

**MATEMATICKO-FYZIKÁLNÍ
FAKULTA**
Univerzita Karlova

BAKALÁŘSKÁ PRÁCE

Vojtěch Klimeš

**Analýza vazby mezi teplotou vzduchu ve
standardní výšce a v hladině bylinného
patra v závislosti na meteorologických
podmínkách**

Katedra fyziky atmosféry

Vedoucí bakalářské práce: doc. Mgr. Michal Žák, Ph.D.

Studijní program: Fyzika

Studijní obor: FP

Praha 2023

Prohlašuji, že jsem tuto bakalářskou práci vypracoval(a) samostatně a výhradně s použitím citovaných pramenů, literatury a dalších odborných zdrojů. Tato práce nebyla využita k získání jiného nebo stejného titulu.

Beru na vědomí, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorského zákona v platném znění, zejména skutečnost, že Univerzita Karlova má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle §60 odst. 1 autorského zákona.

V dne

Podpis autora

V první řadě bych chtěl poděkovat panu doc. Mgr. Michalu Žákovi, Ph.D. za trpělivost a věnovaný čas při vedení této práce. Za poskytnutá data a konzultace patří velké díky Mgr. Martinovi Kopeckému Ph.D., doc. Ing. Janu Wildovi Ph.D. a jejich kolegyním a kolegům. Dále bych chtěl poděkovat Českému hydrometeorologickému ústavu za možnost použití dostupných dat z meteorologických stanic. Speciální poděkování patří mým nejbližším za pomoc a podporu při psaní práce.

Název práce: Analýza vazby mezi teplotou vzduchu ve standardní výšce a v hladině bylinného patra v závislosti na meteorologických podmínkách

Autor: Vojtěch Klimeš

katedra: Katedra fyziky atmosféry

Vedoucí bakalářské práce: doc. Mgr. Michal Žák, Ph.D., Katedra fyziky atmosféry

Abstrakt: Lesní mikroklima je odlišné od podmínek měřených na meteorologických stanicích. Podmínky v bylinném patře jsou ovlivněny jak okolní vegetací, tak makroklimatickými faktory. V práci zkoumáme vztah mezi rozdílem teplot ve výšce 2 m nad zemí a poblíž zemského povrchu v lesním porostu a meteorologickými podmínkami. Mikroklimatická data jsou měřena pomocí teplotních čidel v národních parcích Šumava a Bavorský les. Navazujeme na studie zkoumající vliv vegetace na teploty v lesním porostu a doplňujeme tím obrázek o fungování lesního mikroklimatu. Tyto znalosti jsou klíčové pro porozumění dopadu klimatické změny a k dalšímu výzkumu pomocí pokročilého modelování a zobecnění na jiné biotopy. Pro vybrané meteorologické podmínky měřené na stanicích byl zjištěn statisticky významný vztah pro rozdíl teplot, který je nejsilnější pro výšku sněhu a nejslabší pro srážky.

Klíčová slova: mikroklimatologie mikrometeorologie lesní klima

Title: Study of relationship between temperature measurement in standard level and herb layer according to meteorological conditions

Author: Vojtěch Klimeš

Department: Department of Atmospheric Physics

Supervisor: doc. Mgr. Michal Žák, Ph.D., Department of Atmospheric Physics

Abstract: The forest microclimate is different from the conditions measured at meteorological stations. Conditions in the herbaceous layer are influenced by both the surrounding vegetation and macroclimatic factors. In this thesis, we investigate the relationship between the temperature difference at 2 m and near the ground surface in a forest and meteorological conditions. Microclimatic data are measured using temperature sensors in the national parks Šumava and Bavarian Forest. We build on studies investigating the influence of vegetation on temperatures in forest stands to complete the picture of how forest microclimate functions. This knowledge is crucial for understanding the impact of climate change and for further research using advanced modeling and generalisation to other habitats. For selected meteorological conditions measured at the stations, a statistically significant relationship was found for the temperature difference, which is strongest for snow depth and weakest for precipitation.

Keywords: microclimatology micrometeorology forest climate

Obsah

Úvod	3
1 Analýza lesního mikroklimatu	5
1.1 Fyzikální pohled na děje při povrchu země	5
1.1.1 Vliv latentního tepla	6
1.1.2 Albedo	7
1.1.3 Vliv lokálních podmínek	8
1.1.4 Vliv okraje lesa	8
1.1.5 Vliv vegetace	9
1.1.6 Rozdíl mezi teplotou při povrchu země a ve standardní výšce	11
1.2 Analýza faktorů ovlivňující teplotu vzduchu v lesním porostu	11
1.2.1 Vliv topografie a struktury krajiny na teplotu	11
1.2.2 Vliv porostu na teplotu	12
1.2.3 Vliv meteorologických podmínek na teplotu	13
1.3 Popis měření meteorologický veličin	16
1.3.1 Měření na meteorologických stanicích	16
1.3.2 Speciální měření pro studium podmínek v porostu	16
1.3.3 ERA5	17
1.3.4 Výpočet insolace	18
1.4 Národní park Šumava a Bavorský les	18
1.4.1 Klima	19
1.5 Statistické metody	22
1.5.1 Lineární smíšený model	22
1.5.2 ARMA model	22
1.5.3 F-test	23
1.5.4 Kvantil-kvantilový graf	23
1.5.5 Semivariogram	23

2	Analýza dat	25
2.1	Data z ČHMÚ	25
2.2	Data z Botanického ústavu Akademie věd	27
2.3	Insolace	29
2.4	Ukázka použitých dat	29
2.5	Metody analýzy dat	30
2.5.1	Korelace dat	32
2.5.2	Lineární model se smíšenými efekty	32
2.5.3	Přehled statistických modelů	36
2.5.4	Použitý software	39
3	Výsledky a diskuze	41
3.1	Analýza lineární smíšených modelů	41
3.1.1	Předpoklady lineárního smíšeného modelu	47
3.1.2	Insolace a minimální teplota	47
3.1.3	Srovnání modelů pro maximální teplotu a výšku 15 cm .	48
3.1.4	Srovnání modelů pro maximální teplotu a výšku 0 cm .	49
3.1.5	Srovnání modelů pro minimální teplotu a výšku 15 cm .	50
3.1.6	Srovnání modelů pro minimální teplotu a výšku 0 cm . .	51
3.1.7	Syntéza všech modelů	51
	Závěr	55
	Seznam použité literatury	57

Úvod

Meteorologická měření jsou po celém světě prováděna na standardizovaných meteorologických stanicích. Data z těchto stanic slouží například k předpovědi počasí nebo modelování klimatu. Z tohoto důvodu je snaha, aby na měřené veličiny, jako například teplotu vzduchu, neměly vliv místní podmínky. Meteorologická stanice by se proto neměla vyskytovat ve městě, kde je silný vliv tepelného ostrova nebo naopak v lese, kde stromy brání volnému proudění vzduchu. Existují ovšem i případy, kdy nás zajímá lokální klima. Například můžeme chtít studovat vliv podmínek, kterým jsou organismy vystaveny (Zellweger et al., 2019).

Vegetace, ať už louka, les nebo jiný biotop, významně ovlivňuje lokální klimatické podmínky. Nejvýznamnějším vlivem, který můžeme pozorovat napříč všemi většími lesními porosty po celém světě, je snížení teplot o 1 °C až 4 °C vůči teplotám mimo lesní porost (Zellweger et al., 2019). Tento pokles je způsoben stíněním slunečního záření, transpirací flóry, prouděním vzduchu a mnoha dalšími navzájem interagujícími prvky klimatického systému. Mezoklimatem myslíme klimatické podmínky na měřítku jednotek až desítek kilometrů a makroklimatem na libovolně větších škálách, zatímco mikroklimatem měřítko centimetrů až jednotek metrů. Lesním mikroklimatem máme na mysli klimatické podmínky uvnitř lesního porostu jako například teplota vzduchu, vlhkost vzduchu, rychlost větru a podobně. Každé lesní mikroklima má svá specifika daná typem porostu, roční dobou nebo například topografií a nadmořskou výškou.

Oteplování klimatu způsobuje změny, kterým se musí organismy rychle adaptovat. Porozuměním vztahu mezi makroklimatem a mikroklimatem v lese můžeme pochopit měnící se podmínky, které organismy zažívají. V posledních letech se věnuje větší pozornost tématu mikroklimatu v lesních porostech. Moderní čidla dokážou po dlouhou dobu automaticky měřit podmínky v lese bez pravidelné přítomnosti odborníka nebo odbornice (Wild, Kopecký et al., 2019). Tímto vzniká velké množství dat, ke kterým v minulosti nebyl přístup, a zároveň se otevírají nové možnosti vědeckého bádání. V současnost vzniká mnoho článků o vlivu topografie a vlivu typu lesního porostu na mikroklima prostřednictvím parametrů jako jsou otevřenost porostu, množství stromů v okolí, ale také vzdálenost k okraji lesa (Zellweger et al., 2019; Vanwalleghe a Meentemeyer, 2009; De Frenne

et al., 2021; Lindenmayer et al., 2022). Menší důraz se pak klade na vliv meteorologických podmínek na mikroklima. Z tohoto důvodu, se v rámci této práce snažíme spojit teoretické poznatky o vlivu vegetace na mikroklima, se znalostmi z mikrometeorologie a mikroklimatologie.

Cílem této práce je analyzovat rozdíl mezi teplotami naměřenými v lesním porostu ve výšce 2 m nad zemí a v 15 cm, resp. 0 cm nad zemí. Zájmovou oblastí je Národní park Šumava a Národní park Bavorský les z důvodu dostatečně dlouhé časové řady mikroklimatických dat. Rozdíl mezi těmito teplotami se snažíme vysvětlit pomocí meteorologických podmínek naměřených na nejbližších stanicích: výšky sněhové pokrývky, oblačnosti, půdní vlhkosti, množství srážek, rychlosti větru a insolaci. Nulová hypotéza je, že v dostupných datech nemají tyto prediktory vliv na rozdíl teplot v lesním porostu. Alternativní hypotéza je, že existuje vztah mezi prediktory a rozdílem teplot. Cílem této práce není pouze zkoumání, zdali existuje vztah mezi meteorologickými podmínkami a teplotami ve vegetaci, ale také hledání důvodů pro ne/přítomnost tohoto vztahu pomocí rešerše relevantní literatury. Toto nám může pomoci porozumět dynamice mikroklimatu. V budoucnosti by bylo možné navázat hlubší analýzou a modelováním a například provádět interpolaci na místa bez čidel nebo extrapolovat lesní mikroklima do minulosti.

První kapitola obsahuje teoretickou část práce. Nejprve rozebíráme energetickou bilanci poblíž zemského povrchu a následně se zaměříme na to, jakým způsobem je mikroklima v lese ovlivněno přítomností vegetace a jaký vliv má například topografie na denní průběh teplot. V další části popisujeme, jak meteorologické podmínky ovlivňují teplotu blízko země, a nakonec představujeme statistické metody, které jsou využité při analýze dat.

Ve druhé kapitole uvádíme příklad dat z meteorologických stanic a z čidel napříč Národními parky Šumava a Bavorský les. Následně na jednom modelu ilustrujeme, jakým způsobem budeme statisticky zpracovávat data a například zde řešíme nenormalitu dat, jejich časovou nebo prostorovou korelaci.

Ve třetí kapitole představujeme 32 modelů pro různé typy čidel a meteorologické parametry. Následně provedeme srovnání modelů mezi sebou a interpretujeme tyto výsledky pomocí znalostí z mikroklimatologie a mikrometeorologie. V poslední části se soustředíme na nedokonalosti a možná pokračování v tomto tématu.

Kapitola 1

Analýza lesního mikroklimatu


V následující části 1.1 popíšeme fyzikální děje odehrávající se poblíž zemského povrchu z pohledu mikrometeorologie a mikroklimatologie. Od jednoduchých ilustračních příkladů se přesuneme k tomu, jaký vliv má na mikroklima topografie 1.1.3 a přítomnost vegetace 1.1.5. V závěrečné části této kapitoly 1.3 popíšeme jak meteorologické podmínky ovlivňují teplotu a jak jsou měřeny, a v 1.4 se podíváme na klima typické pro Národní park Šumava a Bavorský les. V kapitole 1.5 popisujeme statistické metody využití v kapitole 2.

1.1 Fyzikální pohled na děje při povrchu země

Nyní popíšeme energetickou bilanci poblíž povrchu země. Pro rovný a téměř homogenní povrch, který můžeme omezit zeshora a zespoda rovinou, platí zjednodušená rovnice vyjadřující energetickou bilanci (Arya, 2001)

$$R_N = H + H_L + H_G + \Delta H_S, \quad (1.1)$$

kde R_N je celková bilance záření, H je tok zjevného tepla z/do atmosféry, H_L je latentní teplo, H_G je tok tepla ze země a ΔH_S je změna uchovaného tepla za jednotku času na jednotku plochy přes celou hloubku vrstvy. ΔH_S můžeme také interpretovat jako rozdíl mezi energií dodanou a odevzdanou z vrstvy, která nás zajímá. Pak platí pro $\Delta H_S > 0$ se vrstva ohřívá a pro $\Delta H_S < 0$ se ochlazuje, protože platí, že $H_{in} < H_{out}$. Na jednoduchém případě na obrázku 1.1 vidíme vývoj toku energie na povrch vyschlého jezera. Přes den se povrch ohřívá díky dopadu slunečního záření $R_N > 0$, část tepla uniká pod povrch, $H_G < 0$ a část ohřívá atmosféru, která sama pouze velmi málo absorbuje záření $H < 0$. Naopak v noci vyzařuje povrch dlouhovlnné záření a tím se ochlazuje, tedy $R_N < 0$, H je téměř nulové, a zahřáté hlubší vrstvy půdy zpětně ohřívají povrch, $H_G > 0$. Po celou dobu jde o suchý povrch, $H_L = 0$ (Arya, 2001). Většinou ovšem nemůžeme měřit přímo jednotlivé toky tepla.



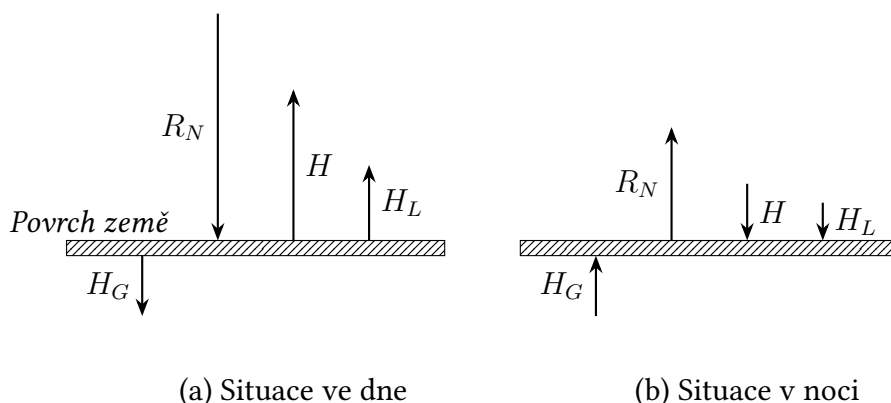
Obrázek 1.1 Pozorovaný tok tepla nad vyschlým jezerem El Mirage v Kalifornii 10.-11.6.1950 převzato z (Arya, 2001).

1.1.1 Vliv latentního tepla

Latentní teplo, které značíme H_L , je veličina týkající se změny skupenství látek, v našem případě týkající se vody. Formálně můžeme latentní teplo zavést jako $H_L = T\Delta s$, kde T je teplota, při které dochází ke změně skupenství, a Δs je rozdíl mezi molárními entropiemi obou fází (Callen, 1985). Za standardního atmosférického tlaku 1013 hPa je měrné latentní teplo tání $H_{lT} = 334 \text{ kJ/kg}$ a latentní teplo vypařování $H_{lv} = 2265 \text{ kJ/kg}$.

Výše jsme analyzovali situaci, kdy šlo o suchý povrch. Pro vlhký povrch se nám situace změní. Část tepla bude absorbována vodou a spotřebována na výpar. Můžeme ovšem mít i opačnou situaci, kdy dochází ke kondenzaci vodní páry a uvolňování latentního tepla. Analogicky můžeme uvažovat situaci v zimě, kdy je přítomná voda v pevném skupenství. V našem zjednodušeném příkladě je tedy přes den $H_L > 0$ a v noci $H_L < 0$. Schématické znázornění můžeme vidět na obrázku 1.2. Velikost jednotlivých toků tepla je ovlivněna mnoha faktory (Arya, 2001).

Vliv vlhkosti a deště můžeme ilustrovat na takzvaném "oázovém efektu". Oázovým efektem nazýváme situaci, kdy vítr přináší suchý teplý vzduch nad chladnou a vlhkou oblast. Dochází k silnému výparu, který ochlazuje povrch země. Například po dešti se může hodnota H_L stát v rovnici (1.1) i dominantní složkou. Následně máme tok tepla H negativní zatímco H_L je větší a pozitivní. Může se stát, že i tok tepla v půdě H_G změni znaménko, pokud povrch bude chladnější než půda (Arya, 2001).



Obrázek 1.2 Schéma energetické bilance ve dne a v noci.

Typ povrchu	Albedo
Vodní plocha	0.10-1.00
Čerstvý sníh	0.45-0.95
Suchý písek	0.35-0.45
Vlhký písek	0.2-0.3
Krátký trávník (20 cm)	0.26
Delší trávník (1 m)	0.16
Opadavý les	0.1-0.2
Neopadavý les	0.05-0.15

Tabulka 1.1 Výběr různých typů povrchů a odpovídajících hodnot albeda. Převzato z Arya, 2001.

1.1.2 Albedo

Energetickou bilanci ovlivňuje i albedo. Albedo je koeficient udávající poměr mezi odraženým a dopadajícím zářením. Nabývá hodnot v intervalu $\langle 0, 1 \rangle$, kde 0 znamená, že povrch všechno záření pohlcuje a jedná se o černé těleso. Naopak pokud albedo nabývá hodnoty 1, tak povrch všechno záření odráží. V mikrometeorologii myslíme albedem většinou odrazivost v konkrétní části spektra a to 0.15 μm až 4 μm . Vyzářování povrchu země se pak týká delších vlnových délek od 3 μm do 100 μm .

Už samotný typ povrchu má na albedo významný vliv. Může dosahovat velmi různých hodnot ať už jde o písek, vodní plochu, půdu bez vegetace nebo například vlhkou půdu. Albedo se také liší s ohledem na typ vegetace. Ilustrační příklady jsou v tabulce 1.1. Hodnoty jsou závislé i na úhlu dopadu záření, vliv má výška porostu nebo roční období (Arya, 2001; Geiger, 2009).

1.1.3 Vliv lokálních podmínek

V následující části se soustředíme na vliv topografie na meteorologické proměnné. Pro standardizované meteorologické stanice je typické, že jsou postavené na travnaté ploše, která není zastíněná a terén není nakloněn. V reálné krajině tohle ovšem neplatí.

1.1.4 Vliv okraje lesa

V oblasti okraje lesního porostu je rozhraní, ve kterém se rychle můžou měnit podmínky. Geografická orientace má vliv na to, jak dlouho dopadá denní světlo na toto rozhraní. Množství dopadající energie může být pro okraj lesa orientovaný na jih i několikrát větší, než pro okraj orientovaný na sever. To platí například pro lesy v Evropě. Na rozhraní lesa a otevřené oblasti můžeme dokonce pozorovat vyšší teploty než uvnitř lesa a mimo něj, částečně to může být kvůli sníženému promíchávání vzduchu, větší absorpci slunečního záření, stínění dlouhovlnného záření a nižšímu výparu. Vliv na teplotu má i vítr. Jestliže fouká směrem do lesa, teplota na okraji lesa má tendenci být podobná teplotě mimo les a naopak, pokud vítr fouká směrem z lesa (Geiger, 2009).

Vliv sklonu a orientace svahu

Množství slunečního záření, které dopadne na povrch země závisí na mnoha faktorech. Musíme vzít v potaz zeměpisnou šířku, období v roce, denní čas, sklon svahu a orientaci svahu. Například svah orientovaný na sever s velkým sklonem na severní polokouli nemusí dostat během zimy po většinu dne žádné sluneční záření. Abychom dostali úplný obrázek musíme započítat i difúzní záření, které je primární složkou záření, pokud je velká oblačnost. Difúzní sluneční záření je složka slunečního záření rozptýlená například atmosférou nebo oblaky a nemá daný směr narušen od přímého slunečního záření. Difúzní záření není do takové míry ovlivněné sklonem svahu (Geiger, 2009).

Vliv údolí

Dalším důležitým faktorem je utváření podmínek v dané lokalitě (kopec, údolí), kterou se zabýváme. Studený vzduch je hustší a tudíž klesá do údolí, kde pak může vznikat kapsa studeného vzduchu a inverze. Naopak v létě může docházet k intenzivnějšímu ohřátí údolní oblasti. Na dno pak může dopadat menší množství slunečního záření a dlouhovlnné záření může být částečně stíněno okraji údolí. Do údolí hůře proniká vítr, a tudíž je zde snížena turbulence a tím i turbulencí předávané teplo, viz 1.1.5. Všechny tyto faktory mají opačný vliv v případě kopců a obecně vyvýšených míst (Geiger, 2009).

1.1.5 Vliv vegetace

Vliv na toky tepla

Do členů v rovnici 1.1 můžeme zahrnout i růst vegetace. V tu chvíli musíme počítat s významnou prostorovou závislostí všech toků tepla a záření. Následně jsou pro nás nejdůležitější hodnoty R_N , H a H_L nad vegetací. ΔH_S se skládá ze dvou částí, a to změny uchovaného tepla ve vzduchu nebo vegetaci a změny energie biochemického původu skrze fotosyntézu a přesunu oxidu uhličitého. Latentní teplo se skládá z výparu a kondenzace vody a také z transpirace vody listy rostlin, mluvíme o evapotranspiraci. Při měření je obtížné od sebe transpiraci a evaporaci oddělit. Například během růstu plodín zpočátku je hlavní složka evapotranspirace výpar, ale později plodina zakrývá větší plochu povrchu tak se stává majoritní složkou transpirace a má významný vliv na energetickou bilanci (Arya, 2001; Allen et al., 1998).

Vliv na celkový tok energie má i výška porostu, například v lese může být nezanedbatelné množství tepla uchovaného v úrovni vegetace, které může způsobit, že prostředí reaguje pomalu na změnu teploty a jiných veličin. Pro suchý porost může uchovaná energie dosahovat až 7 % celkového toku energie. Situace se ovšem pro vlhký porost obrací, a uchovaná energie může být záporná. Míru uchování energie v porostu měříme v $J \cdot m^{-2} \cdot s^{-1}$. Typicky je kladná během dne, kdy se vzduch ohřívá a záporná v noci. Například oblačnost zmenšuje amplitudu denního chodu uchované energie (Geiger, 2009).

Podle (Geiger, 2009) ovlivňuje teplotu hustota porostu. Měříme-li teplotu v řídkém lese a sledujeme její průběh od země až po koruny stromů, tak teplo snadněji prochází vegetací. Při zemi budou podobné teploty jako ve výšce několika metrů nebo až v korunách stromů. Naopak, pokud se nacházíme v hustějším lese, tak bude teplota růst dříve v oblasti korun stromů a teplota při zemi může stoupat o několik hodin později a také dosahovat nižších denních maximálních hodnot. V noci také může v řídkém lese docházet k inverzi teplot, zatímco v hustějším lese budou teploty podobné napříč porostem.

Tok tepla v lese je ovlivněn i větrem. Jestliže fouká silný vítr, dochází k přenosu tepelné energie z nebo do lesního porostu. Rychlost přenosu může opět záviset na hustotě lesa (Geiger, 2009).

Vliv na míru turbulence

Turbulence vzduchu je zodpovědná za přenos hmoty, tepla a hybnosti v blízkosti povrchu země. Bez turbulence by promíchávání probíhalo na molekulární úrovni a řádově menším měřítku. Turbulenci ovlivňuje typ povrchu přes který se vzduchová hmota pohybuje. Například nad sněhovým polem nebo klidnou vodní plochou bude vzduch proudit s menší turbulentí a pro les s vegetací v bylinném

patře naopak vyšší (Geiger, 2009).

Vliv na rychlost větru

Přítomnost vegetace ovlivňuje rychlost větru a přenos vzduchových hmot z/do oblasti porostu. Profil větru může být v lese závislý na výšce nad zemským povrchem. Například koruny stromů mohou rychlost větru výrazně snižovat. Zatímco rychlost větru blíž povrchu může být vyšší, pokud blízko země nejsou menší stromy, keře nebo jiné překážky. To má pak vliv na teploty uvnitř porostu, které se mohou více podobat teplotám ve volném vzduchu. Z toho plyne, že vliv na rychlost větru má i přítomnost listů a jejich absence v zimě (Geiger, 2009).

Vliv na vlhkost vzduchu

V předchozím odstavci jsme zmínili transpiraci flóry, která slouží jako zdroj vodní páry. Ukázková situace v jehličnatém lese může vypadat tak, že tlak vodní páry dosahuje dvou maxim, a to při povrchu půdy z důvodu nižšího promíchávání vzduchu a výparu a v oblasti korun stromů kvůli listům. Druhé maximum bývá menší, kvůli promíchávání se suchým vzduchem nad korunami stromů (Geiger, 2009).

Vliv na rosu

Přítomnost stromů také ovlivňuje rozložení a množství rosy v jejich okolí. Tam, kde je porost hustší, dochází kvůli stínění dlouhovlnného záření k tvorbě menšího množství rosy a pomalejšího poklesu teplot během večera. Díky relativně vyšším večerním teplotám se sníží množství rosy. Nad ránem se naopak v lese drží déle nižší teploty, protože porost brání dopadu slunečního záření a tím setrvává rosa na zemi delší dobu. Při měření množství ranní rosy v různé vzdálenosti od kmene stromu s celkovým zápojem o poloměru 5.2 m bylo pozorováno, že množství rosy roste strmě do zhruba 2 m od kmene a dále pomaleji. Doba, po kterou zůstala rosa na zemi, také se vzdáleností rostla a od vzdálenosti 4 m lehce klesala (Geiger, 2009).

Vliv na déšť

Typ porostu (listnaté/jehličnaté lesy) má vliv na distribuci deště. Největší množství vody se objevuje na vnějším okraji půdorysu stromu ohraničeném korunou. Stromy bez listů mají na prostorové rozložení srážek minimální vliv. Pod jehličnaté stromy dopadá pouze 60 % až 90 % srážek, a v oblasti okraje korun dopadá o 10 % až 20 % více srážek než v místě bez porostu. Tento rozdíl je způsoben tím, že část vody stéká po větvích a listech směrem od kmene stromu. Konkrétní hodnoty

jsou ovlivněné druhem dřeviny a roční dobou. Lesní porost také při slabém dešti může úplně zabránit dopadu srážek na půdu. Množství vody, které takto dokážou stromy zachytit, se může pohybovat od 1 mm do 3 mm. Část vody se také vypaří z povrchu listu. To je podpořeno výraznějším promícháváním vzduchu v oblasti horní části korun stromů (Geiger, 2009).

Vliv na sníh

Množství sněhových srážek, které dopadnou na zem v lesním porostu, záleží na několika faktorech. Jestliže jde o mokrý sníh, pak snadno zůstává v korunách stromů. Takto může být v korunách zachyceno až 10 cm sněhu. Suchý sníh naopak snáze dopadne na zem. Množství zachyceného sněhu závisí také na typu vegetace, jestli jde o listnaté nebo jehličnaté stromy, případně o jaký druh stromu jde. Na jaře taje sníh v lese pomaleji a jeho přítomnost je pro místní klima velmi důležitá, protože funguje jako zásobník vody (Geiger, 2009).

1.1.6 Rozdíl mezi teplotou při povrchu země a ve standardní výšce

Teplota vzduchu se typicky měří ve výšce 1.25 m až 2 m (WMO, 2021), přičemž stanice Churáňov a ostatní automatické stanice použité v této práci měří teplotu vzduchu ve 2 m (ČHMÚ, 2023b). Jestliže máme situaci, kdy na povrch svítí přímé sluneční záření, tak se můžou poblíž povrchu vyskytovat výrazné gradienty teplot, a to 10 K/mm – 20 K/mm. Tyto výrazné gradienty jsou ovlivněné mnoha faktory jako například druh povrchu nebo jeho vlhkost a další, které byly diskutovány výše (Arya, 2001).

1.2 Analýza faktorů ovlivňující teplotu vzduchu v lesním porostu

V předchozích odstavcích jsme diskutovali vliv vegetace a topografie na různé meteorologické proměnné. Tuto souvislost v následující části budeme aplikovat na konkrétní studii týkající se výzkumných lesních ploch po střední Evropě.

1.2.1 Vliv topografie a struktury krajiny na teplotu

Při hledání vlivu topografie na rozdíl mezi teplotou v lesním porostu a na nejbližší meteorologické stanici ve střední Evropě byly ve výzkumu (Zellweger et al., 2019) použity následující prediktory:

- plocha pokrytá lesním porostem v okruhu 250 m vyjádřená v procentech
- vzdálenost k okraji lesa
- vzdálenost k nejbližšímu pobřeží
- výška nad mořem
- orientace svahu ke světovým stranám
- sklon svahu vzhledem k horizontální/vodorovné rovině
- index udávající zda-li jde spíše o údolí nebo vyvýšené místo
- slabšími prediktory pak byl sklon svahu k severu/jihu, sklon svahu a hodnota udávající zda-li jde spíše o údolí nebo vyvýšené místo

U plochy pokryté lesním porostem nebyla nalezena spojitost s rozdílem teplot. Vzdálenost k okraji lesa byla nevýznamným prediktorem. Vzdálenost k nejbližšímu pobřeží a výška nad mořem byly nejsilnějšími prediktory, zároveň jde ovšem o silně korelované veličiny. Sklon svahu k severu/jihu, sklon svahu k horizontální/vodorovné rovině a index údolí/vyvýšeného místa byly slabšími prediktory.

Tyto výsledky ovšem nejsou konzistentní mezi různými studiemi. Například podle (Greiser et al., 2018) je plocha pokrytá lesním porostem důležitou hodnotou a může vést ke zvýšení minimální denní teploty až o 3 °C, zároveň (Greiser et al., 2018) ukázali, že vzdálenost k okraji lesa je středně silným prediktorem.

1.2.2 Vliv porostu na teplotu

Druhou skupinou prediktorů, kterou se (Zellweger et al., 2019) zabýval, byly proměnné týkající se porostu v blízkém okolí čidla.

- zápoj, neboli míra uzavřenosti korun stromů, kde 0 % znamená, že obloha není stromy vůbec zakrytá a 100 %, že je úplně zakrytá
- otevřenost porostu vyjádřená jako část viditelné oblohy
- plocha koruny stromů
- procento plochy pokryté dřevinami s průměrem větším než 7.5 cm
- výška stromu, na kterém bylo čidlo upevněno
- schopnost porostu vytvářet stín podle typu dřeviny

Zápoj má pro hodnoty nižší než 89 % záporný vliv, pro vyšší hodnoty pak neutrální až lehce kladný vliv. Otevřenost porostu a plocha koruny stromů má záporný nelineární vztah k maximální teplotě. Procento plochy pokryté dřevinami je pouze slabým prediktorem. Výška stromu naopak souvisí s rozdílem maximální teplot kladně, ale opět zde vztah není příliš silný. Schopnost porostu vytvářet stín je středním prediktorem rozdílu maximálních teplot.

1.2.3 Vliv meteorologických podmínek na teplotu

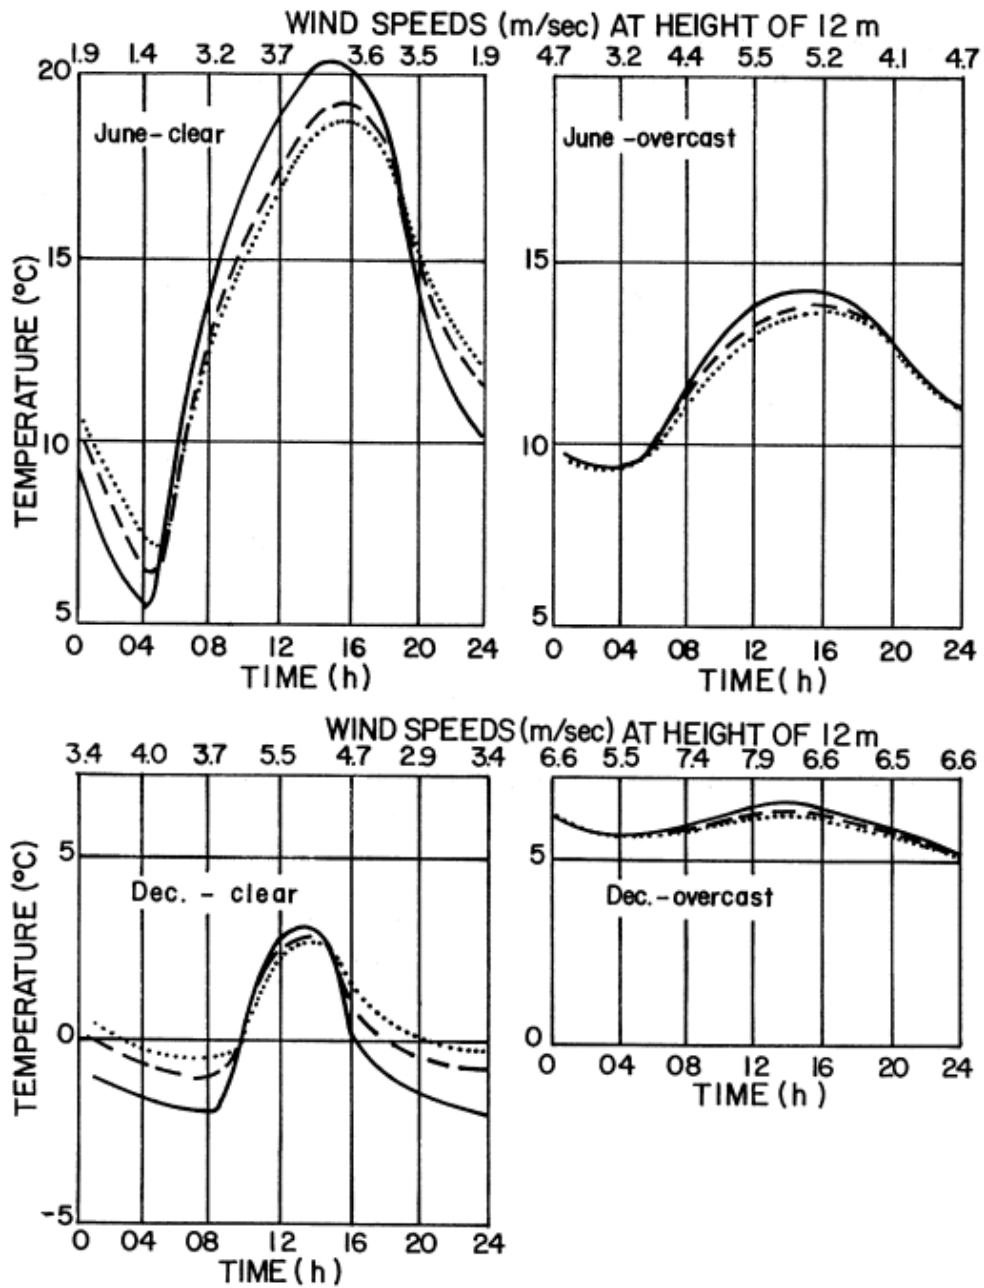
Jak bylo zmíněno v předchozí části, tak na rozdíl mezi teplotou mimo porost a v lese má vliv mnoho faktorů od topografických po konkrétní typ porostu. Tyto faktory se dají vyjádřit mnoha různými prediktory, jejichž vliv můžeme sledovat. Aktuální stav počasí je hlavním faktorem, který ovlivňuje naměřené teploty. Mezi takové faktory patří oblačnost, vlhkost, sněhová pokrývka, srážky, rychlost větru a insolace, s kterými budeme dále pracovat v kapitole 2.

Při větší *oblačnosti* dopadá na zem více rozptýleného záření a povrch země se neohřívá přes den tak rychle. To také závisí na typu oblačnosti, jestli se jedná o vysokou nebo nízkou oblačnost. Oblačnost také přes noc snižuje efektivní záření zemského povrchu, a tedy obecně snižuje amplitudu denních teplot. Tento pokles můžeme vidět na obrázku 1.3 (Arya, 2001).


Vítr napomáhá promíchávání ohřivaného vzduchu u zemského povrchu s vyššími vrstvami, a tedy typicky dochází při silnějším větru k poklesu teplotního gradientu nad zemí (Arya, 2001).

Sníh má nízkou tepelnou vodivost. Pod sněhovou pokrývkou tedy v zimě typicky dochází k nárůstu teplot. Zatímco na povrchu sněhu mohou teploty klesat hluboko pod bod mrazu, sníh izoluje zemský povrch a teploty pod ním se mohou blížit nebo i lehce přesahovat 0 °C. Studie z oblasti Altajského pohoří popsala rozdíl teplot mezi zemským povrchem a horní hranicí sněhové pokrývky (o výšce 0.5 m) až 12.8 °C. Vyšší teploty pod sněhovou pokrývkou využívají různé organismy pro přežití v zimě, viz obrázek 1.4 (Hirakawa a Nagasaka, 2018). Zatímco na rozhraní vzduch-sníh kolísají teploty od 0 °C téměř k -30 °C, tak s hloubkou nejenže amplituda dramaticky klesá, ale také jsou teploty bez výjimky vyšší. Dále můžeme vidět, že výkyvy teplot, ať už dané denním chodem nebo změnou počasí, mají ve sněhové pokrývce zpoždění, které se prodlužuje s výškou sněhu (Zhang et al., 2021). S rostoucí mocností sněhu klesá teplotní gradient uvnitř sněhové pokrývky, viz obrázek 1.5. Přítomnost sněhu snižuje teplotu na rozhraní sníh-atmosféra (Zhang et al., 2021).

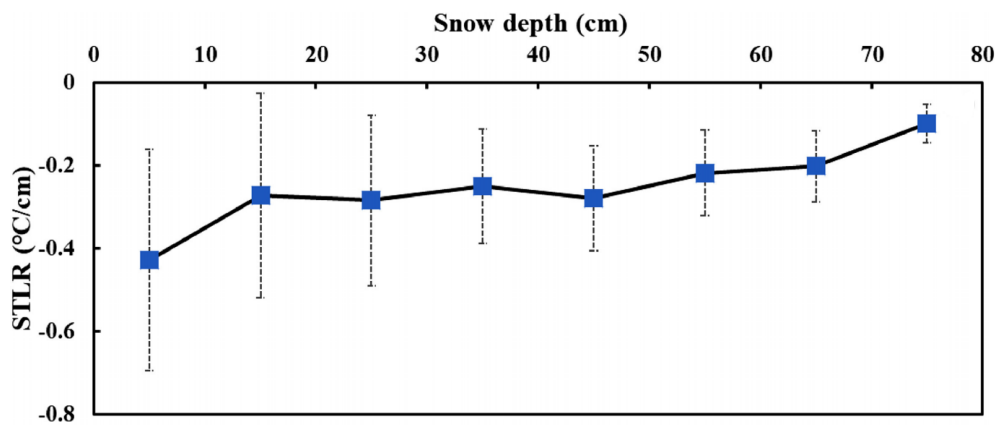
Kapalné *srážky* vedou k nárůstu vlhkosti, jejíž vliv je diskutován výše. Prudký nárůst latentního tepla při výparu může výrazně ovlivnit energetickou bilanci poblíž povrchu, jak bylo nastíněno v části 1.1.1. Dále se srážkami typicky roste oblačnost, a tedy klesá množství slunečního záření dopadajícího na zem. Studie



Obrázek 1.3 Denní vývoj teploty ve třech výškách (plná čára 1.2 m, čárkovaná 7 m a tečkovaná 17 m) v jižní Anglii pro jasnou a zataženou oblohu a pro červnové a prosincové teploty. Pro každou hodinu je uvedena i rychlost větru ve výšce 12 m. Převzato z Arya, 2001.



Obrázek 1.4 Výška sněhové pokrývky (a), průběh teplot pod sněhovou pokrývkou pro 10 cm, 15 cm, 20 cm, 30 cm, 40 cm nad rozhraním půda-sníh a na povrchu sněhu (b) na Altaji během zimní sezóny 2016/2017. Převzato z Zhang et al., 2021.



Obrázek 1.5 Teplotní gradient uvnitř sněhové pokrývky v závislosti na její mocnosti. Měřeno na Altaji od listopadu 2011 do dubna 2018. Chybové úsečky jsou standardní odchylka měření. Převzato z Zhang et al., 2021.

zabývající se korelací srážek a teploty v Evropě na téměř 100 stanicích zjistila, že v zimě na většině území je významná pozitivní korelace mezi množstvím srážek a teplotou. Pro oblast České republiky a Šumavy je korelace o něco menší a to 0.2. Pro letní období je pak naopak záporná, tedy s větším množstvím srážek klesají teploty, konkrétně jde o hodnotu korelace okolo -0.4 (Madden a Williams, 1978).

1.3 Popis měření meteorologický veličin

1.3.1 Měření na meteorologických stanicích

Teplota vzduchu by podle Světové meteorologické organizace (WMO) měla být měřena ve výšce 1.25 m až 2 m (WMO, 2021). V České republice Český hydro-meteorologický ústav provozuje celou řadu meteorologických stanic různého charakteru s měřením různých meteorologických proměnných. Stanice by měla být nad travnatým povrchem nikoliv například na asfaltu a měření probíhají v pravidelných intervalech. Na stanicích jsou měřeny veličiny jako například vlhkost, výška sněhu, množství oblačnosti, tlak a další (ČHMÚ, 2023d). Meteorologická stanice Churáňov, která je pro naše zpracování dat nejdůležitější, je označována za takzvanou automatizovanou stanici. Měření probíhá v souladu s metodickými doporučeními WMO (ČHMÚ, 2023c).

Automatické stanice dovolují častější měření než by bylo možné manuálně. Pomocí automatických stanic je možné měřit v místech, která jsou hůře přístupná. Navíc nám automatické stanice dovolují hustější staniční síť. Automatizace má ovšem i svá omezení, pokud jde o klasifikaci jevů nebo určování typu oblačnosti, zde je úloha meteorologa nebo meteoroložky nezastupitelná (ČHMÚ, 2023a).

1.3.2 Speciální měření pro studium podmínek v porostu

Pomocí meteorologických stanic není možné získat detailní informace o teplotě a dalších veličinách na malých prostorových škálách. Standardní meteorologické stanice nejsou určeny k měření teploty v lesním porostu. Data použítá v této práci jsou měřena pomocí TMS (Temperature-Moisture-Sensor) logger. Kromě čidel jako například Thermochron iButtons, je možné využít radiometrie a z vyzářeného záření z povrchu pomocí Stefan-Boltzmannova zákona spočítat teplotu povrchu. Radiometrie má ovšem své omezení, pokud chceme znát teplotu v lesním porostu, kvůli stínění.

TMS4 a T1 logger

Čidlo TMS4 logger je používané pro sběr dat vědci a vědkyněmi z Botanického ústavu Akademie věd České republiky. Toto čidlo je konstruováno tak, aby měřilo

podmínky, které ovlivňují malou bylinu. Je tedy vysoké 15 cm a sahá do hloubky 14 cm. Je opatřeno třemi teplotními senzory ve výškách 15 cm, 0 cm, -8 cm. Až do hloubky 14 cm je měřena volumetrická půdní vlhkost. Všechny hodnoty jsou měřeny v 15 minutových intervalech. Horní část data loggeru je opatřen optickým stíněním z bílého plastu chránícího horní senzor před přímým slunečním zářením. Podobně je odstíněn i senzor při povrchu země.

Teplotní senzor měří s přesností $\pm 0.5^\circ\text{C}$ a funguje v intervalu -55°C až 125°C . Měření volumetrické půdní vlhkosti je založené na time-domain-transmission (TDT), kdy jsou skrze obvod vysílány elektromagnetické pulzy a množství detekovaných pulzů je přímo úměrné vlhkosti.

METEOS 5 je standardní meteorologickou stanicí od firmy Meteoservis. Tyto stanice jsou používány na profesionálních stanicích ČHMÚ (Zacharov et al., 2015). Při srovnání TMS4 loggeru se stanicí METEOS 5 byla pozorována větší variabilita u teplot v 15 cm než ve 2 m. TMS4 logger byl instalován na krátkém posekaném trávníku, tři metry od stanice, a rozdíl teplot při hodinovém měření se pohyboval od 8.5°C do -6.1°C . Průměrné denní teploty naměřené z TMS4 loggeru byly systematicky nižší, průměrný rozdíl ovšem pouze -0.58°C , v zimě jsou tyto rozdíly větší a to -2.02°C až 0.6°C . Opačný trend pak můžeme pozorovat, pokud není teplotní senzor v 15 cm odstíněn plastovým krytem. V létě byly teploty nižší až o 5.08°C , ale v zimě byly podobné. Teploty z půdních senzorů jak TMS4 loggeru tak stanice METEOS 5 se lišily velmi málo, rozdíl mezi naměřenými teplotami byl zřejmě způsoben primárně polohou senzorů a použitým stíněním než jejich typem. Rozdíly mezi naměřenými teplotami nad zemí byly ještě výraznější pro proměnné, které jsou často používány v ekologických studiích, jako například kvantily extrémních teplot (Wild, Kopecký et al., 2019).

Data měřená při povrchu země jsou na některých místech doplněna stejnými teplotními senzory ve výšce 2 m upevněnými na kmenu stromu a také opatřena plastovým stínítkem.

1.3.3 ERA5

Chybějící hodnoty oblačnosti ze staničních měření doplníme pomocí dat z reanalýzy ERA5. Copernicus Climate Change and Atmosphere Monitoring Services provádí atmosférickou reanalýzu ERA5, která je pátou verzí této reanalýzy s daty od roku 1940 (Hersbach et al., 2018). Data s desítkami veličin jsou dostupná pro každou hodinu s rozlišením 0.5° , konkrétně budeme používat produkt "ERA5 hourly data on single levels from 1940 to present".

1.3.4 Výpočet insolace

Insolace je množství slunečního záření dopadajícího na jednotku vodorovné plochy za jednotku času. Insolace závisí na denní době, roční době a zeměpisné šířce. Okamžitá insolace je dána následujícím vztahem (Rose, 2020):

$$Q = S_0 \left(\frac{d_0}{d} \right)^2 (\sin \phi \sin \delta + \cos \phi \cos \delta \cos h), \quad (1.2)$$

kde S_0 solární konstanta, d_0 je průměrná vzdálenost Země od Slunce, d je aktuální vzdálenost Země od Slunce, ϕ je zeměpisná šířka, δ je deklinační úhel Slunce, h je hodinový úhel Slunce. Tento vzoreček platí pouze pro den, nikoliv v noci, kdy je $Q = 0$. Hodinový úhel Slunce spočteme následovně (Sena, 2021):

$$\begin{aligned} h &= 15^\circ (\text{LST} + \text{offset}/60 - 12) \\ \text{offset} &= \text{eot} + \text{longV} \\ \text{eot} &= 229.18 \cdot (0.000075 + 0.001868 \cos(\gamma) - 0.032077 \sin(\gamma) \\ &\quad - 0.014615 \cos(2\gamma) - 0.040849 \sin(2\gamma)) \\ \text{longV} &= 4 \cdot \text{longitude} \quad \gamma = \frac{2\pi}{365} \left(t - 1 + \frac{\text{hour} - 12}{24} \right), \end{aligned} \quad (1.3)$$

LST je místní sluneční čas, ke kterému přičteme korekci způsobenou eliptickou dráhou okolo země a skloněním zemské osy a korekci zahrnující to na jaké zeměpisné šířce se nacházíme. Faktor γ je část roku vyjádřena ve zlomku. Deklinační úhel s předpokladem, že Země obíhá po kružnici (Honsberg a Bowden, 2019):

$$\delta = -23.45^\circ \cdot \cos \left(\frac{360}{365} \cdot (t + 10) \right),$$

t je den v roce, tedy pro 1. leden $t = 1$. Vzdálenost Země od Slunce pro (1.2) je daná vztahem (Hammen, 2015):

$$d = 1 - 0.01672 \cdot \cos(0.9856 \cdot (t - 4))$$

1.4 Národní park Šumava a Bavorský les

Zájmovou oblastí této práce je Národní park Šumava o rozloze 68 064 ha (MŽP, 2023b) a Národní park Bavorský les, 24 250 ha.

Šumava patří mezi nejstarší pohoří ve střední Evropě (Wild, Neuhäuslová a Sofron, 2004). Typické horniny Šumavy jsou přeměněné horniny a to především ruly a vyvřelé horniny, zejména granity. Dále zde nalezneme uloženiny jako

jsou rašeliny, ale i sedimenty ledovcového původu. Svahové sedimenty jsou pak tvořeny hlínami, hlinitými písky, hlinito-kamenitými sedimenty a blokovými sedimenty. Nejvyšším bodem NP Šumava je Plechý 1378 m n. m., Šumavské pláně ve výšce 1000 m n. m. tvoří hlavní část národního parku (MŽP, 2023b). Většina pohoří na české straně náleží povodí Labe a tedy řece Vltavě.

Nejvyšší bod Národního parku Bavorský les je Großer Rachel (česky Roklan) o výšce 1453 m n. m., povodí většiny Bavorského lesa je Černé moře.

Až 80 % území NP Šumava tvoří lesy, nejvýznamnější jsou bučiny a horské smrčiny. Bučiny zaujímají nižší polohy a roste zde primárně buk lesní, javor klen, jilm horský a další. Ve vyšších polohách roste hlavně smrk ztepilý. Zbytek bezlesnatého území je pokryt rašeliništi, vodními toky nebo například loukami (MŽP, 2023a).


1.4.1 Klima

Průměrná teplota na Šumavě v období 1961 až 2018 se pohybuje od 4.2 °C v nejvýše položených oblastech do 8.3 °C v nižších oblastech. Vůbec nejnižší teplota (−41.6 °C) v NP Šumava byla naměřena v Jezerní slati 30. ledna 1987. Roční úhrn srážek se pohybuje v rozmezí od 800 mm až po 1600 mm. Větší míra srážek je pozorována pro oblasti Šumavy s vyšší nadmořskou výškou, viz obrázek 1.6 podobně pro Bavorsko a Bavorský les na obrázku 1.7. Průměrná sněhová pokrývka se rok od roku může velmi lišit. Například v zimním období 2019/2020 byla na většině stanic menší než 20 cm zatímco o rok dříve byla například na Javoří pile v únoru průměrná výška 100 cm (Bek, 2021). Doba po kterou sněhová pokrývka zůstává je 120 až 150 dní (MŽP, 2023b).

Srážkové poměry ŠUMAVY

Průměrný roční úhrn srážek
v období let 2000 - 2019

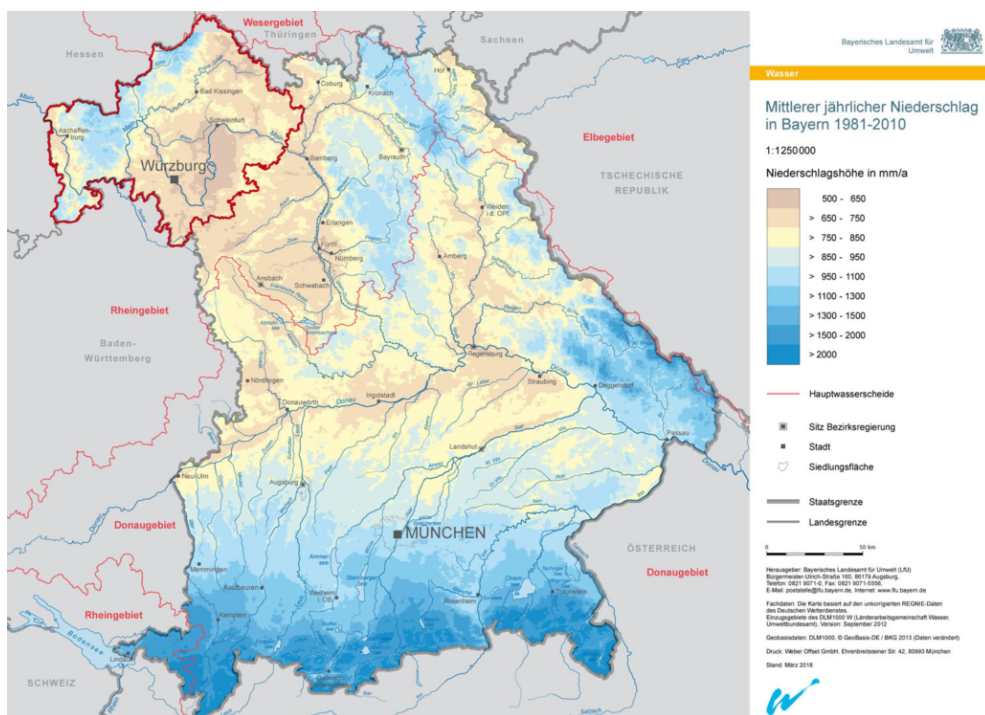
Úhrn srážek [mm]



0 10 20 km

1. Špičák 1450,8 mm	11. Jelení 975,7 mm	21. Rožmítal na Šumavě 772,9 mm	31. Slavkov 702,9 mm
2. Prácheň 1379,6 mm	12. Borová Lada 965,5 mm	22. Lipno 767,9 mm	32. Klemže 689,4 mm
3. Železná Ruda 1209,2 mm	13. Strážný 957,2 mm	23. Prachátce 766,5 mm	33. Sušice 676,6 mm
4. Kvilda 1177,6 mm	14. Štožec 952,5 mm	24. Černá v Pošumaví 747,0 mm	34. Červený Dvůr 673,2 mm
5. Filipova Huť 1127,6 mm	15. Cachrov 893,3 mm	25. Strážov 746,8 mm	35. Český Krumlov 665,0 mm
6. Horská Kvilda 1123,4 mm	16. Kašperské Hory 630,0 mm	26. Vacov 744,7 mm	36. Záleszí 651,0 mm
7. Hojsova Stráň 1091,9 mm	17. Zajítkův 809,2 mm	27. Přídoň 744,6 mm	37. Volyně 641,9 mm
8. Churáňov 1058,3 mm	18. Frantův 782,5 mm	28. Vyšší Brod 744,0 mm	38. Víkonice 639,7 mm
9. Síní 1006,8 mm	19. Vimperk 777,3 mm	29. Strašín 737,0 mm	39. Bavorov 637,7 mm
10. Kubova Huť 983,6 mm	20. Kís 773,1 mm	30. Husinec 709,8 mm	40. Strakonice 628,0 mm
			41. Chelčice 625,9 mm

Obrázek 1.6 Srážkové poměry Šumavy (Vacík, 2020), důležitá je hodnota 1058 mm/rok pro meteorologickou stanici Churáňov.



Obrázek 1.7 Srážkové poměry v Bavorsku (Umwelt BLU, 2023).

1.5 Statistické metody

1.5.1 Lineární smíšený model

V maticovém zápisu je lineární smíšený model definován následovně (McLean, Sanders a Stroup, 1991):

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{u} + \boldsymbol{\epsilon},$$

kde \mathbf{y} je vektor pozorovaných hodnot, $\boldsymbol{\beta}$ je neznámý vektor hledaných fixních efektů, \mathbf{u} je neznámý vektor náhodných efektů $\boldsymbol{\epsilon}$, je neznámý vektor náhodných chyb a matice \mathbf{X} a \mathbf{Z} jsou známé matice udávající vztah mezi pozorovanými hodnotami a fixními, resp. náhodnými efekty, jejichž velikost je daná počtem prediktorů a pozorování (McLean, Sanders a Stroup, 1991).

U lineárního smíšeného modelu předpokládáme normální rozdělení residuí a očekáváme homoskedasticitu, tedy to, že rezidua nezávisí na hodnotě měřené veličiny (Hoffmann, 2021). Dále také předpokládáme data bez autokorelační a prostorové struktury a normální rozdělení náhodných efektů modelu (Hefley et al., 2017).

Pro lineární smíšený model můžeme definovat marginální a podmíněné R^2 . Tato hodnota nám ukazuje kolik variance model vysvětluje. Marginální R_m^2 udává varianci vysvětlenou pomocí fixních efektů a podmíněné R_c^2 celého modelu.

$$R_m^2 = \frac{\sigma_f^2}{\sigma_f^2 + \sigma_\alpha^2 + \sigma_\epsilon^2}, \quad (1.4)$$

$$R_c^2 = \frac{\sigma_f^2 + \sigma_\alpha^2}{\sigma_f^2 + \sigma_\alpha^2 + \sigma_\epsilon^2}, \quad (1.5)$$

kde σ_f^2 je variance fixních efektů, σ_α^2 je variance náhodných efektů a σ_ϵ^2 je variance pozorovaných hodnot (Bartoň, 2023).

1.5.2 ARMA model

Pro modelování autokorelační struktury můžeme využít ARMA (autoregressive moving average) model. Ten je definován jako (Wilson, 2016):

$$y_T = \epsilon_T + \sum_{i=1}^p u_i y_{T-i} + \sum_{i=1}^q \beta_i \epsilon_{T-i},$$

kde y_T časová řada, ϵ je náhodná chyba, u_i jsou parametry náhodné proměnné a β_i jsou parametry fixní proměnné.

1.5.3 F-test

F-test může sloužit k testování statistické významnosti koeficientů lineárního (smíšeného) modelu. Máme-li nulovou hypotézu, že všechny koeficienty modelu $\beta_i = 0 \forall i$. Dále máme-li alternativní hypotézu $\exists j, \beta_j \neq 0$. Spočteme F statistiku jako podíl vysvětlené a nevysvětlené variance. Následně spočteme pomocí statistického softwaru konfidenční interval I , jako $(1 - \alpha) \cdot 100\%$, kde $\alpha = 0.05$. Zavrhneme nulovou hypotézu, pokud $F \notin I$ a určíme p-hodnotu. V programovacím jazyce R můžeme použít například funkci `anova` (Jost, 2017).

1.5.4 Kvantil-quantilový graf

Pro srovnání dvou statistických rozdělení používáme kvantil-quantilový graf. Na ose x jsou kvantily jednoho rozdělení a na ose y druhého. Pokud chceme zjistit, jestli datový soubor je blízký normálnímu rozdělení, vykreslíme proti sobě kvantily normálního rozdělení a kvantily datového souboru, čím blíže jsou hodnoty přímce $y(x) = x$, tím lépe odpovídá rozdělení normálnímu (až na násobek a konstantu rozdělení). Z kvantil-quantilového grafu můžeme také například odhalit, jestli jsou hodnoty zešikmené nebo jestli lépe odpovídají bimodálnímu rozdělení (b, 2014).

K testování normality nějakého rozdělení můžeme také použít formální testy jako například Shapiro-Wilkův test (Kozak a Piepho, 2018).

1.5.5 Semivariogram

Pro posouzení prostorové korelace dat využijeme metodu variogramu. Experimentální variogram nám určuje prostorovou závislost naměřených hodnot. V našem případě jde o hodnoty naměřených teplot neboli jejich rozdíl. Experimentální semivariogram může být definován například následovně

$$\gamma(\mathbf{h}) = \frac{1}{2m(\mathbf{h})} \sum_{i=1}^{m(\mathbf{h})} (t(\mathbf{x}_i) - t(\mathbf{x}_i + \mathbf{h}))^2,$$

kde v našem případě $t(\mathbf{x}_i)$ a $t(\mathbf{x}_i + \mathbf{h})$ jsou pozorované hodnoty (rozdílů) teplot na jednotlivých čidlech a $m(\mathbf{h})$ je počet párů teplot vzdálených od sebe o \mathbf{h} . Hodnota vzdálenosti \mathbf{h} se tedy pohybuje od vzdálenosti dvou nejbližších čidel až po vzdálenost dvou nejvzdálenějších čidel. Variogram je typicky dvojnásobek semivariogramu tedy $2\gamma(\mathbf{h})$ (Oliver, 2015).

Podle článku (Vanwallegem a Meentemeyer, 2009) prostorová korelace průměrný denních teplot v heterogenním lese v severní Kalifornii přestává být významná ve vzdálenosti 4 km až 6 km.

Kapitola 2

Analýza dat

V první části druhé kapitoly se zaměříme na popis struktury použitých dat. V druhé části analyzujeme autokorelační a prostorovou složku dat, a hledat vhodný model pro vysvětlení rozdílů naměřených teplot.


2.1 Data z ČHMÚ

Pro hledání souvislosti mezi meteorologickými podmínkami a rozdílem teplot na čidlech poblíž země jsme využili data z meteorologických stanic Churáňov, Borová Lada, Kvilda, Horská Kvilda a Javoří pila. Nejvíce informací jsme získali ze synoptické stanice Churáňov. Z dostupných dat jsme pro další analýzu využili data o aktuální teplotě ve výšce 2 m, rychlosti větru, výšce sněhové pokrývky, hodinových srážek a oblačnosti. Z ostatních stanic jsme měli k dispozici hodinová data o výšce sněhové pokrývky a pro Borovou Ladu informace o úhrnu srážek.


Analýzu provádíme pro období od 12.10.2019 do 21.5.2021 i když v případě některých čidel kvůli výpadkům měření bude zpracováván interval kratší (viz kapitola 2.2).

Na obrázku 2.1 můžeme vidět ukázkou dat z meteorologické stanice Churáňov. Maximální teplota (27°C) za období 12.10.2019 až 20.5.2021 byla naměřena 21.8.2020 a minimální (-16.1°C) byla naměřena 11.2.2021 a 13.2.2021. Největší sněhová pokrývka byla 48 cm 31.1.2021.


Meteorologická stanice Churáňov měří podle principů popsaných v kapitole 1.3.1. Stanice zaznamenává oblačnost každou hodinu od 6:00 do 20:00 UTC. Maximální teploty jsou typicky dosaženy během dne, kdy většinou oblačnost známe. Například v zimě pod sněhem může ale maximální denní teplota být dosažena i v noci. Minimální denní teploty na druhou stranu typicky nastávají během ranních hodin, po východu Slunce, ale ojedinele i před ním (viz kapitola 2.4 a obrázek 2.5). Pro minimální teploty nám tedy často chybí údaj o oblačnosti. Vyřazení těchto



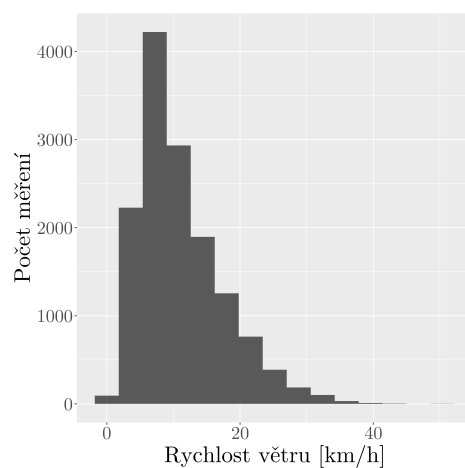
(a) Okamžité denní teploty ve výšce 2 m nad zemí rozdělené podle měsíců v roce.



(b) Denní sněhová pokrývka.



(c) Denní suma srážek.



(d) Histogram pozorovaných okamžitých rychlostí větru.

Obrázek 2.1 Data ze synoptické stanice Churáňov za období 12.10.2019 až 20.5.2021. Rychlost větru zobrazujeme jako obyčejný histogram, protože jde o informativnější graf než dělení podle měsíců v roce. Horizontální čára označuje medián, hodnoty uvnitř krabičky jsou mezi 25 (Q_1) a 75 percentilem (Q_3) a odlehlé body jsou ty, které mají hodnotu větší nebo menší o 1.5násobek velikosti krabičky $Q_3 - Q_1$.

hodnot by vložilo velké zkreslení do dat, tudíž jsme se rozhodli využít data z projektu ERA5.

Pro každou hodnotu, která chybí ze staničního měření použijeme nejbližší hodnotu z ERA5 a to konkrétně z 49° severní šířky a 13.5° východní délky. Tato data byla vzdálená od stanice Churáňov 14.8 km. Tímto zavádíme do dat určitou nejistotu, ať už kvůli prostorovému skoku, ale také zkreslení, když používáme data z odlišných zdrojů, kdy jedním jsou měřená a druhým pouze modelována. Pro robustnější modely a interpretaci by bylo vhodné spočítat modely pouze s daty z ERA5 a porovnat výsledky. Pro sofistikovanější přístup bychom mohli také využít data z více bodů a provést prostorovou interpolaci na místa čidel. Toto jde ovšem za rámec této práce.

2.2 Data z Botanického ústavu Akademie věd

Data poskytnutá Botanickým ústavem Akademie věd České republiky byla naměřená dvěma typy čidel popsány v kapitole 1.3.2. Nadále se budeme zabývat pouze těmi plochami, které jsou opatřeny jak pozemními čidly, tak čidly ve standardní výšce 2 m. Na obrázku 2.2 můžeme vidět jejich prostorové rozložení, celkově jde o 157 čidel.

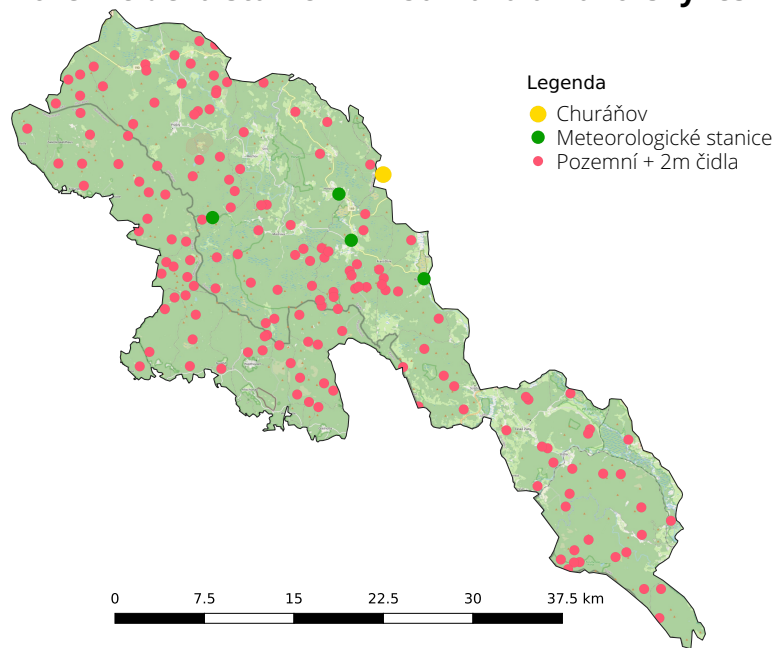
Umístění čidel bylo vybíráno tak, aby pokryly gradienty nadmořské výšky (5 tříd), potenciální solární radiace, určující množství záření, které dopadá na zem (3 třídy) a topografického vlhkostního indexu, který kombinuje svazitost a akumulaci vody v terénu (3 třídy). Plochy byly dále doplněny tak, aby bylo rovnoměrně pokryto území národních parků, a aby se nevyskytovaly poblíž turistických stezek.

Data vykazují malou chybovost, duplicitní a chybějící záznamy byly vyřazeny. Dále byla data vizuálně překontrolována, jestli neobsahují očividně chybná data. Části, kdy byla čidla např. povytažená ze země (pozná se podle hodnot půdní vlhkosti), byly nahrazeny hodnotami NA. Podobně pokud čidlo T1 spadlo ze stromu, tak jsou hodnoty nahrazeny NA. Toto čištění dat provedli RNDr. Josef Brůna, Ph.D., doc. Ing. Jan Wild, Ph.D. a další, s jejichž svolením jsou data využita v této práci. Ve velmi ojedinělých případech chyběly odpovídající hodnoty teplot ve 2 m, v době, kdy při zemi nastalo denní maximum nebo minimum. Pokud existovaly hodnoty až 30 minut starší, tak jsme použili tyto, v opačném případě jsme čidlo pro daný den vyřadili, šlo o jednotky případů.


Dostupnost dat z čidel je vidět na obrázku 2.3a, vidíme zde dvě skupiny čidel. Čidla nacházející se v Národním parku Bavorský les mají dostupná data pro cca 400 dnů. Čidla z Národního parku Šumava mají dostupná data pro téměř 600 dnů. Na obrázku 2.3b vidíme, na kolika čidlech jsou zastoupeny jednotlivé dny.

Pro samotné zpracování jsme vyřadili poslední 4 dny v květnu, kvůli niž-

Rozložení čidel a stanic v NP Šumava a Bavorský les




Obrázek 2.2 Rozložení čidel a meteorologický stanic v Národním parku Šumava ($N = 112$) a Národním parku Bavorský les ($N = 45$).



(a) Histogram ukazující množství dostupných dnů pro jednotlivá čidla.

(b) Graf zastoupení čidel pro jednotlivé dny

Obrázek 2.3 Dostupnost dat z čidel



Obrázek 2.4 Hodnoty insolace na čidlu nejbližze stanici Churáňov v době dosažení maximální denní teploty ve výšce 15 cm.

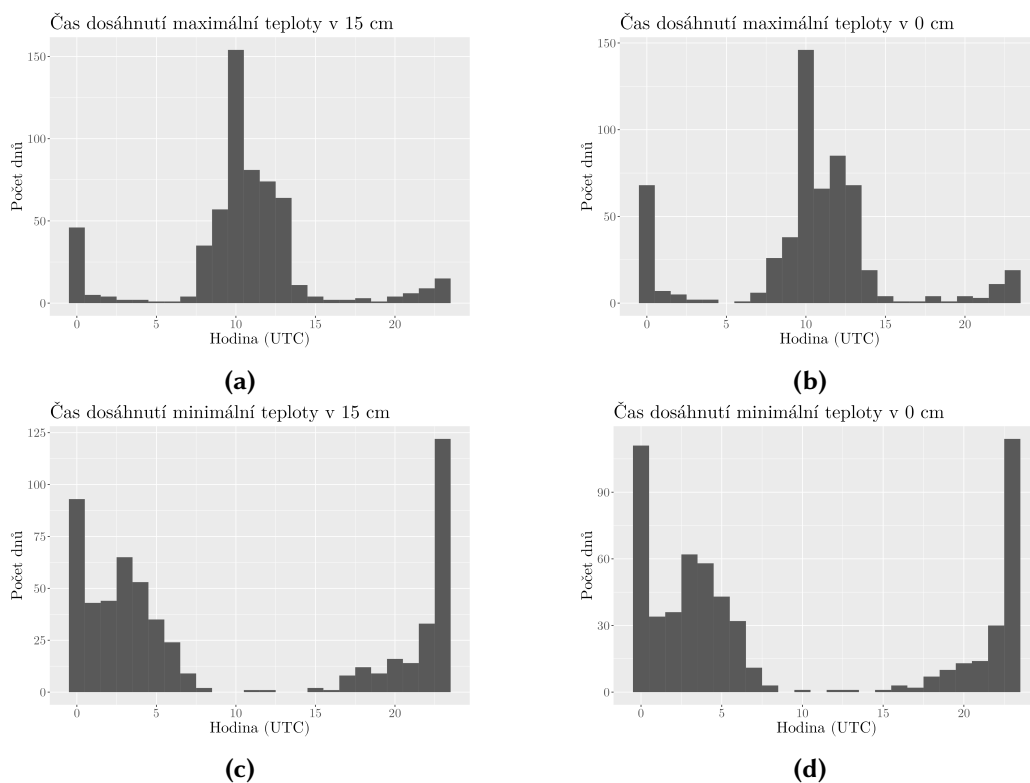
šímu počtu aktivních čidel. Tímto se dostáváme na interval dat od 12.10.2019 do 17.5.2021.

2.3 Insolace

Na obrázku 2.4 můžeme vidět hodnoty insolace spočtené podle odstavce 1.3.4 pro čidlo, které je nejbliž stanici Churáňov. Sinusoida nám téměř určuje hodnotu maximální denní insolace. Maximum insolace většinou nastává dříve než maximální teploty. Dále také pracujeme na časovém měřítku 15 minut a je tedy malá pravděpodobnost, že nastane maximální denní teplota ve stejnou dobu jako maximální denní insolace. Nulové hodnoty odpovídají tomu, že denní maximální teplota nastala v noci, to způsobuje přítomnost sněhu v zimě.

2.4 Ukázka použitých dat

Dále se podíváme na ukázkou dat naměřených na čidlech. Na obrázcích 2.5 můžeme vidět, kdy nastávaly maximální a minimální teploty ve výškách 0 cm a 15 cm nad zemí, denní hodina je uvedena v UTC, nikoliv SEČ nebo SELČ. U maximálních



Obrázek 2.5 Denní doba (UTC) dosažení maximální resp. minimální teploty v 15 cm resp. v 0 cm nad zemí na čidle nejbliže stanici Churáňov

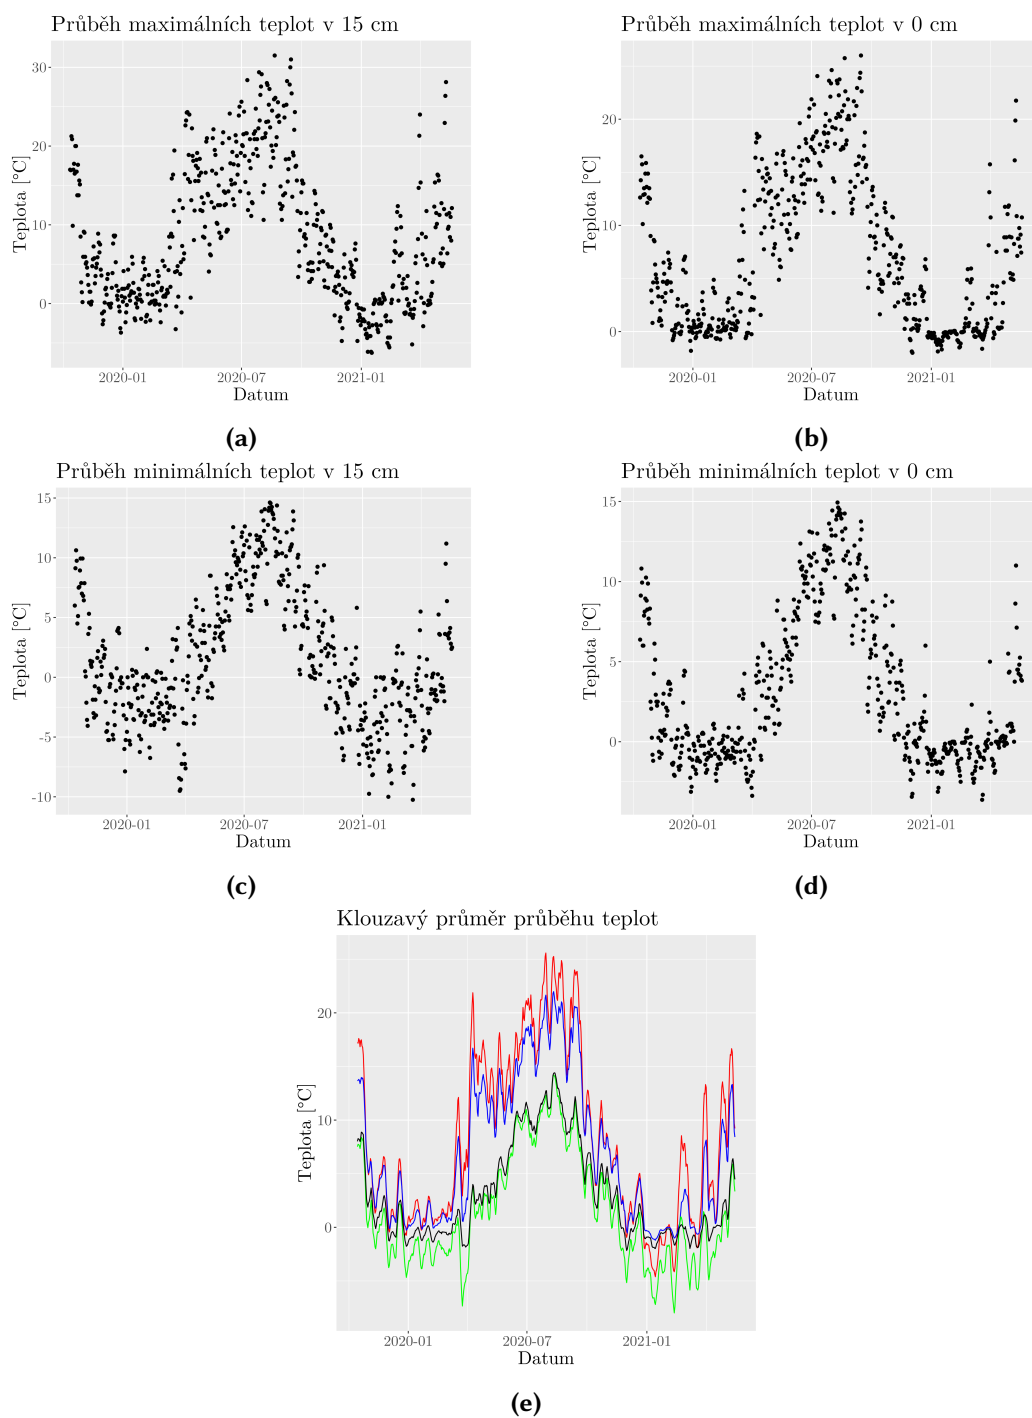
teplot si můžeme všimnout kromě maxima v době kolem 10 UTC také menšího maxima a odlehlých hodnot způsobených přítomností sněhu v zimě. Podobně měl sníh vliv i na dobu minimálních teplot v zimě.

Pro ilustraci se podívejme na konkrétní hodnoty teplot pozorované na nejbližším čidlu meteorologické stanice Churáňov. Na obrázcích 2.6 můžeme vidět průběh denních minim a maxim na jednom z čidel, celkově jde o 587 dní, období od 12.10.2019 do 20.5.2021. Na obrázcích 2.7 můžeme vidět hodnoty teplot naměřených ve výšce 2 m na čidle zavěšeném na stromě poblíž pozemním čidlům, jde o hodnoty naměřené v době denního teplotního maxima a minima ve výšce 15 cm.

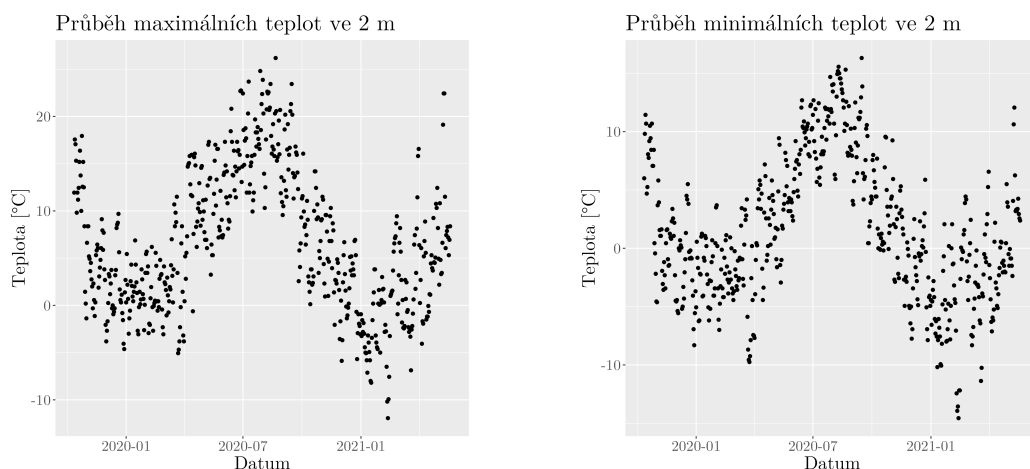
Na obrázku 2.8 můžeme vidět histogramy rozdílů teplot pro jednotlivé výšky a pro maxima a minima.

2.5 Metody analýzy dat

Cílem následující části je ukázat jakým způsobem byla data zpracována, proč byl vybrán daný model a ukázat metody ověření předpokladů.



Obrázek 2.6 Průběh denních maximální resp. minimálních teplot ve výšce 15 cm resp. 0 cm nad zemí na čidle nejbližze stanici Churáňov (a-d). Klouzavý týdenní průměr (e) pro grafy (a-d) s barvami, kde (a) červená, (b) modrá, (c) zelená a (d) černá.



(a) Teploty naměřené ve stejnou dobu jako maximální teploty v 15 cm

(b) Teploty naměřené ve stejnou dobu jako minimální teploty v 15 cm

Obrázek 2.7 Teploty ve výšce 2 m nad zemí na čidle nejbližší stanici Churáňov v době kdy nastalo maximum resp. minimum na čidle ve výšce 15 cm

2.5.1 Korelace dat


Z povahy naměřených dat je zřejmé, že zde existuje časová autokorelace mezi naměřenými maximálními nebo minimálními teplotami. Autokorelace se pak projevuje i u rozdílu teploty naměřené blízko země a ve 2 m. Na obrázku 2.9 vidíme autokorelační funkci pro jedno z čidel.

Autokorelace není takto významná pro všechna čidla, ale i tak nám vylučuje možnost využít jednoduché mnohonásobné lineární regrese.


Kvůli prostorové struktuře dat musíme otestovat prostorovou korelaci. Využijeme teorii popsanou v kapitole 1.5.5. Na obrázcích 2.10 vidíme dvanáct semi-variogramů pro každý první den měsíce v roce 2020. Kvůli lišícím se hodnotám semivariance nemůžeme semi-variogramy zakreslit do jednoho grafu. Ze semi-variogramů můžeme usoudit, že v datech neexistuje významná prostorová korelace, kterou bychom museli v modelu zohlednit (prostorovou korelaci, bychom očekávali hlavně v prvních deseti kilometrech viz kapitola 1.5.5).

2.5.2 Lineární model se smíšenými efekty

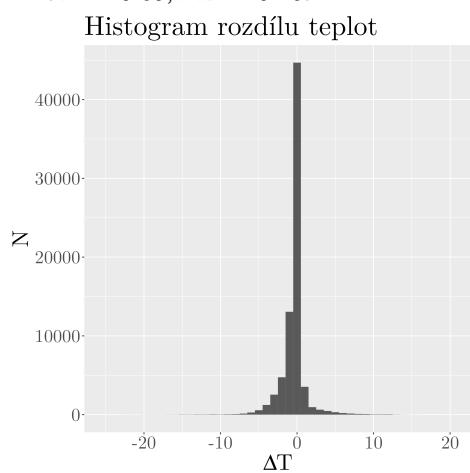
Pro analýzu vlivu meteorologických proměnných je vhodný lineární model se smíšenými efekty popsaný v kapitole 1.5.1. Jako náhodný efekt, jehož reálná hodnota pro nás není důležitá, určíme identitu (název) páru pozemního čidla a čidla ve výšce 2 m. Vybereme identitu čidla jako náhodný efekt, protože nás ve výsledném modelu nezajímají koeficienty každého čidla, nejde pro nás o důležitý prediktor.




(a) Rozdíl maximálních teplot v 15 cm a 2 m. $M = 0.69$, $MD = 0.25$.



(b) Rozdíl maximálních teplot v 0 cm a 2 m. $M = -0.24$, $MD = -0.25$.

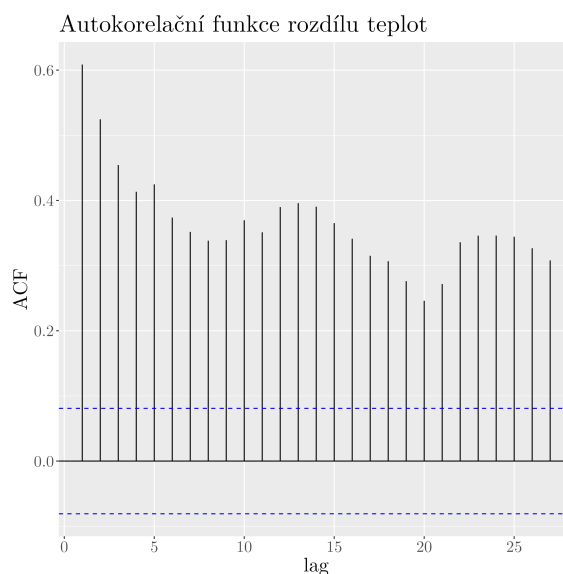


(c) Rozdíl minimálních teplot v 15 cm a 2 m. $M = -0.36$, $MD = -0.125$.



(d) Rozdíl minimálních teplot v 0 cm a 2 m. $M = 1.14$, $MD = 0.9375$.

Obrázek 2.8 Histogramy rozdílů maximální, resp. minimální teploty v 15 cm, resp. v 0 cm a ve 2 m. Ke každému histogramu uvádíme odpovídající hodnotu průměru M a mediánu MD .



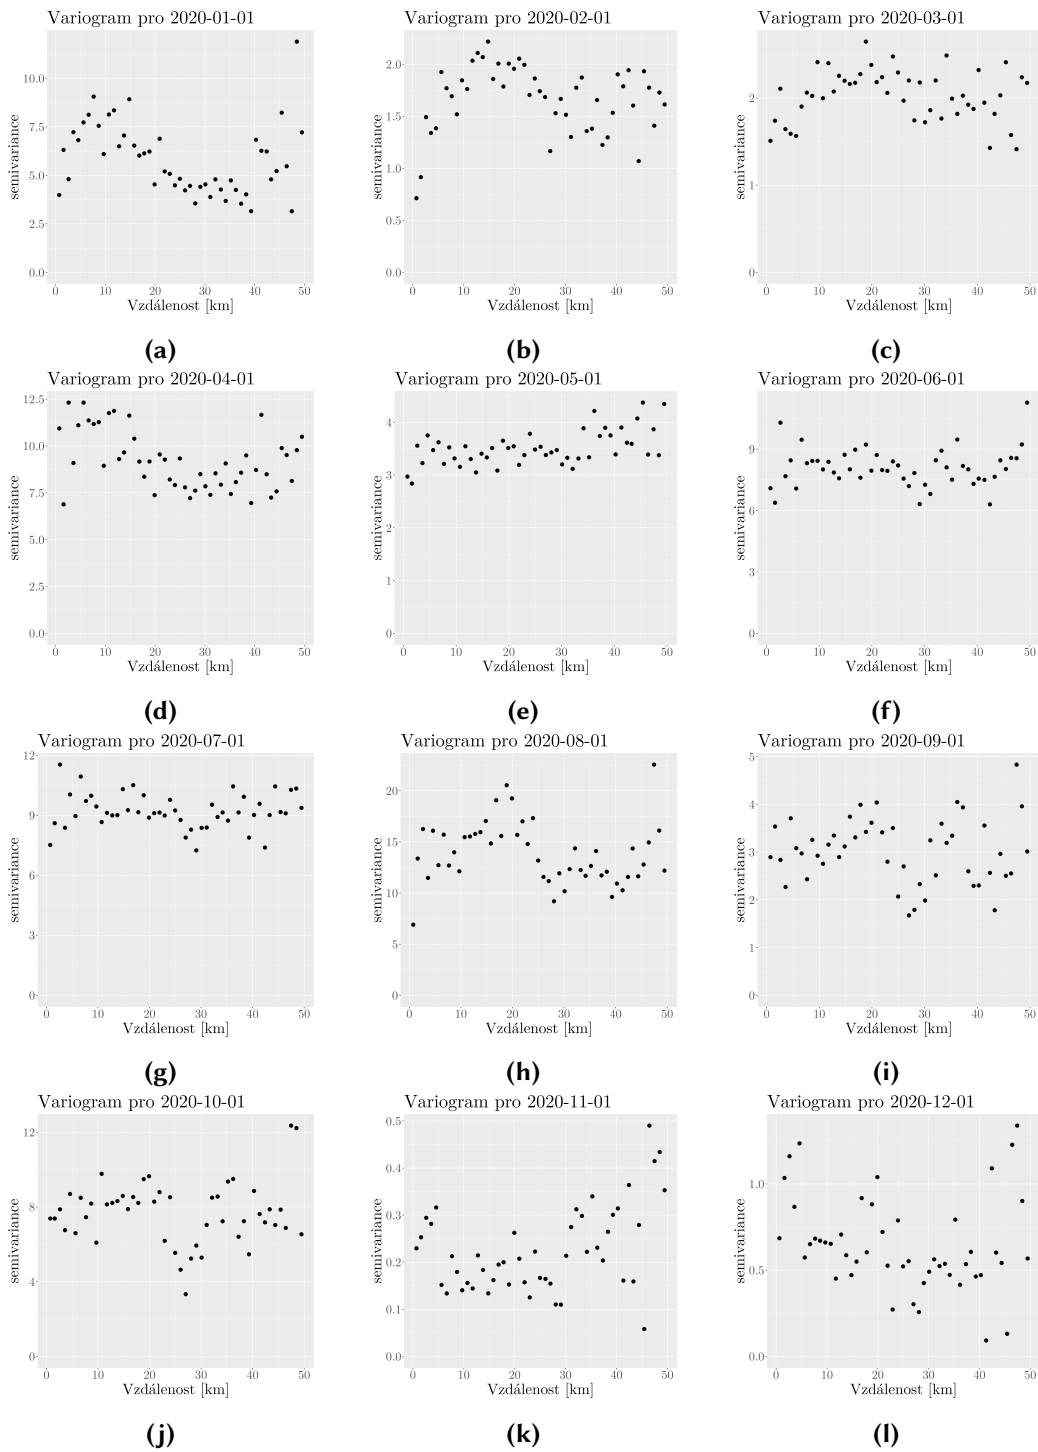
Obrázek 2.9 Časová autokorelační funkce pro rozdíl teplot mezi maximální teplotou v 15 cm a teplotou ve 2 m na páru čidel nejbližší meteorologické stanici Churáňov.

Také předpokládáme, že díky tomu, že jsou čidla rovnoměrně rozložena po ploše národních parků tak jde o výběr s normálním rozdělením z možných pozic čidel. Když vyřadíme měření, pro která chybí některá data z meteorologických stanic, a poslední čtyři dny měření, kdy máme data z menšího množství čidel, tak máme 76627 měření, hodnoty pro jiné kombinace čidel a maximálních/minimálních teplot jsou v tabulce 2.1.

Zpracovávaná data mají šest prediktorů: insolace, srážky za poslední hodinu, celková sněhová pokrývka, oblačnost, rychlost větru a půdní vlhkost. Oblačnost nabývá diskretních hodnot, je vyjádřena v osminách celkové oblohy. Data z reanalýzy ERA5 jsou vyjádřena v procentech, všechny hodnoty tedy převedeme do intervalu 0 až 1. Rychlost větru je měřena v diskretních násobcích 1 km/h. Ostatní prediktory, stejně jako rozdíl mezi teplotami při povrchu země, který se snažíme vysvětlit, jsou spojité proměnné.

Pro výpočet lineárního modelu se smíšenými efekty použijeme funkci `lme` z balíčku `nlme` programovacího jazyka R.

Pro každý model budeme ověřovat předpoklady lineárního modelu se smíšenými efekty. Krátce ilustrujeme problémy na jednom modelu, s kterými se budeme v kapitole 3 potýkat. Pracujme tedy s maximální denní teplotou ve výšce 15 cm a jejím rozdílem od teploty naměřené ve 2 m. Porovnáme mezi sebou residuály transformované proměnné, kterou se snažíme vysvětlit, a to bez transformace, s logaritmem, odmocninou a třetí odmocninou. Zároveň data mají silnou autokorelaci a tudíž, použijeme pro autokorelační strukturu model ARMA s parametry



Obrázek 2.10 Semivariogramy pro jednotlivé první dny měsíců v roce 2020.

$p = 2$ a $q = 1$ (tyto hodnoty byly vybrány vyzkoušením několika kombinací). Na obrázcích 2.11 vidíme kvantil-kvantilový graf pro jednotlivé transformace. Hodnoty rozdílu teplot jsou ovšem i záporné, tudíž místo jednoduchého logaritmu použijeme transformaci (2.1). Podobně ošetříme záporné hodnoty i pro ostatní transformace, jako například 3. odmocninu (2.2). V datech se objevují i hodnoty rozdílu teplot $\Delta t = 0$ pro které nemůžeme spočítat logaritmus. Jde ovšem o hodnoty pouze blízké nule, způsobené konečnou přesností čidel, tudíž na tyto hodnoty aplikujeme funkci `jitter`. Tato funkce přidá k hodnotám šum a používáme defaultní parametr `factor = 0`. Tímto je odlišíme od nuly a následně provedeme transformaci.

$$T \mapsto \text{sign}(T) \cdot \ln |T| \quad (2.1)$$

$$T \mapsto \text{sign}(T) \cdot \sqrt[3]{|T|} \quad (2.2)$$

Vidíme, že nejlépe normálnímu rozdělení odpovídá transformace pomocí třetí odmocniny, a proto s ní budeme nadále pracovat. Transformace ovšem není dokonalá, stále jsme se úplně nezbavili šikmosti (skewness). Formální testy normality rozdělení jako například Shapiro-Wilkův test se zde nehodí, neboť jsou velmi náchylné na malé odchylky od normálního rozdělení (Meys, 2018).


Homoskedasticitu budeme ověřovat graficky, pomocí srovnání fitovaných hodnot a residuálů modelu. Pokud nebyl porušen předpoklad homoskedasticity, tak nesmíme pozorovat závislost mezi fitovanými hodnotami a residuály, jak bylo popsáno v kapitole 1.5.1. V našem modelu není žádná výrazná heteroskedasticita, tedy není zde zřejmý vztah mezi residuály modelu a fitovanými hodnotami, viz obrázek 2.12.

Pro ilustraci důležitosti ARMA modelu na obrázku 2.13a autokorelační funkci bez modelu ARMA a na 2.13b s modelem ARMA. Hodnota ACF pro lag = 0 je vyřazená pro větší přehlednost grafu, vždy nabývá hodnoty 1.


Vidíme, že přidání ARMA s hodnotami ($p = 2$ a $q = 1$) se výrazně zlepšil autokorelační funkce a korelační strukturu jsme téměř odfiltrovali. Testovali jsme i jiné hodnoty p a q , ale pro $p = 2$ a $q = 1$ nám vyšla autokorelační funkce s nejmenšími hodnotami. S rostoucím p a q také roste výpočetní náročnost, pro $p = 3$ a $q = 3$ se ACF téměř nezmění, ale výpočet trvá až 4-krát déle (na počítači, který byl používán ke zpracování, šlo o více než 3 hodiny výpočetního času).

2.5.3 Přehled statistických modelů

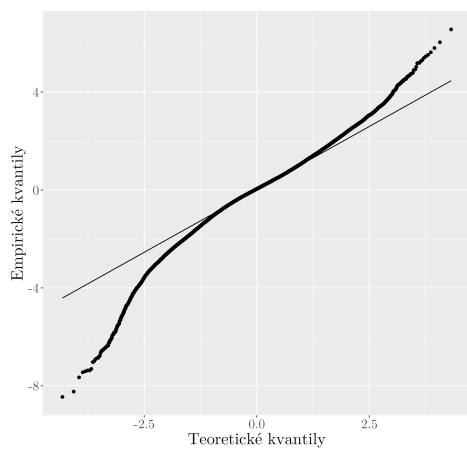
Výše jsme ukázali, jakým způsobem zpracováváme jednotlivé modely. Pro přehlednost označujeme modely zkratkou. Seznam modelů je v tabulce 2.1. Kromě již zmiňovaných modelů pro maximální a minimální denní teploty a výšku 15 cm



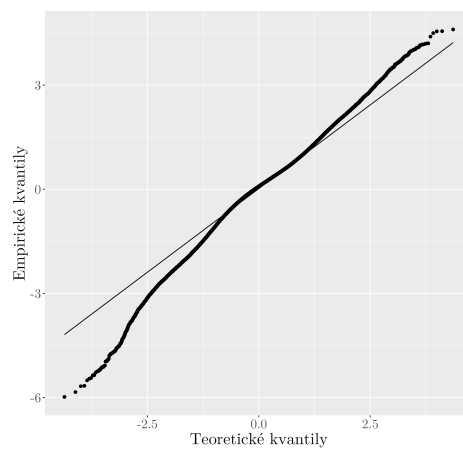
(a) Bez transformace



(b) Přirozený logaritmus




(c) Druhá odmocnina

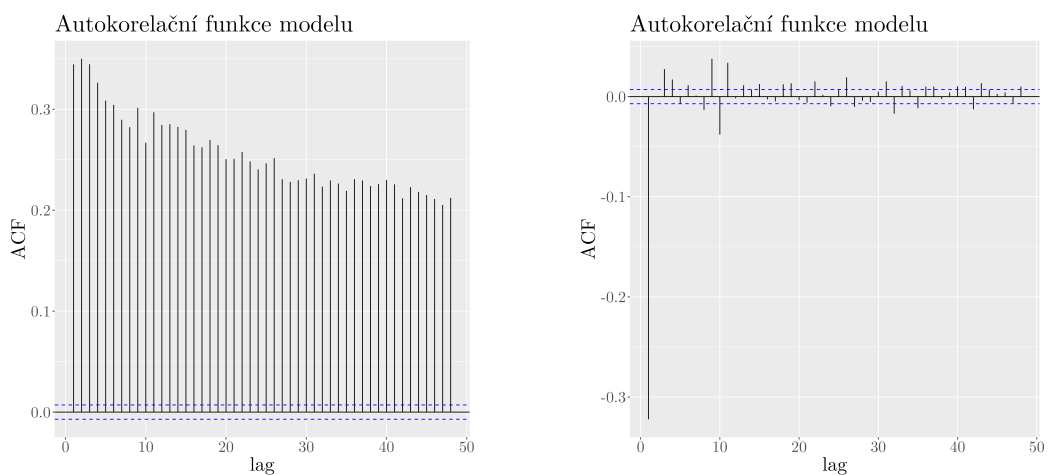


(d) Třetí odmocnina

Obrázek 2.11 Kvantil-kvantilový graf pro jednotlivé transformace vysvětlované proměnné.



Obrázek 2.12 Srovnání residuálů modelu s fitovanými hodnotami pro transformaci pomocí třetí odmocniny.



(a) Autokorelační funkce pro model s transformací $\sqrt[3]{\cdot}$, ale bez modelování autokorelační struktury.

(b) Autokorelační funkce pro model s transformací $\sqrt[3]{\cdot}$, s modelováním autokorelační struktury, kde $p = 2$, $q = 1$.

Obrázek 2.13 Srovnání autokorelační funkce modelu s a bez ARMA

Název modelu	Teploty	Výška čidla	Období	Počet čidel	Počet měření
Max15all	max.	15 cm	vše	157	76627
Max0all	max.	0 cm	vše	157	76635
Min15all	min.	15 cm	vše	157	74225
Min0all	min.	0 cm	vše	157	74083
Max15warm	max.	15 cm	teplé	157	32062
Max0warm	max.	0 cm	teplé	157	32108
Min15warm	min.	15 cm	teplé	157	30716
Min0warm	min.	0 cm	teplé	157	30651
Max15cold	max.	15 cm	studené	156	44563
Max0cold	max.	0 cm	studené	156	44528
Min15cold	min.	15 cm	studené	156	43505
Min0cold	min.	0 cm	studené	156	43429
Max15allc	max.	15 cm	vše	157	76627
Max15coldc	max.	15 cm	studené	156	44563
Min15allc	min.	15 cm	vše	157	74225
Min15coldc	min.	15 cm	studené	156	43505

Tabulka 2.1 Seznam lineárních smíšených modelů pro vyhodnocení vlivu meteorologických podmínek na rozdíl teplot. "c" u posledních čtyř modelů znamená, že prediktor výšky sněhu je nahrazen kategoriemi (bez sněhu, nad sněhem a pod sněhem). Druhou sadu modelů, kdy bereme absolutní hodnotu závislé proměnné, tak budeme značit písmenem "A" na začátku názvu.

a 0 cm jsme počítali modely pouze pro období od začátku května do konce října (teplé období) a pro období od začátku listopadu do konce dubna (studené období). Pro modely s čidlem ve výšce 15 cm ve studeném období jsme spočetli modely, kdy jsme výšku sněhu nahradili kategorickou proměnou (0 odpovídá hodnotám bez sněhu, 1 čidlo je nad sněhem, 2 čidlo je pod sněhem). K těmto 16 modelům jsme přidali ještě dalších 16 modelů, které mají stejné parametry, ale místo rozdílu teplot např. $\Delta t = t_{15cm} - t_{2m}$ jako závislou proměnnou bereme její absolutní hodnotu, jako např. $\Delta t_{abs} = |t_{15cm} - t_{2m}|$. Tyto modely budeme označovat písmenem "A" na začátku (např. AMax15all) a pomůžou nám v interpretaci výsledků.

2.5.4 Použitý software

Pro zpracování dat jsme využívali primárně programovací jazyk R (R Core Team, 2022) a jeho verzi 4.1.3. Použili jsme následující balíčky a knihovny pro přípravu a analýzu dat: `stringr` (Wickham, 2022), `e1071` (Meyer et al., 2023), `xlsx` (Dragulescu a Arendt, 2020), `geosphere` (Hijmans, 2022), `ggplot2` (Wickham, 2016), `lmtest` (Zeileis a Hothorn, 2002), `data.table` (Dowle a Srinivasan, 2023), `lubridate` (Grolemund a Wickham, 2011), `nlme` (Pinheiro a Bates, 2000), `forecast` (Hyndman a Khandakar, 2008), `moments` (Komsta a Novomestky, 2022),

profvis (Chang, Luraschi a Mastny, 2020) a climate (Czernecki, Głogowski a Nowosad, 2020). Pro otevření dat formátu grib a jejich transformaci z reanalýzy ERA5 jsme použili programovací jazyk Python, verzi 3.8.13 (Python Core Team, 2019) a knihovny xarray (Hoyer a Hamman, 2017), numpy (Harris et al., 2020), pandas (McKinney, 2010), cfrib (Russell, 2023) a eccodes (Varela, 2022). Pro vykreslení obrázku 2.2 byl použit software QGIS, verze 3.10 (QGIS Development Team, 2023)

Kapitola 3

Výsledky a diskuze

V první části této kapitoly ukážeme výsledky řady modelů, jejichž výpočet byl po teoretické stránce popsán v kapitole 1.5. V druhé části diskutujeme výsledky.

3.1 Analýza lineární smíšených modelů

Nyní studujeme pomocí lineárního smíšeného modelu vztah mezi rozdílem maximálních, resp. minimálních teplot poblíž země a ve výšce 2 m nad zemí a meteorologických podmínek: výšce sněhu, půdní vlhkosti, oblačnosti, insolaci, rychlosti větru a množství srážek.

Uvedeme zde celkově 32 modelů, které rozdělíme do tabulek podle výšky pozemního čidla, minimálních/maximálních teplot a toho, jestli bereme absolutní hodnotu závislé proměnné (tyto modely označujeme jako modely "s absolutní hodnotou"). Teplou sezónou (téměř bez sněhu) pak nazýváme období od začátku května do konce října a studená sezóna bude od začátku listopadu do konce dubna. Podle tabulky 2.1 počítáme také modely, které se týkají pouze teplot v 15 cm, protože změním prediktor výšky sněhu na kategorickou proměnnou. Hodnota 0 bude odpovídat hodnotám bez sněhu, 1 hodnotám se sněhem menším než 15 cm a 2 hodnotám nad 15 cm.

Pro každý model uvedeme podmíněné a marginální R^2 , koeficienty jednotlivých prediktorů v modelu, jejich chybu (uvádíme jí v závorce, tedy $1.61(1)$ je to samé jako 1.61 ± 0.01) a označíme ty, které vyšly jako statisticky nevýznamné.

V tabulce 3.1 jsou modely pro maximální teplotu a pozemní čidlo v 15 cm a v tabulce 3.2 ty samé, ale s absolutní hodnotou. V tabulce 3.3 pro maximální teplotu a 0 cm a k nim s absolutní hodnotou v tabulce 3.4. V tabulce 3.5 jsou modely pro minimální teplotu a 15 cm a v tabulce 3.6 opět s absolutní hodnotou. Nakonec v tabulce 3.7 jsou modely pro minimální teplotu a 0 cm a v tabulce 3.8 jsou modely s absolutní hodnotou. Zkratky všech modelů jsou rozepsané v tabulce 2.1. Postupem

popsaným v kapitole 2.5 jsme ověřili předpoklady všech modelů a určili, že zde není významná autokorelace, jestliže použijeme autokorelační strukturu ARMA ($p = 2$ a $q = 1$). Také jsme se na základě výběru a analýzy semivariogramů rozhodli prostorovou korelaci zanedbat a ověřili jsme, že v datech není přítomná heteroskedasticita a že residuály modelu nejsou významně odlišné od normálního rozdělení než na obrázku 2.11d.

16 modelů s absolutní hodnotou jsme počítali, aby byla interpretace výsledků jednodušší. Jestliže se snažíme interpretovat velikost koeficientu prediktoru v modelu, tak pokud nepoužijeme absolutní hodnotu, nedokážeme vždy určit, jestli dochází ke snížení rozdílů teplot mezi čidly. Pokud je koeficient kladný, znamená to, že rozdíl teplot roste. To může znamenat, že se záporné hodnoty zvětšují k nule (neboli gradient u země se zmenšuje) nebo že kladné hodnoty rostou (neboli teplotní gradient se zvětšuje). Pokud spočteme model s absolutní hodnotou, můžeme rozhodnout jestli má prediktor složitější vliv na rozdíl teplot nebo primárně snižuje jejich rozdíl. Model AMax0cold se nám nepodařilo spočítat, kvůli problémům s konvergencí funkce lme.

Model	Max15all	Max15warm	Max15cold	Max15allc	Max15coldc
R_m^2	0.031	0.098	0.066	0.032	0.067
R_c^2	0.20	0.51	0.19	0.20	0.19
Konstanta	0.42(6)	-0.55(7)	0.96(7)	0.43(6)	0.99(7)
Výška sněhu	0.0045(7)	-	0.0031(7)	0.040(9)	0.005(9)
Oblačnost	-0.041(8)	-0.16(1)	0.03(1)	-0.040(8)	0.03(1)
Vlhkost	-0.6(1)	2.2(1)	-2.4(2)	-0.6(1)	-2.4(2)
Srážky	0.002(2)	-0.04(1)	0.003(2)	0.002(2)	0.003(2)
Rychlost větru	-0.0072(4)	-0.0034(7)	-0.0098(6)	-0.0072(4)	-0.0098(6)
Insolace	0.000 42(1)	0.000 65(1)	0.000 29(2)	0.000 42(1)	0.000 28(2)

Tabulka 3.1 Srovnání modelů pro maximální denní teplotu a výšku 15 cm. Šedě označené jsou hodnoty, pro které vyšla v F testu p hodnota > 0.05 a nepovažujeme je statisticky významné od nuly (nezavrhli jsme nulovou hypotézu). Standardní chyba koeficientu je uvedena v závorce.

Model	AMax15all	AMax15warm	AMax15cold	AMax15allc	AMax15coldc
R_m^2	0.089	0.11	0.066	0.086	0.079
R_c^2	0.37	0.54	0.19	0.37	0.23
Konstanta	1.02(3)	1.08(3)	0.92(3)	1.04(3)	0.97(3)
Výška sněhu	0.0044(3)	-	0.0044(3)	0.024(3)	0.022(4)
Oblačnost	-0.304(4)	-0.357(6)	-0.263(5)	-0.301(4)	-0.260(5)
Vlhkost	0.18(5)	-0.08(6)	0.32(6)	0.14(5)	0.26(6)
Srážky	-0.0023(9)	-0.04(1)	-0.001(1)	-0.0023(9)	-0.001(1)
Rych. větru	-0.0025(2)	-0.0035(3)	-0.0026(2)	-0.0024(2)	-0.0026(2)
Insolace	0.000 193(5)	0.000 306(7)	0.000 166(7)	0.000 190(5)	0.000 161(7)

Tabulka 3.2 Srovnání modelů pro maximální denní teplotu a výšku 15 cm se závislou proměnnou v absolutní hodnotě. Šedě označené jsou hodnoty, pro které vyšla v F testu p hodnota > 0.05 a nepovažujeme je statisticky významné od nuly (nezavrhli jsme nulovou hypotézu). Standardní chyba koeficientu je uvedena v závorce.

Model	Max0all	Max0warm	Max0cold
R_m^2	0.055	0.20	0.087
R_c^2	0.16	0.60	0.16
Konstanta	-0.28(7)	-2.5(1)	0.99(7)
Výška sněhu	0.0197(9)	-	0.0158(8)
Oblačnost	0.09(1)	0.11(2)	0.09(1)
Vlhkost	0.8(1)	6.7(2)	-2.6(2)
Srážky	0.02(1)	0.05(1)	-0.04(2)
Rychlost větru	-0.0138(5)	-0.0020(9)	-0.0161(7)
Insolace	-0.000 26(1)	-0.000 27(2)	-0.000 30(2)

Tabulka 3.3 Srovnání modelů pro maximální denní teplotu a výšku 0 cm. Šedě označené jsou hodnoty, pro které vyšla v F testu p hodnota > 0.05 a nepovažujeme je statisticky významné od nuly (nezavrhli jsme nulovou hypotézu). Standardní chyba koeficientu je uvedena v závorce.

Model	AMax0all	AMax0warm	AMax0cold
R_m^2	0.069	0.10	-
R_c^2	0.19	0.33	-
Konstanta	1.10(2)	1.32(3)	-
Výška sněhu	0.0052(3)	-	-
Oblačnost	-0.247(7)	-0.300(6)	-
Vlhkost	0.31(5)	-0.46(6)	-
Srážky	-0.020(5)	-0.029(6)	-
Rychlost větru	-0.0012(2)	-0.0011(4)	-
Insolace	0.000 129(5)	0.000 236(7)	-

Tabulka 3.4 Srovnání modelů pro maximální denní teplotu a výšku 0 cm se závislou proměnnou v absolutní hodnotě. Šedě označené jsou hodnoty, pro které vyšla v F testu p hodnota > 0.05 a nepovažujeme je statisticky významné od nuly (nezavrhli jsme nulovou hypotézu). Standardní chyba koeficientu je uvedena v závorce. Model AMax0cold se nám nepodařilo spočítat.

Model	Min15all	Min15warm	Min15cold	Min15allc	Min15coldc
R_m^2	0.14	0.24	0.12	0.090	0.055
R_c^2	0.42	0.71	0.29	0.37	0.22
Konstanta	-1.23(5)	-2.44(7)	-0.11(6)	-1.17(5)	-0.1(6)
Výška sněhu	0.0222(5)	-	0.0214(6)	0.226(7)	0.211(8)
Oblačnost	0.211(6)	0.265(7)	0.185(9)	0.217(6)	0.194(9)
Vlhkost	1.9(1)	4.5(1)	-0.6(1)	1.8(1)	-0.7(1)
Srážky	0.0006(6)	0.0005(6)	-0.001(1)	0.0005(6)	-0.002(1)
Rychlost větru	-0.0018(4)	0.0106(5)	-0.0073(5)	-0.0016(4)	-0.0071(5)
Insolace	0.00006(2)	0.00028(2)	-0.00027(4)	0.00006(2)	-0.00026(4)

Tabulka 3.5 Srovnání modelů pro minimální denní teplotu a výšku 15 cm. Šedě označené jsou hodnoty, pro které vyšla v F testu p hodnota > 0.05 a nepovažujeme je statisticky významné od nuly (nezavrhli jsme nulovou hypotézu). Standardní chyba koeficientu je uvedena v závorce.

Model	AMin15all	AMin15warm	AMin15cold	AMin15allc	AMin15coldc
R_m^2	0.078	0.13	0.065	0.065	0.027
R_c^2	0.51	0.65	0.37	0.50	0.34
Konstanta	1.21(3)	1.45(3)	0.89(3)	1.25(3)	0.95(3)
Výška sněhu	0.0067(2)	-	0.0072(3)	0.047(3)	0.052(3)
Oblačnost	-0.131(3)	-0.162(4)	-0.101(4)	-0.128(3)	-0.097(4)
Vlhkost	-0.85(4)	-1.48(5)	-0.09(6)	-0.93(4)	-0.21(6)
Srážky	-0.0008(3)	-0.0005(3)	-0.0013(6)	-0.0008(3)	-0.0015(6)
Rychlost větru	-0.0047(2)	-0.0042(3)	-0.0053(2)	-0.0045(2)	-0.0051(2)
Insolace	0.00007(1)	0.00003(1)	0.00009(2)	0.00007(1)	0.00009(2)

Tabulka 3.6 Srovnání modelů pro minimální denní teplotu a výšku 15 cm se závislou proměnnou v absolutní hodnotě. Šedě označené jsou hodnoty, pro které vyšla v F testu p hodnota > 0.05 a nepovažujeme je statisticky významné od nuly (nezavrhli jsme nulovou hypotézu). Standardní chyba koeficientu je uvedena v závorce.

Model	Min0all	Min0warm	Min0cold
R_m^2	0.050	0.21	0.088
R_c^2	0.28	0.57	0.23
Konstanta	0.30(6)	-1.60(8)	1.63(6)
Výška sněhu	0.0171(5)	-	0.0152(6)
Oblačnost	0.053(8)	0.21(1)	-0.05(1)
Vlhkost	0.9(1)	5.1(2)	-1.9(1)
Srážky	0.0008(4)	0.0059(9)	-0.0002(4)
Rychlost větru	-0.0184(5)	-0.0065(7)	-0.0241(6)
Insolace	-0.000 18(3)	0.000 15(4)	-0.000 33(5)

Tabulka 3.7 Srovnání modelů pro minimální denní teplotu a výšku 0 cm. Šedě označené jsou hodnoty, pro které vyšla v F testu p hodnota > 0.05 a nepovažujeme je statisticky významné od nuly (nezavrhli jsme nulovou hypotézu). Standardní chyba koeficientu je uvedena v závorce.

Model	AMin0all	AMin0warm	AMin0cold
R_m^2	0.10	0.053	0.13
R_c^2	0.19	0.29	0.22
Konstanta	1.08(2)	0.81(3)	1.24(3)
Výška sněhu	0.0098(3)	-	0.0098(3)
Oblačnost	-0.106(3)	-0.091(4)	-0.098(4)
Vlhkost	0.33(5)	0.70(6)	0.10(6)
Srážky	-0.0003(2)	0.0001(4)	-0.0004(2)
Rychlost větru	-0.0086(2)	-0.0038(3)	-0.0111(3)
Insolace	0.000 15(1)	0.000 08(2)	0.000 17(2)

Tabulka 3.8 Srovnání modelů pro minimální denní teplotu a výšku 0 cm se závislou proměnnou v absolutní hodnotě. Šedě označené jsou hodnoty, pro které vyšla v F testu p hodnota > 0.05 a nepovažujeme je statisticky významné od nuly (nezavrhli jsme nulovou hypotézu). Standardní chyba koeficientu je uvedena v závorce.

3.1.1 Předpoklady lineárního smíšeného modelu

Pro každý model jsme ověřili jednotlivé předpoklady, jak bylo popsáno v kapitole 2. Pokud se zaměříme na normálnost residuálů modelu, tak všechny mají nezanedbatelnou míru šikmosti nebo jiných odlehlých hodnot, které se nám nepodařilo žádnou transformací opravit. Existují i složitější transformace, které jsme nezkoušeli jako například Box-Cox transformace nebo jiné, které by data mohla zlepšit. Složitější transformací může být ale těžší na interpretaci, protože například používáme nějaký posun hodnot o konstantu, a proto jsme v této práci zvolili transformaci pomocí třetí odmocniny.

Dále jsem ověřovali autokorelaci časových řad. Pomocí modelu ARMA jsme vylepšili původní model, ale i nadále některé hodnoty autokorelace neklesly do takové míry, abychom mohli říct, že zde autokorelace není. Jedním z řešení by mohlo být například pracovat s delší časovou řadou a následně vyřadit každý x-tý den a tím autokorelaci snížit.

Z několika variogramů jsme určili, že prostorová korelace není v našich datech silná. Zároveň jsme ale nezkoumali jiné typy korelace, například korelace dat s výškou nad zemí nebo v množství potenciální solární radiace nebo topografického vlhkostního indexu, což jsou všechno veličiny, podle kterých byla čidla rozdělována do jednotlivých tříd, viz kapitola 2.2. Složitější způsob modelování dat by bylo použít prostoročasový model.

Výše popsané problémy můžou zkreslovat naše výsledky. Interpretace výše ovšem nezáleží na konkrétních hodnotách vysvětlené variability nebo jednotlivých koeficientů, ale především na znamenkách prediktorů a obecnější trend, který je vůči těmto problémům robustnější.

3.1.2 Insolace a minimální teplota

Insolaci je vybrána jako jeden z prediktorů, abychom v datech zahrnuli i denní a roční chod. Zvolený způsob má výhodu z hlediska výpočetního času, jde o jeden prediktor. Další výhodou je, že pak jde o fyzikální veličinu s jasnou interpretací. První problém je, že insolace se mění během dne a tudíž můžeme dostat dvě stejné hodnoty i např. měsíc od sebe, pouze z důvodu, že denní maximum (nebo minimum) nastalo v jinou denní dobu a tím se maskuje roční průběh. Druhý problém je, že jsme se rozhodli brát insolaci v noci rovnou nule, ale pro minimální teploty a pro období, kdy je čidlo pod sněhem, máme většinu hodnot nulových a pak nám prediktor neříká nic o denní nebo roční době. Řešením, které se zde nabízí, je rozdělit prediktor na dva pro denní a roční chod zvlášť s tím, že pro noční dobu neurčíme pouze jednu hodnotu. Těmito prediktory by mohlo být například maximální denní insolace a hodinový úhel Slunce.

3.1.3 Srovnání modelů pro maximální teplotu a výšku 15 cm

V tabulce 3.1 srovnáváme modely pro maximální denní teplotu a výšku 15 cm mezi sebou (modely s absolutní hodnotou jsou tabulce 3.2). Když srovnáme kvalitu modelů jako množství vysvětlené variability, tak model pro teplotu sezónu vychází nejlépe s $R_c^2 = 0.51$, resp. $R_c^2 = 0.54$ pro model s absolutní hodnotou. *Výška sněhu* má kladný vliv na rozdíl teplot a vede k jeho nárůstu, což je v souladu s teorií v kapitole 1.2.3. Čidlo nacházející se pod sněhem totiž může mít výrazně rozdílnou teplotu od čidla ve standardní výšce (vliv sněhu na teploty v lesním klimatu popisují se stejnými závěry také De Frenne et al., 2021). 3 ze 4 modelů pro výšku sněhu jako kategorickou proměnnou nejsou signifikantní, je možné, že nahrazením ztratíme moc velké množství informací a že tím klesne v modelu závislost na sněhové pokrývce.

Pokud srovnáme modely Max15warm a Max15cold, vidíme, že *oblačnost* má opačný vliv na rozdíl teplot. Z modelů AMax15warm a AMax15cold je zřejmé, že oblačnost snižuje rozdíl teplot na čidlech. Gradient teplot blízko země roste s ohřevem povrchu slunečním zářením, tudíž oblačnost přes den tento gradient snižuje. Vliv oblačnosti na mikroklima jako faktor snižující absolutní gradient teplot je popsán např. zde De Frenne et al., 2021; Brower et al., 2011. Koeficienty pro prediktor oblačnosti jsou pro modely s absolutní hodnotou několikanásobně vyšší, to naznačuje, že oblačnost především snižuje absolutní rozdíl teplot. Tuto roli plní také přítomnost lesního porostu (Zellweger et al., 2019). Jestliže je pozemní čidlo pod sněhem, může maximální teplota nastávat i v noci. V tuto dobu oblačnost omezuje únik tepla dlouhovlnným zářením, a tedy nedochází k tak rychlému poklesu teplot. Pokud je čidlo pod sněhem, tak meteorologické podmínky ovlivňují hlavně čidlo ve standardní výšce 2 m, protože pozemní čidlo má většinou teplotu blízkou 0 °C.

Vliv *půdní vlhkosti* na rozdíl teplot je v teplém období kladný a ve studeném záporný. Pro celou časovou řadu pak vychází lehce záporný. Pro 4 z 5 modelů s absolutní hodnotou je vliv vlhkosti statisticky významný, to znamená, že dopad tohoto prediktoru je složitější než jenom nárůst nebo pokles absolutního gradientu teplot. Pokud je na zemi přítomný sníh, půdní vlhkost může rychle vzrůst, když stoupne teplota a sníh začne tát. Pokud je čidlo stále pod sněhem tak bude teplota blízká 0 °C, zatímco ve výšce 2 m může teplota růst více oproti stavu, kdy sníh netál. Teploty ve 2 m tedy byly záporné a zvýšily se, čímž mohlo dojít k poklesu rozdílu teplot, jak vidíme v tabulce pro studené období. V teplém období narůstá půdní vlhkost zejména po dešti. Vzhledem k experimentálnímu uspořádání čidel (viz kapitola 1.3.2) je čidlo ve 2 m lépe odstíněno od deště a tudíž jakmile po dešti začne teplota stoupat, bude se v této výšce tak dít rychleji než na čidle poblíž země. Rozdíl teplot tedy bude růst, jak opět vidíme v tabulce. V teplém období také při poklesu půdní vlhkosti klesá míra evapotranspirace a tím narůstá teplota

v bylinném patře (o vztahu teplot v lesním porostu s transpirace pojednávají De Frenne et al., 2021).

Srážky vedou k poklesu absolutního rozdílu teplot. Výjimkou je ale studené období, což je způsobeno několika různými faktory. Část období je pozemní čidlo pod sněhem, tudíž nové srážky na něj nemusí mít vliv a dále čidlo, které je ve 2 m, tak je upevněno na stromě a tudíž stíněno od slabých srážek. Pro lepší kvantifikaci vlivu srážek bychom potřebovali podrobnější data z lesního porostu.

Rychlost větru má napříč všemi modely záporný vliv na rozdíl teplot, což je ve shodě s teorií popsanou v 1.2.3. To, že je ve studeném období vliv silnější, bude nejspíš způsobeno opět tím, že čidlo poblíž země je část zimy pod sněhem. Vítr pak ovlivňuje výhradně čidlo ve standardní výšce (podobný vliv větru je popsán i ve článku Chen, Franklin a Spies, 1993). *Insolace* je nejslabší ze všech prediktorů a má pro tuto sadu modelů vždy kladný vliv. Vyšší insolace znamená potenciálně větší množství záření dopadající na povrch a ohřívající pozemní čidlo.

3.1.4 Srovnání modelů pro maximální teplotu a výšku 0 cm

V tabulce 3.3 obdobně předchozí kapitole máme srovnání modelů maximální denní teploty a výšky 0 cm. *Výška sněhu* má opět kladný vliv na rozdíl teplot. Vliv je také několikanásobně vyšší, srovnajme hodnotu 0.0031(7) pro studené období a výšku 15 cm s hodnotou koeficientu 0.0158(8) pro model 0 cm a studené období. To ovšem je v souladu s tím, že níže položené čidlo bude pod sněhem delší dobu (tento vliv sněhové pokrývky na teploty poblíž země byl popsán i v De Frenne et al., 2021).

Pro *oblačnost* jsou na rozdíl od hodnot v tabulce 3.1 všechny hodnoty kladné. Když se podíváme na modely s absolutní hodnotou, tak vidíme, že oblačnost snižuje absolutní rozdíl teplot. Vzhledem k tomu, že koeficienty pro modely bez absolutní hodnoty také vycházejí signifikantně, je pravděpodobné, že existují další složitější vazby mezi rozdílem teplot a oblačností a dalšími prediktory.

Vlhkost půdy je pro teplé období nejsilnějším prediktorem. Zřejmě je to způsobeno malou vzdáleností od měření vlhkosti půdy k povrchu, která více ovlivňuje čidlo ve výšce 0 cm než v 15 cm, ovšem pro studené období už není rozdíl tak významný. Při poklesu půdní vlhkosti klesá schopnost rostlin transpirovat, tento vliv je nejvýznamnější v létě (o vztahu transpirace a následného nárůstu teplot pojednávají De Frenne et al., 2021). Vliv na rozdíl teplot je v jednotlivých obdobích stejný jako pro 15 cm, ale silnější vliv v teplém období způsobí, že výsledný dopad na rozdíl teplot pro všechna dostupná data je kladný.

Srážky jsou pro sezónní modely signifikantním prediktorem a obecně opět vedou k poklesu absolutního gradientu teplot skrze ochlazení povrchu. Srážky z fyzikálního hlediska také souvisí s přítomností oblačnosti, ovšem v našich datech je korelace velmi nízká (a záporná) -0.043 . To může být způsobeno využitím dat

z ERA5 nebo příliš malou četností srážek.

Rychlost větru má záporný vliv a opět platí, že ve studeném období je silnější než v teplém. Když srovnáme velikost koeficientů ve studeném období mezi modely pro 0 cm a 15 cm, tak pro první z nich je v absolutní hodnotě vyšší. Čidlo blíže země je pravděpodobně více stíněno od větru a tudíž jsou zde více rozdílné podmínky od čidla ve 2 m (vliv větru na mikroklima byl pozorován např. ve článku Chen, Franklin a Spies, 1993).

Insolace má kladný vliv pro modely s absolutní hodnotou, opět je to způsobené ohřevem povrchu. Pro modely bez absolutní hodnoty jsou koeficienty záporné. Očekávali bychom, že vyšší hodnota insolace povede k rychlejšímu ohřevu pozemního čidla a tedy, že rozdíl teplot bude růst. Insolace zároveň není závislá na ostatních veličinách. Čas v kterém nastane maximální teplota už ano. Koeficienty pro modely bez absolutní hodnoty jsou řádově menší, tudíž by to mohlo být způsobeno například korelací s rychlostí větru, která má také záporný vliv. Korelace ovšem není moc vysoká, pouze 0.098.

3.1.5 Srovnání modelů pro minimální teplotu a výšku 15 cm

Pro interpretaci výsledků v tabulce 3.5 a 3.6 je nutné si uvědomit, že minimální teplota většinou nastává v ranních hodinách. V období, kdy se na zemi nachází sníh, minimální teplota nastává během noci (viz obrázek 2.5). Z tohoto důvodu jsou hodnoty *insolace* pro většinu minimálních teplot nulové a tedy nám tento prediktor nemůže poskytnout mnoho informací, více k tomuto v kapitole 3.1.2. I přesto jsou pro všechny modely s absolutní hodnotou koeficienty prediktoru insolace kladné. To bychom očekávali kvůli souvislosti s ohřevem povrchu, nabývají ovšem menších hodnot.

Stejně jako u všech ostatních modelů popsaných výše, můžeme vidět, že *výška sněhu* má kladný vliv na rozdíl teplot. To je způsobené tím, že dochází k odlišnému chování teplot u země a ve výšce 2 m (jak bylo popsáno v De Frenne et al., 2021). Také si můžeme všimnout, že podobně jako u modelu Max15allc, tak u modelů Min15allc a Min15coldc je sníh silnějším prediktorem. V tomto případě až desetinásobně, ale neplatí to pro modely s absolutní hodnotou.

Oblačnost je pro rozdíl teplot (kladným) významným prediktorem a má silnější vliv než u maximálních teplot. V noci přítomnost oblačnosti snižuje míru ochlazování povrchu, klesá absolutní gradient teplot. Můžeme vidět na modelech s absolutní hodnotou, že prediktor je vždy záporný. Pokles absolutního gradientu teplot je popsán i ve studii Brower et al., 2011.

Půdní vlhkost snižuje absolutní rozdíl teplot. Nemůžeme opomenout vliv transpirace rostlin, která se v menší míře děje i v noci (podle práce Jansová, 2021), ale zároveň nemusí mít vliv, pokud nerostou na zemi menší byliny. Pro studené období má půdní vlhkost o něco slabší záporný vliv. Opět zde bude často

nárůst vlhkosti spojen s táním sněhu a oteplením. Z modelu AMin15cold můžeme vidět, že pokles absolutního rozdílu teplot zde není tak jednoznačný, a tedy vztah mezi vlhkostí a teplotami bude složitější.

Rychlost větru i pro minimální teplotu vede k poklesu absolutního rozdílu teplot, který je zároveň stabilní i napříč studeným a teplým obdobím.

3.1.6 Srovnání modelů pro minimální teplotu a výšku 0 cm

Koeficienty modelů pro minimální teplotu a výšku 0 cm jsou v tabulkách 3.7 a 3.8. *Výška sněhu* má opět kladný vliv na rozdíl teplot, sníh tedy obecně způsobuje, že teploty pod sněhem jsou vyšší než ve výšce 2 m. Všimněme si také, že blíže země je vliv sněhu silnější, například to můžeme vidět při srovnání modelů AMin0All a AMin15All.

Oblačnost snižuje absolutní rozdíl teplot ovšem v menší míře než pro 15 cm. *Půdní vlhkost* má kladný vliv na absolutní rozdíl teplot, narozdíl od modelů pro 15 cm. Zatímco ve výšce 15 cm je vliv deště hlavně vlivem ochlazení okolního vzduchu (které se děje i pro čidlo ve výšce 2 m), tak pro samotný povrch půdy se může čidlo ocitnout pod vodou. Teploty zde tedy můžou klesnout více a tím absolutní rozdíl teplot naopak růst.

Vliv *srážek* je pro část modelů nesignifikantní nebo s vysokou relativní chybou. Podle modelu Min0warm srážky v teplém období způsobují nárůst rozdílu teplot, nikoliv ovšem absolutního, tedy vliv na teplotu u povrchu země je složitější. *Rychlost větru* má opět záporný vliv na absolutní rozdíl teplot, zároveň bychom očekávali, že bude menší než pro modely s 15 cm. Pro teplé období je koeficient u modelu AMin0warm téměř stejný jako u AMin15warm. Důvod, proč je dvakrát vyšší v zimním období u modelu AMin0cold než u AMin15cold, zřejmě tkví v přítomnosti sněhu. Čidlo ve výšce 0 cm je sice lépe chráněno od větru, ale ve studeném období je déle pod sněhem.

Insolace má opět slabý kladný vliv, viz diskuze výše pro výšku 15 cm.

3.1.7 Syntéza všech modelů

Napříč všemi modely můžeme pozorovat, že *výška sněhu* zvětšuje rozdíl teplot mezi čidly poblíž země a ve výšce 2 m. Zkoušeli jsme pro čidla ve výšce 15 cm nad zemí nahradit sníh kategoričkou proměnnou, podle toho, jestli je čidlo pod sněhem nebo ne. Pro modely Max15allc, Min15allc a Min15coldc jsme tímto dosáhli toho, že prediktor se stal až desetkrát silnějším. Pro model Max15coldc vyšel koeficient nesignifikantní, možné důvody jsme diskutovali výše. Je zřejmé, že výška sněhu v lese může být velmi rozdílná od výšky sněhu na meteorologické stanici. Způsobuje to rozdílná nadmořská výška, vzdálenost míst od sebe nebo přítomnost porostu, který brání sněhu dopadnout na zem. Také brání tání sněhu, když přijde obleva.

Ukázali jsme tedy, že sníh má silný význam na rozdíl teplot u země a to především tím, že pod dostatečnou vrstvou se teploty pohybují okolo 0 °C. Dále by bylo možné spočítat modely se sněhem jako kategorickou proměnnou i pro výšku 0 cm. Ovšem zde by ztráta informace o výšce sněhu byla ještě výraznější, protože by kategorická proměnná měla pouze dvě hodnoty. Vhodné by bylo k tomu použít data o výšce sněhu v lese. Z denního průběhu teplot na pozemním čidle by také bylo možné zkusit odvodit, kdy je čidlo pod sněhovou pokrývkou a nejlépe výsledky srovnat s přímým měřením sněhu v lese. Toto by ovšem vyžadovalo rozsáhlou analýzu časových řad, která je za rámcem možností této práce.

Oblačnost je dalším silným prediktorem v našich modelech a bez výjimky způsobuje absolutní pokles rozdílu teplot, viz diskuze výše. Pro některé modely bez absolutní hodnoty dostáváme ovšem velmi různé hodnoty i magnitudy koeficientů, např. model Max15warm a Max15cold. Je pravděpodobné, že přítomnost sněhu koeficienty velmi ovlivní, ale jde o rozdíl, který by bylo vhodné dále prozkoumat. Například bychom se mohli podívat na počasí v době měření nebo souvislost s jinými prediktory než výškou sněhu. Prediktor oblačnosti bychom také mohli rozdělit podle typu oblačnosti: vysoká, střední a nízká oblačnost. Vysoká oblačnost, například typu cirrus, nesnižuje množství dopadajícího záření tolik jako typu altostratus, ale zároveň tyto oblaky souvisejí i s dalšími meteorologickými podmínkami jako příchod fronty a podobně.

Půdní vlhkost je jediným prediktorem, který spolu s teplotami měříme na každém čidle. Toto má velkou výhodu a vysvětluje to, proč jde obecně o nejsilnější prediktor. Zde je také vztah zřejmě nejsložitější, jak si můžeme všimnout, když srovnáme například modely typu AMax15. Pouze pro jeden z nich vychází vlhkost signifikantní. Nemůžeme tedy jednoduše říct, že by vlhkost snižovala nebo zvyšovala rozdíl teplot, viz diskuze výše.

Srážky naopak pro klasické modely vycházejí téměř vždy nesignifikantně a pro modely s absolutní hodnotou jsou vždy záporným prediktorem (nebo jsou nesignifikantní). Srážky zřejmě nemají tak silný nebo někdy dokonce skoro žádný vliv na rozdíl teplot. Částečně je to také způsobeno tím, že listy a větve stromů absorbují část srážek a také, že srážky někdy mohou být značně lokální v případě například přeháňky.

Rychlost větru pro všechny modely způsobuje snižování absolutního rozdílu teplot, pro modely bez absolutní hodnoty je jedinou výjimkou model Min15warm, viz diskuze výše. Ačkoliv jde o jednoznačný prediktor, tak není příliš silný. To může být způsobeno velkou prostorovou variabilitou rychlosti větru a přítomností lesa, který ji velmi ovlivňuje. Opět bychom očekávali, že prediktor bude silnější, pokud bychom měli lokálnější zdroj dat.

Insolace má vždy kladný vliv na absolutní rozdíl teplot a je nejslabším prediktorem. Důvodem zřejmě bude, že v hodnotách insolace není započítána oblačnost, přítomnost lesa, sklon a orientace svahu, na kterém se čidlo nachází. Sklon a

orientaci svahu bychom mohli jednoduše přidat k prediktoru jako koeficient. Přítomnost lesa bychom mohli započítat pomocí analýzy hemifotografie, tedy fotografie z místa čidla, z které bychom zjistili kolik procent oblohy je viditelné. Další řešení by bylo mít na čidle fotodiodu a tímto detekovat, jestli na něj zrovna dopadá sluneční světlo. Zároveň bychom ovšem ztratili v datech roční a denní chod, viz diskuze v kapitole 3.1.2.

Pokud srovnáme modely z hlediska vysvětlené variability, vidíme, že se od sebe výrazně liší. Nejvyšší hodnoty mají tendenci mít modely pouze pro teplé období, z toho můžeme usuzovat, že přítomnost sněhu velmi komplikuje analýzu a vznikají zde jevy, které se snažíme modelovat lineárním modelem, ale lineární nejsou, například, to jestli je čidlo pod sněhem nebo nad sněhem. Kdybychom měli lokálnější data o výšce sněhové pokrývky, mohli bychom data nerozdělovat podle teplého a studeného období, ale podle přítomnosti sněhu.

U všech modelů také zbývá velké množství vůbec nevysvětlené variability. V první řadě námi vybrané prediktory zdaleka nevyčerpávají informace o aktuálních meteorologických podmínkách. Více jsme jich nevybrali z důvodu výpočetní náročnosti modelů a také, že s více prediktory se objevují problémy s velkou vzájemnou korelací a takzvanému "overfittingu", kdy máme více prediktorů než můžeme zdůvodnit daty. Pro takové případy je vhodné použít například krokovou regresi a Akaikeho informační kritérium, kroková regrese by nám zvýšila výpočetní náročnost ještě více. Významná část nevysvětlené variability je daná tím, že čidla kterými jsme se zabývali, nejsou na stejných místech. U každého čidla se liší topografie a vegetace a další faktory zmiňované v kapitole 1.1.3 a 1.1.5. Například pokud se budeme zabývat výškou sněhu tak náš způsob statistického zpracování dat nebere v potaz už zmiňované zachycení části sněhových srážek vegetací, ale také to, že na každém čidle bude míra zachycení sněhových srážek odlišná. Dále také to, že čidla se nacházejí v různé nadmořské výšce a tudíž může být na zemi více či méně sněhu. Čidla se také nacházejí na topograficky různých místech. Některá mohou mít sněhovou pokrývku mnohem déle, protože se u nich drží studený vzduch a některá jsou naopak na jižních svazích a sníh zde roztaje rychleji. Hodnoty o výšce sněhu z několika meteorologických stanic nemůžou tyto nuance pokrýt a jde tedy o velkou mezeru ve zpracování dat. Uvedme ještě jeden příklad. Rychlost větru je také ovlivněna okolím čidla. Zde jsme opět předpokládali, že pro všechna čidla jsou podmínky stejné, ale velikost a hustota stromů v okolí se liší pro každý pár čidel stejně jako výška a typ vegetace. To jsou všechno spolu s lokální topografií faktory, které jsme ve statistickém zpracování nebrali v potaz a ovlivňují rychlost větru. Zahrnutí těchto a dalších vlivů by bylo možné, ale výrazně by zkomplikovalo analýzu, která by pak byla nad rámec této práce.

Závěr

V této práci jsme zkoumali vliv meteorologických podmínek na rozdíl teplot v blízkosti zemského povrchu v lesním porostu. K tomu jsme využili data z meteorologických stanic a ze 157 čidel rozmístěných napříč národními parky Šumava a Bavorský les. Ke zpracování byla dostupná data za období od 12.10.2019 do 17.5.2021. Spočítali jsme 32 lineární smíšených modelů rozdělených do hlavních skupin podle toho, jestli závislá proměnná byla v absolutní hodnotě (modely s absolutní hodnotou), jestli jsme studovali maximální nebo minimální teploty, a nebo jestli zdroj teplot u země bylo čidlo ve výšce 0 cm nebo 15 cm. Nulovou hypotézu jsme pomocí modelů vyvrátili a zjistili, že mezi rozdílem maximálních, resp. minimálních denních teplot na čidlech ve výšce 0 cm, resp. 15 cm a 2 m a meteorologickými proměnnými ze staničních měření existuje vztah, neboli jejich koeficienty jsou pro většinu modelů nenulové. Tento vztah jsme zkoumali u řady prediktorů: výška sněhu, oblačnost, půdní vlhkost, množství srážek, rychlost větru a insolace.

Kromě statistického zpracování dat jsme také provedli interpretaci výsledků v kontextu rešerše dostupných znalostí z oblasti mikroklimatologie a mikrometeorologie. Ukázali jsme, že výška sněhu má kladný vliv na rozdíl teplot a nahrazení výšky sněhu za kategorickou proměnnou (žádný sníh, čidlo nad sněhem a čidlo pod sněhem) může výrazně zvýšit sílu prediktoru. Jako hlavní vliv výšky sněhu jsme určili to, že pod dostatečnou vrstvou sněhu se teplota pohybuje okolo 0 °C. Prediktor oblačnosti má silný záporný vliv na rozdíl teplot především proto, že při větší oblačnosti dochází k menšímu ohřevu povrchu. Rychlost větru má záporný vliv na rozdíl teplot, protože dochází k silnějšímu promíchávání vzduchu. Insolace má slabý kladný vliv, protože souvisí s ohřevem povrchu. Množství srážek byl nejméně průkazný prediktor, který pro některé modely ukazoval pokles absolutního rozdílu teplot, který byl silnější pro čidla ve výšce 0 cm. Půdní vlhkost byla silným prediktorem, který se ovšem výrazně lišil mezi modely s a bez absolutní hodnoty a mezi jednotlivými částmi roku. Možné důvody jsme uvedli v diskuzi. Hlavním důvodem pro nejistotu v interpretaci všech prediktorů byla relativní vzdálenost čidel od meteorologických stanic, které měřily meteorologické podmínky. Nebylo zde tedy v některých případech možné udělat hlubší analýzu

problematiky kvůli kvalitě dat.

Dále jsme navrhli způsob, jak možnosti studia mikroklimatu vylepšit. Kvalita analýzy by byla výrazně vylepšena měřením meteorologických podmínek i v lesním porostu, ale také zpracováním delšího časového období z následujících let. Také jsme při zpracování dat nebrali v potaz rozdílný vliv topografie a vegetace na každé čidlo a kvůli tomu modely nemohly vysvětlit více variability rozdílu teplot. Některé prediktory bychom mohli v hlubší analýze upravit nebo nahradit jinými. Ze statistického hlediska by největším zlepšením zřejmě bylo vytvořit složitější prostorovočasový model. Výsledky práce otevírají možnosti dalšímu výzkumu, který by mohl vést například k interpolaci chybějících mikroklimatických dat, a pomáhají nám porozumět interakci mezi teplotami v lesním porostu a ostatními meteorologickými podmínkami.

Seznam použité literatury

- Allen, Richard G. et al. (1998). *Crop evapotranspiration - Guidelines for computing crop water requirements - FAO Irrigation and drainage*. Accessed: 2023-06-24. URL: <https://www.fao.org/3/x0490e/x0490e04.htm>.
- Arya, S. Pal (2001). *Introduction to micrometeorology*. eng. 2nd ed. International geophysics series ; 27. San Diego: Academic Press. ISBN: 0-12-059354-8.
- b, Glen (2014). *How to interpret a QQ plot*. Cross Validated. Accessed: 2021-09-04). URL: <https://stats.stackexchange.com/q/101290>.
- Bartoň, Kamil (2023). *MuMIn: Multi-Model Inference*. R package version 1.47.5. URL: <https://CRAN.R-project.org/package=MuMIn>.
- Bek, Dominik (2021). *Sněhové sucho a řídicí faktory ovlivňující meziroční variabilitu sněhové pokrývky na Šumavě*. cze.
- Brower, Lincoln P et al. (2011). "Overwintering Clusters of the Monarch Butterfly Coincide with the Least Hazardous Vertical Temperatures in the Oyamel Forest". eng. In: *Journal of the Lepidopterists' Society* 65.1, s. 27–46. ISSN: 0024-0966.
- Callen, Herbert B. (1985). *Thermodynamics and an introduction to thermostatistics*. eng. 2nd ed. New York: Wiley. ISBN: 0-471-86256-8.
- Czernecki, Bartosz, Arkadiusz Głogowski a Jakub Nowosad (2020). *Climate: An R Package to Access Free In-Situ Meteorological and Hydrological Datasets For Environmental Assessment*. R package version 0.9.1, s. 394. DOI: 10.3390/su12010394. URL: <https://github.com/bczernecki/climate/>.
- ČHMÚ (2023a). *Automatizace v meteorologické měřicí technice*. <http://old.cmes.cz/cs/node/273>. Accessed: 2023-06-16.
- (2023b). *Churáňov*. <https://www.chmi.cz/aktualni-situace/aktualni-stav-pocasi/ceska-republika/stanice/profesionalni-stanice/prehled-stanic/churanov?l=cz>. Accessed: 2023-06-16.
- (2023c). *Meteorologická měření a pozorování*. <https://www.chmi.cz/files/portal/docs/ruzne/vyuka/METEO/2.pdf>. Accessed: 2023-06-16.
- (2023d). *Meteorologické stanice ČHMÚ*. https://www.chmi.cz/files/portal/docs/poboc/OS/stanice/ShowStations_CZ.html. Accessed: 2023-05-28.

- De Frenne, Pieter et al. (2021). “Forest microclimates and climate change: Importance, drivers and future research agenda”. eng. In: *Global change biology* 27.11, s. 2279–2297. ISSN: 1354-1013.
- Dowle, Matt a Arun Srinivasan (2023). *data.table: Extension of ‘data.frame’*. R package version 1.14.8. URL: <https://CRAN.R-project.org/package=data.table>.
- Dragulescu, Adrian a Cole Arendt (2020). *xlsx: Read, Write, Format Excel 2007 and Excel 97/2000/XP/2003 Files*. R package version 0.6.5. URL: <https://CRAN.R-project.org/package=xlsx>.
- Geiger, Rudolf (2009). *The Climate near the ground*. eng. 7th ed. Lanham: Rowman & Littlefield Publishers. ISBN: 978-0-7425-5560-0.
- Greiser, Caroline et al. (2018). “Monthly microclimate models in a managed boreal forest landscape”. eng. In: *Agricultural and forest meteorology* 250-251, s. 147–158. ISSN: 0168-1923.
- Grolemund, Garrett a Hadley Wickham (2011). “Dates and Times Made Easy with lubridate”. In: *Journal of Statistical Software* 40.3, s. 1–25. URL: <https://www.jstatsoft.org/v40/i03/>.
- Hammen, David (2015). *Earth-Sun distance on a given day of the year*. <https://physics.stackexchange.com/questions/177949/earth-sun-distance-on-a-given-day-of-the-year>. Accessed: 2023-05-28.
- Harris, Charles R et al. (2020). “Array programming with NumPy”. In: *Nature* 585.7825, s. 357–362. ISSN: 1476-4687. DOI: 10.1038/s41586-020-2649-2. URL: <https://doi.org/10.1038/s41586-020-2649-2>.
- Hefley, Trevor J. et al. (2017). “The basis function approach for modeling autocorrelation in ecological data”. eng. In: *Ecology (Durham)* 98.3, s. 632–646. ISSN: 0012-9658.
- Hersbach, H. et al. (2018). *ERA5 hourly data on single levels from 1940 to present*. 10.24381/cds.adbb2d47. Accessed: 2023-06-08.
- Hijmans, Robert J. (2022). *geosphere: Spherical Trigonometry*. R package version 1.5-18. URL: <https://CRAN.R-project.org/package=geosphere>.
- Hirakawa, Hirofumi a Yu Nagasaka (2018). “Evidence for Ussurian tube-nosed bats (*Murina ussuriensis*) hibernating in snow”. eng. In: *Scientific reports* 8.1, s. 12047–8. ISSN: 2045-2322.
- Hoffmann, John P (2021). “Homoscedasticity”. eng. In: *Linear Regression Models*. United Kingdom: CRC Press LLC. ISBN: 0367753685.
- Honsberg, C. B. a S. G. Bowden (2019). *Photovoltaics Education Website*. <https://www.pveducation.org/pvcdrom/properties-of-sunlight/declination-angle>. Accessed: 2023-05-28.
- Hoyer, S. a J. Hamman (2017). “xarray: N-D labeled arrays and datasets in Python”. In: *Journal of Open Research Software* 5.1. DOI: 10.5334/jors.148. URL: <https://doi.org/10.5334/jors.148>.

- Hyndman, Rob J a Yeasmin Khandakar (2008). "Automatic time series forecasting: the forecast package for R". In: *Journal of Statistical Software* 26.3, s. 1–22. DOI: 10.18637/jss.v027.i03.
- Chang, Winston, Javier Luraschi a Timothy Mastny (2020). *profvis: Interactive Visualizations for Profiling R Code*. R package version 0.3.7. URL: <https://CRAN.R-project.org/package=profvis>.
- Chen, Jiquan, Jerry F. Franklin a Thomas A. Spies (1993). "Contrasting microclimates among clearcut, edge, and interior of old-growth Douglas-fir forest". eng. In: *Agricultural and forest meteorology* 63.3, s. 219–237. ISSN: 0168-1923.
- Jansová, Renata (2021). *Noční transpirace a její význam pro C3 a C4 rostliny*. cze.
- Jost, Steve (2017). *The F-test for linear regression*. Accessed: 2023-06-24. URL: <http://facweb.cs.depaul.edu/sjost/csc423/documents/f-test-reg.htm>.
- Komsta, Lukasz a Frederick Novomestky (2022). *moments: Moments, Cumulants, Skewness, Kurtosis and Related Tests*. R package version 0.14.1. URL: <https://CRAN.R-project.org/package=moments>.
- Kozak, M. a H.-P. Piepho (2018). "What's normal anyway? Residual plots are more telling than significance tests when checking ANOVA assumptions". eng. In: *Journal of agronomy and crop science (1986)* 204.1, s. 86–98. ISSN: 0931-2250.
- Lindenmayer, David et al. (2022). "Stand age related differences in forest microclimate". eng. In: *Forest ecology and management* 510, s. 120101–. ISSN: 0378-1127.
- Madden, Roland A. a Jill Williams (1978). "The Correlation between Temperature and Precipitation in the United States and Europe". eng. In: *Monthly weather review* 106.1, s. 142–147. ISSN: 0027-0644.
- McKinney, Wes (2010). "Data Structures for Statistical Computing in Python". In: *Proceedings of the 9th Python in Science Conference*. Ed. Stéfan van der Walt a Jarrod Millman, s. 51–56.
- McLean, Robert A., William L. Sanders a Walter W. Stroup (1991). "A Unified Approach to Mixed Linear Models". eng. In: *The American statistician* 45.1, s. 54–. ISSN: 0003-1305.
- Meyer, David et al. (2023). *e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien*. R package version 1.7-13. URL: <https://CRAN.R-project.org/package=e1071>.
- Meys, Joris (2018). *Is normality testing "essentially useless"?* Cross Validated. URL: <https://stats.stackexchange.com/q/2498> (version: 2018-03-05). eprint: <https://stats.stackexchange.com/q/2498>. URL: <https://stats.stackexchange.com/q/2498>.
- MŽP (2023a). *Biotopy*. URL: <https://www.npsumava.cz/priroda/biotopy/> (cit. 27.06.2023).
- (2023b). *Prirodní pomery - Narodni park Sumava*. URL: <https://www.npsumava.cz/priroda/prirodni-pomery/> (cit. 11.05.2023).

- Oliver, Margaret A. (2015). *Basic Steps in Geostatistics: The Variogram and Kriging*. eng. 1st ed. 2015. SpringerBriefs in Agriculture. Cham: Springer International Publishing. ISBN: 3-319-15865-1.
- Pinheiro, José C. a Douglas M. Bates (2000). *Mixed-Effects Models in S and S-PLUS*. New York: Springer. DOI: 10.1007/b98882.
- Python Core Team (2019). *Python: A dynamic, open source programming language*. Python Software Foundation. URL: <https://www.python.org/>.
- QGIS Development Team (2023). *QGIS Geographic Information System*. QGIS Association. URL: <https://www.qgis.org>.
- R Core Team (2022). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria. URL: <https://www.R-project.org/>.
- Rose, Brian E. J. (2020). *Insolation*. <https://brian-rose.github.io/ClimateLaboratoryBook/courseware/insolation.html>. Accessed: 2023-05-28.
- Russell, Iain (2023). “cfgrib”. In: ECMWF. URL: <https://github.com/ecmwf/cfgrib>.
- Sena, Solar (2021). *Solar Hour Angle and How to Calculate it*. <https://solarsena.com/solar-hour-angle-calculator-formula/>. Accessed: 2023-05-29.
- Umwelt BLU, Bayerisches Landesamt für (2023). *Niederschlag – Aktion Grundwasserschutz*. URL: <https://aktiongrundwasserschutz.de/die-situation/niederschlag/> (cit. 14.05.2023).
- Vacík, Pavel (2020). *Srážkové poměry Šumavy*. URL: <https://www.facebook.com/chmi.cz/photos/a.236774606346470/4759703104053575/> (cit. 12.05.2023).
- Vanwalleghe, T a R. K Meentemeyer (2009). “Predicting Forest Microclimate in Heterogeneous Landscapes”. eng. In: *Ecosystems (New York)* 12.7, s. 1158–1172. ISSN: 1432-9840.
- Varela, Daniel (2022). “ecCodes”. In: ECMWF. URL: <https://confluence.ecmwf.int/display/ECC/ecCodes+Home>.
- Wickham, Hadley (2016). *ggplot2: Elegant Graphics for Data Analysis*. Springer-Verlag New York. ISBN: 978-3-319-24277-4. URL: <https://ggplot2.tidyverse.org>.
- (2022). *stringr: Simple, Consistent Wrappers for Common String Operations*. R package version 1.5.0. URL: <https://CRAN.R-project.org/package=stringr>.
- Wild, Jan, Martin Kopecký et al. (2019). “Climate at ecologically relevant scales: A new temperature and soil moisture logger for long-term microclimate measurement”. eng. In: *Agricultural and forest meteorology* 268, s. 40–47. ISSN: 0168-1923.

- Wild, Jan, Zdenka Neuhäuslová a Jaromir Sofron (2004). "Changes of plant species composition in the Šumava spruce forests, SW Bohemia, since the 1970s". eng. In: *Forest ecology and management* 187.1, s. 117–132. ISSN: 0378-1127.
- Wilson, Granville Tunncliffe (2016). "Time Series Analysis: Forecasting and Control, 5th Edition". eng. In: *Journal of time series analysis* 37.5, s. 709–711. ISSN: 0143-9782.
- WMO (2021). "Guide to Instruments and Methods of Observation, Volume I: Measurement of Meteorological Variables". In: 1, s. 93–94. URL: https://library.wmo.int/index.php?lvl=notice_display%5C&id=12407.
- Zacharov, P. et al. (2015). *Observatoř Milešovka*. Accessed: 2023-07-11. URL: https://www.ufa.cas.cz/DATA/files/omet/110/vkn_29web.pdf.
- Zeileis, Achim a Torsten Hothorn (2002). "Diagnostic Checking in Regression Relationships". In: *R News* 2.3, s. 7–10. URL: <https://CRAN.R-project.org/doc/Rnews/>.
- Zellweger, Florian et al. (2019). "Seasonal drivers of understorey temperature buffering in temperate deciduous forests across Europe". eng. In: *Global ecology and biogeography* 28.12, s. 1774–1786. ISSN: 1466-822X.
- Zhang, Wei et al. (2021). "Snow cover controls seasonally frozen ground regime on the southern edge of Altai Mountains". eng. In: *Agricultural and forest meteorology* 297, s. 108271–. ISSN: 0168-1923.

