

Dlouhodobá předpověď počasí ve světě a v České republice

Long-range weather forecast in the world and in the Czech Republic

Jana Solánská

Český hydrometeorologický ústav
Oddělení všeobecné klimatologie
Dvorská 410, 503 11 Hradec Králové – Svobodné Dvory
✉ jana.solanska@chmi.cz

Stanislava Kliegrová

Český hydrometeorologický ústav
Pobočka Hradec Králové
Dvorská 410, 503 11 Hradec Králové – Svobodné Dvory
✉ stanislava.kliegrova@chmi.cz

The first part of the article summarizes the basic knowledge regarding long-term weather forecasting which, by definition, covers a period from a few weeks to several years. This type of forecasting is nowadays undergoing a great development and its use is spreading to a wide range of different sectors. Slowly changing parts of the climate system are important for long-term forecasting, and their evolution over longer time scales is more easily estimated. The success rate of long-term forecasting is therefore high in the tropical Pacific, for example, due to the good predictability of El Niño events, which have a major impact on the weather there. However, Europe has a very diverse climate, influenced by the Atlantic Ocean, the Mediterranean Sea, the Arctic and continental influences from Eastern Europe and Asia. This complexity makes predictions more difficult. In the second part of the paper we discuss the possibilities of statistical downscaling of long-term forecasts for the Czech Republic, which is one of the main objectives of the Perun project.

KLÍČOVÁ SLOVA: downscaling – síť neuronová – projekt Perun – předpověď ansámblová – předpověď dlouhodobá

KEYWORDS: downscaling – neural network – Perun project – ensemble forecast – long-term forecast

1. Úvod

Dlouhodobá předpověď počasí pokrývá období od několika týdnů až po několik let. Podle definice meteorologického slovníku České meteorologické společnosti (eMS 2024) se jedná o předpověď počasí na období od 30 dnů do dvou let, především na měsíc, sezonu či rok. Vyplňuje mezeru mezi krátkodobými předpověďmi počasí (až na 14 dní dopředu) a dlouhodobými klimatickými scénáři (30–100 let). Nelze se na ni dívat

stejně jako na předpověď počasí na pár dnů dopředu. Dlouhodobé předpovědi počasí nejsou určeny k předpovídání počasí pro určitý den na určitém místě v následujících týdnech, měsících či letech. Popisují trendy průměrných povětrnostních podmínek v delších časových měřítkách (např. týdnech, měsících nebo letech) pro větší územní celky a jsou nejčastěji zobrazovány v podobě odchylek od normálního stavu. Jedná se o zhodnocení následujících období jako celku, zda budou (a s jakou pravděpodobností) teplotně (srážkově) podprůměrné, průměrné či nadprůměrné.

I přes chaotickou povahu atmosféry jsou dlouhodobé předpovědi počasí možné díky řadě atmosférických složek, které vykazují změny v dlouhých časových měřítkách a jsou do jisté míry předvídatelné. Nejdůležitější z těchto složek je cyklus El Niño–jižní oscilace (ENSO), který označuje souvislé velkoplošné kolísání teplot oceánů, srážek, atmosférické cirkulace, vertikálních pohybů a tlaku vzduchu v tropickém Pacifiku. V této oblasti mají dlouhodobé předpovědi počasí velmi dobrou úspěšnost (Kumar et al. 2013). Dlouhodobé předpovědi počasí v oblasti Evropy jsou více problematické. Mezi zdroje předpověditelnosti v oblasti Evropy zahrnujeme především severoatlantickou oscilaci (Scaife et al. 2014), ale také stratosférické procesy, sněhovou pokrývku, půdní vlhkost nebo mořský led.

Dlouhodobé předpovědi počasí jsou důležitým nástrojem plánování v mnoha oblastech. Mají široké spektrum využití, např. v zemědělství (Cantelaube et al. 2005; Graça 2019), hydrologii (Svensson et al. 2015), zdravotnictví, energetice (De Felice et al. 2015; Clark et al. 2017), lesnictví, turismu, dopravě (Palin et al. 2016) a dalších odvětvích. Při znalosti průměrného vývoje počasí v řádu měsíců existuje potenciál snížení škod a předcházení rizik způsobených proměnlivostí počasí.

V Českém hydrometeorologickém ústavu je nejdelší pravidelně vydávanou předpověď měsíční výhled počasí, který je založen na statisticko-analogové metodě a výstupech numerických předpovědních modelů (ČHMÚ 2024). Poskytuje informace o pravděpodobných trendech vývoje teploty vzduchu a úhrnu srážek pro následující 4 týdny i období jako celku.

2. Jak vzniká dlouhodobá předpověď počasí

Tvorba dlouhodobých předpovědí počasí prošla v posledních několika desetiletích obrovskou proměnou. Od čistě akademického výzkumu na počátku 90. let až po současnou situaci, kdy několik meteorologických předpovědních služeb po celém světě provádí rutinní operativní dlouhodobou předpověď.

K dlouhodobým předpovědím počasí jsou nyní nejvíce využívány globální oceán-atmosférické modely, přestože tyto mode-

ly trpí jistou chybou vůči naměřeným datům a nejsou schopné poskytnout potřebnou informaci v regionálním měřítku. Z tohoto důvodu jsou dále na vypočtená data používány takzvané downscalingové metody, které nám pomáhají globální předpovědi převést do lokálních měřítek. Máme dva hlavní přístupy ke zmenšení měřítku (downscalingu) klimatické informace, a to statistický a dynamický.

Dynamický downscaling je založen na přechodu k regionálnímu modelu, který běží na gridu s relativně velkým rozlišením (10–20 km) nad menší doménou (např. Evropa). Počáteční a okrajové podmínky jsou brány z výstupů globálního modelu. Výpočetně je velmi náročný. Regionální model je schopen generovat regionální předpověď pro řadu klimatických proměnných, ale stále trpí značnými chybami, které vyžadují další postprocesing upravující chyby, než budou data využita v dopadových aplikacích (Manzanas et al. 2018).

Statistický downscaling je založený na vztahu mezi lokálně naměřenými prediktandy, o které se zajímáme, a jedním nebo více dostupnými modelovými prediktory, buď z reanalýz nebo z globálních dlouhodobých předpovědních systémů. Tyto vztahy hledáme pomocí historických modelových dat (prediktorů) a historických naměřených dat (prediktantů), obvykle několik desetiletí zpět. Poté je aplikujeme na nová modelová data a snažíme se získat odpovídající lokální prediktanty (Manzanas et al. 2018).

Simulace klimatických modelů jsou zatíženy určitými nejistotami, které vyplývají například z neúplné znalosti teoretického základu nebo z numerického přiblížení použitého pro model zemského systému, z drobných chyb počítačových výpočtů, z parametrizace procesů malého rozsahu nebo z nejistot existujících ve zvolených počátečních a okrajových podmínkách atd. Jelikož není možné nejistoty zcela vyřešit matematicky, provádí se celá řada modelových simulací (10–50), aby bylo možné odhadnout rozptyl možného vývoje klimatu. Pro určení nejistoty počátečních podmínek (vyplývající např. z chyb měření) se počáteční podmínky každého běhu předpovědi lehce změni, což vede k mírně odlišným ansámblovým simulacím. Kombinování výstupů z klimatických modelů různých institucí do více modelových ansámblů pomáhá určit nejistotu vyplývající z použití rozdílných klimatických modelů.

Dovednost modelu se zjišťuje porovnáním zpětných předpovědí, které vycházejí z různých časových bodů v minulosti (dále jen hindcast předpovědi), se skutečným pozorováním během vyhodnocovaného období. Pokud jsou zpětné předpovědi schopny dobře reprodukovat minulost, lze očekávat, že za předpokladu, že zjištěná schopnost předpovědi je přenosná v čase, budou předpovědi stejně dobře reprodukovat i budoucnost.

Každý model simuluje procesy zemského systému, které ovlivňují průběh počasí, trochu jiným způsobem a používá trochu jiné aproximace, což vede k různým druhům chyb modelu. Tyto chyby se obvykle zvyšují s rostoucím časem integrace, takže kumulované chyby modelu se stávají významnými ve srovnání se signálem, který má model předpovídat. Některé z těchto chyb jsou náhodné, jejich vliv na výsledek se kvantifikuje pomocí ansámblů. Některé chyby jsou však systematické, pokud tyto chyby určíme, můžeme na předpovědi aplikovat korekce, a tím získáme užitečnější informace. Toho se dosáhne porovnáním retrospektivních předpovědí s pozorováním a tento rozdíl (označovaný jako bias) aplikujeme na budoucí předpověď v reálném čase. Předpověď sama o sobě proto není užitečná bez jejího propojení s příslušnými zpětnými předpověďmi.

3. Dlouhodobá předpověď počasí ve světě a v Evropě

3.1 Světová předpovědní centra

V provozním režimu se dlouhodobé předpovědi po světě věnuje více než 15 předpovědních center (stav k červenci 2024). Významným zdrojem informací se potom stávají webové stránky institucí nebo projektů, kde jsou jednotlivé předpovědi vytvářené těmito předpovědními centry spojeny do jedné vícesystémové dlouhodobé předpovědi. Tento proces obecně kompenzuje některé systematické chyby, které každý z modelů má.

Dlouhou tradici v tvorbě dlouhodobé předpovědi má například International Research Institute for Climate and Society (IRI). Dlouhodobá předpověď IRI je založena na projektu North American Multi-Model Ensemble (NMME) Národního oceánografického a atmosférického úřadu USA (NOAA). Zahrnuje výstupy z ansámblových předpovědních systémů National Centers for Environmental Prediction (NCEP), Environment and Climate Change Canada, NOAA/Geophysical Fluid Dynamics Laboratory, National Aeronautics and Space Administration (NASA), National Center for Atmospheric Research (NCAR) a COLA/University of Miami. Mapy průměrných předpovědních anomálií pro jednotlivé modely NMME naleznete na webové stránce NOAA Climate Prediction Center (CPC). Webový odkaz je uveden v seznamu literatury na konci článku.

Projekt Evropské unie Copernicus shromažďuje dlouhodobé předpovědi počasí z osmi předpovědních center: European Centre for Medium-Range Weather Forecasts (ECMWF), The Met Office (UKMO), Météo-France (MF), Deutscher Wetterdienst (DWD), Centro Euro-Mediterraneo sui Cambiamenti Climatici (CMCC), NCEP, Japan Meteorological Agency (JMA) a Environment and Climate Change Canada (ECCC).

Na webových stránkách projektu Copernicus, jejichž odkaz je uveden v seznamu literatury na konci článku, lze nalézt předpovědi v grafické i digitální podobě jako celek ze všech předpovědních center dohromady i pro jednotlivá centra zvlášť. Grafické produkty jsou zveřejňovány každý měsíc k 10. dni ve 12:00 UTC, data jsou zpřístupňována k 6. nebo 15. dni měsíce ve 12:00 UTC. Lze tu nalézt předpovědi v grafické podobě pro celý svět i pro jednotlivé menší celky (např. Evropa) pro rozličné meteorologické prvky: teplota vzduchu ve 2 m, úhrn srážek, vítr v 10 m, zonální vítr v 10 hPa, tlak vzduchu, teplota povrchu oceánu, teplota v 850 hPa, geopotenciální výška 500 hPa, sněhová pokrývka na pólech.

3.2 Dlouhodobá předpověď národních meteorologických služeb v Evropě

Dlouhodobé předpovědi počasí jsou národními meteorologickými službami pravidelně vydávány v přibližně polovině států Evropy. Liší se jak grafickou podobou, tak rozsahem. Nejčastěji je předpovídána teplota vzduchu a úhrn srážek pro jednotlivé měsíce na dobu tří až šesti měsíců, a to s jakou pravděpodobností bude dané období nadnormální, normální či podnormální. Předpovědi jsou často uveřejňovány pouze v jazyce dané země.

Z našich sousedních států pravidelně uveřejňuje dlouhodobou předpověď počasí Německo a Polsko (webové odkazy jsou uvedeny v seznamu literatury na konci článku).

Německá předpovědní služba (Deutscher Wetterdienst) poskytuje na webových stránkách dlouhodobou předpověď počasí pro teplotu vzduchu a úhrn srážek na 1 až 6 měsíců pro překrývající se tříměsíční období. Německo je rozděleno do čtyř oblastí a pro každou oblast je uvedeno, zda očekáváme teplotně a srážkově podnormální, normální či nadnormální tříměsíční období. Předpokládanou úspěšnost předpovědi mají vyjádřenou pomocí semaforu, kdy zelená značí dobrou předpověď, oranžová uspokojivou a červená špatnou kvalitu předpovědi. Předpověď počítají pomocí vlastního modelu MPI-ESM.

Polské centrum numerických předpovědí počasí (Instytut Meteorologii i Gospodarki Wodnej Państwowy Instytut Badawczy – IMGW-PIB) vydává sezonní předpověď pro 4 nadcházející měsíce po jednotlivých měsících, zda budou teplotně a srážkově nadnormální, normální či podnormální. Oblast Polska mají rozdělenou do 20 menších celků, pro které uvádějí jak předpověď, tak předpokládané normální rozpětí teplot vzduchu a úhrnu srážek ve formě tabulky. K předpovědi využívají vlastní modely IMGW-Reg a IMGW-Bayes a také výsledky numerických modelů NOAA a ECMWF.

4. Projekt Perun a jeho cíl pro dlouhodobou předpověď

V létě 2020 se v Českém hydrometeorologickém ústavu a dalších společenstevních institucích rozběhl jeden z největších projektů posledních let co do počtu zapojených institucí i délky trvání (do konce roku 2026). Je zaměřen na výzkum klimatických extrémů, sucha a důsledků jeho prohlubování v České republice. Garantem projektu je Ministerstvo životního prostředí a kromě ČHMÚ je do řešení zapojena řada dalších odborných institucí: Česká geologická služba, Matematicko-fyzikální fakulta a Přírodovědecká fakulta Univerzity Karlovy, Ústav fyziky atmosféry AV ČR, v. v. i., Ústav výzkumu globální změny AV ČR, v. v. i., Výzkumný ústav vodohospodářský T. G. Masaryka, v. v. i. a PROGEO, s. r. o. Projekt je prezentován pod názvem PERUN, který vznikl zkrácením anglického Prediction, Evaluation and Research for Understanding National sensitivity and impacts of drought and climate change for Czechia, a je podporován Technologickou agenturou ČR a Ministerstvem životního prostředí (SS02030040, www.perun-klima.cz). Projekt má 8 hlavních cílů.

Jeden z cílů je věnován i dlouhodobé předpovědi. Jedná se o hlavní cíl 3 s názvem Systém pro tvorbu sezónních předpovědí klimatických podmínek a sucha pro území České republiky v kontextu střední Evropy. V jeho rámci je analyzována možnost využití stávajících systémů dlouhodobých předpovědí, porovnávány jejich výstupy s výsledky měření na území České republiky a testován přínos statistického post-processingu výstupů ke zvýšení úspěšnosti předpovědí. Cíl se zabývá také možnostmi downscalingu pomocí regionálního modelu ALADIN-CLIMATE s cílem predikovat základní charakteristiky na období 1 až 6 měsíců a na 7 až 12 měsíců, s důrazem na testování předpověditelnosti sucha v podmínkách České republiky s předstihem v řádu měsíců.

V rámci tohoto cíle probíhá více aktivit od jednotlivých řešitelských týmů. Významným úkolem je nalézt vhodnou metodu pro downscaling výstupů globálních předpovědních modelů (popsáno blíže v kapitole 2). V současné fázi projektu se zabýváme především možnostmi statistického downscalingu dlouhodobých předpovědí teploty vzduchu z globálních modelů pro oblast České republiky pomocí neuronových sítí, jejichž

průběžné výsledky jsou prezentovány v následujících částech této kapitoly.

4.1 Data

Od začátku roku 2022 je využíván externí datový cloud, na kterém jsou k dispozici hindcast data (1993–2016) a data sezónních předpovědí (od roku 2020) ze 4 globálních modelů (Météo-France, ECMWF, CMCC a DWD) ze serveru projektu Copernicus (popsáno blíže v kapitole 3.1). Data aktuálních předpovědí jsou kolegy z Ústavu výzkumu globální změny AV ČR pravidelně stahována a zpracovávána, a jsou k dispozici přibližně po 20. dni každého měsíce.

Podle literatury (Manzanas et al. 2018) byly vytipovány jako prediktory teplota vzduchu a tlak vzduchu na hladině moře z globálních modelů, prediktantem byla teplota vzduchu z dat E-OBS (Cornes et al. 2018) interpolovaná do gridových bodů globálních modelů s horizontálním rozlišením $1^\circ \times 1^\circ$.

Pro počáteční analýzu byly vybrány 2 globální předpovědní modely (ECMWF a Météo-France), předpověď z 1. května (na 2. května až 31. srpna) pro oblast České republiky a blízkého okolí (47° – 52° N, 11° – 20° E). Každý z těchto modelů měl v uvažovaném období 25 členů ansámblu, ze kterých byly počítány vybrané statistiky. Zabývali jsme se dlouhodobou předpovědí letních teplot vzduchu (červen, červenec a srpen) pro celé hindcastové období (1993–2016).


4.2 Metoda

Byl využit modul neuronových sítí v softwaru STATISTICA – StatSoft, Inc. (2012), version 11 (www.statsoft.com). Byly hledány sítě typu MLP (Multilayer Perceptron). Jako nejlepší prediktory byly během experimentů vytipovány: zeměpisná šířka, zeměpisná délka, počet dní od předpovědi, průměrná denní teplota vzduchu (průměr, 10. percentil a 90. percentil hodnot ze všech 50 členů ansámblu obou globálních modelů) a tlak vzduchu na hladině moře (průměr, 10. percentil a 90. percentil hodnot ze všech 50 členů ansámblu obou globálních modelů), prediktantem byla průměrná denní teplota vzduchu E-OBS. Prediktory i prediktant byly shodně v síti gridových bodů globálních předpovědních modelů. Sestaveno a trénováno bylo 20 sítí, výsledky z 5 nejlepších (tedy z těch s nejmenšími rozdíly mezi skutečnými a modelovanými denními teplotami vzduchu E-OBS) byly průměrovány.

4.3 Výsledky


Nejprve byly spočteny průměrné teploty vzduchu pro jednotlivé dny období 2. května až 31. srpna a celou uvažovanou oblast (47° – 52° N, 11° – 20° E). Tyto hodnoty byly spočteny jednak pro údaje získané přímo z globálních předpovědních modelů, dále pro hodnoty získané statistickým downscalingem pomocí neuronových sítí a také pro údaje z E-OBS, vždy zprůměrované po jednotlivých dnech pro celé hindcastové období (1993–2016). Porovnání je na obr. 1. Lepší výsledky získané aplikováním metody neuronové sítě jsou patrné z hodnot střední kvadratické chyby (root mean square error, RMSE), která je používána k popsání míry rozdílu mezi hodnotami modelovými a pozorovanými. Pro hodnoty modelu Météo-France byla tato hodnota $2,3^\circ\text{C}$, pro hodnoty modelu ECMWF $2,9^\circ\text{C}$ a pro hodnoty získané downscalingem pomocí neuronových sítí $1,5^\circ\text{C}$.

Dále byly spočteny a zobrazeny rozdíly průměrných měsíčních teplot vzduchu z dat E-OBS a získaných přímo z globálních předpovědních modelů ECMWF a Météo-France, případně sta-



Obr. 1 Průměrná denní teplota vzduchu z globálních předpovědních modelů ECMWF a Météo-France (z 1. května), z pozorování (E-OBS), a získaná downscalingem pomocí neuronových sítí (NN_ENS), zprůměrovaná za celé hindcast období (1993–2016) a celou oblast (47–52° N, 11–20° E).

Fig. 1. Average daily air temperature forecast from global ECMWF and Météo-France models (from May 1), from observations (E-OBS), and from downscaling using neural networks (NN_ENS), averaged over the entire hindcast period (1993–2016) and the entire region (47–52° N, 11–20° E).



Obr. 2 Rozdíly průměrné měsíční teploty vzduchu (v jednotlivých řádcích pro červen, červenec a srpen) mezi pozorováním (E-OBS) a předpovědí z globálních modelů ECMWF a Météo-France (z 1. května), resp. hodnotami downscalingu pomocí neuronových sítí (NN_ENS), zprůměrované za celé hindcast období (1993–2016) v gridových bodech oblasti (47–52° N, 11–20° E).

Fig. 2. Differences in monthly mean air temperature (for June, July and August) between observations (E-OBS) and forecasts from global ECMWF and Météo-France models (from May 1), or from downscaling using neural networks (NN_ENS), averaged over the entire hindcast period (1993–2016) at grid points in the area (47–52° N, 11–20° E).

tistickým downscalingem pomocí neuronových sítí, zprůměrované pro celé hindcastové období (1993–2016) v jednotlivých gridových bodech. Výsledky jsou prezentovány na obr. 2 a v tabulce 1.

Tab. 1 Průměrné rozdíly měsíční teploty vzduchu mezi pozorováním (E-OBS) a předpovědí z globálních modelů ECMWF a Météo-France (z 1. května), resp. hodnotami downscalingu pomocí neuronových sítí (NN_ENS), zprůměrované za celé hindcast období (1993–2016) a celou oblast (47–52° N, 11–20° E).

Table 1. Mean monthly air temperature differences between observations (E-OBS) and forecasts from global ECMWF and Météo-France models (from 1 May), or from downscaling using neural networks (NN_ENS), averaged over the entire hindcast period (1993–2016) and the entire region (47–52° N, 11–20° E).

	Květen	Červen	Červenec	Srpen
E-OBS mínus ECMWF	2,3	2,3	3,0	2,8
E-OBS mínus MF	0,8	-1,1	-1,8	-2,4
E-OBS mínus NN_ENS	-0,7	-0,1	-0,1	0,4

4.4 Shrnutí

Průměrné měsíční teploty vzduchu z modelu ECMWF byly podhodnocené pro všechny analyzované měsíce (červen, červenec a srpen) a gridové body, a to v průměru přes celou doménu nejvýrazněji pro měsíc červenec. Naopak průměrné měsíční teploty vzduchu z modelu Météo-France byly nadhodnocené pro všechny měsíce a téměř ve všech gridových bodech, a to v průměru přes celou doménu nejvýrazněji pro měsíc srpen. Použití metody neuronových sítí přineslo lepší výsledky pro dlouhodobou předpověď průměrné denní teploty vzduchu i průměrné měsíční teploty vzduchu přes celou doménu srovnatelně pro všechny letní měsíce ve většině bodů sítě.

Analýza bude pokračovat pro další měsíce, s více modely a výsledné neuronové sítě budou aplikovány i na předpovědní data globálních modelů pro období 2020–2023.

5. Závěr

V článku jsme představili stručný úvod do problematiky dlouhodobé předpovědi počasí, která podle definice pokrývá období od několika týdnů až do několika let. Pro dlouhodobou předpověď jsou důležité pomalu se měnící části klimatického systému, jejichž vývoj se na delší dobu dá lépe odhadnout. Vysoká úspěšnost dlouhodobé předpovědi je proto například v oblasti tropického Pacifiku, a to díky dobré

předpověditelnosti jevu El Niño, který tam má na počasí zásadní vliv. Evropa má ale velmi rozmanité klima, ovlivněné Atlantickým oceánem, Středozemním mořem, Arktidou a kontinentálními vlivy z východní Evropy a Asie. Tato komplexnost činí předpovědi složitějšími. Tyto předpovědi tak stále zůstávají v oblasti střední Evropy i přes pokroky ve výpočetní technice, vývoji modelů počasí a zlepšení sběru meteorologických dat velkou výzvou.

Možnostem dlouhodobé předpovědi počasí pro území České republiky se věnuje jeden z hlavních cílů projektu Perun. Významným úkolem je nalézt vhodnou metodu pro downscaling výstupů globálních předpovědních modelů, která by umožnila přechod od globálního k regionálnímu měřítku. V současné fázi projektu se zabýváme především možnostmi statistického downscalingu dlouhodobých předpovědí teploty vzduchu z globálních modelů pro oblast České republiky pomocí neuronových sítí.

Použití metody neuronových sítí přineslo lepší výsledky pro dlouhodobou předpověď průměrné denní teploty vzduchu i průměrné měsíční teploty vzduchu pro letní měsíce ve většině bodů sítě, což ukazuje na jistý potenciál zpracování výsledků dlouhodobé předpovědi z globálních modelů pro oblast České republiky tímto způsobem. Nicméně k obecnějším závěrům jsou potřeba analýzy pro další měsíce a s více modely, na kterých se bude pracovat v následujícím období.

Poděkování:

Příspěvek vznikl v rámci řešení projektu „Predikce, hodnocení a výzkum citlivosti vybraných systémů, vlivu sucha a změny klimatu v Česku, PERUN“ (SS02030040), který je podporován Technologickou agenturou ČR.

Autorky článku děkují kolektivu spolupracovníků z HC 3 projektu PERUN, kteří se podíleli ve velké míře na přípravě dat, jmenovitě Petru Štěpánkovi z ÚVGZ a Michalu Beldovi z MFF UK. Poděkování patří také oběma recenzentům (Marku Kašparovi a Ladislavu Metelkovi).

Literatura:

- CANTELAUBE, P., TERRES, J. M., 2005. Seasonal weather forecasts for crop yield modelling in Europe. *Tellus A: Dynamic Meteorology and Oceanography*, Vol. 57, Issue 3, s. 476–87. Dostupné z: <https://doi.org/10.3402/tellusa.v57i3.14669>.
- CLARK, R. T. et al., 2017. Skillful seasonal predictions for the European energy industry. *Environmental Research Letters*, Vol. 12, Article 024002. Dostupné z: <https://doi.org/10.1088/1748-9326/aa57ab>.
- COPERNICUS, 2024. Seasonal forecasts [online]. [cit. 17. 7. 2024]. Dostupné z WWW: <https://climate.copernicus.eu/seasonal-forecasts>.
- CORNES, R., VAN DER SCHRIER, G., VAN DEN BESSELAAR, E. J. M., JONES, P., 2018. An Ensemble Version of the E-OBS Temperature and Precipitation Data Sets. *Journal of Geophysical Research: Atmospheres*. Vol. 123, s. 9391–9409. Dostupné z: <https://doi.org/10.1029/2017JD028200>.
- ČHMÚ, 2024. Dlouhodobý výhled počasí [online]. [cit. 13. 11. 2024]. Dostupné z WWW: <https://www.chmi.cz/predpovedi/predpovedi-pocasi/ceska-republika/dlouhodoby-vyhled-pocasi>.

- DE FELICE, M., ALESSANDRI, A., CATALANO, F., 2015. Seasonal climate forecasts for medium-term electricity demand forecasting. *Applied Energy*. Vol. 137, s. 435–444. ISSN 0306-2619. Dostupné z: <https://doi.org/10.1016/j.apenergy.2014.10.030>.
- DEUTSCHER WETTERDIENST, 2024. Basic Seasonal Climate Predictions [online]. [cit. 17. 7. 2024]. Dostupné z WWW: https://www.dwd.de/EN/ourservices/kvhs_en/1_basic/month/monthly_node.html.
- eMS, 2024. Elektronický meteorologický slovník (eMS) ČMeS [online]. Česká meteorologická společnost [cit 27. 02. 2024]. Dostupné z WWW: <http://slovník.cmes.cz>.
- GRAÇA, A., MEDGOLD, Consortium, 2019. The MED-GOLD project: Advanced user-centric climate services for higher resilience and profitability in the grape and wine sector. *BIO Web of Conferences*, Vol. 12, Article 01005. Dostupné z: <https://doi.org/10.1051/bio-conf/20191201005>.
- INSTYTUT METEOROLOGII I GOSPODARSKY WODNEJ PAŃSTWOWY INSTYTUT BADAWCZY, 2024. Long/range forecasts [online]. [cit. 17. 7. 2024]. Dostupné z WWW: <https://meteo.imgw.pl/>.
- KUMAR, A., CHEN, M., WANG, W., 2013. Understanding prediction skill of seasonal mean precipitation over the tropics. *Journal of Climate*, Vol. 26, s. 5674–5681. Dostupné z: <https://doi.org/10.1175/JCLI-D-12-00731.1>.
- MANZANAS, R. et al., 2018. Dynamical and statistical downscaling of seasonal temperature forecasts in Europe: Added value for user applications. *Climate Services*, Vol. 9, s. 44–56. ISSN 2405-8807. Dostupné z: <https://doi.org/10.1016/j.cliser.2017.06.004>.
- NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION, 2024. Climate Prediction Center – NMME Forecasts of Monthly Climate Anomalies: 3-Month Mean Spatial Anomalies [online]. [cit. 18. 7. 2024]. Dostupné z WWW: www.cpc.ncep.noaa.gov/products/NMME/seasanom.shtml.
- PALIN, E. J., SCAIFE, A. A., WALLACE, E., POPE, E. C. D., ARRIBAS, A., BROOKSHAW, A., 2016. Skillful seasonal forecasts of winter disruption to the U.K. transport system. *Journal of Applied Meteorology and Climatology*, Vol. 55, s. 325–344. Dostupné z: <https://doi.org/10.1175/JAMC-D-15-0102.1>.
- SCAIFE, A. A. et al., 2014. Skillful long-range prediction of European and North American winters. *Geophysical Research Letters*, Vol. 41, s. 2514–2519. Dostupné z: <https://doi.org/10.1002/2014GL059637>.
- SVENSSON, C. et al., 2015. Long-range forecasts of UK winter hydrology. *Environmental Research Letters*, Vol. 10, Article 064006. Dostupné z: <https://doi.org/10.1088/1748-9326/10/6/064006>.

Lektoři (Reviewers):

RNDr. Marek Kašpar, Ph.D., RNDr. Ladislav Metelka, Ph.D.