektra),
- radiometrické a časové rozlišení (určeno časovou frekvencí snímání daného území konkrétním nosičem-satelitem, pohybuje se od desítek minut v případě meteorologických družic až po několik desítek dnů).

### Přístup k datům

Pro samotnou hydrologii a vodní hospodářství je k dispozici velké množství datových produktů:

1. pozorovaná data ze Světové meteorologické organizace (WMO – World Meteorological Organisation), která zahrnuje 9500 stanic ve 161 zemích,
2. gridované reanalyzované klimatické produkty ERA-Interim, ERA5-Land a další,
3. data ze satelitních senzorů.

Schopnost pracovat s rozsáhlými datovými soubory umožňuje přechod od hloubkových experimentů v jednotlivých povodí k rozsáhlým studiím (Slater et al., 2019; Blöschl et al., 2017; Harrigan et al.,

2018), vývoji nových koncepčních nebo fyzických modelů, které jsou použitelné v různých podmínkách a částech povodí a lepšímu porozumění jednotlivých hydrologických procesů (Slater et al., 2019; Gupta et al., 2014).

Rychlý přístup k datům umožnilo rozhraní API (Application Programming Interface), což umožňuje automatické stahování pomocí identifikátorů. Tento přístup je možné uplatnit v programech (Pythonu, R a Javy), nebo je možné stahování dat ve formátu NetCDF (Network Common Data Form). Data NetCDF obsahují dimenze, atributy a proměnné. Programový přístup k datům je umožněn, např. pro Climate Data Store, Copernicus Global Land Service. Ukázka stažených dat 3.11 ve formátu NetCDF ze satelitu Sentinel 3 pro teplotu povrchu (Land surface temperature - LST) v denním cyklu, které byly použité v projektu (Beran et al., 2019a) a disertační práci. Formát stažených NetCDF dat je ukázán níže.

- g2\_BIOPAR\_LST10\_YYYYMMDD\_GLOBE\_GEO\_V\_Major.Minor.nc, kde,
  - g2 a BIOPAR, identifikátory produktu,
  - LST10, název produktu,
  - YYYYMMDD, označení pro rok, měsíc a den,
  - GLOBE, geografický rozsah souboru,
  - GEO, produkt je založen na geostacionárních družicových datech,
  - V a Major.Minor, udávají číslo verze produktu.

### Příklad distančních dat - LST - Land Surface Temperature ze satelitu Sentinel-3

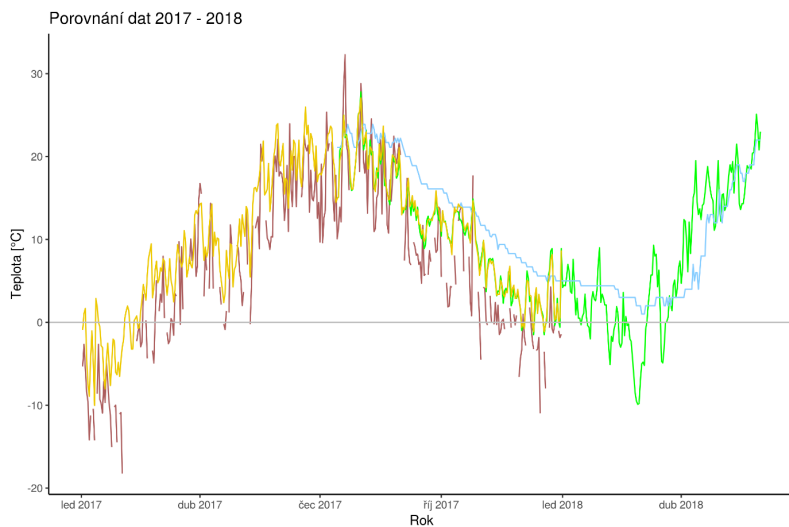
Produkt LST hodinový: může se použít na podrobné analýzy, produkt je monitorován za jasného nebe. Při zatmění (oblačnost) může mít špatné rozlišení.

Produkt LST-10-DC, jsou agregované hodnoty ve 3 dekadách po 10 dnech, obsahuje hodnoty teplot (maximum, medián, minimum). Produkt je vhodný tam, kde není zapotřebí celý denní cyklus a obsahuje medián namísto průměru, který je více citlivý na odlehle hodnoty, které se často odstraňují.

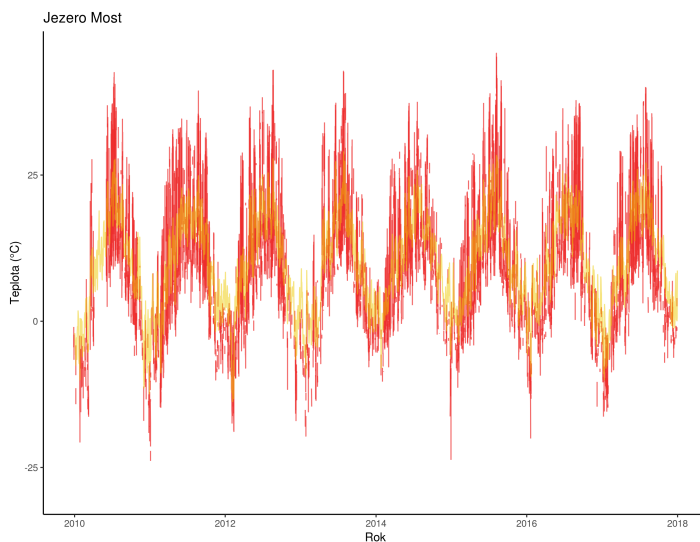
Produkt LST-10 Synthesis & TCI (thermal condition index), jsou agregované hodnoty do 3 dekad po 10 dnech, využívá se k monitorování vegetace. Bylo ověřeno, že dobrý stav vegetace může být odvozen od vlhkosti půdy a od teplotních podmínek (Kogan, 2001). Po statistickém vyhodnocení poskytují teploty: maximum, minimum, medián a hodnotu TC index.

Grafická ukázka distančních dat pro období 2017–2018 a pro 2010–2018 jsou ukázány na Obr. 3.11 a na Obr. 3.12. Produkt LST-10-DC byl porovnán s pozorovanými daty na vodní nádrži jezero Most, kde jsou k dispozici data z meteorologické stanice a plovoucího výparoměru. Obrázek 3.11 ukazuje porovnání hodnot mezi roky 2017–2018. Hodnoty z produkty LST (fialová čára) nejsou totožné s pozemním pozorováním (zelená čára). Hodnoty LST mají viditelná přerušení, která mohou být způsobena špatnou viditelností, oblačností nebo vynecháním části měření, data jsou výrazně podhodnocena oproti pozorování. Odvozené hodnoty teplot (žlutá barva) jsou prakticky shodné s pozorováním na meteorologické stanici (zelená čára), která je umístěna přímo na břehu jezera Most. Teplota vody (modrá linie) vykazuje mnohem větší setrvačnost než pozorovaná a odhadovaná data (Beran et al., 2019a).

Tím, že hodnoty odvozených klimatických (přepočtená klimatická data z gridu (Štěpánek et al., 2011)) a pozorovaných dat (meteorologická stanice jezero Most) vykazovaly mezi sebou shodu, byla ještě porovnaná odhadovaná klimatická data s produktem LST pro roky 2010–2018. Červená čára znázorňuje produkt LST, kde jsou výrazněji vidět chybějící data viz Obr. 3.12.



**Obr. 3.11** Porovnání dat za rok 2017–2018 pro jezero Most, žlutá čára – odvozená data, fialová čára – produkty LST, zelená – teplota vzduchu, modrá čára – teplota vody.



**Obr. 3.12** Porovnání dat za rok 2010–2018 pro jezero Most, žlutá čára – odvozená data, červená čára – produkty LST.

Ve studii [Beran et al. \(2020\)](#) byl porovnán výpar mezi odvozenými vzorci, do kterých byly vstupem reanalyzovaná data pro teplotu ve 2 m nad zemí (ERA-Iterim a odvozená klimatická data teplot) a reanalyzovanými daty ERA5-Land – evapotranspirace).

## Reanalýza klimatu

Účelem reanalýzy klimatu je poskytnout odhad veličin popisujících atmosférické, klimatické a hydrologické procesy a chování oceánů s globálním pokrytím v relativně vysokém časovém a prostorovém rozlišení.

Reanalýzy jsou výstupem různých modelů, které většinou zahrnují i hydrologický, atmosférický a oceánský model a model zemského povrchu. Výhodou je poskytování vícerozměrných prostorově kompletních a koherentních informací o globální cirkulaci a hydroklimatických veličinách. Reanalýzy klimatu vznikají podobně jako numerická predikce počasí, kde pro predikci budoucího stavu atmosféry se používají predikční modely založené na vývoji klimatického systému od počátečního stavu. Počáteční stav klimatu je klíčovým vstupem do prognózy určující budoucí vývoj simulace modelu. Asimilace dat se používá k odhadu počátečního stavu, který nejlépe odpovídá dostupným datům, přičemž se berou do úvahy chyby modelů. Reanalýza klimatu se provádí jako jediná verze asimilace dat, která zahrnuje použití předpovědního modelu ([Dee et al., 2011](#)).


Projekt ERA-Iterim má integrovaný předpovědní systém, proto poskytuje datové soubory, které obsahují atmosférické a povrchové parametry, slouží pro dlouhodobou analýzu klimatu s časovou řadou od ledna 1979. Zkratka ERA (ECMWF Re-Analysis) odkazuje na projekty ECMWF s použitím reanalyzovaných dat ([Dee et al., 2011](#)). Data jsou volně stažitelná z archívu ECMWF WebAPI ve formátu GRIB nebo NetCDF. Pro výpočet výparu z vodní hladiny ([Beran et al., 2020](#)) byla použita teplota vzduchu ve 2 (m) nad povrchem (formát NetCDF). Data jsou transformovaná do zeměpisné mřížky (délka, šířka – lat, lon) v rozlišení  $0.75^\circ \times 0.75^\circ$ , což je přibližně grid 83 km x 83 km. Data byla použita v agregované formě pro jednotlivé měsíce. Poskytnuté teploty vzduchu jsou v Kelvinech (K).

Projekt ERA5-Land poskytuje reanalyzovaný datový soubor obdobně jako projekt ERA-Iterim. Reanalýza využívá kombinace modelovaných dat a pozorovaných dat s důrazem na fyzikální zákonitosti. Data jsou uložena v archívu ECMWF a zkopírovaná do archívu COPERNICUS Climate Data Store, odkud jsou volně stažitelná s použitím CDS katalogu nebo aplikace CDS API ve formátu GRIB nebo NetCDF. Produkt ERA5-Land se může využívat při předpovědi sucha nebo povodní ([Sabater, 2019](#)). Produkt ERA5-Land mimo jiné, popisuje množství vypařené vody ze zásob povrchových vod, zahrnující jezera, vodní plochy a inundační oblasti. Data byla stažena ve formátu NetCDF. Prostorové rozlišení je  $0.1^\circ \times 0.1^\circ$ , což je přibližně grid 9 km x 9 km. Hodnoty jsou v metrech (m) a následně propočteny na milimetry (mm).

Projekty ERA5-Land, ERA5 a ERA-Iterim jsou podporované organizací ECMWF a ERA5-Land a ERA-5 jsou implementované do archívu COPERNICUS Climate Data Store, Obr. 3.13 ukazuje teplotu půdy z 15. března 2010 podle třech různých reanalýz: (i) ERA5-Land, (ii) ERA5 a (iii) ERA-Iterim. ERA-5-Land vpravo má největší rozlišení a umožňuje detailnější pohled a přesnější rozvržení teploty ([Muñoz Sabater, 2019](#)).

## 3.6 Časové řady

Časová řada je posloupnost hodnot zvoleného statistického znaku (ukazatele) uspořádaných z hlediska času ve směru od minulosti po současnost. Ukazatel musí být *věcně* a *prostorově* shodně definován po celé sledované období.



Obr. 3.13 Rozdíl mezi reanalýzami, vlevo ERA-Interim, střed ERA5 a vpravo ERA5-Land Lopez (2020).

Zpravidla prvním úkolem při analýze časových řad je získání rychlé a orientační představy o charakteru procesu, který tato řada reprezentuje. Mezi základní metody proto zcela běžně patří vizuální analýza chování ukazatele využívající grafů spolu s určováním elementárních statistických charakteristik. Na základě grafického záznamu průběhu časových řad lze rozpoznat např. dlouhodobé trendy v průběhu řady či periodicky se opakující vývojové změny apod. Vizuální analýza však není dostatečná k poznání hlubších souvislostí a mechanismů studovaného procesu a neposkytuje informace, které lze mezi sebou porovnávat. Časové řady dělíme na (Hanel a Vizina, 2014):

1. *Časové řady okamžikové* – hodnota ukazatele se plynule mění v čase, časová řada udává stav ukazatele v určitých okamžicích. Hodnoty stavu nemusí přímo záviset na délkách intervalu mezi odečty (při delším intervalu však může pochopitelně dojít k větší změně). Sčítání hodnot ukazatele této řady nemá logiku.
2. *Časové řady intervalové* – hodnoty ukazatele sledují vznik nebo zánik (udávají přírůstek, úbytek) za časový interval, hodnoty tedy závisejí na délkách intervalů. Hodnotu ukazatele za delší interval lze získat sčítáním hodnot za dílčí části tohoto intervalu. Sčítání hodnot má logiku. Pro vzájemné srovnávání hodnot ukazatele intervalové řady jsou nezbytné konstantní délky intervalů (např. rok, čtvrtletí, měsíc a týden).

Pro intervalové časové řady lze vytvořit tzv. odvozené časové řady a existují dva základní typy odvozených řad, a to:

- součtová (kumulativní) řada,
- klouzavá řada.

### Aproximace trendu matematickými funkcemi

Volba vhodné matematické funkce pro danou časovou řadu se vybírá na základě předběžné analýzy řady, velmi často pomocí grafického záznamu řady nebo teoretických znalostí o průběhu trendové složky (Hanel a Vizina, 2014). Na základě směru složky, trend dělíme na:

1. rostoucí,
2. klesající,
3. střídavý – období růstu se střídají s obdobími poklesu,
4. časové řady, které trend postrádají.

Podle tvaru trendové složky se dále dělí na:

1. lineární – přímočarý,
2. nelineární – křivočarý.

Systematická typologie funkcí vhodných pro popis trendové složky je uvedena např. v monografii Kozák et al. (1994). Přehled funkcí:

1. *Konstantní funkce* – předpokládá, že trendová složka je konstantní funkce:

$$T_t = \beta_0, \quad t = 1, 2, \dots, n. \quad (3.10)$$

Poté dostaneme bodový odhad  $b_0$  parametru  $\beta_0$  pomocí metody nejmenších čtverců (viz. 3.6).

2. *Lineární funkce* – platí pro lineární trend:

$$T_t = \beta_0 + \beta_1 t, \quad t = 1, 2, \dots, n. \quad (3.11)$$

Bodové odhady  $b_0$ ,  $b_1$  parametrů  $\beta_0$  a  $\beta_1$  se také řeší pomocí metody nejmenších čtverců, kdy dostaneme soustavu dvou normálních rovnic.

3. *Kvadratická funkce* – v případě kvadratické funkce lze trend zapsat takto:

$$T_t = \beta_0 + \beta_1 t + \beta_2 t^2, \quad t = 1, 2, \dots, n. \quad (3.12)$$

Pro bodové odhady  $b_0$ ,  $b_1$  a  $b_2$  parametrů  $\beta_0$ ,  $\beta_1$  a  $\beta_2$  dostaneme soustavu tří normálních rovnic.

4. *Splínové funkce* – v případě, kdy bylo potřeba popsat trend nějaké časové řady polynomem neúměrně vysokého stupně, rozdělí se časová řada na několik úseků a v každém z nich je provedena aproximace dvou polynomem nízkého stupně (např. prvního nebo druhého). Výsledná funkce je pak dána spojením funkcí z jednotlivých úseků.
5. *a další, jako např. Exponenciální, Logistická, Gompertzova funkce, modifikovaná exponenciální funkce,...*

## Sezónní složka

Při analýze časové řady je třeba rozhodnout, zda-li má řada multiplikační nebo aditivní sezónní složkou. Časová řada vykazuje multiplikační sezónní složku, jestliže je amplituda sezónních fluktuací přímo úměrná úrovni trendu. Je-li však amplituda sezónních výkyvů prakticky nezávislá na úrovni trendu, je vhodné pracovat s aditivní sezónní složkou (Křivý, 2006).

Hodnoty sezónní složky  $S$  se nazývají *sezónní faktory*. Jejich počet je dán počtem období (sezón)  $L$  v roce ( $L = 4$  pro kvartální pozorování,  $L = 12$  pro měsíční pozorování), označují se

$$S_{1+L_j}, S_{2+L_j}, \dots, S_{L+L_j}, \quad (3.13)$$

kde  $j = 0, 1, \dots$  odpovídá postupně prvnímu, druhému, ... roku sledování časové řady. Hodnoty těchto faktorů se pro jednotlivé roky nemění. Pro jednoznačnost dekompozičního rozkladu se zpravidla požaduje, aby se vliv sezónních faktorů v rámci každého roku celkově vykompenzoval, proto se tyto faktory normalizují (normalizace sezónních faktorů). Multiplikační sezónní faktory jsou bezrozměrná čísla. Pro jejich normalizaci se používají podmínky (Křivý, 2006):

$$\sum_{i=1}^L S_{Lj} = L \quad \text{pro} \quad \text{všchna} \quad j = 0, 1, \dots \quad (3.14)$$

Aditivní sezónní faktory se udávají ve stejných jednotkách jako hodnoty časové řady. Normalizační podmínka má tvar:

$$\sum_{i=1}^L S_{Lj} = 0. \quad (3.15)$$

## Periodicita časové řady

Periodické kolísání představuje pravidelně se opakující výkyvy hodnot zkoumaného znaku střídavě oběma směry od hlavního vývojového směru. Je charakteristické délkou periody, velikostí výkyvu (amplitudou) a fázovým posunem (určuje polohu maxim a minim vzhledem k souřadnicím časové osy). Podle přítomnosti či nepřítomnosti periodické složky dělíme časové řady na (Hanel a Vizina, 2014):

1. periodické,
2. neperiodické.

Podle frekvence (déłky periody) periodické složky se časové řady rozlišují na:

1. krátkodobé,
2. střednědobé neboli sezónní s periodou odpovídající přesně jednomu roku,
3. dlouhodobé neboli cyklické s periodou delší než 1 rok.

Protože trendovou a sezónní složku lze většinou matematicky snadno popsat, shrnují se obvykle obě tyto složky pod společný pojem *systematická složka* časové řady.

Měření systematické složky se nazývá vyrovnávání (vyhlazování) časových řad. Nepravidelné kolísání je reprezentované náhodnou složkou časové řady, která je výslednicí různých nesledovaných nebo nepostřehnutelných vlivů.

Typy časových řad:

1. Stacionární řada - řada postrádající trendovou složku.
2. Nestacionární řada - řada s trendovou složkou.
3. Periodická řada - řada obsahující periodickou složku.
4. Neperiodická řada - řada neobsahující periodickou složku.

## Regresní analýza

Smyslem regresní analýzy je zejména nalézt formu systematického funkčního vztahu mezi odezvou a jedním nebo více prediktory. Pokud se toto podaří, slouží získaný model k následujícím účelům:

1. funkční popis závislosti,
2. predikci,
3. nastavení standardů (kontrola procesů).

## Regrese s jedním prediktorem

V přírodních vědách, matematice a fyzice lze často vztah mezi dvěma veličinami  $Y$  a  $z$  popsat, pomocí funkčního vztahu jedinou reálnou funkcí (Anděl, 2002):

$$Y = f(z). \quad (3.16)$$

## Forma modelu

Nejjednodušší formou regresního modelu je *lineární regresní model*. Obdobně jako u aproximace trendu (systematické složky) matematickými funkcemi (viz kapitola 3.6) lze provádět regresní analýzu.

Regresní funkce:

- Prokládá (vyrovnává) hodnoty přímkou
- Zkoumá účinek nezávisle proměnné  $x$  na závisle proměnnou  $y$
- Regresní rovnice
  - Známe-li hodnoty  $x$ , pak můžeme odhadnout  $y$

$$y = a + bx(+e) \quad (3.17)$$

- $y$  ... předpokládaná hodnota  $y$ ,
- $x$  ... pozorovaná hodnota  $x$ ,
- $a$  ... průsečík (konstanta),
- $b$  ... sklon přímky,
- $a, b$  ... parametry regresní rovnice,
- $e$  ... náhodná chyba.

## Podmínky regresní analýzy:

1. Normalita závisle proměnné.
2. Normalita chyb.
3. Nezávislost pozorování.
  - Hodnota pozorování nezávisí na okolních případech.
  - Problematické – časové řady, prostorová data.
4. Homoskedasticita - ve statistice znamená, že rozptyl je nezávislý na parametru (je homogenní).  
V lineárních modelech se provádí test předpokladu homoskedasticity.
  - Rozptyl náhodné složky je konstantní.
  - Graf reziduí.
5. Nekorelovanost proměnných.
  - Multikolinearita.
6. + další (v praxi se na ně nebere ohled).

Kouzlo vícenásobné lineární regrese je definování vlivu dílčích prediktorů na výsledek, někdy to však není možné. Tento problém nastane, pokud jsou dvě proměnné silně korelovány, pak nelze určit nezávislost proměnné na výsledek - multikolinearita.

## Metoda nejmenších čtverců

Ve všech případech, kdy z hodnot měřené závislosti dvou fyzikálních veličin zatížených chybami určujeme její nejpravděpodobnější průběh, mluvíme o vyrovnání funkční závislosti. Toto vyrovnání lze provádět graficky i numericky. Nejznámější numerická vyrovnávací metoda je metoda nejmenších čtverců. Metoda nejmenších čtverců slouží k nalezení takového vyrovnání měření, aby součet druhých mocnin chyb nalezeného řešení byl minimální. Zjednodušeně, aby součet čtverců odchylek byl nejmenší (Schauer, 2007).

Pro proložení měřených hodnot přímkou s rovnicí:

$$y = f(u) = k_1 u + k_0, \quad (3.18)$$



lze vypočítat koeficienty  $k_0$  a  $k_1$  dle následujících vzorců:

$$k_1 = \frac{n \sum u_i y_i - \sum u_i \sum y_i}{n \sum u_i^2 - (\sum u_i)^2}, \quad (3.19)$$

$$k_0 = \frac{\sum u_i^2 \sum y_i - \sum u_i \sum u_i y_i}{n \sum u_i^2 - (\sum u_i)^2}. \quad (3.20)$$

Předpoklady metody nejmenších čtverců:

1. Regresní parametry mohou teoreticky nabývat jakýchkoli hodnot.
2. Regresní model je lineární v parametrech.
3. Jednotlivé nezávislé proměnné jsou skutečně vzájemně nezávislé, tedy mezi nimi nedochází k tzv. multikolinearitě.
4. Podmíněný rozptyl  $D(y/x) = 2$  je konstantní (tzv. podmínka homoskedasticity).
5. Náhodné chyby mají nulovou střední hodnotu  $= 0$ , mají konečný rozptyl a jsou nekorelované.

### 3.7 Random forest

Metoda náhodného/regresního lesa Random Forest (RF) je metoda vyvinuta [Breiman \(2001\)](#). Náhodný les je kombinovaná učící metoda pro klasifikaci a regresi, která vytvoří více rozhodovacích stromů při učení a následně vydá modus (nejčastější hodnotu) tříd vrácených jednotlivými stromy, které tvoří regresní les. Výsledná regresní funkce je definována jako vážený průměr regresních funkcí několika stromů. Regresní lesy patří do tzv. komisičních nebo souborových metod (committee, ensemble methods), jejichž hlavní myšlenkou je kombinace více samostatných modelů do jednoho celku. Využívá tedy tzv. kolektivní rozhodování ([Masaila, 2013](#)).

Náhodný les se skládá ze souboru stromů  $T_1, \dots, T_N$ , jejichž klasifikační nebo regresní funkce lze vyjádřit následovně:

$$h(X, O1), \dots, h(X, ON), \quad (3.21)$$

kde  $h$  je funkce,  $X$  je prediktor a  $O1, \dots, ON$  jsou nezávislé stejně rozdělené náhodné vektory. Pro metodu Random Forests se používají binární stromy typu CART ([Klaschka a Kotrč, 2004](#)). Podobně jako při tvorbě jednotlivých stromů či jiných kalibrací se i zde používá rozdělení na testovací a trénovací soubor. V rámci práce byl použit R-balíku randomForest ([Ishwaran a Kogalur, 2021](#)).

Random Forest představuje přístup k vytváření prediktivních modelů pro klasifikační i regresní úlohy. Je to způsob, jak kombinovat méně výkoné základní modely a získat lepší prediktivní modely. Kvůli jejich jednoduché povaze, nízkým předpokladům a vysokému výkonu byly RF modely široce používány ve strojovém učení. Termín „les“ označuje řadu rozhodovacích stromů, které jsou samy o sobě „slabými“ klasifikátory. Regresní les nemá stejnou prediktivní sílu jako samostatný regresní strom. V případě, že se jeden strom rozděluje do jediného kritéria, je velmi citlivý na změny. Modely RF klasifikují proměnné na základě jejich důležitosti pro dosažení nejlepšího RF modelu ([Nhu et al., 2020](#)).

### 3.8 M-denní průtoky a čára překročení

M-denní průtoky patří dle normy ČSN 75 1400 (Kulasová et al., 1997) mezi základní hydrologické údaje a pro libovolný profil říční sítě jsou poskytovány Českým hydrometeorologickým ústavem (ČHMÚ). Hodnoty M-denních průtoků jsou např. dle zákona 254/2001 Sb. a související Vyhlášky MZe 432/2001 Sb. nutné jako doklad pro vydání povolení k nakládání s povrchovými nebo podzemními vodami.

M-denní průtoky ve vodoměrných stanicích  $Q_{M_d}$  se určují z funkce překročení průměrných denních průtoků a udávají se v  $\text{m}^3 \cdot \text{s}^{-1}$  (příp. v  $\text{ls}^{-1}$ ) pro vybrané hodnoty průměrné doby dosažení nebo překročení  $M = 30, 60, 90, 120, 150, 180, 210, 240, 270, 300, 330, 355$  a  $364$  dnů v roce.

Základem pro odvození M-denních průtoků je zpracování průměrných denních průtoků ze sítě vodoměrných stanic a následná aplikace výpočetních nástrojů, které umožňují extrapolaci hodnot M-denních průtoků z vodoměrných stanic do nepozorovaných profilů.

Do konce roku 2012 byly poskytovány hodnoty M-denních průtoků odvozené za referenční období 1931–1980. Od roku 2013 ČHMÚ poskytuje M-denní průtoky za nové referenční období 1981–2010.

Pro odvození M-denních průtoků na nepozorovaných povodích ČHMÚ využívá logaritmicko-normálního rozdělení s pěti parametry (LN5), parametry udávají tvar čáry překročení, která popisuje hydrologický režim vodních toků. Na základě regionalizace těchto parametrů je Česká republika rozdělena do 16 hydrologických oblastí.

Kvantily průtoků (M-denní vody) odvozených z čar překročení jsou v rámci práce využity jako dodatečná informace pro kalibraci modelu Bilan.

### 3.9 Kriteriaální funkce

Při hodnocení modelu se používají různé kriteriaální chyby (criterial error) nebo chybový index (error index) (Legates a McCabe Jr, 1999; Wagener et al., 2001; Moriasi et al., 2007; Gupta et al., 2009). Do této skupiny se zařazují např: střední absolutní chyba (MAE), střední kvadratická chyba (MSE), střední kvadratická chyba RMSE, Kling-Gupta účinnost (KGE), koeficient determinace (R2), relativní chyba (RERR). Chyby MAE, MSE a RMSE patří do skupiny, kde hodnota nula znamená dokonalé přizpůsobení k porovnávanému modelu. Chyby KGE, R2 a RERR dosahují nejlepší shodu když hodnota se blíží k jedné.

- Střední absolutní chyba (MAE)

Ve statistice je střední absolutní chyba (MAE) veličina používaná k měření toho, jak blízko jsou předpovědi nebo prognózy konečným výsledkům. Chyba je méně citlivá na občasné velmi velké chyby, protože neumožňuje chyby ve výpočtu. MAE je dána vztahem:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (3.22)$$

- Střední kvadratická chyba (MSE)

Střední kvadratická chyba může být vztažena ke kvadratickému momentu chyby měření od počátku. Zahrnuje jak rozptyl, tak odchylku v odhadu odborníka. Pokud je odhad odborníka nestranný, pak je střední kvadratická chyba stejná jako rozptyl. Jednotka MSE je stejná jako jednotka měření pro odhadované veličinu. MSE je dána vztahem:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (3.23)$$

kde jsou pozorované hodnoty a  $y$  jsou modelované hodnoty.

- Střední kvadratická chyba (RMSE)

$$RMSE = \sqrt{\left(\frac{1}{n}\right) \sum_{i=1}^n (y_i - x_i)^2}, \quad (3.24)$$

kde  $y_i$  je expertní simulace pro  $i$ -tý případ,  $x_i$  průměr expertní simulace a  $N$  je celkový počet simulovaných hodnot. Byla použita jako standardní statistická metrika, která dává relativně velkou váhu velkým chybám.

- Kling-Gupta parameter (KGE)

KGE je počítané podle

$$KGE = 1 - \sqrt{(s[1] * (r - 1))^2 + (s[2] * (\alpha - 1))^2 + (s[3] * (\beta - 1))^2}, \quad (3.25)$$

kde  $s$  je číselný váhový vektor délky 3 (zde se všemi prvky rovnými 1), který kombinuje Pearsonův korelační koeficient ( $r$ ), poměr mezi směrodatnými odchylkami ( $alpha$ ) a poměr mezi průměrem expertní simulace a simulací kalibrovanou s příslušnou OF ( $beta$ ).

- Koefficient determinace ( $R^2$ )

koefficient determinace označuje míru kvality regresního modelu a vysvětluje jaký je podíl variability závislé proměnné modelu  $R^2$ . Koefficient determinace může nabývat hodnoty maximálně 1, což znamená dokonalou predikci hodnot závisle proměnné. Naopak hodnota 0 znamená, že model nepřináší pro poznání závisle proměnné žádnou informaci a je neúčinný Yin a Fan (2001).

$$R^2 = 1 - \frac{S_e}{S_t}, \quad (3.26)$$

kde  $S_e$  je reziduální počet čtverců a  $S_t$  celkový součet čtverců.

- Relativní chyba (RERR)

Relativní chyba zlepšuje informační význam tím, že je porovnávána se skutečnou hodnotou, je bez-rozměrná veličina a může se uvádět v procentech, nabývá kladných i záporných hodnot. Pomocí relativní chyby se mohou porovnávat veličiny s různým rozměrem Novák (2001).

$$\delta = \frac{\Delta X}{X}, \quad (3.27)$$

kde  $\Delta X$  je absolutní hodnota  $X$ , poměr absolutní chyby a hodnoty této veličiny.



# Metodika

Kapitola 4 představuje metodické postupy dvou základních okruhů činností, potřebná vstupní data a nástroje, pomocí kterých byla práce zpracována:

1. Využití půdní vlhkosti v hydrologickém modelování (kapitola 4.1).
2. Odhad výparu z vodní hladiny pro Českou republiku (kapitola 4.2).

Navržené metodické postupy upřesňují výpočet hydrologické bilance v podmínkách České republiky (především odvození vzorců výparu z vodních ploch). Využití půdní vlhkosti a volba kalibračních strategií je využitelná globálně. Dílčí metodické postupy byly také publikovány, a to především v [Melišová et al. \(2017, 2020\)](#).

Volba kalibrační strategie je důležitá pro správné (fyzikálně věrohodné) stanovení parametrů modelu a následného relevantního vyhodnocení členů hydrologické bilance. Kapitola detailně popisuje rozdělení použitých kalibračních strategií v hydrologickém modelu Bilan a jejich vyhodnocení 4.1. Pro výpočet potenciální evapotranspirace v modelu Bilan byla použita metoda dle [Oudin et al. \(2010\)](#), která se zařazuje mezi jednoduché metody z hlediska vstupních veličin – hlavním vstupem je teplota vzduchu, den v roce a zeměpisná poloha. Hodnoty potenciální evapotranspirace je možné empiricky vypočítat nebo pracovat s hodnotami výparu, které se získávají z měření (srovnávací výparoměr, EWM výparoměry). V posledních době je také možnost využít produktů DPZ (např. satelitních dat) nebo reanalýzy klimatu (tj. simulací numerických modelů – například data ERA5-Land).

Kapitola 4.2 popisuje odvození vztahů pro výpočet výparu z vodní hladiny pro Českou republiku, pilotní lokality, využití reanalyzovaných dat klimatu a sestrojení lineárních modelů (LM) a random forest (RF) modelů pro výpočet výparu. Výpar odhadnutý na základě odvozených vzorců byl porovnáván s pozorováním výparem z výparoměrných stanic. Na závěr byly odvozené vztahy aplikované na vybraných vodních nádržích.

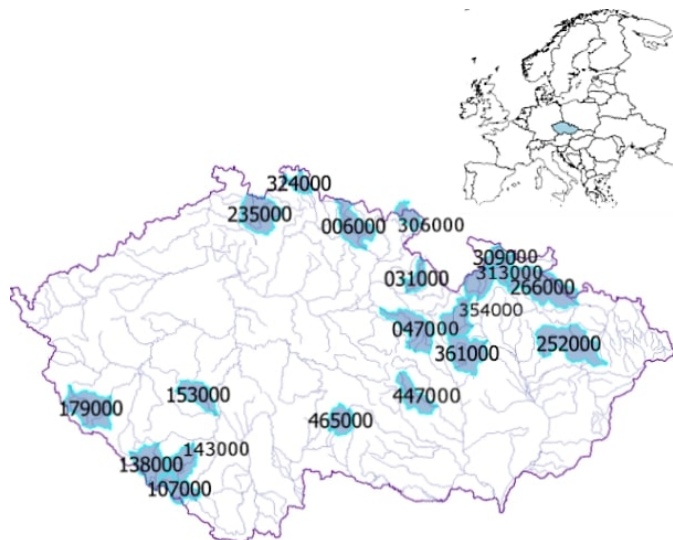
## 4.1 Využití půdní vlhkosti v hydrologickém modelování

V kapitole 4.1 jsou popsány pilotní lokality (povodí), na kterých byla vyhodnocena hydrologická bilance s použitím různých kalibračních strategií (dvě strategie využívají pro kalibraci také hydrologické charakteristiky) s ohledem na hodnocení výkonu modelu. Hodnoceny byly parametry modelu Bilan a odtokové charakteristiky pomocí kritériálních funkcí.

### Zájmové území

Česká republika (ČR) se rozkládá na ploše 78 867 km<sup>2</sup>, podnebí na celém území je mírné, charakterizované jako kontinentální s oceánským vlivem. Dlouhodobý průměr srážkových úhrnů pro období 1981–2010 (klimatologické referenční období pro Českou republiku) je 709,5 mm, průměrná roční teplota vzduchu 7,9 °C a průměrný odtok je 205,5 mm ([Tolasz et al., 2007](#)). Dlouhodobý odtokový součinitel je tedy pro ČR 0,29 (29% srážkových úhrnů odteče). V rámci dizertační práce bylo hodnoceno 20 povodí v různých částech České republiky. Vybraná povodí jsou zobrazena na Obr. 4.1 s identifikátorem DBCN (databázové číslo vodoměrné stanice, které je šestimístné a nahradilo starší čtyřmístný formát DBC). DBCN identifikují uzávěrný profil (vodoměrná stanice) povodí, ve kterých

jsou pozorovány průtoky (odtoky). Většina povodí se nachází v severní části území České republiky. Byla vybrána pouze povodí s volně dostupnými údaji (v době zpracování této studie) bez významného antropogenního vlivu (bez významných vodních nádrží a významných odběrů/vypouštění vody) na odtokový režim. U vybraných povodí je průměrný roční úhrn srážek 792,5 mm, průměrná teplota vzduchu 7,3 °C, průměrná dlouhodobá zásoba vody v půdě je 85,1 mm, průměrný roční odtok je 318,8 mm a odtokový součinitel 0,4. Plocha povodí je v rozmezí od 348 do 932 km<sup>2</sup>, s průměrnou plochou 454 km<sup>2</sup>. Základní charakteristiky jednotlivých povodí jsou uvedeny v Tab. 4.1.



Obr. 4.1 Hodnocená povodí.

## Postup vyhodnocení kalibračních strategií

V dizertační práci byly posuzovány následující kalibrační strategie, kterým předcházela příprava vstupních dat/souborů do hydrologického modelu do požadované struktury:

1. Expertní kalibrace, pro kterou bylo využito grafické uživatelské rozhraní GUI modelu Bilan (podrobný popis je v Kašpárek et al. (2015)). Rozhraní umožňuje volbu kalibrační metody, okrajových podmínek modelu s rychlou (interaktivní) grafickou prezentací výsledků a uložení výsledných sad parametrů expertní kalibrace pro jednotlivá povodí. Prostředí GUI umožňuje také korekci vstupních dat, avšak tato funkcionality nebyla použita.
2. Standardní automatická kalibrace pro zvolená nastavení modelu. V tomto případě bylo použito prostředí R a R-balík Bilan. Získání parametrů modelu.
3. Kalibrace pomocí časové řady a hydrologických charakteristik – kalibrace zohledňující rozdíl mezi pozorovanými a simulovanými charakteristikami odtoku nebo charakteristiky odtoku a vlhkosti půdy.
4. Simulace na validačním období.

Následně bylo provedeno vyhodnocení nejlepší strategie z několika pohledů.

**Tab. 4.1** Charakteristiky povodí:  $\bar{R}$  – průměrný odtok za rok,  $\bar{T}$  – průměrná teplota,  $\bar{P}$  – průměrné srážky za rok,  $\bar{SW}$  – průměrná půdní vlhkost počítaná z modelu SoilClim.

DBCN	Povodí	Plocha km <sup>2</sup>	Nadmořská výška m.n.m	$\bar{R}$ mm	$\bar{T}$ °C	$\bar{P}$ mm	$\bar{SW}$ mm
006000	Labe	543,9	1384,0	2,1	6,8	926,2	111,5
031000	Bělá - Častolovice	213,9	1048,0	374,0	7,6	880,2	82,3
047000	Loučá	625,5	516,0	178,1	8,3	679,7	79,6
107000	Teplá Vltava	348,0	1172,0	7,2	5,6	955,6	98,6
138000	Otava	540,7	627,0	618,8	6,1	1067,2	95,2
143000	Volyněka	394,3	1045,0	223,1	7,1	759,6	79,6
153000	Skalice	374,8	678,0	128,0	8,0	619,0	83,0
179000	Radbuza	710,0	869,0	161,7	8,3	692,3	61,6
239000	Ploučnice	627,0	654,0	261,4	8,0	754,3	81,1
252000	Odra	913,5	633,0	227,3	7,9	715,5	106,4
266000	Opava	932,4	529,0	212,3	7,2	749,1	108,9
306000	Stěnáva	214,8	718,0	288,3	7,5	729,9	70,2
309000	Vidnávkva	164,0	870,0	306,6	7,8	814,1	57,2
313000	Bělá - Mikulovice	230,9	1048,0	519,1	6,4	982,5	86,9
324000	Smědá	191,6	847,0	602,2	7,8	814,1	97,0
340000	Morava	351,2	1370,0	546,4	6,1	956,1	84,0
354000	Moravská Sázava	445,2	780,0	296,6	7,5	774,3	90,1
361000	Třebůvka	579,7	462,0	140,4	7,7	646,3	90,4
447000	Loučka	389,3	725,0	164,4	7,6	647,2	75,1
465000	Jihlava	309,6	670,0	194,5	7,4	687,5	73,3

## Příprava dat

V disertační práci, která byla také podkladem článku (Melišová et al., 2020) bylo použito časové období (1981–2016), které bylo rozděleno na kalibrační (1981–1998) a validační období (1999–2016). Kalibrační období bylo použito pro identifikaci parametrů modelu a validační období pro hodnocení kvality výstupu modelu. Vstupem do modelu byly měsíční časové řady:

### 1. Pozorované:

- Teplota vzduchu ve 2 m (°C), srážkové úhrny (mm). Klimatické veličiny v čtvercové síti/gridu (Štěpánek et al., 2011) byly interpolovány do těžiště povodí.
- Průtoky, které byly přepočteny na odtokové výšky (mm).

### 2. Odvozené:

- Půdní vlhkosti z modelu SoilClim (mm).
- Hydrologické charakteristiky – statistické charakteristiky (kvantily, směrodatné odchylky, průměry, atd.) odtoků a půdní vlhkosti.

## Modelování v prostředí R/GUI

Modelování hydrologické bilance bylo provedeno v následujících bodech:

1. Založení nového běhu modelu Bilan v měsíčním časovém kroku.
2. Nahrání vstupních dat (teploty, srážky, odtok a půdní vlhkost) pro kalibraci.
3. Volba a výpočet potenciální evapotranspirace.
4. Nastavení optimalizace a případné nastavení kritériálních funkcí.

**BOX 4.1** BILAN V PROSTŘEDÍ R

```

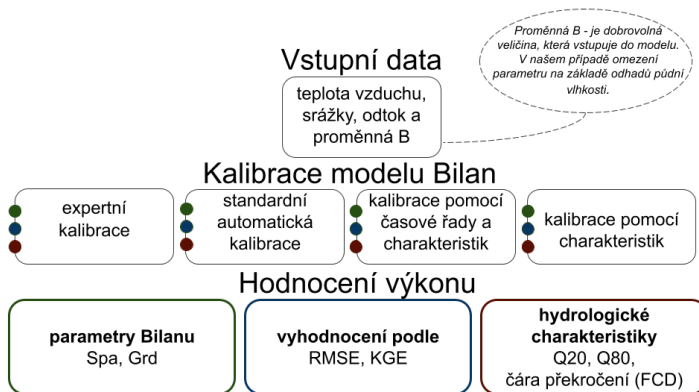
library(Bilan)
b1=bil.new('m')
bil.set.values(b1, data[,.(DTM=DTM, P=Rain, R=R, T=Tavg, B=AWW2)])
bil.pet(b1, pet_type = 'latit')
bil.set.critvars(b1, ...)
bil.optimize(b1)
bil.get.params(b1)

```

5. Spuštění modelu a získání kalibrovaných parametrů.
6. Validace modelu.
7. Vyhodnocení.

**Kalibrační strategie**

Účelem testování čtyř kalibračních strategií bylo najít nastavení hydrologického modelu (kalibrace), které by minimalizovalo odchylku v simulované vodní bilanci a nejistotu v odhadovaných parametrech modelu a to i v případě, že jsou k dispozici pouze omezené údaje o odtokovém režimu daného povodí. První tři kalibrační strategie (expertní, standardní automatická, časová řada s hydrologickými charakteristikami) vyžadují časovou řadu pozorovaného odtoku, čtvrtá (kalibrace s hydrologickými charakteristikami) může být použita také u neměřených povodí. Hydrologické charakteristiky mohou být často úspěšně interpolovány z dostupných údajů nebo odhadnuty z obecných vztahů. Schéma kalibračních strategií je znázorněno na Obr. 4.2.



Obr. 4.2 Schéma hodnocených kalibračních strategií.

Pro samotnou práci bylo použito již zmíněné časové období (1981–2016), které bylo rozděleno na kalibrační (1981–1998) a validační období (1999–2016), přičemž první bylo použito pro identifikaci



parametrů modelu a druhé pro hodnocení kvality výstupu modelu. Optimalizační algoritmus umožňuje posouzení nejistoty parametrů. Model byl aplikován 15krát (15 iterací) pro všechny kalibrační strategie s výjimkou odborné kalibrace, pro kterou byla použita pouze „nejlepší“ sada parametrů. V rámci kalibrace pomocí hydrologických charakteristik bylo použito časově pohyblivé okno, kde:

1. kalibrace byla za období 1981–2000,
2. kalibrace byla za období 1982–2001,
3. ... ,
15. kalibrace končila obdobím 1996–2015.

## Expertní kalibrace

Strategie staví na znalostech povodí (odtokové podmínky, geomorfologie) a zkušenostech hydrologa-modeláře s hydrologickým modelováním. Na základě expertní znalosti hydrologa jsou při modelování pomocí modelu Bilan upraveny rozsahy parametrů tak, aby odpovídaly modelovanému prostředí (zejména co se týče parametrů ovlivňující retenční kapacitu povodí a základní odtok). Po vložení vstupních dat se spustí optimalizační algoritmus. Tato kalibrační strategie ne vždy vede k nejlepší možné shodě mezi pozorovaným a simulovaným odtokem, ale současně zajišťuje, že všechny komponenty vodní bilance mají přiměřené hodnoty a respektují fyzikální podmínky povodí. Výsledky z expertní kalibrace jsou dále brány jako referenční. Pro expertní kalibraci je možné využít prostředí GUI modelu Bilan (Kašpárek et al., 2015), které je interaktivní. Expertní kalibrace je časově nejvíce náročná.

## Standardní automatická kalibrace

Standardní automatická kalibrace využívá diferenční evoluci (použita při kalibraci v této práci) k minimalizaci chyby mezi časovými řadami pozorovaného a simulovaného odtoku. Výhodou automatické kalibrace je, že je rychlejší než expertní kalibrace a lze ji použít na velké sady povodí. Často také vede k lepší shodě mezi pozorovaným a simulovaným odtokem než expertní kalibrace. Nevýhodou automatické kalibrace je, že u některých povodí nemusí být simulovaná vodní bilance (anebo parametry modelu) realistické, což může mít za následek např. nadměrnou akumulaci podzemní nebo půdní vody, nereálnou sněhovou pokrývku atd.

## Kalibrace pomocí časových řad a hydrologických charakteristik

Poslední dvě kalibrační strategie zahrnují hydrologické charakteristiky buď v kombinaci s časovými řadami odtoku anebo půdní vlhkosti nebo jako jedinou složkou kriteriální funkce (OF). Jako hydrologické charakteristiky byly použité statistické ukazovatele (např. průměr, minimum, směrodatná odchylka, mezikvartilové rozpětí) odtoku a vlhkosti půdy.

Konkrétní kombinace proměnných, časových řad a charakteristik jsou zřejmé z Tab. 4.2. Více než polovina OF používá pouze charakteristiky. OF lze rozdělit do sedmi základních skupin (v závorce je uveden identifikátor skupiny):

- Jednosložkové OF s odtokem (R);
- Jednosložkové OF s půdní vlhkostí (SW);
- Dvousložkové OF s odtokem (R2);
- Dvousložkové OF s půdní vlhkostí (SW2);
- Dvousložkové OF s odtokem a půdní vlhkostí (RSW);
- Třísložkové OF s odtokem a půdní vlhkostí (RSW2);

- Čára překročení 300, 330, 355, 364 (FDC).

**Tab. 4.2** Optimální OF jsou označeny tučně. Sloupec časových řad obsahuje časové řady jako odtok a půdní vlhkost (SW). Hydrologická charakteristika sloupce (R) a (SW) je kombinována se statistickými ukazateli jako průměr, IQR, sd a zvolené nastavení (\*).

ID	Časová řada		R-charakteristiky			SW-charakteristiky		
	R	SW	mean	IQR	sd	mean	IQR	sd
<b>Automatic</b>	°							
R-mean			*					
R-iqr				*				
R-sd					*			
SW-mean						*		
SW-iqr							*	
SW-sd								*
SW-optim		*						
<b>R2-mean-sd</b>			°		°			
<b>R2-mean-iqr</b>			°	°				
<b>R2-mean-optim</b>	°		°					
<b>R2-sd-iqr</b>				°	°			
<b>R2-sd-optim</b>	°				°			
<b>R2-iqr-optim</b>	°			°				
SW2-mean-iqr						°	°	
SW2-mean-sd						*		°
SW2-mean-optim		*				*		
SW2-sd-iqr							°	*
SW2-sd-optim		*						*
SW2-iqr-optim		*					°	
<b>RSW-mean-mean</b>				°		°		
RSW-mean-sd				*				*
RSW-mean-optim		*		*				
<b>RSW-mean-iqr</b>				°			°	
RSW-sd-sd					°			°
RSW-sd-optim		*			*			
RSW-sd-iqr					*		°	
<b>RSW-optim-optim</b>	°	°						
<b>RSW-optim-iqr</b>	°						°	
<b>RSW-iqr-iqr</b>				°			°	
RSW2-mean-mean-sd				*		*		°
RSW2-mean-mean-optim		*		*		*		
RSW2-mean-mean-iqr				*		*	°	
RSW2-sd-sd-mean					*	*		°
<b>RSW2-sd-sd-optim</b>		°			*			°
RSW2-sd-sd-iqr					*		°	°
<b>RSW2-optim-optim-sd</b>	°	°						°
<b>RSW2-optim-optim-mean</b>	°	°				°		
<b>RSW2-optim-optim-iqr</b>	°	°					°	
RSW2-iqr-iqr-mean				°		*	*	
RSW2-iqr-iqr-sd				*		*	*	°
RSW2-iqr-iqr-optim		*		*			*	
RSW2-mean-sd-optim		*	*					*
RSW2-sd-mean-optim		*	*		*			
<b>RSW2-optim-mean-sd</b>	°					°		°
RSW2-iqr-sd-optim		*		*			*	*
RSW2-sd-iqr-optim		*			*		*	
<b>RSW2-optim-iqr-sd</b>	°					*	°	°
RSW2-iqr-mean-optim		*		*		*		
RSW2-mean-iqr-optim		*	*				*	
<b>FDC-all</b>	°							
FDC-180	°							
<b>FDC-300-330-355-364</b>	°							

**BOX 4.2** UKÁZKA NASTAVENÍ DLE HYDROLOGICKÝCH CHARAKTERISTIK V R

```

• 'RSW2_sd_sd_optim' = list(
  · obs_vars = c('R', 'B', 'B'),
  · mod_vars = c('RM', 'SW', 'SW'),
  · crits = c('sd', 'sd', 'optim'),
  · obs_values = c(dta_kal[, sd(R)], dta_kal[, sd(AWV2)], dta_kal[,
    mean(AWV2)]),
  · group = ('RSW2'),
  · ts_sig = ('ts + sig'),
  · variable = ('3'),
  · combination = ('R + SW + SW')

• 'FDC_300_330_355_364' = list(
  · obs_vars = c('R'),
  · mod_vars = c('RM'),
  · crits = c('300', '330', '355', '364'),
  · obs_values = c(dta_kal[, mean(R)]),
  · group = ('R'),
  · ts_sig = ('FDC'),
  · variable = ('1'),
  · combination = ('R'),

```

kde: obs\_vars-jsoú pozorované hodnoty, mod\_vars-vybrané modelované hodnoty, crits-nastavení požadovaného kritéria, obs\_values = hodnoty z kterých se počítá charakteristika, group , ts\_sig, variable, combination - v tomto případě slouží jako identifikátory charakteristik.

## Vyhodnocení kalibrací

Vhodnost každé kalibrované sady parametrů byla hodnocena porovnáním s výsledky odborné kalibrace. To znamená, že chceme vyhodnotit, do jaké míry jsme schopni získat výsledky blízké odborné kalibraci, ale s omezenými informacemi (a bez odborných znalostí). Soubory parametrů byly hodnoceny podle kriteriálních funkcí Kling-Gupta efficiency (KGE), root mean square error (RMSE) (Melišová et al., 2020). Ve studii Melišová et al. (2017) se vyhodnocovaly tyto parametry pomocí, mean absolute error (MAE) a mean squared error (MSE). Hodnoceny byly také odchylky parametrů kapacity zásoby půdní vlhkosti (Spa) a parametr určující odtok ze zásoby podzemní vody (Grd) od hodnot identifikovaných expertní kalibrací. Dopad jednotlivých nastavení modelu na celkové výsledky modelu byl vyhodnocen také pro nízké průtoky (Q20), vysoké průtoky (Q80) a porovnány byly také čáry překročení měsíčních průtoků (Obr.4.2).

Výběr nejlepších kriteriálních funkcí (OF) byl proveden metodou seřazování (rankování), tzn., že ke každé OF bylo přiděleno číslo, kolikrát se vyskytuje mezi nejlepšími v jednotlivých povodích dle jednotlivých způsobů hodnocení.


## 4.2 Odhad výparu pro Českou republiku

V kapitole jsou popsány pilotní lokality, kde jsou umístěny výparoměrné stanice a vodní nádrže v České republice. Kapitola 4.2 popisuje práce při odvození vzorců výparu z vodní hladiny, využití a zpracování reanalyzovaných dat klimatu, které jsou poskytnuté v rámci programu Copernicus a sestrojení modelů pro odhad výparu pomocí lineární regrese a random forest regrese. Závěr popisuje výběr nejlepších modelů a jejich využití na vodních nádržích, které neobsahují přímé měření ztráty vody výparem.

Studie výparu z vodní hladiny se skládá ze dvou částí – v první byly využity satelitní odhady teploty pro výpočet výparu na základě vzorců odvozených v [Beran et al. \(2020\)](#). Druhá se zabývá využitím reanalýzy klimatu ER5–Land pro odvození vhodných vztahů pro výpar z vodní hladiny pro celou ČR umožňující odhad výparu pro jakoukoliv lokalitu v ČR pro celé období s dostupnou reanalýzou (v současnosti 1950–2021).

### Zájmové území

Pilotní lokality jsou navrženy podle studie ([Beran et al., 2020](#)), kde byl odhadnut výpar pomocí výparoměrů a výparoměrných stanic, ve studii byl odhadnut výpar pro navrhované vodní nádrže České republiky, viz Obr. 4.3.



Obr. 4.3 Rozdělení výparoměrných stanic a vodních nádrží podle nadmořské výšky [Beran et al. \(2020\)](#).

Ve studii [Beran et al. \(2020\)](#) byly výparoměrné stanice přiřazeny jednotlivým vodním nádržím na základě Quittovi klasifikace, což znamená, že Česká republika byla rozdělena do třech klimatických oblastí (klimatická charakteristika chladných, mírně teplých a teplých oblastí), viz mapa v příloze 7.1 a Tab. pro detailnější přehled dle Quittovi klasifikace (Příloha Tab. 7.2). Další rozdělení bylo na základě nadmořské výšky. Z tabulky je patrné, že k jedné vodní nádrži patří 2 nebo 3 stanice. Rozdíl nadmořské výšky mezi stanicemi a vodními nádržemi nepřesahuje 100 m n.m., viz Tab. 4.3.

Tab. 4.3 Charakteristika vodních nádrží a výparoměrných stanic.

Vodní nádrž	kóta hráze [m n. m.]	Quittova klasifikace	výparoměrná stanice	Quittova klasifikace	nadm. výška	výparoměrná stanice	Quittova klasifikace	nadm. výška	výparoměrná stanice	Quittova klasifikace	nadm. výška
Bedřichov	764	CH6-7	Pec pod Sněžkou	CH6-7	816	Červená	CH6-7	748	Svratouch	CH6-7	734
Bezdrév	381	MT10-11	Dukovany	MT11	400	Plzeň	MT11	360	x	x	x
Brno	232	T2 MT11	Holešov	T2	222	Brno, Tuřany	T2	241	x	x	x
Dalešice	384	MT7-11	Ústí nad Orlicí	MT7	402	Dukovany	MT11	400	x	Vavřinec	MT7
Harcov	370	MT1-2	Liberec	MT2	398	x	x	x	x	x	x
Hněvkovice	372	MT7-10-11	Vavřinec	MT7	385	Plzeň	MT11	360	Ústí nad Labem	T2-MT4	375
Horusický ryb.	416	MT7-11	Dukovany	MT11	400	Plzeň	MT11	360	Ústí nad Orlicí	MT7	402
Hracholuský	489	MT7-11	Cheb	MT7	483	Kocelovice	MT7	519	x	x	x
Jesenice	443	MT7	Cheb	MT7	483	Vavřinec	MT7	385	x	x	x
Kružberk	434	MT4	Ústí nad Orlicí	MT7	402	Luká	MT4	510	x	x	x
Lipno I	728	CH7; MT1-2-3-6	Svratouch	CH6-7	734	Přimda	MT3	742	x	x	x
Mariánské Lázně	716	CH7	Svratouch	CH6-7	734	Přimda	MT3	742	x	x	x
Medard	400	MT7	Ústí nad Orlicí	MT7	402	Cheb	MT7	483	Vavřinec	MT7	385
Most	199	T2	Most	T2	199	x	x	x	x	x	x
Nechranice	274	T2-MT7	Tušimice	T2-MT7	322	Zaječice	T2	290	x	x	x
Nesyt	175	T4	Brno, Tuřany	T2	241	x	x	x	x	x	x
Nové Mlýny	173	T2-4	Brno, Tuřany	T2	241	Holešov	T2	222	Doksany	T2	158
Orlík	361	MT11	Plzeň	MT11	360	x	x	x	x	x	x
Přísečnice	735	CH7	Červená	CH6-7	748	Svratouch	CH6-7	734	x	x	x
Rozkoš	285	T2 MT7	Tušimice	T2-MT7	322	Zaječice	T2	290	x	x	x
Rožnberk	429	MT7-10-11	Dukovany	MT11	400	Ústí nad Orlicí	MT7	402	Vavřinec	MT7	385
Římov	473	MT7	Kocelovice	MT7	519	Cheb	MT7	483	x	x	x
Skalka	444	MT7	Cheb	MT7	483	Vavřinec	MT7	385	x	x	x
Slezská Harta	500	MT4	Přibyslav	MT4	532,5	Luká	MT4	510	x	x	x
Staňkovský ryb.	469	MT7	Cheb	MT7	483	Kocelovice	MT7	519	x	x	x
Stráž p. Ralskem	304	MT7	Ústí nad Labem	T2-MT4	375	Tušimice	T2-MT7	322	x	x	x
Svíhov	381	MT7	Ústí nad Labem	T2-MT4	375	Ústí nad Orlicí	MT7	402	Vavřinec	MT7	385
Třebícko	297	T2 MT7-10	Praha, Libuš	T2	302	Tušimice	T2-MT7	322	Zaječice	T2	290
Vír I	470	MT4	Přibyslav	MT4	532,5	Luká	MT4	510	x	x	x
Vrané	203	T2 MT11	Holešov	T2	222	Praha, Podbaba	T2	191	x	x	x
Vranov	353	MT7-11	Dukovany	MT11	400	Plzeň	MT11	360	Vavřinec	MT7	385
Žehuňský ryb.	204	T2	Holešov	T2	222	Praha, Podbaba	T2	191	Most	T2	199

## Data

Pro výpočet byla použita data:

1. Pozorovaná data: data ze staničního měření a odvozené data.
2. Satelitní data - Land Surface Temperature (povrchová teplota - LST), data jsou dostupná na webové stránce: [land.copernicus.eu](http://land.copernicus.eu).
3. Reanalýza klimatu - ERA5-Land, data jsou dostupná na webové stránce: [cds.climate.copernicus.eu](http://cds.climate.copernicus.eu).

### Pozorovaná data

Ve studii [Beran et al. \(2020\)](#) pro odhad výparu pro vybrané vodní plochy byla použita následující pozorovaná klimatická data: teplota vzduchu ve 2 metrech  $T_a$  ( $^{\circ}\text{C}$ ), teplota hladiny vody  $T_w$  ( $^{\circ}\text{C}$ ), globální sluneční radiace  $R_a$  ( $\text{W}\cdot\text{m}^{-2}$ ), rychlost větru ( $\text{m}\cdot\text{s}^{-1}$ ) a relativní vlhkost vzduchu (%100). Výparoměrná stanice Hlasivo a jezero Most obsahují pozorované data výparu, ostatní stanice poskytují data z EWM výparoměřů, čili výparnost. Hodnoty výparnosti byly převedeny na hodnoty výparu vynásobením koeficientem 1,3. Koeficient byl stanoven na základě porovnání naměřených dat v Hlasivu (537 m n. m.) s naměřenými hodnotami ve stanicích v podobné nadmořské výšce a v podobných klimatických podmínkách (stanice Přebyslav, Kocelovice a Košetice) v období 2005–2018, květen–říjen ([Beran et al., 2020](#)). Ve studii [Beran et al. \(2020\)](#) se zjistilo, že výparoměry EWM systematicky podhodnocují skutečný výpar, přibližně o 30 %. Proto byl zvolen koeficient 1,3, kterým jsou vynásobeny hodnoty výparnosti. Pozorovaná data (teplota vzduchu a vody, radiace aj.) pro jednotlivé stanice jsou uvedeny v kapitole přílohy 7.8, 7.5, 7.4, 7.6, 7.7.

### Satelitní data


Pro výpočet byla použita satelitní data, produkt LST - teplota povrchu, který je poskytován ze satelitu Meteosat druhé generace a poskytuje informace o klimatu.

V kapitole 3.5 byl popsán produkt teploty povrchu (LST), které byly v práci použité. Produkt LST byl ověřen na pozorovaných a odhadovaných klimatických datech na vodní nádrži jezero Most. Rozdíl mezi produktem LST a odhadovanými daty v jednotlivých měsících popisuje Obr. 4.4 formou grafu boxplot<sup>1</sup> (krabicový graf). Každý boxplot v tomto případě znamená jeden měsíc. V grafu nejsou zobrazeny odlehle hodnoty, které byly odstraněny z důvodu vizuálního zkreslení krabicových grafů a lepšího vykreslení. V grafu je uveden rozdíl teplot pro jednotlivé měsíce za období 2009–2018. Průměrné rozdíly teploty v jednotlivých měsících: leden 5,12  $^{\circ}\text{C}$ , únor 4,52  $^{\circ}\text{C}$ , březen 3,35  $^{\circ}\text{C}$ , duben 2,53  $^{\circ}\text{C}$ , květen 2,69  $^{\circ}\text{C}$ , červen 2,25  $^{\circ}\text{C}$ , červenec 1,91  $^{\circ}\text{C}$ , srpen 1,40  $^{\circ}\text{C}$ , září 2,35  $^{\circ}\text{C}$ , říjen 3,25  $^{\circ}\text{C}$ , listopad 4,42  $^{\circ}\text{C}$  a prosinec 5,03  $^{\circ}\text{C}$ . Průměrná hodnota rozdílu teploty za celý časový úsek je 3,15  $^{\circ}\text{C}$  ([Beran et al., 2019a](#)).

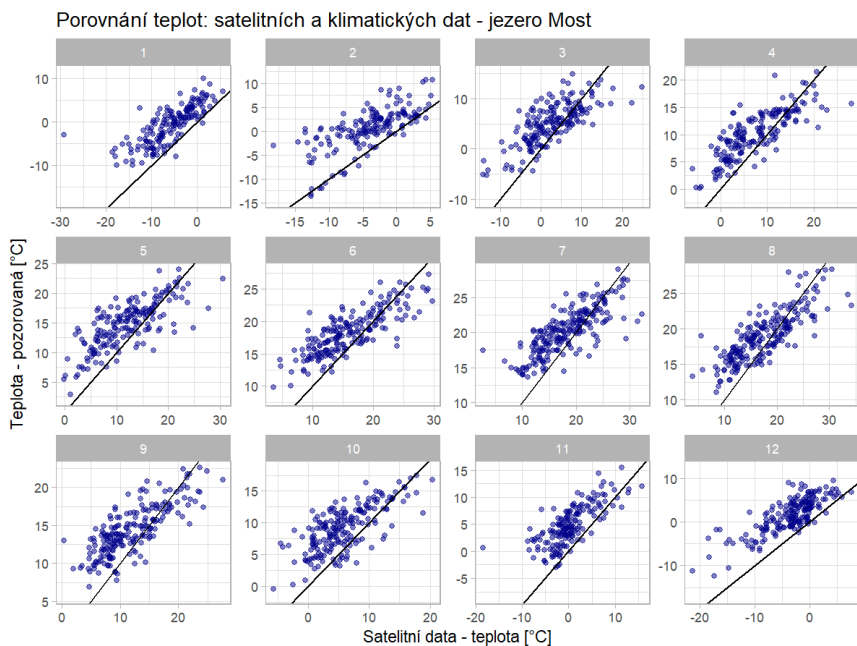
Pro další vyhodnocení byl použit jednoduchý lineární model s jedním prediktorem (odhadované data teplot vs produkt LST) v jednotlivých měsících za celý časový úsek, viz Obr. 4.5. Černá linie znázorňuje ideální podmínky, kde by se měla data v ideálním případě nacházet. V tomto případě, slouží jako referenční příčka. Pro lepší validitu produktu LST, bylo vhodné udělat korekci satelitních dat.

---

<sup>1</sup>je způsobem grafické vizualizace numerických dat pomocí jejich kvartilů, střední „krabicová“ část diagramu je shora ohraničena 3. kvartilem, zesponu 1. kvartilem a mezi nimi se nachází linie vymežující medián.




Obr. 4.4 Rozdíl teploty mezi pozorováním a produktem LST za období 2009–2018 pro jezero Most.



Obr. 4.5 Porovnání produktu Land surface temperature (LST) a klimatických dat.

Pro porovnání odvozených teplot a produktu LST byla využita vrstva GIS, která obsahuje polohu a maximální zátopu v jednotlivých vodních nádržích. V příloze (Tab. 7.9) je viditelné, že největší rozdíl mezi teplotami bylo na vodní nádrži Nesyt v červenci  $-11,83^{\circ}\text{C}$  a v lednu  $15,12^{\circ}\text{C}$ . Záporný rozdíl je viditelný na vodních nádržích Lipno I, Nesyt, Nové Mlýny-horní, Nové Mlýny-dolní, Nové Mlýny-střed a Přísečnice. Ostatní nádrže mají rozdíly kladné. Průměrná hodnota rozdílu všech nádrží je  $2,70^{\circ}\text{C}$ , nejnižší hodnota je  $-1,90^{\circ}\text{C}$ , nejvyšší hodnota potom  $3,61^{\circ}\text{C}$ . Graficky jsou výsledky znázorněny na Obr. 4.6. Obecně nejvíce nadhodnoceny oproti průměru jsou zimní měsíce listopad až únor (Beran et al., 2019a).



Obr. 4.6 Rozdíl teplot pro všechny nádrže a jednotlivé měsíce (červená linie zobrazuje průměr).

## Reanalýza klimatu

Reanalýza klimatu ERA5-Land (bližší informace jsou v kapitole 3.5) byla stažena přes Copernicus CDS ([cds.climate.copernicus.eu](https://cds.climate.copernicus.eu)), kde je možné vybrat typ produktu, proměnnou, rok, měsíc, čas, region a formát dat. Stažená data (období 1981–2019) byla ořezána a extrahována (pomocí GIS nástrojů) pro jednotlivé stanice a vodní nádrže na území České republiky. Obrázek 4.7 ukazuje webový portál sloužící ke stahování jednotlivých veličin (po zadání specifikace: typ produktu, oblast, časové měřítko).

## Zpracování reanalýzy ERA5-Land

Stažená teplota vzduchu ve 2 m, teplota povrchu a hodnoty rosného bodu byly v Kelvinech (K) a bylo nutné je převést na jednotku stupně Celsia ( $^{\circ}\text{C}$ ) dle:

$$0^{\circ}\text{C} = 273,15\text{K}. \quad (4.1)$$

Vítr je poskytován v jednotkách  $\text{m s}^{-1}$ , tlak v Pa a radiace  $\text{J m}^{-2}$ , která byla propočtena na  $\text{W m}^{-2}$  (hodnoty se dělí akumulací dobou vyjádřenou v sekundách). Relativní vlhkost vzduchu (RH) byla dopočtena podle vzorce pomocí rosného bodu a teploty:



Your requests

All Queued In progress Failed Unavailable Complete

Auto refreshed: 12:45:48 Delete selected

Product	Submission date	End date	Duration	Size	Status
• UERRA regional reanalysis for Europe on height levels from 1961 to 2019	2020-09-03 12:44:24		0:01:36		Queued
• <b>ERA5-Land monthly averaged data from 1981 to present</b>	2020-09-03 10:37:14	2020-09-03 10:52:13	0:14:58	9.4 MB	Download

Open request form  
Request ID: 2097ab42-f713-4703-9154-1cfd8f820a48

Product type: Monthly averaged reanalysis

Variable: 10m u-component of wind, 2m temperature, Evaporation from open water surfaces excluding oceans, Skin temperature, Surface solar radiation downwards

Year: 1981, 1982, 1983, 1984, 1985, 1986, 1987, 1988, 1989, 1990, 1991, 1992, 1993, 1994, 1995, 1996, 1997, 1998, 1999, 2000, 2001, 2002, 2003, 2004, 2005, 2006, 2007, 2008, 2009, 2010, 2011, 2012, 2013, 2014, 2015, 2016, 2017, 2018, 2019, 2020

Month: January, February, March, April, May, June, July, August, September, October, November, December

Time: 00:00

Sub-region extraction: North 51.17°, West 11.9°, South 49.44°, East 19°

Format: NECCDF (experimental)

**Obr. 4.7** Ukázka stažených dat ERA5-Land na webovém portálu Copernicus CDS.

$$RH = 100 \frac{\exp\left(\frac{aT_d}{b+T_d}\right)}{\exp\left(\frac{aT}{b+T}\right)}, \quad (4.2)$$

kde  $a = 17,625$  (konstanta),  $b = 243,04$  (konstanta),  $T_d =$  rosný bod v  $^{\circ}\text{C}$  a teplota vzduchu  $T$  v  $^{\circ}\text{C}$ . Rovnice je založena na August-Roche-Magnus aproximaci, vzorec je považován za platný, pokud:

$$0^{\circ}\text{C} < T < 60^{\circ}\text{C}, \quad (4.3)$$

$$0^{\circ}\text{C} < T_d < 50^{\circ}\text{C}. \quad (4.4)$$

K reanalyzovaným datům byla doplněna nadmořská výška, zeměpisná šířka a výška jednotlivých stanic a vybraných vodních nádrží.

## Postup prací

Díky zdigitalizování datových řad sezonního výparu (duben–říjen) ze srovnávacího výparoměru a meteorologických veličin ze stanice Hlasivo u Tábora a Tišice u Neratovic bylo možné vytvořit vzorce pro výpočet výparu. Vzorce byly vytvořeny z datových řad Hlasivo 2006–2017 a 1957–2017. Vypočtený výpar byl validován na datové řadě Hlasivo 1999–2005 a Tišice 1957–1974. Hodnocení a výběr vzorců pro výpar byl založen na základě koeficientu Kling–Gupta efficiency (KGE) a průměrné relativní chyby (MRE) [Beran et al. \(2020\)](#), [Beran et al. \(2019a\)](#).

Ve studiích [Beran et al. \(2020\)](#), [Beran et al. \(2019a\)](#) byl výpar pro vodní nádrže vyhodnocován na základě pozorovaných dat z výparoměrných stanic, kde pomocí lineární regrese byly vytvořené sady vzorců pro jednotlivé vodní nádrže, které měly určitou platnost (podmínky pro použití vzorce, rozpětí hodnot veličin).

Rozsah jednotlivých veličin je na základě rozsahu horního a spodního kvantilu pro veličinu a pro vodní nádrž.

Vzorce pro výpočet výparu z vodní hladiny byly následně aplikovány na jiných datových řadách, než ze kterých byly odvozeny, a tím vznikly unikátní vzorce pro vybrané vodní nádrže.

V dizertační práci byly v první fázi porovnávány satelitní produkty s pozorováními a odvozenými daty. Tato data byla vložena do vzorců, které byly vytvořené na základě dat z výparoměrné stanice

Hlasivo. Dál se navázalo na data reanalýzy klimatu, která měla stejné proměnné jako pozorované data z předchozí studie. Data byla použita při vytváření lineárních a random forest modelů, kde se pomocí statistického vyhodnocení vybraly nejlepší modely. Na základě této analýzy bylo vybráno 6 modelů (3 lineární a 3 RF), které byly aplikované na všechny vodní nádrže.

### Shrnutí jednotlivých kroků při odvození výparu

Body 1–2 vycházejí ze studie [Beran et al. \(2020\)](#), na které se autorka dizertace podílela, body 3–5 byly provedeny pouze v rámci dizertační práce.

1. Z výparoměrných stanic byly převedeny hodnoty výparnosti z EWM výparoměrů na hodnoty výparu, protože EWM výparoměry měří výparnost ([Možný, 2005](#)). Vynásobením výparností koeficientem 1,3 se získal odhad výparu. Výpar se měřil od dubna do října, kdy se teplota vzduchu nepohybuje bod bodem mrazu a nedochází k zamrznání výparoměrných stanic. Hodnoty denního výparu mm/den jsou přepočteny na průměrné měsíční hodnoty, které jsou následně vynásobeny počtem dní v jednotlivých měsících. Pro stanici Hlasivo u Tábora, která je v provozu 64 let a jezero Most byla poskytnutá data výparu. S průběhem výparu byly porovnány průběhy měřených proměnných. Vyhodnocení vzájemných vztahů popisuje, že s rostoucí intenzitou globální sluneční radiace, teplotou vzduchu a teplotou vody výpar roste a s rostoucí vlhkostí vzduchu naopak klesá ([Beran et al., 2019a](#)). Takto upravená data byla spojena s daty reanalyzovanými.
2. Vodní nádrže a výparoměrné stanice byly rozděleny do několika kategorií, a to na základě Quittovy klasifikace klimatu ([Tolasz et al., 2007](#)) a nadmořské výšky. Rozdíl nadmořské výšky mezi nádržemi a stanicemi nepřesahuje 100 m n.m. ([Beran et al., 2019a](#)).
3. Zpracování satelitních a reanalyzovaných dat: v prvním kroku byla testována satelitní data LST (teploty povrchu) z programu Copernicus (více viz 3.5). Dále byla porovnána reanalyzovaná data z programu Copernicus ERA-Interim: teplota vzduchu ve 2 m nad Zemí a ERA5-Land: produkt evapotranspirace. V konečné fázi byly vybrány produkty z reanalyzovaných dat ERA5-Land: vítr, rosný bod, teplota vzduchu, povrchová teplota, radiace a tlak. V datech se objevuje vlhkost vzduchu, která je napočítána z reanalyzovaných dat ERA5-Land, pomocí aproximace dle vzorce August-Roche-Magnus, kde vstupními veličinami byly povrchová teplota a rosný bod. Ve finální přípravě dat byly k reanalyzovaným datům přidány veličiny: nadmořská výška, zeměpisná šířka a délka.
4. Pomocí lineární regrese a regresní metody random forest (RF) bylo sestrojeno 31 modelů. Lineární modely (LM) byly sestrojovány 2 metodami:
  - a první část modelů byla sestavená ručně, nejlepší modely byly vyhodnoceny podle AIC parametru a QQ grafů.
  - b druhá část modelů byla sestrojena pomocí postupné regrese (Stepwise Regression) v R-balíku CARET ([Gareth et al., 2013](#); [Bruce a Bruce, 2017](#)).
5. Modely byly vyhodnoceny pomocí křížové (cross) validace. Data byla rozdělena na testovací a trénovací data s tím, že u trénovacího datasetu se jedna stanice vždy odebírala. Dále byly modely vyhodnoceny na základě kritériálních funkcí MAE, RMSE, R2 a relativní chyby RERR, bližší informace jsou uvedeny v kapitole 3.9. Posledním krokem vyhodnocení bylo vytvoření hodnotící matice a postupně byly jednotlivé modely odebírány od konce (odebírání probíhalo od nejhorších modelů k nejlepším). Aby k odebírání mohlo dojít, bylo potřeba jednotlivé modely seřadit (nejlepšího k nejhoršímu) nebo standardizovat pomocí kritériální funkce. Na základě tohoto postupu bylo provedeno finální vyhodnocení.


## Využití lineární a random forest regrese

Lineární regrese se snaží vysvětlit hodnoty závislé proměnné prostřednictvím jiných veličin. V našem případě byla snaha vysvětlit závislou proměnnou (hodnota výparu nebo výparnosti z výparoměrných stanic a EWM výparoměrů) prostřednictvím jiných veličin (teplota vzduchu, teplota povrchu, vítr, radiace, rosný bod, tlak, zeměpisná výška i šířka a nadmořská výška, rozdělení typu výparu) pomocí 18 lineárních modelů, které byly vytvořeny postupným zkoušením ručně (8 modelů) a na základě postupné regrese (10 modelů). Všechny modely byly využity pro výpočet výparu a výparnosti.

Lineární modely byly nejdříve použity pro výparoměrné stanice, ke stanicím jsou k dispozici skutečné/reálné hodnoty. První sada modelů (sestrojena ručně) byla vyhodnocena na základě hodnoty Akaike Information Criterion (AIC) (Akaike, 1987) a pro vizuální diagnostiku sloužil kvantil-kvantilový graf-QQ graf (Wickham, 2016). Hodnota AIC je součtem dvou členů, první je úměrný logaritmu reziduální sumy čtverců, druhý člen je úměrný složitosti modelu (počet jeho členů). Při sestrování LM modelů se často může stát, že víc nezávislých proměnných snižuje sumu reziduí (zlepšuje shodu modelu s pozorovanými daty), nicméně tím může vzniknout přefitovaný LM. Část AIC penalizující komplexitu modelu by přefitování měla zabránit. Při ověření předpokladů modelu (normalita reziduí) může pomoc QQ grafu reziduí. Do QQ grafu reziduí se vykreslují dva kvantily proti sobě - teoretický kvantil a kvantil se skutečnými rezidui modelu. Graf QQ je schopný odhalit odchylku rozdělení reziduí od Normálního - např. zešikmená nesymetrická data (když hodnoty vytvářejí parabolu nad nebo pod přímkou) a špičatost (identifikuje tvar "S") (Beranová et al., 2012). Ukázka QQ grafu pro lineární model (závislost výparu na teplotě, teplotě povrchu, radiaci a zeměpisné výšce, 2. model v boxu 4.3):

$$E = 21,66 - 0,06T + 0,0081Tp^2 + 0,0085Ra - 0,423Y \quad (4.5)$$

je uveden na Obr. 4.8, kde lze pozorovat relativně dobrou shodu, kdy pouze odlehlé hodnoty neleží na přímce udávající dobrou shodu.



Obr. 4.8 Ukázka QQ grafu pro lineární model s hodnotou AIC.

**BOX 4.3** LINEÁRNÍ MODELY I.

```
lm(eva ~ (tem * rad) + dep + pre + nmv + Y, data = train.data)
lm(eva ~ tem + I(ste2) + rad + Y, data = train.data)
lm(eva ~ huc + win + tem + ste + nmv, data = train.data)
lm(eva ~ win + tem + nmv + (X * Y) , data = train.data)
lm(eva ~ win + tem + I(X * Y) + nmv , data = train.data)
lm(eva ~ win + tem + rad + I(X * Y) + nmv , data = train.data)
lm(eva ~ win + (tem * dep) + rad + nmv + Y + X, data = train.data)
lm(eva ~ X + Y + nmv + (tem * dep) + rad, data = train.data),
```

kde: eva - evapotranspirace pozorovaná, tem - teplota vzduchu, ste - povrchová teplota, rad - radiace, dep - rosný bod, pre - tlak, huc - relativní vlhkost vzduchu odvozená pomocí August-Roche-Magnus aproximací, nmv - nadmožská výška, Y - zeměpisná délka, X - zeměpisná šířka.

Ručně vytvořené modely a jejich zápis v prostředí R jsou znázorněné v boxu 4.3.

Druhá část lineárních modelů byla sestrojena pomocí postupné regrese. Pro tuto regresi byly použity R-balíky `caret`, `leaps`, `MASS` (Bruce a Bruce, 2017). R-balík `caret` využívá principu strojového učení (machine learning) a R-balík `leaps` slouží pro výpočet postupné regrese (Stepwise regression). R-balík `caret` má funkci `train()`, která umožňuje provádění postupného výběru prediktorů, kde se zvolí výběr lineární regrese se:

- zpětným (`leapBackward`),
- dopředným (`leapForward`),
- postupným výběrem (`leapSeq`).

V práci je zvolená metoda se zpětným výběrem. Parametr ladění `nvmax` odpovídá maximálnímu počtu prediktorů, které jsou do modelu zahrnuty. V této práci bylo použito 11 prediktorů, což vede k nejlepšímu modelům s různými vstupy:

1. nejlepší model s 1 prediktorem,
2. nejlepší model s 2 prediktory,
3. ... ,
11. nejlepší model s 11 prediktory.

Dále je možné nastavit parametry validační metody, v práci to byla křížová validace s 500 iteracemi. Nejlepší model z postupné regrese lze vyčíst pomocí funkcí: `názevModelu$results`, `názevModelu$bestTune`, `summary(názevModelu$finalModel)`. Funkce `summary` sumarizuje celkové výsledky. V grafické prezentaci vyhodnocuje jednotlivé modely hvězdičkou, což říká, které prediktory jsou nejlepší od 1 do 11. Ukázka nastavení je uvedena v boxu 4.4, vyhodnocení prediktorů postupné regrese potom v Tab. 4.4.

Na základě vyhodnocení postupné regrese byla vytvořena sada lineárních modelů (11), které jsou uvedeny v boxu 4.5.

V rámci výpočtu se stejné lineární modely (struktura) přepsaly na random forest modely a vyhodnotily stejně jako LM modely s tím, že zvlášť byl vypočten výpar a výparnost. Random forest (RF) modelů bylo 15. Modely, které obsahovaly intercept (3 modely), nebylo možné napočítat pomocí metody RF. Struktura modelů random forest je uvedena v boxu 4.6.

**BOX 4.4** LINEÁRNÍ MODELY II.

```

set.seed(500)
train.control <- trainControl(method = "cv", number = 500)
step.model <- train(eva~., data = dta4,
method = "leapBackward",
tuneGrid = data.frame(nvmax = 1:11),
trControl = train.control)

step.model$results
step.model$bestTune
summary(step.model$finalModel)

```

*Tab. 4.4* Vyhodnocení prediktorů postupné regrese, hvězdička ukazuje vybrané prediktory.

id	win	tem	ste	rad	dep	pre	huc	nmv	Y	X	Výparnost
1			*								
2			*	*							
3			*	*					*		
4			*	*	*				*		
5			*	*	*			*	*		
6			*	*	*	*		*	*		
7			*	*	*	*		*	*	*	
8	*		*	*	*	*		*	*	*	
9	*		*	*	*	*		*	*	*	*
10	*	*	*	*	*	*		*	*	*	*
11	*	*	*	*	*	*	*	*	*	*	*

**BOX 4.5** LINEÁRNÍ MODELY III.

```

lm(eva ~ ste, data = train.data)
lm(eva ~ ste + rad, data = train.data)
lm(eva ~ ste + rad + Y, data = train.data)
lm(eva ~ ste + rad + dep + Y, data = train.data)
lm(eva ~ ste + rad + dep + nmv + Y, data = train.data)
lm(eva ~ ste + rad + dep + pre + nmv + Y, data = train.data)
lm(eva ~ ste + rad + dep + pre + nmv + Y + X, data = train.data)
lm(eva ~ win + ste + rad + dep + pre + nmv + Y + X, data = train.data)
lm(eva ~ win + tem + ste + rad + dep + pre + nmv + Y + X, data = train.data)
lm(eva ~ win + tem + ste + rad + dep + pre + huc + nmv + Y + X, data =
train.data)

```

**BOX 4.6** RANDOM FOREST

```

randomForest(eva ~ ste, data = train.data)
randomForest(eva ~ ste + rad + Y, data = train.data)
randomForest(eva ~ ste + rad + dep + Y, data = train.data)
randomForest(eva ~ ste + rad + dep + nmv + Y, data = train.data)
randomForest(eva ~ ste + rad + dep + pre + nmv + Y, data = train.data)
randomForest(eva ~ ste + rad + dep + pre + nmv + Y + X, data = train.data)
randomForest(eva ~ win + ste + rad + dep + pre + nmv + Y + X, data =
train.data)
randomForest(eva ~ win + tem + ste + rad + dep + pre + nmv + Y + X, data =
train.data)
randomForest(eva ~ win + tem + ste + rad + dep + pre + huc + nmv + Y + X, data
= train.data)
randomForest(eva ~ (tem * rad) + dep + pre + nmv + Y, data = train.data)
randomForest(eva ~ huc + win + tem + ste + nmv, data = train.data)
randomForest(eva ~ win + tem + nmv + (X * Y) , data = train.data)
randomForest(eva ~ win + (tem * dep) + rad + nmv + Y + X, data = train.data)
randomForest(eva ~ X + Y + nmv + (tem * dep) + rad, data = train.data)

```

**Vyhodnocení regresních modelů a výběr modelu**

Vyhodnocení regresních modelů (lineárních a random forest) byla udělána na základě křížové validace (cross validation), která se skládá ze dvou částí:

1. část tvoří trénování (trénovací data),
2. část tvoří testování (testovací data).

Křížová validace se dělala pro jednotlivé stanice a jednotlivé LM a RF modely. Postup křížové validace byl následující:

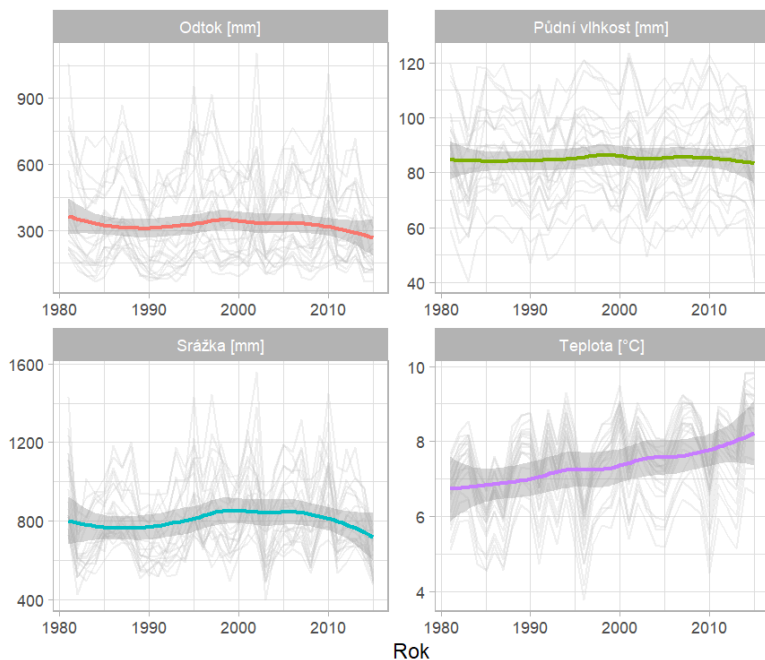
1. V trénovacích datech se jedna z 24 stanic odebrala a byla pro ni provedena validace odvozených vzorců ze 23 povodí.
2. Validace byla postupně provedena pro všechna povodí a modely.
3. Pro validace byly vypočteny kritériální funkce funkce R<sup>2</sup>, RMSE, MAE a relativní chyba.
4. Na základě RMSE byla použita matematické funkce `rank()`, která vypíše pořadí jednotlivých hodnot odpovídajících vzestupně seřazenému vektoru. Po vytvoření unikátního identifikátoru byla vytvořena matice, kde na ose *x* byly modely na ose *y* stanice a na základě této vytvořené matice byly vybrány nejlepší modely.

# Výsledky

## 5.1 Využití půdní vlhkosti v hydrologickém modelování

### Hydroklimatické poměry

Obrázek 5.1 ukazuje vývoj hydroklimatických veličin pro vybraná povodí. Data srážek, teplot a odtoku popisují dlouhodobý vývoj v období 1980–2015, kde šedé linie jsou pro jednotlivá povodí, zvýrazněné linie udávají průměrné hodnoty v jednotlivých letech, které jsou aproximovány filtrem loess (Wickham, 2016). Dlouhodobý měsíční průměr srážek (za 35 let) ukazuje, že hodnota mediánu dosahuje 59,53 mm/měsíc, dolní a horní kvantil mají rozhraní od 37,95 mm do 87,01 mm, minimální a maximální hodnoty jsou 0,41 mm a 160,56 mm. Průměrný medián teplot je 7,50°C, horní a dolní kvantil je mezi 0,98°C a 13,76°C, minimální a maximální hodnoty jsou mezi -10,43°C a 21,88°C. Průměrný medián odtoku je 19,13 mm, horní a dolní kvantil je mezi 10,04 mm a 35,14 mm, minimální a maximální hodnoty jsou 0,16 mm a 72,36 mm. Medián nasycení půdy vodou je 85 mm. Pro odtok, půdní vlhkost, srážky a teplotu byla posouzena významnost trendů, kdy jediná veličina se staticky významných trendem je teplota vzduchu, kdy trend je signifikantní na hladině významnosti 0,01.




Obr. 5.1 Sumarizovaná vstupní data do modelu Bilan (odtoky, půdní vlhkosti, srážkové úhrny a teploty vzduchu).

## Vyhodnocení kalibračních strategií

V práci a ve studii [Melišová et al. \(2020\)](#) bylo kalibrováno, validováno a vyhodnoceno 20 povodí s ohledem na zvolené kalibrační strategie pomocí: kritériálních funkcí RMSE a KGE (viz kapitola 3.9), nejistoty parametrů modelu Bilan Spa a Grd (viz kapitola 3.3), charakteristik nízkých a vysokých odtoků (Q20 a Q80) a čáry překročení (viz kapitola 3.8).

## Vyhodnocení expertní kalibrace

Výsledky expertní kalibrace jsou uvedeny na Obr. 5.2, kde je porovnán pozorovaný a modelovaný odtok pro povodí Labe (DBCN 006000), které patří mezi středně velké povodí s plochou 543,9 km<sup>2</sup>. V tabulce 5.1 jsou vyhodnocena všechna povodí na základě KGE, R2 a RMSE. Zobrazené povodí patří dle kritériálních funkcí mezi středně dobře nakalibrované. I přes to lze však pozorovat relativně dobrou shodu mezi pozorováním i modelovaným odtokem, a relativně dobrou reprezentaci odtokového režimu.



	DBCN	KGE	R2	RMSE
	006000	0.64	0.52	21.87
	031000	0.63	0.47	20.73
	047000	0.62	0.49	6.32
	107000	0.65	0.46	21.65
	138000	0.65	0.55	19.87
	143000	0.55	0.32	12.47
	153000	0.60	0.42	10.24
	179000	0.63	0.50	9.44
	235000	0.61	0.43	7.44
	252000	0.75	0.62	13.08
	266000	0.83	0.71	10.53
	306000	0.56	0.38	16.77
	309000	0.76	0.77	12.74
	313000	0.71	0.83	17.37
	324000	0.29	0.48	28.14
	345000	0.74	0.79	17.32
	354000	0.74	0.60	15.39
	361000	0.73	0.55	7.12
	447000	0.69	0.50	9.85
	465000	0.58	0.42	9.42

**Obr. 5.2** Vyhodnocení expertní kalibrace pro povodí Labe s DBCN 006000. Porovnání pozorovaného a simulovaného odtoku v mm.

**Tab. 5.1** Hodnoty kritériálních funkcí kalibrace pro jednotlivá povodí.

## Vyhodnocení na základě kritériálních funkcí

Výsledky kalibračních strategií jsou porovnány s výsledky expertní kalibrace. Automatická kalibrace poskytuje mírně nižší RMSE a zlepšuje KGE pro kalibraci (v průměru bylo vylepšeno RMSE o 0,134 a KGE o -0,097 v průměru) ve srovnání s expertní kalibrací. Pro validaci se výsledky příliš neliší. Zavedením charakteristik odtoku a půdní vlhkosti pro kalibraci modelu má negativní dopady na metriku kritériálních funkcí, protože pro automatickou kalibraci se používá podobná metrika jako RMSE/KGE. Automatická kalibrace používá pro zlepšení kalibrace kombinaci kritériálních funkcí MSE a MAE, které ovlivňují průměrný odtok a MAPE ovlivňují rozdíl složek odtoku.

Kalibrační kritérium zahrnující pouze charakteristiky odtoku a vlhkosti půdy je horší než při automatické kalibraci. Z tohoto faktu je zřejmé, že samotné charakteristiky půdní vlhkosti nejsou schopny zajistit odpovídající shodu. Kalibrační strategie zahrnující odtok nebo charakteristiky odtoku a vlhkosti půdy fungovaly obdobně, jak pro kalibraci, tak pro validaci.

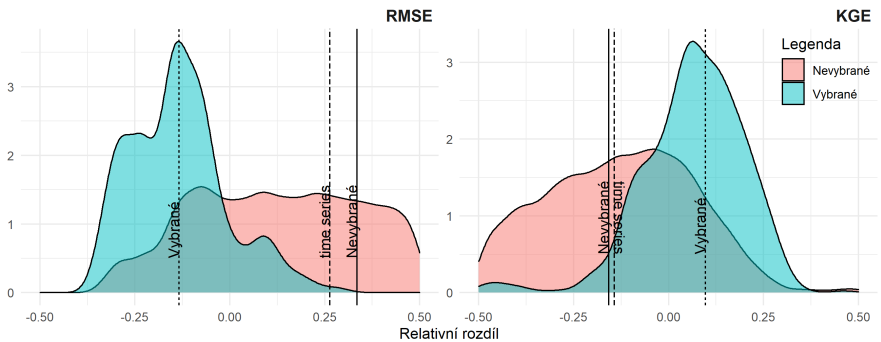


Podle výsledků lze říct, že strategie, které zohledňují data časových řad, fungují lépe než ty, které jsou založeny pouze na charakteristikách. Kalibrační strategie obsahující pouze charakteristiky odtoku/půdní vlhkosti jsou však také schopny poskytnout přiměřené výsledky. Kvantitativní porovnání pro všechny skupiny kritériálních funkcí (OF) podle RMSE a KGE je uvedeno v Tab. 5.2.

**Tab. 5.2** Rozdíl v RMSE a KGE pro všechny skupiny vzhledem k expertní kalibraci. Automatická kalibrace, časová řada + charakteristiky a jenom charakteristiky - kalibrační strategie, které kombinují odtok (R), půdní vlhkost (SW) nebo odtok + půdní vlhkost (R + SW).

GOF	Automatická kalibrace		Časová řada + charakteristiky				R + SW		Charakteristiky R		SW		R + SW	
	mean	median	mean	median	mean	median	mean	median	mean	median	mean	median	mean	median
RMSE	0.134	0.142	0.125	0.138	-0.560	-0.478	-0.257	-0.183	-0.303	-0.222	-0.537	-0.454	-0.383	-0.295
KGE	-0.097	-0.077	-0.099	-0.080	0.270	0.265	0.151	0.129	0.098	0.107	0.236	0.232	0.170	0.156

Dále byl porovnáván rozdíl validačních RMSE a KGE vzhledem k expertní kalibraci pro identifikované (nejlepší) kritériální funkce (OFs) a ostatními OFs 5.3. Je zřejmé, že vybrané OFs poskytují konzistentní zlepšení jak v RMSE, tak v KGE, zatímco ostatní OFs často výsledky zhoršují. Zohlednění OFs založených pouze na časových řadách (bez charakteristik) vede ke značně horším výsledkům v porovnání s vybranými "nejlepšími" OFs.



**Obr. 5.3** Hustota rozdílů RMSE a KGE mezi expertní kalibrací a ostatními kritériálními funkcemi (OF). Tečkovaná čára odpovídá průměru vybraných nejlepších OF, přerušovaná čára odpovídá průměru OF včetně časových řad, a plná čára odpovídá průměru OF, které nebyly vybrány.

## Vyhodnocení na základě nejistoty parametrů modelu Bilan

Parametr  $Spa$ , představuje kapacitu zásoby půdní vlhkosti a parametr  $Grd$ , určuje odtok ze zásoby podzemní vody (základní odtok) a jsou důležité pro charakterizaci hydrologické bilance v povodí. Pro vyhodnocení rozdílů odhadů parametrů oproti expertní kalibraci bylo nutné oba parametry standardizovat. Čím menší rozdíl, tím lepší výsledek.

Podle souhrnné Tab. 5.3 je pro parametr  $Spa$  nejlepší kalibrační strategie automatická standardní kalibrace. Lze říct, že odtok tvoří důležitou součást kalibrací pro kalibrace pomocí časové řady i charakteristik a kalibrace pouze pomocí charakteristik. Kalibrační strategie, které obsahují časovou řadu a charakteristiky (R, SW a R+SW) dosahují lepších výsledků než kalibrační strategie, které obsahují jenom charakteristiky.

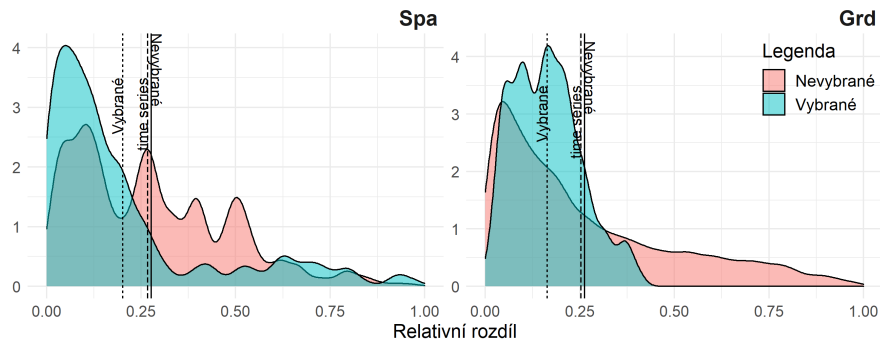
Samostatný parametr Spa je nadhodnocen při kalibraci pomocí časových řad a hydrologických charakteristik a při kalibraci pouze na charakteristiky. Z výsledků vyplývá, že parametr Spa dosahuje lepších výsledků pokud jsou k dispozici časové řady odtoku.

Parametr Grd ukazuje, že automatická kalibrace dosáhla nejlepších výsledků, mezi další s dobrými výsledky patří strategie s časovými řadami i charakteristikami a strategie pouze s charakteristikami. V tomto případě charakteristiky půdní vlhkosti zlepšily parametr Grd, ale pouze v kombinaci s pozorovaným odtokem. Samostatná složka půdní vlhkosti parametr Grd nadhodnocuje přibližně o 10% až 20%.

**Tab. 5.3** Relativní rozdíl parametrů Spa a Grd modelu Bilan mezi expertní kalibrací a dalšími kalibračními strategiemi. Automatická, časové řady + charakteristiky a pouze charakteristiky jsou kalibrační strategie, které kombinují odtok (R), půdní vlhkost (SW) nebo odtok + půdní vlhkost (R + SW).

BP	Automatická kalibrace		Časová řada + charakteristiky				Charakteristiky				R + SW			
	mean	median	R mean	R median	SW mean	SW median	R + SW mean	R + SW median	R mean	R median	SW mean	SW median	R + SW mean	R + SW median
Spa	0.202	0.121	0.204	0.122	0.282	0.280	0.275	0.267	0.243	0.163	0.297	0.269	0.305	0.272
Grd	0.163	0.158	0.164	0.161	0.388	0.363	0.233	0.169	0.232	0.148	0.391	0.358	0.252	0.164

Hustota rozdělení relativních chyb v parametrech Spa a Grd oproti expertní kalibraci pro všechny kalibrační strategie je uvedena na Obr. 5.4. Opět platí, že chyby pro vybrané (nejlepší) kritériální funkce (OF) jsou mnohem nižší než pro ostatní OF. Zejména u parametru Spa je zřejmé, že u vybraných OF nedochází k přitahování do lokálních optim, což je evidentní u ostatních nevybraných OF (viz červené oblasti na Obr. 5.4).



**Obr. 5.4** Hustota relativních chyb v parametrech Spa (vlevo) a Grd (vpravo) na základě vybraných nejlepších OF (zelená plocha) a nevybraných (červená plocha). Tečkovaná čára odpovídá průměru vybraných nejlepších kritériálních funkcí, přerušovaná čára průměru OF zahrnujících časové řady a plná čára průměru OF, které nebyly vybrány.

## Vyhodnocení pro odtokové kvantily


Nakonec byla vyhodnocena efektivita kalibračních strategií pro nízké (Q20, 20% percentil) a vysoké průtoky (Q80, 80% percentil), která je uvedena v Tab. 5.4. V případě nízkých průtoků se výstup modelu zlepší, když se zohlední charakteristiky odtoku a zlepší se ještě více, když se to provede v kombinaci s charakteristikami půdní vlhkosti za předpokladu využití časových řad. Na druhou stranu se standardní automatická kalibrace zařadila mezi nejhorší OF. Obecně lze říct, že u vysokých

průtoků jsou rozdíly mnohem méně variabilní, přičemž automatická kalibrace je o něco lepší než kalibrace pro ostatní OF.

**Tab. 5.4** Relativní rozdíl v Q20 a Q80 pro odtok. Automatická, časové řady + charakteristiky a pouze charakteristiky jsou kalibrační strategie, které kombinují odtok (R), půdní vlhkost (SW) nebo odtok + půdní vlhkost (R + SW).

CHO	Automatická kalibrace		Časová řada + charakteristiky				Charakteristiky				R + SW			
	mean	median	R mean	R median	SW mean	SW median	R + SW mean	R + SW median	R mean	R median	SW mean	SW median	R + SW mean	R + SW median
Q20	0.224	0.172	0.225	0.181	0.568	0.570	0.391	0.323	0.354	0.299	0.545	0.565	0.482	0.439
Q80	0.075	0.056	0.073	0.057	0.182	0.159	0.114	0.087	0.141	0.106	0.221	0.173	0.155	0.127

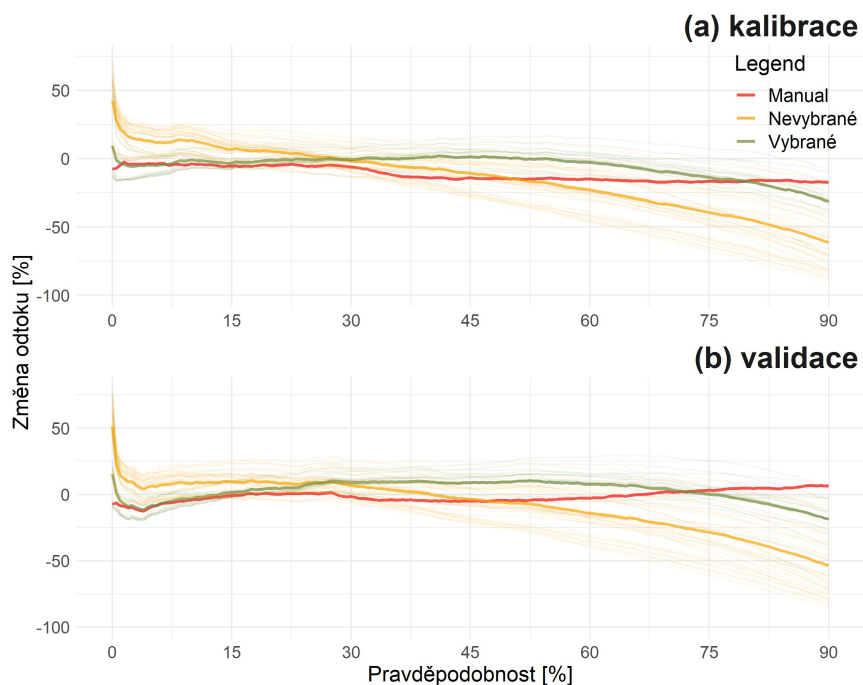
Rozdíl v chování mezi Q20 a Q80 je také zřejmý z hustoty pravděpodobnosti uvedené na Obr. 5.5, kde vybrané OF vedou k mnohem užší distribuci chyb než ostatní OF pro Q20, zatímco v případě Q80 je rozdíl velmi malý.



**Obr. 5.5** Hustota chyb charakteristik odtoku v Q20 (vlevo) a Q80 (vpravo) na základě vybraných nejlepších OF (zelená plocha) a ostatních (červená plocha). Tečkovaná čára odpovídá průměru vybraných nejlepších kritériálních funkcí, přerušovaná čára průměru OF zahrnujících časové řady a plná čára průměry OF, které nebyly vybrány.

## Vyhodnocení na základě čáry překročení

Pro vyhodnocení kalibrace a validace byla dále použita čára překročení, která ukazuje pravděpodobnost překročení jednotlivých hodnot (na grafu je relativní rozdíl modelovaného odtoku a odtoku pozorovaného). Výsledky jsou uvedeny na Obr. 5.6. Výsledkem expertní kalibrace (červená linie) je odtok, který dobře odpovídá pozorovaným datům a rozdíly v jednotlivých pravděpodobnostech se pohybují kolem 0. Významný rozdíl je možno konstatovat mezi vybranými OF (zelená linie) a nevybranými OF (oranžová linie). Obecně OF velmi podhodnocují nízké průtoky, kde pro vybrané OF 95. percentil je podhodnocen -49% odtoku pro kalibraci a -37% pro validaci a pro nevybrané OF 95. percentil je podhodnocen o -77% odtoku pro kalibraci a -75% pro validaci. Podle expertní kalibrace jsou nízké průtoky nadhodnoceny (95. percentil je 8% odtoku). I přes tato úskalí jsou vybrané kalibrační OF dobře fungující a přibližují docela dobře expertní kalibraci a pozorovaným datům, což lze pozorovat na Obr. 5.6, jak po kalibraci, tak v rámci validaci.



**Obr. 5.6** Čára překročení pro odtok v relativních hodnotách, pro kalibrační a validační část. Rozdíl odtoku v % (pozorovaný vs modelovaný odtok) a pravděpodobnost dosažení v %.

### Shrnutí kvality výstupů OF

Kalibrace hydrologického modelu Bilan byla provedena na základě různých kalibračních strategií. Bylo vytvořeno 52 kritériálních funkcí (OF), které zahrnovaly veličiny: odtok (R, R2), půdní vlhkost (SW, SW2) a odtok i půdní vlhkost (RSW, RSW2) ve formě časových řad nebo hydrologických charakteristik. OF byly hodnoceny pomocí kritériálních funkcí (GOF: good-of-fitness), nejistoty parametrů modelu Bilan (BP) a odchylek charakteristik odtoku (RS). Hodnocení bylo provedeno pro každé povodí a následně bylo vyhodnoceno, které OF se objevují nejčastěji. Soubor těchto vybraných OF je uveden v Tab. 5.5.

Ve skupině s nejlepší kvalitou výstupů pro všechna tři kritéria jsou:

- standardní automatická kalibrace,
- R2-mean-optim,
- R2-iqr-optim.

Je zřejmé, že informace o časových řadách jsou pro hydrologickou simulaci zásadní. Výsledky však také naznačují, že OF obsahující hydrologické charakteristiky se mohou řadit mezi nejlepší, a to pro relativně správný odhad parametrů hydrologického modelu i pro modelování různých kvantilů průtoku. Výsledky naznačují relativně dobrou shodu mezi modelovaným a pozorovaným odtokem.

Obdobně jako u [Pohrel et al. \(2012\)](#); [Pfannerstill et al. \(2014\)](#) se ukazuje, že pokud se využijí pro diagnostiku modelu velmi nízké kvantily průtoků, tak jsou ve většině nastavení modelu výrazně podceňovány.

Tato studie byla provedena na 20 povodích, což znamená, že odhad nemusí být tak robustní jako u studií, které zahrnují více povodí s různým vodním režimem umožňujícím lepší popis chování jednotlivých parametrů, hydrologických charakteristik nebo vybraných proměnných ([Addor et al., 2018](#)). Studie [Addor et al. \(2018\)](#) také uvádí, že hydrologické charakteristiky jsou obvykle více ovlivňovány klimatickými a topografickými vlivy než pokryvem, vlastnostmi půdy a geologií. Ačkoli se v práci nehodnotily jiné než hydroklimatické faktory, studie potvrdila důležitost klimatických faktorů, zejména těch, které souvisejí s půdní vlhkostí. Půdní vlhkost ovlivňuje zejména nízké průtoky a parametr (Grd) modelu Bilan svázaný s podzemní vodou.

Obdobně jako [Hrachowitz et al. \(2014\)](#) se ukázalo, že neomezené parametry kalibrování modelu vedou k širokému rozsahu nepravděpodobných hodnot a je nutné vyvažovat mezi automatizovanou kalibrací modelu a strategií využívající expertní znalosti a porozumění místním systémům. Hydrologické charakteristiky navíc značně zužují rozsah hodnot parametrů a dobře odpovídají parametrům kalibrovaným odborníkem. Měly by proto být brány v úvahu při kalibraci a diagnostice modelu, zejména se modelují extrémny, jak již navrhl [Pfanterstill et al. \(2014\)](#).

**Tab. 5.5** Nejlepší OF podle kriteriálních funkcí (goodness-of-fit GOF), parametrů hydrologického modelu (BP) a ukazatele vysokého a nízkého průtoku (RS). Časové řady, R-charakteristiky a SW-charakteristiky znamenají kombinaci časové řady nebo charakteristiky odtoku (R) a půdní vlhkosti (SW), jejich statistické ukazatele jsou průměr, mezikvartilové rozpětí (IQR) a sd. Žvolené nastavení je označeno (\*).


ID	Časová řada			R - charakteristiky			SW - charakteristiky			Vyhodnocení		
	R	SW		mean	IQR	sd	mean	IQR	sd	GOF	BP	RS
automatic	*									*	*	*
R2 - mean - sd				*		*					*	
R2 - mean - iqr				*	*						*	*
R2 - mean - optim	*			*						*	*	*
R2 - sd - iqr				*	*	*				*	*	*
R2 - sd - optim	*			*		*				*	*	*
R2 - iqr - optim	*			*	*					*	*	*
RSW - mean - mean				*			*			*	*	*
RSW - mean - iqr				*			*	*		*	*	*
RSW - sd - sd				*		*		*		*	*	*
RSW - optim - optim	*	*		*				*	*	*	*	*
RSW - optim - iqr	*	*		*				*	*	*	*	*
RSW - iqr - iqr				*	*			*		*	*	*
RSW2 - sd - sd - optim		*		*		*		*		*	*	*
RSW2 - optim - optim - sd	*	*		*				*	*	*	*	*
RSW2 - optim - optim - mean	*	*		*			*	*		*	*	*
RSW2 - optim - optim - iqr	*	*		*			*	*	*	*	*	*
RSW2 - optim - mean - sd	*	*		*			*	*	*	*	*	*
RSW2 - optim - iqr - sd	*	*		*			*	*	*	*	*	*

## 5.2 Odhad výparu pro Českou republiku

Hydrologický model Bilan slouží k vyhodnocení hydrologické bilance, pro výpočet bilance jsou důležitá vstupní data. Při kalibraci a validaci je v modelu Bilan nastavován výpočet pro potenciální evapotranspiraci. Evapotranspirace je důležitou součástí bilanční rovnice, která říká, že odtok je roven rozdílu srážky a evapotranspirace. Klimatické scénáře predikují nárůst teploty, a díky tomu je větší pravděpodobnost, že bude narůstat výpar z povrchu, z půdy a z vodních ploch. Cílem je odhadnout výpar z vodních ploch a porovnat s dalšími výsledky, případně s ČSN normou. Výpar může být odhadován více způsoby: pomocí DPZ, reanalyzovanými klimatickými daty, či pomocí statistických metod nebo jejich kombinací.

### Dlouhodobý vývoj

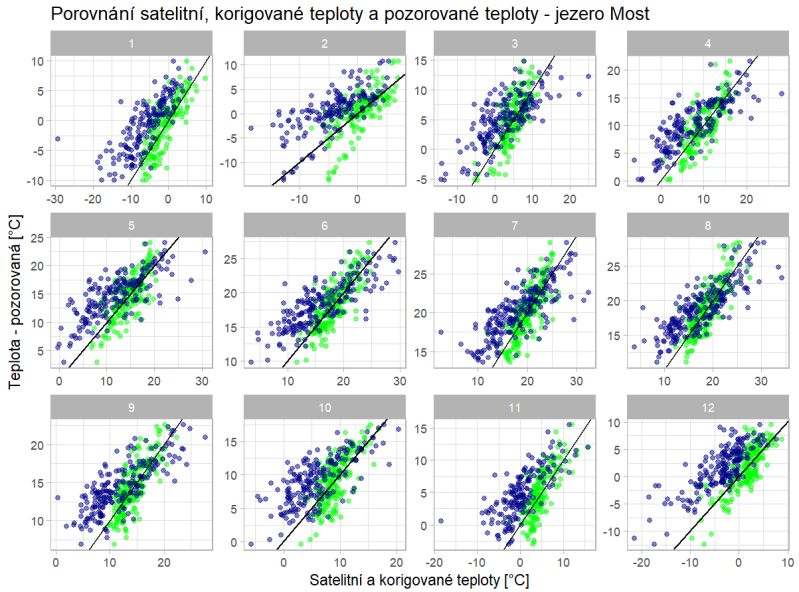
Na obrázku 5.7 je znázorněna časová řada (1957–2019) pro stanici Hlasivo, která provozuje dlouhodobé měření výparu z vodní hladiny. Z grafu je patrné, že v posledních desetiletích má výpar z vodní hladiny rostoucí charakter. V grafu jsou dále uvedeny ostatní stanice, které byly v práci použity. Tyto stanice mají však kratší dobu monitoringu. Dlouhodobý průměr výparu na stanici Hlasivo je 463 mm (duben–říjen), v posledních 5 letech je to však již 596 mm. Tento nárůst je prakticky na všech vodních plochách v České republice a má to významný dopad na vodní režim, především v letním období. Trend výparu ve stanici Hlasivo je statisticky významný na hladině významnosti 0,001. Pozorovaná data od roku 2005 pro jednotlivé stanice a veličiny jsou uvedeny v příloze 7.3.



**Obr. 5.7** Vyhodnocení pozorování výparu pro výparoměrné stanice (červeně: stanice Hlasivo) od roku 1957 do 2019.

### Korekce satelitních dat

V kapitole 7.5 byla porovnána satelitní data (produkt LST) s teplotami vzduchu. Pro lepší validitu produktu bylo vhodné udělat korekci satelitních dat. Na obrázku 5.8 je porovnání satelitních a korigovaných dat (zelené body) a odvozené teploty vzduchu (modré body) pro jezero Most. Pomocí



**Obr. 5.8** Porovnání odvozených teplot vzduchu a korigovaných dat, modré body – produkty LST, zelené body – korigovaná data.

odvozených dat bylo možné udělat porovnání pro celý rok, s pozorováními daty by to bylo možné jenom od dubna do října. Korekce dat byla provedena pomocí lineární regrese, kde závislá proměnná byla teplota z vodní nádrži Jezero most a nezávislá proměnná (prediktor) byla teplota z produktu LST. Z grafu je patrné, že lineární model podstatně přibližuje satelitní data pozorování, nicméně stále je zde prostor pro zlepšení.


Po korekci dat byla data použita ve vzorcích pro odhad výparu, které byly navrženy ve studii [Beran et al. \(2019a\)](#). V případě této studie vstupuje do vzorců pouze teplota vzduchu. V tomto případě to byly korigované teploty produktu LST. Vzorce vznikly na základě dat z výparoměrné stanice Hlasivo pro období 1957–2017. Všechny vzorce byly validovány ve stanici Tišice 1957–1974 na stanici Hlasivo 1995–2005. Jedná se o vzorce:

$$E2 = 0,1077 * T_v^{1,246}, \quad (5.1)$$

$$EA = (0,2128 * T_v) - 0,3571, \quad (5.2)$$

$$ES = 0,1177 * T_v^{1,1646}, \quad (5.3)$$

kde  $E2, EA$  a  $ES$  jsou identifikátory vzorců,  $T_v$  je teplota vzduchu a 0,1077; 1,246; 0,2128; 0,3571; 0,1177; 1,1646 jsou konstanty.



Obr. 5.9 Vyhodnocení průměrného denního výparu pro vodní nádrž jezero Most.

Na obrázku 5.9 je vypočtena průměrná denní hodnota výparu podle navrhovaných vzorců pro celý rok. V jednom měsíci je 6 boxplotů, které popisují výpar na základě odvozených a satelitních dat. Podle předpokladů je vidět, že nejnižší výpar je v zimních měsících a nejvyšší v letních měsících. Z výpočtu je vidět, že vzorec s identifikátorem E2 hodnoty nadhodnocuje, nicméně vzorec EA udává záporné hodnoty v zimních měsících. Podle výsledků lze říct, že vzorec ES je nejstabilnější, protože v zimních měsících nevykazuje záporné hodnoty a v letních měsících nenadhodnocuje hodnoty výparu jako vzorec E2. Ve všeobecnosti lze říct, že satelitní data s korekcí dokážou dobře vystihnout průběh teplot vzduchu pro lokalitu jezero Most.


Průměrné měsíční hodnoty výparu jsou uvedeny v Tab. 5.6, kde jsou viditelné záporné hodnoty výparu v zimních měsících (vypovídající o nevhodnosti modelu pro zimní měsíce) a nejvyšší hodnoty výparu jsou vypočteny v letním měsíci červenec, kdy se průměrné hodnoty pohybují kolem hodnoty 4 mm/den. V případě jezera Most (plocha 3,11 km<sup>2</sup>) znamená 1 mm/den ztrátu výparem cca 36 l.s<sup>-1</sup>. Lze tedy jednoznačně konstatovat, že dlouhodobý nárůst výparu o více než 20 % na stanici Hlasivo (změny lze očekávat na celém území ČR) s sebou nesou významné dopady na vodní nádrže a vodní plochy v ČR obecně.

Logickým krokem je aplikace odvozených vzorců na vodních nádržích (viz Obr. 5.10), kde průběh je podobný jako u vodní nádrže jezero Most. Vzorce EA opět vykazují záporné hodnoty v zimních měsících a vzorce E2 nadhodnocují hodnoty výparu. Při aplikaci na více lokalitách (vodních nádržích) jsou výsledky na základě využití vzorců mezi sebou více rozkolísané. Výsledky jsou podobné pro vzorce EA a ES, a to při využití satelitních dat, tak pozorování. Jak již bylo zmíněno, vzorce jsou navrženy pro stanici Hlasivo a validované na stanici Tišice a Hlasivo. Rozkolísanost může být tedy způsobena prostorovou variabilitou vodních nádrží, nadmořskou výškou nebo nevhodnou korekcí u satelitních dat.



Tab. 5.6 Výpar v mm/den pro jezero Most na základě jednotlivých vzorců.

Měsíc	E2_sat	E2_poz	EA_sat	EA_poz	ES_sat	ES_poz
I	0,43	0,48	-0,53	-0,58	0,42	0,46
II	0,39	0,5	-0,26	-0,29	0,38	0,48
III	0,93	0,86	0,71	0,48	0,87	0,81
IV	1,96	1,68	1,79	1,51	1,76	1,52
V	3,09	2,82	2,77	2,54	2,7	2,48
VI	4,03	3,66	3,53	3,22	3,47	3,17
VII	4,57	4,13	3,94	3,6	3,91	3,55
VIII	4,21	3,94	3,67	3,46	3,62	3,4
IX	2,69	2,83	2,69	2,50	2,62	2,5
X	1,71	1,65	1,58	1,49	1,55	1,5
XI	0,8	0,81	0,65	0,46	0,75	0,76
XII	0,44	0,53	-0,02	-0,28	0,44	0,51



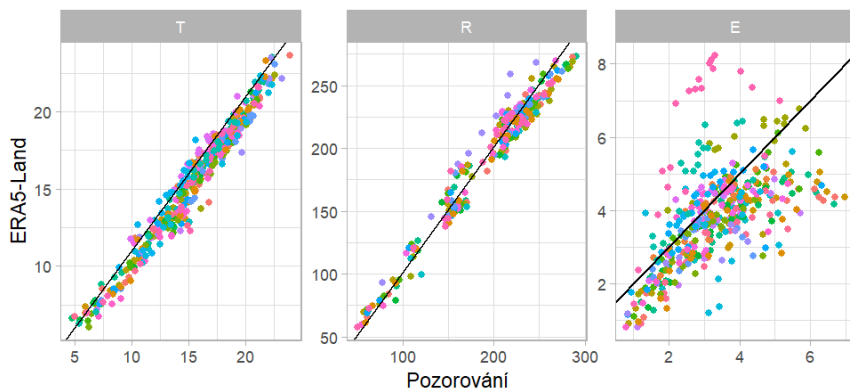
Obr. 5.10 Vyhodnocení výparu pro navrhované vodní nádrže v jednotlivých měsících.

V práci se dále sjednotila data nepřímého měření s pozorovanými daty, byla vybrána reanalyzovaná data klimatu (produkt ERA5-Land) a veličin, které odpovídaly veličinám pozorovaným na jednotlivých stanicích. Na těchto datech byly navrženy lineární a random forest modely s primárním cílem: odhad výparu z vodní hladiny pomocí jednoho modelu pro Českou republiku.

## Porovnání reanalýzy klimatu s pozorovanými daty

Reanalýza klimatu ERA5-Land byla zvolena kvůli své komplexnosti (obsahuje řadu relevantních proměnných, pouze vlhkost vzduchu byla dopočítaná z August-Roche-Magnus aproximace) a relativně podrobnému prostorovému rozlišení (9 km x 9 km), viz kapitola 3.5. Porovnání teploty, radiace

a evapotranspirace z reanalízy ERA5-Land a pozorovaných dat je uvedena na Obr. 5.11. Teplota i radiace jsou zjevně simulovány relativně dobře, nicméně u teploty je patrně poměrně významné podhodnocení, které na druhou stranu může být jednoduše odstraněno i pomocí lineárního modelu. Největší chyby v reanalýze jsou patrné pro evapotranspiraci, pro kterou je rovněž možné konstatovat systematické podhodnocení. Nicméně rozptyl chyb je značný a pro část stanic dochází i k podstatnému nadhodnocení.



**Obr. 5.11** Porovnání pozorovaných dat (poz) a reanalízy ERA5-Land pro teplotu (T), radiaci (R) a evapotranspiraci (E). Barvami jsou odlišeny hodnoty pro jednotlivé stanice.

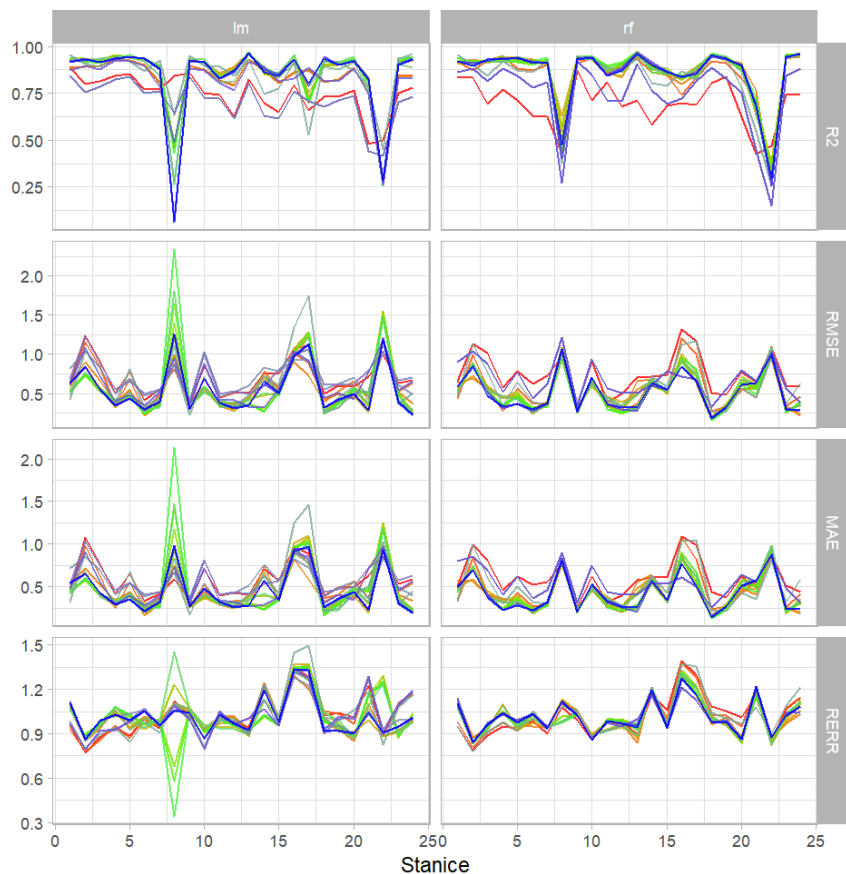
## Vyhodnocení modelů pro odhad výparu

Modely byly vyhodnoceny a porovnány pomocí kritériálních funkcí RMSE, R2, MAE a RERR viz Obr. 5.12. Podle výsledků je patrné, že RF modely se dokážou lépe přizpůsobit datům než LM modely. RF modely jsou u všech kritériálních funkcí více konzistentní než LM modely. Z grafu a výsledků je také patrné, že pro některé stanice modely nedosahují dobrou shodu.

U všech LM modelů lze pozorovat odlehle hodnoty, což se děje také u RF modelů, ale v menším měřítku. Aby se zjistilo, která povodí obsahují tyto odlehle hodnoty, vypočítalo se maximum pro danou kritériální funkci a určila se limitní hodnota, od které lze odvozovat tyto odlehle hodnoty. U kritériální funkce RMSE jsou viditelné 3 stanice, které vykazovaly vysoké hodnoty RMSE. Pro zjištění odlehle hodnot byla stanovena hodnota 1,5, která odpovídala cca 70 % maximální hodnoty. Tímto způsobem byly identifikovány stanice: Hlasivo, Praha-Podbaba a jezero Most. Podobný průběh má kritériální funkce R2, která byla vyhodnocena obdobně a limitní hodnota byla stanovena na hodnotu 1. Na základě toho se identifikovaly stanice: Dukovany, Hlasivo, Praha-Libuš, Praha-Podbaba a jezero Most. Pro kritériální funkci RERR, kde  $RERR > 1,3$  to jsou stanice: Hlasivo, Praha Libuš, Praha Podbaba a jezero Most.

Na základě této analýzy lze konstatovat, že odvozené modely jsou neporovnatelné ve stanicích: Hlasivo, jezero Most a Praha-Podbaba.

Pomocí vyhodnocení (viz kapitola 4.1, 4.2), které bylo provedeno metodou seřazování se vybraly nejlepší 3 lineární a 3 random forest modely. Vybrané modely s průměrnými hodnotami kritériálních funkcí jsou uvedeny v Tab. 5.7.




**Obr. 5.12** Vyhodnocení modelů podle kritériálních funkcí (RMSE, R2, MAE, RERR). Barevně jsou odlišeny jednotlivé modely.

**Tab. 5.7** Průměrné hodnoty kritériálních funkcí vybraných modelů.

id	R2	RMSE	MAE	RERR	MOD
11	0.85	0.58	0.47	1.04	lm
17	0.84	0.56	0.45	1.01	lm
18	0.84	0.56	0.46	1.02	lm
10	0.86	0.51	0.42	1.01	rf
17	0.86	0.51	0.42	1.02	rf
18	0.86	0.51	0.42	1.02	rf

## Vybrané regresní vzorce

Mezi nejlepší 3 lineární modely dle všech kritériálních funkcí patří LM 11, 17 a 18 a mezi nejlepší random forest modely RF patří 10, 17 a 18. Vybrané modely jsou zobrazeny na Obr. 5.13. Průměrné hodnoty kritériálních funkcí si jsou velmi podobné (Tab. 5.7). Průměrná hodnota RMSE pro vybrané lineární modely je 0,56, minimální hodnota je 0,22. Vybrané random forest modely měly průměrnou hodnotu RMSE 0,52 a minimální hodnotu 0,18. Ukázalo se také, že modely, které byly navrženy na základě postupné regrese dosáhly horších výsledků než modely, které byly sestaveny ručně na základě analýzy dat (mezi vybranými 3 lineárními modely nejsou) a testování jejich nastavení, což bylo časově náročné. Z tohoto pohledu některé modely sestavené postupnou regresí jsou použitelné. Lineární modely byly dále doplněny o LM 4, který také vykazoval dobré výsledky a odvozená vzorec je pro praxi využitelnější.



Obr. 5.13 Vyhodnocení modelů podle kritériálních funkcí (RMSE, R2, MAE, RERR). Barevně jsou odlišeny vybrané modely.

Vybrané regresní vzorce na základě lineárních modelů:

1. LM11:

$$E1 = 45,84 + (0,173T \cdot (-0,004R))^{0,0008} - 0,183D - 0,0002P - 0,0002nmv - 0,475Y, \quad (5.4)$$

2. LM17:

$$E2e = 16,97 + 0,082W + (0,235T \cdot (-0,263D))^{0,007} + 0,008R - 0,0003nmv - 0,368Y + 0,063X, \quad (5.5)$$

3. LM18:

$$E3 = 17,33 + 0,055X - 0,367Y - 0,0003nmv + (0,2134T * (-0,277D))^{0,009} + 0,008R, \quad (5.6)$$

4. LM4:

$$E4 = 19,82 + 0,302ST + 0,006R - 0,170D - 0,419Y, \quad (5.7)$$

kde:

- E1, E2e, E3 a E4 jsou identifikátory vzorců pro výpar,
- T ... °teplota vzduchu ve 2 m,
- ST ... ° povrchová teplota,
- P ... °tlak,
- W ... °rychlost větru,
- R ... °radiace,
- D ... °rosný bod,
- H ... °relativní vlhkost,
- nmv ... °nadmořská výška,
- Y ... °zeměpisná délka,
- X ... °zeměpisná šířka.

### Vybrané random forest

Vybrané random forest modely jsou v praxi využitelné například v prostředí R (příklad je uveden v boxu 4.6). Prediktory pro výpočet výparu do vybraných modelů jsou (popis veličin je uveden výše):

1. RF 10:  $W + T + ST + R + D + P + H + nmv + Y + X$ ,
2. RF 17:  $W + (T * D) + R + nmv + Y + X$ ,
3. RF 18:  $X + Y + nmv + (T * D) + R$ .

### Aplikace modelů na vodní nádrže

Pro testování byly vybrány již popsané nejlepší modely LM modely (LM 11, LM 17, LM 18 a LM 4), RF modely (RF 10, RF 17, RF 18) a vybrané vzorce, které se aplikovaly na vybrané vodní nádrže v České republice (33), květen–říjen. Na Obr. 5.14 jsou zobrazeny výpary na jednotlivých vodních nádržích, kde oranžová barva ukazuje aplikaci vzorců ze studie [Beran et al. \(2020\)](#), modrá aplikaci vzorců založených na lineárních modelech a zelená potom na základě random forest modelů. Lze vidět, že modely založené na LM dávají největší rozptyl ve výsledcích a je v nich nejméně postihnuto lokální vliv. V rámci letních měsíců lze pozorovat významný nárůst dle všech modelů. V příloze 7.10 jsou uvedeny výsledky pro vodní nádrž Orlick.




**Obr. 5.14** Výpar z vodních nádrží pro vybrané vzorce a jednotlivé měsíce (květen–říjen), modře je výpar na základě lineárních modelů, zeleně: random forest a oranžově ze studie [Beran et al. \(2020\)](#).

Vliv nadmořské výšky a vybraných vzorců ES (oranžově), LM11 (modře) a RF10 (zeleně) jsou na Obr. 5.15. Pro zobrazení vztahu byl zvolen lineární trend, lze však pozorovat podkladové vrstvy (šedě), že mají významný lokální charakter. Sklon jednotlivých odvozených průměrů je však podobný.

Dále byly porovnány průměrné hodnoty výparu z vodní hladiny pro zvolené nádrže s hodnotami, které jsou uvedeny v manipulačních řádcích nádrže (výpočet výparu v MR je většinou dle ČSN 75 2405). Výpar pro vodní hladinu v vodní nádrže Orlík je na Obr. 5.16, kde se projevuje významný rozdíl mezi hodnotami na základě normy (černá linie) a ostatních odvozených hodnot na základě vzorců (modře: lineární modely, zeleně: random forest modely a oranžově na základě studie [Beran et al. \(2020\)](#)). Tento rozdíl je dán:

1. ČSN vychází z neaktuálních klimatických podmínek.
2. Vizualizované hodnoty jsou za období 2011–2019.

Slabá červená linie potom zobrazuje hodnoty potenciální evapotranspirace vypočteny modelem Bilan dle Oudina za období 2011–2019, která relativně odpovídá odvozeným vzorcům, především v období



**Obr. 5.15** Vztah výparu a nadmořské výšky na základě odvozených vzorců (modrá: lineární model, zelená random forest a oranžová dle studie [Beran et al. \(2020\)](#)).

květen–červenec, potom se hodnoty trochu liší. Rozdíl (výpar dle normy a odvozený výpar) na vodní nádrži Orlík ve vegetačním období činí téměř 3 miliony  $\text{m}^3$  (cca  $190 \text{ L s}^{-1}$ ).


Průměrné hodnoty výparu z vodní hladiny pro vybrané vodní nádrže jsou zobrazeny v Tab. 5.8, kde lze pozorovat rozptýl hodnot dle různých typů výpočtu (tučně jsou vybrané vzorce).

### Shrnutí výparu z vodních ploch

Pro odhad výparu pro vodní nádrže byly použité lineární modely (LM), random forest modely (RF) a vzorce ze studie [Beran et al. \(2019a\)](#). Lineární modely byly sestaveny pro různé prediktory z reanalýzy klimatu ERA5-Land (teplota vzduchu, povrchová teplota, tlak, rychlost větru, radiace, rosný bod, relativní vlhkost, nadmořská výška a zeměpisná délka, šířka) 2 metodami, a to: (i) ručně, (ii) pomocí postupné regrese. Modely, které byly navrženy na základě postupné regrese nebyly tak úspěšné jako modely, které byly sestaveny ručně (ale testování je časově náročné). Z výsledků také vyplynulo, že i některé modely, které pro stanovení prediktorů využily postupné regrese jsou v některých případech použitelné, např. pro kritériální funkci RMSE nejlépe vyšel model z postupné regrese s málo vstupy LM4. Stejně prediktory byly následně aplikovány pro random forest modely.

Na základě vyhodnocení dle kritériálních funkcí ( $R^2$ , RMSE, MAE a RERR) a pomocí metody seřazování byly vybrány 3+(1) lineární modely a 3 RF modely. Z každé skupiny (LM, RF) byl doporučen 1 model, lineární modely byly doplněny o další jeden, který je méně náročný na vstupy (využitelnější pro praxi) a nejlépe vyšel dle hodnocení RMSE.

Vybrané modely byly aplikovány na vybrané vodní nádrže v České republice, pro které byly vstupem výstupy z ERA5-Land, nadmořská výška a souřadnice těžiště vodní nádrže. Výsledky hodnot výparu z vodní hladiny (viz Tab. 5.8) byly porovnány se studií [Beran et al. \(2019a\)](#) a pro vodní nádrž Orlík také s údaji uvedených v manipulačním řádu (výpočet výparu dle ČSN).



Obr. 5.16 Průměrné měsíční hodnoty výparu pro vodní nádrž Orlick (modrá: lineární model, zelená random forest, oranžová dle studie Beran et al. (2020) a černá: výpočet dle ČSN v MŘ).

Tab. 5.8 Průměrné hodnoty výparu pro vybrané vodní nádrže dle jednotlivých odvozených a vybraných vzorců.

Vodní nádrž	LM_11	LM_17	LM_18	LM_04	RF_07	RF_10	RF_17	E2	EA	ES
Mariánské Lázně	456.57	406.37	407.53	460.76	445.22	437.55	448.52	477.72	432.78	422.16
Medard	517.42	419.89	420.58	445.50	468.76	451.30	465.48	500.78	452.07	441.21
Nesyt	734.47	738.63	738.35	720.95	679.38	695.21	694.19	664.92	585.42	575.53
Rožmberk	621.84	577.57	579.15	581.44	570.79	555.14	578.33	568.95	508.66	497.39
Staňkovský ryb	629.94	570.13	570.85	586.79	568.76	551.65	565.30	551.73	494.48	483.24
Bezdrev	629.52	568.50	568.80	564.59	558.68	538.64	569.91	561.12	502.30	490.99
jezero Most	507.42	470.84	468.07	449.22	532.22	511.08	541.66	559.74	500.68	489.70
Bedřichov	302.96	379.47	381.93	398.94	444.41	441.87	443.24	505.53	456.25	445.21
Brno	612.95	625.37	626.29	606.97	622.80	610.59	628.59	606.61	538.73	528.04
Dalešice	617.56	606.14	606.28	607.93	618.48	598.47	611.63	580.57	517.75	506.79
Harcov	437.17	405.10	408.10	404.30	449.35	446.11	452.36	510.73	460.42	449.45
Hněvkovice	616.43	565.34	566.31	570.69	558.63	545.28	567.27	562.45	503.41	492.08
Nové Mlýny dolní	715.26	723.92	724.69	703.13	677.00	691.64	691.65	660.69	582.02	572.08
Nové Mlýny horní	716.69	718.96	719.29	696.68	672.25	685.74	686.22	657.27	579.29	569.29
Nové Mlýny střed	719.17	718.65	719.25	693.89	672.07	684.81	685.73	656.59	578.74	568.74
Orlick	566.86	536.74	536.87	551.54	549.83	539.10	556.52	559.60	500.97	489.72
Přísečnice	392.88	364.87	363.56	404.01	441.61	427.91	448.00	467.62	424.11	413.75
Rozkoš	483.40	480.53	481.91	453.28	514.46	491.30	516.19	548.99	491.97	480.90
Skalka	485.34	421.82	425.00	460.64	473.57	457.84	472.98	511.70	461.32	450.28
Slezská Harta	455.25	487.71	483.71	463.05	512.08	480.82	508.54	521.91	469.58	458.62
Stráž p Ralskem	447.56	439.12	441.68	430.19	461.76	463.61	464.46	543.57	487.66	476.50
Těrlicko	510.93	547.67	546.09	492.15	534.87	509.07	539.67	565.74	506.05	494.77
Vranov	646.21	617.51	616.28	621.22	604.75	589.54	601.34	578.05	515.76	504.75
Vrané	547.91	543.23	540.54	543.30	512.61	522.06	513.21	585.82	522.35	511.19
Vir I	521.65	513.87	512.16	510.30	534.58	504.01	531.22	527.09	473.85	462.88
Hracholusky	543.98	491.44	490.70	513.37	496.38	491.84	501.45	538.24	483.33	472.14
Jesenice	507.08	421.91	424.18	456.80	472.22	454.73	469.59	501.53	452.80	441.87
Kružberk	508.67	503.72	499.90	480.90	518.81	490.99	514.08	518.63	466.94	455.95
Lipno I	586.06	508.19	510.88	541.07	498.10	475.70	518.89	494.21	446.79	435.86
Nechranice	493.24	479.92	476.84	465.56	491.50	491.00	502.12	566.56	506.24	495.28
Římov	625.90	558.38	559.47	564.04	553.54	527.29	559.20	541.27	485.95	474.67
Švihov	546.86	527.77	526.51	533.85	513.27	507.06	513.05	555.11	497.31	486.04
Žehuňský ryb	536.57	564.87	563.07	548.24	544.56	549.11	544.17	611.53	543.15	532.21



## Diskuze a závěr

Disertační práce je zaměřena na vyhodnocení hydrologické bilance na nepozorovaných povodích a je zaměřena především na posouzení různých kalibračních strategií modelu hydrologické bilance Bilan a upřesnění výparu z vodní hladiny, který významně hydrologickou bilanci ovlivňuje. Modelování hydrologických veličin s sebou nese mnoho otázek, přístupů a nejistot.

Na základě výzkumných cílů se diskuze zaměřuje na následující otázky:

- Které kalibrační strategie jsou nejúspěšnější?
- Je kalibrace hydrologického modelu Bilan možná pouze s použitím hydrologických charakteristik?
- Jaká je přidaná hodnota hydrologických charakteristik a odhadů vlhkosti půdy při kalibraci konceptuálního hydrologického modelu?
- Do jaké míry zlepšují hydrologické charakteristiky kalibraci hydrologického modelu Bilan?
- Jakým způsobem je možno odhadnout výpar pro vodní plochy?

Klíčovou otázkou první části práce je, jaký vliv mají hydrologické charakteristiky, a jestli tyto charakteristiky mohou zlepšit modelování hydrologické bilance a samotnou kalibraci hydrologického modelu. Pro samotné vyhodnocení bylo vybráno 20 povodí v různých částech České republiky s průměrnou plochou 454 km<sup>2</sup> a bez významného antropogenního vlivu (bez významných vodních nádrží a významných odběrů/vypouštění vody) na odtokový režim.

Kalibrace hydrologického modelu Bilan byla provedena na základě 4 strategií: (i) expertní kalibrace, (ii) automatická kalibrace, (iii) kalibrace na základě časových řad a hydrologických charakteristik a (iv) kalibrace na základě hydrologických charakteristik. Zařazení hydrologických charakteristik doporučují i některé zahraniční studie (McMillan, 2021). Hydrologické charakteristiky byly reprezentovány: průměrem (mean), směrodatnou odchylkou (sd), mezikvartilovým rozpětím (IQR), M-denními vodami a případně další funkcí. Vstupní data byla doplněna o modelované půdní vlhkosti půdy z modelu SoilClim a bylo vytvořeno 52 kritériálních funkcí (OF), které zahrnovaly veličiny: odtok (R, R2), půdní vlhkost (SW, SW2) a odtok i půdní vlhkost (RSW, RSW2) ve formě časových řad nebo hydrologických charakteristik. Jednotlivé strategie a povodí byly vyhodnoceny prostřednictvím porovnání modelovaného a pozorovaného odtoku (GOF), nejistoty parametrů modelu Bilan (BP) a odchylek charakteristik odtoku (RS). Expertní kalibrace byla brána jako referenční.

Z výsledků je zřejmé, že informace o časových řadách (především průtoku) jsou pro hydrologickou simulaci zásadní. Kalibrace modelu pouze na základě hydrologických charakteristik a půdní vlhkosti s sebou často nese řadu úskalí a lze ji doporučit pouze pokud nejsou k dispozici pozorované průtoky. Na druhou stranu se mezi vybrané OF dostalo z 52 OF na základě hodnocení (GOF, BP a RS) 7 kalibrací, které neobsahovaly časové řady.

Také se ukázalo, že mezi nejlepší kalibrace patří standardní automatická kalibrace a vybrané OF R2-mean-optím (časová řada odtoku a charakteristika odtoku), R2-iqr-optím (časová řada odtoku a mezikvartilové rozpětí). Výsledky však také naznačují, že OF obsahující hydrologické charakteristiky se mohou řadit mezi nejlepší, a to pro relativně správný odhad parametrů hydrologického modelu i pro modelování různých kvantilů průtoku. Obdobně jako u Pokhrel et al. (2012); Pfannerstil et al. (2014) se ukazuje, že pokud se využijí pro diagnostiku modelu velmi nízké kvantily průtoků, tak jsou ve většině nastavení modelu výrazně podceňovány. Dále bylo potvrzeno, obdobně jako

Hrachowitz et al. (2014), že neomezené parametry kalibrování modelu vedou k širokému rozsahu nepravděpodobných hodnot a je nutné vyvažovat mezi automatizovanou kalibrací modelu a strategií využívající expertní znalosti.

Studie Addor et al. (2018) také uvádí, že hydrologické charakteristiky jsou obvykle více ovlivňovány klimatickými a topografickými vlivy než pokryvem, vlastnostmi půdy a geologií. Ačkoli se v práci nehodnotily jiné než hydroklimatické faktory, studie potvrdila důležitost klimatických faktorů, zejména těch, které souvisejí s půdní vlhkostí. Půdní vlhkost ovlivňuje zejména nízké průtoky a parametr (Grd) modelu Bilan svázaný s podzemní vodou.

## Odhad výparu pro Českou republiku

Hlavním cílem odhadu výparu z vodní hladiny bylo odvození univerzálního vztahu pro celé území České republiky. Stanovení výparu pro vodní plochy je komplikované, protože prakticky žádné vodní plochy nemají pozorovaná data. Z tohoto důvodu je stanovení založeno na odhadu pomocí statistických metod.

Výběr výparoměrných stanic byl proveden v rámci projektu Beran et al. (2020). Pro stanovení výparu byla důležitá kategorizace vodních ploch dle Quitta a nadmořské výšky. Na základě kategorizace se dalo očekávat, že stanice, kde jsou pozorovaná data budou mít podobné klimatické podmínky jako vodní nádrže. Ve vybraných 22 stanicích jsou EWM výparoměry, které udávají hodnotu výparnosti, ve stanici Hlasivo je srovnávací výparoměr a na jezeru Most je umístěn plovoucí výparoměr, které udávají hodnotu výparu.

Pro odvození byla použita data z reanalýzy klimatu ERA5-Land, která byla zvolena z důvodu jejich komplexnosti, dostupnosti, vysokému prostorovému rozlišení, dlouhé časové řadě a příznivé manipulaci. Do výsledků byla dopočtena relativní vlhkost vzduchu na základě August-Roche-Magnus aproximace. Data reanalýzy klimatu byla exportována pro stanice a vodní plochy.

Odvození vztahu pro výpar bylo provedeno na základě metody vícenásobné lineární regrese, kde se hledaly hodnoty závislé proměnné (výparu) na základě dvou nebo více proměnných (prediktorů: teplota vzduchu, povrchová teplota, vítr, radiace, rosný bod, tlak, nadmořská výška, zeměpisná šířka, délka a dopočtená vlhkost vzduchu). Sestrojování vzorců bylo děláno: (i) ručně, kdy vyhodnocování probíhalo pomocí AIC parametru a pro vizuální diagnostiku sloužil kvantil-kvantilový graf-QQ, tento způsob byl časově náročný, (ii) pomocí postupné regrese, kde vstupují prediktory postupně a vznikají modely od jedné po X-zvolených proměnných, tato metoda není časově náročná. Pro postižení nelineárních vztahů byla použita random forest regrese. Modely lineární a random forest regrese byly validovány pomocí křížové validace a vyhodnoceny na základě kritériálních funkcí (R2, RMSE, MAE a RERR). Nakonec byly vybrány 3(+1) LM modelů a 3 RF modely. Modely obsahovaly velké množství nezávislých proměnných (6–7), což může vést k přefitování modelu, a proto byl dále vybrán další model, který vycházel nejlépe pro kritériální funkci RMSE a obsahuje pouze 4 nezávislé proměnné a je tedy uživatelsky přívětivější.

Ukázalo se, že v ručně odvozených modelech se více objevovaly geomorfologické informace (nadmořská výška, poloha) na rozdíl od modelů sestavených pomocí metody postupné regrese. Při porovnání lineární a random forest regrese bylo zjištěno, že LM mají mnohem větší variabilitu ve výsledku oproti random forest modelům. Výhoda random forest modelů je jejich adaptace, ale problémem může být následná interpretace výsledků.

Pro vybrané vodní plochy a vybrané vzorce byly vypočteny na základě dat reanalýzy klimatu ERA5-Land hodnoty výparu za období 1981–2019. Pro vodní nádrž Orlík byly tyto hodnoty porovnány s výparem z vodní nádrže dle manipulačního řádu (výpar dle ČSN). Dlouhodobě se ukazuje, že je výpar na vodních nádržích mnohem vyšší než se často v manipulačních řádech uvádí. Vypočtené hodnoty výparu se také porovnal s hodnotou vypočtené evapotranspirace dle metody Oudin et al. (2010)

a výsledky byly srovnatelné. Z toho vyplývá, že by bylo vhodné do modelu Bilan přidat parametr, který by udával procento vodních ploch v povodí. V těchto částech povodí by byl poté aktuální výpar roven vypočtené potenciální evapotranspiraci případně by se mohl využít jeden odvozených vzorců (E1 mnohem více reflektuje lokální podmínky), které jsou:

$$E1 = 45,84 + (0,173T \cdot (-0,004R))^{0,0008} - 0,183D - 0,0002P - 0,0002nmv - 0,475Y, \quad (6.1)$$

případně:

$$E4 = 19,82 + 0,302ST + 0,006R - 0,170D - 0,419Y, \quad (6.2)$$

kde:

- E1, E2e, E3 a E4 jsou identifikátory vzorců pro výpar,
- T ... °teplota vzduchu ve 2 m,
- ST ... ° povrchová teplota,
- P ... °tlak,
- W ... °rychlost větru,
- R ... °radiace,
- D ... °rosný bod,
- H ... °relativní vlhkost,
- nmv ... °nadmořská výška,
- Y ... °zeměpisná délka,
- X ... °zeměpisná šířka.

Práce ověřila možnosti využití hydrologických charakteristik a půdní vlhkosti na nepozorovaných povodích a je zřejmé, že při dodání dalších vstupních informací do modelu vedou k věrohodnějším výsledkům. Samotné využití hydrologických charakteristik pro kalibraci modelu je použitelné, ale je potřeba počítat s určitou nejistotou ve výsledcích. Na druhou stranu takto nakalibrované modely mohou při simulacích či simulacích dopadů změny klimatu dát odpověď, jaké jsou či mohou být trendy jednotlivých veličin hydrologické bilance. Samotný model Bilan by mohl být doplněn o parametr zastoupení vodních ploch v povodí a následného přepočtu aktuálního výparu. Upřesněné hodnoty výparu z vodních hladin mohou mít aplikaci například v systému HAMR, který s touto hodnotou počítá.



# Literatura

- Addor, N., Nearing, G., Prieto, C., et al. (2018) A ranking of hydrological signatures based on their predictability in space. *Water Resources Research*, 54(11), 8792–8812.
- Akaike, H. (1987) Factor analysis and AIC. In *Selected papers of hirotugu akaike*, Springer, 371–386.
- Alain, R., Kenneth, H., Carmelo, A., C., Paul, C. (2018) *Annual Report*, volume 1. Eumetsat, Germany.
- Andrews, F., Guillaume, J. (2018) *hydromad: Hydrological Model Assessment and Development*. R package version 0.9–26.
- Andrews, F., Croke, B. F., Jakeman, A. J. (2011) An open software environment for hydrological model assessment and development. *Environmental Modelling & Software*, 26(10), 1171–1185.
- Anděl, J. (2002) *Základy matematické statistiky*. Univerzita Karlova v Praze, Matematicko-fyzikální fakulta.
- Bárdossy, A. (2007) Calibration of hydrological model parameters for ungauged catchments. *Hydrology and Earth System Sciences Discussions*, 11(2), 703–710.
- Barrett, E. C., Curtis, L. F. (1999) *Introduction to environmental remote sensing*. Psychology Press.
- Becker, A., Serban, P. (1990) Hydrological models for water-resources system design and operation. Technická zpráva, Organizaci6n Meteorol6gica Mundial.
- Beran, A. (2019) Zm6ny hydrologick6 balance vlivem klimatick6 zm6ny a moznosti adapta6n6ch opatren6. *6esk6 zem6d6lsk6 univerzita v Praze*.
- Beran, A., Hanel, M., Nesl6dkov6, et al. (2013) Climate change impacts on water balance in Western Bohemia and options for adaptation. *Vodohospod6rsk6 technicko-ekonomick6 informace*, (55), 4.
- Beran, A., Fialov6, P., Kožitn, R., Melišov6, E., Bl6cher, J., and Bašta, P. (2019a) Odvození vzorců pro výpočet výparu, využití dálkového průzkumu Země pro výpočet výparu. *Souhrnn6 v6zkumn6 zpr6va za rok 2018*.
- Beran, A., Kašp6rek, L., Vizina, A., Šuh6jkov6, P. (2019b) Ztr6ta vody výparem z voln6 vodn6 hladiny. *Vodohospod6rsk6 technicko-ekonomick6 informace*, 61(4), 12–18.
- Beran, A., Fialov6, P., Kožitn, R., Melišov6, E., Bl6cher, J., and Bašta, P. (2020) Vzorce pro výpočet výparu z vodn6 hladiny pro vybran6 vodn6 plochy v 6R. *Souhrnn6 v6zkumn6 zpr6va za rok 2019*.
- Beranov6, P., Blažkov6, L., Uldrich, M. (2012) Manuál k ovládání programu STATISTICA.

- Bernhardt, M., Schulz, K. (2015) *Remote Sensing Hydrology*. Vienna : Institute of Water Management. Hydrology and Hydraulic Engineering.
- Biondi, D., De Luca, D. L. (2017) Rainfall-runoff model parameter conditioning on regional hydrological signatures: Application to ungauged basins in southern Italy. *Hydrology Research*, 48(3), 714–725.
- Blöschl, G., Hall, J., Parajka, J., et al. (2017) Changing climate shifts timing of European floods. *Science*, 357(6351), 588–590.
- Breiman, L. (2001) Random forests. *Machine learning*, 45(1), 5–32.
- Bruce, P., Bruce, A. (2017) Practical statistics for data scientists.
- Campbell, J. B., Wynne, R. H. (2011) *Introduction to remote sensing*. Guilford Press.
- Copernicus (2021) Copernicus. Online, accessed 13-January-2021.
- Coron, L., Thirel, G., Delaigue, O., Perrin, C., Andréassian, V. (2017) The suite of lumped GR hydrological models in an R package. *Environmental modelling & software*, 94, 166–171.
- Coron, L., Delaigue, O., Thirel, G., et al. (2021) *airGR: Suite of GR Hydrological Models for Precipitation-Runoff Modelling*. doi: 10.15454/EX11NA, r package version 1.6.10.4.
- Croke, B., Merritt, W., Jakeman, A. (2004) A dynamic model for predicting hydrologic response to land cover changes in gauged and ungauged catchments. *Journal of Hydrology*, 291(1–2), 115–131.
- Dee, D. P., Uppala, S. M., Simmons, A., et al. (2011) The ERA-Interim reanalysis: Configuration and performance of the data assimilation system. *Quarterly Journal of the royal meteorological society*, 137(656), 553–597.
- Donnelly, C., Andersson, J. C., Arheimer, B. (2016) Using flow signatures and catchment similarities to evaluate the E-HYPE multi-basin model across Europe. *Hydrological Sciences Journal*, 61(2), 255–273.
- Duan, Q., Sorooshian, S., Gupta, V. K. (1994) Optimal use of the SCE-UA global optimization method for calibrating watershed models. *Journal of hydrology*, 158(3–4), 265–284.
- Elachi, C., Van Zyl, Jakob, J. (2006) *Introduction to the physics and techniques of remote sensing*, volume 28. John Wiley&Sons.
- Farmer, D., Sivapalan, M., Jothityangkoon, C. (2003) Climate, soil, and vegetation controls upon the variability of water balance in temperate and semiarid landscapes: Downward approach to water balance analysis. *Water Resources Research*, 39(2).
- Fendeková, M., Fendek, M., Porubská, D., et al. (2015) Catchment properties conditioning drought occurrence in selected catchments in Slovakia and Czechia. *Acta Geologica Slovaca*, 7(2), 187–194.
- Gareth, J., Daniela, W., Trevor, H., Robert, T. (2013) *An introduction to statistical learning: with applications in R*. Springer.
- Gidrometeoizdat (1976) *Rekomendacii po rastu isparenija spoverchnosti suši*. Leningrad.

- Gupta, H. V., Kling, H., Yilmaz, K. K., Martinez, G. F. (2009) Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of hydrology*, 377(1-2), 80–91.
- Gupta, H. V., Perrin, C., Blöschl, G., et al. (2014) Large-sample hydrology: a need to balance depth with breadth. *Hydrology and Earth System Sciences*, 18(2), 463–477.
- Halwatura, D., Najim, M. (2013) Application of the HEC-HMS model for runoff simulation in a tropical catchment. *Environmental modelling & software*, 46, 155–162.
- Hanel, M., Vizina, A. (2014) *Metody vyhodnocování vodohospodářských dat*. Fakulta životního prostředí, Česká zemědělská univerzita v Praze.
- Hanel, M., Mrkvičková, M., Máca, P., Vizina, A., Pech, P. (2013) Evaluation of simple statistical downscaling methods for monthly regional climate model simulations with respect to the estimated changes in runoff in the Czech Republic. *Water resources management*, 27(15), 5261–5279.
- Hanel, M., Horáček, S., Daňhelka, J., Tomek, M., Hánová, K., Vizina, A., Ledvinka, O., Tremel, P., Melišová, E. (2014) Aktualizace odhadu hydrologických dopad klimatické změny na povodích ČR. *Vodohospodářské technicko-ekonomické informace*, 56.
- Hanel, M., Havlíček, V., Heřmanovský, M., Máca, P. (2019) Dopady klimatické změny na bilanci povodí Labe po Drážďany. *Ochrana přírody*, 2.
- Harrigan, S., Hannaford, J., Muchan, K., Marsh, T. J. (2018) Designation and trend analysis of the updated UK Benchmark Network of river flow stations: The UKBN2 dataset. *Hydrology Research*, 49(2), 552–567.
- Havlíček, V., Hanel, M., Máca, P., Kuráž, M., Pech, P. (2013) Incorporating basic hydrological concepts into genetic programming for rainfall-runoff forecasting. *Computing*, 95(1), 363–380.
- Heřmanovský, M., Havlíček, V., Hanel, M., Pech, P. (2017) Regionalization of runoff models derived by genetic programming. *Journal of hydrology*, 547, 544–556.
- Hlavinka, P., Trnka, M., Balesk, J., et al. (2011) Development and evaluation of the SoilClim model for water balance and soil climate estimates. *Agricultural Water Management*, 98(8), 1249–1261.
- Hlavinka, P., Trnka, M., Kersebaum, K. C., et al. (2015) The use of Soilclim and Hermes model for irrigation water demand estimates. *ŠÍŠKA, B. et al*, 15–18.
- Hofierka, J. (2003) *Geografické informačné systémy a diaľkový prieskum Zeme*. Prešovská univerzita-Fakulta humanitných a prírodných vied.
- Horáček, S., Rakovec, O., Kašpárek, L., Vizina, A. (2009) Vývoj modelu hydrologické bilance BILAN. *VTEI*, 51(mimořádné číslo I), 2–5, příloha Vodního hospodářství 2009(11).
- Hrachowitz, M., Savenije, H., Blöschl, G., et al. (2013) A decade of Predictions in Ungauged Basins (PUB)—a review. *Hydrological Sciences Journal*, 58(6), 1198–1255, doi: 10.1080/02626667.2013.803183.
- Hrachowitz, M., Fovet, O., Ruiz, L., et al. (2014) Process consistency in models: The importance of system signatures, expert knowledge, and process complexity. *Water resources research*, 50(9), 7445–7469.
- Hrádek, F., Kuřík, K. (2001) *Maximální odtok z povodí: teorie svahového odtoku a hydrologický model DesQ-MAX Q*. Česká zemědělská univerzita v Praze ve vydavatelství Credit.

- Ishwaran, H., Kogalur, U. (2021) *Fast Unified Random Forests for Survival, Regression, and Classification (RF-SRC)*. R package version 2.10.1.
- Jakubcová, M., Máca, P., Pech, P. (2015) Parameter estimation in rainfall-runoff modelling using distributed versions of particle swarm optimization algorithm. *Mathematical Problems in Engineering*, 2015.
- Jean-Yves, L. G., Alice, B., Marc, S. (2019) *Annual Report*, volume 1. Head of the Policy and Programme Coordination Department of the European Space Agency.
- Jeníček, M. (2005) Možnosti využití srážko-odtokových model na malých a středně velkých povodích. *Praha: UK PřF*, 112–126.
- Juckes, M. (2018) The EU Copernicus Programme and a New Generation of Data Services: a Perspective from the Centre for Environmental Data Analysis. 1–48.
- Kašpárek, L., Hanel, M., Horáček, S., Máca, P., Vizina, A. (2015) *Bilan: Bilan water balance model*. Verze 2015-06-23.
- Klaschka, J., Kotrč, E. (2004) Klasifikační a regresní lesy. *Sborník prací 13. letní školy JČMF*, 13.
- Kořňová, J., Tesař, M., Šípek, V. (2019) The influence of observed and modelled net longwave radiation on the rate of estimated potential evapotranspiration. *Journal of Hydrology and Hydro-mechanics*, 67(3), 280–288.
- Kogan, F. N. (2001) Operational space technology for global vegetation assessment. *Bulletin of the American meteorological society*, 82(9), 1949–1964.
- Kožnarová, V., Klabzuba, J. (2009) Aplikovaná meteorologie a klimatologie: VI. díl–Voda v atmosféře, výpar, vlhkost vzduchu, pdy a materiálu.
- Kozák, J., Hindls, R., Artl, J. (1994) *Úvod do analýzy ekonomických časových řad*. Vysoká škola ekonomická.
- Kulasová, B., Holík, J., Kratochvílová, L. (1997) *Hydrologické údaje povrchových vod ČSN 75 1400*. Praha : Český normalizační institut, 1997.
- Kulhavý, Z., Kovář, P. (2000) *Využití model hydrologické bilance pro malá povodí*. Výzkumný ústav meliorací a ochrany pdy.
- Křivý, I. (2006) *Analýza časových řad*. Ostravská univerzita.
- Landgrebe, D. A. (2005) *Signal theory methods in multispectral remote sensing*, volume 29. John Wiley & Sons.
- Legates, D. R., McCabe Jr, G. J. (1999) Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. *Water resources research*, 35(1), 233–241.
- Li, X., Weller, D. E., Jordan, T. E. (2010) Watershed model calibration using multi-objective optimization and multi-site averaging. *Journal of Hydrology*, 380(3–4), 277–288.
- Lopez, N. (2020) Copernicus releases new dataset for land observation.
- Máca, P., Bašta, P., Kožín, R., Hanel, M. (2016) Využití geomorfologických charakteristik pro odhad celkové retence povodí. *Vodohospodářské technicko-ekonomické informace*, 58(6), 54–57.



- Machlica, A., Horvát, O., Horáček, S., et al. (2012) Influence of model structure on base flow estimation using Bìlan, frier and HBV-light models/Vplyv štruktúry modelu na stanovenie veľkosti podzemného odtoku využitím modelov bilan, frier a hbv-light. *j. hydrol. hydromech.*, 60, 2012, 4; 29 lit., 7 obr., 1 tab. *Journal of Hydrology and Hydromechanics*, 60(4), 242–251.
- Madsen, H. (2000) Automatic calibration of a conceptual rainfall–runoff model using multiple objectives. *Journal of hydrology*, 235(3–4), 276–288.
- Masaila, A. (2013) *Regresní stromy*. Master's thesis, Univerzita Karlova v Praze, Matematicko-fyzikální fakulta.
- Masih, I., Uhlenbrook, S., Maskey, S., Ahmad, M. (2010) Regionalization of a conceptual rainfall–runoff model based on similarity of the flow duration curve: A case study from the semi-arid Karkheh basin, Iran. *Journal of hydrology*, 391(1–2), 188–201.
- Mauricio Zambrano-Bigiarini (2020) *hydroGOF: Goodness-of-fit functions for comparison of simulated and observed hydrological time series*. doi: 10.5281/zenodo.839854, r package version 0.4-0.
- McMillan, H., Westerberg, I., Branger, F. (2017) Five guidelines for selecting hydrological signatures. *Hydrological Processes*, 31(26), 4757–4761.
- McMillan, H. K. (2021) A review of hydrologic signatures and their applications. *Wiley Interdisciplinary Reviews: Water*, 8(1), e1499.
- Melišová (2015) Využití DPZ v hydrologických konceptuálních modelech. *Rešerš*.
- Melišová, E., Hanel, M., Vizina, A. (2017) Evaluation of hydrological balance using soil moisture. *International Multidisciplinary Scientific GeoConference: SGEM*, 17, 261–268.
- Melišová, E., Vizina, A., Staponites, L. R., Hanel, M. (2020) The Role of Hydrological Signatures in Calibration of Conceptual Hydrological Model. *Water*, 12(12), 3401.
- Merz, R., Blöschl, G. (2004) Regionalisation of catchment model parameters. *Journal of hydrology*, 287(1–4), 95–123.
- Moriasi, D. N., Arnold, J. G., Van Liew, M. W., et al. (2007) Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885–900.
- Možný, M. (2003) Automatizace merení výparu z vodní hladiny. 56.
- Možný, M. (2005) Problematika měření evapotranspirace v ČHMÚ. *Obsah sborníku*, 7.
- Možný, M., Trnka, M., Vlach, V., Vizina, A., et al. (2020) Past (1971–2018) and future (2021–2100) pan evaporation rates in the Czech Republic. *Journal of Hydrology*, (519).
- Muñoz Sabater, J. (2019) First ERA5–Land dataset to be released this spring. *ECMWF Newsllett*, 159.
- Netopil, R. (1970) *Základy hydrologie povrchových a podpovrchových vod*. SPN.
- Nhu, V.-H., Shahabi, H., Nohani, E., et al. (2020) Daily Water Level Prediction of Zrebar Lake (Iran): A Comparison between M5P, Random Forest, Random Tree and Reduced Error Pruning Trees Algorithms. 9(8), 479.

- Novák, J. (2001) Základy teorie chyb a zpracování fyzikálních měření. *Fsv ČVUT v Praze, katedra fyziky*, [cit. 13. března 2016]. Dostupné z: <http://webfyzika.fsv.cvut.cz/PDF/teoriechyb.pdf>.
- Oudin, L., Andréassian, V., Perrin, C., Michel, C., Le Moine, N. (2008) Spatial proximity, physical similarity, regression and ungauged catchments: A comparison of regionalization approaches based on 913 French catchments. *Water Resources Research*, 44(3).
- Oudin, L., Moulin, L., Bendjoudi, H., Ribstein, P. (2010) Estimating potential evapotranspiration without continuous daily data: possible errors and impact on water balance simulations. *Hydrological Sciences Journal–Journal des Sciences Hydrologiques*, 55(2), 209–222.
- Parajka, J., Merz, R., Blöschl, G. (2007) Uncertainty and multiple objective calibration in regional water balance modelling: case study in 320 Austrian catchments. *Hydrological Processes: An International Journal*, 21(4), 435–446.
- Pavelková, Chmelová, R., Frajer, J. (2013) Základy fyzické geografie 1–hydrologie. *Univerzita Palackého v Olomouci. Katedra geografie. Olomouc*.
- Pavlásek, J., Máca, P., Ředinová, J. (2006) Analýza hydrologických dat z modravských povodí. *Journal of Hydrology and Hydromechanics*, 54(2), 207–216.
- Peláková, M., a kol. (2020) *Voda a Praha*. Praha : Výzkumný ústav vodohospodářský T. G. M., ISBN 978-80-87402-82-5, veřejná výzkumná instituce.
- Pfannerstill, M., Guse, B., Fohrer, N. (2014) Smart low flow signature metrics for an improved overall performance evaluation of hydrological models. *Journal of Hydrology*, 510, 447–458.
- Pfannerstill, M., Bieger, K., Guse, B., et al. (2017) How to constrain multi-objective calibrations of the SWAT model using water balance components. *JAWRA Journal of the American Water Resources Association*, 53(3), 532–546.
- Pokhrel, P., Yilmaz, K. K., Gupta, H. V. (2012) Multiple-criteria calibration of a distributed watershed model using spatial regularization and response signatures. *Journal of Hydrology*, 418, 49–60.
- Qamar, M. U., Azmat, M., Cheema, M. J. M., et al. (2016) Model swapping: A comparative performance signature for the prediction of flow duration curves in ungauged basins. *Journal of Hydrology*, 541, 1030–1041.
- R Core Team (2020) *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria.
- Sabater, M. (2019) from 1981 to Present. *Copernicus Climate Change Service (C3S) Climate Data Store (CDS)*.
- Samuel, J., Coulibaly, P., Metcalfe, R. A. (2011) Estimation of continuous streamflow in Ontario ungauged basins: comparison of regionalization methods. *Journal of Hydrologic Engineering*, 16(5), 447–459.
- Schauer, P. (2007) *Metoda nejmenších čtverců*. FAST VUT v Brně.
- Seibert, J. (1997) Estimation of parameter uncertainty in the HBV model: Paper presented at the Nordic Hydrological Conference (Akureyri, Iceland–August 1996). *Hydrology Research*, 28(4–5), 247–262.
- Shafii, M., Tolson, B. A. (2015) Optimizing hydrological consistency by incorporating hydrological signatures into model calibration objectives. *Water Resources Research*, 51(5), 3796–3814.

- Slater, L. J., Thirel, G., Harrigan, S., et al. (2019) Using R in hydrology: a review of recent developments and future directions. *Hydrology and Earth System Sciences*, 23(7), 2939–2963.
- Sobišek, B. (1993) *Meteorologický slovník výkladový terminologický: S cizojazyčnými názvy hesel ve slovenštině, angličtině, němčine, francouzštině a ruštině*. Academia.
- Šobr, M. (2016) Hydrologický cyklus. *Geografické rozhledy*, 26(2).
- Starý, M. (2005) Hydrologie (MODUL 01). Brno: VUT v Brně–Fakulta stavební.
- Storn, R., Price, K. (1997) Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11(4), 341–359.
- Strnad, F., Moravec, V., Hanel, M., et al. (2017) Regionalizace nedostatkových objem v České republice. *Vodohospodářské technicko-ekonomické informace*, 59(4), 12–17.
- Štěpánek, P., Zahradniček, P., Huth, R. (2011) Interpolation techniques used for data quality control and calculation of technical series: an example of a Central European daily time series. *IDŐJÁRÁS - Quarterly Journal of the Hungarian Meteorological Service*, 115(1–2), 87–98.
- Šuhájková, P., et al. (2020) Výpar z výparoměrných stanic VÚV TGM. *Vodohospodářské technicko-ekonomické informace*, 62(5), 16–27.
- Tallaksen, L. M., Van Lanen, H. A. (2004) *Hydrological drought: processes and estimation methods for streamflow and groundwater*, volume 48. Elsevier.
- Tolasz, R., Míková, T., Valeriánová, A., Voženílek, V. (2007) Atlas podnebí Česka. Prague: Český hydrometeorologický ústav, UPOL.
- Toum, E. (2021) *HBV.IANIGLA: Modular Hydrological Model*. 0.2.0.
- Tuo, Y., Marcolini, G., Disse, M., Chiogna, G. (2018) A multi-objective approach to improve SWAT model calibration in alpine catchments. *Journal of hydrology*, 559, 347–360.
- Viglione, A., Parajka, J. (2020) *TUWmodel: Lumped/Semi-Distributed Hydrological Model for Education Purposes*. R package version 1.1–1.
- Vissersri, S., McIntyre, N. (2016) Regionalisation of hydrological responses under land-use change and variable data quality. *Hydrological Sciences Journal*, 61(2), 302–320.
- Vizina, A., Hanel, M., Novický, O., Treml, P. (2010) Experience from Simulation of Climate Impacts on Water Regime in Monthly and Daily Time Step. Prague, TG Masaryk Water Research Institute.
- Vizina, A., Hanel, M., Melišová, E. (2014) Analýza propagace sucha pomocí generátoru počasí. *Vodní hospodářství*, 5–11.
- Vizina, A., Horáček, S., Hanel, M. (2015) Nové možnosti modelu Bilan. *Vodohospodářské technicko-ekonomické informace*, 57(4–5), 7–10.
- Vizina, A., Vlnas, R., Hanel, M., Kašpárek, L., Melišová, E., Beran, A., Kožín, R., Strnad, F. (2017) Hydrologická bilance a disponibilní vodní zdroje v České republice v době hydrologického sucha. *Vodohospodářské technicko-ekonomické informace*, 60(4), 6–11.
- Vizina, A., Hanel, M., Trnka, M., et al. (2018) HAMR: online systém pro zvládání sucha—operativní řízení během suché epizody. *Vodohospodářské technicko-ekonomické informace*, 60(5), 22–28.

- Wagener, T., Boyle, D. P., Lees, M. J., et al. (2001) A framework for development and application of hydrological models. *Hydrology and Earth System Sciences*, 5(1), 13–26.
- Westerberg, I., Guerrero, J.-L., Younger, P., et al. (2011) Calibration of hydrological models using flow–duration curves. *Hydrology and Earth System Sciences*, 15(7), 2205–2227.
- Westerberg, I. K., Wagener, T., Coxon, G., et al. (2016) Uncertainty in hydrological signatures for gauged and ungauged catchments. *Water Resources Research*, 52(3), 1847–1865.
- Wickham, H. (2016) *ggplot2: Elegant Graphics for Data Analysis*. Springer-Verlag New York, ISBN 978-3-319-24277-4.
- Yilmaz, K. K., Gupta, H. V., Wagener, T. (2008) A process-based diagnostic approach to model evaluation: Application to the NWS distributed hydrologic model. *Water Resources Research*, 44(9).
- Yin, P., Fan, X. (2001) Estimating  $R^2$  shrinkage in multiple regression: A comparison of different analytical methods. *The Journal of Experimental Education*, 69(2), 203–224.
- Žalud, Z., Hlavinka, P., Prokeš, K., et al. (2017) Impacts of water availability and drought on maize yield—A comparison of 16 indicators. *Agricultural water management*, 188, 126–135.
- Zhang, Y., Vaze, J., Chiew, F. H., Teng, J., Li, M. (2014) Predicting hydrological signatures in ungauged catchments using spatial interpolation, index model, and rainfall–runoff modelling. *Journal of hydrology*, 517, 936–948.

# Přílohy

## 7.1 Výpočet výparu v modelu Bilan

### Územní výpar a hydrologická bilance v půdě za letních podmínek

Pokud je infiltrace, která se rovná srážkám, větší nebo rovna potenciální evapotranspiraci

$$INF(i) \geq PET(i) \quad (7.1)$$

územní výpar je roven potenciální evapotranspiraci

$$ET(i) = PET(i) \quad (7.2)$$

přebytek vody  $INF(i) - PET(i)$  může dotovat půdní vlhkost

$$SW(i) = SW(i-1) + INF(i) - PET(i), \quad (7.3)$$

a pokud je překročena kapacita zásoby půdní vlhkosti

$$SW(i) > Spa, \quad (7.4)$$

zbývající voda perkoluje směrem dolů

$$PERC(i) = SW(i) - Spa \quad (7.5)$$

a zásoba půdní vlhkosti  $SW(i)$  je rovna parametru  $Spa$ .

Převýší-li potenciální evapotranspirace srážky (infiltraci), územní výpar je dotován ze zásoby půdní vlhkosti, která se vyprazdňuje

$$SW(i) = SW(i-1) \cdot e^{\frac{INF(i) - PET(i)}{Spa}} \quad (7.6)$$

kde  $e$  je základ přirozených logaritmů.

Územní výpar je roven součtu srážek a prázdnění zásoby půdní vlhkosti

$$E(i) = INF(i) + SW(i-1) - SW(i) \quad (7.7)$$

a žádná voda neperkoluje.

Územní výpar a hydrologická bilance na povrchu za zimních podmínek

Pokud součet srážky a zásoby vody ve sněhové pokrývce převýší v daném dni potenciální evapotranspiraci, předpokládá se, že je územní výpar roven potenciální evapotranspiraci.

$$ET(i) = PET(i), \quad \text{pro } SS(i-1) + P(i) \geq PET(i) \quad (7.8)$$

v opačném případě se územní výpar vypočte jako součet srážky a zásoby vody ve sněhu

$$ET(i) = SS(i-1) + P(i), \quad \text{pro } SS(i-1) + P(i) < PET(i) \quad (7.9)$$

Množství zbývající vody uložené ve sněhu čtní

$$SS(i) = \max(SS(i-1) + P(i) - PET(i), 0) \quad (7.10)$$

kde  $SS(i-1)$  je zásoba vody ve sněhové pokrývce ve dni  $i-1$ .

Infiltrace je nulová

$$INF(i) = 0 \quad (7.11)$$

### Územní výpar a hydrologická bilance na povrchu za podmínek tání sněhu

Pokud srážky převyšují v daném dni potenciální evapotranspiraci, předpokládá se, že je územní výpar roven potenciální evapotranspiraci.

$$ET(i) = PET(i) \quad \text{pro } P(i) > PET(i) \quad (7.12)$$

v opačném případě je územní výpar roven množství srážek

$$ET(i) = P(i) \quad \text{for } P(i) \leq PET(i) \quad (7.13)$$

Množství roztálené vody v určitém dni (dostupné pro infiltraci) je dáno tepelnou kapacitou vzduchu umožňující tání sněhové pokrývky. Tato kapacita je vyjádřena jako

$$MELT(i) = T(i) \cdot Dgm \quad (7.14)$$

kde  $T(i)$  je průměrná teplota vzduchu ve dni  $i$  a  $Dgm$  je parametr vyjadřující míru tání v závislosti na teplotě vzduchu.

Zbývající zásoba vody ve sněhu je poté vypočtena jako

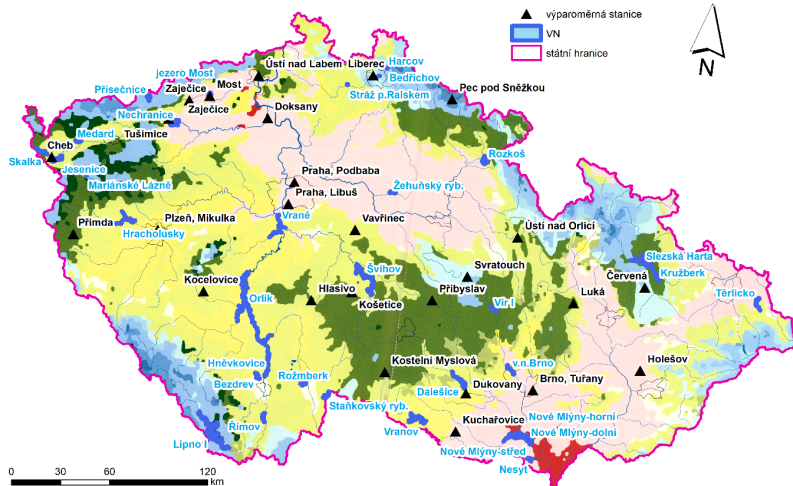
$$SS(i) = \max(SS(i-1) - MELT(i), 0) \quad (7.15)$$

Voda z tání sněhu, případně ještě s přebývajícím množstvím srážek, infiltruje:

$$INF(i) = MELT(i) \quad \text{pro } P(i) \leq PET(i) \quad (7.16)$$

$$ET(i) = MELT(i) + P(i) - PET(i) \quad \text{pro } P(i) > PET(i) \quad (7.17)$$

## 7.2 Zájmové území

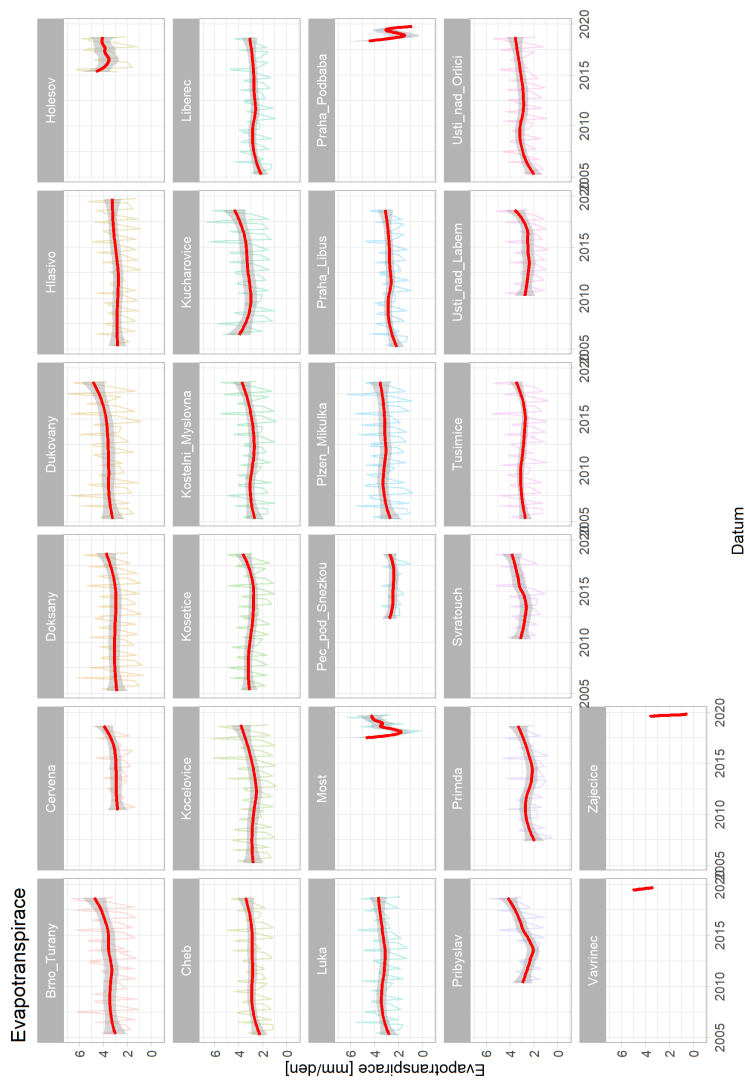


Obr. 7.1 Rozdělení výparoměrných stanic a vodních nádrží dle klimatického rozdělení dle Quittovy klasifikace Beran et al. (2020)

Parametr	Klimatické charakteristiky chladných oblastí Climate characteristics of cool regions							Klimatické charakteristiky mírně teplých oblastí Climate characteristics of moderately warm regions											Klimatické charakteristiky teplých oblastí Climate characteristics of warm regions				
	CH1	CH2	CH3	CH4	CH5	CH6	CH7	MT1	MT2	MT3	MT4	MT5	MT6	MT7	MT8	MT9	MT10	MT11	T1	T2	T3	T4	T5
Počet letních dní	0-10	0-10	0-20	0-20	10-30	10-30	20-30	20-30	20-30	20-30	30-40	30-40	30-40	40-50	40-50	40-50	40-50	40-50	50-60	50-60	60-70	60-70	60-70
Počet dní s průměrnou teplotou 10° C a více	0-30	0-30	80-100	80-100	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120
Počet dní s mrazem	160-180	160-180	160-180	160-180	140-160	140-160	140-160	140-160	110-130	110-130	110-130	110-130	110-130	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120
Počet ledových dní	60-80	60-70	60-70	60-70	60-70	50-60	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	30-40	30-40	30-40	30-40	30-40	30-40	30-40	30-40	< 30
Průměrná ledová teplota	+7 - +8	+7 - +8	+7 - +8	+7 - +8	+5 - +6	+4 - +5	+3 - +4	+5 - +6	+3 - +4	+2 - +3	+4 - +5	+5 - +6	+2 - +3	+4 - +5	+3 - +4	+2 - +3	+2 - +3	+3 - +5	+2 - +3	+2 - +3	+3 - +4	+2 - +3	+1 - +2
Průměrná denní teplota	10-12	10-12	12-14	12-14	14-15	14-15	15-16	15-16	16-17	16-17	16-17	16-17	16-17	16-17	17-18	17-18	17-18	17-18	17-18	18-19	18-19	19-20	19-20
Průměrná odnožová teplota	0-2	0-2	2-4	2-4	2-4	4-5	5-6	6-7	6-7	6-7	6-7	6-7	6-7	7-8	7-8	7-8	7-8	7-8	7-8	7-8	7-8	7-8	7-8
Průměrná říjnová teplota	2-4	2-4	2-4	4-5	5-6	5-6	6-7	6-7	6-7	6-7	6-7	6-7	6-7	7-8	7-8	7-8	7-8	7-8	7-9	7-9	8-9	8-10	8-10
Průměr počtu dní se srážkami 1 mm a více	160-180	160-180	120-140	120-140	120-140	120-140	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120	100-120
Suma srážek ve vegetačním období	800-1000	700-900	600-700	600-700	500-600	500-600	500-600	500-600	400-500	400-500	400-500	400-500	400-500	400-500	400-500	400-500	400-500	400-500	400-500	400-500	400-500	400-500	400-500
Suma srážek v zimním období	1600-2000	500-600	400-500	400-500	350-400	350-400	300-350	250-300	250-300	250-300	250-300	250-300	250-300	250-300	250-300	250-300	250-300	250-300	200-300	200-300	200-300	200-300	200-300
Počet dní s sněhovou pokrývkou	160-200	160-200	140-160	140-160	120-140	120-140	100-120	100-120	80-100	80-100	80-100	80-100	80-100	80-100	60-80	60-80	60-80	60-80	60-80	60-80	60-80	60-80	< 40
Počet zatažených dní	130-150	130-150	140-150	130-150	140-150	150-160	150-160	150-160	150-160	150-160	150-160	150-160	150-160	150-160	150-160	150-160	150-160	150-160	150-160	150-160	150-160	150-160	< 110
Počet jasných dní	30-40	30-40	30-40	30-40	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50	40-50

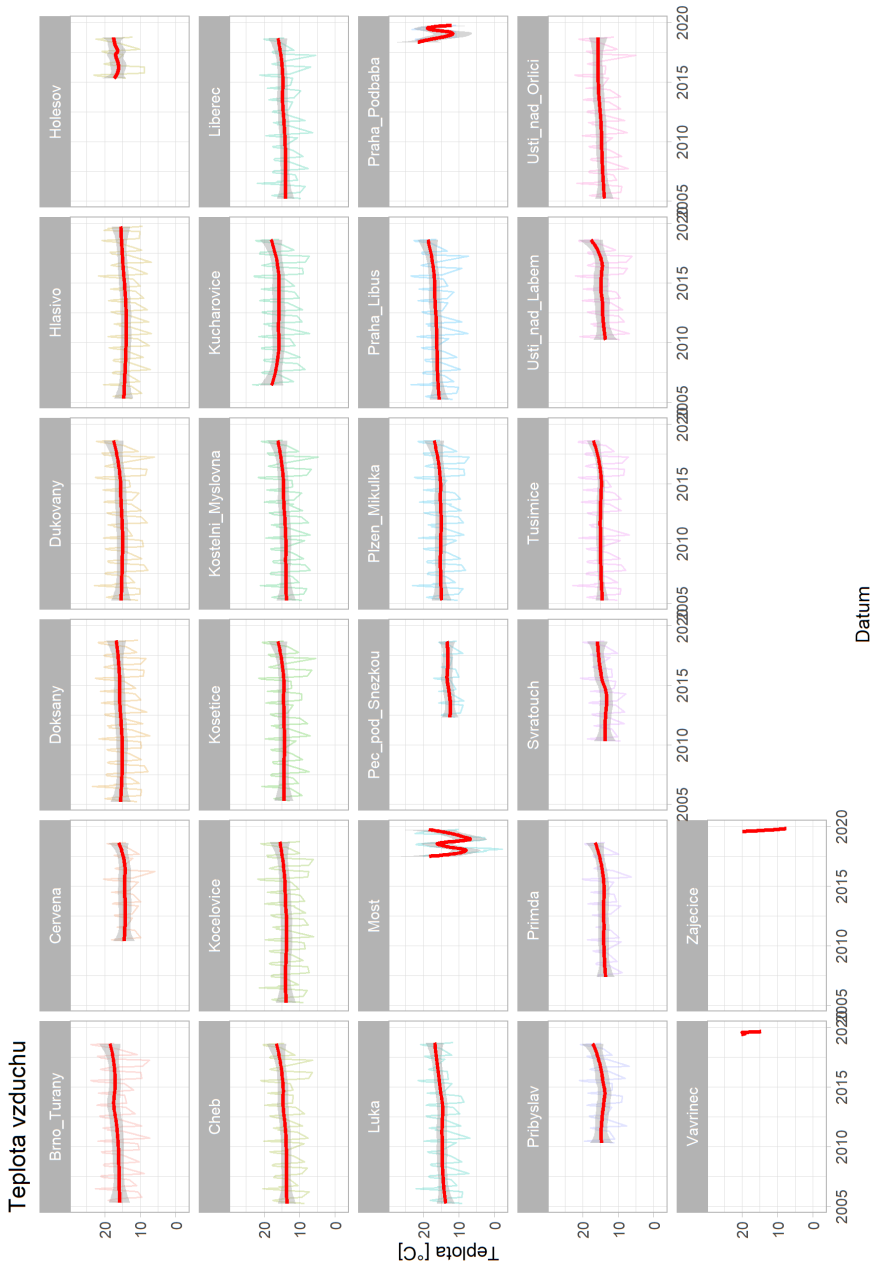
Obr. 7.2 Detailnější rozdělení Quittovy klasifikace podnebí Beran et al. (2020)

## 7.3 Pozorovaná data

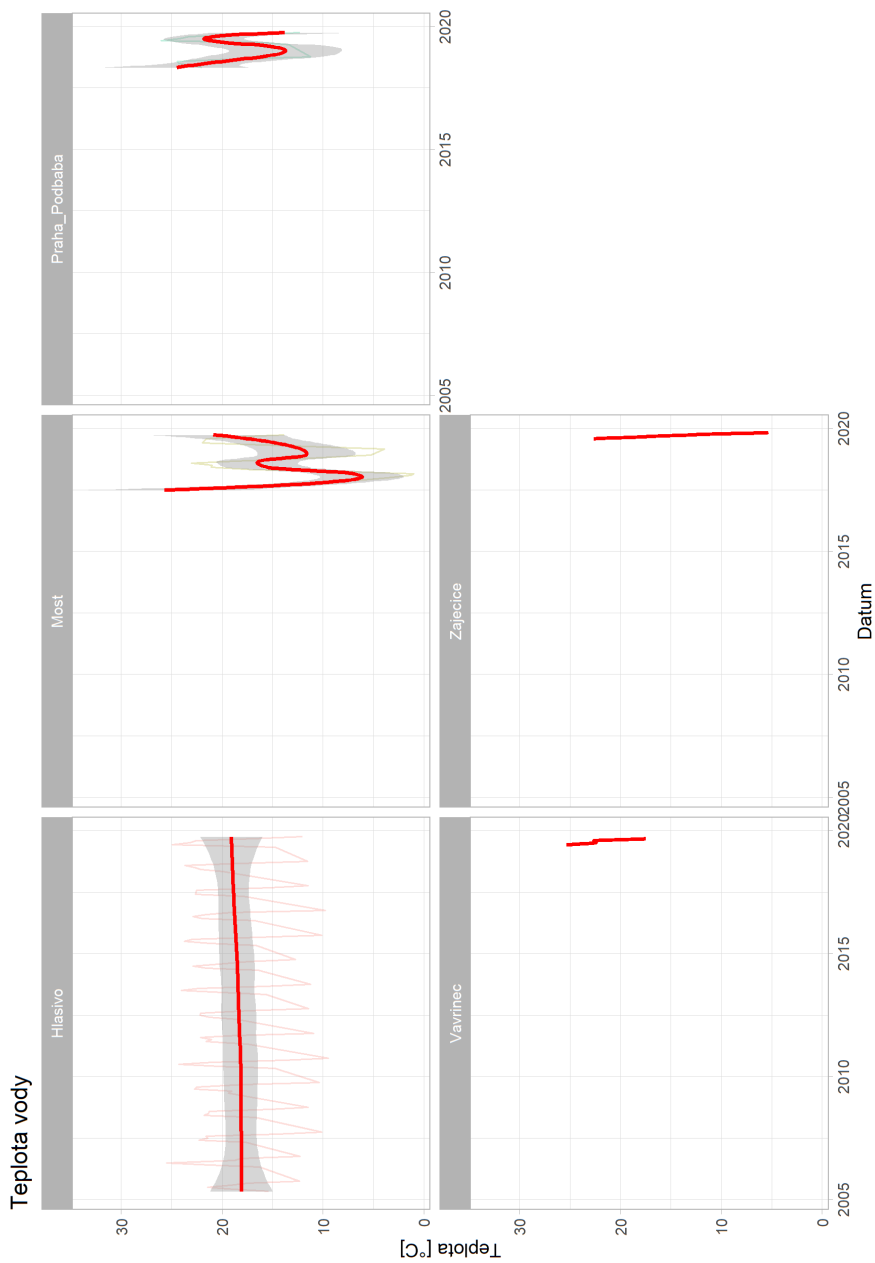


Obr. 7.3 Pozorovaná data výparu ve stanicích.

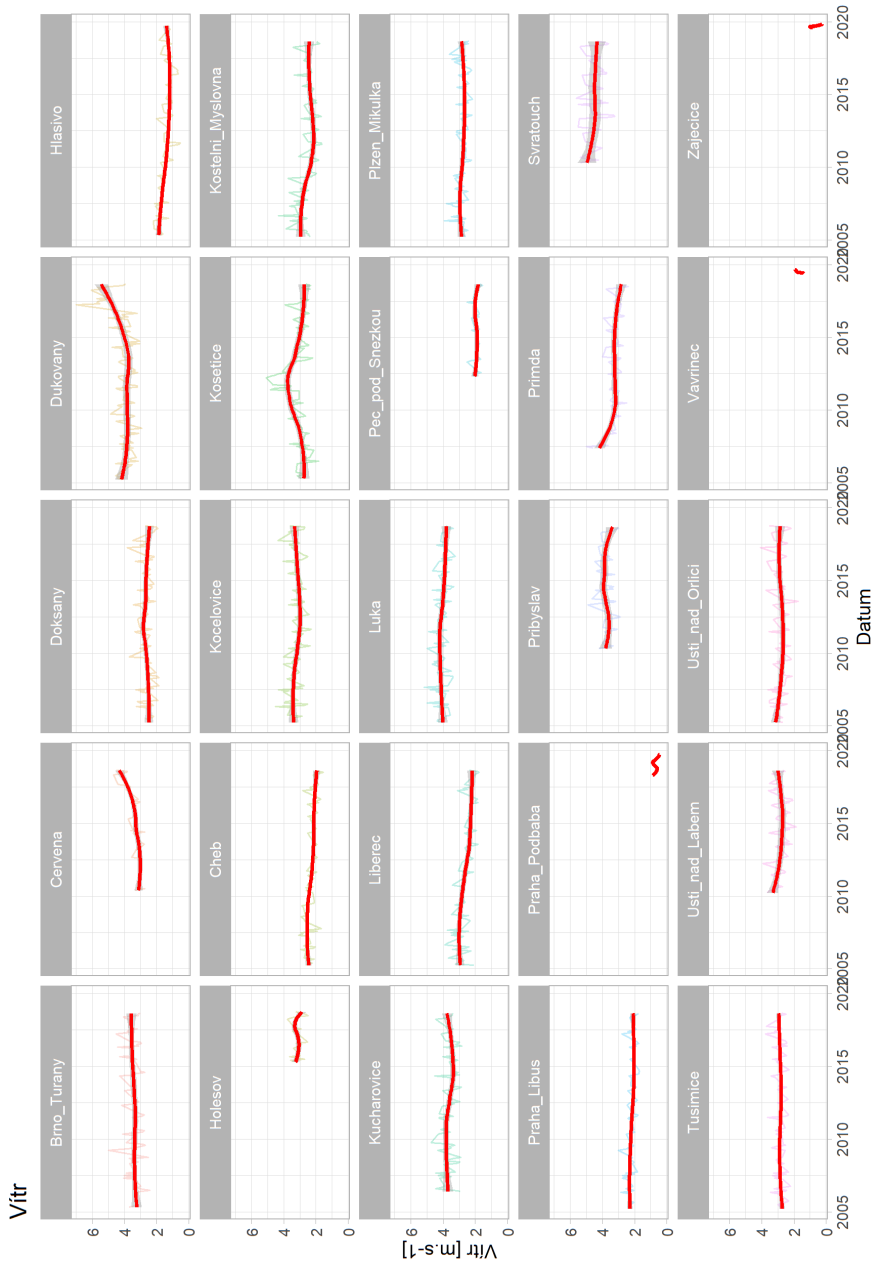




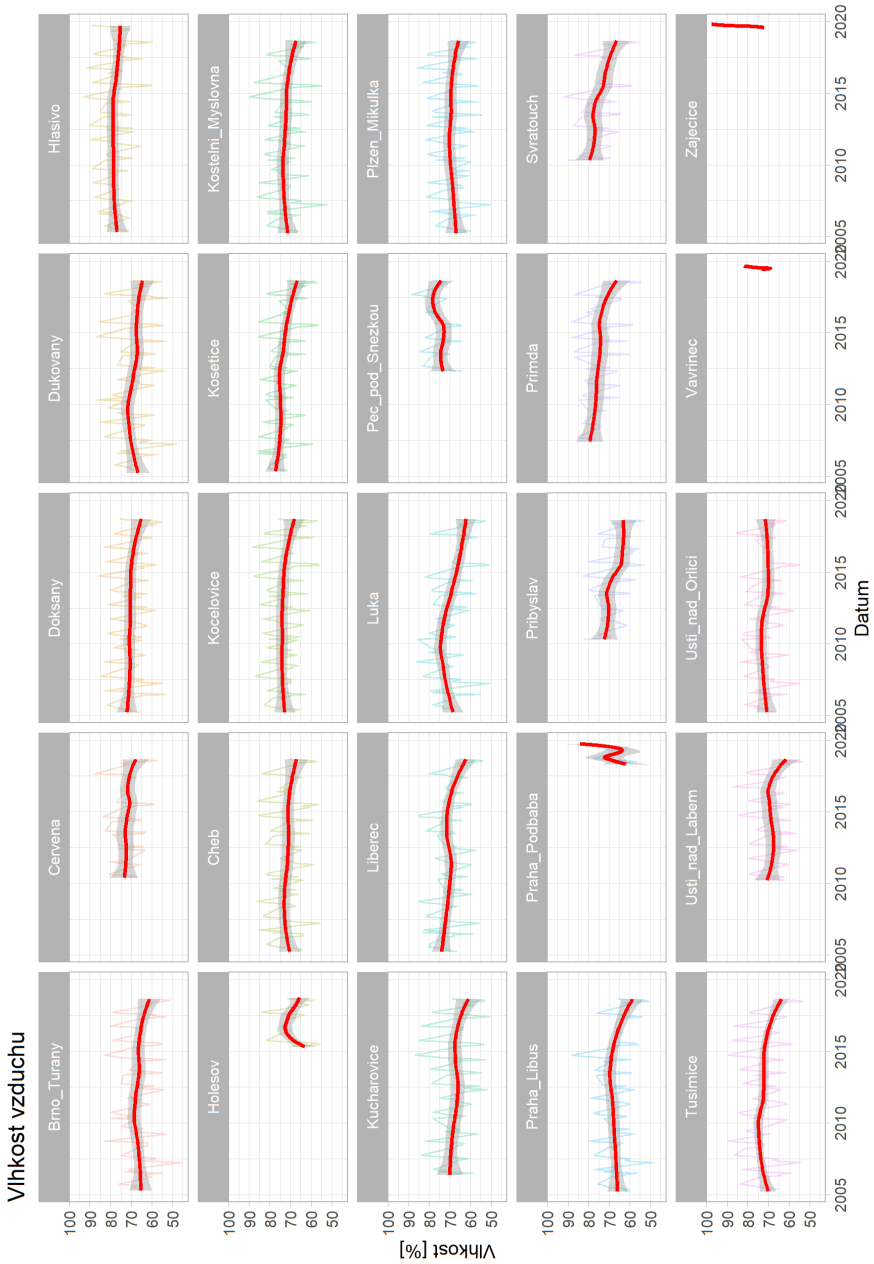
Obr. 7.4 Pozorovaná data teploty vzduchu ve stanicích.



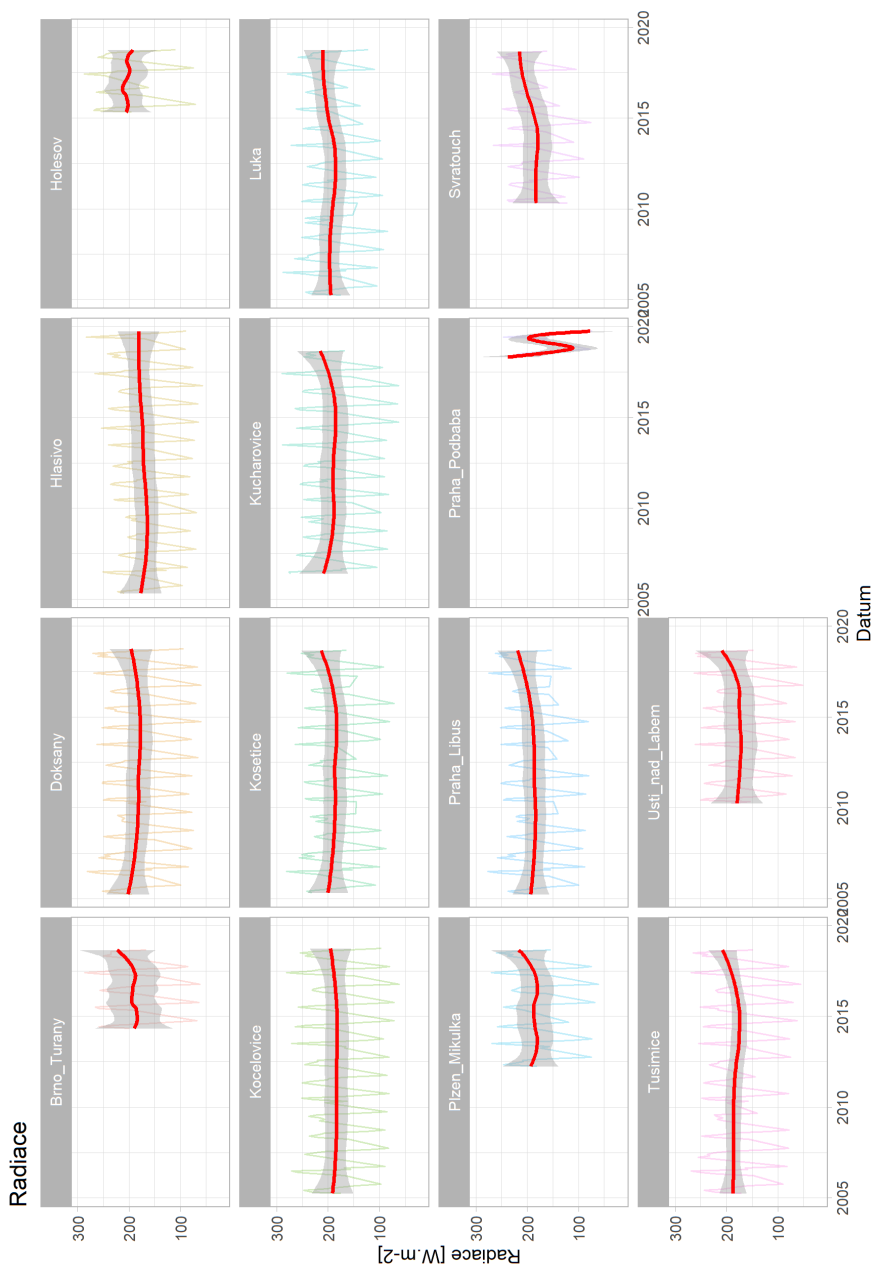
Obr. 7.5 Pozorovaná data pro teplotu vody ve stanicích.



Obr. 7.6 Pozorovaná data pro rychlost větru ve stanicích.



Obr. 7.7 Pozorovaná data pro relativní vlhkost ve stanicích.



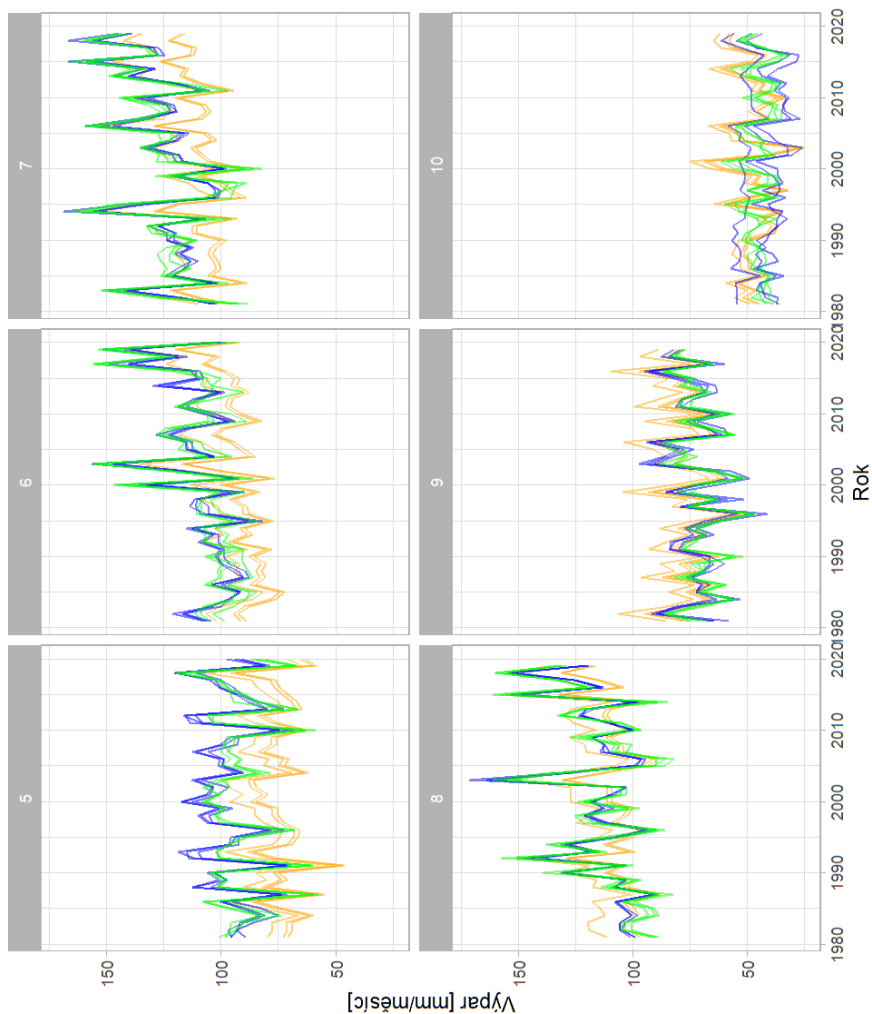
Obr. 7.8 Pozorovaná data globální sluneční radiaci ve stanicích.

## 7.4 Satelitní data

Název	Leden	Únor	Březen	Duben	Květen	Červen	Červenec	Srpen	Září	Ríjen	Listopad	Prosinec	Průměrná hodnota
Medard	5,92	5,67	2,76	2,99	2,94	2,68	2,2	1,95	2,6	2,67	4,3	5,31	3,5
v.n. Kráňbark	5,55	5,3	3,38	3,04	3,27	3,63	2,82	2,23	2,66	2,93	3,29	4,76	3,57
v.n. Hracholuský	4,66	3,85	1,96	2,14	3,38	3,14	2,31	1,22	1,73	2,29	3,28	4,13	2,84
v.n. Svithov	4,81	4,34	2,48	2,58	3,05	2,92	2,7	2,26	2,05	2,3	2,74	3,2	2,95
v.n. Sež I	5,24	5,24	2,84	2,56	3,11	3,04	2,46	1,96	2,46	2,5	3,26	4,69	3,28
v.n. Vír I	4,94	4,39	2,58	2,23	2,88	2,72	2,43	1,86	2,27	2,36	2,89	4,25	2,88
v.n. Lipno I	<b>-1,4</b>	<b>-2,19</b>	<b>-1,97</b>	<b>-0,17</b>	0,84	1,01	<b>-0,1</b>	<b>-2,02</b>	2,45	<b>-5,23</b>	<b>-3,87</b>	<b>-3,99</b>	<b>-1,88</b>
Nesyt	15,12	11,84	5,55	0,38	<b>-4,93</b>	<b>-8,54</b>	<b>-11,83</b>	<b>-10,81</b>	<b>-5,29</b>	1,94	7,46	12,94	1,15
Máchovo Jezero	5,17	4,62	2,32	2,47	2,67	2,55	1,73	1,27	1,81	2,86	3,63	4,62	2,98
v.n. Brno	4,03	3,04	2,05	1,93	2,38	2,6	1,8	1,5	2,01	2,38	3,02	3,69	2,54
v.n. Šance	4,88	4,78	2,65	2,8	2,29	2,78	1,94	1,61	1,75	2,46	2,69	4,31	2,91
v.n. Ofík	6,28	4,94	2,67	2,91	3,43	2,77	1,94	1,18	2,4	2,61	3,97	4,55	3,3
v.n. Vrané	4,54	4,08	2,3	2,69	3,92	3	2,16	2,45	2,67	2,69	3,3	4,36	3,18
v.n. Šalka	5,52	5,06	2,84	2,84	2,97	3,22	3,53	2,97	2,03	2,56	2,66	4,05	4,83
v.n. Přívěraice	14,05	13,01	7,8	2,42	<b>-1,97</b>	<b>-5,58</b>	<b>-7,97</b>	<b>-7,43</b>	<b>-2,5</b>	2,35	7,55	10,88	2,72
v.n. Zemanice	6,19	6,42	2,96	3,15	3,22	2,98	1,85	1,65	2,18	2,87	3,54	5,05	3,51
v.n. Nechranice	5,71	5,3	3,49	3,31	3,5	3,06	2,03	1,43	2,11	3,28	4,18	4,78	3,51
v.n. Rimov	5,54	4,34	1,56	2,35	3,45	2,79	1,86	1,27	2,16	2,15	2,94	4,06	2,87
v.n. Slezská Harta	4,46	5,01	2,86	2,87	3,09	3,45	2,81	2,05	2,38	2,36	2,8	3,93	3,17
Zeluhavský rb.	4,57	3,72	2,08	2,19	2,17	1,1	0,76	0,64	1,65	2,38	3,65	4,1	2,42
Horusavský rb.	5,72	5,25	3,24	3,2	3,84	3,81	3,12	2,26	2,51	2,66	3,82	4,6	3,67
v.n. Jesanice	4,69	4,09	1,62	2,04	2,3	1,5	0,99	0,65	1,97	2,05	3,25	3,97	2,43
v.n. Hněchovice	5,54	4,34	1,56	2,35	3,45	2,79	1,86	1,27	2,16	2,15	2,94	4,06	2,87
v.n. Rímov	3,99	1,88	1,62	1,93	2,28	2,27	1,68	1,14	1,6	1,65	2,36	3,81	2,48
v.n. Vranov	4,66	3,97	2,62	2,67	3,04	3,21	2,26	1,64	1,8	2,6	2,87	3,58	2,91
Rožimberk	4,99	4,17	2,48	2,37	2,67	1,61	1,24	0,98	2	2,7	3,49	4,25	2,74
Dvořišské	5,41	4,39	1,99	2,31	2,81	1,86	1,46	0,91	1,84	2,12	3,05	4,03	2,68
jezero Most	4,39	3,77	2,02	2,37	3,66	2,56	2,1	1,96	2,09	2,02	2,69	3,74	2,78
v.n. Slapy	5,36	4,68	2,01	1,65	2	1,11	0,79	0,47	1,3	2,07	2,83	3,97	2,35
Pelky Tisý	5,29	3,84	1,78	2,27	3,04	2,03	1,25	1,18	1,54	2,22	3,57	4,56	2,72
Bezdrev	4,11	2,18	1,44	0,94	0,71	0,84	0,13	<b>-0,27</b>	0,61	1,5	2,61	3,61	1,53
v.n. Nové Mlýnsy-horní	5,88	4,9	2,49	2,54	3,22	2,38	1,51	1,12	2,18	2,84	3,98	4,85	3,16
Deblář	3,78	2,66	1,43	0,99	1,11	1,07	0,24	<b>-0,04</b>	0,41	1,42	2,38	3,26	1,56
v.n. Nové Mlýnsy-dolní	6,81	5,92	3,2	3,28	3,02	2,88	1,88	1,78	2,19	3,29	3,65	5,4	3,61
v.n. Terčičko	4,88	3,96	1,62	1,59	2,18	1,11	0,77	0,3	1,11	1,76	2,92	3,83	2,17
Záblanský rb.	3,84	2,27	1,28	0,99	0,86	1,07	0,3	<b>-0,13</b>	0,58	1,41	2,31	3,32	1,51
v.n. Nové Mlýnsy-střed	4,64	4,03	2,09	2,1	2,9	2,63	1,86	1,36	1,76	2,25	3,07	3,74	2,7
v.n. Dulešice	6,12	5,31	2,41	2,34	2,22	2,29	1,21	1,02	1,8	2,64	3,91	5,36	3,05
v.n. Rozkoš													

Obr. 7.9 Rozdíl teplot mezi odvozenými teplotami vzduchu a satelitními daty pro vybrané stanice

## 7.5 Výpar z vodních nádrží



*Obr. 7.10* Výpar z vodní nádrže Orlik pro vybrané vzorce a jednotlivé měsíce (květen–říjen), modře je výpar na základě lineárních modelů, zeleně: random forest a oranžově ze studie [Beran et al. \(2020\)](#).

**Školitel:**

prof. Ing. Martin Hanel, Ph.D.

**Školitel specialista:**

Ing. Adam Vizina, Ph.D.

**Lektorovali**

prof. RNDr. Miriam Fendeková, CSc.

Ing. Ladislav Kašpárek, CSc.

Ing. Miroslav Tesař, Ph.D.

**Vyhodnocení hydrologické bilance na nepozorovaných povodích**

Ing. Eva Melišová