


Vícerozměrné metody předpovědi klimatických anomálií

Disertační práce

Stanislava Kliegrová



Katedra meteorologie a ochrany prostředí

Matematicko-fyzikální fakulta

Univerzita Karlova v Praze

Leden 2006

**Školitel: Doc. RNDr. Jaroslava Kalvová, CSc.
KMOP MFF UK, Praha**

Prohlašuji, že jsem tuto práci vypracovala samostatně a pouze s použitím uvedené literatury. Souhlasím se zapůjčováním práce pro studijní účely.

Stanislava Kliegrová

Chtěla bych velmi poděkovat paní Doc. RNDr. Jaroslavě Kalvové, CSc., za odborné vedení mého doktorandského studia a za trpělivost a cenné připomínky při vypracovávání této disertační práce. Za výjimečnou trpělivost, kterou se mnou měli, musím také poděkovat své skvělé rodině, která se během mého studia rozrostla o dalšího člena (Martine, Pavlíku a Jakoubku, díky!).

Obsah

Úvod

1. Dlouhodobé předpovědi

1.1 Typy předpovědí podle metod

- 1.1.1 Statistické modely
- 1.1.2 Dynamické modely
- 1.1.3 Srovnání statistických a dynamických modelů

1.2 Typy předpovědí podle jejich formulace

1.3 Dlouhodobé předpovědi pro oblast Evropy

- 1.3.1 Evropské centrum pro střednědobé předpovědi počasí, Reading, U.K.
- 1.3.2 Mezinárodní výzkumný ústav pro klimatickou předpověď, USA
- 1.3.3 Meteorologická služba, Velká Británie
- 1.3.4 Český Hydrometeorologický Ústav, ČR

2. Popis statistických metod

2.1 Předzpracování dat

- 2.1.1 Analýza hlavních komponent
- 2.1.2 Shluková analýza

2.2 Sestavování modelů

- 2.2.1 Vícenásobná lineární regrese
- 2.2.2 Neuronové sítě

2.3 Vyhodnocování výsledků modelů

- 2.3.1 Brier Skill Score
- 2.3.2 Ranked Probability Skill Score
- 2.3.3 Linear Error in Probability Space score

3. Sestavování empirických modelů

3.1 Vstupní data a jejich zdroje

3.2 Předzpracování prediktorů

- 3.2.1 Korelace mezi měsíčními hodnotami NAO indexu a měsíčními teplotami v ČR
- 3.2.2 Korelace mezi řadami měsíčních teplot v ČR
- 3.2.3 Korelace mezi měsíčními hodnotami teplot povrchu oceánu a měsíčními hodnotami teplot v ČR

4. Empirické modely a jejich vyhodnocení

4.1 Výběr potenciálních prediktorů

4.2 Výsledky

4.2.1 Předpovědi průměrných lednových teplot

4.2.2 Předpovědi průměrných únorových teplot

4.2.3 Předpovědi průměrných březnových teplot

4.2.4 Předpovědi průměrných dubnových teplot

4.2.5 Předpovědi průměrných květnových teplot

4.2.6 Předpovědi průměrných červnových teplot

4.2.7 Předpovědi průměrných červencových teplot

4.2.8 Předpovědi průměrných srpnových teplot

4.2.9 Předpovědi průměrných zářijových teplot

4.2.10 Předpovědi průměrných říjnových teplot

4.2.11 Předpovědi průměrných listopadových teplot

4.2.12 Předpovědi průměrných prosincových teplot

4.3 Shrnutí výsledků nalezených modelů

5. Závěr

Literatura

Úvod

V poslední době jsou uživatelé stále více žádané předpovědi počasí na měsíc až několik měsíců dopředu. Podle definice Světové meteorologické organizace (the World Meteorological Organization, WMO) se předpovědi na více než třicet dní a méně než dva roky dopředu nazývají dlouhodobé předpovědi. Může se jednat o předpovědi průměrných hodnot meteorologických prvků na určitý měsíc (měsíční předpověď), na tříměsíční období (tříměsíční nebo 90-ti denní předpověď), nebo na definovanou sezónu (sezónní předpověď). Další informace o terminologii a definicích, které se vztahují k dlouhodobé předpovědi počasí, lze nalézt na webových stránkách WMO [1], jejíž adresa je uvedena na konci seznamu literatury.

Lze však vůbec předpovídat měsíční až sezónní hodnoty teplot a srážek (tedy jakési „průměrné počasí“) na měsíc až několik měsíců dopředu? Obecně „předpovídatelnější“ na delších časových škálách je průměrné počasí v těch oblastech světa, kde se projevuje velký vliv teploty povrchu oceánu (Sea Surface Temperature, SST) na stav atmosféry. Je to dáno tím, že oceány mají velkou tepelnou kapacitu, a teplotní anomálie povrchu tedy trvají delší dobu (řádově týdny). V případě vysokých korelací mezi hodnotami teploty povrchu oceánu a hodnotami meteorologických prvků je potom možno vydat odhad budoucího vývoje počasí.

Takovou oblastí jsou například tropy. Ve východním tropickém Pacifiku vzniká známý jev El Niño – Southern Oscillation (ENSO, viz například Kumar a kol., 2000, Neelin a kol., 1998), který svou intenzitou ovlivňuje současné i budoucí počasí ve všech tropických oblastech, v menším měřítku potom i v dalších částech světa (Ropelewski a Halpert, 1987, 1989). Vzhledem k tomu, že jev ENSO je v hlavních rysech možno namodelovat (Xu a Von Storch, 1990, Xue a kol., 1994), můžeme pro tyto oblasti dostat použitelnou předpověď průměrných hodnot teplot a srážek na základě znalosti hodnot SST, případně přímo hodnot indexu El-Niño (Hutchinson, 1992).

Ve vyšších zeměpisných šířkách je situace bohužel složitější. Korelace mezi hodnotami SST a průměrnými hodnotami teplot a srážek jsou menší, do hry vstupují atmosférické cirkulační systémy velkého měřítko, situaci „komplikuje“ rozložení kontinentů a mořských proudů.

Cílem této práce je shrnout dosavadní poznatky o dlouhodobé předpovědi počasí, s důrazem na dosažitelné informace pro oblast Evropy. Dále potom otestovat možnosti sestavení jednoduchých empirických modelů pro předpovědi klimatických anomálií pro středoevropskou oblast a vyhodnotit jejich prognostický potenciál pomocí vhodných verifikačních metod.

1 Dlouhodobé předpovědi

1.1 Typy předpovědí podle metod

Dlouhodobé předpovědi lze podle metod, kterými se získávají, rozdělit do dvou skupin: statistické a dynamické (neboli numerické).

1.1.1 Statistické modely

Obecně ve statistickém modelu předpokládáme, že můžeme použít předchozí, současné, nebo očekávané hodnoty (získané pomocí jiných, například dynamických, metod) určitých proměnných (prediktorů) k předpovědi budoucího stavu, nebo vývoje předpovídané proměnné (prediktandu), a to na základě nalezených matematických vztahů v řadě historických pozorování.

U většiny modelů pro statistické předpovědi sezónních klimatických anomálií jsou jako hlavní prediktor uvažovány hodnoty teplot povrchu oceánu (Sea Surface Temperatures, SST), ať již dříve naměřené či předpověděné. V literatuře můžeme najít popisy statistických modelů např. pro oblasti Sahelu (Thiaw a kol., 1999), východní Afriky (Mutai a kol., 1998), jižní Afriky (Landman a Mason, 1999), severovýchodní Brazílie (Uvo a kol., 1998), Austrálie (Casey, 1998), Evropy (Johansson a kol., 1998), USA (Barnston, 1994) a Kanady (Shabbar a Barnston, 1996). Větší prediktabilita je v oblasti tropického Pacifiku, ale mění se v závislosti na fázi ENSO (Kumar a kol., 2000). Jisté zlepšení předpovědí lze dosáhnout přidáním některých atmosférických prediktorů, např. hodnot výšky tlakových hladin 500 a 700 hPa (Hastenrath, 1995).

Přes skutečnost, že vzájemné vztahy jednotlivých složek klimatického systému jsou ve své podstatě nelineární, metody používané pro statistické sezónní předpovědi jsou zatím v drtivé většině lineární. S tím souvisí problém, že tyto metody nejsou schopny postihnout dlouhodobou variabilitu prediktandu.

Nejčastěji používané statistické techniky jsou regresní modely, především vícenásobná lineární regrese (Multiple Linear Regression, MLR) a kanonická korelační analýza (Canonical Correlation Analysis, CCA).

Používá se i diskriminační analýza (např. Osborn a Hulme, 1998), která patří mezi metody zabývající se zkoumáním závislostí mezi skupinou kvantitativních proměnných na jedné straně a jednou kvalitativní proměnnou na straně druhé. Vstupní data tedy představují hodnoty numerických proměnných zjištěných u souboru objektů (v tomto případě prediktorů) a hodnotu „klasifikační“ proměnné, která určuje příslušnost objektu do nějaké skupiny (v klimatologii často do kategorií nadnormální, normální, podnormální hodnoty prediktandu). Při samotné diskriminační analýze se potom snažíme najít diskriminační funkce, které nám usnadní klasifikaci do daných skupin. Takto získané funkce potom zpravidla používáme pro rozřazování nových objektů do skupin.

Podrobnější informace o výše zmíněných statistických metodách lze nalézt ve statistické literatuře (viz např. Meloun, Miličty, Hill, 2005; Wilks, 1995).

1.1.1 Dynamické modely

Pro klimatické předpovědi jsou v současné době používány dva typy numerických modelů: atmosférické cirkulační modely (Atmospheric General Circulation Models - AGCMs) a spřažené oceán-atmosféra cirkulační modely (Coupled General Circulation Models - CGCMs). Do AGCMs (Bengtsson, 1993, Hunt, 1997) vstupují SST jako okrajové podmínky, které následně působí na atmosféru, jejíž chování plně těmto podmínkám podléhá. V CGCMs se atmosféra i oceán vyvíjejí určitý čas nezávisle, a v určitých časových intervalech dochází v hraničních oblastech mezi atmosférou a oceánem k výměně informací. To je jedna z výhod CGCMs. Naopak nedostatkem CGCMs je, že pole SST se má tendenci s postupujícím časem integrace odchylovat od reálných hodnot, což potom způsobuje nereálné atmosférické anomálie. Toto „odchylování“ může probíhat rychle (způsobeno chybami v procesu asimilace dat), nebo pomaleji (způsobeno např. nedostatky v parametrizaci), viz například Delecluse, 1998.

Výsledky dynamických sezónních předpovědí mají charakter skupinových předpovědí (ensemblovou formu), tzn. že se jedná o řadu předpovědí pro stejné období. Jednotlivé členy skupinové předpovědi se mohou lišit svými okrajovými podmínkami, počátečními atmosférickými podmínkami, a/nebo fyzikálními parametrizacemi. Skupinové předpovědi vedou k pravděpodobnostně formulovaným sezónním předpovědím (viz 1.2).

Pro dosažení většího prostorového i časového rozlišení dynamických předpovědí, a pro korekci případných systematických nepřesností modelu, byla vyvinuta celá řada metod. Často používané jsou např. downscalingové metody (Osborn a Hulme, 1998, Wilby a Wigley, 1997).

1.1.2 Srovnání statistických a dynamických modelů

Detailní srovnání možností statistického a dynamického modelu jsou stále vzácné. Statistické předpovědi monzunových srážek v Indii jsou příkladem, kdy statistické modely překonávají modely dynamické (Hastenrath, 1995). Výsledky jednotlivých ansáblů dynamické předpovědi se pohybují v širokém rozmezí. Statistické modely mohou v podobném případě pomoci najít ty nejdůležitější atmosférické prediktory.

Pro oblast jižní Afriky se zdá být dynamický model o něco málo lepší než model statistický (Landman, 2001).

Velkou výhodou dynamických modelů je jejich nezávislost na existenci a na kvalitě historických dat. Výsledky nejsou zkrusleny nestacionaritou klimatu, mohou postihnout i extrémní hodnoty, které v řadě historických měření nebyly zaznamenány (a s kterými mají statistické modely problémy). Nevýhodou dynamických modelů jsou poměrně vysoké provozní náklady. Úspěšnost dynamických předpovědí se pro daný region liší pro různé sezóny a proměnné. Volba typu modelu nakonec záleží na možnostech (především toho kdo předpovědi produkuje) a potřebách (uživatele). Bylo by asi výhodné používat obě tyto metody paralelně

1.2 Typy předpovědí podle jejich formulace

Podle toho, jakým způsobem je předpověď formulována, mluvíme o následujících typech předpovědí:

Deterministické, které předpovídají, zda jev nastane nebo nenastane (např. „srážky budou/nebudou“);

Pravděpodobností, které předpovídají pravděpodobnost výskytu nějakého jevu (např. „pravděpodobnost výskytu srážek je XX %“);

Kontinuální, které předpovídají hodnoty v nějaké spojité škále (např. „maximální teplota bude YY °C“) nebo

Kategoriální, které předpovídají charakteristiky příslušnosti daného prvku do nějaké kategorie nebo intervalu hodnot (např. „letní den“, ale i „maximální teplota bude od A do B °C“).

Teoreticky mohou nastat tyto následující kombinace typů předpovědí:

- deterministická kategoriální („maximální teplota bude od X do Y °C“),
- deterministická kontinuální („napadne Z cm sněhu“),
- pravděpodobnostní kategoriální („pravděpodobnost výskytu letního dne je X%“),
- pravděpodobnostní kontinuální (předpokládaná distribuční funkce nebo hustota pravděpodobnosti).

V praxi mají dlouhodobé předpovědi většinou kategoriální podobu (deterministickou i pravděpodobnostní).

1.3 Dlouhodobé předpovědi pro oblast Evropy

1.3.1 Evropské centrum pro střednědobé předpovědi počasí (European Centre for Medium-Range Weather Forecasts, ECMWF), Reading, U.K.

Sezónní předpovědní systém se skládá z modelu oceánu založeného na modelu HOPE (Hamburg Primitive model), který odhaduje počáteční podmínky. Ty dále vstupují do spřaženého oceán-atmosféra cirkulačního modelu vyvinutého v Evropském centru pro střednědobé předpovědi počasí (dále jen ECMWF). Výsledky tohoto numerického modelu jsou potom zpracovány do výsledné podoby vhodnými post-processing postupy a jsou dostupné na webových stránkách tohoto centra v grafické formě pro tři následující, překrývající se, tříměsíční období. Internetovou adresu [2] lze nalézt na konci seznamu literatury. Kompetentní pracovníci Českého meteorologického ústavu mohou získat přístup i do archivu s číselnými daty. Předpovědi se aktualizují jednou měsíčně. Předpovídanými meteorologickými prvky jsou: teplota vzduchu ve 2 metrech, tlak vzduchu na hladině moře, množství srážek, hodnoty teplot povrchu oceánu (dále SST), teplota vzduchu v hladině 850 hPa, geopotenciální výška hladiny 500 hPa. Tyto prvky jsou v jednotlivých mapách charakterizovány ansámblovým průměrem; pravděpodobností, že jejich hodnoty budou větší než medián; pravděpodobností, s jakou budou hodnoty v dolním, středním a horním tercilu hodnot, a pravděpodobností, s jakou budou hodnoty v horním a dolním 15 % kvantilu (tedy pravděpodobnost extrémních hodnot). Ukázky těchto předpovědních map pro teplotu vzduchu ve 2 metrech lze najít v příloze (obr.1).

1.1.3 Mezinárodní výzkumný ústav pro klimatickou předpověď (International Research Institute for Climate Prediction, IRI), USA

Podobně jako v ECMWF (viz 1.1.3) jsou dlouhodobé předpovědi v tomto centru produkovány ve třech následných krocích. Nejprve jsou předpovězeny hodnoty teplot povrchu oceánu (dále SST), a to kombinací dynamických i statistických modelů. SST dále vstupují jako počáteční podmínky do třech cirkulačních modelů atmosféry, které byly vyvinuty ve třech různých předpovědních centrech (National Center of Environmental Prediction, Max Planck Institute a National Center Atmospheric Research). Výsledky jsou po následném statistickém zpracování, které se snaží vyloučit zejména systematické chyby, dostupné na webových stránkách (označené jako [3] na konci seznamu literatury) v grafické formě pro čtyři následující, překrývající se, tříměsíční období. Předpovědi se aktualizují jednou měsíčně. Předpovídanými meteorologickými prvky jsou: teplota vzduchu ve 2 metrech a množství srážek. Tyto prvky jsou v jednotlivých mapách charakterizovány pravděpodobností, s jakou budou hodnoty v dolním, středním a horním tercilu hodnot. Ukázku předpovědní mapy pro teplotu vzduchu ve 2 metrech uvádím v příloze (obr.2).

1.1.4 Meteorologická služba (MetOffice), Velká Británie

Na webových stránkách této služby se lze dočíst, že k sezónním předpovědím se používá stejný numerický model jako ke krátkodobým předpovědím. Tento model je však počítán na delší časový úsek (až šest měsíců), počítá se vzájemnými interakcemi mezi atmosférou a oceánem, a je pouštěn několikrát s malými změnami počátečních podmínek. Výsledky jsou dostupné na webových stránkách (označené jako [4] na konci seznamu literatury) v grafické formě pro tři následující, překrývající se, tříměsíční období. Předpovědi se aktualizují jednou měsíčně. Předpovídanými meteorologickými prvky jsou: teplota vzduchu ve 2 metrech a množství srážek. Tyto prvky jsou v jednotlivých mapách charakterizovány pravděpodobností hodnot prvků v jednotlivých tercilech. Ukázku předpovědní mapy pro teplotu vzduchu ve 2 metrech uvádím v příloze (obr.3).

Tato meteorologická služba zveřejňuje na svých webových stránkách i výsledky empirického modelu pro předpovědi letní teploty vzduchu pro oblast Evropy (adresa je označená jako [5] na konci seznamu literatury). Tato předpověď pravděpodobností jednotlivých tercilů teplot vzduchu vychází z SST anomálií v Severním Atlantiku v lednu a v únoru (Colman, Davey, 1997). Je vydávána v březnu a aktualizována v červenci, kdy jsou zohledněny ještě SST anomálie v Severním Atlantiku z března až června. Ukázku předpovědní mapy lze nalézt v příloze (obr. 4).

Pro úplnost uvádím ještě odkazy na dva zdroje, ze kterých lze také získat informace o dlouhodobých předpovědích pro oblast Evropy. Jedná se o webové stránky Klimatického předpovědního centra (Climate Prediction Center, CPC, USA, [6] na konci seznamu literatury) a Národního úřadu pro letectví a kosmonautiku (National aeronautics and space administration, NASA, [7] na konci

seznamu literatury). Pro tyto zdroje je však oblast Evropy spíše okrajovou záležitostí, což se projevuje například i nepravidelnou aktualizací předpovědí.

1.1.5 Český hydrometeorologický ústav (ČHMÚ), ČR

V rámci synoptické praxe jsou třikrát v měsíci produkovány měsíční předpovědi pomocí analogů, které předpovídají teploty a srážky (v kategoriích: nadnormální, normální, podnormální) pro následující měsíční období. Ukázka této předpovědi je na obrázku 5 v příloze. Od začátku roku jsou na webových stránkách pobočky ČHMÚ v Hradci Králové (označené jako [8] na konci seznamu literatury) zveřejňovány i dlouhodobé předpovědi, které vycházejí z předpovědí center ECMWF a IRI (viz 1.3.1 a 1.3.2). Ukázka je opět uvedena v příloze, na obrázku 6. V začátcích jsou experimenty s klimatickou verzí předpovědního modelu ALADIN, Aladin Climate.

2 Popis statistických metod

Data v této práci byla zpracována pomocí statistického softwaru STATISTIKA (StatSoft, Inc. (2001). STATISTICA Cz [Softwarový systém na analýzu dat], verze 6), který nabízí i níže popsané statistické metody.

2.1 Předzpracování dat

2.1.1 Analýza hlavních komponent (Principal Component Analysis, PCA)

Metoda analýzy hlavních komponent je jedna z nejvíce používaných metod vícerozměrné analýzy (Meloun, Militký, Hill, 2005; Wilks, 1995). Jejím hlavním cílem je především zjednodušení popisu skupiny vzájemně lineárně závislých neboli korelovaných znaků. Techniku lze popsat jako metodu lineární transformace původních proměnných na nové, nekorelované proměnné nazvané hlavní komponenty. Každá hlavní komponenta představuje lineární kombinaci původních proměnných. Základní charakteristikou každé hlavní komponenty je její míra variability čili rozptyl. Hlavní komponenty jsou seřazeny dle důležitosti, tj. dle klesajícího rozptylu, od největšího k nejmenšímu. Většina informace o variabilitě původních dat je přitom soustředěna do první komponenty a nejméně informace je obsaženo v poslední komponentě.

Standardním využitím PCA je snížení dimenze úlohy čili redukce počtu znaků bez velké ztráty informace, a to užitím pouze prvních několika hlavních komponent (Principal Components). Předpokládá se, že nevyužité hlavní komponenty obsahují malé množství informace, protože jejich rozptyl je příliš malý. Tato metoda je atraktivní také proto, že hlavní komponenty jsou nekorelované. Namísto vyšetřování velkého počtu původních znaků s komplexními vnitřními vazbami analyzuje uživatel pouze malý počet nekorelovaných hlavních komponent.

Matematicky řečeno, základním cílem PCA je transformace původních znaků x_j , $j=1, \dots, m$ do menšího počtu latentních proměnných y_j . Tyto latentní proměnné mají vhodnější vlastnosti: je jich výrazně méně, vystihují téměř celou proměnlivost původních znaků a jsou vzájemně nekorelované. Latentní proměnné jsou nazvány hlavními komponentami a jsou to lineární kombinace původních proměnných: první hlavní komponenta y_1 popisuje největší část proměnlivosti čili rozptylu původních dat, druhá hlavní komponenta y_2 zase největší část rozptylu neobsaženého v y_1 atd. První hlavní komponenta je tedy takovou lineární kombinací vstupních znaků, která pokrývá největší rozptyl mezi všemi ostatními lineárními kombinacemi.

2.1.2 Shluková analýza (Cluster analysis, CLU)

Analýza shluků (např. Meloun, Militký, Hill, 2005) patří mezi metody, které se zabývají vyšetřováním podobnosti vícerozměrných objektů (tj. objektů, u nichž je změřeno větší množství proměnných) a jejich klasifikací do tříd čili shluků. Hodí se zejména tam, kde objekty projevují přirozenou tendenci se seskupovat. Shluk je skupina objektů, jejichž vzdálenost (nepodobnost) je menší než vzdálenost, resp. nepodobnost, kterou mají objekty do shluku nepatřící. Meziobjektová podobnost

může být měřena rozličnými způsoby. Je také známo více postupů podle způsobu shlukování.

V této práci byla použita metoda nejbližších těžišť (K-Means), která poskytuje pouze jediné řešení pro zadaný počet požadovaných shluků. Její princip spočívá v rozdělení n objektů o m znacích do k shluků tak, že mezishluková suma čtverců je minimalizována. Počet shluků k musí být předem zadán uživatelem. Postup je založen na nejbližším těžišti, kdy je objekt zařazen do shluku s nejmenší vzdáleností mezi objektem a těžištěm shluku. Těžiště shluků byla určována iteračním výpočtem z dat. Z řady metod, které jsou k dispozici k výpočtu těžišť, byla vybrána strategie vybírající objekty, které mají velké vzdálenosti mezi sebou. Tyto hodnoty jsou použity jako počáteční odhady těžišť shluků. Algoritmus pracuje tak, že prvních k objektů v datech (kde k je počet požadovaných shluků) je vybráno jako dočasné těžiště. V následujících krocích nahradí objekt těžiště, když jeho nejmenší vzdálenost k těžišti bude větší než vzdálenost mezi dvěma nejbližšími těžišti. Těžiště, které je bližší k objektu, je pak vyměněno. Objekt se dosadí na místo těžiště, když vzdálenost z objektu k těžišti je větší než nejmenší vzdálenost mezi těžištěm a všemi ostatními těžišti. Znovu se vymění těžiště nejtěsnější k němu. Počáteční přiblížení ovlivňuje konečné uspořádání shluků. Proto algoritmus pro každý pokus zcela náhodně přiřazuje každý objekt jednomu shluku. Toto uspořádání je pak optimalizováno. Start procesu z rozličných náhodných uspořádání velmi zvýší pravděpodobnost nalezení nejlepšího řešení. Kritérium věrohodnosti čili těsnosti proložení je uvedeno např. v Meloun, Militký, Hill, 2005.

2.2 Sestavování modelů

2.2.1 Vícenásobná lineární regrese (Multiple Linear Regression, MLP)

Vícenásobná lineární regrese je jedna z nejčastěji používaných metod pro analýzu časových řad (např. von Storch and Zwiers, 1999).

Předpokládáme, že závisle proměnná y je jednoznačně určena funkcí r ($r > 1$) nezávisle proměnných x_1, x_2, \dots, x_r což lze zapsat jako

$$y = \varphi(x_1, x_2, \dots, x_r). \quad (2.2.1)$$

Pro daný vektor $\mathbf{x}^T = (x_1, x_2, \dots, x_r)$ dostaneme jedinou hodnotu proměnné y . V důsledku působení náhodných činitelů má však závisle proměnná povahu náhodné veličiny s určitým rozdělením pravděpodobnosti. Dále předpokládejme, že podmíněná střední hodnota veličiny Y pro dané hodnoty x_1, x_2, \dots, x_r je rovna:

$$E(Y | x_1, x_2, \dots, x_r) = f(x_1, x_2, \dots, x_r; \beta_1, \dots, \beta_p), \quad (2.2.2)$$

Tj. je funkcí x_1, x_2, \dots, x_r a p ($p \geq 1$) parametrů β_1, \dots, β_p . Funkce (2.2.2) se nazývá regresní funkce a parametry β_1, \dots, β_p regresní parametry (nebo koeficienty).

Funkci f uvažujeme ve tvaru:

$$f = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k. \quad (2.2.3)$$

V tomto vztahu jsou x_1, x_2, \dots, x_k nenáhodné (fixní) proměnné. Platí tedy $r = p = k+1$.

Máme-li n vektorů pozorování $(Y_i, x_{0i}, x_{1i}, \dots, x_{ki})^T, i = 1, \dots, n$, můžeme z nich nalézt odhady regresní funkce f v daném bodě $\mathbf{x}^T = (x_0, x_2, \dots, x_k)$.

Pro fixní proměnné x (a funkce ve tvaru (2.2.3)) lze rovnici (2.2.2) přepsat:

$$Y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + e,$$

kde e je náhodná odchylka. (2.2.4)

K určení parametrů $\beta_0, \beta_1, \dots, \beta_k$ se nejčastěji používá metoda nejmenších čtverců. Mějme n náhodných veličin Y_1, Y_2, \dots, Y_n , které se dají vyjádřit jako lineární funkce $k+1$ regresních parametrů $\beta_0, \beta_1, \dots, \beta_k$. Veličiny e_1, e_2, \dots, e_n jsou náhodné chyby, tj.:

$$Y_i = f_i + e_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + e_i, i = 1, \dots, n. \quad (2.2.5)$$

Kromě tohoto předpokladu je nutné splnění několika podmínek (viz například . Hebák, Hustopecský, 1987).

Popsaný postup umožňuje určit koeficienty regresního modelu, neřeší však otázku, jak vybírat vhodné prediktory. Často se setkáváme s problémem, jak z velkého počtu vysvětlujících proměnných vybrat omezenou množinu do regresního modelu. Jedním z postupů, jak to řešit, je kroková regrese, popsaná například Kennedym a Gentlem (1980).

Krokovou regresi lze popsat následujícími kroky:

- 1) Vybere se prediktor nejvíce korelovaný s prediktandem.
- 2) Sestrojí se všechny regresní modely v nichž se postupně vždy po jednom přidávají k již dříve vybraným prediktorům všechny ostatní potenciální prediktory. Pro každý potenciální prediktor se určuje hladina významnosti, na které se přijímá hypotéza o jeho nulovosti.
- 3) Vybere se prediktor s nejmenší hladinou významnosti určenou v bodě 2. Pokud je tato hodnota menší než zvolená kritická hodnota, je tento prediktor přidán k dříve vybraným prediktorům. V opačném případě je výběr u konce.
- 4) Sestrojí se regresní model s vybranými veličinami. Pro všechny regresní parametry se určí hladina významnosti, na které nelze vyloučit hypotézu o jejich nulovosti. Pokud je maximální hodnota větší než zvolená hodnota, je odpovídající prediktor vyřazen. Poté se sestrojí nová regresní rovnice se zbylými prediktory a znovu se celý postup opakuje tak dlouho, dokud lze nějaký prediktor vyloučit.
- 5) Pokud je počet prediktorů menší než požadovaný počet, pokračuje se znovu bodem 2.

V popsaném postupu je kritériem pro výběr regresorů test nulové hodnoty regresních koeficientů. Jsou ale možné i jiné přístupy. Je možné vypustit krok zpětného vyřazování nebo zvolit postup, při němž se zvolené veličiny pouze vyřazují z regresního modelu.

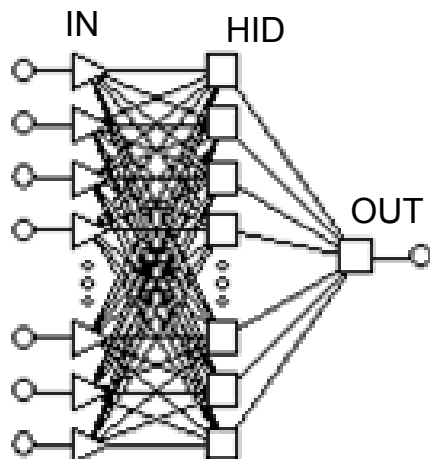
V softwaru byla při sestavování lineárního regresního modelu na všechny potenciální prediktory aplikována kroková regrese popsaná výše. Hypotézy byly zamítnuty na 5% hladině významnosti.

2.2.2 Neuronové sítě (NN)

Neuronové sítě (NN) patří k tzv. nedeklarativním systémům umělé inteligence a slouží především k sestavování statistických modelů ve značně komplexních systémech, kde nelze dostatečně spolehlivě odhalit charakter vazeb uvnitř systému. Nedeklarativní jsou v tom smyslu, že kromě dat není třeba do modelu zadávat žádné další informace o předpokládaném tvaru závislosti mezi nezávisle a závisle proměnnými, jako je tomu např. při použití metod regresní analýzy nebo expertních systémů, které ke své práci potřebují "databázi znalostí". Inteligencí je zde myšlena především schopnost modelu zachytit a vhodným způsobem kvantifikovat obecné vlastnosti dat a vztahů mezi nimi a naopak potlačit vazby, které se vyskytují sporadicky nebo nejsou dostatečně spolehlivé a pevné. Přitom tato kvantifikace vychází pouze z vlastností samotných dat. Jedním z nejvýznamnějších rysů neuronových sítí je jejich schopnost "učit se" jak z charakteru samotných dat, tak i z vlastních chyb při snaze zachytit vztah mezi nezávisle a závisle proměnnými. V současné době je dostupná celá řada literatury o neuronových sítích a jejich aplikacích, například Haykin, 1999.

V současnosti existuje celá řada typů neuronových sítí. Některé z nich jsou vhodné pro řešení úloh regresního typu, jiné např. pro klasifikační úlohy. Výběr optimálního typu sítě přitom může být důležitý z hlediska kvality výsledků. Pro usnadnění výběru vhodného typu sítí byly vyvinuty i některé algoritmy, které jsou schopny postupným testováním jednotlivých typů sítí výběr do značné míry optimalizovat, aniž by bylo nutné provádět manuálně celou řadu experimentů.

Neuronové sítě principiálně vycházejí z funkce skutečných neuronů v biologických nervových systémech a i terminologie je touto skutečností poměrně výrazně ovlivněna. Umělé neuronové sítě jsou konstruovány z řady elementů (neuronů), které jsou, podobně jako biologické neurony, vzájemně propojeny tzv. synapsemi. Každý neuron má svoji prahovou hodnotu. V umělých neuronových sítích jsou často neurony organizovány v tzv. vrstvách (viz obr. 2.2.1). Synapse pak zajišťují tok signálu mezi neurony. Každá synapse v umělých neuronových sítích má právě jeden vlastní parametr, tzv. váhu synapse.



Obr.2.2.1: Schéma umělé neuronové sítě. IN=neurony vstupní vrstvy, HID=neurony skryté vrstvy, OUT=neuron výstupní vrstvy.

Neuron jako základní prvek neuronové sítě pak plní tři základní úkoly: agregaci vstupních signálů, prahování a nelineární (v nejjednodušším případě možno i lineární) transformaci. Zpracování signálu v jednotlivých neuronech probíhá podle následujícího schématu:


- Ve fázi agregace vstupních signálů dochází k zobrazení vektoru vstupních signálů na skalární signál. Nejjednodušeji můžeme toto zobrazení realizovat jako vážený průměr výstupních signálů z neuronů předchozí vrstvy, přičemž pro vážení se použijí přímo váhy příslušných synapsí.
- Ve fázi prahování se porovná skalární signál s vnitřním parametrem neuronu - tzv. prahovou hodnotou. Nejjednodušší variantou je odečtení prahové hodnoty neuronu od skalárního signálu.
- Ve fázi transformace se prahovaný skalární signál transformuje pomocí vhodné nelineární (lineární) transformační funkce na výstupní signál. Obvykle používané transformační funkce zajišťují, že při nízké hodnotě prahovaného signálu je na výstupu z neuronu signál blízký jeho pasivnímu stavu (0) a pro rostoucí hodnoty prahovaného signálu výstupní signál monotónně roste až do jisté saturované hodnoty (1 - aktivní stav neuronu). Takovým typem nelineární transformace je např. často používaná sigmoidální transformace ve tvaru:

$$y = \frac{1}{1 + e^{-x}} \quad (2.2.3)$$

V této práci byly použity následující dva typy sítí:

Vícehladinová perceptronová síť (Multilayer perceptron neural network, MLP, např. Hsieh, Tang, 1998), u které byla v neuronech vstupní vrstvy použita lineární transformace, v neuronech skryté a výstupní vrstvy potom transformace nelineární (konkrétně sigmoidální). Dodatečně jsem zjistila, že nastavením jiného druhu transformace do výstupní vrstvy lze jako výstup získat přímo pravděpodobnosti jednotlivých kategorií (Bishop, 1995; Bridle, 1990). Jedná se o softmax funkci, tedy exponenciální funkci ($y = e^{-x}$) s výsledky normalizovanými tak, že součet aktivací v dané vrstvě je 1.

Lineární síť (Linear neural network), která má pouze dvě vrstvy. Na neuronech obou vrstev byly použity lineární transformace.



Obr.2.2.2: Schéma lineární neuronové sítě, která má jen 2 vrstvy IN=neurony vstupní vrstvy, OUT=neurony výstupní vrstvy.

Samotné zpracování dat pomocí neuronové sítě probíhá ve třech základních fázích; organizační, adaptační a aktivační.

V organizační fázi je třeba určit počet výkonných prvků (neuronů), jejich uspořádání a strukturu vzájemného propojení (synapsí).

V adaptační fázi dochází k vlastnímu procesu učení (tréninku) sítě. Obecně je každý trénink sítě založen na poměrně jednoduchém principu. Síť se nejprve inicializuje, zpravidla náhodně (tj. náhodně se nastaví váhy všech synapsí a prahové hodnoty neuronů). Na vstup do sítě se pak vloží vektor nezávisle proměnných. Síť jako celek zobrazí tento vektor do prostoru závisle proměnných, následně je vyhodnocen rozdíl mezi skutečnými hodnotami závisle proměnných a výstupem sítě (tj. chyba, s jakou síť zobrazuje data). Nakonec se mírně upraví volné parametry sítě tak, aby se chyba tohoto zobrazení snížila. Vzhledem k iterativní adaptaci parametrů sítě je zpravidla nutné tento krok učení sítě opakovat mnohokrát, aby se zobrazení, produkované sítí, stabilizovalo a aby síť jako celek zobrazovala vstupní data s co nejnižší chybou. Často je tak nutné použít k učení sítě data z celého souboru opakovaně, v několika stovkách nebo tisících cyklů. Konkrétní hodnoty volných parametrů vytrénované sítě pak reprezentují zkušenosti, uložené do sítě v procesu učení. Existuje celá řada algoritmů, zajišťujících učení sítě právě tímto způsobem. Jedním z nejnámějších

je tzv. BEP (Back-error propagation, tedy algoritmus zpětného šíření chyby), který byl použit i pro MLP sítě v tomto případě. Bližší informace lze nalézt v literatuře, např. v manuálu pro software STATISTICA .

V aktivační fázi jsou pak vektory nezávisle proměnných zobrazovány sítě jako celkem do prostoru závisle proměnných. Signál, přivedený na vstupní neurony se postupně šíří sítí a prochází soustavou lineárních a nelineárních transformací. Výsledkem procesu je vznik signálu na výstupních neuronech. Tato fáze se uplatňuje jak při testování funkce sítě, tak i pro odhady hodnot závisle proměnných.

Užití neuronových sítí má svá úskalí, dvě z nich považuji za nutné zdůraznit. Prvním z nich je optimální odhad komplexnosti sítě v organizační fázi. Neuronové sítě často pracují s daty nepřesnými, ovlivněnými šumem nebo vlivy, které nemají obecnou platnost. Podobně jako u ostatních regresních metod, příliš komplexní neuronová síť regresního typu umožňuje, aby se parametry sítě a v nich uložené zkušenosti adaptovaly i na tyto vlivy. Funkce naučené sítě je tím pochopitelně nepříznivě ovlivněna. Tento jev se v teorii neuronových sítí nazývá přetrénování sítě a je velice podobný tzv. přeparametrizování regresní závislosti, kdy je odhadováno příliš mnoho volných parametrů, takže zbývá málo stupňů volnosti. Příliš jednoduchá síť naopak může shlazovat i některé obecné charakteristiky závislosti dat. Je tedy zřejmé, že správný odhad komplexnosti sítě je velice důležitým předpokladem korektního použití této metodiky. Často používaným postupem, který má zabránit přetrénování sítě, je metoda tzv. křížové validace, kdy se datový soubor dělí, často náhodně, na dvě podmnožiny. První z nich, tzv. tréninková, je použita k vlastnímu učení sítě v adaptační fázi, druhá (testovací) k nezávislému testování sítě. Nárůst chyby sítě při zpracování testovacího souboru v aktivační fázi je zpravidla jasným signálem přetrénování. V tom případě je třeba zjednodušit síť a snížit počet volných parametrů sítě, např. odstraněním některých neuronů ve skrytých vrstvách nebo i celých vrstev. Druhou možností je ukončení procesu učení v okamžiku, kdy se začnou projevovat příznaky přetrénování.

Pro hledání níže podrobněji popsaných empirických modelů byl využit software STATISTICA Neural Networks 4.0, který obsahuje Intelligent Problem Solver pro automatický výběr optimálního typu sítě. Jako nejlepší typ sítě se jevil typ Multilayer perceptron neural network (MLP), u nás se překládá jako vícehladinová perceptronová síť (např. Hsieh, Tang, 1998). Při sestavování empirických modelů pomocí neuronových sítí bylo patrné, že velmi limitujícím faktorem je malý počet dat, který umožňoval vyzkoušet danou metodu opravdu jen na neuronových sítích jednoduché struktury (s malým počtem skrytých neuronů v jediné vrstvě).

V použitém softwaru STATISTICA Neural Networks 4.0 byl datový soubor rozdělen náhodně na tři podmnožiny (tréninková, verifikační, testovací), a to v poměru $\frac{1}{2}$, $\frac{1}{4}$, $\frac{1}{4}$. Je samozřejmě možné použít i jiné poměry dělení, použitý postup je však zcela standardní a v naprosté většině úloh zcela vyhovující. Uživatel dále určí množinu potenciálních prediktorů (nezávislých, vysvětlujících proměnných) a prediktand (závislou, vysvětlovanou proměnnou). Software se snaží najít takovou síť (model), který co nejlépe „umí“ pomocí nezávislých proměnných určit závislou proměnnou. Síť je sestavena a trénována podle

tréninkových dat, optimalizována vzhledem k vývoji chyby verifikačního datasetu, a nakonec je k nezávislému zhodnocení použit do té doby zcela vynechaný testovací dataset. Výběr optimálního typu a architektury sítě probíhal automaticky pomocí nástroje Intelligent Problem Solver, který testoval i možnosti různých kombinací potenciálních prediktorů (viz níže, 3.3). Výsledkem hledání byla tabulka 10 nejlepších nalezených sítí, tedy sítí s nejmenší chybou tréninkových datasetů. Nejlepší sítě (ve všech případech, kromě jedné lineární sítě, typu MLP) byly dále trénovány. Sítě MLP pomocí algoritmu zpětného šíření chyby (BEP, viz výše), aby se zjistil jejich sklon k přetrénování. Lineární síť byla trénována pomocí pseudo-inverzní techniky, která přímým výpočtem a bez nutnosti iterativního postupu optimalizuje váhy na výstupní vrstvě a minimalizuje chybu RMSE (Root Mean Squared Error, viz např. Wilks, 1995) tréninkového datasetu. Vytrénovaná síť s nejlepšími parametry byla uložena. Postupně byly po jednom vynechávány případy od 1. do 37., síť byla bez tohoto jednoho případu znovu vytrénována, a výsledek vynechaného případu byl takto modifikovanou sítí dopočítán. Tyto výsledky byly použity pro validaci modelů.

2.3 Vyhodnocování výsledků modelů

Metody validace, tedy vyhodnocení úspěšnosti předpovědi, jsou různé a závisí na typu předpovědi (viz 1.2). Této poměrně složité problematice jsem věnovala podstatnou část článku v Meteorologických zprávách (Kliegrová, 2003). Nejčastěji jsou sezónní předpovědi formulovány jako pravděpodobnostní, což souvisí s ansámblovým charakterem dynamických předpovědí (viz 1.1 a 1.3). Velmi propracovaný systém validace má centrum ECMWF (viz 1.3.1). Některá centra se spokojují jen se slovní diskuzí a popisem rozdílů mezi mapami předpovědními a pozorovanými (IRI, 1.3.2). Pokud se týče časopisecké literatury, která se věnuje problematice dlouhodobých předpovědí a jejich validace, nejčastěji jsem narazila na použití následujících dvou charakteristik: Brier Skill Score a Ranked Probability Skill Score (CLIVAR Exchanges No.32, No.33). Jedná se o skill (v angličtině znamená úspěšný, šikovný) skóre, která se snaží postihnout, o kolik je testovaný předpovědní model lepší než předpověď pomocí jednoduchých předpovědních strategií (předpověď pomocí klimatologických hodnot, náhodných hodnot, perzistentní předpověď). Skill skóre (obecně formuluje např. Wilksovi, 1995) je interpretováno jako procentuální zlepšení právě oproti takové jednoduché předpovědní strategii (referenční předpovědi). V této práci se však jedná o modely empirické, jejichž výsledky jsou formulovány deterministicky a kategoriálně (viz 1.2.). Jako hlavní srovnávací charakteristika bylo proto použito Linear Error in Probability Space (LEPS) score (viz 2.3.3). Teprve dodatečně jsem zjistila možnost, jak v případě sítí s kategoriálním výstupem získat jako výsledek přímo pravděpodobnost jednotlivých kategorií. Proto bylo možno použít k vyhodnocení a porovnání některých sítí i Ranked Probability Skill Score (RPSS, viz 2.3.2).

2.3.1 Brier Skill Score

Brier (nebo half Brier) score (dále označené BS) je zřejmě nejběžnější používané skóre pro pravděpodobnostní předpovědi (Wilks, 1995). V níže

uvedené formě platí pouze pro kategoriální pravděpodobnostní předpovědi pro dvě kategorie, a sice jev A nastal, jev A nenastal:

$$BS = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2, \quad (2.3.1)$$

kde x_i , $i=1\dots n$, je řada n předpověděných pravděpodobností, a y_i , $i=1\dots n$, je odpovídající řada n pravděpodobností pozorovaných hodnot ($y=1$ pokud jev nastal, $y=0$ pokud jev nenastal). Toto skóre vlastně vyjadřuje střední kvadratickou chybu pravděpodobnostních předpovědí. Hodnoty BS se pohybují od 0 po 1 včetně ($0 \leq BS \leq 1$). Perfektní předpověď má Brier score rovno 0, méně přesné předpovědi mají vyšší hodnoty score. Například pokud předpovíme, že jev, který opravdu nastal, nastane s 60% pravděpodobností, je $BS = (0.6-1)^2 = 0.16$

Skill score odpovídající Bier score můžeme spočítat:

$$SS = \frac{BS - BS_{ref}}{BS_{perf} - BS_{ref}} = 1 - \frac{BS}{BS_{ref}}, \quad (2.3.2)$$

když BS_{ref} je Brier score pro srovnávací (referenční) předpovědní strategii (například předpověď pomocí klimatologických hodnot) a pro bezchybnou předpověď platí $BS_{perf} = 0$.

2.3.2 Ranked Probability Skill Score

Ranked Probability Score (RPS) se stejně jako Brier score používá pro vyhodnocování kategoriálních pravděpodobnostních předpovědí, jejichž výsledky však mohou patřit do více než dvou kategorií. Kvadratická chyba je počítána vzhledem ke kumulativní pravděpodobnosti (Wilks, 1995):

$$RPS = \sum_{m=1}^J (X_m - Y_m)^2, \quad (2.3.3)$$

kde X_m, Y_m jsou kumulativní pravděpodobnosti předpovědí a pozorování pro J kategorií.

Kumulativní pravděpodobnosti jsou definovány následovně:

$$X_m = \sum_{i=1}^J x_i, \quad m = 1, \dots, J, \quad (2.3.4)$$

a

$$Y_m = \sum_{i=1}^J y_i, \quad m = 1, \dots, J, \quad (2.3.5)$$

kde x_i , $i=1\dots n$, je řada n předpověděných pravděpodobností, a y_i , $i=1\dots n$, je odpovídající řada n pravděpodobností pozorovaných hodnot ($y=1$ pokud jev nastal, $y=0$ pokud jev nenastal). Bezchybná předpověď by měla RPS rovno nule.

Použití tohoto skóre může být ilustrováno na následujícím příkladě:

Nechť předpověď teploty vzduchu je následující: 20% pravděpodobnost podnormální teploty ($x_1 = 0.2$), 40% pravděpodobnost teploty kolem normálu ($x_2 = 0.4$), a 40% pravděpodobnost teploty podnormální ($x_3 = 0.4$). Při pozorování byla naměřena teplota podnormální ($y_1 = 0, y_2 = 0, y_3 = 1$).

Podle výše uvedených vztahů spočteme $X_1 = x_1 = 0.2, X_2 = x_1 + x_2 = 0.6, X_3 = x_1 + x_2 + x_3 = 1, a Y_1 = y_1 = 0, Y_2 = y_1 + y_2 = 0, Y_3 = y_1 + y_2 + y_3 = 1$.

Dosazením do definice pro Ranked Probability score (rovnice (2.3.3))

$$RPS = \sum_{m=1}^J (0.2 - 0)^2 + (0.6 - 0)^2 + (1 - 1)^2 = 0.76,$$

dostaneme:

Skill score odpovídající Ranked Probability score (RPSS) můžeme spočítat:

$$RPSS = 1 - \frac{RPS}{RPS_{ref}}, \quad (2.3.6)$$

kde RPS_{ref} obdržíme dosazením 33% pravděpodobnosti do každé kategorie. Perfektní předpověď by měla $RPSS=1$. Pokud je $RPSS$ negativní, je předpověď horší než předpověď náhodná (pravděpodobnosti v jednotlivých kategoriích jsou stejné).

2.3.3 Linear Error in Probability Space (LEPS) score

Linear Error in Probability Space (LEPS) score může být v zásadě použito pro zhodnocení předpovědí kontinuálních i kategoriálních proměnných (Potts a kol., 1996).

Předpokládejme, že perfektní předpověď by měla skóre a . Pokud by předpověď nebyla zcela stoprocentní, bylo by skóre a zmenšeno v závislosti na rozdílu mezi pozicí pozorované hodnoty v distribuční funkci P_v a pozicí této pozorované hodnoty v předpovědní distribuční funkci P_f . Hodnoty P_v a P_f se pohybují mezi 0 a 1. Toto skóre bychom potom mohli zapsat jako:

$$S = a - |P_f - P_v| \quad (2.3.7)$$

Druhou derivací S získáme normalizovanou a upravenou verzi LEPS score. Matematické podrobnosti lze nalézt v (Potts a kol., 1996).

V níže uvedené tabulce 2.3.1 uvádím verzi LEPS score optimalizovanou pro kategoriální předpovědi v klimatologii (hodnoty budou nadnormální, normální, nebo podnormální), která byla získána spočtením očekávaných skóre pro každou kombinaci pozorovaných a předpověděných kategorií. Čísla z této tabulky používáme při vyhodnocování kategoriálních předpovědí jako váhy, což bude ukázáno v následujícím příkladě. Jak je možné si všimnout, LEPS score penalizuje víc tzv. větší chyby (tedy předpověď nadnormální v případě, že skutečnost byla podnormální, a naopak).

Tab. 2.3.1 Verze LEPS score optimalizovaná pro tři kategorie. PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

Pozorování	Předpověď		
	NN	N	PN
NN	0.89	-0.11	-0.78
N	-0.11	0.22	-0.11
PN	-0.78	-0.11	0.89

Předpokládejme, že výsledky předpovědi byly obecně vyhodnoceny takto:

Pozorování	Předpověď		
	NN	N	PN
NN	a	b	c
N	d	e	f
PN	g	h	i

LEPS score je definováno:

$$LEPS = \frac{(a \times 0.89) + (b \times -0.11) + (c \times -0.78) + \dots + (g \times -0.78) + (h \times -0.11) + (i \times 0.89)}{((a + b + c) \times 0.89) + ((d + e + f) \times 0.22) + ((g + h + i) \times 0.89)} \times 100\%$$

(2.3.8)

Použití LEPS score si můžeme ilustrovat na konkrétním příkladě. Předpokládejme, že naše předpovědi teploty vzduchu byly vyhodnoceny tak, jak je uvedeno v tabulce 2.3.2.

Tab. 2.3.2 Příklad vyhodnocení předpovědi teploty vzduchu. PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

Pozorování	Předpověď		
	NN	N	PN
NN	8	3	1
N	2	5	5
PN	2	5	6

Čísla z definiční tabulky pro LEPS score (tab. 2.3.1) použijeme jako váhy, a konkrétní hodnotu LEPS score pro náš příklad vypočteme dosazením do obecného vzorce (2.3.8) takto:

$$LEPS = \frac{(8 \times 0.89) + (3 \times -0.11) + (1 \times -0.78) + \dots + (2 \times -0.78) + (5 \times -0.11) + (6 \times 0.89)}{(12 \times 0.89) + (12 \times 0.22) + (13 \times 0.89)} \times 100\%$$

$$LEPS = 38\%$$

Všimněme si, že 100% úspěšné předpovědi by měly LEPS rovno 1, LEPS score náhodných předpovědí by se mělo pohybovat kolem 0.

3 Sestavování empirických modelů

3.1 Data a jejich zdroje

Prediktand

Zdrojem průměrných měsíčních teplot vzduchu (dále jen měsíční teploty) ze stanic v ČR za období 1961 až 1999 je databáze Českého hydrometeorologického ústavu. Celé naše území bylo popsáno jedinou teplotní řadou, která byla sestavena na základě výsledků lineární regrese mezi hodnotami teplot v jednotlivých měsících a nadmořskou výškou z údajů ze cca 30 stanic, které jsou uvedeny v příloze v tabulce 1. Horské stanice Churáňov, Lysá hora, Praděd byly po předchozím testování vyloučeny. Regresní křivky byly spočteny pro každý měsíc každého roku zvlášť, a z nich byla odečtena hodnota pro nadmořskou výšku 400 metrů. Regresní závislosti (mezi teplotami a nadmořskou výškou) byly statisticky významné na 5% hladině významnosti kromě 3 případů (leden 1964, leden 1971, leden 1982), což by se zřejmě dalo vysvětlit zvýšeným výskytem inverzních situací.

Prediktory

Zdrojem měsíčních hodnot teplot povrchu Atlantiku v gridových bodech (v síti $2 \times 2^\circ$) za období 1961 až 1999 byl National Center for Atmospheric Research (NCAR). Internetová adresa tohoto zdroje je uvedena jako [9] na konci seznamu literatury).

Zdrojem měsíčních hodnot NAO (North Atlantic Oscillation) indexů za období 1961 až 1999 byl Climate Prediction Center (CPC), který na svých webových stránkách (označeny jako [10] na konci seznamu literatury) zveřejňuje indexy 14 oscilačních systémů. Hodnoty standardizovaných hodnot indexů telekonexí jsou získávány pomocí rotované analýzy hlavních komponent aplikované na pole anomálií geopotenciálních výšek hladiny 700 hPa, kterou popisují Barnston a Livezey, 1987. Pro úplnost dodávám, že NAO je jeden z nejvýraznějších oscilačních systémů, který je definován ve všech sezónách, nejvýrazněji v zimě (Marshall a kol., 2001). Jde o bipolární propojení s jedním centrem v oblasti Grónska a druhým centrem opačného znaménka v centrálních šířkách severního Atlantiku mezi 35 a 40° N. Toto propojení přitom signalizuje i částečnou statistickou vazbu mezi akčními centry v severním Atlantiku (Islandskou tlakovou níží a Azorskou tlakovou výší), neboť typické polohy obou center NAO jsou prakticky totožné s polohou těchto akčních center. Různé fáze NAO jsou spojeny i s různými polohami a intenzitou severoatlantického jet-streamu a s různými podmínkami zonálního i meridionálního transportu tepla a vlhkosti, což může ovlivnit charakter teplotního i srážkového pole v oblasti od východu USA po západní a částečně i střední Evropu.

3.2 Předzpracování prediktorů

Vybrat relevantní prediktory z daného velkého množství prediktorů potenciálních nebylo jednoduché. Vztahy mezi nimi a měsíčními hodnotami teplot v ČR byly nejprve zkoumány pomocí korelačního koeficientu, který vyjadřuje míru lineární závislosti mezi proměnnými. Konkrétně byl použit výběrový Pearsonův korelační koeficient, který je definován následujícím způsobem:

$$r(x, y) = \frac{s(x, y)}{s(x) \cdot s(y)}, \quad (3.2.1)$$

kde $s(x, y)$ je výběrová kovariance, $s(x)$, $s(y)$ jsou směrodatné odchylky a \bar{x} , \bar{y} jsou průměrné hodnoty proměnných X a Y .

$$s(x, y) = \frac{1}{n-1} \sum_{i=1}^n (x(i) - \bar{x})(y(i) - \bar{y}) \quad (3.2.2)$$

$$s(y) = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y(i) - \bar{y})^2} \quad (3.2.3)$$

$$s(x) = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x(i) - \bar{x})^2} \quad (3.2.4)$$

3.2.1 Korelace mezi měsíčními hodnotami NAO indexu a měsíčními teplotami v ČR

V tabulce 3.2.1 jsou uvedeny korelační koeficienty mezi měsíčními hodnotami NAO indexu a řadami měsíčních teplot v České republice za období 1961-1999. Statisticky významné korelace (jsou tučně zvýrazněné) byly zjištěny mezi zimními hodnotami NAO indexu (prosinec, leden, březen) a stejnými měsíčními teplotami v ČR. Nejvyšší korelační koeficient 0,66 byl zjištěn mezi lednovými NAO indexy a lednovou teplotou u nás. Statisticky významná závislost byla zjištěna i mezi letními NAO indexy (konkrétně pro červen, srpen, září) a odpovídajícími měsíčními teplotami v ČR. Tyto informace však nemají pro případný prognostický potenciál valný význam. Dále se objevily statisticky významné korelační koeficienty mezi březnovými (červencovými) NAO indexy a květnovými (zářijovými) teplotami u nás (tedy korelace „přes jeden měsíc“). Objevily se i statisticky významné vazby mezi NAO indexy a „vzdálenějšími“ měsíčními teplotami v ČR (například vyšší hodnota NAO indexu v únoru, naznačuje možnost vyšších srpnových teplot v ČR). Právě tyto řady NAO indexů s vysokými korelačními koeficienty budou brány jako potenciální prediktory v sestavovaných předpovědních modelech pro měsíční teploty v České republice. Statisticky významné koeficienty jsou až na jednu výjimku všechny kladné.

Tab. 3.2.1 Hodnoty korelačních koeficientů mezi řadami měsíčních NAO indexů a měsíčními řadami teplot v České republice (šedá část tabulky pro měsíce v témže roce, bílá část srovnává NAO indexy s teplotami z roku následujícího). T1 (T2,...,T12) je označení pro řady lednových (únorových,..., prosincových) teplot. Analogicky jsou číslem označeny i příslušné měsíční řady NAO indexů.

	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
NAO 1	0,66	0,07	0,27	0,27	0,03	-0,28	-0,12	0,13	0,05	-0,01	-0,27	-0,04
NAO 2	0,09	0,20	0,21	-0,19	-0,04	-0,19	0,13	0,38	0,08	-0,04	-0,05	-0,08
NAO 3	0,38	0,20	0,38	0,00	0,41	0,12	-0,04	0,23	-0,04	0,02	-0,10	0,36
NAO 4	0,08	-0,14	0,17	-0,03	-0,18	-0,17	0,12	-0,09	-0,09	-0,17	0,21	-0,03
NAO 5	-0,06	0,19	-0,07	0,06	-0,15	0,17	0,24	0,15	0,20	0,00	0,27	-0,12
NAO 6	-0,28	0,20	-0,20	-0,21	-0,28	0,35	-0,13	-0,21	-0,05	-0,06	0,26	-0,16
NAO 7	0,20	0,20	-0,18	-0,21	-0,14	0,00	0,26	0,21	0,34	-0,03	0,39	-0,08
NAO 8	0,01	0,18	0,11	-0,08	0,09	0,03	-0,01	0,34	-0,07	-0,15	-0,04	-0,05
NAO 9	0,21	0,08	-0,14	0,23	-0,20	0,13	-0,08	0,00	0,46	-0,05	0,06	0,11
NAO 10	-0,30	-0,23	-0,23	-0,02	-0,33	0,17	-0,19	-0,28	-0,19	0,15	0,03	-0,06
NAO 11	0,04	0,06	0,04	-0,14	-0,08	0,23	-0,03	0,06	0,15	-0,23	0,23	0,11
NAO 12	0,21	0,08	0,29	0,06	-0,18	-0,31	0,35	0,09	0,42	0,05	-0,28	0,42

3.2.2 Korelace mezi řadami měsíčních teplot v ČR

V tabulce 3.2.2 jsou uvedeny korelační koeficienty mezi řadami měsíčních teplot v ČR za období 1961-1999. Statisticky významné korelace (jsou tučně zvýrazněné) byly zjištěny mezi zimními měsíčními teplotami (prosinec, leden, únor) a březnovou teplotou. Řady ze stejných měsíců korelují i s listopadovými teplotami, jen s opačným znaménkem. Jinými slovy, pokud jsou měsíční teploty u nás v zimě nižší, mohly by být nižší i v březnu, a v listopadu naopak vyšší. Nejvyšší korelační koeficient byl zjištěn mezi zářijovou a následně dubnovou teplotou (+0,49). Předcházející řady měsíčních teplot, které mají statisticky významné korelace s tou řadou měsíčních teplot v ČR, pro kterou budu hledat předpovědní model, budou zařazeny mezi potenciální prediktory.

Tab. 3.2.2 Hodnoty korelačních koeficientů mezi řadami měsíčních teplot v ČR (šedá část tabulky pro měsíce v témže roce, bílá část srovnává teplotní řady v řádku s teplotami ve sloupci z roku následujícího). T1 (T2,...,T12) je označení pro řady lednových (únorových,..., prosincových) teplot.

	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
T1	1,00	0,27	0,35	0,06	0,03	-0,17	-0,00	0,31	-0,02	-0,11	-0,38	0,07
T2	0,45	1,00	0,36	0,13	0,09	0,06	-0,09	0,20	-0,05	0,12	-0,37	0,23
T3	0,28	0,06	1,00	-0,16	-0,03	0,04	-0,26	0,26	0,19	-0,11	-0,10	0,22
T4	-0,07	-0,19	-0,33	1,00	0,13	0,08	0,17	-0,06	0,08	0,34	-0,11	-0,18
T5	0,12	-0,02	0,11	-0,13	1,00	0,22	0,39	0,29	-0,12	0,14	-0,11	0,20
T6	0,08	0,22	-0,19	-0,15	-0,31	1,00	0,03	-0,09	0,06	0,03	0,32	-0,15
T7	0,21	-0,04	-0,07	-0,10	0,04	0,13	1,00	0,18	-0,02	0,28	-0,01	-0,23
T8	0,24	0,13	0,01	0,26	0,07	-0,21	0,37	1,00	0,10	-0,34	-0,06	0,14
T9	0,34	0,11	-0,17	0,49	0,10	0,08	0,27	0,11	1,00	0,04	-0,04	0,06
T10	-0,21	-0,28	0,01	-0,06	-0,10	-0,04	0,01	-0,15	-0,18	1,00	-0,03	-0,28
T11	-0,18	-0,04	-0,33	-0,17	-0,08	0,05	0,16	-0,06	0,10	-0,21	1,00	-0,39
T12	0,41	0,27	0,38	0,17	0,05	-0,26	-0,03	0,01	0,02	0,14	-0,45	1,00

3.2.3 Korelace mezi měsíčními hodnotami SST a měsíčními hodnotami teplot v ČR

Zpracování korelačních koeficientů mezi řadami měsíčních hodnot povrchu Atlantiku (SST) a řadami měsíčních teplot v České republice T (i časově posunutými, kdy SST předchází T) pro ČR bylo provedeno za období 1961 až 1990.

Korelační koeficienty byly vypočteny pro řady hodnot SST v jednotlivých gridových bodech Atlantiku mezi 0°N a 59.5°N (v síti 2x2°) v programu CLIMLAB 2000 (Version 1.0. Copyright (C) 1999 International Research Institute for Climate Prediction), který byl volně přístupný na webových stránkách IRI. Korelační koeficienty byly dále zpracovány v programu STATISTICA.

V prvé řadě mě zajímalo, teploty kterých oblastí povrchu oceánu vykazují statisticky významné korelační koeficienty s teplotou vzduchu u nás. Problémem bylo najít metodu, která by trochu zpřehlednila velké množství informací. K dispozici jsem měla 132 tabulek korelačních koeficientů. Pro každou měsíční řadu T to bylo 11 tabulek, kdy každá tabulka obsahovala korelační koeficienty mezi touto řadou T a řadami průměrných měsíčních (postupně s posunem -1 až -11 měsíců) hodnot SST v každém gridovém bodě. Například pro řadu lednových teplot v ČR byly postupně zjišťovány korelační koeficienty s řadami prosincových hodnot SST (1.tabulka) v jednotlivých gridových bodech, s řadami listopadových hodnot SST (2.tabulka), až s řadami únorových hodnot SST (11.tabulka). Chtěla jsem vysledovat případný vliv změn hodnot SST jednotlivých částí oceánu na teplotu v ČR. Proto další zpracování probíhalo následovně: ze všech 11 tabulek, které obsahovaly korelační koeficienty s řadou lednových teplot u nás, byly vybrány ty gridové body, pro které se aspoň v jedné tabulce objevila statisticky významná korelace na 5% hladině významnosti (pro tento rozsah souboru je to hodnota korelačního koeficientu větší než +0,36 nebo menší než -0,36). Pro tyto gridové body byly vypsány řady korelačních koeficientů ze všech 11 tabulek, které vlastně popisují časový vývoj korelace mezi SST v daném gridovém bodě a lednovou teplotu v ČR. Stejný postup byl aplikován na všechny řady měsíčních teplot u nás. Stále však zůstával problém, jak se vyznat i v tomto omezenějším množství dat, a jakým způsobem je interpretovat.

Vyzkoušela jsem metodu shlukové analýzy (viz 2.1.2), která měla rozdělit oceán do jednotlivých oblastí (shluků), ve kterých by průběh korelačních koeficientů mezi řadami SST (s posunem -1 až -11 měsíců od měsíční teploty T u nás) a řadou dané měsíční teploty T byl podobný. Byla zvolena metoda K-means Clustering, která rozdělila hodnoty SST do k shluků (k je předem zadáno, v rozmezí mezi 8 a 12 pro všechny měsíce) tak, aby byla minimalizována variabilita hodnot korelačních koeficientů uvnitř shluku, a naopak maximalizována variabilita hodnot korelačních koeficientů mezi shluky. Výsledkem je 12 map (pro každou řadu měsíčních teplot T u nás jedna), na kterých jsou zakresleny jednotlivé shluky různými barvami, a je u nich poznačeno, s kterou měsíční řadou hodnot SST byl zaznamenán nejvyšší (nebo nejnižší) korelační koeficient. Jednotlivé shluky jsou popsány ještě podrobně v 12 tabulkách (nejsou uvedeny), kde je pro každý z 11 sloupců, který představuje výsledky lineární regrese mezi T a řadou SST z měsíce s daným posunem (-1 až -11), uveden průměr, medián, minimum, maximum korelačních koeficientů.

Mapy korelačních koeficientů mezi měsíčními hodnotami SST a měsíčními hodnotami teplot v ČR

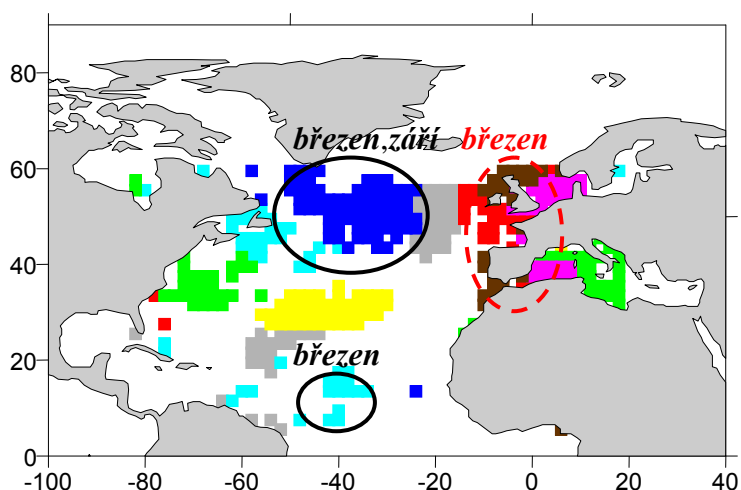
Výsledky postupu uvedeného v předcházející části této kapitoly 3.2.3 jsou znázorněny ve 12 mapách, pro každou měsíční řadu teplot v České republice v jedné mapě. Jednotlivé shluky, ve kterých se korelační koeficienty mezi hodnotami měsíčních teplot v ČR daného měsíce a hodnotami teplot povrchu oceánu z 1. až 11. předcházejících měsíců „chovají“ podobně, jsou barevně odlišeny. Dále jsou zakroužkovány oblasti, ve kterých byly zaznamenány maximální hodnoty korelačních koeficientů (červená přerušovaná čára) a minimální hodnoty (černá plná čára). U těchto oblastí je uvedeno, s kterou měsíční řadou hodnot SST bylo těchto extrémních hodnot korelačních koeficientů dosaženo.

V zajímavých případech, kdy se jeví souvislost mezi měsíčními hodnotami NAO indexů, teplotami povrchu Atlantiku v určitých oblastech a následně i teplotami v ČR, jsou uvedeny ještě pro porovnání mapy korelačních koeficientů mezi měsíčními řadami hodnot NAO indexů a teplot povrchu oceánu (SST), kdy NAO předchází SST. Označeny jsou oblasti statisticky významných kladných (červeně, šrafované) a záporných (modře, nešrafované) korelačních koeficientů.

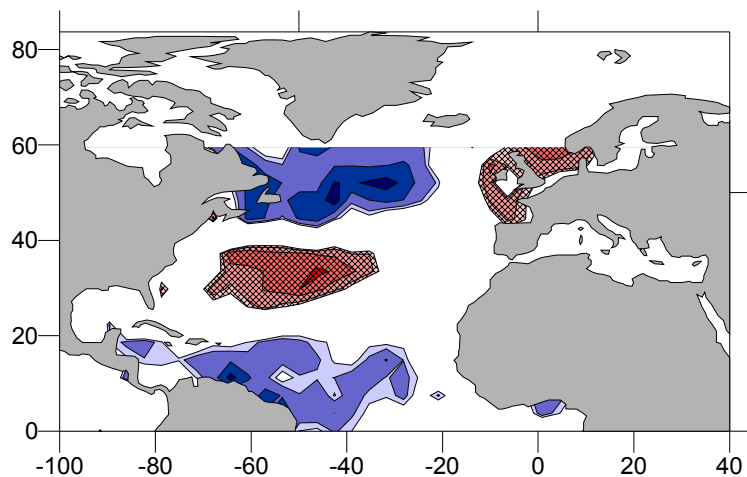
Leden

Pokud se objevily záporné anomálie měsíčních hodnot teplot povrchu oceánu (SST) v oblasti kolem New Foundlandu a Grónska v průběhu března, a září a října, znamenalo to kladné anomálie teploty v České republice v lednu (obr. 3.2.1). Pokud se podíváme podrobněji na tabulku popisující jednotlivé shluky (tabulka 2 v příloze), vidíme, že nejvýraznějších záporných hodnot korelačních koeficientů (-0,54) je dosaženo v oblasti pod Grónskem pro březnové hodnoty SST. Největší kladné korelační koeficienty byly zaznamenány v oblasti u břehů západní a severní Evropy pro březnové hodnoty SST (až +0.62). V podobných oblastech oceánu pod Grónskem a u severní Evropy nacházíme statisticky významnou korelaci hodnot březnových NAO indexů a březnových hodnot SST (obr.3.2.2). Oblast pod Grónskem se potom objevuje i na mapě korelací mezi hodnotami březnových NAO indexů a zářijových SST (obr.3.2.3). Mezi březnovými hodnotami NAO indexu a teplotou v ČR v následujícím lednu je korelační koeficient +0,38 (tab. 3.2.1). Zjištěné skutečnosti potvrzují souvislosti mezi měsíčními hodnotami NAO indexů a SST v jistých oblastech Atlantiku (konkrétně v březnu). Zajímavé je, že tytéž oblasti se jeví „důležité“ i pro vývoj lednových teplot v ČR. Tato zjištěná fakta jsem se pokusila využít při sestavování empirického modelu pro předpověď lednových teplot u nás (viz 4.2.1).

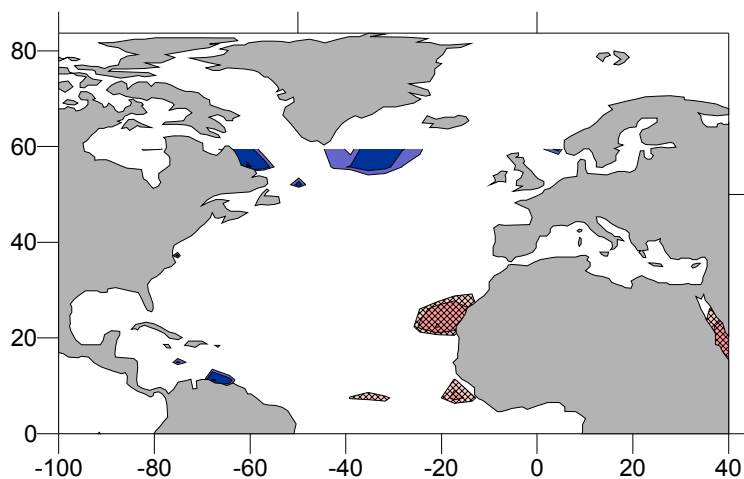
Obr. 3.2.1 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a lednovou teplotou v ČR



Obr. 3.2.2 Mapa statisticky významných korelačních koeficientů mezi březnovými hodnotami NAO indexů a březnovými hodnotami SST Atlantiku



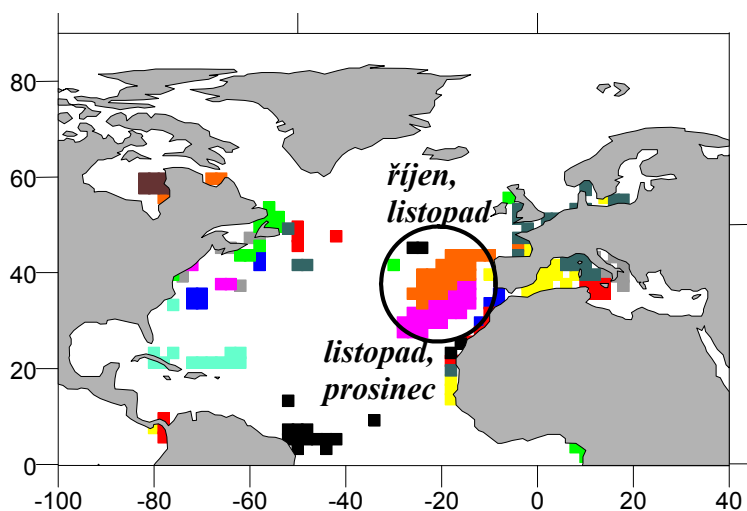
Obr. 3.2.3 Mapa statisticky významných korelačních koeficientů mezi březnovými hodnotami NAO indexů a zřijovými hodnotami SST Atlantiku



Únor

Oblasti významných korelačních koeficientů mezi řadami měsíčních hodnot SST a řadou únorových teplot v ČR na této mapě (obr. 3.2.4) by zřejmě mohly být časově posunuté oblasti anomálií z oblasti pod Islandem (viz obr. 3.2.1) ve směru proudění Kanárského proudu. Největší korelační koeficienty záporného znaménka (až -0.54) se objevují pro říjnové až prosincové SST v oblasti u Pyrenejského poloostrova. Teploty povrchu Atlantiku právě z této oblasti se jeví jako použitelný prediktor pro hledaný předpovědní model únorových teplot v ČR (viz 4.2.2).

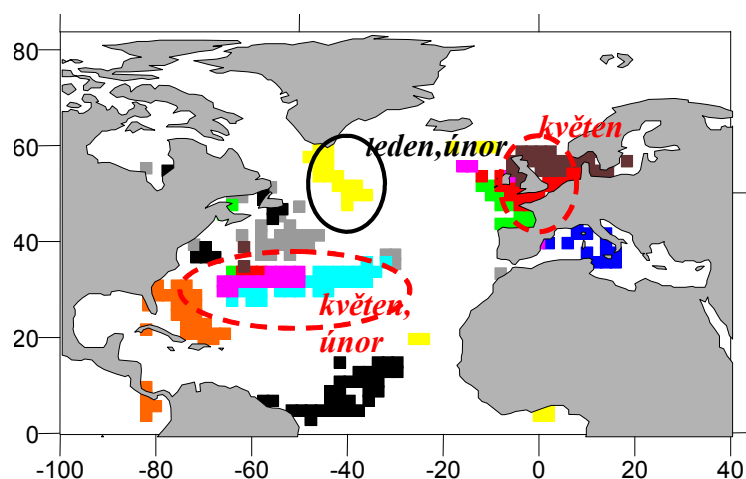
Obr. 3.2.4 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a únorovou teplotou v ČR



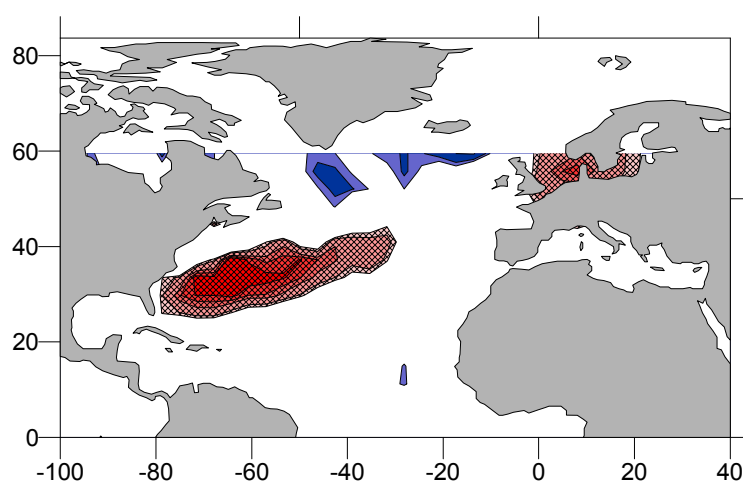
Březen

Mapa korelačních koeficientů mezi měsíčními teplotami povrchu oceánu (SST) a březnovou teplotou v ČR (obr. 3.2.5) ukazuje tři oblasti, kde se vyskytly extrémní korelační koeficienty (až $+0.55$ a -0.53) mezi lednovými, únorovými, květnovými SST a březnovými teplotami v ČR. Obdobné oblasti vidíme i na mapě korelací mezi hodnotami NAO indexů v lednu a únorových hodnot SST (obr.3.2.6). Opět tedy vidíme stejné oblasti oceánu, jejichž únorová teplota souvisí jednak s lednovými NAO indexy a potom s březnovou teplotou v ČR. Přímá statisticky významná vazba mezi lednovými NAO indexy a březnovou teplotou u nás se však tentokrát neukázala (viz tabulka 3.2.1, kde je korelační koeficient mezi NAO1 a T3 jen 0,27. Hodnoty SST ze zde vyznačených oblastí byly zařazeny mezi potenciální prediktory hledaných předpovědních modelů pro březnovou teplotu v ČR (viz 4.2.3).

Obr. 3.2.5 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a březnovou teplotou v ČR



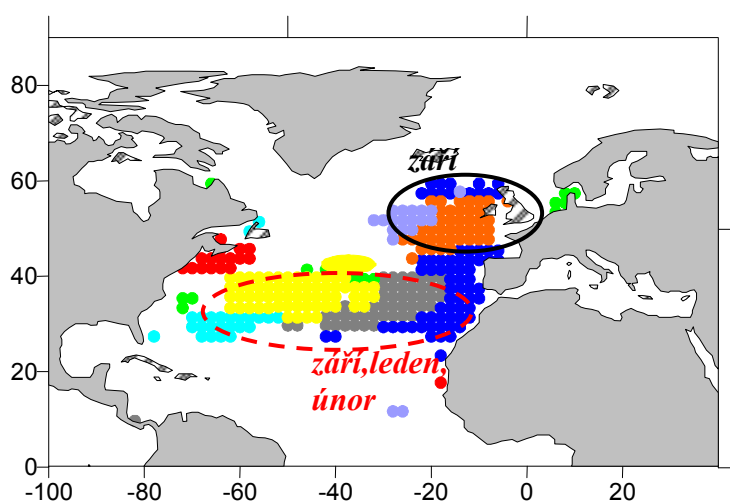
Obr.3.2.6 Mapa statisticky významných korelačních koeficientů mezi lednovými hodnotami NAO indexů a únorovými hodnotami SST Atlantiku



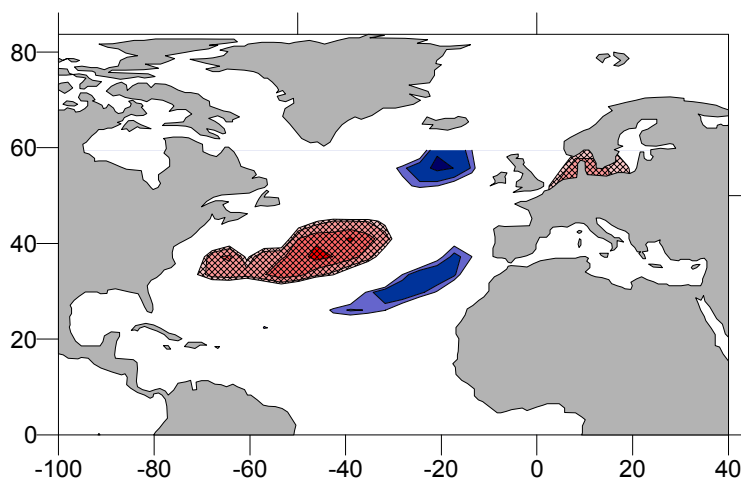
Duben

Na této mapě korelačních koeficientů mezi měsíčními teplotami povrchu oceánu (SST) a dubnovými teplotami v ČR (obr.3.2.7) můžeme vidět dipól korelací zářijových SST s dubnovými teplotami u nás (až -0.51 a $+0.64$). Podobné rozložení můžeme vidět na mapě korelací mezi zářijovými NAO indexy a zářijovými SST (obr.3.2.8). Zářijové hodnoty SST ze zde vyznačených oblastí byly zařazeny mezi potenciální prediktory hledaných předpovědních modelů pro dubnovou teplotu v ČR (viz 4.2.4).

Obr. 3.2.7 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a dubnovou teplotou v ČR



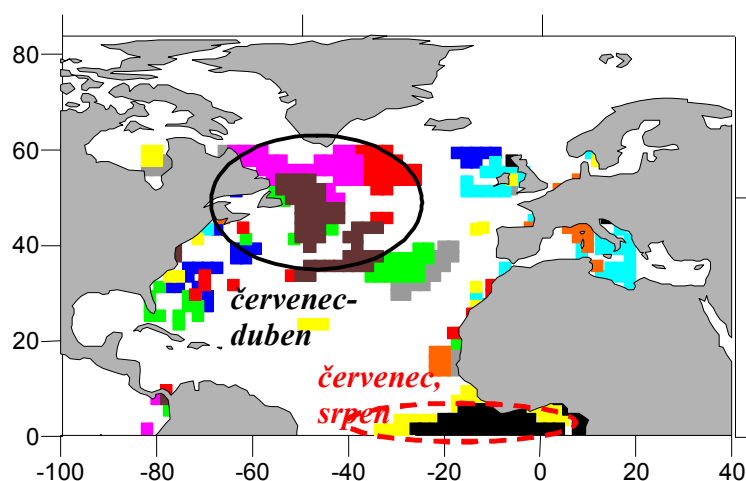
Obr. 3.2.8 Mapa statisticky významných korelačních koeficientů mezi zářijovými hodnotami NAO indexů a zářijovými hodnotami SST Atlantiku



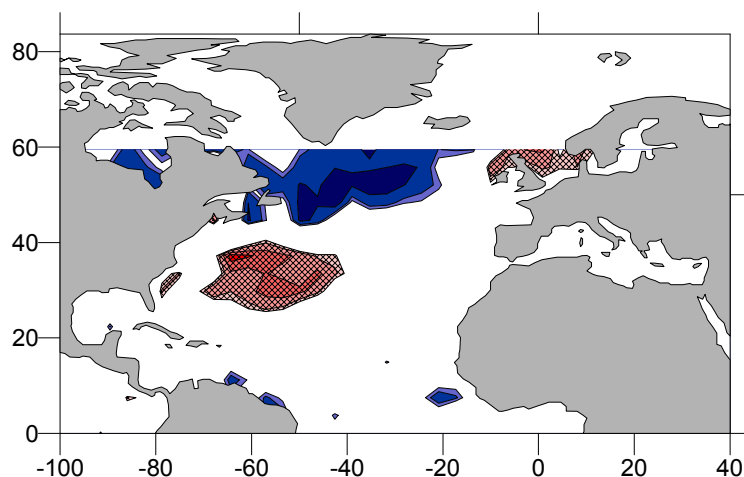
Květen

Květnová teplota v ČR koreluje s rozsáhlou oblastí červencových až dubnových SST (obr. 3.2.9). Podobnou oblast nacházíme také na mapách korelací březnových hodnot NAO indexů s dubnovými hodnotami SST (obr. 3.2.10). Za zmínku stojí ještě oblast vysokých korelací především s hodnotami červencových až říjnových SST u pobřeží rovníkové Afriky, kterou můžeme vidět i na mapě korelací březnových NAO indexů s červencovými a srpnovými hodnotami SST (i když posunutou na jih), obr.3.2.11. Hodnota korelačního koeficientu přímo mezi březnovými NAO indexy a květnovými teplotami u nás je +0.41 (viz tab. 3.2.1). Mezi potenciální prediktory pro předpovědní model květnových teplot v ČR budou zařazeny lednové a červencové hodnoty SST z hnědé oblasti a červencové hodnoty z černé oblasti.

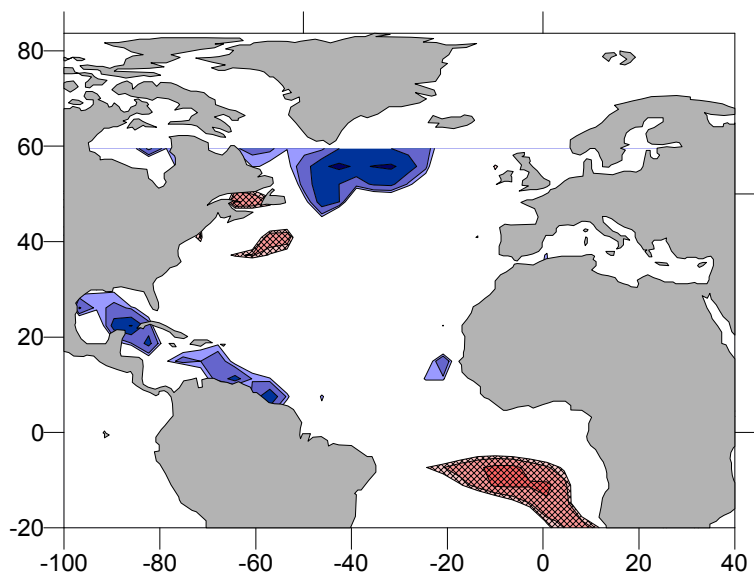
Obr. 3.2.9 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a květnovou teplotou v ČR



Obr. 3.2.10 Mapa statisticky významných korelačních koeficientů mezi březnovými hodnotami NAO indexů a dubnovými hodnotami SST Atlantiku



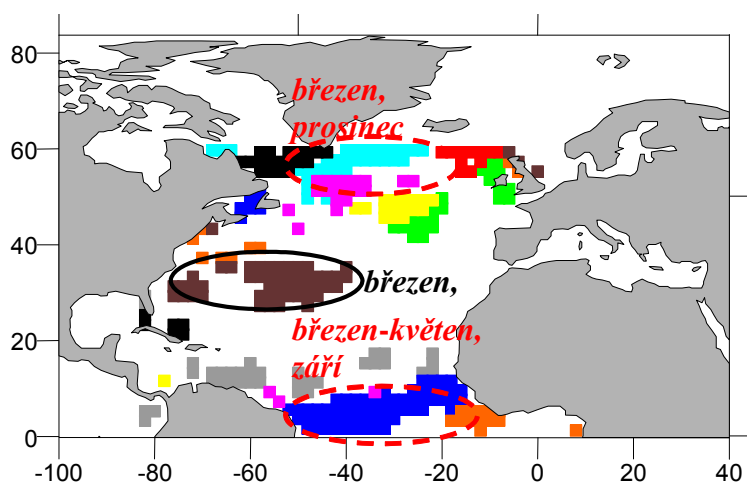
Obr. 3.2.11 Mapa statisticky významných korelačních koeficientů mezi březnovými hodnotami NAO indexů a červencovými hodnotami SST Atlantiku



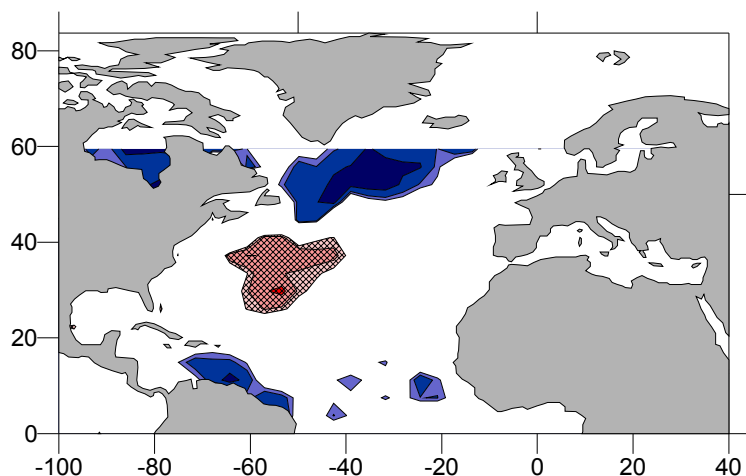
Červen

Na mapě shluků korelačních koeficientů červnových teplot v ČR s měsíčními hodnotami SST (obr.3.2.12) vidíme tři oblasti význačných korelací (až +0,41 a -0,45) mezi březnovými až květnovými SST (oblast kladných korelací pod Grónskem, oblast záporných korelací ve středním Atlantiku, a kladnou oblast v rovníkovém Atlantiku). Světle modrá oblast obsahuje význačné korelační koeficienty i pro prosincové hodnoty SST (až +0,43) a tmavě modrá pro zářijové hodnoty SST (až -0,57). Tato mapa ukazuje podobné rozložení jako mapa pro lednovou teplotu. Podobné rozložení těchto oblastí vidíme i na mapě korelací březnových NAO indexů a březnových až květnových SST (ale s opačným znaménkem), postupně obr. 3.2.2, 3.2.10, 3.2.13. Prosincové hodnoty SST ze světle modré oblasti, březnové hodnoty SST z hnědé oblasti a zářijové hodnoty z tmavě modré oblasti byly zařazeny mezi potenciální prediktory hledaných předpovědních modelů pro červnovou teplotu v ČR (viz 4.2.6).

Obr. 3.2.12 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a červnovými teplotami v ČR



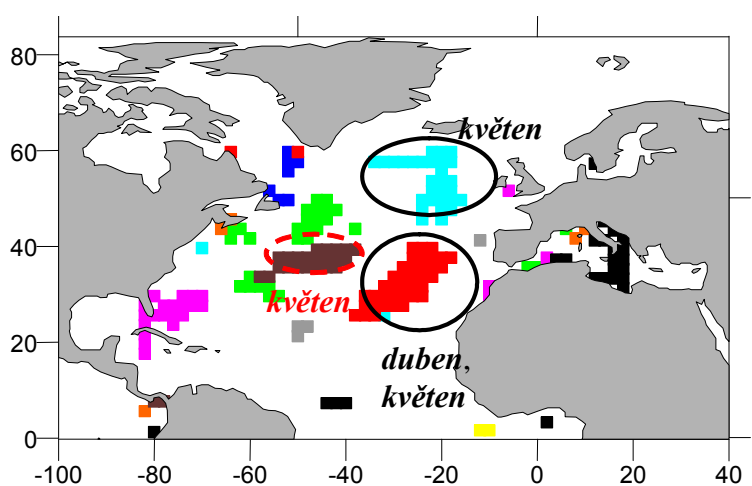
Obr. 3.2.13 Mapa statisticky významných korelačních koeficientů mezi březnovými hodnotami NAO indexů a květnovými hodnotami SST Atlantiku



Červenec

Mapa korelací mezi měsíčními hodnotami teploty povrchu oceánu (SST) a červencovou teplotou v ČR (obr. 3.2.14) ukazuje pouze nevelké, rozdrobené oblasti význačných korelací (obr.3.2.14). Do předpovědních modelů pro červencové teploty v ČR budou přidány jako potenciální prediktory zářijové hodnoty SST ze světle modré a červené oblasti (viz 4.2.7).

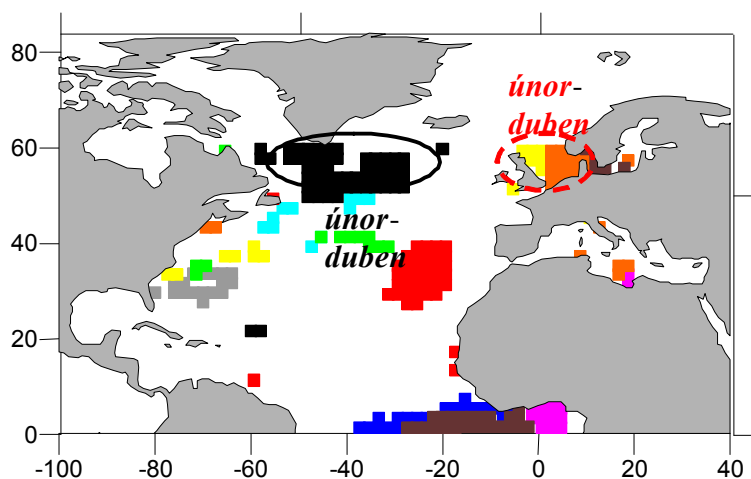
Obr. 3.2.14 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a červencovou teplotou v ČR



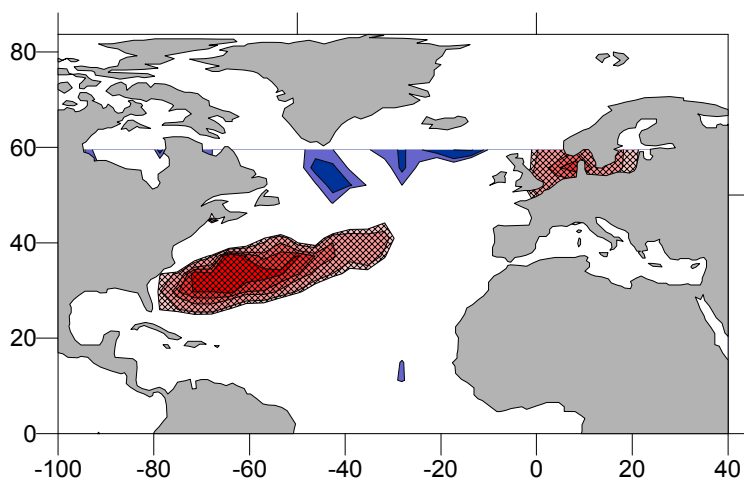
Srpen

Mapa korelačních koeficientů mezi SST a srpnovou teplotou v ČR (obr.3.2.15) ukazuje výraznou negativní korelaci (až -0.55) mezi únorovými až dubnovými SST v severním Atlantiku a teplotou v ČR, a výraznou kladnou korelaci (až $+0.52$) SST v témže období u Skandinávie a teplotou v ČR. To koresponduje s prací Colmana a Daveyho (1997), kteří právě na tomto poznatku založili statistické předpovědi pro letní teploty vzduchu v Anglii (viz 1.3.3). Podobné rozložení vidíme na mapách korelací mezi lednovými NAO indexy a SST v lednu, v únoru (obr. 3.2.16); březnovými NAO indexy a březnovými SST (obr.3.2.2). Přímou mezi únorovým NAO indexem a srpnovou teplotou v ČR je také poměrně vysoká korelace ($+0.38$). Dubnové hodnoty SST z obou na mapě ohraničených oblastí budou zahrnuty jako potenciální prediktory do hledaných předpovědních modelů pro hodnoty srpnových teplot v České republice (viz 4.2.8).

Obr. 3.2.15 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a srpnovou teplotou v ČR



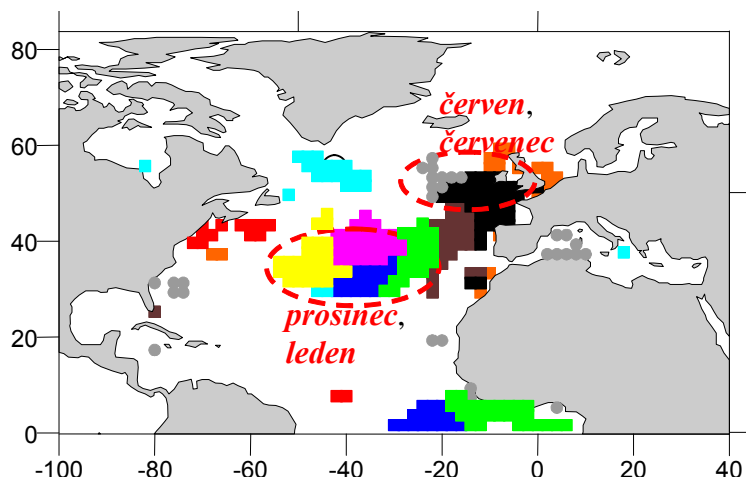
Obr.3.2.16 Mapa statisticky významných korelačních koeficientů mezi lednovými hodnotami NAO indexů a únorovými hodnotami SST Atlantiku




Září


Teplota v září v ČR je kladně korelovaná se zimními (prosinec, leden) SST v oblasti centrálního Atlantiku (obr. 3.2.17). Podobnou oblast najdeme i na mapě korelací mezi prosincovými hodnotami NAO indexu a lednovými hodnotami SST (obr.3.2.18). Dále můžeme na obr. 3.2.17 rozlišit oblast kladných korelačních koeficientů červnových a červencových SST u Britských ostrovů se zářijovou teplotou u nás, stejnou oblast jako na mapě korelací mezi červencovými hodnotami NAO indexu a červencovými hodnotami SST (obr. 3.2.19). Přímou mezi prosincovými, respektive červencovými indexy NAO, a zářijovou teplotou v ČR jsou také vysoké kladné korelace (+0.42; +0.34). Některé měsíční hodnoty SST z ohraničených oblastí budou použity při sestavování předpovědních modelů pro zářijové teploty v ČR (viz 4.2.9).

Obr. 3.2.17 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a zářijovou teplotou v ČR



Obr. 3.2.18 Mapa statisticky významných korelačních koeficientů mezi prosincovými hodnotami NAO indexů a lednovými hodnotami SST Atlantiku



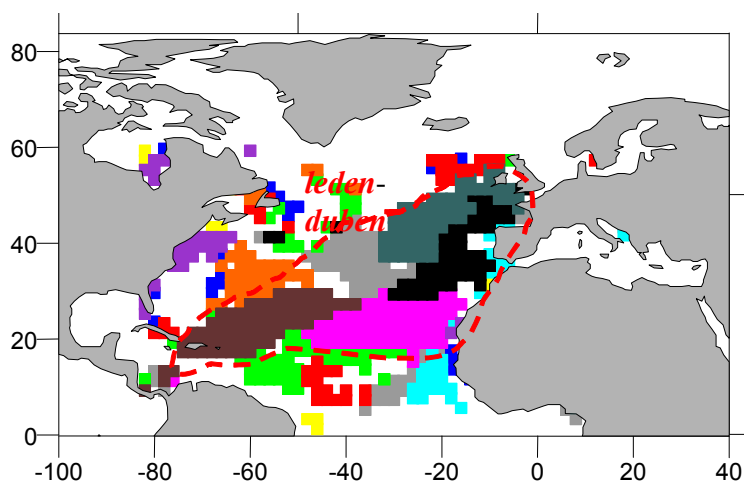


Obr. 3.2.19 Mapa statisticky významných korelačních koeficientů mezi červencovými hodnotami NAO indexů a červencovými hodnotami SST Atlantiku

Říjen

Tato mapa shluků korelačních koeficientů mezi hodnotami SST Atlantiku a říjnovou teplotou v ČR (obr. 3.2.20) obsahuje vůbec největší počet gridových bodů (604), ve kterých se objevily statisticky významné korelace mezi měsíčními hodnotami SST a řadou měsíčních teplot v ČR. Také se zde objevují jedny z vůbec nejvyšších hodnot korelačních koeficientů (až +0.64), a to pro březnové hodnoty SST. Zdá se pravděpodobné, že tyto oblasti anomálií SST souvisí opět s intenzitou jevu NAO v zimě (obr. 3.2.2, 3.2.6). Přímá lineární závislost mezi řadami NAO indexů a říjnovou teplotou v ČR se neprojevila (viz tabulka 3.2.1). Říjnové hodnoty SST z šedo-modré, černé a růžové oblasti budou zahrnuty jako potenciální prediktory do hledaných předpovědních modelů pro hodnoty říjnových teplot v České republice (viz 4.2.10).

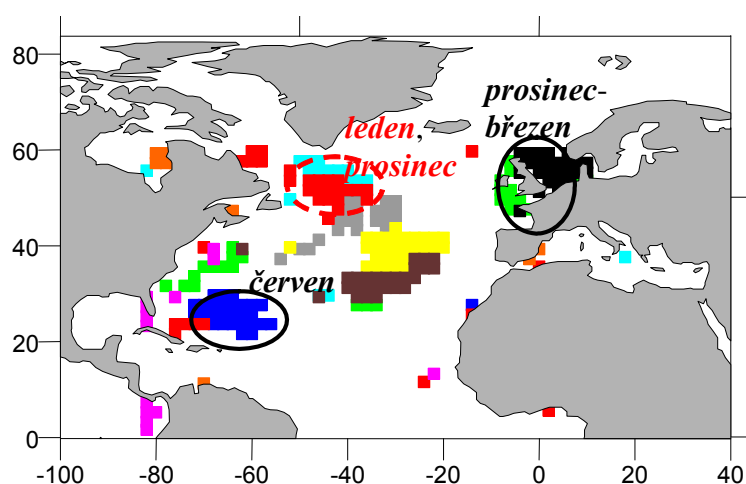
Obr. 3.2.20 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a říjnovou teplotou v ČR



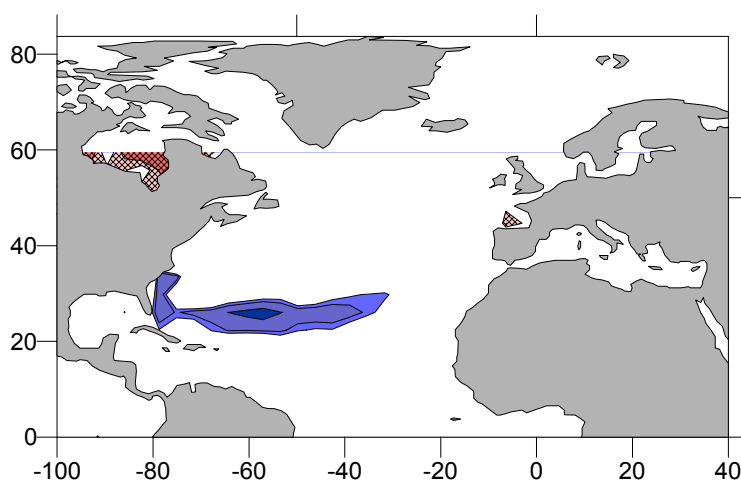
Listopad

Mapa shluků korelačních koeficientů mezi měsíčními hodnotami teploty povrchu Atlantiku a listopadovou teplotou v ČR (obr.3.2.21) už obsahuje oproti předcházející mapě méně než polovinu význačných gridových bodů (270). Za zmínku stojí dipól statisticky významných korelací s SST z prosince až března, který je (až na znaménko) stejný jako na mapě pro naši březnovou teplotu (obr. 3.2.5). Oblast u břehů Kuby představuje záporné korelace červnových SST a listopadových teplot v ČR, stejnou oblast najdeme i na mapě korelací červnových NAO a SST (obr.3.2.22). Červnové hodnoty SST z tmavě modré oblasti a prosincové hodnoty SST z červené a černé oblastí budou zahrnuty jako potenciální prediktory do hledaných předpovědních modelů pro hodnoty listopadových teplot v České republice (viz 4.2.11).

Obr. 3.2.21 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a listopadovou teplotou v ČR



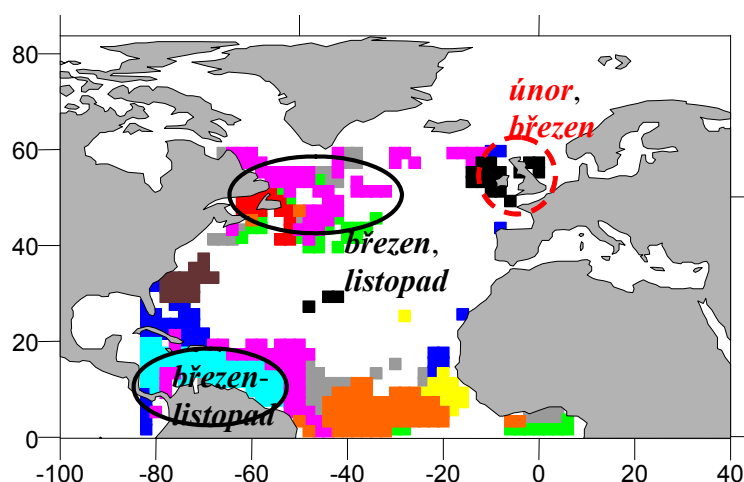
Obr. 3.2.22 Mapa statisticky významných korelačních koeficientů mezi červnovými hodnotami NAO indexů a červnovými hodnotami SST Atlantiku



Prosinec

Oblasti význačných korelací na mapě shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a prosincovou teplotou v ČR (obr. 3.2.23) velmi dobře korespondují s oblastmi na mapě korelací mezi březnovými NAO indexy a březnovými SST (obr.3.2.2). Nejvyšší korelace byly nalezeny právě mezi březnovými SST v těchto oblastech a prosincovou teplotou v ČR. Korelace přímo mezi březnovými indexy NAO a prosincovou teplotou v ČR je také statisticky významná (+0.36, viz tabulka 3.2.1). Březnové hodnoty SST z ohraničených oblastí budou zahrnuty jako potenciální prediktory do hledaných předpovědních modelů pro hodnoty prosincových teplot v České republice (viz 4.2.12).

Obr. 3.2.23 Mapa shluků korelačních koeficientů mezi měsíčními hodnotami SST Atlantiku a prosincovou teplotou v ČR



Na předcházejících mapách se velmi často objevují dipóly (i vícepóly) oblastí Atlantiku s významnými korelačními koeficienty mezi teplotou povrchu oceánu a měsíčními teplotami v ČR.

Zdá se, že zimní měsíční teploty (prosinec, leden) v ČR souvisí se situací v Atlantiku předcházející jaro a podzim (obr. 3.2.1 a 3.2.23). Charakter léta v ČR je částečně dán situací v Atlantiku v zimě až na jaře (obr. 3.2.12, 3.2.14 a 3.2.15). Mapy pro dubnovou a říjnovou teplotu v ČR (obr. 3.2.7 a 3.2.20) ukazují vliv centrálního Atlantiku na teplotu v těchto přechodových měsících. Zatímco březnové hodnoty v ČR korelují s podzimními (zejména zářijovými) SST v těchto oblastech, říjnové hodnoty v ČR korelují s jarními (konkrétně březnovými) SST. Na mapách korelačních koeficientů měsíčních hodnot SST s červnovými a listopadovými teplotami v ČR (obr. 3.2.12 a 3.2.21) vidíme, že oblasti významných korelací (SST v obou případech z prosince až z března) mají opačné znaménko, než na všech zbývajících mapách. V tomto případě byla zjištěna kladná statisticky významná korelace i přímo mezi těmito dvěma teplotními řadami (+0,38, viz tab. 3.2.2).

Zajímavé je, že pokud spočteme korelační koeficienty přímo mezi měsíčními hodnotami NAO indexu a řadami měsíčních teplot v ČR, zjistíme, že

většina statisticky významných korelací je „zprostředkována“ přes oblasti anomálií SST. Tedy že jde vystopovat posloupnost, kdy nejprve statisticky významně koreluje NAO index s teplotami povrchu jistých částí oceánu, a teploty těchto částí oceánu statisticky významně korelují s teplotními řadami v ČR. Obráceně to však neplatí. Více než v polovině případů, kdy byla prokázána statisticky významná korelace mezi NAO indexem a SST, a dále statisticky významná korelace mezi těmito SST a teplotou v ČR, se přímá statisticky významná souvislost mezi NAO a teplotou v ČR neprojevila. Co to znamená? Vracíme se k nedokonalosti zde použité metody korelačních koeficientů, která stanovuje míru lineární závislosti mezi proměnnými. Ale vztahy mezi veličinami v klimatologii za lineární považovat nelze, situaci komplikují různé zpětné vazby, do hry vstupují i jiné meteorologické prvky, které nejsou mezi prediktory vůbec zahrnuty, atd.

4 Empirické modely a jejich vyhodnocení

Výše uvedené získané poznatky o statistických vztazích mezi měsíčními hodnotami NAO indexů, hodnotami teplot povrchu oceánu (SST) a hodnotami teplot vzduchu v České Republice, naznačují jistou možnost dlouhodobých předpovědí pro měsíční teploty vzduchu v ČR, aspoň pro některé měsíce. Proto byly pro jednotlivé měsíce na základě zjištěných statistických vztahů sestaveny jednoduché empirické předpovědní modely. Jednalo se o modely lineární, ve kterých byla použita vícenásobná lineární regrese, i nelineární, využívající neuronové sítě.

V praxi to znamenalo, že byly nejprve hledány vhodné potenciální prediktory na základě výsledků předzpracování prediktorů (viz 3.2). Byly vytipovány oblasti v Severním Atlantiku, ve kterých byly zjištěny největší korelační koeficienty mezi hodnotami SST a hodnotami měsíčních teplot v ČR v daném měsíci (obr. 3.2.1 až 3.2.23). Z teplot povrchu oceánu v gridových bodech těchto oblastí byly vypočítány průměrné hodnoty (dále označované jako MEAN), které potom vstupovaly do modelů jako potenciální prediktory. Dalšími potenciálními prediktory byly hlavní komponenty (PC, viz 2.1.1) vypočítané z teplotních řad povrchu oceánu v gridových bodech těchto vytipovaných oblastí. Do modelů byly dále jako prediktory brány řady měsíčních NAO indexů a měsíčních teplot v ČR, které s teplotní řadou daného měsíce měly statisticky významné korelační koeficienty (tabulky 3.2.1 a 3.2.2).

Při hledání možných předpovědních modelů jsem řešila v klimatologii běžný regresní problém, kdy se snažíme vyjádřit hodnoty vysvětlované proměnné pomocí množiny vysvětlujících proměnných. Pokud řešíme tento problém „klasickými“ statistickými metodami, musíme už při hledání tohoto modelu předpokládat tvar funkční závislosti. Výhoda metody neuronových sítí je v tom, že tuto funkční závislost hledá sama. Neuronové sítě navíc umějí pracovat jak s číselnými, tak s nominálními hodnotami proměnných (v našem případě přímo s kategoriemi podnormální, normální, nadnormální teplota), což umožňuje srovnat úspěšnost předpovědí číselných i nominálních.

Modely byly sestavovány a vyhodnocovány pro období 1961 až 1997. Vzhledem k definici NAO indexů (viz 3.1) byly výpočty prováděny se standardizovanými hodnotami. Výsledky modelů, i reálně naměřené hodnoty, byly rozděleny do tří kategorií: teplota podnormální (PN), normální (N), nadnormální (NN). Mezní hodnoty jednotlivých kategorií byly stanoveny tak, aby do každé kategorie připadla 1/3 naměřených (reálných) hodnot. Problémem je interpretace výsledků v okolí těchto mezních hodnot. I zanedbatelná odchylka 0.1°C může znamenat odlišnou kategorii, odlišný výsledek.

4.1 Výběr potenciálních prediktorů

Nejprve bylo nutno vybrat pro dlouhodobé předpovědi měsíčních teplot v ČR vhodné prediktory. Ty byly vybírány na základě výsledků získaných při předzpracování (viz. 3.2). Jednalo se o následující tři skupiny prediktorů:

1. Na základě výsledků korelací mezi měsíčními řadami NAO indexů a měsíčními teplotami v ČR (viz. tab.3.2.1) byly mezi potenciální prediktory vybrány

ty řady NAO indexů, které měly s danou řadou měsíčních teplot u nás (tedy s řadou teplot pro měsíc pro který hledáme předpovědní model) statisticky významné korelační koeficienty.

2. Na základě výsledků korelací mezi řadami měsíčních teplot v ČR (viz tab. 3.2.2) byly mezi potenciální prediktory vybrány ty řady měsíčních teplot u nás, které danou řadu měsíčních teplot u nás (tedy řadu teplot pro měsíc pro který hledáme předpovědní model) předcházely a zároveň s ní měly statisticky významné korelační koeficienty.

3. Na základě výsledků korelací mezi měsíčními hodnotami teplot povrchu oceánu (SST) a měsíčními hodnotami teplot v ČR byly vytipovány oblasti Atlantiku s nejvyššími korelacemi (viz 3.2.3). Pro tyto oblasti byly jednak spočteny průměrné hodnoty SST z jednotlivých gridových bodů (označeny jako *MEAN*) a jednak spočteny první hlavní komponenty, které popisují variabilitu dané oblasti (označeny jako *FAC*). Pokud se objevil na mapě dipól oblastí se statisticky významnými koeficienty, byl mezi potenciální prediktory zahrnut i rozdíl průměrných SST (označen jako *ROZDÍL*).

4.2 Výsledky

Postupně byly sestaveny a validovány tři typy modelů. Lineární regresní model (dále označován jako LIN), nelineární model sestavený pomocí neuronových sítí s číselným výstupem, kdy jako výsledek hledám číselnou hodnotu měsíční teploty v ČR (dále označováno jako NN_c), a nelineární model sestavený pomocí neuronových sítí s kategoriálním výstupem (dále NN_k), kdy jako výsledek hledám kategorii (podnormální, normální nebo normální) do které hodnota měsíční teploty v ČR patří.

Vyhodnocování výsledků modelů probíhalo pomocí křížové validace. Křížová validace spočívá v postupném vynechávání jednoho případu, sestavení statistického modelu na zbývajících datech, a následné aplikaci modelu na vynechaný případ (Michaelsen, 1987).

V případě lineárních modelů byly pomocí krokové regrese (viz 2.2.1) nalezeny prediktory vhodné pro předpověď měsíční (např. lednové) teploty v ČR. Tyto prediktory byly využity pro sestavení 37 regresních modelů tak, že byly postupně vynechány případy od 1. do 37. (tedy postupně hodnoty např. lednových teplot od roku 1961 do roku 1997). Hodnota vynechaného případu byla tímto regresním modelem dopočítána. Tyto výsledky byly použity pro validaci modelu.

V případě nelineárních modelů jsem postupovala obdobně. Vytrénované sítě s nejlepšími parametry pro předpovědi jednotlivých měsíčních teplot v ČR byly uloženy (viz 2.2.2). Postupně byly po jednom vynechávány případy od 1. do 37., síť byla bez tohoto jednoho případu znovu vytrénována, a výsledek vynechaného případu byl takto modifikovanou sítí dopočítán. Tyto výsledky byly použity pro validaci modelů.

Výsledky jsou zaznamenány v následujících tabulkách, které uvádí počty pozorovaných a předpověděných hodnot v jednotlivých kategoriích pro každý výše uvedený typ modelu zvlášť. U modelů sestavených pomocí lineární regrese jsou v závorce za označením typu modelu (LIN) uvedeny i zkratky názvů vybraných prediktorů. U modelů sestavených pomocí neuronových sítí je za označením modelu (NN_c pro neurální síť s číselným výstupem nebo NN_k pro neurální síť s kategoriálním výstupem) uvedena architektura dané neuronové sítě. Nejčastěji

se jednalo o typ Multilayer perceptron neural network (MLP), jejichž architektura je blíže popsána uvedenými čísly, kdy první číslo znamená počet prediktorů, druhé číslo počet neuronů ve skryté vrstvě (viz 2.2.2). Tedy například MLP 2-1 označuje vícevrstevnou perceptronovou síť se dvěma vstupy a s jedním neuronem ve skryté vrstvě. Za tabulkou je uvedeno Linear Error in Probability Space (LEPS) score (viz 2.3.3, rovnice 2.3.8), pomocí kterého je hodnocena úspěšnost předpovědi. Čím vyšší je hodnota LEPS score, tím je model úspěšnější. Hodnota LEPS score kolem 0,4 naznačuje už jistou „použitelnost“ modelu. Bezchybný model by dosáhl LEPS score rovné 1. Dodatečně byla zjištěna možnost, jak v případě neurálních sítí s kategoriálním výstupem získat jako výsledek přímo pravděpodobnost jednotlivých kategorií. Proto bylo možno použít k vyhodnocení a porovnání některých sítí i Ranked Probability Skill Score (RPSS), které se využívá k vyhodnocování pravděpodobnostně formulovaných předpovědí (viz 2.3.2). V tomto případě je hodnota tohoto score také uvedena za tabulkou s výsledky. Bezchybná předpověď by měla hodnotu RPSS rovnu 1.

4.2.1 Předpovědi průměrných lednových teplot

Potenciální prediktory byly získány podle pravidel uvedených v 4.1, očíslování si také vzájemně odpovídá:

1. **NAO3** - řada březnových NAO indexů, v tab. 3.2.1 (str. xx) je uveden mezi NAO3 a T1 (lednové teploty v ČR) korelační koeficient +0,38
2. **T9** - řada zářijových teplot v ČR, v tab. 3.2.2 je uveden mezi T9 a T1 korelační koeficient +0,34
3. **MEANa** - březnový průměr SSTs v oblasti 25-40° W, 45-55° N, v příloze v tab.2, která popisuje obr. 3.2.1, můžeme nalézt, že pro březnové SST z této (tmavě modré) oblasti s T1 dosahují korelační koeficienty hodnot až -0,54
- MEANb** - březnový průměr SSTs v oblasti 10°W - 5°E, 50 -59.5°N, v příloze v tab.2, která popisuje obr. 3.2.1, můžeme nalézt, že pro březnové SST z této (červené, růžové a hnědé) oblasti s T1 dosahují korelační koeficienty hodnot až +0,62
- FACa** - první hlavní komponenta oblasti **a**, korelační koeficient mezi FACa a T1 je -0,34
- FACb** - první hlavní komponenta oblasti **b**, korelační koeficient mezi FACb a T1 je +0,46
- ROZDÍL** - rozdíl průměrných březnových teplot povrchu oceánu v oblastech **a** a **b**, korelační koeficient mezi ROZDIL a T1 je -0,49.

Výsledky:

Všechny tři modely si vybraly z výše uvedených potenciálních prediktorů řadu průměrných zářijových teplot v ČR (T9) a rozdíl průměrných březnových teplot povrchu oceánu v oblastech **a** a **b** (ROZDÍL), NN_k (tedy model sestavený pomocí neuronové sítě s kategoriálním výstupem) má navíc ještě jako další prediktor první hlavní komponentu oblasti **b** (FACb). Jak je patrné z hodnot uvedených v následující tabulce 4.2.1, nejlepších výsledků bylo celkově dosaženo pomocí NN_k. Hodnota LEPS score 0,47 je poměrně vysoká. V literatuře se většinou

uvádí, že LEPS score větší než 0,4 naznačuje už použitelné modely. Při porovnávání úspěšnosti určování jednotlivých kategorií, je NN_k lepší ve správném určování nadnormálních a podnormálních hodnot, zatímco pro normální hodnoty je o něco horší než zbylé dva modely.

Tab. 4.2.1 Výsledky modelů pro předpověď průměrných lednových teplot v ČR (za typem modelu, popř. architekturou neurální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů). PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

a) LIN (T9, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	5	5	1
N	3	6	4
PN	0	7	6

LEPS=0,34

b) NN_c, MLP 2-1, výstup=číslo (T9, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	4	6	1
N	2	7	4
PN	1	7	5

LEPS=0,24

c) NN_k, MLP 3-3, výstup=kategorie (T9, ROZDÍL, FACb)

Pozorování	Předpověď		
	NN	N	PN
NN	9	1	1
N	3	5	5
PN	2	4	7

LEPS=0,47

4.2.2 Předpovědi průměrných únorových teplot

Potenciální prediktory:

1. v této skupině nebyl nalezen vhodný prediktor
2. v této skupině nebyl nalezen vhodný prediktor

3. **MEANa** – listopadové SSTs v oblasti 10 - 30°W, 30 - 40°N, pro listopadové SST z této (na obr.3.2.4 růžové a oranžové) oblasti s T2 (únorové teploty v ČR) dosahují korelační koeficienty hodnot až -0,54

Výsledky:

Pro tento měsíc se nepodařilo najít žádný uspokojivý model, ať už lineární nebo nelineární.

4.2.3 Předpovědi průměrných březnových teplot

Potenciální prediktory:

1. v této skupině nebyl nalezen vhodný prediktor
2. **T11, T12, T1** - řady listopadových, prosincových a lednových teplot v ČR, mezi T11 a T3 (březnové teploty v ČR) byl zjištěn korelační koeficient - 0,33, mezi T12 a T3 +0,38, mezi T1 a T3 +0,35 (tab. 3.2.2)
3. **MEANa** - průměr květnových SST v oblasti 50-65°W, 30-35°N, pro květnové SST z této (na obr. 3.2.5 růžové) oblasti s T3 dosahují korelační koeficienty hodnot až +0,54
MEANb – průměr květnových SST v oblasti 5°W-10°E, 50-59.5°N, pro květnové SST z této (na obr. 3.2.5 hnědé) oblasti s T3 dosahují korelační koeficienty hodnot až +0,55
MEANc – průměr lednových SST v oblasti 35-50°W, 50-59.5°N, pro lednové SST z této (na obr. 3.2.5 žluté) oblasti s T3 dosahují korelační koeficienty hodnot až -0,44

Výsledky:

Výsledky validace všech typů modelů jsou uvedeny v tabulce 4.2.2. Oba dva nelineární modely (tedy model sestavený pomocí neuronových sítí s číselným výstupem NN_c i s kategoriálním výstupem NN_k) dosáhly srovnatelných výsledků, které jsou mnohem lepší než výsledky lineárního modelu. Lineární model měl problémy s určováním hodnot, které se lišily od normálních. Všechny modely se vcelku dobře „vyhýbaly“ hrubým chybám (tedy určení nadnormální kategorie v případě podnormální a obráceně). Celkově však nejsou výsledky uspokojivé ani u jednoho z modelů. LEPS score menší než 0,4 nenaznačují možnost praktického využití.

Tab. 4.2.2 Výsledky modelů pro předpověď průměrných březnových teplot v ČR (za typem modelu, popř. architekturou neuronální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů). PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

a) LIN (T12)

Pozorování	Předpověď		
	NN	N	PN
NN	0	11	1
N	3	9	1
PN	0	8	5

LEPS=0,13

b) NN_c , MLP 2-3, výstup=číslo (MEANa, MEANb))

Pozorování	Předpověď		
	NN	N	PN
NN	6	5	1
N	2	9	2
PN	0	10	3

LEPS=0,26

c) NN_k , MLP 4-2, výstup=kategorie (MEANa, MEANb, T12)

Pozorování	Předpověď		
	NN	N	PN
NN	5	5	2
N	5	5	3
PN	2	4	7

LEPS=0,27

4.2.4 Předpovědi průměrných dubnových teplot

Potenciální prediktory:

1. v této skupině nebyl nalezen vhodný prediktor
2. **T9** – řada zářijových teplot v ČR, v tab. 3.2.2 je uveden mezi T9 a T4 (dubnové teploty v ČR) korelační koeficient +0,49
3. **MEANa** - průměr zářijových SST v oblasti 5-20°W, 45-55°N, pro zářijové SST z této (na obr. 3.2.7 oranžové) oblasti s T4 dosahují korelační koeficienty hodnot až -0,45

MEANb – průměr zářijových SST v oblasti 35-62.5°W, 32.5-40°N, pro zářijové SST z této (na obr. 3.2.7 žluté) oblasti s T4 dosahují korelační koeficienty hodnot až +0,53

ROZDÍL - rozdíl průměrných zářijových teplot povrchu oceánu v oblastech a a b , korelační koeficient mezi ROZDIL a T4 je +0,41

Výsledky:

Ve všech typech modelů byly použity dva stejné prediktory, řada zářijových teplot v ČR (T9) a rozdíl průměrných zářijových teplot povrchu oceánu v oblastech a a b (ROZDÍL). V tabulce 4.2.3 vidíme, že výsledky všech tří typů modelů jsou srovnatelné, i když nelineární modely dávají přeci jen o něco lepší výsledky. Rozdíly nenalzáme ani při podrobnějším prozkoumání a porovnání výsledků pro jednotlivé kategorie. Hodnoty LEPS score jsou poměrně vysoké a naznačují možnost i praktického využití.

Tab. 4.2.3 Výsledky modelů pro předpověď průměrných dubnových teplot v ČR (za typem modelu, popř. architekturou neuronální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů)

a) LIN (T9, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	6	6	1
N	4	5	4
PN	0	4	7

LEPS=0,41

b) NN_c, MLP 2-1, výstup=číslo (T9, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	7	5	1
N	2	6	3
PN	0	4	7

LEPS=0,47

c) NN_k, MLP 2-3, výstup=kategorie (T9, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	10	2	1
N	5	4	4
PN	1	5	5

LEPS=0,45

4.2.5 Předpovědi průměrných květnových teplot

Potenciální prediktory:

1. **NAO10, NAO3** - řada říjnových a březnových NAO indexů, v tab. 3.2.1 je uveden mezi NAO10 a T5 (květnové teploty v ČR) korelační koeficient -0,33, mezi NAO3 a T5 +0,41
2. **T6** - řada průměrných červnových teplot (T6), v tab. 3.2.2 je uveden mezi T6 a T5 korelační koeficient -0,31
3. **MEANa** - průměr lednových SST v oblasti 40-50°W, 40-52.5°N, pro lednové SST z této (na obr. 3.2.9 hnědé) oblasti s T5 dosahují korelační koeficienty hodnot až -0,46
MEANb - průměr červencových SST v oblasti 40-50°W, 40-52.5°N, pro červencové SST z této (na obr. 3.2.9 hnědé) oblasti s T5 dosahují korelační koeficienty hodnot až -0,60
MEANc - průměr červencových SST v oblasti 10-30°W, 0-7.5°N, pro červencové SST z této (na obr. 3.2.9 černé) oblasti s T5 dosahují korelační koeficienty hodnot až +0,48

Výsledky:

Výsledky všech tří typů nalezených modelů jsou poměrně špatné. Nejlepší byl model NN_c (nalezený pomocí neuronové sítě a s číselným výstupem), který má dva prediktory (NAO3, T6). Model NN_k se sestavoval a trénoval dlouho, a složitě. Síť měly výrazný sklon k přetrénování a měly tendenci ignorovat jednu kategorii (viz tabulka 4.2.4, ze které jsou patrné špatné výsledky NN_k pro nadnormální kategorii). Nejlepší lineární model si vystačil s jedním prediktorem (NAO3). Nastavením vhodné aktivační funkce ve výstupní vrstvě modelu NN_k jsem mohla odečítat na výstupu přímo pravděpodobnosti jednotlivých kategorií (viz 2.2.2) a spočítat tak pro tento model další validační charakteristiku, Ranked Probability Skill Score (RPSS, viz 2.3.2). Její hodnota 0,09, která se jen málo liší od 0, však naznačuje, že předpověď nepřináší výrazné zlepšení oproti předpovědi pomocí rovných pravděpodobností v jednotlivých kategoriích.

Tab. 4.2.4 Výsledky modelů pro předpověď průměrných květnových teplot v ČR (za typem modelu, popř. architekturou neurální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů). PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

a) LIN (NAO3)

Pozorování	Předpověď		
	NN	N	PN
NN	2	7	3
N	2	9	1
PN	0	9	4

LEPS=0,12

b) NN_c, MLP 2-2, výstup=číslo (NAO3, T6)

Pozorování	Předpověď		
	NN	N	PN
NN	3	5	4
N	1	11	0
PN	0	7	6

LEPS=0,24

c) NN_k, MLP 2-1, výstup=kategorie (NAO3, T6)

Pozorování	Předpověď		
	NN	N	PN
NN	1	6	5
N	2	10	0
PN	2	3	8

LEPS=0,14

RPSS=0,09

4.2.6 Předpovědi průměrných červnových teplot

Potenciální prediktory:

1. v této skupině nebyl nalezen vhodný prediktor
2. v této skupině nebyl nalezen vhodný prediktor
3. **MEANa** - průměr prosincových SST v oblasti 25-60°W, 55-60°N, pro prosincové SST z této (na obr. 3.2.12 světle modré) oblasti s T6 (červnové teploty v ČR) dosahují korelační koeficienty hodnot až +0,43

MEANb - průměr březnových SST v oblasti 40-62.5°W, 27.5-38.5°N, pro březnové SST z této (na obr. 3.2.12 hnědé) oblasti s T6 dosahují korelační koeficienty hodnot až -0,49

MEANc - průměr zářijových SST v oblasti 30-50°W, 0-7.5°W, pro zářijové SST z této (na obr. 3.2.12 tmavě modré) oblasti s T6 dosahují korelační koeficienty hodnot až -0,57

Výsledky:

Výrazně nejlepšího výsledku bylo dosaženo pomocí neurální sítě s kategoriálním výstupem (NN_k). Rozdíl i mezi nelineárními modely je velmi výrazný. Jak je vidět v následující tabulce 4.2.5, všechny modely si jako prediktor vybraly MEANa, nelineární modely potom ještě přibraly jeden prediktor (MEANb v případě NN_c a MEANc v případě NN_k). Lineární regresní model a NN_c se chovaly podobně v tom, že nedělaly hrubé chyby (určení podnormální kategorie v případě nadnormální a naopak), ale zároveň tyto krajní kategorie špatně

identifikovaly vůbec. NN_k měl v případě nadnormální a podnormální kategorie podstatně více správně zařazených případů, ale dopustil se i více hrubých chyb.

Tab. 4.2.5 Výsledky modelů pro předpověď průměrných červnových teplot v ČR (za typem modelu, popř. architekturou neurální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů). PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

a) LIN (MEANa)

Pozorování	Předpověď		
	NN	N	PN
NN	1	12	0
N	0	10	2
PN	1	9	2

LEPS= 0,06

b) NN_c, MLP 2-1, výstup=číslo (MEANa, MEANb)

Pozorování	Předpověď		
	NN	N	PN
NN	4	8	1
N	2	5	5
PN	1	7	4

LEPS= 0,17

c) NN_k, MLP 2-3, výstup=kategorie (MEANa, MEANc)

Pozorování	Předpověď		
	NN	N	PN
NN	9	2	2
N	3	4	5
PN	3	2	7

LEPS= 0,40

4.2.7 Předpovědi průměrných červnových teplot

Potenciální prediktory:

1. **NAO12** - řada prosincových NAO indexů, v tab. 3.2.1 je uveden mezi NAO12 a T7 (červencové teploty v ČR) korelační koeficient +0,35
2. **T5** - řada květnových teplot v ČR, v tab. 3.2.2 je uveden mezi T5 a T7 korelační koeficient +0,39
3. **MEANa** - průměr květnových SST v oblasti 40-55°W, 35-40°N, pro květnové SST z této (na obr. 3.2.14 hnědé) oblasti s T7 dosahují korelační koeficienty hodnot až +0,47

MEANb - průměr květnových SST v oblasti 20-40°W, 30-40°N, pro květnové SST z této (na obr. 3.2.14 červené) oblasti s T7 dosahují korelační koeficienty hodnot až -0,51

MEANc - průměr květnových SST v oblasti 17.5-25°W, 50-57.5°N, pro květnové SST z této (na obr. 3.2.14 světle modré) oblasti s T7 dosahují korelační koeficienty hodnot až -0,49

ROZDÍL - rozdíl průměrných květnových teplot povrchu oceánu v oblastech a a b, korelační koeficient mezi ROZDIL a T7 je +0,36

Výsledky:

Výsledky pro červencové předpovědi jsou u všech typů modelů velmi slabé, celkově nejslabší ze všech měsíců. Lineární regresní model (LIN) téměř vůbec neidentifikoval podnormální a nadnormální kategorie. Model NN_k udělal zase hodně hrubých chyb. Podle výsledných hodnot LEPS score jsou všechny nalezené modely prakticky nepoužitelné.

Tab. 4.2.6 Výsledky modelů pro předpověď průměrných červencových teplot v ČR (za typem modelu, popř. architekturou neurální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů). PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

a) LIN (MEANc)

Pozorování	Předpověď		
	NN	N	PN
NN	0	13	0
N	1	12	0
PN	0	10	2

LEPS= 0,04

b) NN_c, MLP 2-2, výstup=číslo, (NAO12, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	2	10	1
N	2	10	1
PN	1	7	4

LEPS= 0,15

c) NN_k, MLP 2-2, výstup=kategorie (NAO12, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	3	6	4
N	2	9	2
PN	1	5	6

4.2.8 Předpovědi průměrných srpnových teplot

Potenciální prediktory:

1. **NAO2** - řada únorových NAO indexů (NAO2), v tab. 3.2.1 je uveden mezi NAO2 a T8 (srpnové teploty v ČR) korelační koeficient +0,38
2. v této skupině nebyl nalezen vhodný prediktor
3. **MEANa** - průměr dubnových SST v oblasti 30-60°W, 53.5-59.5°N, pro dubnové SST z této (na obr. 3.2.15 černé) oblasti s T8 dosahují korelační koeficienty hodnot až -0,46
MEANb - průměr dubnových SST v oblasti 10°W-5°E, 43.5-57.5°N, pro dubnové SST z této (na obr. 3.2.15 žluté a oranžové) oblasti s T8 dosahují korelační koeficienty hodnot až +0,47
ROZDÍL - rozdíl průměrných dubnových teplot povrchu oceánu v oblastech a a b, korelační koeficient mezi ROZDÍL a T8 je +0,44

Výsledky:

Nejlepších výsledků dosáhla neuronová síť s lineární architekturou, kdy výstupem byla přímo kategorie (NN_k). Nejhorších výsledků dosáhl lineární regresní model (LIN), který měl problém zejména se správným určením nadnormální a podnormální kategorie. Rozdíly jsou vidět i mezi oběma modely sestavenými pomocí neuronových sítí. Zatímco neuronový model s číselným výstupem (NN_c) měl problémy se správným zařazením do nadnormální kategorie, vedl si naopak lépe v určování normálních hodnot (v porovnání s NN_k). Modely sestavené pomocí neuronových sítí se jeví (vzhledem k poměrně vysokým hodnotám LEPS score) prakticky použitelné, výsledky lineárního regresního modelu jsou neuspokojivé.

Tab. 4.2.7 Výsledky modelů pro předpověď průměrných srpnových teplot v ČR (za typem modelu, popř. architekturou neurální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů). PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

a) LIN (NAO2)

Pozorování	Předpověď		
	NN	N	PN
NN	3	7	0
N	6	8	1
PN	0	8	4

b) NN_c, MLP 2-4 ,výstup=číslo (NAO2, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	3	6	1
N	4	10	1
PN	1	3	8

LEPS=0,48

c) NN_k, lineární neuronová síť, výstup=kategorie (NAO2, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	6	2	2
N	5	7	3
PN	1	2	9

LEPS=0,6

4.2.9 Předpovědi průměrných zářijových teplot

Potenciální prediktory:

1. **NAO7, NAO12** - řada červencových a prosincových NAO indexů, v tab. 3.2.1 je uveden mezi NAO7 a T9 (zářijová teplota v ČR) korelační koeficient +0,34, mezi NAO 12 a T9 +0,42
2. v této skupině nebyl nalezen vhodný prediktor
3. **MEANa** - průměr červnových SST v oblasti 5-20°W, 40-55°N, pro červnové SST z této (na obr. 3.2.17 černé) oblasti s T9 dosahují korelační koeficienty hodnot až +0,51
MEANb - průměr prosincových SST v oblasti 20-50°W, 30-45°N, pro prosincové SST z této (na obr. 3.2.17 žlutá, růžová, zelená) oblasti s T9 dosahují korelační koeficienty hodnot až +0,65
MEANc - průměr říjnových SST v oblasti 5-20°W, 40-55°N, pro říjnové SST z této (na obr. 3.2.17 černé) oblasti s T9 dosahují korelační koeficienty hodnot až -0,62
MEAND - průměr říjnových SST v oblasti 40-50°W, 45-55°N, pro říjnové SST z této (na obr. 3.2.17 světle modré) oblasti s T9 dosahují korelační koeficienty hodnot až +0,51
ROZDÍL - rozdíl průměrných říjnových teplot povrchu oceánu v oblastech c a d, korelační koeficient mezi ROZDIL a T9 je -0,46

Výsledky:

Všechny tři typy modelů si z potenciálních prediktorů vybraly stejné tři prediktory (NAO12, NAO7, ROZDÍL; viz tab. 4.2.8) . Výsledky modelů sestavených pomocí neuronových sítí (bez ohledu na formu výstupu, NN_c nebo NN_k) jsou stejné a lepší, než výsledky lineárního regresního modelu (LIN). NN_k si nejlépe poradil se správným zařazením hodnot do nadnormální a podnormální kategorie, na druhou stranu udělal nejvíc hrubých chyb a chyboval nejvíc i při zařazování normálních hodnot. Modely sestavené pomocí neuronových sítí se jeví (vzhledem k hodnotám LEPS score nad 0,4) prakticky použitelné.

Tab. 4.2.8 Výsledky modelů pro předpověď průměrných zářijových teplot v ČR (za typem modelu, popř. architekturou neurální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů). PN označuje kategorii podnormálních teplot , N kategorii normálních a NN nadnormálních teplot.

a) LIN (NAO12, NAO7, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	8	2	2
N	2	5	4
PN	2	5	6

LEPS=0,37

b) NN_c, MLP 3-4, výstup=číslo (NAO12, NAO7, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	8	4	0
N	2	4	5
PN	1	5	7

LEPS=0,47

c) NN_k, MLP 3-2, výstup=kategorie (NAO12, NAO7, ROZDÍL)

Pozorování	Předpověď		
	NN	N	PN
NN	10	0	2
N	3	3	5
PN	3	2	8

LEPS=0,47

4.2.10 Předpovědi průměrných říjnových teplot

Potenciální prediktory:

1. v této skupině nebyl nalezen vhodný prediktor
2. **T4, T8** – řady dubnových a srpnových teplot v ČR, v tab. 3.2.2 je uveden mezi T4 a T10 (říjnové teploty v ČR) korelační koeficient +0,34, mezi T8 a T10 -0,34
3. **MEANa** - průměr březnových SST v oblasti 50°W, 20-30°N, pro březnové SST z této (na obr. 3.2.20 růžové) oblasti s T10 dosahují korelační koeficienty hodnot až +0,59
MEANb - průměr březnových SST v oblasti 10-30°W, 30-45°N, pro březnové SST z této (na obr. 3.2.20 černé, šedo-modré) oblasti s T10 dosahují korelační koeficienty hodnot až +0,64

Výsledky:

Pro všechny typy modelů byly vybrány stejné tři prediktory (MEANa, T4, T8; viz tab. 4.2.9). Všechny modely udělaly jen jednu hrubou chybu a byly úspěšnější při určování normálních a podnormálních hodnot (ve srovnání s kategorií hodnot nadnormálních). Hodnoty LEPS score jsou poměrně vysoké pro všechny typy modelů a patří k nejvyšším i ve srovnání s výsledky předpovědních modelů pro další měsíce (tab. 4.3.1 a obr. 4.3.1). Nejúspěšnější byl model sestavený pomocí neuronové sítě s kategoriálním výstupem (NN_k). Nastavením vhodné aktivační funkce ve výstupní vrstvě jsem mohla odečíst na výstupu přímo pravděpodobnosti jednotlivých kategorií (viz 2.2.2) a spočítat pro neuronovou síť s kategoriálním výstupem další validační charakteristiku, Ranked Probability Skill Score (RPSS, viz 2.3.2). Její hodnota 0,60 ukazuje, že daná předpověď přináší výrazné zlepšení oproti předpovědi pomocí rovných pravděpodobností v jednotlivých kategoriích.

Tab. 4.2.9 Výsledky modelů pro předpověď průměrných říjnových teplot v ČR (za typem modelu, popř. architekturou neurální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů). PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

a) LIN (MEANa, T4, T8)

Pozorování	Předpověď		
	NN	N	PN
NN	4	8	0
N	0	10	2
PN	1	4	8

LEPS=0,42

b) NN_c, MLP 3-4, výstup= číslo (MEANa, T4, T8)

Pozorování	Předpověď		
	NN	N	PN
NN	4	8	0
N	1	11	0
PN	1	3	9

LEPS=0,48

c) NN_k, MLP 3-4, výstup= kategorie (MEANa, T4, T8)

Pozorování	Předpověď		
	NN	N	PN
NN	5	7	0
N	2	10	0
PN	1	3	9

LEPS=0,51

RPSS=0,6

4.2.11 Předpovědi průměrných listopadových teplot

Potenciální prediktory:

1. **NAO7** - řada červencových NAO indexů, v tab. 3.2.1 je uveden mezi NAO7 a T11 (listopadové teploty v ČR) korelační koeficient +0,39
2. **T12, T1, T2** - řady prosincových, lednových a únorových teplot, v tab. 3.2.2 je uveden mezi T12 a T11 korelační koeficient -0,45, mezi T1 a T11 - 0,38, mezi T2 a T11 -0,37
3. **MEANa** - průměr červnových SST v oblasti 55-75°W, 20-30°N, pro červnové SST z této (na obr. 3.2.21 tmavě modré) oblasti s T11 dosahují korelační koeficienty hodnot až -0,44
MEANb - průměr prosincových SST v oblasti 30-45°W, 45-60°N, pro prosincové SST z této (na obr. 3.2.21 červené) oblasti s T11 dosahují korelační koeficienty hodnot až +0,48
MEANc - průměr prosincových SST v oblasti 10°E-5°W, 50-60°N, pro prosincové SST z této (na obr. 3.2.21 černé) oblasti s T11 dosahují korelační koeficienty hodnot až -0,49
FACa - první hlavní komponenta oblasti, korelační koeficient mezi FACa a T11 je -0,44
FACc - první hlavní komponenta oblasti c, korelační koeficient mezi FACc a T11 je -0,52

Výsledky:

Lineární regresní model (LIN) s uspokojivými výsledky se nepodařilo nalézt. V tabulce 4.2.10 jsou pro úplnost uvedeny výsledky nalezeného lineárního

regresního modelu se dvěma prediktory (T1, FACc), jehož výsledky jsou však zcela neuspokojivé. Výsledky modelů sestavených pomocí neuronových sítí jsou o poznání lepší. Jako nejlepší a jediný použitelný se jeví model sestavený pomocí neuronových sítí s kategoriálním výstupem (NN_k), který dosáhl při validaci LEPS score rovné 0,4.

Tab. 4.2.10 Výsledky modelů pro předpověď průměrných listopadových teplot v ČR (za typem modelu, popř. architekturou neurální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů). PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

a) LIN (T1, FACc)

Pozorování	Předpověď		
	NN	N	PN
NN	0	9	3
N	2	8	3
PN	1	7	4

LEPS=0,0

b) NN_c, MLP 3-3, výstup=číslo (T1, FACa, FACc)

Pozorování	Předpověď		
	NN	N	PN
NN	4	7	1
N	3	5	5
PN	1	4	8

LEPS=0,32

c) NN_k, MLP 3-3, výstup=kategorie (T1, FACa, FACc)

Pozorování	Předpověď		
	NN	N	PN
NN	7	4	1
N	2	7	4
PN	2	1	10

LEPS=0,4

4.2.12 Předpovědi průměrných prosincových teplot

Potenciální prediktory:

1. **NAO2** - řada březnových NAO indexů, v tab. 3.2.1 je uveden mezi NAO3 a T12 (prosincové teploty v ČR) korelační koeficient +0,36
2. v této skupině nebyl nalezen vhodný prediktor
3. **MEANa** - průměr březnových SST v oblasti 40-60°W, 40-59.5°N, pro březnové SST z této (na obr. 3.2.23 růžové) oblasti s T12 dosahují korelační koeficienty hodnot až -0,53
MEANb - průměr březnových SST v oblasti 10°E-5°W, 50-59.5°N, pro březnové SST z této (na obr. 3.2.23 černé) oblasti s T12 dosahují korelační koeficienty hodnot až +0,40
MEANc - průměr březnových SST v oblasti 20-50°W, 0-10°N, pro březnové SST z této (na obr. 3.2.23 oranžové) oblasti s T12 dosahují korelační koeficienty hodnot až -0,55
MEAND - průměr březnových SST v oblasti 50-80°W, 10-20°N, pro březnové SST z této (na obr. 3.2.23 světle modré) oblasti s T12 dosahují korelační koeficienty hodnot až -0,58
FACa - první hlavní komponenta oblasti a, korelační koeficient mezi FACa a T12 je -0,46

Výsledky:

Jak je vidět z výsledků uvedených v tabulce 4.2.11, modely sestavené pomocí neuronových sítí měly lepší výsledky. Znatelně nejlépe si vedl model sestavený s pomocí neuronové sítě s kategoriálním výstupem (NN_k), který měl nejvyšší počet správně určených nadnormálních hodnot, ale na druhou stranu měl i nejvyšší počet hrubých chyb (určení podnormální kategorie v případě nadnormální a opačně). Hodnoty LEPS score ani jednoho modelu nenaznačují možnost využití v předpovědní praxi.

Tab. 4.2.11 Výsledky modelů pro předpověď průměrných prosincových teplot v ČR (za typem modelu, popř. architekturou neurální sítě, jsou v závorkách uvedeny zkratky použitých prediktorů). PN označuje kategorii podnormálních teplot, N kategorii normálních a NN nadnormálních teplot.

a) LIN (MEANc, FACa)

Pozorování	Předpověď		
	NN	N	PN
NN	2	7	3
N	4	5	4
PN	1	5	7

LEPS=0,15

b) NN_c, MLP 3-3, výstup=číslo (MEANc, FACa, NAO3)

Pozorování	Předpověď		
	NN	N	PN
NN	3	8	1
N	3	6	4

PN	2	3	8
----	---	---	---

LEPS=0,27

c) NN_k, MLP 3-2, výstup=kategorie (MEANa, MEANc, NAO3)

Pozorování	Předpověď		
	NN	N	PN
NN	8	1	3
N	3	4	6
PN	3	2	8

LEPS=0,36

4.3 Shrnutí výsledků nalezených modelů

Shrnutí výsledků nalezených empirických modelů pro předpovědi měsíčních teplot v ČR lze nalézt v tabulce 4.3.1, v grafické formě pak na obr. 4.3.1.

Při sestavování modelů pomocí neuronových sítí jsem narážela opakovaně na problém související s malým počtem dat. Sítě měly tendenci k přetrénování (viz 2.2.2), bylo tedy třeba velmi uvážlivě přistupovat k trénování, volit jen malý počet opakování. U měsíců, které se jeví méně předpovědatelné (mají nižší LEPS score) se sítě s kategoriálním výstupem sestavovaly nejhůře. Sítě měly tendenci ignorovat jednu kategorii (například vůbec nepředpovídaly kategorii nadnormálních teplot). V těchto případech se mezi nejlepšími sítěmi objevily i sítě typu RBF (Radial Basis Function), který popisuje například Bishop, 1995. Zřejmě by bylo vhodné provést další výpočty s větším počtem dat, které by mohly přinést zlepšení.

Pro únorové měsíční teploty se nepodařilo najít uspokojující prediktory, a tím pádem ani předpovědní modely.

Některé měsíční teploty se jeví „předpovědatelnější“ než jiné. Nejlepších validačních výsledků dosahují modely pro srpen, září, říjen, leden. Nejhorší výsledky mají modely pro květen, červenec.

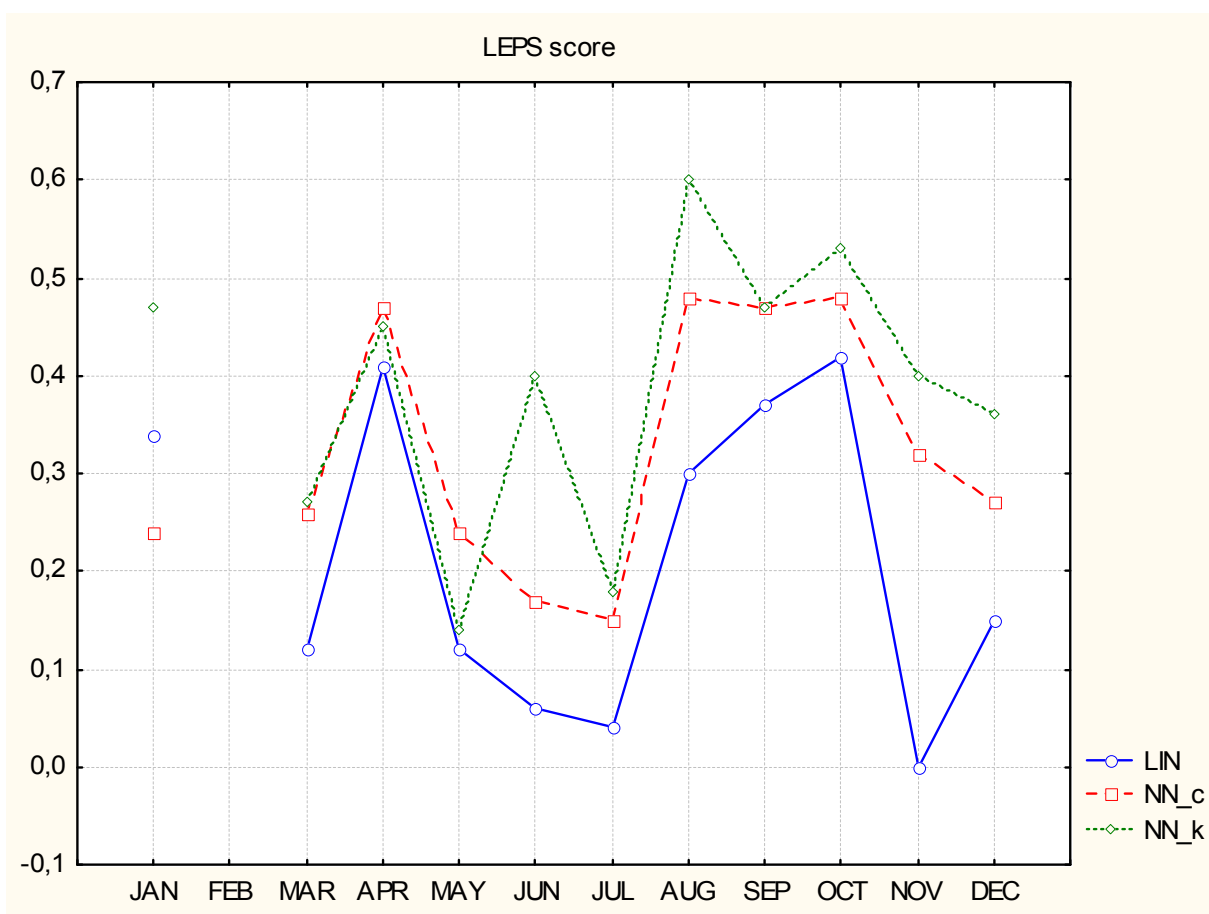
Pro všechny měsíce byly nalezené nelineární modely (tedy modely nalezené s pomocí neuronových sítí) lepší, než modely lineární.

Porovnání mezi modely pomocí neuronových sítí s číselnými a kategoriálními výstupy vyznělo lépe pro modely, kde výsledkem byla přímo kategorie.

Tab.4.3.1 Hodnoty LEPS score předpovědních modelů pro měsíční teploty v ČR; modely lineární (LIN), modely pomocí neuronové sítě s číselným výstupem (NN_c) a modely pomocí neuronové sítě s kategoriálním výstupem (NN_k).

	LIN	NN_c	NN_k
JAN	0,34	0,24	0,47
FEB	----	----	----
MAR	0,12	0,26	0,27
APR	0,41	0,47	0,45

MAY	0,12	0,24	0,14
JUN	0,06	0,17	0,40
JUL	0,04	0,15	0,18
AUG	0,30	0,48	0,60
SEP	0,37	0,47	0,47
OCT	0,42	0,48	0,51
NOV	0,00	0,32	0,40
DEC	0,15	0,27	0,36



Obr.4.3.1 Grafické znázornění hodnot LEPS score předpovědních modelů pro měsíční teploty v ČR; lineární (LIN), modely nalezené pomocí neuronové sítě s číselným výstupem (NN_c) a modely nalezené pomocí neuronové sítě s kategoriálním výstupem (NN_k).

5. Závěr

Dlouhodobým předpovědím (tedy podle definice uváděné Světovou meteorologickou společností předpovědím na třicet dní až dva roky dopředu) je poslední dobou věnována značná pozornost meteorologů a klimatologů. Do značné míry je tento fakt dán tlakem veřejnosti, pro kterou by tyto informace byly velmi užitečné, protože by mohly pomoci snížit škody způsobené dlouhodobým vývojem počasí. Překážky bránící využívání dlouhodobých předpovědí mají několik příčin. Nejdůležitější je v tom, že předpověditelnost na tak dlouhých časových horizontech je pouze omezená, a použitelné předpovědi jsou zatím dostupné pouze pro některé regiony a období.

Tato práce se zabývá možností dlouhodobých předpovědí pro oblast České Republiky. Dlouhodobé předpovědi pro oblast Evropy (a tím pádem i pro Českou Republiku) jsou dostupné na webových stránkách několika předpovědních center (viz 1.3). Co se týče možností dlouhodobých předpovědí, které by byly produkovány přímo v České Republice, do budoucna se zde rýsuje možnost využití dynamického modelu Aladin Climate, který je provozován v Českém hydrometeorologickém ústavu, ale experimenty jsou teprve v začátcích. Provozování dynamického modelu je navíc velmi náročné na strojový čas, a tím pádem i finančně. Proto jsem se pokusila o sestavení jednoduchých empirických modelů pro předpověď průměrných měsíčních teplot vzduchu v ČR na základě vytipovaných prediktorů.

Zdrojem průměrných měsíčních teplot vzduchu (dále jen měsíční teploty) ze stanic v ČR byla databáze Českého hydrometeorologického ústavu. Celé naše území bylo popsáno jedinou teplotní řadou, která byla sestavena na základě výsledků lineární regrese mezi hodnotami teplot v jednotlivých měsících a nadmořskou výškou z údajů ze cca 30 stanic, které jsou uvedeny v příloze v tabulce 1. Horské stanice Churáňov, Lysá hora, Praděd byly po předchozím testování vyloučeny. Regresní křivky byly spočteny pro každý měsíc každého roku zvlášť, a z nich odečtena hodnota pro nadmořskou výšku 400 metrů. Mezi vytipovanými prediktory byly potom řady měsíčních hodnot NAO indexů (the North Atlantic Oscillation), řady teplot povrchu Atlantiku (SST) a řady předcházejících měsíčních teplot v ČR. Míra těsnosti vztahu mezi těmito potenciálními prediktory a měsíčními teplotami vzduchu v ČR byla zkoumána pomocí korelačních koeficientů (viz 3.2). Několik vhodných prediktorů (ty, které měly statisticky významné korelační koeficienty vysokých hodnot s hodnotami měsíčních teplot u nás) bylo použito při sestavování jednoduchých předpovědních modelů pro hodnoty měsíčních teplot v ČR (tabulky 3.2.1, 3.2.2, obrázky 3.2.1 až 3.2.23).

Pro srovnání jsem hledala modely lineární (sestavené pomocí vícenásobné lineární regrese, viz 2.2.1) i nelineární (sestavené pomocí neuronových sítí, viz 2.2.2). Byly testovány dva typy neuronových sítí, s číselným výstupem (kdy výsledkem byla číselná hodnota měsíční teploty v ČR) a s kategoriálním výstupem (kdy výsledkem byla kategorie – podnormální, normální nebo nadnormální – do které měsíční teplota v ČR patří). Vyhodnocování modelů probíhalo metodou

křížové validace (viz 4.2). Výsledné hodnoty měsíčních teplot byly i v případě modelů s číselnými výstupy rozděleny do jednotlivých kategorií (podnormální, normální nebo nadnormální) a výsledky byly zaznamenány do tabulek 4.2.1 až 4.2.11. Jako validační charakteristika bylo použito Linear Error in Probability Space (LEPS) score , popřípadě v některých případech i Ranked Probability Skill Score (RPSS); viz 2.3. Čím vyšší hodnoty LEPS score bylo dosaženo, tím je model lepší. Hodnota LEPS score kolem 0,4 naznačuje už jistou „použitelnost“ modelu. Bezchybný model by dosáhl LEPS score rovné 1.

Nevýhodou mého pokusu o měsíční předpovědi teplot je to, že výsledky validačních charakteristik (konkrétně RPSS, které je využíváno pro vyhodnocování rozšířenějšího typu pravděpodobnostní předpovědi) nemohou být jednoduše srovnány s výsledky předpovědi předpovědních center (ECMWF, IRI), protože jejich předpovědi jsou produkovány na tříměsíční období. Velmi rozdílné výsledky empirických modelů v jednotlivých měsících však ukazují na to, že měsíční krok může být v našem případě užitečný.

Výsledky validace jsou shrnuty v tabulce 4.3.1 a na obrázku 4.3.1. Nejlepší nalezené neurální sítě byly typu MLP (Multilayer perceptron neural networks), u nás překládáno jako vícevrstevné perceptronové sítě (např. Hsieh, Tang, 1998). Modely sestavené s pomocí neuronových sítí jsou výrazně lepší než modely lineární. Neuronové sítě s kategoriálním výstupem jsou jako celek o něco lepší než neuronové sítě s číselným výstupem, ale neplatí to pro všechny měsíce. Ukázalo se, že pro některé měsíce nejsou empirické předpovědi jako celek přínosné, ale pro některé měsíce (leden, duben, srpen, září a říjen) by se daly využít.

Doporučila bych další experimenty s delšími datovými řadami, protože právě malé množství dat bylo velmi limitujícím faktorem. Pro zlepšení výsledků modelů by se mohly zkusit přidat i další atmosférické prediktory, například hodnoty vybraných výšek tlakových hladin, popřípadě indexů dalších cirkulačních systémů. Více experimentů by si zasloužily neuronové sítě s takovou konfigurací, které umožňují na výstupu odečítat přímo pravděpodobnosti jednotlivých kategorií.

Nabízí se také možnost vyzkoušet sestavení empirických modelů pro měsíční úhrny srážek pro vybrané stanice. Výsledky modelování úhrnů srážek lze však očekávat, vzhledem k větší variabilitě a silné orografické závislosti, celkově horší, než zde uvedené výsledky modelování teplot .

Literatura:

Anderson et. al., 1999: Present-day capabilities of numerical and statistical models for atmospheric extratropical seasonal simulation and prediction, Bull. Amer. Meteorol. Soc., **80**, s.1349-1362.

Barnston, Anthony G., 1992: Correspondence among the Correlation, RMSE, and Heidke Forecast Verification Measures; Refinement of the Heidke Score. Weather and Forecasting, 4, s. 699–700.

Barnston, A.G., 1994: Linear statistical short-term climate predictive skill in the Northern Hemisphere, J.Climate, 7, s.1513-1564.

Barnston A.G., Livezey R.E., 1987: Classification, Seasonality and Persistence of Low-Frequency Atmospheric Circulation Patterns. Monthly Weathwr Review, Vol. 115, str.1083-1126.

Bengtsson, L., Schlese, U., Roeckner, E., Latif, M., Barnett, T. P.,Graham, N. E., 1993:A Two tiered approach to long-range climate forecasting, Science, 261, s.1026-1029.

Bishop, C., 1995: Neural Networks for Pattern Recognition. Oxford: University Press.

Bridle, J.S., 1990: Probabilistic interpretation of feedforward classification network outputs, with relationships to statistical pattern recognition. In F. Fogelman Soulie and J. Hérault (Eds.), Neurocomputing: Algorithms, Architectures and Applications, 227-236. New York: Springer-Verlag.

Casey, T. M., 1998: Assessment of a seasonal forecast model, Austr. Meteorol. Mag., 44, s.219-224.

Charney, J.G., Shukla, J., 1981: Monsoon Dynamics, Cambridge University Press, New York, s.99-109.

Colman, A., Davey, M., 1997: Prediction of Summer Temperature, Rainfall and Pressure in Europe from Preceding Winter North Atlantic Ocean Temperature, Int. J. Climatol., 12, 1997, s.1285-1300.

Delecluse, P., Davey, M. K., Kitamura, Y., Philander, S. G. H., Suarez, M., Bengtsson, L., 1998: Coupled general circulation modeling of the tropical Pacific, J. Geophys. Res., 103, s. 14357-14373.

Frankignoul, C., 1985: Sea surface temperature anomalies, planetary waves and air-sea feedback in the middle latitudes, Rev. Geophys., 23, s.357-390.

Gray, W. M., Landsea, C. W., Mielke, P. W., Berry, K. J., 1992: Predicting Atlantic seasonal hurricane activity 6-11 months in advance, Wea. Forecasting, 7, s.440-455.

Gray, W. M., Landsea, C. W., Mielke, P. W., Berry, K. J., 1994: Predicting Atlantic basin seasonal tropical cyclone activity by 1 June, Wea. Forecasting, 9, s. 103-115.

Hamill, T. M., 1997: Reliability diagrams for multicategory probabilistic forecasts, Wea. Forecasting, 12, s. 736-741.

Hastenrath, S., 1995: Recent advances in tropical climate prediction, J. Climate, 8, s.1519-1532.

Haykin, S., 1999: Neural networks: A comprehensive foundation (2nd edition). Prentice Hall, Upper Saddle River, New Jersey.

Hebák, P., Hustopecký, J., 1987: Vícerozměrné statistické metody s aplikacemi, SNTL Praha.

Hsieh, W. W., Tang, B., 1998: Applying neural network models to prediction and data analysis in meteorology and oceanography, Bull. Amer. Meteor. Soc. 79, 1855-1870.

Hsu, W., R., Murphy, A. H., 1986: The attributes diagram: a geometrical frame work for assessing the quality of probability forecasts, *Int. J. Forecasting*, 2, s.285-293.

Hunt, B.G., 1997: Prospects and problems for multi-seasonal predictions: some issues arising from a study of 1992, *Int. J. Climatol.*, 17, s.134-154.

Hutchinson, P., 1992: The Southern Oscillation and prediction of Der season rainfall in Somalia, *J. Climate*, 5, s.525-531.

Johansson, A., Barnston, A., Saha, S., Van Den Dool, H., 1998: On the Level and Origin of Seasonal Forecast Skill in Northern Europe, *J. Atmos. Sci.*, 55, s.103-127.

Kennedy, W. J., Jr., Gentle, J. E., 1980: *Statistical Computing*, New York, Marcel Dekker.

Kliegrová, S., 2003: Současné přístupy k sezónním předpovědím a hodnocení jejich úspěšnosti, *Meteorolog. Zpr.*, 56, č.3, str.65-72.

Kumar, A. et. al., 2000: Changes in the spread of the variability of the seasonal mean atmospheric states associated with ENSO, *J.Climate*, 17, s. 3139–3151.

Landman, W. A., Mason, S.J., 1999: Operational prediction of South African rainfall using canonical correlation analysis, *Int. J.Climatol.*, 19, 1073-1090.

Landman, W. A. et. Al, 2001: Retro-active skill of multi-tiered forecasts of summer rainfall over southern Africa, *Int. J. Climatol.*, 1, s.1-19.

Lehmiller, G. S., Kimberlain, T. B., Elsner, J. B., 1997: Seasonal prediction models for North Atlantic basin hurricane location, *Mon. Wea. Rev.*, 125, 1780–1791.

Marshall, J., Kushnir, Y. , Battisti, D., Chang, P., Czaja, A., Dickson, R., McCartney, M., Saravanan, R., Visbeck, M., 2001: North Atlantic Climate Variability: phenomena, impacts and mechanisms. *Inter. Jour. Climatology*, 15, s.1863-1898.

Mason, S.J., 1998: Seasonal forecasting of South African rainfall using a non-linear diskriminant analysis model, *Int. J. Climatol.*, 18, s.147-164.

Meloun, M., Militký, J., Hill, M., 2005: Počítačová analýza vícerozměrných dat v příkladech, *Academia*

Metelka, L., 2001: Optimalizace kategoriálních předpovědí, *Meteorolog. Zpr.*, 54, č.2, s.39-45.

Michaelsen, J., 1987: Gross-validation in statistical climate forecast models. *J. Clim. Appl. Meteorol.*, 26, 1589-1600.

Mutai, C. C. et al., 1998: Towards the prediction of the East Africa rains based on sea-surface temperature-atmosphere coupling, *Int. J. Climatol.*, 18, s.975-997.

Neelin, J. D., Battisti, D. S., Hirst, A. C., Jin, F. F., Wakata, Y., Yamagata, T., Zebiak, S. E., 1998: ENSO theory, *J. Geophys. Res.*, 103, s. 14261–14290.

Osborn, T. J., Hulme, M., 1998: Evaluation of the European daily precipitation characteristics from the atmospheric model intercomparison project, *Int. J. Climatol.*, 18, s. 505–522.

Potts, J.M. et al., 1996: Revised „LEPS“ Scores for Assessing Climate Model Simulations and Long-Range Forecast, *J. Climate*, 9, s.34-52.

Ropelewski, C. F., Halpert, M., 1987: Global and regional scale precipitation patterns associated with the El Niño/Southern Oscillation, *Mon. Wea. Rev.*, 115, s. 1606–1626.

Ropelewski, C. F., Halpert, M., 1989: Precipitation patterns associated with the high index phase of the Southern Oscillation, *J. Climate*, 2, s. 268–284.

Shabbar, A., Barnston, A.G., 1996: Skill of seasonal climate forecasts in Canada using canonical correlation analysis, *Mon. Wea. Rev.*, 124, s.2370-2385.

STATISTICA: Neural Networks. Manuál k programu STATISTICA:Neural Networks. StatSoft Inc., Tulsa, Oklahoma, USA, 1998

Thiaw, W. et al., 1999: Predictions of African rainfall on the seasonal timescale, *J. Geophys. Res.*, 104, s.31589-31597.

Uvo, C.B., et al., 1998: The relationships between tropical Pacific and Atlantic SST and northeast Brazil monthly precipitation, *J. Climate*, 13, s.287-293.

Von Storch H., Zwiers W., 1999: *Statistical Analysis in Climate Research*. Cambridge University Press, Cambridge.

Wilby, R. L., Wigley, T. M. L., 1997: Downscaling general circulation model output: A review of methods and limitations, *Prog. Phys. Geogr.*, 21, s.530-548.

Wilks, D. S., 1995: *Statistical Methods in the Atmospheric Sciences*, International Geophysics Series, 59, Academic Press, San Diego, s. 464 pp.

Xu, J.S., von Storch, H., 1990: Principal oscillation pattern: prediction of the state of ENSO, *J. Climate*, 3, s.1316–1329.

Xue, Y., Cane, M. A., Zebiak, S. E., Blumenthal, M. B., 1994: On the prediction of ENSO: A study with a low-order Markov model, *Tellus*, 46A, s. 512–528.

Internetové adresy (stav ke květnu 2006):

[1] WMO, Standardised Verification System for Long-Range Forecasts,
<http://www.wmo.ch/web/www/DPS/LRF/LRF-standardised-verif-sys-2002.pdf>

[2] ECMWF, sezónní předpovědi,
<http://www.ecmwf.int/products/forecasts/seasonal/>

- [3] IRI, sezónní předpovědi,
http://iri.columbia.edu/climate/forecast/net_asmt/
- [4] MetOffice, sezónní předpovědi
<http://www.metoffice.gov.uk/research/seasonal/>
- [5] MetOffice, empirické předpovědi letních teplot vzduchu v Evropě,
http://www.metoffice.gov.uk/research/seasonal/regional/european_summers/index.html
- [6] CPC, sezónní předpovědi,
http://www.cpc.ncep.noaa.gov/products/analysis_monitoring/lanina/ensoforecast.html
- [7] NASA, sezónní předpovědi
http://nsipp.gsfc.nasa.gov/exptlpreds/exptl_preds_main.cgi
- [8] ČHMÚ, sezónní předpovědi
http://www.chmi.cz/poboc/HK/OK/CLIMFOR/cf_main.htm
- [9] NCAR, zdroj měsíčních hodnot teplot povrchu Atlantiku,
<http://dss.ucar.edu/>
- [10] CPC, zdroj měsíčních hodnot NAO indexů
<http://www.cpc.ncep.noaa.gov/data/teledoc/telepatcalc.html>

Doplnění seznamu literatury:

Kennedy, W. J., Jr., Gentle, J. E., 1980: Statistical Computing, New York, Marcel Dekker.