

UNIVERZITA KARLOVA V PRAZE

Přírodovědecká fakulta
Katedra fyzické geografie a geoekologie

Studijní program: Geografie
Studijní obor: Fyzická geografie a geoekologie



Zuzana KREJČOVÁ

STATISTICKÝ DOWNSCALING EXTRÉMNÍCH HODNOT TEPLOTY

STATISTICAL DOWNSCALING OF EXTREME TEMPERATURE VALUES

Diplomová práce

Vedoucí závěrečné práce/Školitel: RNDr. Radan Huth, Dr.Sc.

Praha, 2017

Prohlášení:

Prohlašuji, že jsem závěrečnou práci zpracovala samostatně a že jsem uvedla všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyly předloženy k získání jiného nebo stejného akademického titulu.

V Praze dne

.....
Zuzana KREJČOVÁ

Poděkování

Děkuji mnohokrát panu RNDr. Radanu Huthovi, DrSc., vedoucímu této diplomové práce, za předání cenných znalostí, velmi přívětivý přístup a připomínky, které mi poskytoval po dobu jejího vypracovávání.

Zadání diplomové práce

Název:

Statistický downscaling extrémních hodnot teploty

Cíle práce:

Cílem bylo zjistit, zda je vhodné simulovat extrémní teploty pomocí průměrných sezónních proměnných ve volné atmosféře s využitím lineární regrese

Datové zdroje, zájmové území:

Jako proměnné ve volné atmosféře (prediktory) jsem použila geopotenciální výšku hladiny 500 a 1000 hPa a teplotu 850 hPa, data pocházela z reanalýzy ERA 40

Extrémní hodnoty teploty vzduchu pro 10 vybraných stanic v Evropě byly zjištěny z dat European Climate Assessment & Dataset a ČHMÚ

Datum zadání: 17. 12. 2014

Podpis studenta

Podpis vedoucího práce

Podpis vedoucího katedry

Obsah

Abstrakt	6
1 Úvod	7
1.1 Emisní scénáře	8
1.2 Globální klimatické modely	9
2 Downscaling	10
2.1 Dynamický downscaling	12
2.2 Statistický downscaling	12
2.2.1 Výběr prediktorů a prediktandů	14
2.2.2 Statistický downscaling v hydrologii	19
2.2.3 Metody	20
2.2.3.1 Lineární	20
2.2.3.1.1 Regresní metody	21
2.2.3.2 Nelineární	22
2.2.3.2.1 Neuronové sítě	22
2.2.3.2.2 Klasifikace	23
2.2.3.3 Porovnání metod	24
2.3 Porovnání statistického a dynamického downscalingu	29
2.4 Klimatický region a sezonalita	31
2.5 Validace	36
2.6 Downscaling extrémních událostí	37
3 Downscaling extrémních teplot	43
3.1 Prediktandy	44
3.2 Prediktory	45
3.3 Metody	45
3.4 Výsledky	46
3.4.1 Volba prediktorů	48
3.4.2 Vliv počtu prediktorů	52
3.4.3 Vliv nadmořské výšky	56
3.4.4 Vliv kontinentality	60
3.4.5 Vliv zeměpisné šířky	61
4 Závěr	63
5 Diskuze	64
Zdroje	65

Abstrakt

Tato diplomová práce se zabývá statistickým downscalingem extrémních teplot. V první části jsou popsány dva typy downscalingu: dynamický a statistický. Ke každému jsou uvedeny a základně popsány příklady různých metod, které slouží k simulacím klimatických prvků, zejména pak teplot nebo srážek. Dále jsou zde porovnány lineární a nelineární metody a dosažené výsledky předchozích studií zabývajících se touto problematikou. Poslední dobou se studie zaměřují nejen na denní nebo měsíční průměrné hodnoty, ale i na extrémní. Extrémní hodnoty jsou obtížnější simulovat. V mé práci jsem se pak zaměřila na downscaling extrémních teplot, kdy jsem použila metodu lineární regrese. Zaměřila jsem se na oblast Evropy, kde jsem si vybrala 10 stanic, které pokrývají rozmanité klima Evropy. Extrémní hodnota byla vybrána vždy za sezónu, tedy nejnížší teplota v zimě a nejvyšší v létě. Cílem této práce bylo zjistit, zda je vhodné k simulacím extrémních teplot použít sezónní průměrné hodnoty proměnných ve volné atmosféře.

Klíčová slova: downscaling, statistický downscaling, extrémní teplota, simulace klimatu

Abstract

This diploma thesis deals with statistical downscaling of extreme temperature values. In first section describes two type sof downscaling- dynamical and statistical. All the examples are listed and described variol methods to simulation chmate elements, in particular temperatures and precipitation. Then there asre the linea rand non-linear methods were compared and the results of previous studies deals with this problem. These studies address not only daily or monthly average values, but also extrémé. Extreme values are more difficult to simulate. In my thesis, I focus on downscaling of extrémé temperature using linear regression. I focused on the are sof Europe, where I chose 10 stations, which cover variol chmate of Europe. Extreme values to every season, the lowest in winter and the highest in summer. The aim of this thesis was determine whether i tis appropriate to use to simulate extreme temperature seasonal average values in the free atmosphere.

Key words: downscaling, statistical downscaling, extreme temperature, climate simulation

1. Úvod

Globální změna klimatu je poslední dobou v centru pozornosti nejen odborníků, ale i široké veřejnosti. Nejčastěji se pak hovoří o globálním oteplování, tedy o zvyšování globální teploty Země. V této souvislosti je často probírán i skleníkový efekt jako negativní činitel. Ovšem málokdo pak ví, že bez skleníkového efektu by průměrná teplota Země byla $-15\text{ }^{\circ}\text{C}$. Člověk ale tento efekt zesiluje tím, že do atmosféry vypouští skleníkové plyny, které pak nepropouští zpět do vesmíru dlouhovlnné záření, které je pohlcováno zemským povrchem, a tím se planeta Země ohřívá. Mezi globální změny klimatu ale patří i zvyšování či snižování počtu horkých/studených vln, prodlužování období dešťů/sucha a v neposlední řadě se zvažuje i to, že by mohly zesílit tropické cyklony (IPCC, 2013).

Mezi základní klimatické prvky ale nepatří jen teplota. Dalšími prvky jsou oblačnost, tlak, vítr a srážky. Všechny tyto klimatické prvky se v budoucnu změní, jen zůstává otázkou jak. Předpokládá se, že tropické cyklony budou hlubší, tlak v jejich středu bude klesat ještě na nižší hodnoty, to dále vyvolá větší rychlosti a nárazy větru.

S rostoucí teplotou pak souvisí i více srážek. Při zvýšené teplotě dochází k tepelné roztažnosti vody a následnému zvyšování hladiny oceánů a zesílení hydrologického cyklu. Ve skutečnosti to ale neznamená, že vymizí pouště, protože bude více pršet, ale že zesílí přívalové srážky a tropické cyklony. V oblastech, kde už nyní je dostatek srážek, jich bude ještě více a naopak v aridních oblastech bude ještě větší sucho než doposud.

Zde ale přichází otázka, jak budou změny velké, které klimatické prvky se opravdu změní a především jak se změní. Na tuto otázku hledají odpověď globální klimatické modely, které dokážou simulovat budoucí klima. Ovšem to je závislé především na budoucím chování lidí na Zemi, proto existují emisní scénáře. Jedná se o pokud možno reálný popis budoucího vývoje skleníkových plynů, pokud budou zahrnuty předpokládané antropogenní vlivy. Je to rozdíl mezi současností (nejčastěji obdobím 1961-1990) a budoucím klimatem, který se vypočte pomocí klimatických modelů pro určité časové období.

Klimatický model odpovídá klimatickému systému, do kterého jsou vkládány různé emisní scénáře na základě socioekonomického vývoje, tedy podle množství skleníkových plynů a aerosolů. Existuje velké množství emisních scénářů, ze kterých byly vytvořeny 4 základní, které by měly být dostatečně reprezentující. Může jít buď o globální (1), nebo regionální (2), dále se pak mohou rozdělit podle toho, jestli lidé začnou řešit problém

životního prostředí (B), nebo budou pokračovat v současném stavu, popřípadě se životní prostředí ještě zhorší (A), více v následující části Emisní scénáře.

1.1. Emisní scénáře


Budoucí klima je důležité pro mnoho odvětví, ať už se jedná o zemědělství či samotný život na Zemi. Ovšem jeho simulace je poněkud složitější, jelikož zde vzniká otázka, jak se budou lidé na Zemi v následujících několika desítkách let chovat. Klimatické podmínky jsou ovlivněny několika plyny, tzv. skleníkové plyny. Nejdůležitějším skleníkovým plynem je vodní pára, dále pak klima výrazně ovlivňuje vzrůstající množství CO₂ v ovzduší. Tento plyn je produktem i lidské činnosti, přímo je vypouštěn do ovzduší především spalováním fosilních paliv, ovšem k jeho nárůstu přispívá i odlesňování. Dalším plynem je metan, ten vzniká například při živočišné výrobě, ovšem metan se do ovzduší nedostává jen lidskou činností, uvolňuje se i z močálů. Dále pak freony, jejichž výroba byla výrazně omezena Montrealským protokolem v roce 1987.

Nikdo ale neví, jak moc se bude množství skleníkových plynů v atmosféře zvyšovat. Proto existuje velké množství emisních scénářů. Emisní scénář je vytvořen na základě různého směru vývoje společnosti. Základně se dají emisní scénáře klasifikovat na dvě větve, a to buď situace, kdy lidé začnou brát ohled na životní prostředí a omezí produkci skleníkových plynů, nebo budou neustále více využívat fosilní paliva a podporovat vznik těchto plynů. Druhé hlavní dělení vychází z toho, zda se bude svět stále více globalizovat, nebo se regiony budou vyvíjet samostatně.

Na základě těchto různých informací vzniká řada studií, které pak Mezinárodní panel pro klimatickou změnu (IPCC) shrne v hodnotící zprávě. Různé studie počítají s různým množstvím emisí, které mohou za daných situací vzniknout, a následně jsou vypočteny budoucí koncentrace skleníkových plynů v atmosféře. Nakonec klimatické modely podle koncentrací emisí určí, o kolik se změní teplota na Zemi. Jak bylo řečeno, byly vytvořeny 4 základní rodiny emisních scénářů. Emisní scénář A je zaměřený spíše na ekonomický a společenský růst, scénář B potom bere ohled na životní prostředí. Druhé dělení je podle globalizace, kdy 1 předpokládá především globalizaci, naopak 2 vychází z toho, že se regiony budou vyvíjet odděleně (Obr. 1).

Z výše uvedeného je jasné, že emisní scénáře nejsou nijak úplně přesné. Ale i tak jsou pro simulace klimatu velmi důležité. Ve zprávě IPCC z roku 2007 je uvedeno, že teplota na konci 21. století bude o 1,1 až 6,4 °C vyšší v závislosti na emisním scénáři,

tento rozptyl je pak důkazem toho, že vše je závislé především na tom, jak se budou koncentrace skleníkových plynů v atmosféře vyvíjet. Pokud se začnou využívat alternativní zdroje energie a omezí se spalování fosilních paliv, teplota na Zemi nemusí vzrůst o tak markantní hodnotu.



Obrázek 1: Základní rozdělení emisních scénářů podle IPCC

1.2. Globální klimatické modely

Podnebí je charakteristické stálostí v určité oblasti, ovšem v dlouhém geologickém vývoji Země docházelo k různým změnám. Klimatický systém není ale jen samostatné klima, velmi výraznou roli zde hraje například i oceán nebo kryosféra či biosféra. Všechny tyto části tvoří pak komplexní klimatický systém. Pro simulace vývoje klimatu se používají klimatické modely, které jsou počítány numericky. Nejčastěji využívané jsou globální klimatické modely (GCM). Jde o modely všeobecné cirkulace atmosféry, kde je započten vliv všech výše zmíněných složek, tedy oceánu, kryosféry a biosféry.

Modelování klimatu je velmi složitý a i výpočetně náročný proces. Jedná se o velmi složité numerické rovnice, které se snaží popsat děje v klimatickém systému. Globální klimatické modely se pak využívají pro simulace klimatu pro větší oblasti, jelikož mají nízké rozlišení - horizontální rozlišení se pohybuje přibližně mezi 200 a 300 km. U menších oblastí by docházelo k výrazným nepřesnostem, jelikož GCM například zachytí obrysy kontinentů či výrazná pohoří, ovšem nedokáže zachytit menší členitost pobřeží

nebo menší pohoří. K simulacím podnebí pro menší oblasti se pak využívá tzv. downscaling.

2. Downscaling

Globální klimatické modely dokáží tedy s určitými nepřesnostmi simulovat klima na různě dlouhé období, za předpokladu, že se lidé budou chovat určitým způsobem. Problém ale je v tom, že globální klimatické modely mají nízké rozlišení. Pokud nás tedy bude zajímat menší oblast, jako například území České republiky, tak bude simulace poměrně nepřesná, jelikož naše území v globálním klimatickém modelu při rozlišení přibližně 110 km leží na severním úpatí Alp. Tudíž je potřeba zpřesnit klimatickou informaci, která nás do budoucna bude zajímat. Tedy získat simulaci, kde bude vyšší rozlišení. K tomu se využívá tzv. downscaling, což je přemostění mezi tím, co globální klimatické modely dokáží simulovat, a tím, co společnost zajímá, především kvůli budoucímu vývoji. Pokud by nás zajímalo zvýšení globální teploty Země, tak jsou globální klimatické modely dostačující. Ovšem pokud budeme chtít vědět, jaká léta nebo zimy čekají Střední Evropu v následujících letech, potřebujeme vyšší rozlišení. Poslední dobou se pozornost obrací také na simulace extrémních událostí, jelikož extrémně vysoké nebo nízké teploty mají přímý vliv i na životy lidí.


Downscaling pomocí určitých technik a simulací z globálních klimatických modelů, dokáže získat informace ve vyšším rozlišení. Nejprve se ale musí downscaling otestovat na současném nebo minulém klimatu, aby se zjistila jeho přesnost. Downscaling může být buď dynamický, nebo statistický. Dynamický downscaling využívá regionální klimatické modely (RCMs), které mají okrajová vstupní data z globálních klimatických modelů. Dynamický downscaling pracuje dobře s orografií a dokáže vystihnout extrémy, ale je výpočetně náročnější. Pokud je ale chyba v globálním klimatickém modelu, přenesse se i do regionální úrovně. Často využíváný je i statistický downscaling, který funguje na základě využití empirických statistických vztahů mezi prvky ve volné atmosféře (prediktory) a přízemními prvky (prediktandy). Statistický downscaling je výpočetně méně náročný a založený na standardních statistických přístupech. Nevýhodou je ale to, že jsou potřebné dlouhé časové řady pozorování, a také musí být vhodně zvoleny prediktory, aby byl downscaling úspěšný. V Tab. 1 je uveden přehled hlavních výhod a nevýhod obou typů (Fowler a kol. 2007).

	Downscaling	
	statistický	dynamický
Výhody	poměrně levný a výpočetně efektivní	vytváří reakce založené na fyzicky konzistentních procesech
	může poskytnout bodové měřítko klimatických proměnných z výstupu GCMs	vytváří vyšší rozlišení z výstupů GCMs, které mohou vyřešit atmosférické procesy v menším měřítku
	může pomoci získat proměnné, které nejsou dostupné v RCMs	
	dobře přenosný mezi různými oblastmi	
	založený na standardních a uznávaných statistických postupech	
	možnost přímo zahrnout pozorování do metod	
Nevýhody	požaduje dlouhé a spolehlivé historické řady pro kalibraci	počítačová náročnost
	závislý na volbě prediktorů	omezený počet dostupných scénářů
	nestacionární ve vztahu prediktor- prediktand	silná závislost na hraničních bodech GCM
	nezahrnuje zpětnou vazbu klimatického systému	
	závislost na hraniční "síle" GCM; ovlivněn chybami GCM	
	velikost oblasti, klimatický region a sezóna ovlivňují přesnost downscalingu	

Zdroj: Fowler a kol. (2007)

Tabulka 1: Shrnutí výhod a nevýhod statistického a dynamického downscalingu

První model SDMS (software pro statistický downscaling) byl vytvořen v roce 2000 a skládal se z pěti základních kroků: 1) výběr prediktorů, 2) kalibrace modelu, 3) validace, 4) generování budoucích scénářů a 5) analýza výstupů (Wilby a Dawson, 2013). Od roku 1993 vzniklo přes 1700 publikací týkajících se downscalingu (Obr. 2). Po roce 2011 je publikováno každý rok přibližně dalších 300 prací.



Wilby a Dawson (2013)

Obrázek 2: Počty publikací týkající se simulací klimatu pomocí downscalingu od roku 1993 až do roku 2011 (dynamický i statistický)

2.1. Dynamický downscaling

Dynamický downscaling vychází přímo z globálních klimatických modelů. Jedna z hlavních metod dynamického downscalingu je regionální klimatický model. Další metody se pak liší podle modelů všeobecné cirkulace atmosféry (AGCMs), kdy může být buď s nerovnoměrnou sítí uzlových bodů, nebo s rovnoměrnou s vysokým rozlišením, nebo s vysokým orografickým rozlišením.

Metoda vnořeného regionálního klimatického modelu má velmi široké využití, používá se hlavně pro studie, kde se řeší regionální změny klimatu a její dopady například na vodní zdroje nebo zemědělství. Může se také využívat pro odhady extrémních událostí. Největší problém je ale v tom, že v regionálních klimatických modelech jsou vstupní okrajové podmínky převzaté z globálních klimatických modelů, takže pokud globální klimatický model obsahuje určitou chybu, projeví se následně i v regionálním klimatickém modelu.

Metoda AGCMs s nerovnoměrnou sítí uzlových bodů spočívá v tom, že zvýšíme rozlišení jen v oblasti, která nás v tuto chvíli zajímá, například v našem případě by se jednalo o území České republiky. AGCMs s rovnoměrnou sítí uzlových bodů s vysokým rozlišením se jeví jako ideální metoda pro modelování regionálního klimatu, ale má velkou výpočetní náročnost. Poslední metoda, AGCMs s vysokým orografickým rozlišením je vhodná pro modelování regionálního klimatu v oblastech, kde je počasí výrazně ovlivněno orografií jako například srážky v Alpách (Frei a kol. 2003).

2.2. Statistický downscaling

Existuje tedy velká mezera mezi tím, co globální klimatické modely dokáží simulovat, a tím, co my potřebujeme znát pro hodnocení dopadu klimatické změny v regionálním měřítku. A právě statistický downscaling vytváří „most“ pomocí empirických vztahů. Statistický downscaling je velmi často využívaný a je založený na hledání vztahů mezi prvky velkého měřítku, nejčastěji ve volné atmosféře a přízemními prvky jako je například teplota. K přemostění této mezery může docházet buď pomocí metod lineárních, nebo nelineárních. Statistickým downscalingem se zabývá velké množství studií, přičemž každá se zaměřuje jen na vybrané metody. V této části dojde k porovnání různých metod. Ovšem porovnání metod je občas i nemožné, a to z důvodu různých prediktorů a prediktandů.

Statistický downscaling slouží k simulaci lokálních prvků- prediktandů (srážky, teplota, atd.). Vychází z prvků velkého měřítku- prediktorů (tlak vzduchu, relativní vlhkost).

Hlavním cílem statistického downscalingu je získat simulace v regionálním měřítku bez využití regionálních klimatických modelů. Mezi lineární metody patří hlavně regresní modely, mezi nelineární umělé neuronové sítě nebo typizace. Regresní modely přímo kvantifikují vztah mezi prediktorem a prediktandem, ale je zde jedna důležitá podmínka, že proměnné - prediktandy musí mít normální rozdělení. Nejčastěji využívaná je jednoduchá nebo vícenásobná lineární regrese, dále se pak často používá i kanonická korelační analýza nebo analýza hlavních složek.

Při nelineárním přístupu typizace, se počasí klasifikuje do několika dopředu definovaných tříd, shluků nebo kategorií například na základě pole tlaku vzduchu a místní počasí je potom pomocí prediktandů odvozeno pro každou třídu/shluk nebo kategorii. Prediktor je v tomto přístupu ne jeden bod, ale celé pole, tedy to, jak je prvek rozložen. Mezi metody využívané při typizaci patří neuronové sítě nebo meteorologické analogy.

Velmi důležité pro statistický downscaling je nejen časové období, pro které se downscaling počítá (Huth a kol. 2001, Huth 2002), ale i prostorová struktura sítí uzlových bodů (Easterling 1999, Solman a Nunez 1999, Huth 2002) a statistické rozdělení proměnných, jako je šikmost a špičatost.

Statistický downscaling může být rozdělen na tři základní skupiny podle hodnocení vztahu mezi prediktory a prediktandy - regresní modely, typizace počasí a generátory počasí. Každá tato skupina zahrnuje několik metod, přičemž všechny závisí na určité funkci. Tyto vztahy mohou být stochastické nebo deterministické funkce mezi proměnnými ve volné atmosféře (prediktory) a lokálními proměnnými (prediktandy). Jako prediktor může sloužit například tlak přepočtený na hladinu moře nebo geopotenciální výška. Z toho pak vyplývá vztah:

$$R = F(X)$$

kdy R je proměnná regionálního klimatu, X je proměnná z volné atmosféry a F je funkce, která tyto vztahy určuje. Shoda mezi vypočítanou a pozorovanou hodnotou se poté hodnotí pomocí korelačních koeficientů. Pro provedení statistického downscalingu je ale několik předpokladů. První z nich je situace, kdy by prediktor měl být významný a hlavně dobře nasimulovaný GCMs. Dalším předpokladem je to, že vztah mezi prediktorem a prediktandem je v čase stacionární, ovšem platnost tohoto předpokladu není možná ověřit jen na pozorovaných datech, což tvrdí několik autorů (Huth, 1997, Slonosky a kol., 2001, Fowler a Kilsby, 2002). Následně je potřeba provést validaci na řadě dat s odlišnými klimatickými charakteristikami (Charles a kol. 2004).

Statistické metody jsou více přímočaré než metody dynamického downscalingu, ovšem mají sklon podhodnocovat odchylky a hůře napodobovat extrémní události (Fowler a kol., 2007). Více sofistikovaný downscalingový přístup je kanonická korelační analýza, kterou poprvé použil Bürger (1996). Dále ji pak ve své práci použili Huth (1999), Dehn a kol. (2000) a Müller- Wohlfel a kol. (2000).

2.2.1. Výběr prediktorů a prediktandů

Velmi důležitý je výběr prediktorů, jelikož některé se mohou jevit jako významné pro současné klima, ovšem pro budoucí už to tak být nemusí (Wilby, 1998). Také je nutné zmínit, že vybrané prediktory musí splnit více požadavků než jen se nejlépe přiblížit pozorovaným prediktandům. Minimálně jsou zde další dva požadavky. Jedním z nich je ten, že prediktory by měly být správně simulované globálním klimatickým modelem, pokud tomu tak není, nelze to správně ověřit na proměnných, které jsou z nich odvozené. Druhým požadavkem je to, aby proměnné vybrané jako prediktory pokrývaly nejen přirozenou variabilitu v současných klimatických podmínkách, ale musí zahrnout i změnu klimatu, což je ale nemožné ověřit na pozorovaných datech. Proto by měl jeden prediktor vycházet z GCMs, poté by měl být porovnán s klimatickými změnami, které byly GCMs nasimulovány a následně odvozený z downscalingu. Pokud se tyto dva predikandy shodnou, neznamená to ale, že downscalingový vztah napodobí změnu klimatu a že vybrané proměnné jsou správné pro změnu klimatu. Spíše dochází jen k naznačení toho, že vybrané prediktory by nemusely být špatně vybrané (Huth, 2002).

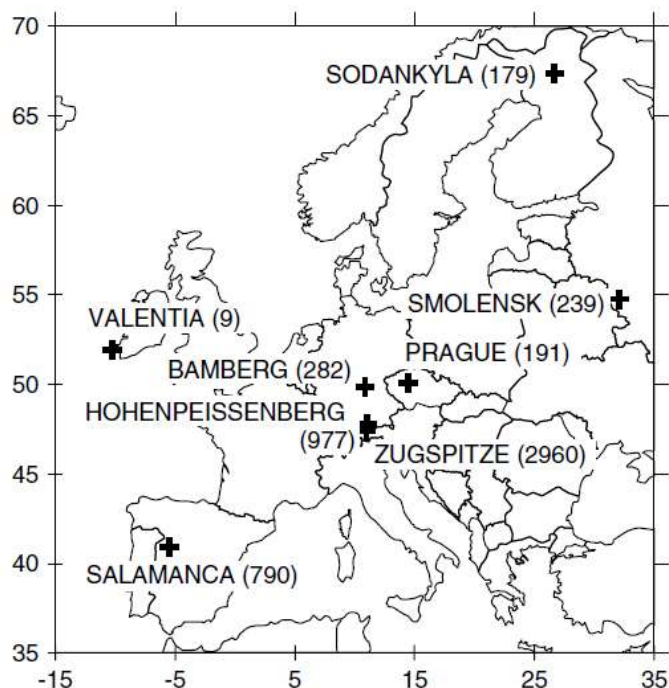
Dříve se jako prediktory používaly převážně proměnné cirkulace velkého měřítko (geopotenciální výška), dále pak teplota (Hewitson 1994), srážky (Saunders a Byrne 1996, Noguer 1994) a tlak přepočtený na hladinu moře (Heyen a kol. 1996). Tudiž se předpokládalo, že změna v povrchových složkách počasí je způsobena skleníkovým efektem, jenže pro delší časový úsek to tak být nemohlo (Widmann a Schar 1997). První verze SDMS zkoušela velké množství prediktorů (Tab. 2), zahrnovala jak teploty v různých hladinách, tak i různé geopotenciální výšky, ale i složku větru či relativní vlhkost. Proto se jako prediktory začaly používat i teploty ve volné atmosféře nebo vlhkostní proměnné (Wilby a kol. 1998). Prvním důležitým krokem při downscalingu je výběr správných prediktorů, dále pak výběr vhodné časové řady a oblasti, pro kterou se bude downscaling počítat. Easterling (1999) například zkoumal závislost korelace mezi stanicemi na jejich vzdálenosti.

Predictor	Description
TEMP	Mean temperature at 2 m
MSLP	Mean sea level pressure
H850	850 hPa geopotential height
H500	500 hPa geopotential height
USUR	Near surface westerly wind
U850	Westerly wind at 850 hPa
U500	Westerly wind at 500 hPa
VSUR	Near surface southerly wind
V850	Southerly wind at 850 hPa
V500	Southerly wind at 500 hPa
FSUR	Near surface wind strength
F850	Wind strength at 850 hPa
F500	Wind strength at 500 hPa
ZSUR	Near surface vorticity
Z850	Vorticity at 850 hPa
Z500	Vorticity at 500 hPa
DSUR	Near surface divergence
D850	Divergence at 850 hPa
D500	Divergence at 500 hPa
QSUR	Near surface-specific humidity
Q850	Specific humidity at 850 hPa
Q500	Specific humidity at 500 hPa
RSUR	Near surface relative humidity
R850	Relative humidity at 850 hPa
R500	Relative humidity at 500 hPa

Tabulka 2: Testované prediktory v prvním SDSM

Zdroj: Wilby a Dawson, 2013

Huth a kol. (2008) ve své studii zvolili jako prediktandy denní minimální a maximální teploty na osmi stanicích v Evropě (Obr. 4). Stanice byly vybrány tak, aby byly dostatečně reprezentativní, tedy jsou tam jak oceánské, tak kontinentální, severní i jižní a i dvě horské. Data použili z ECA projektu (Klein Tank a kol. 2002). Data pro volnou atmosféru použili z reanalýz NCEP/NCAR (Kalnay a kol. 1996), a to výšky 500 hPa a 1000 hPa, a teplotu z výšky 850 hPa vždy ve 12:00 UTC, přičemž do modelu jako prediktory vstoupily výška 500 hPa a teplota v 850 hPa. Tyto prediktory byly vybrány na základě předchozích studií (Huth 1999, Huth 2002), kdy se ukázala tato kombinace jako nejlepší pro území střední a západní Evropy. Oblast prediktorů zasahovala od 25 ° s. š. až k 80° s. š. a od 50° z. d. až k 55° v. d. a byla rozdělena do 25 čtverců, síť uzlových bodů byla tedy 5° x 5°. Rozlišení originálního souboru bylo 2,5° x 2,5°, takže každá druhá hodnota byla zachována. Pro jejich práci by bylo rozlišení zbytečně husté. Analýza byla provedena pro zimní měsíce, tedy prosinec až únor, v letech 1958/1959 až 1992/1993.




Obrázek 4: Umístění stanic s jejich nadmořskou výškou v m n. m.

Ve studii Hutha (2002) je proveden downscaling pro denní průměrné teploty v zimě (prosinec až únor) pro období 1982/1983 až 1989/1990. Data jsou vybrána pro 39 stanic ve střední a západní Evropě. Stanice jsou v různých nadmořských výškách, a jak u oceánu, tak i uvnitř kontinentu. Stanice použité v této studii jsou ukázány v Tab. 3, kde je uvedena i jejich nadmořská výška, na Obr. 5 je ukázána jejich poloha na kontinentu. Díky krátkému časovému období, jsou data úplná. Jako prediktory byly vybrány výška 500 hPa, tlak přepočtený na hladinu moře, teplota 850 hPa a tloušťka 1000 až 500 hPa. Původní soubor z NCEP/NCAR měl vysoké rozlišení ($2,5^\circ \times 2,5^\circ$), pro danou studii ale stačilo rozlišení $5^\circ \times 10^\circ$, kdy zkoumaná oblast prediktorů zasahovala od 35° s.š. k 70° s.š. a od 45° z.d. až ke 45° v.d.

No.	Station name	Country	Alt	No.	Station name	Country	Alt
1	Hradec Králové	CZ	278	21	Gießen		186
2	Velké Meziříčí		452	22	Saarbrücken		319
3	Holešov		224	23	Würzburg		268
4	Milešovka		833	24	Nürnberg		314
5	Teplice		225	25	Stuttgart		373
6	Husinec	SK	536	26	München		515
7	Hurbanovo		115	27	Neuchâtel	CH	487
8	Sliač		313	28	Basel		317
9	Oravská Lesná		780	29	Zürich		569
10	Štrbské Pleso		1360	30	Säntis		2498
11	Poprad		695	31	Davos		1590
12	Košice		230	32	Reutte	AT	870
13	Norderney	DE	11	33	Sonnblick		3105
14	Hamburg		13	34	Feurkogel		1618
15	Greifswald		2	35	Klagenfurt		447
16	Kleve		46	36	Wien		202
17	Hameln		66	37	Koksijde	BE	5
18	Potsdam		81	38	Deurne		10
19	Cottbus		69	39	Saint Hubert		556
20	Erfurt		316				

Zdroj: Huth, 2002

Tabulka 3: Seznam stanic použitých ve studii Huth (2002) s nadmořskou výškou



Zdroj: Huth, 2002

Obrázek 5: Umístění stanic

Schoof a Pryor (2001) se zabývali dopady lidské činnosti na klimatické podmínky a následným vlivem na zemědělství na středozápadě USA, protože delší období vyšších teplot s podprůměrnými srážkami může negativně ovlivnit například růst kukuřice (Carlson, 1990). Hledali tedy propojení mezi cirkulací velkého měřítka, která určuje množství srážek nebo pokrytí oblačností, a povrchovými podmínkami, přičemž tento vztah může být i vysoce nelineární. Zabývali se oblastí v Severní Americe zasahující od 35° do 45° s. š. a od 80° do 95° z. d., což zahrnuje státy Indiana, Illinois, Ohio, Kentucky, Tennessee, Michigan, Missouri, západ Pensylvánie a jihovýchodní Wisconsin. Při výběru této oblasti hrálo důležitou roli zemědělství v této části USA, ale také to, že se jedná o rovinný terén. Pracovali s daty ze sedmi stanic pro osmnáctileté leté období (1973-1990),

kteře zahrnovalo denní minimální a maximální teploty, a celkový denní úhrn srážek. Jako prediktory použili výšky 500 hPa a 700 hPa, teplotu 850 hPa, tlak přepočtený na hladinu moře a relativní vlhkost.

Kidson a Thompson (1998) se zaměřili na oblast Nového Zélandu. Jedním z důvodů bylo to, že jde převážně o hornatý stát. Chtěli se zaměřit hlavně na interakci počasí s orografií, která pak utváří specifické regionální klima. Na většině míst jsou nadmořské výšky vyšší než 1500 m, Jižní ostrov pak leží přímo v dráze převládajícího západního proudění. Pracovali sice s kratší časovou řadou, ale data byla celkem obsáhlá. Sledované období bylo 1980 až 1994, soubor měl rozlišení 2,5° zeměpisné délky i šířky, a to v časech 00:00 a 12:00 UTC. Data pro celé období ale nebyla stejná, pro období 1980 až 1989 měli hodnoty ze sedmi výškových hladin - 1000, 850, 700, 500, 300, 200 a 100 hPa, mezi léty 1990 až 1993 navýšili počet hladin na 14 (přidali 400, 250, 150, 70, 50, 30 a 10 hPa) a v posledním roce 1994 byla přidána poslední výška 925 hPa. Zahrnuli zde geopotenciální výšku, teplotu, složku větru a relativní vlhkost. Jako přízemní hodnoty si vybrali denní úhrn srážek, maximální a minimální teplotu pro 78 stanic, které dobře reprezentují Nový Zéland. Jako prediktory ale použili jen výšky 1000 a 500 hPa mezi 160 ° v. d. až 175 ° z. d. a 25 ° až 55 ° j. š.

Kettle a Thompson (2004) se později zaměřili také na horské oblasti, tentokrát ale v Evropě. Jejich důvod byl především ten, že v horských oblastech leží velké zásoby vody ve formě sněhu a ledu a pokud by se změnily klimatické podmínky a tato voda by roztála, mělo by to obrovský ekologický dopad. Pracovali s denními teplotami vzduchu pro období od roku 1994 do 2001 pro regresní modely, ověřování pak probíhalo pro měsíční teploty mezi léty 1980 až 1990. Jelikož se zabývali jen horskými oblastmi, tak pro analýzu vybrali stanice ležící ve výšce nad 1000 m ve střední a jižní Evropě, ve Skandinávii pak nad 700 m, z toho důvodu, že se jedná o severnější zeměpisné šířky a teplotní podmínky odpovídají vyšším nadmořským výškám v Alpách. V Tab. 4 je uveden přehled stanic, které byly použity pro tuto práci.

Kvůli dálkovým vazbám byla data ve studii Kettle a Thompson (2004) rozdělena do léta- červen, červenec, srpen a na tzv. „dlouhou zimu“ - zbytek roku, protože telekonekce (dálkové vazby) se projevují více v zimním období, tudíž modely pro letní období požadovaly jen polovinu počtu prediktorů než pro zimu (Kettle a Thompson, 2004). Huth (2002) uvádí, že downscalingové modely jsou vytvořeny nejlépe s jednou hodnotou teploty a jednou hodnotou cirkulace jako prediktorem, Kettle a Thompson (2004) pak použili jako prediktor teplotu 850 hPa (T850) a tlak přepočtený na hladinu moře (SLP).

Table 1. Details of daily data (1994 to 2001) used in this study. **Bold values** indicate stations for which there is also long-term (from 1958) monthly data. m a.s.l.: metres above sea level

ID	Name	Country	Lat. (°N)	Long. (°E)	Altitude (m a.s.l)	
1	012380	Fokstua II	Norway	62.15	9.28	0974
2	028010	Kilpisjarvi	Finland	69.05	20.78	0476
3	066800	Säntis	Switzerland	47.25	9.35	2500
4	067300	Jungfrau	Switzerland	46.55	7.98	3576
5	067500	Guetsch	Switzerland	46.65	8.62	2284
6	067530	Piotta	Switzerland	46.52	8.68	1016
7	067590	Cimetta	Switzerland	46.20	8.80	1648
8	067820	Disentis	Switzerland	46.70	8.85	1180
9	067910	Corvatsch	Switzerland	46.42	9.82	3299
10	067920	Samedan airport	Switzerland	46.53	9.89	1706
11	075600	Mount Aigoual	France	44.12	3.58	1565
12	082150	Navacerrada Pass	Spain	40.78	-4.02	1888
13	111460	Sonnblick	Austria	47.05	12.95	3107
14	111550	Feuerkogel	Austria	47.82	13.73	1621
15	112120	Villacheralpe	Austria	46.60	13.67	2160
16	112140	Preitenegg	Austria	46.93	14.92	1055
17	114570	Churanov	Czech Rep.	49.07	13.62	1126
18	117870	Lysa Hora	Czech Rep.	49.55	18.45	1327
19	119300	Lomnický Stit	Slovakia	49.20	20.22	2635
20	125100	Sniezka	Poland	50.73	15.73	1613
21	150520	Rarau	Romania	47.45	25.57	1541
22	151080	Ceahlau Toaca	Romania	46.93	25.92	1898
23	152800	Omu	Romania	45.45	25.45	2509
24	153020	Predeal	Romania	45.50	25.58	1093
25	160080	S. Valentino alla	Italy	45.75	10.53	1461
26	160210	Rolle Pass	Italy	46.30	11.78	2006
27	160220	Paganella	Italy	46.15	11.03	2129
28	161240	Cisa Pass	Italy	44.43	9.93	1040
29	161340	Cimone	Italy	44.20	10.70	2173

Zdroj: Kettle a Thompson (2004)

Tabulka 4: Seznam stanic s jejich zeměpisnými souřadnicemi a nadmořskou výškou

Huth (2002) zkoumal vliv velikosti oblasti, na niž jsou definovány prediktory, ten se ale ukázal jen velmi malý. Pokud je použita regrese v uzlových bodech, tak hustota stanic a ani velikost oblasti prediktandů nemá žádný vliv. Dále uvádí, že je vhodné pracovat s proměnnými volné atmosféry jako prediktory pro povrchovou teplotu. Ovšem nejlepších výsledků se ale dosáhne, pokud se vytvoří pár prediktorů, přičemž jeden ponese informaci o teplotě a druhý o cirkulaci.

2.2.2. Statistický downscaling v hydrologii

Často kladenou otázkou je to, zda bude klima čím dál tím extrémnější nebo nikoliv. Tuto otázku pokládá i IPCC v hodnotících zprávách. Dále je řešeno i to, zda bychom měli věnovat více pozornosti nejen měnícím se teplotám a jejím extrémům, ale i srážkám, protože globální oteplování může vést k zintenzivnění hydrologického cyklu a zvýšení průměrných nebo i přívalových srážek. Proto je downscaling využíván i v hydrologii, kde podobně jako v klimatologii je potřeba vytvořit přemostění mezi tím, co nasimulují GCMs a

lokálními procesy, které se v důsledku globálního oteplování změní. Fowler a kol. (2007) srovnávají metodologické studie, modelují extrémní události a rozšiřují práci Xu (1999), který zkoumal, jaký dopad budou mít klimatické změny na vodní zdroje.

2.2.3. Metody

Pro simulace pomocí statistického downscalingu může být použito velké množství metod. Tyto metody se mohou úplně základně dělit na lineární či nelineární, tedy podle vztahu mezi prediktorem a predikantem. Ačkoliv se dříve uvažovalo, že vztah může být pouze lineární, postupem času se ukázalo, že tento vztah je v některých případech i nelineární. Zvláštní metodou jsou pak generátory počasí, které nespádají ani do jedné z výše uvedených kategorií. Kettle a Thompson (2004) uvádí, že existují základní 4 kategorie downscalingu - regresní metody, typizace počasí, stochastické generátory počasí a regionální klimatické modely (Wilby a Wigley, 1997), jejich práce například využívá regresní metody pro simulace teplot.

Generátory počasí jsou stochastické modely. Při simulování srážek jsou generátory počasí o trochu přesnější než typizace počasí (více v části Nelineární metody), zejména pak při extrémních událostech (Fowler a kol., 2007). Ovšem hlavní nevýhodou je, že jsou vytvářeny pomocí vztahů v lokálním klimatu, takže by mohl nastat problém, pokud by byly použité v jiné klimatické oblasti, ale jejich možná použitelnost nebyla v práci Fowler a kol. (2007) testována.

2.2.3.1. Lineární

Lineární metody předpokládají lineární vztah mezi prediktorem a predikantem. Patří sem například násobná lineární regrese, která byla vyvinuta a úspěšně použita již před několika desetiletími k určení přízemní teploty, hlavně kvůli předpovědi počasí Kleinem (1962). Lineární metody byly například použity v práci Mpelasoka a kol. (2001) pro měsíční teploty a srážky nebo ve studii Wilbyho a kol. (1998) pro denní úhrn srážek.

Statistické vztahy mezi proměnnými, které jsou simulované globálním klimatickým modelem a proměnnými při zemském povrchu, mohou být popsány několika statistickými metodami. Jednou z nejvyužívanějších metod je násobná lineární regrese, která může vycházet buď přímo z hodnot v uzlových bodech, nebo ze základních složek prediktorů. Další často používanou metodou je kanonická korelační analýza.

2.2.3.1.1. Regresní metody

Regresní modely přímo kvantifikují vztah mezi prediktem a prediktorem. Patří sem násobné regresní modely (Hellström a kol., 2001), dále pak další komplexní techniky zahrnující hlavní složky tlakového pole nebo geopotenciální výšky (Kidson a Thompson, 1998, Hanssen-Bauer a kol., 2003), více sofistikované metody jako je například kanonická korelační analýza (Karl a kol., 1990) a také metoda zvaná „singular value decomposition“ (Huth, 1999, von Storch a Zwiers, 1999).

Huth a kol. (2008) použili tři typy metod. Jednou z nich byly dva lineární modely, přičemž jeden byl založený na násobné regresi hlavních složek velkého měřítka, kde prediktory byly vybrány krokově, druhý vycházel také z násobné regrese, ale prediktory byly vybrány z hodnot v uzlových bodech. Byl zde použitý i S - mode, kde sloupce odpovídaly hodnotám v uzlových bodech a řady dním. Regresní modely mohou být vytvořeny pro různý počet hlavních složek, Huth a kol. (2008) použili 4, 6, 12, 16 a 20 hlavních složek.

V práci Hutha (2002) se hodnotí 3 lineární metody statistického downscalingu - kanonická korelační analýza (CCA) přefiltrovaná analýzou hlavních složek, násobná lineární regrese (MLR) a dále metoda, která se nazývá analýzou singular value decomposition (SVD), přičemž jako nejlepší se jeví násobná lineární regrese. Bretherton a kol. (1992) se detailněji zabývali metodami CCA a SVD. Hlavní myšlenka těchto dvou metod spočívá v hledání dvojic, které mají společné maximum korelace (CCA), nebo kovariance (SVD). Huth (2002) použil tři rozdílné modely násobné lineární regrese, a to krokové třídění hlavních složek pole prediktorů (dále jen kroková regrese), MLR prediktorů hlavních složek bez třídění (všechny hlavní složky vstupují do modelu) - dále jen úplná regrese, a poslední krokovou regresi hodnot v uzlových bodech (dále jen regrese v uzlových bodech). Při krokovém třídění je každý potenciální prediktor (buď hlavní složka, nebo hodnota v uzlovém bodě) hodnocen kvůli jeho individuální hladině významnosti před zahrnutím do regresní rovnice, po přidání do rovnice je každá proměnná uvnitř rovnice hodnocena pro vlastní významnost jako součást rovnice. Proměnná je přidána do rovnice, pokud hladina významnosti je nižší než 10 %. Prediktory a prediktandy do všech modelů vstupují jako normalizované anomálie. Kidson a Thompson (1998) k výpočtu použili také regresní rovnice.

2.2.3.2. Nelineární

Poslední dobou se začínají používat i nelineární metody, do kterých patří tzv. několiknásobné splíny (Corte-Real a kol. 1995) nebo umělé neuronové sítě (Crane a Hewitson 1998; Wilby a kol 1998). Dalšími nelineárními metodami jsou typizace počasí nebo i klasifikace, která spočívá ve výskytu konkrétních typů počasí, které jsou rozděleny do tříd v místním klimatu. Třídy počasí mohou být vytvořeny několika způsoby. Například na základě synoptiky, kde se používá empirická ortogonální funkce (Goodess a Palutikof, 1998), dále indexem tlaku přepočteného na hladinu moře (Conway a kol., 1996) nebo použitím shlukové analýzy (Fowler a kol., 2000). Klimatická změna se může odhadnout pomocí vyhodnocení změn ve frekvenci různých tříd počasí simulované GCMs.

2.2.3.2.1. Neuronové sítě

Velmi často využívané jsou neuronové sítě, které se snaží ukázat, že vztah mezi prediktorem a predikandem nemusí být jen lineární. Neuronové sítě se postupně staly velmi oblíbenými v různých vědeckých odvětvích, protože slouží jako praktický nástroj k analýze různých časových období. Podrobnější informace jsou uvedeny v několika studiích, například se jimi zabývá Hsieh a Tang (1998) nebo Gardner a Dorling (1998). Nejjednodušším modelem je perceptron, protože je tvořen jen jedním neuronem. Ovšem dá se použít jen při lineárním rozdělení, proto vznikl vícevrstevný perceptron, který má podstatně širší využití. V práci Hutha a kol. (2008) se vícevrstevný perceptron skládal ze vstupní vrstvy, kde počet neuronů byl roven počtu prediktorů, a výstupní vrstvy, kde počet neuronů se rovnal počtu prediktandů, dále obsahoval i jednu nebo více skrytých vrstev.

Huth a kol. (2008) ve své práci jako jednu z metod použili neuronové sítě. Jako nejlepší pro analýzy, které prováděli, se ukázal vícevrstevný perceptron, který použil například i Mpelasoka a kol. (2001). Při použití vícevrstevného perceptronu ale hrozí, že nebude dosaženo globálního minima chybové funkce, ale učení bude ukončeno lokálním minimem. Také může dojít k přeučení, pokud proces učení poběží příliš dlouho, síť bude příliš optimalizovaná jen pro soubor určený k učení a nedokáže ho zobecnit. Při testech se ukázalo, že je lepší počítat jen s jednou skrytou vrstvou, proto Huth a kol. (2008) zvolili vícevrstvý perceptron s pouze jednou skrytou vrstvou jako model neuronové sítě pro svoji studii. Při vytváření neuronových sítí Huth a kol. (2008) hledali různé kombinace potenciálních prediktorů a nejlepší síť uzlových bodů. Datový soubor byl rozdělený na tři části, a to trénovací, ověřovací a testovací. Zkoumány jsou v práci dva odlišné modely neuronových sítí, první je podobný regresi v uzlových bodech, kde potenciační

prediktory zahrnují standardizované hodnoty ve výškách 500 hPa v uzlových bodech a teploty 850 hPa ve všech uzlových bodech. Ve druhém modelu potenciální prediktory zahrnují 20 prvních hlavních složek ve výšce 500 hPa a teplot 850 hPa. V obou modelech jsou prediktandy standardizované teploty na stanicích. Regrese z hodnot v uzlových bodech modelu neuronové sítě byla provedena pro všech 8 stanic. První výsledky modelu hlavních složek, které vycházely z neuronové sítě, byly podobné výsledkům regrese v uzlových bodech, proto se dále kvůli počítačové náročnosti počítaly jen pro čtyři stanice.

Huth a kol. (2008) ale došli k závěru, že pro zlepšení downscalingu v neuronových sítích je důležitý nižší počet prediktorů, aby došlo ke snížení nejistot v parametrech. Také ukázali, že brát základní složky jako prediktory není správná cesta, protože zde chybí důležité informace. Jelikož jejich výběr stanic byl reprezentativní, mohou být výsledky zobecněny alespoň pro střední zeměpisné šířky.

2.2.3.2.2. Klasifikace

Mezi klasifikační metody patří například k - means, což je metoda shlukové analýzy, která se velmi často používá v klimatologii, dále pak analýza hlavních složek v T - modu. Klasifikační metody mají odlišné vlastnosti, výhody a i své nevýhody (Huth, 1996). Metoda k - means je citlivá na výběr počátečních zdrojových bodů a také vytváří stejně velké třídy. Její hlavní výhodou je dobré oddělení tříd. Metoda analýzy hlavních složek v T - modu je výborná v napodobení známé struktury dat, ovšem na úkor menšího oddělení tříd. Obě metody byly použity v řadě studií, které se zabývaly atmosférickou cirkulací. T - mode použili například Compagnucci a Salles (1997) nebo Huth (1997) a k - means Esteban a kol. (2005), Santos a kol. (2005) nebo Terray a kol. (2004).

Huth a kol. (2008) uvádí, že u vztahu mezi prediktorem a prediktandem hraje důležitou roli i typ synoptické situace. Klasifikace by mohla, ale i nemusela zlepšit výsledky. Při downscalingu byla klasifikace použita jen párkrát, v jednom případě Saunders a Byrne (1996,1999) uvádí, že průměrná hodnota třídy je přičtena ke každému členovi této třídy, v druhém případě měsíční/roční frekvence denních cirkulačních typů slouží jako prediktor měsíčních/ročních průměrů, což uvedli Goodness a Jones (2002).

Metoda klasifikace byla použita jako třetí metoda v práci Huth a kol. (2008). Použili dvě klasifikační metody, a to k - means a analýzu hlavních složek v T - modu. Klasifikace vytvořili pro výšky 500 a 1000 hPa. V analýze hlavních složek v T - modu sloupce odpovídají časovému pozorování a řádky odpovídají hodnotám v uzlových bodech. Zde

Huth a kol. (2008) uvádí, že počet tříd je roven počtu hlavních složek a vybrali 4,11 a 18 hlavních složek pro výšky 500 hPa a 4, 12 a 18 hlavních složek pro výšky 1000 hPa. Druhá klasifikační metoda, kterou použili, byl k - means, což je metoda shlukové analýzy, která je velmi široce využívána v klimatologii. Dohromady bylo vytvořeno 12 různých klasifikací.

2.2.3.3. Porovnání metod

Nelineární metody byly o trochu méně využívány, z tohoto důvodu Mikšovský a Raidl (2005) porovnali nelineární metody s nejčastěji využívanou lineární metodou - násobnou lineární regresí. Použili denní průměrné, minimální a maximální teploty z 25 stanic v Evropě a reanalýzu pro downscaling. Dospěli k závěru, že všechny jimi zkoumané nelineární metody jsou přesnější než lineární regrese, a to ve většině zkoumaných případů. Jsou ale i další studie, které se snažily dokázat, že nelineární metody simulují hodnoty lépe než lineární, například Trigo a Palutikof (1999) na denních teplotách nebo Schoof a Pryor (2001) pro denní teploty a měsíční úhrny srážek. Huth a kol. (2008) porovnali statistický downscaling denních teplot lineárními metodami s příslušnými modely neuronových sítí.

Schoof a Pryor (2001) při downscalingu zjistili, že ke zjištění vztahu mezi synoptickým měřítkem a místními podmínkami lze použít velké množství metod, například regresi (Wilby a kol., 1998), kanonickou korelační analýzu (Heyen a kol., 1996), umělé neuronové sítě (Hewitson a Crane, 1992) a stochastické generátory počasí (Hughes a Guttorp, 1994). V této práci jsou prediktory proměnné atmosférické cirkulace (Huth, 1999), a to z toho důvodu, že při downscalingu jsou důležité výstupy z GCMs, které musí být velmi přesně napodobeny, proto Schoof a Pryor (2001) využívali jak cirkulaci, tak teplotu, ale i vlhkost jako proměnnou. Při downscalingu použili 75 % dat k trénování a zbylých 25 % k hodnocení modelu. Pro denní maximální teploty zjistili, že nejlepší metodou jsou umělé neuronové sítě, jelikož korelace mezi predikovanými a pozorovanými hodnotami byly vyšší. Podobných výsledků dosáhl ale i Easterling (1999), který použil tři atmosférické proměnné (výšky 850 a 500 hPa, teplotu 500 hPa a relativní vlhkost 500 hPa) k simulaci měsíční maximální a minimální teploty a měsíčního úhrnu srážek na 32 stanicích v centrálním USA. Jeho korelační koeficienty se pohybují mezi simulovanými a pozorovanými hodnotami v rozmezí od 0,8 do 0,9 pro měsíční maximální teploty, od 0,7 do 0,8 pro měsíční minimální teploty a od 0,4 do 0,7 pro měsíční úhrn srážek. Pro porovnání, v práci Schoof a Pryor (2001) jsou hodnoty takové: pro denní maximální

teploty 0,34 až 0,85, pro denní minimální teploty 0,63 až 0,89 a pro měsíční úhrn srážek od 0,54 do 0,65.

Weichert a Bürger (1998) simulovali teplotu, tlak vodní páry a úhrn srážek v Německu, jako prediktory jim sloužily výška 500 hPa a teplota 850 hPa. Srovnávali kanonickou korelační analýzu a umělé neuronové sítě. Přišli na výrazný rozdíl mezi těmito metodami, neuronové sítě vysvětlily některé extrémní srážkové události, zatímco lineární metody je nerozpoznaly. Schoof a Pryor (2001) došli k závěru, že modely, které simulovaly teploty, byly celkově dobré, modely simulující srážky nedokázaly zachytit jejich variabilitu ovládanou cirkulací synoptického měřítka. Z tohoto důvodu je proto nutné použít další proměnné k předpovídání extrémních srážkových událostí, a to hlavně v kratším časovém úseku.

V práci Zorita a von Storch (1999) je ukázáno, že neuronové sítě simulují s menší přesností denní úhrny srážek než jednoduchá analogová metoda. Cavazos (1997) simulovala denní srážky pomocí neuronových sítí na 20 stanicích na severovýchodě Mexika pro 8 zimních sezon (1985 - 1993), jako prediktory použila tlak přepočtený na hladinu moře, výšku 500 hPa a tloušťku 1000-500 hPa. Její korelační koeficienty mezi predikovanými a pozorovanými hodnotami byly i přes odlišné fyzicko-geografické vlastnosti vysoké, a to 0,7. Také v práci upozornila na extrémní události, jako je například El Niño.

Huth a kol. (2008) se zabývali nelinearitami, které vstupují do downscalingových modelů. Dospěli ale k tomu, že nelinearity vedou ke zlepšení, ale jen tvarů statistického rozdělení pro neuronové sítě a v prostorové struktuře pro klasifikaci. Dále ale zvažovali dvě možná řešení, první z nich se týkalo neuronových sítí a druhé stratifikace souboru cirkulačními typy. Toto porovnávali pro 8 stanic v Evropě (které byly reprezentativně rozmístěny) v zimních měsících. Došli k závěrům, že nejlepší lineární metodou je regrese v uzlových bodech. U modelů neuronových sítí jsou lepší hodnoty v uzlových bodech, v nichž jsou definované prediktory. A mezi klasifikačními modely je nejlepší nejmenší počet tříd (4). Největší úspěšnost je dosažena lineárními metodami, použitím neuronových sítí a stratifikace došlo ke zlepšení jen u pár výjimek. Neuronové sítě dobře napodobí šikmost, ale nedokáží zachytit rozsah špičatosti. V závěru práce Huth a kol (2008) uvádí, že ze všech jimi zkoumaných metod je nejlepší lineární regrese v uzlových bodech. Také uvádí, proč jsou nelineární metody ve většině případů horší než ty lineární. Zprv by mohl být problém v nelineárním vztahu mezi prediktory a predikandy, protože vztah mezi prediktorem a denní teplotou by měl být lineární, nebo by se alespoň lineárnímu vztahu měl blížit (Mikšovský a Raindl, 2005). Zadruhé je v modelech neuronových sítí příliš

mnoho parametrů, aby se dalo jasně říci, které způsobují větší nejistoty. Zatřetí kvůli nepřesnostem v klasifikačních modelech. Lineární downscaling se ukázal jako nejlepší metoda pro denní extrémní teploty ze všech zkoumaných. Nicméně skupina lineárních metod je velmi rozsáhlá a obsahuje i odlišné lineární metody a kombinace prediktorů (Huth, 2002). V této práci také nebyly zkoumány ani zdaleka všechny metody, ovšem kroková regrese v uzlových bodech se ukázala jako nejlepší a dalece překonává regresi základních složek, kanonické korelace a i SVD.

Huth a kol. (2008) se zabývali i empirickým rozdělením, přičemž zjistili, že regrese v uzlových bodech a metoda klasifikace je blízká normálnímu rozdělení. Neuronové sítě jsou jediné schopné simulovat odchylky teplotního rozdělení od normálu. Lineární metody jen přenáší statistické vlastnosti prediktorů na prediktandy. Jelikož mají prediktory více nebo méně normální rozdělení, lineárně downscalované hodnoty se nijak nemohou odchýlit od normálu, což už řešili i Huth a kol. (2003).

Při srovnávání downscalingových metod Huth (2002) použil kombinaci dvou prediktorů, a to teploty 850 hPa a výšky 500 hPa, ostatní výsledky byly podobné. Jedna z věcí, kterou v této práci Huth (2002) řeší, je ideální počet hlavních složek, které vstupují do násobné lineární regrese nebo kanonické korelační analýzy. Výsledky násobné lineární regrese můžete vidět v Tab. 5, ze které je patrné, že se zvyšujícím se počtem hlavních složek se zlepšuje i přesnost downscalované hodnoty.

TABLE 2. Performance (in terms of areally averaged rmse, in °C) of stepwise and full regression for different numbers of PCs of predictors. The last row shows results for the pointwise regression. The range of the number of variables selected in the stepwise regression models is in the last column.

No. of PCs	Rmse stepwise regression	Rmse full regression	No. of variables in stepwise regression
3	4.00	4.00	1–3
5	3.84	3.83	3–5
7	3.69	3.69	4–7
9	3.55	3.55	5–9
11	3.53	3.52	6–11
15	3.52	3.50	8–14
Pointwise	2.88	—	10–29

Tabulka 5: Výkonost krokové a celkové regrese pro různý počet hlavních složek prediktorů

Zdroj: Huth (2002)

Dále Huth (2002) zjistil, že regrese v uzlových bodech je lepší než regrese vycházející z hlavních složek, k podobnému výsledku ale dospěli už i Klein a Walsh (1983). Ohledně kanonické korelační analýzy, tak Huth (2002) uvádí, že přidáním více kanonických modů dochází ke zlepšení přesnosti, ale po překročení určitého počtu začíná přesnost nepatrně klesat. Ale i u CCA se ukázalo, že čím vyšší počet hlavních složek, tím větší je přesnost downscalované hodnoty. Úplně největší přesnost je dosaženo při použití 15 hlavních složek prediktorů, 15 hlavních složek prediktandů a pro 5 kanonických modů,

ale i tak je střední kvadratická větší (3,55 °C) než pro regresi v uzlových bodech (2,88 °C) (Tab. 6). Použitím poslední metody - SVD Huth (2002) zjistil, že nejnižší možná střední kvadratická chyba je 3,64 °C, takže se metoda SVD ukázala z těchto tří jako nejhorší, protože při zvyšování počtu hlavních složek rostla střední kvadratická chyba rychleji.

TABLE 4. Areally averaged rmse for CCA with different combinations of the numbers of predictor and predictand PCs. Results are only shown for the number of canonical modes (indicated in parenthesis) that yields the lowest rmse. The omitted values were not calculated.

No. of predictor PCs	No. of predictand PCs			
	4	7	9	15
3	4.12 (3)	4.06 (2)	4.04 (3)	—
5	3.98 (4)	3.96 (4)	3.92 (3)	—
7	3.89 (4)	3.85 (4)	3.78 (4)	—
9	3.70 (3)	3.64 (3)	3.62 (3)	—
11	3.65 (4)	3.62 (4)	3.63 (5)	—
15	—	—	—	3.55 (5)


Tabulka 6: Průměrná střední kvadratická chyba s různým počtem hlavních složek prediktorů a prediktandů

Zdroj: Huth (2002)

Dibike a Coulibaly (2005) srovnávali statistický downscalingový model (SDMS) a stochastické generátory počasí pro oblast v severním Quebecu a došli k závěru, že pro simulování srážek jsou obě metody vhodné, ovšem metoda generátorů počasí lépe napodobila vlhké a suché období, SDMS zkracoval období se srážkami. Podobných výsledků dosáhl i Khan a kol. (2006), kteří srovnávali SDMS, generátory počasí a umělé neuronové sítě, ale SDMS se jevil jako nejlepší model.

Z pohledu prediktandů je důležité zmínit, že na rozdíl od násobné regrese, metoda CCA bere prediktandy jako pole, nikoliv jako jednotlivé nezávislé stanice, z tohoto důvodu může být chování závislé na velikosti oblasti. Hlavní zjištění Hutha (2002) spočívá v tom, že první hlavní složka při zkoumání malé oblasti dokáže objasnit až 97 % celkového rozdílu na rozdíl od větší oblasti, kdy se jedná přibližně jen o 3/4.

Hlavním cílem práce Hutha (2002) bylo ukázat, že downscalingová metoda by měla být vybrána podle toho, jakých výsledků chceme dosáhnout. Je uveden příklad, že pokud budeme chtít hodnotit dopady klimatických změn, měla by být vhodná regrese v uzlových bodech, naopak pokud cílem bude regionalizace, vhodná metoda je kanonická korelační analýza, ale použít se může i regrese v uzlových bodech. Na Obr. 5 je ukázáno, že lineární metody v pěti případech překonávají neuronové sítě. Výsledky Hutha a kol. (2008) se dají potencionálně vysvětlit tím, že vztahy mezi prediktory a denními teplotami jsou blízko lineárním.




Obrázek 5: Korelační koeficient ($\times 100$) mezi pozorovanými a downscalovanými hodnotami pro modely neuronových sítí a jejich lineární protějšky: maximální teplota (nahore) a minimální teplota (dole). Každý soubor sloupců odpovídá jedné stanici: levé (pravé) páry sloupců uvnitř každého souboru ukazují model 20 hlavních složek (regrese v uzlových bodech); šedé sloupce odpovídají modelu lineární regrese (neuronových sítí)


Zdroj: Huth a kol. (2008)

Rozsah a prostorové rozdělení časové autokorelace se zpožděním jeden den jsou nejlépe vypočteny lineární regrese v uzlových bodech, všechny ostatní nadhodnocují trvání, problém by pak mohl nastat v letních měsících (Huth, 2002). Napodobení prostorové struktury povrchových teplot v práci Hutha (2002) bylo vytvořeno korelačními mapami, ale i rozdělením oblastí do menších regionů. V obou případech se ukázala jako nejlepší metoda kanonická korelační analýza, i když všechny downscalingové metody nadhodnocovaly prostorové korelace.

Na Obr. 6 jsou ukázány výsledky Hutha a kol. (2008) pro lineární regresi, které jen potvrzují dvě nejvíce pozoruhodná fakta z práce Huth (1999, 2002). První fakt je ten, že simulace pomocí regrese z hodnot v uzlových bodech (černý sloupec) lépe odpovídají pozorovaným hodnotám než regrese hlavních složek (šedé sloupce). Druhým potvrzujícím faktem je, že se stoupajícím počtem hlavních složek se zvyšuje i přesnost downscalingu.



Obrázek 6: Korelační koeficient ($\times 100$) mezi pozorovanými a downscalovanými hodnotami pro lineární modely: maximální teploty (nahore) a minimální teploty (dole). Každý soubor sloupců odpovídá jedné stanici; uvnitř souboru šedé sloupce ukazují regresi hlavních složek pro (z leva do prava) 4, 6, 12, 16, 20 a černý sloupec odpovídá regresi v uzlových bodech.



Zdroj: Huth a kol. (2008)

2.3. Porovnání statistického a dynamického downscalingu

Často dochází ke srovnávání metod statistického a dynamického downscalingu. Kidson a Thompson (1998) porovnali výkonnost regionálních atmosférických modelujících systémů (RAMS), regionálních klimatických modelů (RCM) a metody založené na regresní analýze pro oblast Nového Zélandu. Jako prediktandy použili teplotu a srážky a upozornili na to, že je nepatrný rozdíl pro denní a měsíční časové řady. RAMS dobře simulovaly konvekční srážky, ovšem celkově při simulaci množství srážek byly lepší statistické modely. K podobným závěrům, jen pro Evropu, dospěl i Murphy (1999). Hellström a kol. (2001) srovnával výstupy z dynamického downscalingu s regresními modely založenými na cirkulaci velkého měřítko, která zahrnovala i stupeň vlhkosti. Wilby a kol. (2000) srovnávali také tyto dvě základní metody downscalingu pro horské oblasti v Coloradu, používali regresní metody ke zjištění teplot a výskytu i množství srážek. Zjistili, že statistické metody dokáží simulovat maximální a minimální teploty lépe než srážky. Podobné výsledky pak byly dosaženy i pro další tři horské oblasti ve Washingtonu, Coloradu a Nevadě (Hay a Clark, 2003).

Fowler a kol. (2007) srovnávali dynamický a statistický downscaling, jejich výhody a nevýhody (Tab. 1). Dynamický downscaling používá hraniční podmínky z GCMs,

nejčastěji je rozlišení 0,5° zeměpisné šířky i délky. Dokáže skutečně simulovat orografické srážky (Frei a kol. 2003), extrémní klimatické události (Fowler a kol. 2005) a anomálie klimatu regionálního měřítka nebo nelineární vlivy jako je El Niño (Leung a kol. 2003). Dynamický downscaling je lépe využitelný v oblastech, kde má na teplotu a srážky vliv topografie (Nový Zéland) než v rovinných regionech jako jsou například Velké Pláně v USA (Wang a kol. 2004). Podle Schmidle a kol. (2007) může dynamický downscaling poskytnout lepší simulace srážkových procesů v mezoměřítku. Fowler a kol. (2007) uvádí, že při modelování současného klimatu jsou metody dynamického downscalingu o něco málo výhodnější než metody statistického.


Kidson a Thompson (1998) se zabývali také srovnáním regresních metod s regionálním modelem pro downscaling maximálních a minimálních denních teplot, dále měsíčních teplot a i celkového úhrnu srážek na Novém Zélandu. I přesto, že v této oblasti je poměrně extrémní reliéf, jejich výsledky byly podobné výsledkům Schoof a Pryor (2001) - korelační koeficienty pro denní maxima 0,5 až 0,7, pro denní minima 0,3 až 0,6 a měsíční teploty a srážky 0,1 až 0,5.

Fowler a kol. (2007) ve své práci podávají přehled downscalingových metod, a to jak statistických, tak dynamických nebo statisticko - dynamických. Je zde zmíněn i projekt Statistický a regionální dynamický downscaling extrémů pro evropské regiony (STARDEX), jehož hlavním cílem je právě srovnání těchto metod se zaměřením na downscaling extrémů. Srovnání statistických metod je vcelku běžné, nejčastěji downscaling zkoumá teplotu nebo srážky. Benestad (2001) ve své práci porovnával metody pro downscaling měsíčních průměrných teplot, použil empirickou ortogonální funkci (EOF) a kanonickou korelační analýzu, a zjistil, že EOF lépe simuluje globální klimatické scénáře.

Haylock a kol. (2006) zkoumali přívalové srážky na severozápadě a jihovýchodě Anglie, porovnali šest statistických a dvě dynamické downscalingové metody. Ukázalo se, že v zimě je schopnost downscalovat podstatně vyšší než v létě. Metody umělých neuronových sítí nejlépe simulují meziroční proměnlivost, ale velmi špatně napodobují extrémní události. Modelování srážek ve Švédsku se zabýval Hellström a Chen (2003), kteří použili statistický downscaling a prostřední krok dynamického.

2.4. Klimatický region a sezonalita

Při downscalingu nemá vliv jen výběr prediktorů a prediktandů, ale také je důležité, v jakém klimatu se mají simulovat dané podmínky, tím se zabýval Fowler a kol. (2007). Na Obr. 7 je ukázáno, že nejvíce studií se zabývá středními zeměpisnými šířkami, a to hlavně Severní Amerikou a Evropou. Tab.7 ukazuje přehled vybraných oblastí, pro které daní autoři provedli downscaling. Právě Huth (1999) říká, že správnost downscalingových metod má geografickou a sezónní složku. Takže například v tropech se použijí jiné metody než ve středních zeměpisných šířkách, důležitá je ale i sezónnost. Matulla (2005) uvádí, že v některých případech je potřeba provést statistický downscaling odděleně pro každou sezónu, především kvůli silnému propojení mezi cirkulací velkého měřítka a lokálním klimatem středního měřítka. Dalším příkladem může být práce Huth (1999), kde se autor zabývá denními průměrnými teplotami na několika stanicích ve střední Evropě a dochází ke zjištění, že je zde závislost na nadmořské výšce. Čím výše je stanice položena, tím lépe dochází k simulaci statistickým downscalingem, druhým zjištěním bylo to, že kontinentální stanice jsou simulované o něco lépe než přímořské. Protikladem je ale práce Kleinna a kol. (2005), kteří použili dynamický downscaling pro simulování teplot a srážek, kde naopak dochází ke zhoršení simulací s rostoucí nadmořskou výškou.



Zdroj: Wilby a Dawson (2013)

Obrázek 7: Počet downscalingových studií podle regionu od roku 1993 do roku 2011. Pacifické ostrovy zahrnují Hawaii, Filipíny a Japonsko

Sezónními a geografickými rozdíly při downscalingu se zabývali Cavazos a Hewitson (2005), kteří použili metodu umělých neuronových sítí a pak analýzu hlavních složek při modelování srážek. Nejlepší simulace vyšly pro střední zeměpisné šířky při chladném a suchém období, naopak největší chyby nastaly při vlhkém období. Nejhorší podmínky jsou pak v tropech, jedním z důvodů mohou být konvekční procesy, které je

těžké předpovědět, nebo i horší kvalita dat pro reanalýzy (Fowler a kol., 2007). Goodess a kol. (2007) v rámci projektu STARDEX napsali studii, která se považuje za nejcelistvější. Porovnává se zde 22 statistických downscalingových metod pomocí deseti extrémních ukazatelů o různém rozsahu, frekvenci a trvání, a to pro 6 evropských regionů, ale i pro Evropu jako celek. Zjistili, že i přesto, že se liší stanice od stanice, metoda od metody či sezóna od sezóny, tak výkonnost downscalingu je lepší v zimním období než v letním, a lepší výsledky jsou dosaženy spíše pro vlhčí oblasti než sušší.

V Číně pak hodnotil srážky Wetterhall a kol. (2006) pomocí 4 statistických metod a dospěl k podobným závěrům jako Goodess a kol. (2007). Pokud se k prediktorům přidá i vlhkost, zlepší se meziroční variabilita. Jako problém se pak jeví oblast Svalbard v Arktidě, kterou zkoumali Benestad a kol. (2002).

Jelikož byla vhodně zvolená oblast a byly vybrány reprezentativní stanice, mohou výsledky práce Huth (2002) posloužit i pro jiné oblasti na jiných kontinentech ve středních zeměpisných šířkách.

Table II. Examples of recent statistical downscaling studies. This list is not intended to be exhaustive but illustrative of the geographical distribution of downscaling studies and the methods employed. Abbreviations used in this table are: REG – linear regression methods, ANN – artificial neural networks, CCA – canonical correlation analysis, OTH – other, SCA – scaling methods, SVD – singular value decomposition, WG – weather generators, WT – weather typing. For predictands, T – temperature, P – precipitation, PE – potential evapotranspiration, H – humidity variables.

Authors	Statistical Downscaling Technique	Location	Predictand	Authors	Statistical Downscaling Technique	Location	Predictand
Europe							
Kysely (2002)	REG	Central Europe	T				
Abaurrea and Asin (2005)	REG	Ebro valley, Spain	P	Matulla (2005)	CCA	Austria	T, P
Bárdossy <i>et al.</i> (2002)	WT	Germany, Greece	T, P	Murphy (2000)	REG	Europe	T, P
Beckmann and Buishand (2002)	REG	Netherlands and Germany	P	Tatli <i>et al.</i> (2004)	REG	Turkey	P
Bergant and Kajfez-Bogataj (2005)	REG	Slovenia	T, P	Widmann and Schär (1997)	WT	Switzerland	P
Cawley <i>et al.</i> (2003)	ANN	North-west UK	P	North America			
Diaz-Nieto and Wilby (2005)	WG	Thames Valley	P	Qian <i>et al.</i> (2005)	WG	Canada	T, P
Enke <i>et al.</i> (2005a,b)	WT	Germany	T, P	Schoof and Pryor (2001)	ANN, REG	Indianapolis, USA	T, P
Goodess and Jones (2002)	WT	Iberian Peninsula	P	Salathé (2003)	SCA, OTH	Washington and Oregon, UK	P
Goodess and Palutikof (1998)	Automated LWT – Markov process	Guadalentin Basin, SE Spain	P	Wood <i>et al.</i> (2004)	OTH	Pacific North West USA	T, P
Hellström <i>et al.</i> (2001); Hellström and Chen (2003)	REG	Sweden	P	Widmann <i>et al.</i> (2003)	SCA, SVD	NW USA	P
Huth (1999, 2002)	CCA, SVD, REG	Central Europe	T	Australasia			
Huth <i>et al.</i> (2003)	REG, WG	Central Europe	T	Kidson and Thompson (1998)	REG	New Zealand	T, P
Huth (2005)	REG	Czech Republic	H	Africa			
Jasper <i>et al.</i> (2004)	REG	Switzerland	T, P	Penlap <i>et al.</i> (2004)	CCA	Cameroon	P
Kettle and Thompson (2004)	REG	Europe (high elevation)	T				

Zdroj: Fowler a kol. (2007)

Tabulka 7: Příklady současných studií zabývajících se statistickým downscalingem se zájmovými oblastmi

Kettle a Thompson (2004) si na začátku své práce položili několik otázek, na které chtěli v závěru odpovědět. Nejdříve je zajímalo, jestli se liší přesnost downscalovaných minimálních, maximálních a průměrných teplot vzduchu, přičemž zjistili, že nejpřesnější je downscalovaná průměrná denní teplota, s nejmenší přesností pak minimální teplota. Dále chtěli vědět, jestli je nějaká sezóna lepší pro simulace. V tomto ohledu zjistili, že s největší přesností dochází k simulacím v zimě, kdy je zároveň vyšší i přirozená proměnlivost, proto

se může objevit více absolutních chyb než v létě. Také zjistili, že prostorové korelace jsou nadhodnocovány. Jako nejdůležitější prediktory pak označili teplotu 850 hPa pro reanalýzy v uzlových bodech. Hlavní složky SLP a T850 jsou pak častěji používané v modelech pro zimu než pro léto, jelikož obecně se dá říci, že letní modely potřebují jen polovinu prediktorů než zimní. Kettle a Thompson (2004) provedli simulace pro různá období, při simulaci období 1980 až 1990, zjistili, že toto období je trochu zkreslené v zimě (0,09 °C), letní teploty jsou pak slabě nadhodnoceny (0,22 °C). Pro dlouhodobé simulace zjistili, že obecně jsou hodnoty podhodnocovány, což je výrazně vidět pro období 1958 až 2001 nebo 1970 až 2001. Především Kettle a Thompson (2004) tvrdí, že jejich simulace ukazuje rychlejší nárůst maximálních teplot než minimálních, což má pak za následek zvýšení denní amplitudy v letech 1958 až 2001, ale Weber a kol. (1994, 1997) uvádí, že maximální i minimální teploty se zvyšují přibližně stejným tempem v horských oblastech Evropy s nevýznamnou změnou denních amplitud.

Kettle a Thompson (2004) došli k závěru, že na podzim není v žádném regionu nijak významný trend. Naopak v zimě nastává většina významných trendů, výraznější jsou u maximálních teplot než u minimálních, výjimkou je jen Skandinávie. Toto tvrzení je ale v naprostém rozporu s prací Weber a kol. (1994), který uvádí, že největší oteplení je v centrálních Alpách na podzim. V horských oblastech západní Evropy dochází ke zvyšování maximálních i minimálních teplot, a to v létě i v zimě.

Obecně se dá říci, že lepší výsledky jsou dosaženy tam, kde je volná atmosféra nejbližší zemskému povrchu, proto se downscalované hodnoty nejlépe shodují s pozorovanými na horských stanicích. Ve většině případů jsou lépe simulovány maximální teploty, protože minima jsou zejména v zimě často ovlivněna místními podmínkami a zvláštnostmi počasí jako je třeba inverze. Mikšovský a Raidl (2005) upozornili, že vztah mezi prediktory a predikandy nemusí být vždy lineární, ale může být i nelineární. Rozdíl je právě především mezi ročními obdobími. V létě je vztah spíše lineární, zatímco v zimě převažují nelinearity.

V práci Hutha (2002) se řeší i velikost oblasti, a to jak z pohledu prediktorů, tak prediktandů. V Tab. 8 můžeme vidět, že se porovnávala menší a větší oblast pro tři metody, například při regresi v uzlových bodech jsou rozdíly nepatrné. Ovšem bylo pozorováno, že v menších oblastech jsou lepší výsledky dosaženy ve vyšších nadmořských výškách, zatímco oblasti nížin jsou lépe napodobené ve větších oblastech.

TABLE 5. Comparison of rmse (in °C) between large and small predictor domains for pointwise regression, full regression, and CCA, all for HGT and TEM as predictors. For CCA, the number of predictor/predictand PCs is shown.

	Pointwise regression		Full regression		CCA	
	Large	Small	Large	Small	Large	Small
No. of PCs	—	—	11	5	11/9	5/9
No. of modes	—	—	—	—	5	4
Rmse (°C)	2.88	2.89	3.52	3.34	3.63	3.46

Zdroj: Huth (2002)

Tabulka 8: porovnání střední kvadratické chyby mezi velkými a menšími oblastmi.

Studie Kettle a Thompson (2004) potvrdila to, že globální oteplování se více projevuje na minimálních teplotách než na maximálních, což vede k poklesu denních amplitud teplot (Karl a kol., 1993, Easterling a kol., 1997). Ovšem poukazují i na rozdíl v horských oblastech, kde je trend opačný, denní maximální teploty rostou rychleji než minimální, což může být způsobeno tím, že nížiny jsou často pokryty oblačností, zatímco horské oblasti vyčnívají nad ní.

Jelikož jsou korelace mezi teplotami vzduchu na několika horských stanicích v daném regionu vyšší než korelace mezi teplotami na několika níže položených stanicích ve stejném regionu (Weber a kol., 1997), vyplývá z toho, že horské stanice jsou méně ovlivněny místními vlivy. Ovšem důležitá je nejen nadmořská výška, ale vliv zde hraje i expozice svahu, sklon, pokrytí sněhem, atd. Kettle a Thompson (2004) tvrdí, že v každém lineárním modelu, který je použit pro downscaling, by měla být individuálně začleněna i topografie a land use každé stanice.

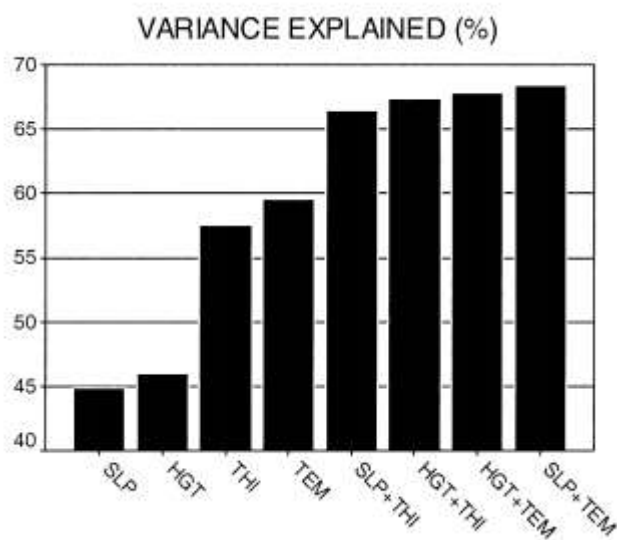
Výpočty v práci Kidson a Thompson (1998) ukázaly, že u maximálních teplot byl rozptyl nejvíce snížen na jihu východního pobřeží a to na obou ostrovech Nového Zélandu, nejspíše v důsledku závětrí hor, kde jsou teploty nejvíce nestálé. U minimálních teplot je snížení rozptylu relativně jednotné napříč celým územím, pohybují se v rozsahu od 40 do 55 %, výjimkou je ale jihovýchod Jižního ostrova, kde se počasí mění nejvíce a prediktor 1000 - 500 hPa vysvětluje méně než 20 %. Kettle a Thompson (2004) po provedení analýzy hlavních složek ukázali, že prvních 14 hlavních složek v T850 vysvětluje 81 % rozptylu v létě a prvních 9 SLP vysvětluje 78 % rozptylu. Pro zimní období je to pro T850 13 hlavních složek vysvětlujících 89 % rozptylu a prvních 10 SLP 88 % rozptylu.

2.5. Validace

Jak bylo řečeno výše, downscaling se nejprve provede na historických nebo současných datech, na kterých se poté ověří přesnost dané metody, tedy schopnost simulovat, co nejpřesněji dané klimatické prvky. Pro ověření se nejčastěji využívá křížová validace.

Křížová validace se používá hlavně proto, že je zde snaha o to, aby se zapojilo co nejvíce dat do budování modelu. Proces křížové validace je založený na vynechání jedné hodnoty v pořadí a model je sestaven ze zbývajících dat, model pak mohu ověřit na té jedné vynechané hodnotě. Ovšem v datech může dojít k autokorelaci, což by způsobilo problém, proto se postupuje jinak. Místo jedné hodnoty mohu vynechat například 4 po sobě jdoucí data, model vytvořím pomocí zbývajících dat a ověřím si na vynechaných 4.

Pro ověření byla použita křížová validace ve studii Huth a kol. (2008). Statistický model byl v tomto případě postaven na 34 sezónách a na poslední 35. byl ověřen. I Huth (2002) použil pro ověření křížovou validaci. Porovnával i výběr prediktorů, v jednom případě si zvolil jako prediktory teploty v 850 hPa a tloušťku 1000-500 hPa, v druhém případě použil cirkulaci - tlak přepočtený na hladinu moře a výšku 500 hPa. V posledním případě si zvolil jeden teplotní prediktor a druhý cirkulační. Na Obr. 8 je ukázán podíl objasněného rozdílu, nejlepší kombinace prediktorů je podle Hutha (2002) tlak přepočtený na hladinu moře a teplota v 850 hPa, což bylo potvrzeno i v dalších studiích.



Obrázek 8: Procento vysvětleného rozdílu, zprůměrované pro 39 stanic, pro různé prediktory a jejich kombinace, vždy pro regresi v uzlových bodech.

Zdroj: Huth (2002)

Kettle a Thompson (2004) pro ověření použili křížovou validaci, přesnost downscalingu se ukázala být větší v létě než v zimě.

2.6 Downscaling extrémních událostí

Simulace klimatu jsou velmi důležité pro další vývoj společnosti, ovšem často je opomíjena otázka extrémních událostí. Samozřejmě zvýšení průměrné teploty nebo pokles úhrnu srážek by způsobily velké problémy ve všech odvětvích, ovšem pokud v létě nastane dvojnásobek horkých vln, bude to mít dopad i na životy lidí. Proto je důležité se zabývat i simulacemi těchto událostí, ty jsou ovšem podstatně hůře vypočitatelné než průměrné denní či měsíční hodnoty. Fowler a kol. (2007b) uvádí, že obecně se dá říci, že metody dokáží podstatně lépe napodobit průměrné hodnoty než extrémy, a to jak u teplot, tak i u srážek. Například Abbaurrea a Asín (2005) zjistili, že sezónní charakteristiky a i denní úhrny srážek byly simulované lépe než extrémní události, když se zabývali srážkami v oblasti řeky Ebro ve Španělsku.

Na zvyšující počet extrémních událostí, ať už se jedná o přivalové srážky či horké vlny upozorňují hodnotící zprávy IPCC. Už Nicholls a kol. (1996) poukázali na to, že je potřeba se zabývat i krátkodobými extrémy, a ne jen dlouhodobými změnami klimatu. Důkazy jasně hovoří o tom, že zvyšování průměrné teploty Země může způsobit jak vyšší průměrné úhrny srážek, tak i větší intenzitu přivalových srážek (Frei a kol., 1998).

Velký počet studií si také pokládá otázku, co je extrémní událost, například Fowler a kol. (2005) nebo i Ekström a kol. (2005) definovali vzácnou extrémní událost tím, že se objeví přibližně jednou za 50 let. Ovšem obecně extrémních událostí je velké množství, může se jednat o jevy spojené s teplotou, srážkami nebo i tlakem či větrem, a schopnost downscalingu toto vše simulovat je velmi rozdílná. Fowler a kol. (2005) uvádí, že pokud nastane nějaký extrémní jev v jednom povodí, nemusí potom mít stejný rozsah v jiném. Downscalingem extrémů se také zabývá práce Bürgera a kol. (2012), kde je porovnáno 5 statistických metod pro modelování extrémních událostí. Zabývali se zde nejen extrémními teplotami, ale i srážkami. Nejprve si ale museli stanovit, co považují za extrémní událost. Využili zde Climate Indices of Extremes (ClimDEX), které jsou zobrazeny v Tab. 9. Tyto definice extrémních událostí byly dále přebrány i Programem světového klimatického výzkumu (World Climate Research Programme), dále je použil i pro své hodnotící zprávy Mezinárodního panel pro klimatickou změnu (IPCC).

TABLE 1. ClimDEX indices.

ID	Indicator name	Definitions	Units
CDD	Consecutive dry days	Maximum number of consecutive days with RR < 1 mm	days
CSDI	Cold spell duration	Days with at least six consecutive days when TN < 10th percentile	days
CWD	Consecutive wet days	Maximum number of consecutive days with RR ≥ 1 mm	days
DTR	Diurnal T range	Monthly mean difference between TX and TN	°C
FD0	Frost days	Annual count when TN (daily minimum) < 0°C	days
GSL	Growing season length	Days between first and last span of at least six warm enough days	days
ID0	Ice days	Annual count when TX (daily maximum) < 0°C	days
PRCPTOT	Annual total wet-day precipitation	Annual total PRCP in wet days (RR ≥ 1 mm)	mm
R10	Number of heavy precipitation days	Annual count of days when PRCP ≥ 10 mm	days
R20	Number of very heavy precipitation days	Annual count of days when PRCP ≥ 20 mm	days
R95p	Very wet days	Annual total PRCP when RR > 95th percentile	mm
R99p	Extremely wet days	Annual total PRCP when RR > 99th percentile	mm
R25	Number of days above 25 mm	Days when PRCP > 25 mm	Days
RX1day	Max 1-day precipitation	Monthly maximum 1-day precipitation	mm
Rx5day	Max 5-day precipitation amount	Monthly maximum consecutive 5-day precipitation	mm
SDII	Simple daily intensity index	Annual total precipitation divided by the number of wet days (PRCP ≥ 1 mm)	mm day ⁻¹
SU25	Summer days	Annual count when TX (daily maximum) > 25°C	days
TN10p	Cool nights	Percentage of days when TN < 10th percentile	%
TN90p	Warm nights	Percentage of days when TN > 90th percentile	%
TNn	Min TN	Monthly minimum value of daily minimum temp	°C
TNx	Max TN	Monthly maximum value of daily minimum temp	°C
TR	Tropical nights	Annual count when TN (daily minimum) > 20°C	days
TX10p	Cool days	Percentage of days when TX < 10th percentile	%
TX90p	Warm days	Percentage of days when TX > 90th percentile	%
TXn	Min TX	Monthly minimum value of daily maximum temp	°C
TXx	Max TX	Monthly maximum value of daily maximum temp	°C
WSDI	Warm spell duration	Days with at least six consecutive days when TX > 90th percentile	days

Zdroj: Bürger a kol. (2012)

Tabulka 9: Definované extrémy ClimDEX, které byly použity v práci Bürger a kol. (2012)

Schopnost simulovat momenty vyššího řádu (šikmost a špičatost) se liší i mezi jednotlivými globálními klimatickými modely, například simulace momentů vyššího řádu pro teploty ve Střední Evropě dobře dokázal ECHAM4 - odpovídala šikmost i špičatost, naopak CCCM2 v tomto případě zklamal (Huth a kol. 2003). I Kyselý (2002) uvádí, že globální klimatické modely simulují extrémně nízké nebo vysoké teploty s určitým omezením. Také je rozdíl, zda se snažíme modelovat extrémně vysoké teploty v létě, kdy se částečně osvědčil ECHAM4 pro oblast Evropy, nebo extrémně nízké teploty v zimě, kdy to byl pro CCCM2 problém, nejspíše kvůli nízké půdní vlhkosti (Fowler a kol., 2007).

Extrémní události se zkoušejí simulovat pomocí dynamického, ale i statistického downscalingu (Fowler a kol., 2007). Simulace extrémů dynamickým downscalingem jsou hodnoceny hned v několika studiích, například při simulaci srážek, které se vyskytnou jednou za 50 let na území Velké Británie Fowler a kol. (2005) použili HadRM3H-regionální klimatický model. Největším problémem bylo to, že model nedokázal napodobit srážky, které byly spojené s orografickými procesy, tudíž nebyl zachycen srážkový stín na

východě severního Skotska. Mnoho nejistot ohledně budoucích změn je zakotveno už ve výběru klimatického modelu nebo scénáře, což uvádí Déqué a kol. (2007). Fowler a kol. (2007) toto tvrzení dále rozvinuli a tvrdí, že by se lépe porozumělo možným budoucím klimatickým změnám, pokud by se odvodily na základě srovnání několika klimatických modelů, ovšem za jiných vstupních podmínek- emisních scénářů.

Frei a kol. (2003) simulovali extrémní srážky pro oblast Alp v Evropě, a to za pomoci šesti regionálních klimatických modelů, přičemž okrajové podmínky pocházely z HadAM3H. Modely ukázaly určitou schopnost simulovat 5 ti leté extrémní události. Ukázaly se ale i chyby, které byly spojené více s intenzitou srážek než s jejich výskytem.

Extrémní události se simulují i statistickým downscalingem. Goodess a kol. (2007) porovnali 22 metod pro šest evropských regionů a i pro celou Evropu. Schopnost downscalingu se ale liší podle sezóny, stanice i prediktorů. Více jsou využívány klasické metody jako lineární regrese nebo korelační analýzy spíše než umělé neuronové sítě (Harpham a Wilby, 2005), ale Haylock a kol. (2006) vytvořili novější přístup na základě neuronových sítí a zjistili, že při simulacích extrémních srážek dochází ke zpřesnění oproti klasické metodě neuronových sítí. Obecně se liší metoda od metody, či sezóna od sezóny, ovšem lepší simulace srážek jsou v zimě než v létě. Fowler a kol. (2007) dále uvádí, že lépe je napodobena frekvence těchto událostí než jejich rozsah. Nejlépe jsou simulovány extrémní události, když se jako prediktor využije cirkulace velkého měřítko, rozsah těchto událostí je ale více závislý na menších lokálních procesech.

Mezi další metody statistického downscalingu při simulacích extrémních událostí patří i genetické programování, které použil Coulibaly (2004) pro modelování místních extrémních teplot, a to jak minimálních, tak maximálních, v severní Kanadě. V této práci Coulibaly (2004) zjistil, že tato metoda předčila SDSM pro simulaci minimálních teplot, ovšem pro maximální teploty měly modely podobné výsledky.

Šikmost letních maximálních a zimních minimálních teplot pro stejné regiony byla dobře simulována stochastickými generátory počasí (Huth a kol. 2003). Ovšem downscaling počítaný regresními metodami pro zimní minima napodobil šikmost, ale ne rozsah. Letní maxima pak dosáhla nereálné negativní šikmosti. Kyselý (2002) uvádí, že downscalingové metody napodobují extrémy, které jsou ale příliš mírné oproti těm pozorovaným, což může být spojené s předpokladem linearity ve většině downscalingových metod. Ukázal se také rozdíl mezi krokovou regresí, které měla výstupní data ze dvou různých globálních klimatických modelů - ECHAM4 a CCCM2 pro Evropu, což naznačuje, že je zde i závislost na globálním klimatickém modelu. ECHAM4

dosáhl lepších downscalovaných výsledků, ovšem CCCM ukázal lepší zastoupení extrémních událostí. Studené vlny jsou více ovlivněny radiační bilancí a lokálními podmínkami než cirkulací velkého měřítka, a proto jsou simulovány hůře než maximální teploty (Fowler a kol., 2007). Na základě předchozích studií Fowler a kol. (2007) došli k závěru, že metody dynamického downscalingu simulují o trochu lépe extrémní události než metody statistického downscalingu. Což je v rozporu s tvrzením Hutha a kol. (2008), kteří uvádí, že nejlepší pro simulace denních extrémních hodnot jsou lineární metody, ovšem upozorňují na to, že v práci nebyly zdaleka řešeny všechny existující metody.

Bürger a kol. (2012) se zaměřili na oblast Britské Kolumbie a vybrali si stanice, které leží v odlišném klimatu. Zvolili si stanici na pobřeží, v horách a pak také na severu, kde převládá subarktické klima. Použili 5 statistických metod, patří sem automatizovaná regrese statistického downscalingu - ASD (vycházející z práce Wilby a kol., 2002), prostorové disagregace - BCSD (použita například Salathe a kol., 2007), kvantilová regrese neuronových sítí- QRNN (Cannon, 2011), TreeGen - TG (Stahl a kol., 2008) a nakonec rozšířený downscaling - XDS (Bürger, 1996). Pro každou metodu byly vybrány prediktory odlišně, v práci Bürger a kol. (2012) jsou metody popsány poměrně detailně.

Metoda ASD byla vytvořena jako automatizovaná verze modelu statistického downscalingu (SDSM) Wilby a kol. (1999,2002) pro širší komunitu, je tedy založená na jednoduchých nástrojích downscalingu (Hessami a kol., 2008). Dochází zde ke spojení vzorců cirkulačních polí a atmosférických vlhkostních proměnných s místními prvky počasí (srážky, teplota). Další studie, kde byla použita metoda ASD nebo SDSM je například práce Gachon a Dibike (2007) nebo Khan a kol. (2006).

Druhou metodou je BCSD, která poskytuje vysoké rozlišení v teplotním a srážkovém poli v relativně velké oblasti. Velmi často je využívána hlavně u hydrologických modelů. U downscalingu teplot vychází především z průměrných teplot, ze kterých je dále nepřímo odvozeno minimum a maximum. Tuto metodu už použili například Maurer a kol. (2007) nebo Hayhoe a kol. (2007).

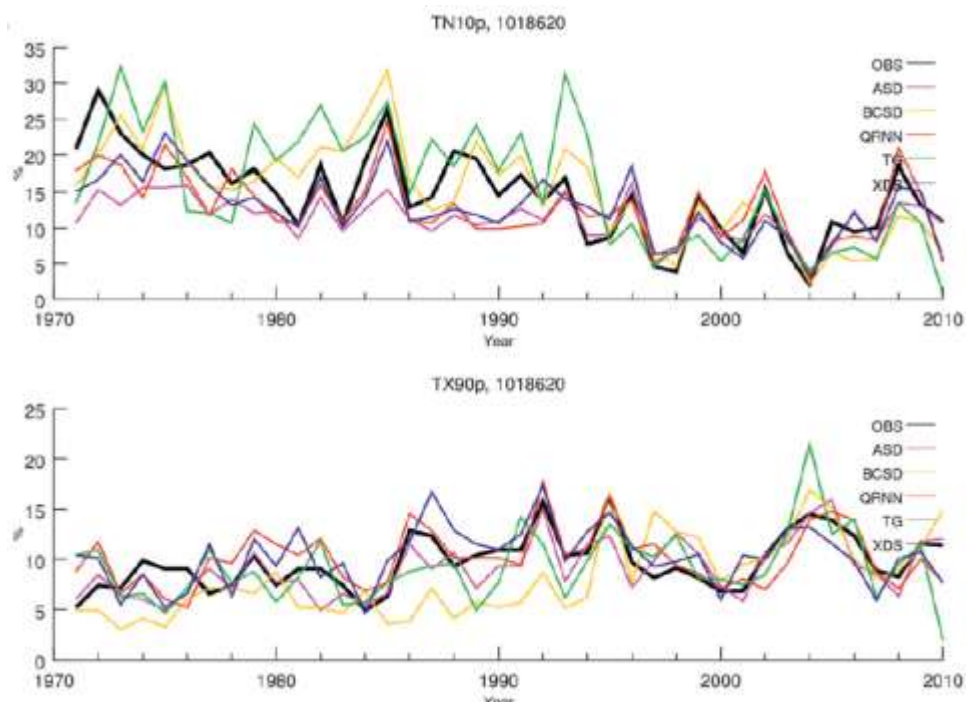
Třetí metoda, kterou použil Bürger a kol. (2012) je QRNN. Tato metoda je založena na odhadu závislých hodnot individuálního kvantilu pomocí vícevrstvého perceptronu neuronové sítě. Dochází zde k tomu, že tvar rozdělení může být změněn podle podmínek budoucího klimatu, tedy pokud se změní prediktory simulované GCMs. Tato metoda je tedy podobná metodě vícevrstvého perceptronu neuronové sítě, kterou použil Haylock a kol. (2006). Upravená verze byla použita jen v práci Cannona (2011).

Čtvrtá metoda, tzv. TreeGen je hybridní technika, která vychází hned z několika přístupů statistického downscalingu (typizace počasí, regresní modely, analogické nevzorkování a stochastické generátory počasí). Prediktory jsou zde vybírány na základě hlavních složek (PCs) z NCEP a i z GCMs. Tato metoda byla použita například v práci Stahl a kol. (2008) nebo Allen a kol. (2010).

Poslední metoda, kterou k downscalingu extrémů použili Bürger a kol. (2012), byla XDS. Vznikla z důvodu simulací lokálních extrémů, které jsou vyvolány skutečnými místními proměnnými. Tato metoda je častěji využívána pro hydrologické simulace (Dehn a kol. 2000, Bronstert 2004) z důvodu, že jsou zde zahrnuty právě reálné proměnné a i korelace mezi stanicemi.

Pro ověření přesnosti byly použity hned tři testy, přičemž první z nich odpovídal současným odchylkám v reanalýzách, druhý napodoboval současné rozdělení indexů z reanalýz a třetí simuloval současné rozdělení, ale z indexů pocházejících z GCMs. Také kvůli rozdílným klimatickým oblastem, byl test proveden vždy pro každou zvlášť, tedy jak pro dvě pobřežní stanice, kde je klima mírnější a v teplotách se sezonalita příliš neprojevuje, naopak u srážek je to opačně. Pak i pro tři horské stanice, kde je výrazný vliv topografie, a to jak na teploty, tak na srážky. Nakonec i pro jednu subarktickou stanici, která je charakteristická dlouhou zimou a nestabilním počasím v létě. Data byla pro období 1979 - 2010. Výsledky jsou v této práci velmi obsáhlé, rozděleny jsou jak podle regionů, tak i podle jednotlivých metod, proto se ve své práci zaměřím jen na některé.

V práci Bürgera a kol. (2012) jsou výsledky popsány detailně pro každou zkoumanou oblast, i podle jednotlivých metod, já se zde zaměřím převážně na simulace extrémních teplot. Na Obr. 9, který je pro pobřežní oblast Victoria, je vidět trend v obou zkoumaných teplotách, který dokázaly zachytit všechny použité metody. Zatímco metody TG a BCSD převážně nadhodnocovaly výsledky, ASD podhodnocovala. Všechny metody poté ukazují výrazné oteplení po roce 2000. U simulací teplot se nejlépe v pobřežní oblasti osvědčila metoda BCSD, zatímco u srážek XDS, v horských oblastech byly teploty simulované relativně přesně většinou metod (Bürger a kol. 2012.). Na Obr. 10 jsou pak ukázané výsledky simulací teplot na stanici se subarktickým klimatem. U minimálních teplot se jako nejcitlivější ukázala metoda BCSD, ovšem anomálie v letech 1996 a 2008 jsou simulované všemi metodami. Také oteplení u minimálních teplot je modelované poměrně přesně po roce 1980 všemi metodami. U maximálních teplot pak nejlépe vyšla metoda XDS a částečně i metoda ADS.



Zdroj: Bürger a kol. (2012)

Obrázek 9: Simulované a pozorované roční hodnoty pro TN10p (procento dnů, kdy byla teplota nižší než 10. percentil)- nahoře a TX90p (procento dnů, kdy byla teplota vyšší než 90. percentil)- dole pro pobřežní region použitými metodami




FIG. 9. The TNn and TXx index for the taiga region (Fort Nelson).

Zdroj: Bürger a kol. (2012)

Obrázek 10: Porovnání pozorovaných a simulovaných minimálních a maximálních teplot 5 metodami

Cílem Bürgerera a kol. (2012) bylo porovnat pět metod statistického downscalingu, které byly již dříve použity, ovšem v některých případech došlo k pozměnění metody, jako například u ADS. Tyto změny pak vedly ke zlepšení výsledků při downscalingu extrémních událostí. Při simulaci teplot se ukázalo, že nezáleží na tom, jaký test bude zvolen a zda jde o maximální nebo minimální teplotu, jelikož hodnoty byly vždy simulovány s přiměřenou přesností (nad 50 %). U srážek takto jasné výsledky nebyly, jelikož se zde projevuje výrazně topografie, záleží tedy na lokaci stanice, přičemž nejhorsích výsledků bylo dosaženo v subarktické oblasti.

3. Downscaling extrémních teplot

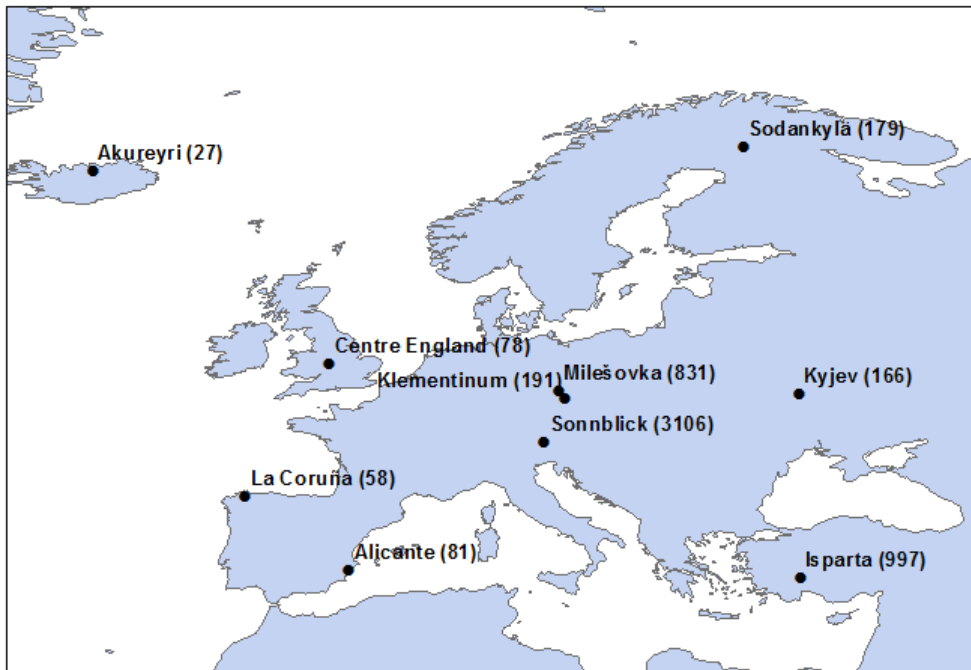
I přesto, že je důležité simulovat denní či měsíční průměrné teploty, pro mnoho odvětví jsou prioritní především extrémy počasí, protože horké či chladné vlny mají dopad téměř na celou společnost, zejména pak na zdraví člověka. Extrémní události mají výrazný vliv i na zemědělství nebo průmysl. Právě práce Schoof a Pryor (2001) se zaměřuje na změnu klimatu a jejího dopadu na zemědělství na Středozápadě USA. Většina prací zabývajících se downscalingem je zaměřena na denní nebo měsíční průměrné hodnoty, a to jak na teploty, tak na srážky. Extrémní hodnoty se špatně simulují a stále se mnoho vědců po celém světě snaží přijít na to, jak je co nejlépe simulovat. Pro společnost je simulování extrémních událostí velmi důležité, a to ať už se jedná o vlny veder (chladu) nebo dlouhá období sucha, která mají výrazný dopad zejména na zemědělství.

Tato práce se zaměřuje na downscaling - simulaci extrémních teplot, které nemusí být jen vysoké, ale i velmi nízké. Zaměřila jsem se na downscaling sezónních extrémů teploty vzduchu - maximální teplota v létě a minimální teplota v zimě. Pro zvolené období (1979 - 2007) jsem dále pracovala se sezónními prediktory (průměrná hodnota za zimu i za léto) velkého měřítka - výšky z hladiny 500 hPa, 1000 hPa a teplota v 850 hPa. Zkoumala jsem oblast Evropy, tedy střední zeměpisné šířky, jelikož tato oblast se v předchozích studiích zabývajících se downscalingem ukázala jako nejvhodnější. Dalším důvodem je i to, že tato oblast je reprezentativní a výsledky, kterých bude zde dosaženo, mohou být použity například i pro oblast USA ve stejných zeměpisných šířkách. Výsledky této práce by tedy měly přinést zjištění, zda je downscaling vhodný i pro simulování extrémních hodnot, popřípadě pro jakou oblast ve středních zeměpisných šířkách se dají extrémní teploty simulovat s největší přesností.

3.1. Prediktandy

V této práci jsem pracovala s deseti stanicemi v Evropě pro období 1979 až 2007. V každém roce jsem zjistila nejvyšší naměřenou hodnotu maximální denní teploty v létě (červen, červenec a srpen) a nejnižší naměřenou hodnotu minimální denní teploty v zimě (prosinec, leden a únor) na každé z 10 stanic (Sodankylä, Sonnblick, Kyjev, Milešovka, Praha - Klementinum, Alicante, Central England, Akureyri, Isparta a La Coruña). Stanice byly vybrány tak, aby tato práce postihla většinu klimatických poměrů, které se v Evropě vyskytují. Jsou zde tedy zastoupeny jak horské stanice, tak i stanice v nižších polohách, oceánské i vnitrozemské, z jižní Evropy i ze severní. Na Obr. 11 jsou zobrazeny stanice v mapě i s jejich nadmořskou výškou.

Data jsem získala z databáze ECA&D, kde jsem měla na výběr dva druhy dat, a to buď „blended“, nebo „non-blended“, přičemž v mé práci jsou použita „non-blended“ data. Důvod byl ten, že „blended“ data jsou „slepená“ z více časových řad z různých zdrojů, tedy jedno pozorování může být mezi lety 1850 až 1970, druhé pak od roku 1940 až do současnosti, následně vznikne časová řada 1850 až současnost, ovšem měření mohla probíhat rozdílně. „Non-blended“ data pak pocházejí pouze z jedné časové řady (Klein Tank a kol., 2002), tam ale nastával problém v tom, že u některých stanic nebylo pokryté celé mnou sledované období a musela být vybrána jiná stanice. Jen na stanici Praha - Klementinum nebyla řada úplná, pro poslední tři roky (2005, 2006 a 2007) tak byla použita data z Českého Hydrometeorologického ústavu. Hodnoty teplot pro Central England jsou počítány jako průměr z několika stanic ve vnitrozemí, nejedná se tudíž o data ze stanice jako v ostatních případech.



Obrázek 11: Mapa stanic, pro které byly simulované extrémní teploty pomocí statistického downscalingu, v závorce je uvedena jejich nadmořská výška v metrech

3.2. Prediktory

Jako prediktory, tedy proměnné ve volné atmosféře byly zvoleny průměrné hodnoty za každou sezónu (léto a zima) - teplota 850 hPa, a geopotenciální výšky hladin 500 a 1000 hPa, a to na základě předchozích studií, kdy se tyto proměnné jeví jako nejvíce vhodné pro statistický downscaling (Huth a kol., 2008). Data jsem získala z reanalýzy ERA-40, přičemž teploty byly ve stupních Kelvina, i když to nebylo nutné pro mé výpočty, byly přepočteny na stupně Celsia. Původní síť byla 2° x 2° zasahující od 50° z. d. až k 50° v. d. a od 30° do 80° s. š., což pokrývá téměř celou Evropu a i přilehlý Atlantský oceán. Následně byl krok sítě upraven na 10° x 10°, protože tato práce nevyžadovala, tak hustou síť.

3.3. Metody

Z velkého množství metod statistického downscalingu, jsem si pro výpočet zvolila metodu lineární regrese, především kvůli poměru přesnosti simulací a nízké výpočetní náročnosti. Pro každou stanicí jsem pomocí programu Statistica zjistila, jaké prediktory do rovnice vstupují a s jakými koeficienty. Použila jsem záložku Analyze, kde jsem zvolila možnost Regression a následně vybrala Linear. Jako závislou jsem vložila denní maximální teploty na jedné stanici, jako nezávislé pak byly vybrány všechny prediktory

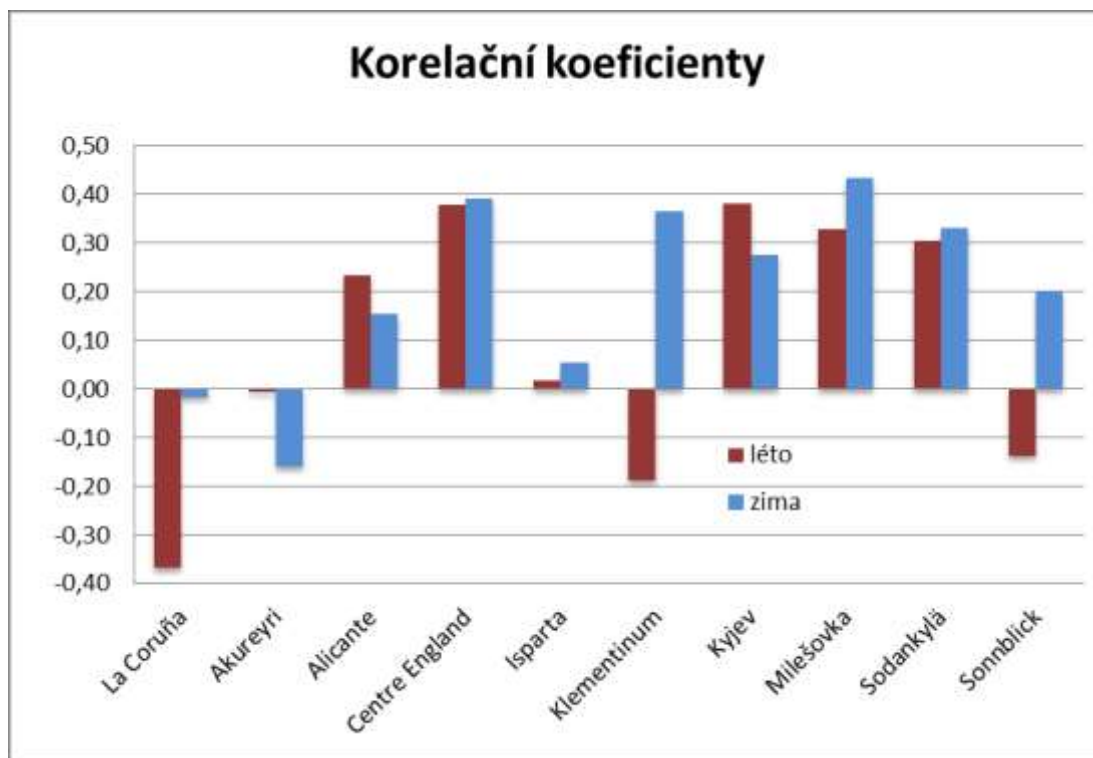
(Z500, Z1000 a T850) ve všech uzlových bodech. Nakonec jsem vybrala krokovou metodu. Toto jsem udělala pro každou stanici zvlášť.

Následně jsem získané výsledky ověřila křížovou validací, která probíhala stejně. Vše jsem tedy spočítala pro každou stanici znovu – Analyze -> Regression -> Linear s krokovou metodou, jen jsem postupně vynechávala hodnotu vždy pro jeden rok. Pro tento vynechaný rok mi program Statistica vytvořil rovnici lineární regrese, které se samozřejmě v každém roce lišily koeficienty, v mnoha případech i výběrem prediktorů. Do těchto vytvořených rovnic jsem následně dosadila hodnoty vybraných prediktorů a vypočetla simulované extrémní teploty. Toto jsem provedla pro každý rok na každé stanici v každém období. Nakonec jsem pomocí Pearsonova korelačního koeficientu v programu Excel zjistila korelace mezi extrémními naměřenými a simulovanými hodnotami.

3.4. Výsledky

Výsledné korelace mezi naměřenými extrémními teplotami a simulovanými jsou zobrazeny pomocí sloupců na Obr. 12. Korelace jsou převážně kladné a často i nad 0,1, ovšem jsou zde i výjimky, kdy jsou korelace dokonce záporné, především pak v letním období. Na Obr. 12 je vidět, že korelační koeficient 0,4 byl překročen pouze na jedné stanici, a to v zimě na Milešovce. Důvod může být ten, že jde o stanici s vyšší nadmořskou výškou, tudíž je blíže volné atmosféře. Ovšem horská stanice v Rakousku-Sonnblick má výrazně vyšší nadmořskou výšku, ale korelace je v zimě jen 0,2 a v létě dokonce záporná. Třetí nejvýše položenou stanicí je Isparta, ovšem nejedná se přímo o horskou stanici, ale o stanici ležící na náhorní plošině v Turecku, takže se zde podmínky oproti horským stanicím liší, což může být vysvětlením, proč jsou korelace tak nízké, i přesto že leží ve výšce 997 m n. m.


V některých případech byly dosaženy dokonce záporné korelace, tedy nepřímá lineární závislost. Na stanici La Coruña v létě je nejvyšší negativní korelace, hned za ní je ovšem Akureyri pro zimní období. Závislost simulovaných a naměřených hodnot je téměř nulová ve čtyřech případech, pro obě období jen na již zmiňované stanici Isparta. Obecně se potvrdilo, že statistický downscaling je vhodnější provádět pro zimní období, kdy jsou korelace vyšší. Výjimkou jsou jen stanice Alicante a Kyjev, kde byla dosažena větší shoda mezi naměřenými a simulovanými hodnotami v létě.



Obrázek 12: Korelace naměřených a simulovaných extrémních teplot na jednotlivých stanicích pro léto (červeně) a zimu (modře)

Na Obr. 13 jsou zobrazeny dva grafy, přičemž na horním grafu je zobrazen průběh extrémních teplot za celé sledované období na stanici s nejvyšší dosaženou korelací a na spodním grafu pak s nejnižší korelací. Největší přesnost simulovaných extrémních teplot byla v zimě na stanici Milešovka. Jen v roce 2002 došlo k výraznému odchýlení od skutečné hodnoty, a to téměř o 10 °C. Po většinu sledovaného období se naměřené a simulované hodnoty lišily maximálně o 3 °C. V letech 1995 a 2003 byla extrémní teplota simulovaná s přesností 0,2 °C.

Naopak nejnižší korelace se ukázala na stanici na severu Islandu, a to 0,006, což značí, že je zde téměř nulová závislost naměřených a simulovaných hodnot. Nejvýraznější odchylka simulované hodnoty je v roce 1998, podobně jako na Milešovce přibližně o 10 °C. Ovšem na rozdíl od Milešovky jsou zde i další výrazné rozdíly mezi naměřenou a simulovanou extrémní hodnotou. Například v roce 1983 byla odchylka 9 °C. V letech 1981, 1991 a 2004 byl rozdíl mezi hodnotami vyšší než 5 °C. Nejvíce se hodnoty shodovaly v roce 1994, ale i přesto byla odchylka 0,4 °C. V dalších letech často rozdíl převyšoval 1 °C.



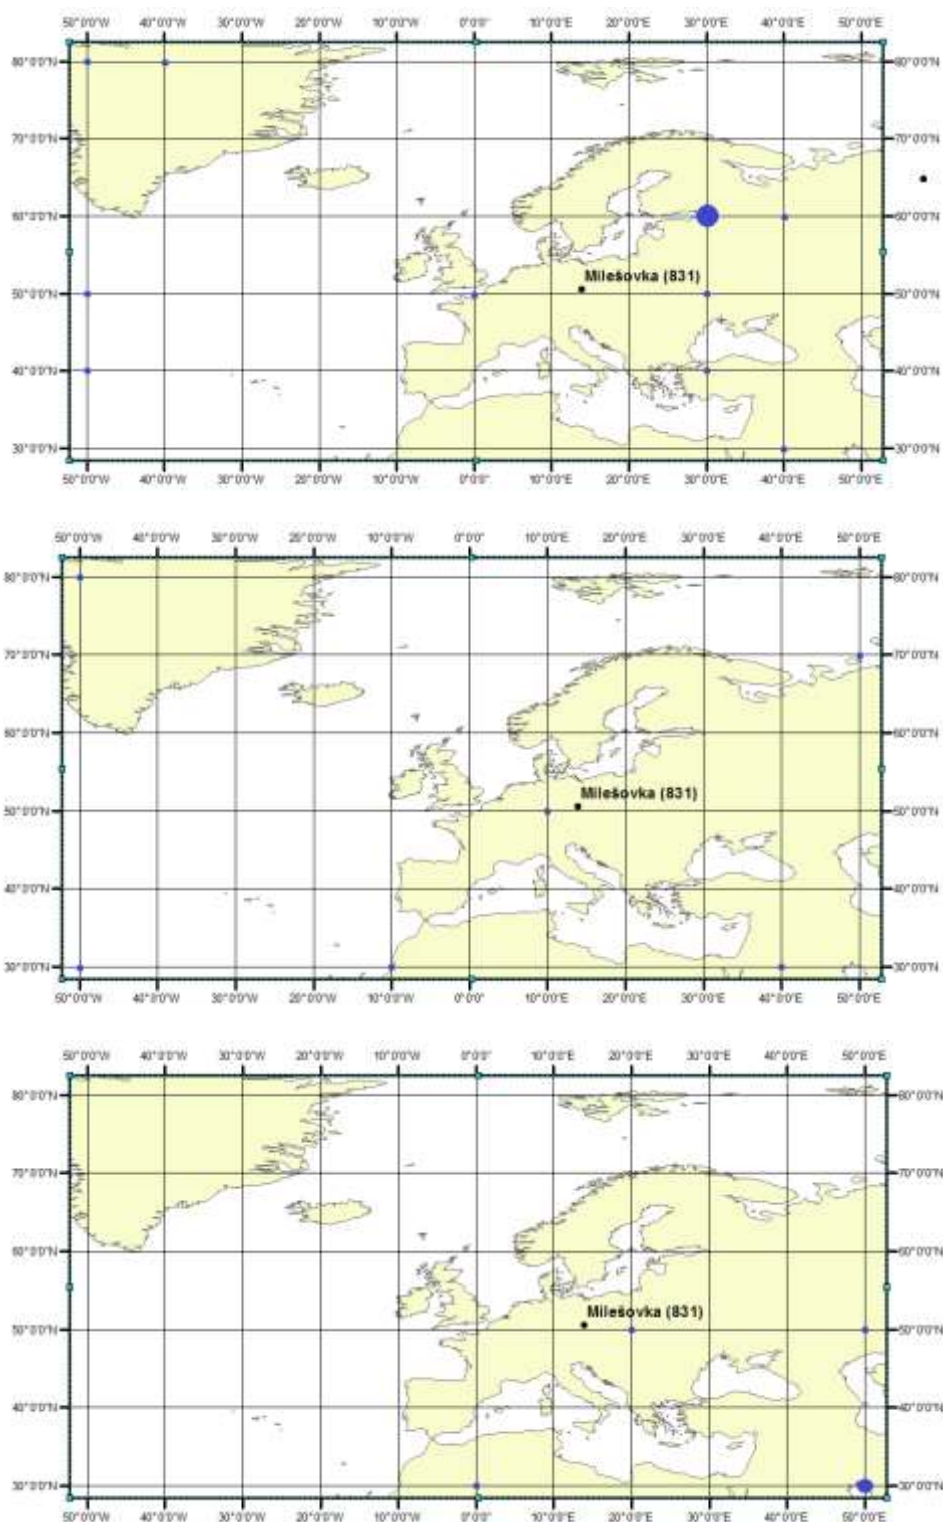
Obrázek 13: V grafech jsou zobrazeny pozorované a simulované extrémní teploty, na horním grafu je zobrazena stanice s nejvyšší korelací a na spodním grafu stanice s nejnižší korelací

3.4.1 Volba prediktorů

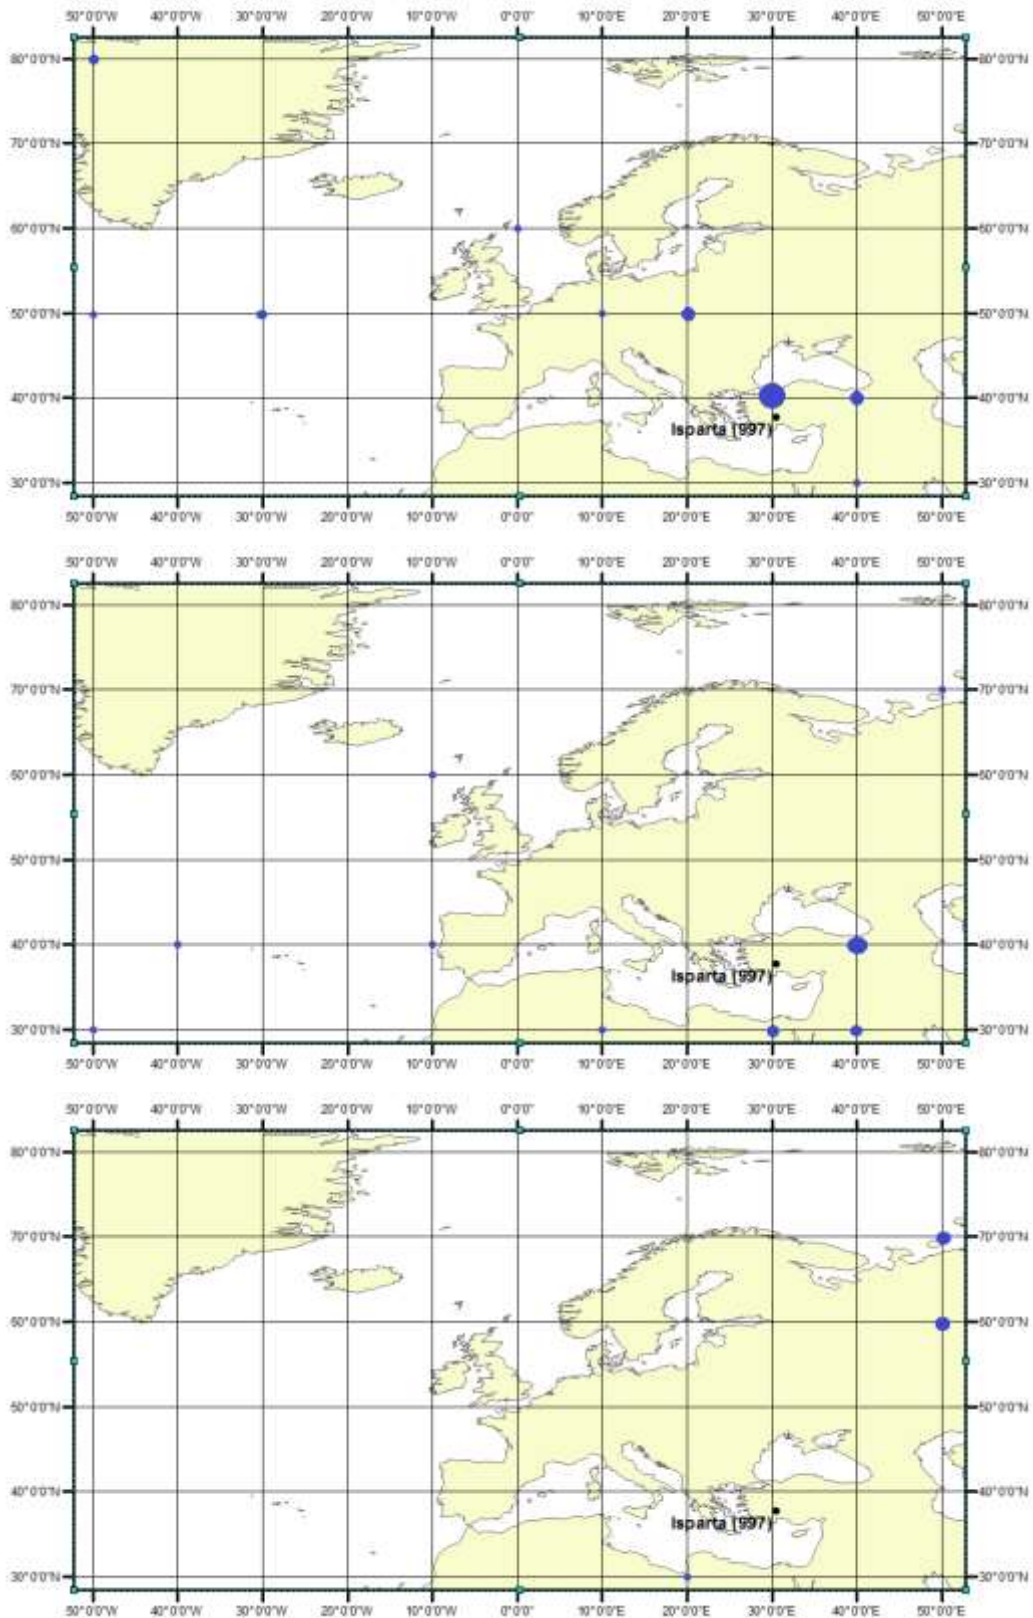
Prediktory byly vybrány programem Statistica a zároveň byly vypočteny i koeficienty. Průměrně do regresní rovnice v jednom roce vstoupilo od 0 do 10,57 prediktorů (Tab. 10). Pro křížovou validaci se pak jednotlivé rovnice lišily jak koeficienty, tak i výběrem prediktorů. Na ukázkou jsem zvolila zimní sezónu, a to pro stanici, kde bylo dosaženo nejvyšší korelace - Milešovku, a pak stanici, kde byly korelace poměrně nízké- Isparta.

Na Obr. 14 je ukázáno v síti $10^\circ \times 10^\circ$, z jakého bodu byly prediktory nejčastěji voleny pro stanici Milešovka. Celkově byla nejčastějším prediktorem T850, celkem v 36 případech z toho 27x byla zvolena v uzlovém bodě 60° s. š. a 30° v. d., což není nejbližší bod. Nejbližší vybraný uzlový bod v síti prediktorů byl 50° s. š. a 0° , který byl vybrán do regresní rovnice pouze v jednom případě. Ve 4 případech se do rovnice dostal prediktor ze západní polokoule. Jen 6x vstoupila do rovnice výška 500 hPa, přičemž nejbližší uzlový bod byl 50° s. š. a 10° v. d., což je zároveň nejbližší možný bod. Naopak se v jedné rovnici objevil i uzlový bod na souřadnici 80° s. š. a 50° z. d. Zbylé prediktory Z500 pak byly rozděleny přesně na polovinu, 3 ze západní a 3 z východní polokoule. Posledním prediktorem byla výška 1000 hPa, která byla vybrána stejně jako předchozí prediktor 6x. Nejbližší uzlový bod - 50° s. š. a 20° v. d. byl zvolen pouze jednou, naopak 3x byl vybrán uzlový bod na souřadnici 30° s. š. a 50° v. d. Nezápadnějším bodem procházel nultý poledník, tudíž ze západní polokoule nebyl ani jeden prediktor Z1000.

Stejně porovnání je ukázáno i pro stanici Isparta v zimě na Obr. 15. Při výpočtech pro stanici Isparta byla také T850 nejčastějším prediktorem. V 19 případech byl vybrán v bodě 40° s. š. a 30° v. d., což přibližně odpovídá souřadnicím stanice. Poté bylo vybráno i několik sousedních bodů, naopak nejvzdálenější bod - 80° s. š. a 50° z. d., který vstoupil do regresní rovnice, byl zvolen dokonce 2x. Prediktor Z500 pak vstoupil do rovnic celkem 16x, z toho 6x v bodě 40° s. š. a 40° v. d., geograficky bližší uzlový bod (40° s. š. a 30° v. d.) nebyl vybrán ani jednou. Nejvzdálenějším vybraným uzlovým bodem byl 30° s. š. a 50° z. d. Nejméně prediktorů bylo vybráno z výšky 1000 hPa. Zde se výběr prediktorů odchýlil spíše na sever, kdy z celkových 5 byly 2 na 70. rovnoběžce a další 2 na 60. rovnoběžce, poslední bod byl stanici Isparta nejbližší, a to 30° s. š. a 20° v. d.



Obrázek 14: Síť prediktorů T850 (nahore), Z500 (uprostřed) a Z1000 (dole) pro stanici Milešovka v zimě. Čím větší kolečko, tím více daných prediktorů v určitém uzlovém bodě bylo celkem vybráno do regresních rovnic za období 1979-2007.



Obrázek 15: Síť prediktorů T850 (nahore), Z500 (uprostřed) a Z1000 (dole) pro stanici Isparta v zimě. Čím větší kolečko, tím více daných prediktorů v určitém uzlovém bodě bylo celkem vybráno do regresních rovnic za období 1979-2007.

Teplota 850 hPa byla tedy nejčastějším prediktorem na obou stanicích, dokonce v obou případech byl tento prediktor použit v zimě celkem 36x v regresních rovnicích pro celé období 1979-2007. Na stanici s nižší korelací byl vybrán nejbližší možný uzlový bod, naopak, na Milešovce, kde byla korelace nejvyšší, byla nejčastěji použita hodnota až ze vzdálenějšího uzlového bodu. Výrazně se pak stanice lišily v počtu prediktorů Z500, geopotenciální výška hladiny 1000 hPa pak byla opět v podobném počtu.

3.4.2 Vliv počtu prediktorů

Při zpracování této práce došlo ke zjištění, že do lineárních rovnic vstupuje různé množství prediktorů. Tyto čísla se celkově ovšem nelišila jen v řádu jednotek, ale i v řádu desítek, výjimečně i stovek (Tab. 10). Proto mě zajímalo, jestli na stanicích, kde je počet prediktorů vysoký, jsou extrémní teploty simulované s větší přesností, a naopak pokud do každé lineární rovnice vstoupil pouze jeden či dva prediktory, tak zda se simulovaná hodnota alespoň trochu přibližuje té pozorované.

Do jednotlivých rovnic vstupoval různý počet prediktorů, proto jsem se ve své práci zaměřila i na to, zda korelace závisí například i na množství prediktorů, které vstupují do rovnice lineární regrese. Jak je zmíněné v předchozí kapitole, tak simulované extrémní teploty odpovídají těm naměřeným více v zimním období. Tab. 10 zobrazuje celkový počet jednotlivých prediktorů, které byly vybrány do jednotlivých rovnic lineární regrese, v závorce je pak uveden průměrný počet prediktorů na jednu rovnici, tedy celkový počet vydělen 29, tedy počtem let, pro které byly extrémy počítány. Jak je ale vidět v Tab. 10, tak v létě je téměř dvojnásobný počet prediktorů než v zimě, což ukazuje, že alespoň v tomto případě množství prediktorů nemá vliv na korelace. Největší počet prediktorů byl na stanici Isparta pro letní období, průměrně do každé rovnice vstoupilo 10 prediktorů, ovšem naměřené teploty se s těmi simulovanými shodovaly skoro nejméně.

Největší negativní korelace byla dosažena v létě na stanici La Coruña, kde do lineární regrese vstupovaly v průměru jen dva prediktory. Ale například stanice Kyjev měla poměrně vysoké korelace (v létě téměř 0,4), ale průměrně v rovnici bylo počítáno jen se 3,93 prediktory. Korelace pro stanici Sodankylä jsou také pro obě období poměrně vysoké - nad 0,3, ale lineární regrese byla v obou obdobích počítána přibližně se sedmi prediktory.



Nedá se tedy jasně říci, zda množství prediktorů má vliv na velikost korelace, ovšem v tomto případě mohu uvést, že určitě neplatí, čím více prediktorů v rovnici lineární regrese, tím lépe simulované teploty.

	léto				zima			
	celkem	850	500	1000	celkem	850	500	1000
La Coruña	61 (2,1)	42 (1,45)	12 (0,41)	7 (0,24)	80 (2,76)	34 (1,17)	27 (0,93)	19 (0,66)
Akureyri	208 (7,17)	108 (3,72)	49 (1,69)	51 (1,76)	31 (1,07)	3 (0,10)	28 (0,97)	0 (0)
Alicante	93 (3,21)	57 (1,97)	15 (0,52)	21 (0,72)	100 (3,45)	55 (1,90)	40 (1,38)	5 (0,17)
Central England	203 (7)	87 (3)	73 (2,52)	42 (1,45)	89 (3,07)	41 (1,41)	14 (0,48)	34 (1,17)
Isparta	296 (10,21)	138 (4,76)	73 (2,52)	85 (2,93)	57 (1,97)	36 (1,24)	16 (0,55)	5 (0,17)
Klementinum	200 (6,9)	82 (2,83)	69 (2,38)	49 (1,69)	147 (5,07)	87 (3)	18 (0,62)	42 (1,45)
Kyjev	114 (3,93)	35 (1,21)	30 (1,03)	49 (1,69)	84 (2,9)	58 (2)	22 (0,76)	4 (0,14)
Milešovka	176 (6,07)	111 (3,83)	33 (1,14)	32 (1,1)	48 (1,66)	36 (1,24)	6 (0,21)	6 (0,21)
Sodankylä	211 (7,28)	108 (3,83)	52 (1,79)	51 (1,76)	200 (6,9)	98 (3,38)	49 (1,69)	53 (1,83)
Sonnblick	128 (4,41)	38 (1,31)	35 (1,21)	55 (1,9)	77 (2,66)	54 (1,86)	9 (0,31)	14 (0,48)
celkem	1690 (58,28)	806 (27,79)	441 (15,21)	442 (15,24)	913 (31,48)	502 (17,31)	229 (7,9)	182 (6,28)

Tabulka 10: Celkový počet prediktorů vstupujících do rovnic lineární regrese na jednotlivých stanicích (v závorce je uveden průměrný počet prediktorů pro jeden rok, tedy pro jednu rovnici lineární regrese- celkový počet vydělen 29)

V Tab. 10 je také vidět, že nejčastěji vybraným prediktorem byla teplota ve výšce 850 hPa, naopak nejméně častým výška 1000 hPa. Akureyri jako jediná stanice měla největší počet prediktorů z výšky 500 hPa v zimě, ovšem korelace zde byla poměrně dost záporná. Naopak v Kyjevě byla velmi častým prediktorem v létě geopotenciální výška 1000 hPa a korelace se zde přibližovaly k hodnotě 0,4. Na Milešovce, kde byla korelace nejvyšší, je nejčastějším prediktorem teplota 850 hPa, což vypovídá o předchozím tvrzení, že horské stanice jsou blíže volné atmosféře a tudíž jsou teploty pomocí těchto prediktorů simulovány lépe.

Na základě proměnných, které byly vybrány pro tuto práci, se tedy dá říci, že nejčastěji je vybrána teplota ve výšce 850 hPa, naopak nejméně častým prediktorem je výška 1000 hPa. Výběr prediktorů nemá přímo vliv na správnost simulovaných hodnot, ovšem na horských stanicích se tyto hodnoty těm naměřeným přibližují.




Obrázek 16: V grafech jsou zobrazeny pozorované a simulované extrémní teploty v létě, na horním grafu je zobrazena stanice s největším počtem prediktorů a na spodním grafu stanice s nejmenším počtem prediktorů

Na Obr. 16 je ukázán průběh extrémních teplot za celé letní období na stanici s největším a s nejmenším počtem prediktorů. Na stanici La Coruña je korelace výrazně záporná, teploty jsou dokonce protichůdné, největší rozdíl - téměř 10 °C mezi naměřenými a simulovanými teploty je v roce 1980, naopak rozdíl je nejmenší v závěru sledovaného období.

Na stanici Isparta do rovnice vstoupilo nejvíce prediktorů, ale korelační koeficient, je také blízko nule. Největší rozdíl - opět téměř 10 °C mezi extrémními teplotami je pak v 90. letech. V 80. letech byly teploty simulované s menším rozdílem - jen do 5 °C. Ke konci sledovaného období jsou ale opět rozdíly výraznější. Grafy tedy opět potvrzují

předchozí tvrzení, že množství prediktorů nemá vliv na přesnost simulovaných extrémních hodnot. Jak při nízkém počtu prediktorů, tak při vysokém jsou rozdíly místy velmi výrazné.



Obrázek 17: V grafech jsou zobrazeny pozorované a simulované extrémní teploty v zimě, na horním grafu je zobrazena stanice s největším počtem prediktorů a na spodním grafu stanice s nejmenším počtem prediktorů, vynechaná místa značí, že nebyl vybrán žádný predátor, tudíž hodnota nemohla být simulována

Grafy byly vytvořené i pro zimní období, kdy jsou obecně korelace vyšší. Na stanici Akureyri v zimním období do rovnice vstoupilo průměrně 1,07 prediktorů, ovšem v roce 2002 a 2007 nebyl vybrán žádný vhodný prediktor, proto hodnota nemohla být simulována (Obr. 17). Celkově bylo na této stanici počítáno s nejmenším počtem prediktorů ze všech vybraných. Největší odchylka simulované hodnoty byla v roce 1995 - přes 8 °C. S malou

přesností byl simulován i rok 2000, rozdíl mezi hodnotami byl 7 °C. S největší přesností byly napodobeny roky 1994 a 1998, rozdíl byl jen 0,3 °C.

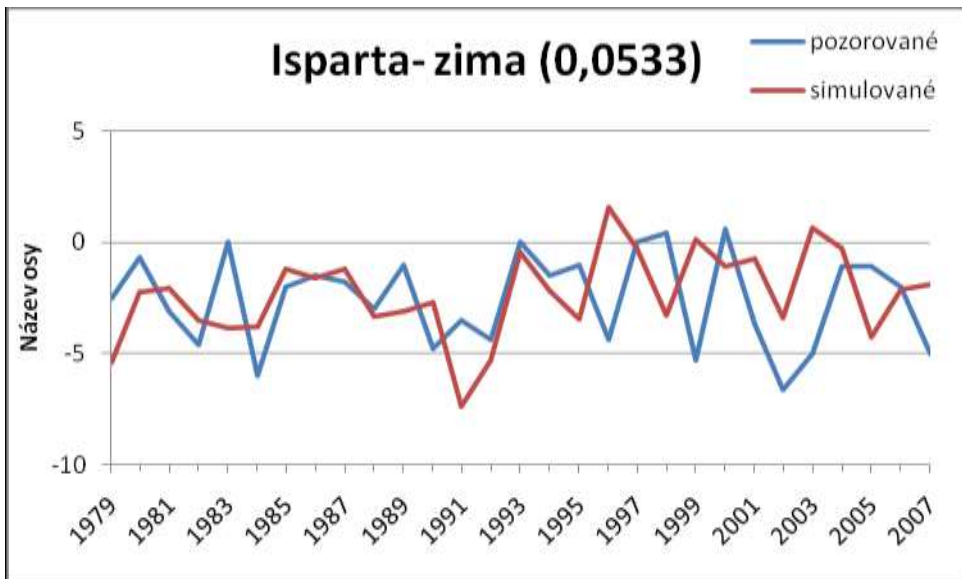


Na stanici Sodankylä byly extrémní hodnoty simulované poměrně přesně, respektive výkyvy jsou zachyceny i v simulovaných hodnotách, ovšem rozdíl je často i přes 3 °C. Například v roce 1999 byla extrémní teplota nasimulována s rozdílem 4 °C od naměřené (Obr. 17), ale i v dalších letech na této stanici na severu Evropy byly extrémní minimální teploty poměrně dobře simulované, větší rozdíl byl jen v roce 1984, a to 12 °C. O dobře simulovaných hodnotách, svědčí i vyšší korelační koeficient.

Naopak na stanici Akureyri, která také leží na severu Evropy, nejsou extrémy příliš vystiženy. V 90. letech se křivky shodují, ovšem ve zbylém časovém období jsou odchylky od skutečných hodnot, přičemž nejvýrazněji se teploty rozcházejí v již zmíněných letech 1995 a 2000, výrazný rozdíl je i na začátku 80. let, 2 hodnoty nebyly nasimulovány vůbec. Při pohledu na tyto dva grafy (Obr. 17), by se dalo odporovat předchozímu tvrzení, že velikost korelace nezávisí na počtu prediktorů, jelikož na stanici Sodankylä do lineární regrese vstoupilo nejvíce prediktorů a korelace jsou zde celkem vysoké, pro stanici Akureyri jsou hodnoty nízké, dokonce záporné, a je zde nízký počet prediktorů.

Závěr je tedy takový, že obecně přesnost simulovaných hodnot na počtu prediktorů nezávisí, v letním období bylo toto tvrzení potvrzeno, ovšem v zimě nikoliv. Jak zmiňují ve své práci Kettle a Thompson (2004) vliv zde mohou mít dálkové vazby, tzv. telekonekce, které se projevují výrazněji v zimě než v létě, to ovšem nijak nesouvisí s počtem vybraných prediktorů.

3.4.3 Vliv nadmořské výšky

Závislost downscalingu na nadmořské výšce byla řešena už v minulosti při simulacích denních nebo měsíčních teplot, ovšem při simulování extrémních hodnot jen nepatrně. Proto jsem se zde rozhodla porovnat tři nejvýše položené stanice a jejich korelace. Nakonec jsem porovnala stanice s nejvyšší a nejnižší nadmořskou výškou.





Obrázek 18: V grafech jsou zobrazeny pozorované a simulované extrémní teploty v zimě na třech nejvýše položených stanicích

Proto dalším zkoumaným „jevem“ bylo, zda má vliv nadmořská výška na velikost korelace. Nejvýše položenou stanicí je Sonnblick, který leží ve výšce 3 106 m n. m., velmi dobře byl nasimulovaný extrém v roce 1997, kdy rozdíl mezi naměřenou a simulovanou hodnotou byl necelých 0,2 °C. Ale i v dalších letech jsou křivky poměrně blízko, k velkému rozdílu dochází jen ve 2. polovině 80. let. Grafy jsou zobrazeny na Obr. 18.

Výrazně níže položená Milešovka ležící ve výšce 831 m n. m. má největší korelace ze všech zkoumaných stanic, i když v roce 2002 je teplota nasimulována s rozdílem téměř 10 °C, po většinu období jsou rozdíly mezi naměřenými a simulovanými hodnotami poměrně nízké, většinou do 5 °C, tomu odpovídá i vysoká korelace.

Třetí vysoko položenou stanicí je Isparta, ovšem nejedná se o horu, ale o stanici na náhorní plošině v Turecku, která leží ve výšce 997 m n. m. To by mohl být hlavní důvod, proč jako jediná „horská stanice“ má velmi nízké korelace, a to pro obě sledovaná období. V zimě (Obr. 18) je největší rozdíl v roce 2003, ale jen přibližně 5 °C mezi naměřenou a simulovanou hodnotou, ovšem rozdíl od zobrazených dvou stanic je ten, že teploty se liší o nízké hodnoty, ale po většinu sledovaného období. Na stanici Isparta není žádný výrazný výkyv, jako například na Milešovce (10 °C), tam ale po zbytek období jsou simulované hodnoty blízko těm naměřeným.

Na základě mnou zkoumaných tří stanic s nadmořskou výškou nad 800 m (horské stanice) se dá říci, že pokud se jedná o typicky horskou stanici, extrémní teploty jsou simulované lépe než pro stanici na náhorní plošině, protože místní vlivy se v horách lépe simulují. Ovšem nedá se říci, že čím vyšší nadmořská výška, tím větší korelace, jelikož nejlépe simulované hodnoty jsou na Milešovce, která je o 2 275 m níže než Sonnblick, i přesto, že by se dalo očekávat, že ve vyšších nadmořských výškách jsou podmínky blíže volné atmosféře, a tudíž budou hodnoty simulovány přesněji.




Obrázek 19: V grafech jsou zobrazeny pozorované a simulované extrémní teploty v zimě na stanici s nejvyšší (Sonnblick- 3106 m n. m.) a nejnižší nadmořskou výškou (Akureyri- 27 m n. m.)

Předchozí tvrzení podporuje i porovnání korelací na nejvýše a nejnižše položené stanici (Obr. 19). Na stanici Akureyri, která leží v nadmořské výšce 27 m, jsou korelace v zimním období dokonce záporné a pro tři roky ani nemohla být teplota nasimulována. Zimní období jsem zde zvolila z důvodu, že právě v zimě mohou být teploty v nižších polohách ovlivněny specifickými projevy počasí, jako je například inverze, která ale teploty na horských stanicích většinou neovlivní.

3.4.4 Vliv kontinentality klimatu

Na základě předchozích prací, které jsou zaměřené převážně na downscaling denních nebo měsíčních průměrných teplot či srážek, jsem se i ve své práci zamyslela nad tím, zda může mít vliv kontinentalita klimatu i u simulování extrémních teplot. Obecně je počasí na přímořských stanicích více proměnlivé, protože je pod vlivem oceánu. Teplotní amplituda je pak výrazně vyšší na kontinentálních stanicích, a to jak během dne, tak i v průběhu roku. Takže by se mohlo zdát, že vyšší (nižší) extrémní teploty budou právě na kontinentálních stanicích, a tím pádem by downscaling simuloval s větší přesností extrémy na přímořských stanicích.



Obrázek 20: V grafech jsou zobrazeny pozorované a simulované extrémní teploty pro kontinentální stanici (nahore) a oceánskou (dole)

Proto vznikla další otázka, zda při simulování extrémních hodnot má vliv i kontinentalita, popřípadě oceanita klimatu. Zde jsem porovnála dvě stanice v letním období (Obr. 20). Jako nejvíce kontinentální ze zkoumaných stanic byl Kyjev, naopak jako nejvíce oceánskou stanicí jsem zvolila Central England. Na obou stanicích jsou korelace vysoké.



Na Obr. 20 stojí za povšimnutí rok 1997 v Kyjevě, kde byla extrémní teplota nejnižší za celá 90. léta, nasimulovaná teplota také zachycuje pokles, ovšem je o celých 5 °C nižší. Simulované teploty se v letech 1987 a 1988 liší jen o pouhou jednu desetinu °C. Celkově se tedy dá říci, že na kontinentální stanici jako je Kyjev, jsou extrémní teploty simulované pomocí statistického downscalingu jen s malými rozdíly od skutečných, jen výjimečně odchylna převyšuje 4 °C, a to ve třech letech.

Ovšem i Central England, kde má na počasí velký vliv oceán, má vysoké korelace. I když na této stanici je jeden velký rozdíl mezi naměřenou a simulovanou hodnotou. Jedná se o rok 1997, kdy je rozdíl téměř 10 °C, také bych upozornila na fakt, že mezi lety 1997 a 1999 došlo k poklesu maximálních teplot, což je zachyceno i v simulovaných hodnotách, ovšem podstatně výrazněji. V roce 1997 byla naměřená teplota 30,4 °C a v roce 1999 pak 29,8 °C, což je rozdíl 0,6 °C, ale simulované hodnoty zaznamenaly rozdíl o 12 °C. Největší shoda byla ve dvou případech, stejně jako na stanici Kyjev, a to v letech 1989 a 1991, kdy byl rozdíl jen 0,1 °C.

Na základě mých výsledků se tedy nedá říci, že by extrémní teploty byly simulované lépe na kontinentální či oceánské stanici. Obě stanice mají vysoký korelační koeficient, a to dokonce pro léto, kdy jsou hodnoty obecně simulovány s menší přesností než v zimě, jak je uvedeno výše.

3.4.5 Vliv zeměpisné šířky

Již výše je uvedeno, že downscaling se nemůže provádět po celém světě, například v tropických oblastech by byl využit téměř s nulovou přesností. Nejlepší jsou pro simulace střední zeměpisné šířky, tedy například i oblast Evropy, které je zkoumána i v mé práci. Ovšem položila jsem si otázku, zda ve vybrané oblasti, která je vhodná pro statistický downscaling, má vliv i to, zda leží stanice spíše na jihu či spíše na severu Evropy.



Obrázek 21: V grafech jsou zobrazeny pozorované a simulované extrémní teploty pro nesevernější zkoumanou stanici (nahore) a nejižnější (dole)

Nakonec jsem se tedy ve své práci zaměřila na to, zda jsou extrémní teploty lépe simulované pro severní nebo jižní oblasti ve středních zeměpisných šířkách. Na Obr. 21 jsou zobrazené extrémní teploty pro Sodankylä, což byla nejseverněji položená stanice, a Alicante, která leží na jihu Pyrenejského poloostrova, ovšem nejižnější zkoumanou stanicí byla Isparta, ovšem kvůli jejímu specifickému umístění - náhorní plošina a východní stanice, jsem ji ne zvolila v tomto porovnání.

Stanice Sodankylä má vysoké korelace a teploty byly simulovány s velkou přesností, Velmi dobře zde bylo zachyceno i roční kolísání teplot. Například v roce 1998 je extrémní teplota zachycena jen s rozdílem necelé 4 °C. Ovšem maximální rozdíl mezi hodnotami je v roce 2004, kdy se teploty liší o 18 °C. Nejméně se hodnoty liší v roce 1986

a 2002, kdy je rozdíl jen 0,2 °C. Jižní stanice Alicante má korelaci 0,1534, největší rozdíl mezi naměřenou a simulovanou extrémní hodnotou je v roce 1981, a to přes 7 °C, což je oproti severní stanici výrazný nepoměr, i když korelace za celé období je podstatně vyšší.

Z výše uvedených grafů by se tedy dalo říci, že pro severněji položené stanice jsou extrémní teploty pomocí statistického downscalingu simulované podstatně lépe, i když zde může dojít k výraznému rozdílu mezi naměřenou a simulovanou hodnotou, ovšem je to spíše výjimečné, po většinu období jsou pak rozdíly minimální. Na jihu takový extrémní rozdíl dosažen nebyl, ale teploty se liší většinou o 2 až 3 °C, což snižuje celkovou korelaci pro celé sledované období.

4 Závěr

V této práci jsem zkoumala přesnost simulací extrémních teplot pomocí lineární regrese. Při výběru prediktorů jsem vycházela z předchozích prací, jelikož této problematice se věnovalo již dříve několik autorů (Kidson a Thompson, 1998; Huth, 2002). Zvolila jsem metodu lineární regrese, jelikož denní či měsíční průměrné hodnoty teplot simulovala dobře, tedy ve většině případů bylo dosaženo vysokých korelací s pozorovanými hodnotami. Také jsem se zaměřila na to, zda má významný vliv při downscalingu extrémních teplot vliv umístění stanice, zde jsem porovnála hned několik případů, například vliv nadmořské výšky nebo vliv kontinentality (viz výše). Ukázalo se, že poloha stanice má bezpodmínečně vliv na simulace, ovšem bylo zde zkoumáno jen 10 stanic. I přesto, že postihly rozmanité klimatické poměry napříč Evropou, pro potvrzení výsledků by byly nutné simulace pro další stanice.

Cílem této práce bylo zjistit, zda je vhodné simulovat extrémní teploty ze sezónních průměrů pomocí regresních rovnic. Tato metoda se příliš neosvědčila, i když na některých stanicích byly extrémní hodnoty simulované s korelačním koeficientem nad 0,3, na Milešovce dokonce i nad 0,4, přesto jsou tyto hodnoty celkem nízké. U některých stanic byly zachyceny i roční proměnlivosti, často ale s určitými rozdíly mezi pozorovanými a simulovanými hodnotami. Nejvíce překvapující jsou dvě fakta. První je ten, že pro Milešovku byly hodnoty simulované s větší přesností než pro výše položenou stanici Sonnblick. Druhý pozoruhodný fakt je ten, že na stanici Milešovka byly hodnoty simulované nejlépe, i přesto, že vybrané prediktory v uzlových bodech neležely v těsné blízkosti stanice, naopak velmi nízké korelace (kolem 0) byly na stanici Isparta, kde prediktory byly nejčastěji vybírány v těsné blízkosti stanice.

5 Diskuse

Downscaling je převážně počítán pro denní nebo měsíční průměrné teploty, kdy nejvyšších korelací dosáhl Easterling (1999) od 0,8 do 0,9 pro měsíční maximální teploty, pro minimální potom od 0,7 do 0,8. Korelace v práci Schoof a Pryor (2001) se pro denní maximální teploty pohybovaly od 0,34 do 0,85 a pro denní minimální teploty od 0,63 do 0,89. V porovnání tedy s mými výsledky jsou korelace opravdu vysoké. Ovšem tato práce se zaměřovala na downscaling extrémních teplot, u kterých je podstatně větší problém je simulovat. Proto výsledné hodnoty v těchto pracích nemohou být srovnávány s těmi, kterých bylo dosaženo v mé práci.

Ovšem s ostatními autory se shodují v tom, že downscaling je více úspěšný v zimním období než v letním, a to tedy jak u simulování denních či měsíčních hodnot, tak u simulací extrémních teplot. Ovšem toto tvrzení neplatí úplně vždy. Ukázalo se, že na downscaling má rozhodně vliv umístění stanice, jak bylo porovnáno výše, pro vyšší nadmořské výšky jsou extrémní teploty simulovány přesněji než pro nižší polohy, což se shoduje se simulací denních průměrných teplot (Huth, 1999). Zejména pak v zimě se v nižších polohách mohou projevovat místní specifické projevy počasí jako je například inverze. Rozdíl je také v tom, zda se jedná o horskou stanici nebo o stanici umístěnou na náhorní plošině.

Zda leží stanice na severu či na jihu, by také mohlo mít určitý vliv na přesnost simulací, ovšem v mé práci stanice Akureyri, která leží na severu Islandu, vykazuje nízké, dokonce v obou případech i slabě záporné korelace, narozdíl od stanice Sodankylä, která leží na severu Finska, kde jsou korelace naopak v obou případech vysoké. Jižnější stanice ale neukázaly v žádném případě dobrou schopnost simulovat extrémní teploty, alespoň ne ty, se kterými jsem v této práci pracovala. Takže by se dalo říci, že simulování extrémních teplot pro severněji položené stanice je přesnější než pro jižní stanice.

Předpoklad o simulaci na kontinentálních stanicích potvrzen nebyl. Při simulaci extrémních teplot pomocí statistického downscalingu by nemělo mít vliv, zda je stanice přímořská, či leží ve vnitrozemí, což je rozdíl oproti simulování denních průměrných teplot, kdy dochází k větší přesnosti simulovaných hodnot na stanicích s kontinentálním klimatem (Huth, 1999).

Ohledně počtu prediktorů ale zůstává otázka, zda s větším počtem dochází k přesnějším simulacím, či ne. Při porovnání dvou stanic, kde byl nejvyšší počet (Isparta) a nejmenší počet (La Coruña) prediktorů v létě se ukázalo, že při nižším počtu byla

korelace poměrně vysoce záporná. Ovšem v zimním období byl největší počet prediktorů na stanici Sodankylä, které obecně měla vysoké korelace pro obě sledovaná období. Naopak na stanici Akureyri, kde v zimě do rovnice vstoupilo nejméně prediktorů, byla dosažena záporná korelace. Na základě mých výsledků, se tedy dá říct, že počet prediktorů může mít vliv na přesnost simulací, ovšem jen nepatrný, a to v zimě.

Zdroje:

- Abaurrea, J., Asín, J. (2005): Forecasting local daily precipitation patterns in a climate change scenario. *Climate Research*, 28, 183–197
- Allen, D., Cannon, A., Toews, M., Scibek, J. (2010): Variability in simulated recharge using different GCMs. *Water Resour. Res.*, 46, W00F03, doi:10.1029/2009WR008932.
- Benestad, R. E. (2001): A comparison between two empirical downscaling strategies. *International Journal of Climatology*, 21, 1645–1668.
- Benestad, R. E., Førland, E. J., Hanssen-Bauer, I. (2002): Empirically downscaled temperature scenarios for Svalbard. *Atmospheric Science Letters*, 3(2), 71–93, DOI: 10.1006/Asle.2002.0051.
- Bretherton, C. S., Smith, C., Wallace, J. M. (1992): An intercomparison of methods for finding coupled patterns in climate data. *Journal of climate*, 5 (6), 541-560.
- Bronstert, A. (2004): Rainfall runoff modelling for assessing impacts of climate and land use change. *Hydrol. Processes*, 18, 567- 570.
- Bürger, G., (1996): Expanded downscaling for generating local weather scenarios. *Climate Res.*, 7, 111- 128.
- Bürger, G. (1996): Expanded downscaling for generating local weather scenarios. *Climate Research*, 7, 111–128.
- Bürger, G., Murdock, T. Q., Werner, A. T., Sobie, R. (2012): Downscaling extremes- An intercomparison of multiple statistical methods for present climate. *Journal of Climate*, 25, 4366- 4388.
- Cannon, A. J. (2011): Quantile regression neural networks: Implementation in R and application to precipitation downscaling. *Comput.Geosci.*, 37, 1277- 1284, doi:16/j.cageo.2010.07.005.
- Carlson, R. E. (1990): Heat stress, plant-available soil moisture, and corn yield in Iowa: A short- and long-term view. *Journal of Production Agriculture*, 3, 293-297.
- Cavazos, T. (1997): Downscaling large-scale circulation to local winter rainfall in North-eastern Mexico. *International Journal of Climatology*, 17, 2069-1082.
- Cavazos, T., Hewitson, B. C. (2005): Performance of NCEP-NCAR reanalysis variables in statistical downscaling of daily precipitation. *Climate Research*, 28, 95–107.
- Compagnucci, R. H., Salles, M. A. (1997): Surface pressure patterns during the year over southern South America. *International Journal of Climatology*, 17 (6), 635-653.
- Conway, D., Wilby, R. L., Jones, P. D. (1996): Precipitation and air flow indices over the British Isles. *Climate Research*, 7, 169–183.
- Corte-Real, J., Zhang, X., Wang, X. (1995): Downscaling GCM information to regional scales: a non-parametric multivariate regression approach. *Climate Dynamics*, 11, 413.
- Coulibaly, P. (2004): Downscaling daily extreme temperatures with genetic programming. *Geophysical Research Letters*, 31, L16203, DOI: 10.1029/2004GL020075.
- Crane, R. G., Hewitson, B. C. (1998): Doubled CO₂ precipitation changes for the Susquehanna basin: down-scaling from the GENESIS general circulation model. *International Journal of Climatology*, 18 (1), 65-76.
- Dehn, M., Burger, G., Buma, J., Gasparetto, P. (2000): Impact of climate change on slope stability using expanded downscaling. *Engineering Geology*, 55, 193–204.
- Déqué, M., Rowell, D. P., Lüthi, D., Giorgi, F., Christensen, J. H., Rockel, B., Jacob, D., Kjellström, E., de Castro, M., van den Hurk, B. (2007): An intercomparison of regional

- climate simulations for Europe: assessing uncertainties in model projections. *Climatic Change*, 81(Supplement 1), 53–70.
- Dibike, Y. B., Coulibaly, P. (2005): Hydrologic impact of climate change in the Saguenay watershed: comparison of downscaling methods and hydrologic models. *Journal of Hydrology*, 307, 145–163.
 - Ekström, M., Fowler, H. J., Kilsby, C. G., Jones, P. D. (2005): New estimates of future changes in extreme rainfall across the UK using regional climate model integrations. 1. Future estimates and use in impact studies. *Journal of Hydrology*, 300, 234–251
 - Easterling, D. R. a kol. (1997): Maximum and minimum temperature trends for the globe. *Science*, 277 (5324), 364-367.
 - Easterling, D. R. (1999) Development of regional climate scenarios using a downscaling approach. *Climate Change*, 41, 615-634
 - Esteban, P., Jones, P. D., Martín-Vide, J., Mases, M. (2005): Atmospheric circulation patterns related to heavy snowfall days in Andorra, Pyrenees. *International Journal of Climatology*, 25 (3), 319-329.
 - Fowler, H. J., Kilsby, C. G., O'Connell, P. E. (2000): A stochastic rainfall model for the assessment of regional water resource systems under changed climatic conditions. *Hydrology and Earth System Sciences*, 4, 261–280.
 - Fowler, H. J., Kilsby, C. G. (2002): Precipitation and the North Atlantic Oscillation: a study of climatic variability in Northern England. *International Journal of Climatology*, 22, 843–866.
 - Fowler, H. J., Ekström, M., Kilsby, C. G., Jones, P. D. (2005): New estimates of future changes in extreme rainfall across the UK using regional climate model integrations. 1. Assessment of control climate. *Journal of Hydrology*, 300, 212–233.
 - Fowler, H. J., Blenkinsop, S., Tebaldi, C. (2007): Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling. *International Journal of Climatology*, 27, 1547- 1578
 - Frei, C., Schär, C., Lüthi, D., Davies, H. C. (1998): Heavy precipitation processes in a warmer climate. *Geophysical Research Letters*, 25(9), 1431–1434.
 - Frei, C., Christensen, J. H., Déqué, M., Jacob, D., Jones, R. G., Vidale, P. L. (2003): Daily precipitation statistics in regional climate models: evaluation and intercomparison for the European Alps. *Journal of Geophysical Research*, 108(D3), 4124, DOI: 10.1029/2002JD002287.
 - Gardner, M. W., Dorling, S. R. (1998): Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment*, 32 (14), 2627-2636.
 - Gachon, P., Dibike, Y. (2007): Temperature change signals in northern Canada: Convergence of statistical downscaling results using two driving GCMs. *Int. J. Climatol.*, 27, 1623- 1641.
 - Goodess, C. M., Palutikof, J. (1998): Development of daily rainfall scenarios for southeast Spain using a circulation-type approach to downscaling. *International Journal of Climatology*, 18, 1051–1083.
 - Goodess, C. M., Jones, P. D. (2002): Links between circulation and changes in the characteristics of Iberian rainfall. *International of Journal Climatology*, 22, 1593-1615
 - Goodess, C. M., Anagnostopoulou, C., Bardossy, A., Frei, C., Harpham, C., Haylock, M. R., Hundscha, Y., Maheras, P., Ribalaygua, J., Schmidli, J., Schmith, T., Tolika, K., Tomozeiu, R., Wilby, R. L. (2007): An intercomparison of statistical downscaling methods for Europe and European regions – assessing their performance with respect to extreme temperature and precipitation events. *Climatic Change*.
 - Hanssen-Bauer, I., Førland, E. J., Haugen, J. E., Tveito, O. E. (2003): Temperature and precipitation scenarios for Norway: comparison of results from dynamical and empirical downscaling. *Climate Research*, 25, 15–27.
 - Harpham, C., Wilby, R. L. (2005): Multi-site downscaling of heavy daily precipitation occurrence and amounts. *Journal of Hydrology*, 312, 1–21.
 - Hay, L. E., Clark, M. P. (2003): Use of statistically and dynamically downscaled atmospheric model output for hydrologic simulations in three mountainous basins in the western United States. *Journal of Hydrology*, 282, 56–75.

- Hayhoe, K. a kol. (2007): Past and future changes in climate and hydrological indicators in the US Northeast. *Climate Dyn.*, 28, 381- 407.
- Haylock, M. R., Cawley, G. C., Harpham, C., Wilby, R. L., Goodess, C. M. (2006): Downscaling heavy precipitation over the United Kingdom: a comparison of dynamical and statistical methods and their future scenarios. *International Journal of Climatology*, 26, 1397–1415.
- Hellstrom, C., Chen, D., Achberger, C., Räisänen, J. (2001): Comparison of climate change scenarios for Sweden based on statistical and dynamical downscaling of monthly precipitation. *Climate Research*, 19, 45–55.
- Hellstrom, C., Chen, D. (2003): Statistical downscaling based on dynamically downscaled predictors: application to monthly precipitation in Sweden. *Advances in Atmospheric Sciences*, 20, 951–958.
- Hessami, M., Gachon, P., Ouarda, T. B. M. J., St-Hilaire, A. (2008): Automated regression-based statistical downscaling tool. *Environ. Modell. Software*, 23, 813- 834.
- Hewitson, B. C., Crane, R. G. (1992): Large-scale atmospheric controls on local precipitation in tropical Mexico. *Geophysical research Letters*, 19, 1835-1839.
- Hewitson, B. (1994): Regional climates in the GISS general circulation model: Surface air temperature. *J. Climate*, 7, 283-303
- Heyen, H. a kol. (1996) Statistical downscaling of monthly mean North-Atlantic air-pressure to sea level anomalies in the Baltic sea. *Tellus*, 48A, 312-323.
- Hsieh, W. W., Tang, B. (1998): Applying neural network models to prediction and data analysis in meteorology and oceanography. *Bulletin of the American Meteorological Society*, 79(9), 1855-1870.
- Hughes, J. P., Guttorp, P. (1994): A class of stochastic models for relativ synoptic atmospheric patterns to regional hydrologic phenomena. *Water Resources Research*, 30, 1535-1546.
- Huth, R. (1996): An intercomparison of computer-assisted circulation classification methods. *International journal of climatology*, 16 (8), 893-922.
- Huth, R. (1997): Potential of continental-scale circulation for the determination of local daily surface variables. *Theoretical and Applied Climatology*, 56, 165–186.
- Huth, R. (1999): Statistical downscaling in Central Europe: evaluation of methods and potential predictors. *Climate Research*, 13, 91-101.
- Huth, R., Kyselý, J., & Dubrovský, M. (2001): Time structure of observed, GCM-simulated, downscaled, and stochastically generated daily temperature series. *Journal of Climate*, 14 (20), 4047-4061.
- Huth, R. (2002): Statistical downscaling of daily temperature in central Europe. *J. Climate*, 15, 1731-1742.
- Huth, R., Kyselý, J., Dubrovský, M. (2003): Simulation of surface air temperature by GCMs, statistical downscaling and weather generator: higher order statistical moments. *Studia Geophysica et Geodaetica*, 47, 203–216.
- Huth, R., Kliegrová, S., Metelka, L. (2008): Nonlinearity in statistical downscaling: does it bring an improvement for daily temperature in Europe? *Int. J. Climatol.*, 28, 465-477.
- Charles, S. P., Bates, B. C., Smith, I. N., Hughes, J. P. (2004): Statistical downscaling of daily precipitation from observed and modelled atmospheric fields. *Hydrological Processes*, 18, 1373–1394.
- IPCC (2013): The Fifth Assessment Report - AR5
- IPCC (2013): The Fourth Assessment Report - AR5
- Kalnay, E. a kol. (1996): The NCEP/NCAR 40-year reanalysis project. *Bulletin of the American meteorological Society*, 77 (3), 437-471.
- Karl, T. R., Wang, W. C., Schlesinger, M. E., Knight, R. W., Portman, D. (1990): A method of relating general circulation model simulated climate to observed local climate. Part I: seasonal statistics. *Journal of Climate*, 3, 1053–1079.
- Karl, T. R., Jones, P. D., Knight, R. W., Kukla, G. a kol. (1993): Asymmetric trends of daily maximum and minimum temperature. *Bull. Am. Meteorol. Soc.*, 74, 1007–1023
- Kettle, H., Thompson, R. (2004): Statistical downscaling in European mountains: verification of reconstructed air temperature. *Climate research*, 26, 97- 112.
- Khan, M. S., Coulibaly, P., Dibike, Y. (2006): Uncertainty analysis of statistical downscaling methods. *Journal of Hydrology*, 319, 357–382.

- Kidson, C. G., Thompson, C. S. (1998): A comparison of statistical and model-based downscaling techniques for estimating local climate variations. *Journal of Climate*, 11, 735-753.
- Klein, W. H. (1962): Specification of monthly mean surface temperatures from 700 mb heights. *J. Appl. Meteor.*, 1, 154-156
- Klein, W. H. a Wlasch, J.E. (1983) A comparison of pointwise screening and empiric orthogonal functions in specifying monthly surface temperature from 700 mb data. *Mon. Wea. Rev.*, 111, 669-673
- Klein Tank, A. M. G. A kol (2002): Daily dataset of 20th- century surface air temperature and precipitation series for the European Climate Assessment. *International Journal of Climatology*, 22, 1441-1453.
- Kleinn, J., Frei, C., Gurtz, J., Luthi, D., Vidale, P. L., Schär, C. (2005): Hydrologic simulations in the Rhine basin driven by a regional climate model. *Journal of Geophysical Research*, 110, D04102, Doi:10.1029/2004JD005143.
- Kyselý, J. (2002), Comparison of extremes in GCM-simulated, downscaled and observed central-European temperature series. *Climate Research*, 20, 211–222.
- Leung, L. R., Qian, Y., Bian, X., Hunt, A. (2003b): Hydroclimate of the western United States based on observations and regional climate simulation of 1981–2000. Part II: mesoscale ENSO anomalies. *Journal of Climate*, 16, 1912–1928
- Matulla, C. (2005): Regional, seasonal and predictor-optimized downscaling to provide groups of local scale scenarios in the complex structured terrain of Austria. *Meteorologische Zeitschrift*, 14, 31–47.
- Maurer, E. P., Brekke, L., Pruitt, T., Duffy, P. (2007): Fine-resolution climate projections enhance regional climate change impact studies. *Eos, Trans. Amer. Geophys. Union*, 88, 504, doi:10.1029/2007EO470006.
- Mikšovský, J., Raidl, A. (2005): Testing the performance of free nonlinear methods of time series analysis for prediction and downscaling of European daily temperatures. *Nonlinear Processes in Geophysics*, 12, 979-991.
- Mpelasoka, F. S., Mullan, A. R., Heerdegen, R. G. (2001): New Zealand climate change information derived by multivariate statistical and artificial neural network approaches. *International Journal of Climatology*, 21, 1415-1433.
- Muller-Wohlfeil, D. I., Bürger, G., Lahmer, W. (2000): Response of a river catchment to climate change: application of expanded downscaling to northern Germany. *Climatic Change*, 47, 61–89.
- Murphy, J. (1999): An evaluation of statistical and dynamical techniques for downscaling local climate. *Journal of Climate*, 12, 2256–2284.
- Nicholls, N., Gruza, G., Jouzel, J., Karl, T. R., Ogallo, L. A., Parker, D. E. (1996): Observed climate change and variability. In *Climate Change 1995: The Science of Climate Change. The Second Assessment Report of the IPCC: Contribution of Working Group I*, Houghton JT, Meira Filho LG, Callender BA, Harris N, Kattenberg A, Maskell K (eds). Cambridge University Press: Cambridge; 133–192.
- Noguer, M. (1994): Using statistical techniques to deduce local climate distributions. An application for model validation. *Meteor. Appl.*, 1, 277-287
- Santos, J. A., Corte-Real, J., Leite, S. M. (2005): Weather regimes and their connection to the winter rainfall in Portugal. *International Journal of Climatology*, 25 (1), 33-50.
- Salathe, E. P., Mote, Jr., P. W., Wiley, M. W. (2007): Review of scenario selection and downscaling methods for the assessment of climate change impacts on hydrology in the United States Pacific Northwest. *Int. J. Climatol.*, 27, 1611-1621.
- Saunders, I. R., Byrne, J. M. (1996): Generating regional precipitation from observed and GCM synoptic-scale pressure fields southern Alberta, Canada. *Climate Res.*, 6, 237-249
- Saunders, I. R., Byrne, J. M. (1999): Using synoptic surface and geopotential height fields for generating grid- scale precipitation. *International Journal of Climatology*, 19, 1165-1176
- Schmidli, J., a kol. (2007): Statistical and dynamical downscaling of precipitation: An evaluation and comparison of scenarios for European Alps. *J. Geophys. Res.*, 112
- Schoof, J. T., Pryor, S. C. (2001) Downscaling temperature and precipitation: A comparison of regression-based methods and artificial neural networks. *International Journal of Climatology*, 21, 773-790

- Slonosky, V. C., Jones, P. D., Davies, T. D. (2001): Atmospheric circulation and surface temperature in Europe from the 18th century to 1995. *International Journal of Climatology*, 21, 63–75.
- Solman, S. A., Nuñez, M. N. (1999): Local estimates of global climate change: a statistical downscaling approach. *International Journal of Climatology*, 19 (8), 835-861.
- Stahl, K., Moore, R. D., Shea, J. M., Hutchinson, D., Cannon, A. J. (2008): Coupled modelling of glacier and streamflow response to future climate scenarios. *Water Resour. Res.*, 44, W02422, doi:10.1029/2007WR005956.
- Terray, L. a kol. (2004): Simulation of late-twenty-first-century ganges in wintertime atmospheric circulation over Europe due to anthropogenic causes. *Journal of Climate*, 17, 4630-4635.
- Trigo, R. M., & Palutikof, J. P. (1999): Simulation of daily temperatures for climate change scenarios over Portugal: a neural network model approach. *Climate Research*, 13 (1), 45-59.
- von Storch, H., Zwiers, F. (1999): *Statistical Analysis in Climate Research*. Cambridge University Press: Cambridge
- Wang, Y., Leung, L. R., McGregor, J. L., Lee, D. K., Wang, W. C., Ding, Y., Kimura, F. (2004): Regional climate modeling: progress, challenges, and prospects. *Journal of the Meteorological Society of Japan*, 82, 1599–1628.
- Weber, R. O., Talkner, P., Stefanicki, G. (1994): Asymmetric diurnal temperature change in the Alpine region. *Geophys. Res. Lett.*, 21, 673–676
- Weber, R. O., Talkner, P., Auer, I., Bohm, R., Gajic-capka, M., Zaninovic, K., Brazdil, R., Fasko, P. (1997): 20th-century changes of temperature in the mountain regions of central Europe. *Clim. Change.*, 36, 327–344.
- Weichert, A., Bürger, G. (1998): Linear versus nonlinear techniques in downscaling. *Climate research*, 10, 83-93.
- Wetterhall, F., Bardossy, A., Chen, D., Halldin, S., Xu, C. (2006): Daily precipitation-downscaling techniques in three Chinese regions. *Water Resources Research*, 42, W11423, DOI: 10.1029/2005WR004573.
- Widmann, M., Schär, C. (1997): A principal component and long-term trend analysis of daily precipitation on Switzerland. *Int. J. Climatol.*, 17, 1333-1356
- Wilby, R. L., Wigley, T. M. L. (1997): Downscaling general circulation model output: a review of methods and limitations. *Prog. Phys. Geogr.*, 21, 530–548
- Wilby, R. L. (1998). Statistical downscaling of daily precipitation using daily airflow and seasonal teleconnection indices. *Climate Research*, 10 (3), 163-178.
- Wilby, R. L., Wigley, T. M. L., Conway, D., Jones, P. D., Hewitson, B. C., Main, J., Wilks, D. S. (1998): Statistical downscaling of general circulation model output: a comparison of methods. *Water Resources Research*, 34, 2995–3008.
- Wilby, R. L., Hay, L. E., Leavesley, G. H. (1999): A comparison of downscaled and raw GCM output: Implications for climate change scenarios in the San Juan River basin, Colorado. *J. Hydrol.*, 225 (1–2), 67- 91.
- Wilby, R. L., Wigley, T. M. L. (2000): Precipitation predictors for downscaling: observed and general circulation model relationships. *International Journal of Climatology*, 20, 641–661.
- Wilby, R. L., Dawson, C.W., Barrow, E. M. (2002): SDSM—A decision support tool for the assessment of regional climate change impacts. *Environ. Modell. Software*, 17, 145- 157.
- Wilby, R.L., Dawson, C.W. (2013): The Statistical downscaling model: insights from one decade of application. *Int. J. Climatol.*, 33, 1707-1719.
- Xu, C. Y. (1999) From GCMs to river flow: a review of downscaling methods and hydrologic modelling approaches. *Progress in Physical Geography*, 23 (2), 229- 249.
- Xu, C. Y. (1999). From GCMs to river flow: a review of downscaling methods and hydrologic modelling approaches. *Progress in physical Geography*, 23 (2), 229-249.
- Zorita, E., von Storch, H. (1999): The analog method as a simple statistical downscaling technique: Comparison with more complicated methods. *Journal of Climate*, 12, 2474–2489.