

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE
Fakulta životního prostředí
Katedra vodního hospodářství a environmentálního modelování

**Předpověď vybraných indikátorů sucha
modely neuronových sítí**

Diplomová práce

**Vedoucí práce: doc. Ing. Petr Máca, Ph.D.
Diplomant: Bc. Martina Dubská**

2017

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Martina Dubská

Environmentální modelování

Název práce

Předpověď vybraných indikátorů sucha modely neuronových sítí

Název anglicky

The forecast of selected drought indices using neural networks

Cíle práce

Cílem práce je analýza předpovědí indikátorů sucha vybranými modely neuronových sítí na vybraných povodích v České republice.

Metodika

Při řešení práce se zaměřte na:

1. Výběr lokalit a přípravu vstupních dat
2. Odhad vhodných indikátorů sucha
3. Přípravu předpovědních modelů indikátorů sucha, které budou založeny na modelech neuronových sítí
4. Vyhodnocení předpovědi analyzovaných indikátorů sucha

Doporučený rozsah práce

standardní

Klíčová slova

standardní

Doporučené zdroje informací

Bishop, C. M. Neural Networks for Pattern Recognition. Oxford University Press, Inc., 1995. ISBN 0198538642.

Máca, P. – Pech, P. – Pavlasek, J. Comparing the Selected Transfer Functions and Local Optimization Methods for Neural Network Flood Runoff Forecast. Mathematical Problems in Engineering. 2014.

Mishra, A. K. – Singh, V. P. Drought modeling – A review. Journal of Hydrology. JUN 6 2011, 403, 1-2, s. 157–175.

Morid, S. – Smakhtin, V. – Bagherzadeh, K. Drought forecasting using artificial neural networks and time series of drought indices. International Journal of Climatology. DEC 2007, 27, 15, s. 2103–2111.

WoS a SCOPUS

Předběžný termín obhajoby

2016/17 LS – FŽP

Vedoucí práce

doc. Ing. Petr Máca, Ph.D.

Garantující pracoviště

Katedra vodního hospodářství a environmentálního modelování

Elektronicky schváleno dne 4. 4. 2017

doc. Ing. Martin Hanel, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 5. 4. 2017

prof. RNDr. Vladimír Bejček, CSc.

Děkan

V Praze dne 18. 04. 2017

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně, pod vedením doc. Ing. Petra Máci, Ph.D., a že jsem uvedla všechny literární prameny, ze kterých jsem čerpala.

V Praze 7. dubna 2017

Bc. Martina Dubská

Poděkování

Ráda bych poděkovala svému vedoucímu práce doc. Ing. Petrovi Mácovi, Ph.D. za ochotu, trpělivost, čas a cenné rady, které mi během psaní mé práce věnoval.

V Praze 7. dubna 2017

Bc. Martina Dubská

Abstrakt

Obsahem této diplomové práce je predikce indikátorů sucha pomocí neuronových sítí na čtrnácti povodí v České republice. K hodnocení sucha byly vybrány tři indikátory: standardizovaný srážkový indikátor (SPI), standardizovaný srážkový evapotranspirační indikátor (SPEI) a indikátor nasycenosti půdy (SSI). V první části je uveden popis a rozdělení sucha, dále je uveden krátký přehled indikátorů sucha a umělých neuronových sítí. Dále je popsána metodika výpočtu indikátorů a výsledky. V této práci byl testován autoregresní model, pro výpočet byla zvolena vrstevnatá síť (MLP) s dvěma skrytými vrstvami s dopředným šířením signálu učená algoritmem zpětného šíření chyby.

Klíčová slova: sucho, indikátor, umělé neuronové sítě

Abstract

The aim of this thesis is to predict drought indices using artificial neural networks (ANN) on fourteen basins in the Czech republic. The analyzed drought indices are the standardized precipitation index (SPI), the standardized precipitation evapotranspiration index (SPEI) and the standardized soil moisture index (SSI). The first part deals with description and distribution of drought, furthermore, the paper describes selected drought indices and artificial neural networks. The next section describes methodology of calculating the indices and results. Tested artificial neural network was multilayer perceptron (MLP) with two hidden layers and was trained using back propagation algorithm.

Key words: drought, index, artificial neural networks

OBSAH

Obsah	8
1 Úvod a cíle práce	11
1.1 Úvod	11
1.2 Cíl práce	12
2 Definice a rozdělení sucha	13
2.1 Definice sucha	13
2.2 Rozdělení sucha	13
2.2.1 Meteorologické sucho	14
2.2.2 Hydrologické sucho	14
2.2.3 Agronomické sucho	14
2.2.4 Socioekonomické sucho	15
2.3 Dopady sucha	15
2.4 Hodnocení sucha	15
2.4.1 Přehled vybraných indikátorů sucha	17
3 Umělé neuronové sítě	21
3.1 Formální neuron	21
3.2 Topologie neuronových sítí	22
3.2.1 Vrstevnatý perceptron	23
3.2.2 RBF sítě	23
3.2.3 Rekurentní ANN	23
4 Data a aplikované metody	25
4.1 Metodika výpočtu indikátorů sucha	26
4.2 Výběr modelu neuronové sítě	26
4.3 Kritéria	27
5 Výsledky a diskuse	31

5.1	Výpočet indikátorů sucha	31
5.1.1	Výpočet indikátoru SPI	31
5.1.2	Výpočet indikátoru SPEI	32
5.1.3	Výpočet indikátoru SSI	32
5.2	Neuronové sítě	33
5.3	Diskuze	33
6	Závěr	67
7	Přílohy	69
	Literatura	73

Kapitola 1

ÚVOD A CÍLE PRÁCE

1.1 Úvod

Sucho je pravděpodobně jednou z nejvíce významných přírodních katastrof, která zasahuje společnost a životní prostředí po celém světě. Od ostatních přírodních katastrof se odlišuje tím, že není jednoduché stanovit jeho začátek a konec [Blinka, 2004].

V oblastech tropických deštných lesů (např. Bali) nastává sucho již po šesti dnech bez výskytu srážek, taková definice sucha nemůže být uplatněna v pouštních oblastech (např. Libye), kde jsou roční srážky nižší než 180 mm. Obecně lze tedy sucho definovat, jako nedostatek srážek v delším časovém období, v České republice je to v řádech týdnů až měsíců, který vede k deficitu vody pro určité životní prostředí. V České republice vyvolá sucho problémy zejména v zemědělství a hydroenergetice, avšak díky vysoké vodohospodářské infrastruktuře (vodní nádrže, vodovody) zatím nedošlo k mnohem horším krizím, jako například přerušení dodávek pitné vody pro obyvatelstvo [Elleder, 2013].

V roce 2015 zasáhla západní a střední Evropu, včetně České republiky, významná epizoda sucha, která vznikla kombinací deficitu srážek, vysokých teplot a vysokým výparem. Tyto meteorologické příčiny poté měly za následek deficit půdní vlhkosti, následný pokles průtoků na vodních tocích a snížení hladiny podzemní vody. Ve stejném pořadí i sucho odeznívá, a proto i při nadměrném úhrnu srážek může sucho přetrvávat. V roce 2015 trápil nedostatek srážek Českou republiku již od února, nedostatek pokračoval i přes jarní měsíce, v červnu se deficit ustálil na čtvrtině průměrného kumulovaného srážkového úhrnu. V období od 1. ledna do 31. srpna 2015 byl průměrný úhrn srážek 352 mm, což představuje od roku 1961 druhý nejnižší srážkový úhrn, nižší srážkový úhrn nastal v roce 2003 s hodnotou 335 mm [David and Davidová, 2016].

Pravděpodobnost výskytu sucha je jeden z dopadů klimatických změn, i když se výsledky různých klimatických modelů v předpovědi změny

režimu srážek výrazně liší v obou směrech, odhady změn teploty vzduchu vedou k vyšším hodnotám evapotranspirace, které mají negativní vliv na vodní bilanci [Elleder, 2013].

K predikci a hodnocení sucha nám slouží indikátory sucha, dále je lze použít k přípravě návrhů pro zvládnání sucha, nedostatku vody a ke koncepci řešení krizových situací. Indikátory rozšiřují a sjednocují systém včasného varování před výskytem hydrologického sucha a dávají nám informace o jeho průběhu [Vlnas et al., 2014].

1.2 Cíl práce

Hlavním cílem této diplomové práce, je analýza předpovědi vybraných indikátorů sucha pomocí modely umělých neuronových sítí na povodích v České republice. Zbytek práce je rozdělen na popis samotného sucha, indikátorů sucha, umělých neuronových sítí a popis datového souboru vybraných povodí. Další část obsahuje výsledky předpovědi analyzovaných indikátorů sucha a závěr diplomové práce.

Kapitola 2

DEFINICE A ROZDĚLENÍ SUCHA

2.1 Definice sucha

Definice sucha existuje celá řada, např. [Wilhite, 2000] uvádějí přes 150 publikovaných definic sucha. Jednu z hlavních definic uvedl [Thornthwaite, 1948], který sucho rozděluje na hlavní tři druhy:

- **stálé** nejsušší klimatická pásma
- **sezónní** některá klimatická pásma v monzunových oblastech
- **nahodilé** v důsledku nepravidelných a proměnlivých četností a intenzit výskytu srážek.

Sucho je jedním z hlavních přírodních rizik, od ostatních (např. povodně, tropické cyklóny, zemětřesení) se však odlišuje tím, že je velmi obtížné stanovit jeho počátek a konec. Účinky sucha mají kumulativní charakter, neboť velikost intenzity sucha se zvyšuje s jeho délkou, a proto jsou jeho následky ohromné [Blinka, 2004].

Sucho lze definovat jako deficit srážek vzhledem k očekávané srážce (normálu), který se vyskytuje v průběhu sezóny nebo delší části roku [Wilhite, 1991]. Sucho, jako přechodná anomálie klimatu, která se může vyskytovat ve všech klimatických zónách (srážkových režimech) a liší se tak od aridity (úhrn srážek je nižší než výpar nebo vsak), která je považována za trvalý znak klimatu [Blinka, 2004].

2.2 Rozdělení sucha

Ve většině vědeckých prací se sucho rozděluje na sucho meteorologické, hydrologické, agronomické a socioekonomické. První tři definice počítají sucho jako fyzický úkaz, poslední se zabývá suchem z hlediska nabídky a poptávky, sledování dopadů nedostatku vody jako řetězovou reakcí skrz socioekonomickou sféru [Wilhite and Glantz, 1985].

2.2.1 Meteorologické sucho

Meteorologické sucho je obvykle definováno na základě míry suchosti (v porovnání s "normálem" nebo s průměrnými hodnotami) a trvání suchého období. Definice meteorologického sucha musí být dobře uvážena v závislosti na regionu. Některé definice meteorologického sucha rozlišují periody sucha na základě počtu dní, kdy se vyskytovaly srážky s nižším prahem. Toto měřítko je vhodné pro regiony charakteristické s ročním srážkovým režimem, jako jsou tropické deštné pralesy, vlhké subtropické podnebí nebo pásy vlhkého mírného podnebí, jako jsou například tyto lokace: Manaus, Brazílie; New Orleans, Louisiana (USA); a Londýn, Anglie. Ostatní klimatické režimy jsou charakterizovány sezónním srážkovým vzorcem, např.: centrální státy v USA, severovýchod Brazílie, Západní Afrika a severní Austrálie. Delší periody bez úhrnu srážek jsou společné pro Omahu, Nebraska (USA); Fortaleza, Ceará (Brazílie); a Darwin, Severní Teritorium (Austrálie) [Wilhite, 2000].

2.2.2 Hydrologické sucho

Hydrologické sucho popisuje nedostačující množství povrchových a podpovrchových vod. Hydrologické sucho se může vyskytovat, i když už meteorologické sucho skončilo a také se nemusí objevit během něj, většinou se objevuje ke konci dlouho trvajícího sucha, během kterého se neobjevily kapalné ani smíšené srážky [Tate and Gustard, 2000].

2.2.3 Agronomické sucho

Agronomické sucho nastává, když není v půdě dostatek vláhy pro určitou plodinu v dané vegetační fázi. Agronomické sucho definuje sucho meteorologické, které má přímé dopady na zemědělství, hlavně např. nedostatek srážek, odchylka od normálu nebo mnohé meteorologické faktory jako je evapotranspirace. Nároky rostlin na vodu jsou odkázány na převažujících meteorologických podmínkách, biologických charakteristikách jednotlivých rostlin, jako je vegetační fáze růstu, fyzikálních a biologických vlastnostech půdy. Funkční definice agronomického sucha by měla považovat nestálou citlivost úrody v různých fázích sklizně. [Tallaksen and Van Lanen, 2004] Například, nedostatek vláhy v podloží v brzké fázi růstu

bude mít malý vliv na konečný výtěžek sklizně, pokud je množství vody v ornici dostačující pro růstové podmínky. Avšak, pokud nedostatek vláhy v podloží přetrvává, ztráty při sklizni budou značné [Tate and Gustard, 2000].

2.2.4 Socioekonomické sucho

Následky výše zmíněných such mají dopad na sucho socioekonomické, které nastává, když nedostatek vody začne mít vliv na společnost a hospodářství. Nastává když poptávka vody převyšuje nabídku [Tate and Gustard, 2000].

2.3 Dopady sucha

Dopady sucha ovlivňují všechny části našeho prostředí a společnost, dopady lze rozdělit do tří hlavních kategorií: environmentální, ekonomické a sociální dopady, které lze dále rozdělit na přímé a nepřímé. Stručný přehled dopadů sucha je uveden v tabulce 2.1 [Tallaksen and Van Lanen, 2004].

2.4 Hodnocení sucha

K vyhodnocení sucha se používají indikátory sucha. Metody pro vyhodnocení sucha by měly splňovat tato kritéria:

robustnost neboli odolnost vyjadřuje užitečnost přes širokou škálu fyzických podmínek

kontrolovatelnost (z anglického tractability) představuje praktické vlastnosti/aspekty indikátoru sucha, např. těžko řešitelný indikátor může vyžadovat vysoký stupeň numerického počítání, nebo vlastní kroky výpočtu mohou být mimořádně komplikované. Složitý indikátor může také požadovat data, která jsou jen řídce pozorována nebo potřebují pro výpočet rozsáhlá historická měření

transparentnost uvažuje srozumitelnost cíle a důvodu za indikátorem. Považuje se to za důležité měřítko, pragmatický indikátor sucha by měl být srozumitelný nejen vědeckému okruhu, ale také přidružené společnosti. Toto je důvod, proč je nedostatek vody často v médiích

Tabulka 2.1: Příklady dopadů sucha

ASPEKTY	Přímé	Nepřímé
Environmentální	<ul style="list-style-type: none"> Půdní vlhkost Hladina podzemní vody Průtok podzemní vody Pokles pramenů Průtoky Výška hladiny jezera Výška hladiny vodní nádrže Rychlost vody Výška hladiny vody 	<ul style="list-style-type: none"> Kvalita vody Růst rostlin Přírozené prostředí Ohrožené druhy Písečné bouře Lesní požár
Ekonomické	<ul style="list-style-type: none"> Jímání podzemní vody Odběr povrchové vody Odtok z nádrže Snížené úrody 	<ul style="list-style-type: none"> Závlaha Užitková voda Neúroda Úmrtí domácích zvířat Splavnost řek Vodní energie Vyšší cena potravin a krmiva Ekonomický růst
Sociální	<ul style="list-style-type: none"> Pití vody 	<ul style="list-style-type: none"> Konflikty mezi spotřebiteli vody Nezaměstnanost Hladomor Chudoba Zdraví Migrace Úmrtí

popisován procentuálně, a proto transparentnost může představovat hlavní vlastnost

propracovanost je poněkud v rozporu s předešlým bodem, transparentností, klade důraz na kvalitu dat a pokud je to nutné, je zapotřebí použít náročné metody

roztžitelnost v čase

rozměrnost výsledná hodnota by měla mít odpovídající jednotky

citlivost důležitá vlastnost

přenositelnost a porovnatelnost mezi různými regiony, výsledné hodnoty je možné použít pro rajonizaci [Keyantash and Dracup, 2002].

2.4.1 Přehled vybraných indikátorů sucha

Světová meteorologická organizace (The World Meteorological Organization) definovala indikátor sucha jako *"indikátor, který se vztahuje k některým z kumulativních účinků dlouhotrvajícího a abnormálního nedostatku vlhkosti"*.

Indikátory sucha jsou nepostradatelným nástrojem k detekci, sledování a hodnocení epizod sucha. Stejně jako neexistuje univerzálně platný způsob stanovení sucha, tak není k dispozici ani podobně platný indikátor. V literatuře můžeme najít více než 160 indikátorů sucha, lze je rozdělit na indikátory: **meteorologické, všeobecné, hydrologické, kombinované a založené na dálkovém průzkumu Země.** [Niemeyer et al., 2008].

Indikátory nejčastěji reprezentují vztah mezi pozorovanými hodnotami sledované veličiny a jejich dlouhodobými normály. Obvykle se nejedná přímo o samotnou fyzikální veličinu – indikátor je bezrozměrný. Může se jednat i o kombinaci více typů dat. Odlišnosti mezi jednotlivými indikátory spočívají především ve:

- způsobu, jakým je tato odchylka od normálu stanovována
- v jakém časovém kroku je indikátor vyhodnocován
- jak dlouhé období indikátor charakterizuje (časový interval).

Účelem indikátorů je zprostředkovat popis a mapování případů sucha. Indikátory tedy musí umožnit stanovení hlavních charakteristik sucha: délku trvání (počátek, konec), velikost, intenzitu, četnosti výskytu a plošný rozsah [Elleder, 2013].

V dnešní době se zdá být nevhodnější, ale zároveň i nejnáročnější cestou ke komplexnímu pojetí popisu sucha kombinace indikátorů z různých oborů, např. hlavními indikátory pro sledování sucha ve Spojených státech amerických (U.S. Drought Monitor) jsou standardizovaný srážkový indikátor, Palmerův indikátor závažnosti sucha nebo model CPC nasycenosti půdy a kvantily týdenních průtoků [Elleder, 2013].

Z hlediska nejnáze pozorovatelných vlivů rozvíjejícího se hydrologického sucha na stav vodních zdrojů, by bylo logické soustředit se zejména na indikátory, které nějakým způsobem uvažují s odtokem vody nebo zásobami vody v povodí [Elleder, 2013].

Standardizovaný srážkový indikátor (z anglického The Standardized Precipitation Index, dále jen SPI, 1993) se využívá k vyhodnocení meteorologického sucha, ale lze jej použít i pro posouzení sucha agronomického a hydrologického. Jeho hlavní dvě výhody jsou jednoduchost, stačí znát jen srážková data, a že umožňuje popsat sucho na několika časových řadách. Je velmi účinný, když je aplikován pouze na jeden region nebo jediné období. Indikátor SPI využívá většina systémů monitoringu sucha [Gocic and Trajkovic, 2014].

Indikátor SPI vychází z vyhodnocení srážkových dat, která jsou vyjádřena pomocí svého rozdělení pravděpodobnosti, které je dále spojeno s normálním rozdělením s nulovou střední hodnotou a jednotkovou směrodatnou odchylkou. Stanovení SPI se skládá z odhadu parametrů rozdělení pravděpodobnosti srážkových dat a výpočtu hodnot pravděpodobnosti z odhadnuté distribuční funkce pro daná srážková data. Následně jsou odhadnuté pravděpodobnosti transformovány inverzní funkcí k distribuční funkci normovaného rozdělení pravděpodobnosti [?].

Standardizovaný srážkový evapotranspirační indikátor (z anglického The standardized precipitation evapotranspiration index, dále jen SPEI) vychází ze srážkových a teplotních dat. Informace o teplotách je transformována do informace o potenciální evapotranspiraci. SPEI indikátor je vyjádřen za pomoci rozdílu mezi srážkovými daty a potenciální evapotranspirací. Výpočet je shodný s odhadem SPI indikátorem, jediným

rozdílem je použití rozdílu srážkových a evapotranspiračních dat namísto srážkových dat [?].

Standardizovaný indikátor nasycenosti půdy (z anglického The standardized soil moisture index, dále jen SSI) je podobný předešlým indikátorům, počítá s historickými daty nasycenosti půdy, která se získávají empiricky pomocí Grigortenyovy metody pro odhad dat [AghaKouchak, 2014].

Mungerův index (MI) (1916) byl vyvinut pro posouzení rizika lesních požárů, je definován jako počet po sobě jdoucích dnů, ve kterých srážka nepřesáhla hranici 1,27 mm. Munger poznamenal, že vysychání lesní vegetace vlivem sucha není přímo úměrně s jeho trváním. Munger předpokládal, že intenzita sucha vzrůstá jako druhá mocnina jeho trvání, představil grafické znázornění intenzity, kde je oblast představena jako pravoúhlý trojúhelník. Vhodnější pro posouzení krátkodobých such, lze srovnávat rozdílné oblasti a období mezi sebou. Rovnice pro výpočet MI:

$$MI = 1/2L^2 \quad (2.1)$$

kde L představuje délku trvání sucha ve dnech.

Kincerův index (KI) (1919) je podobný jako Mungerův index, definuje sucho, kdy srážka nepřesáhla hodnoty 6,35 mm za 24 hodin po dobu 30 dní.

Marcovitchův indikátor (MRI) počítá s teplotou nad 32,2° a úhrnem srážek ve dnech, kdy tyto teploty nastaly.

$$MRI = \frac{1}{2} \cdot \left(\frac{N}{R} \right)^2 \quad (2.2)$$

kde: *N*...počet dní, *R*...úhrn srážek za měsíc. Často se tento indikátor využívá při zpětné studii.

Bluemnstockův indikátor (1942) ukončuje bezsrážkovou periodu, když srážka přesáhne hranici 2,54 mm za 48 hodin, využívá se pro krátkodobé sucho.

Index předchozího deště (z anglického Antecedent Percipitation index, 1954) původně byl navržen pro odhad nasycenosti půdy pro předpověď povodní. API počítá se srážkami, hodnota je násobena koeficientem, nejčastěji 0,9.

Indikátor přiměřené vlhkosti (z anglického Moisture Adequacy Index, 1957) slouží k posouzení zemědělského sucha, je založený na výpočtu z půdní vlhkosti a srážek.

Keetch-Byramův indikátor sucha (1968) slouží k předpovědi vzniku požárů. K výpočtu potřebujeme znát srážková data za posledních 24 hodin, maximální teplotu vzduchu a půdní vlhkost v souvislosti s vodní bilancí. Hodnoty jsou v rozmezí 0 až 800, čím nižší hodnota, tím nižší riziko vzniku požáru. [Janis et al., 2002].

Indikátor anomálního úhrnu srážek (z anglického Rainfall Anomaly Index, 1965) používá jako vstupní parametry srážková data, není složitý na výpočet. Slouží hlavně pro určení agronomického sucha. Srovnává historické hodnoty měření srážek v dané lokalitě s aktuálními hodnotami [Van Rooy, 1965].

Čínský Z indikátor (z anglického China Z Index, 1995) pro jeho výpočet je potřeba měsíčních srážkových dat, je poměrně jednoduchý na výpočet. Používá se při určení meteorologického sucha. Monitoruje suchá a vlhká období pro různá časová vymezení, je velmi podobný zde zmíněnému SPI indikátoru [Wu et al., 2001].

Palmerův indikátor závažnosti sucha (z anglického Palmer Drought Severity Index, 1965) je široce využívaný indikátor sucha, od svého vzniku prošel několika úpravami a existuje několik jeho variant, byl vyvinut ve Spojených státech amerických k vyhodnocení sucha ve vztahu k rostlině, půdě a atmosféře.

Standardizovaný odtokový indikátor (z anglického The Standardized Runoff Index, SRI) slouží k vyhodnocení prostorových změn hydrologického sucha v celém pozorovaném území. Matematicky, je SRI definován jako standardizované normálové rozdělení. Slouží k vyhodnocení prostorových změn hydrologického sucha v celé studované oblasti. Indikátor SRI odráží anomálie povrchového odtoku [Shukla and Wood, 2008].

Monitor sucha (Drought Monitor, 1999) sjednocuje několik indikátorů sucha, víceúčelový [Heim Jr, 2002].

Kapitola 3

UMĚLÉ NEURONOVÉ SÍTĚ

Umělé neuronové sítě (z anglického Artificial Neural Networks, dále jen ANN) vycházejí z činnosti lidského mozku, který je propojen vysokým počtem buněk- neuronů, které spolu komunikují pomocí elektrických impulsů. Hlavními složkami biologického neuronu jsou: synapse, axon, dendrit, tělo, Myelinová pochva a Schwannovy buňky. Formální neuron, neboli perceptron, je analogií neuronu biologického a je základní stavební jednotkou pro umělou neuronovou síť [Bishop, 1995].

Hlavní výhodou ANN je schopnost učit se, zapamatovat si kombinace, které vedly k požadovanému výstupu. Nové vstupy do sítě jsou již "ponaučeny" a na základě zkušeností odhadují výsledek. Možnosti aplikace ANN jsou např.:

- **regrese** předpověď spojité proměnné na základě vstupů
- **klasifikace** zařazování do tříd (bankovníctví, lékařství)
- **časové řady** (regrese) modelování spojitých proměnných, které procházejí vývojem v čase
- **časové řady** (klasifikace) závislá proměnná lze vysvětlit pouze svým historickým průběhem v čase
- **shluková analýza** nepoužívá závislou proměnnou (učení bez učitele), Kohonovova síť

3.1 Formální neuron

Základní stavební jednotku ANN je neuron, jeho chování lze rozdělit do tří kroků:

1. přijímání signálu a vytvoření aktivace neuronu
2. transformace přijímaného signálu aktivační funkcí

3. poslání transformovaného signálu v rámci ANN.

Vstup do neuronu reprezentuje vážený vstupní vektor x , synaptické váhy w jsou spojnicemi mezi buňkami, na základě vah mohou být jednotlivé vstupy potlačeny nebo zvýhodněny. Formální neuron je rozdělen na dvě části- sumační a aktivační. Výstupem sumační části je vážený součet vstupu- aktivace a , na kterou je aplikována aktivační funkce, mezi které patří např. skoková, lineární, Gaussova nebo logistická funkce. Výstupní hodnota neuronu je aktivita. Spojením několika neuronů vznikne neuronová síť. Neuron lze popsat následující rovnicí:

$$y = f \cdot \left(\sum_{i=1}^n x_i \cdot w_i - \theta \right) \quad (3.1)$$

kde: x_i vstupní hodnota na i -tém vstupu, W_i váha vstupu, θ prahová hodnota, n celkový počet vstupů, f aktivační funkce a y hodnota výstupu.

3.2 Topologie neuronových sítí

Sítě neuronů jsou tvořeny jednotlivými neurony, neuronové sítě mohou obsahovat jednu a více vrstev. Topologie je dána počtem vrstev a počtem neuronů ve vrstvách a jejich vzájemné propojení. Topologii neuronových sítí lze rozdělit dle těchto hledisek:

- **dle struktury** vrstevnaté, nevrstevnaté
- **dle propojení neuronů** plně propojené, neúplně propojené
- **dle směru šíření signálů ve vrstevnatých sítích** s dopředným šířením signálu nebo rekurentní síť.

Typy používaných modelů neuronových sítí je celá řada, dle využití si můžeme vybrat síť s různou topologií, způsobem přenosu a způsobem učení. Nejpoužívanějšími typy neuronových sítí v hydrologii jsou: vrstevnatý perceptron, RBF síť a rekurentní neuronové síť [Maier and Dandy, 2000].

3.2.1 Vrstevnatý perceptron

Vrstevnatý perceptron (z anglického Multilayer perceptron, dále jen MLP) obsahuje kromě vstupní a výstupní vrstvy jednu nebo více skrytých vrstev. Většinou se jedná o síť s dopředným šířením signálu. V hydrologii se používá například pro předpověď průtoků, srážek, koncentrace prvků, salinity, odtoku nebo konduktivity [Bowden et al., 2005].

MLP je neuronová síť, která šíří signál pouze jedním směrem. Síť je složena z jednotlivých jednotek – neuronů, které jsou uspořádány do vrstev. Mezi neurony jedné vrstvy není žádné propojení, které by umožňovalo vzájemnou komunikaci. Každý MLP se tedy skládá z daného počtu vrstev, které mají příslušný počet neuronů. Počet vrstev, neuronů a propojení je nazýváno architekturou neuronové sítě. Hlavní vlastností MLP je přijímání signálu k každému neuronu z předchozí vrstvy, každému spojení je přidána váha, soubor vah tvoří parametry daného modelu neuronových sítí [Máca, 2015].

3.2.2 RBF síť

Neuronové síť typu RBF (Radial Basis Function) jsou síť se dvěma vrstvami neuronů a dopředným šířením signálu. Charakteristickým rysem těchto sítí je převodní charakteristika skrytých neuronů, která je středově symetrická (radial symmetric). V neuronových aplikacích jsou RBF síť vážným konkurentem perceptronovským sítím (MLP). Přestože vznikly později přinášejí řadu výhod zejména v rychlosti učení.

Skrytou vrstvu tvoří RBF neurony. Pro výstupní vrstvu se používají neurony perceptronovského typu. Vstupy sítě a skryté neurony jsou úplně propojeny. Mezi skrytými a výstupními neurony bývá nejčastěji úplné propojení. V určitých případech mohou však být některé spoje vynechány na základě apriorní znalosti o kategoriích vstupních dat. Topologie sítě je naznačena na obr.1 [Park and Sandberg, 1991].

3.2.3 Rekurentní ANN

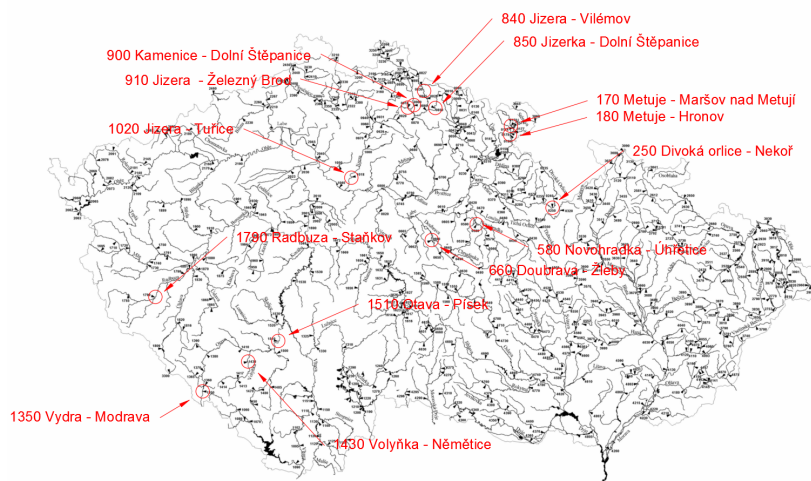
U tohoto typu sítě se signál nešíří pouze od vstupní vrstvy směrem k vrstvě výstupní, ale dochází i ke zpětnovazebnému přenosu informace od vrstev vyšších a zpět do vrstev nižších. Tato zpětná vazba je řešena

prostřednictvím tzv. rekurentních neuronů. Topologie rekurentní sítě se liší od klasické dalšími rekurentními neurony ve vstupní a vnitřní vrstvě. Ve střední vrstvě je jeden neuron odpovídající jednomu neuronu výstupní vrstvy a ve vstupní vrstvě jsou dva rekurentní neurony odpovídající dvou neuronům vnitřní vrstvy. Každý z těchto neuronů přijímá jediný vstupní signál od jemu příslušejícímu regulérního neuronu z následující vrstvy [Vondrák, 1995].

Kapitola 4

DATA A APLIKOVANÉ METODY

V této kapitole jsou popsána data a metody výpočtu. Pro výpočet indikátorů sucha a predikci ANN byla použita data z ČHMÚ, celkem se výpočet prováděl na 14 povodích, která jsou uvedena v tabulce 4.1 a zobrazeny na mapě, obrázek 4.1, kde DBC je zkratka pro databankové číslo vodoměrné stanice. Časové rozpětí datového souboru je od 1.ledna 1981 do 1.prosince 2015. Všechny výpočty byly provedeny pomocí statistického programu R.



Obrázek 4.1: Mapa s vybranými vodoměrnými stanicemi, upraveno a převzato z [ČHMÚ, 2017]

4.1 Metodika výpočtu indikátorů sucha

V této diplomové práci byly k předpovědi použity standardizované indikátory sucha SPI, SPEI a SSI. Jejich popis je uveden v kapitole 3. Pro jejich výpočet byl použit R balík SPEI [Beguería and Vicente-Serrano, 2013]. Pro výpočet rozdělení pravděpodobnosti u SPI indikátoru bylo použito gamma rozdělení a u SPEI bylo použito log-logistické rozdělení pravděpodobnosti. U indikátoru SSI počítáme s obsahem vody v půdní vrstvě 0-100 cm. Škály podle kterých se posuzuje závažnost sucha pro jednotlivé indikátory jsou uvedeny v tabulkách 4.2, 4.3 a 4.4.

Vstupní data pro indikátory:

- **SPI**: měsíční suma srážek [mm]
- **SPEI**: rozdíl měsíční sumy srážek [mm] a potenciální evapotranspirace
- **SSI**: obsah vody v půdní vrstvě 0-100 cm.

Pro statistický popis vypočtených indikátorů byly použity tyto veličiny: minimální hodnota (Min.), 1.kvantil, medián, průměr, 2.kvantil, maximální hodnota (Max.) a směrodatná odchylka (Sd.). Dále byly vytvořeny časové řady indikátorů pro každé povodí a histogramy indikátorů pro každé povodí.

4.2 Výběr modelu neuronové sítě

V této práci byl testován autoregresní model. Pro výpočet byla zvolena vrstevnatá síť s dvěma skrytými vrstvami s dopředným šířením signálu učená algoritmem zpětného šíření chyby. Bylo nastaveno deset opakování neuronové sítě. Pro výpočet byl použit R balík AMORE [Castejón-Limas et al., 2009].

Datový soubor byl rozdělen na validační a kalibrační soubor dat, soubory neobsahují stejné časové úseky dat. Nastavení modelu vrstevnaté neuronové sítě s dopředným šířením signálu:

- **počet neuronů v každé vrstvě:**

vstupní neurony: měnily se od 1 do 12

skryté vrstvy: 2 (každá 10 neuronů)

výstupní neuron: 1

- **objektivní funkce** "LMS"(last mean square)
- **aktivační funkce** skrytých vrstev: hyperbolický tangent "tansig"
- **aktivační funkce** výstupní vrstvy: lineární "purelin"
- **učící metoda** "ADAPTgdn"(Adaptive gradient descent with momentum").

4.3 Kritéria

K posouzení, zda-li nám model podává dobré výsledky, byla použita kritéria, která srovnávají výstupy z modelu s měřenými daty. Pro jejich výpočet byl použit R balík hydroGOF [Zambrano-Bigiarini, 2014]. K vyhodnocení vhodného modelu byla použita tato kritéria:

střední chyba (mean error- ME) odhad systematické chyby, nadhodnocení nebo podhodnocení modelu, dobrý model $\rightarrow 0$

$$ME = \frac{1}{N} \cdot \sum_{i=1}^N (D_{mer}(i) - D_{sim}(i)) \quad (4.1)$$

střední absolutní chyba (mean absolute error- MAE) odhad střední hodnoty absolutních velikostí reziduí, měří velikost reziduí, dobrý model $\rightarrow 0$

$$MAE = \frac{1}{N} \cdot \sum_{i=1}^N (|D_{mer}(i) - D_{sim}(i)|) \quad (4.2)$$

odmocnina střední kvadratické chyby (root mean square error RMSE),

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (Q_{mer}(i) - Q_{sim}(i))^2} \quad (4.3)$$

Tabulka 4.1: Seznam vodoměrných stanic [ČHMÚ, 2017]

DBC	TOK	NÁZEV STANICE	PLOCHA POVODÍ[km^2]
170	Metuje	Maršov nad Metují	94,68
180	Metuje	Hronov	248,59
250	Divoká Orlice	Nekoř	182,49
580	Novohradka	Úhřetice	458,91
660	Doubrava	Žleby	381,86
840	Jizera	Vilémov	146,17
850	Jizerka	Dolní Štěpanice	44,08
900	Kamenice	Bohuňovsko-Jesenný	179,10
910	Jizera	Železný Brod	791,27
1020	Jizera	Tuřice	2 157,41
1350	Vydra	Modrava	89,80
1430	Volyňka	Němětice	383,36
1510	Otava	Písek	2 913,70
1790	Radbuza	Staňkov	701,54

Tabulka 4.2: Kategorie SPI

extrémní sucho	$SPI \leq -2$
závažné sucho	$-2 < SPI \leq -1,5$
mírné sucho	$-1,5 < SPI \leq -1$
velmi mírné sucho	$-1 < SPI < 1$

koeficient determinace R^2 , lineární shoda měřených a simulovaných dat, lineární závislost dat

$$R^2 = 1 - \frac{\sum_{i=1}^N (D_{mer}(i) - D_{sim}(i))^2}{\sum_{i=1}^N (D_{mer}(i) - \bar{D})^2} \quad (4.4)$$

kde

$$\bar{D} = \frac{1}{N} \cdot \sum_{i=1}^N D_{mer}(i) \quad (4.5)$$

kde: D_{sim} jsou simulovaná data a D_{mer} jsou data měřená.

Tabulka 4.3: Kategorie SPEI

extrémní sucho	$\text{SPEI} \leq -2$
závažné sucho	-2 až -1,5
mírné sucho	-1,5 až -1

Tabulka 4.4: Kategorie SSI

mírné sucho	$\leq -0,8$
závažné sucho	$\leq -1,3$

Kapitola 5

VÝSLEDKY A DISKUSE

5.1 Výpočet indikátorů sucha

Předpověď byla prováděna na čtrnácti povodích v České republice. Statistické charakteristiky vyhodnocených dat jsou uvedeny v tabulce 5.2 a v tabulce 5.3. Dále jsou pro jednotlivá povodí uvedeny časové řady indikátorů SPI, SPEI a SSI, na obrázcích 5.2 až 5.8. V přílohách po této kapitole jsou uvedeny histogramy indikátorů.

5.1.1 Výpočet indikátoru SPI

Vstupními daty pro výpočet indikátoru SPI jsou srážky, nejvyšší průměrná měsíční suma srážek je pro DBC 840 (Vilémov- Jizera) a pro stanici DBC 1350 (Vydra- Modrava), naopak nejnižší hodnota je pro DBC 1020 (Jizera- Tuřice) a pro DBC 1790 (Radbuza- Staňkov), viz. tabulka 5.1.

Nejnižší hodnota SPI (-3,43), která indikuje extrémní sucho se vyskytuje u DBC 660 (Doubrava- Žleby), i zde velmi nízká hodnota průměrné měsíční sumy srážek (60,40 mm) a průměrná hodnota SPI je zde -0,002. Nejvyšší hodnoty SPI jsou u DBC 1430 (Volyňka- Němětice) a u DBC 1510 (Otava- Písek). V povodí Vydry, kde je vysoký úhrn srážek je průměrná hodnota SPI -0.004, tudíž velmi mírné sucho.

Z tabulky 5.4, kde je uvedena korelace SPI mezi jednotlivými povodími, je zřejmé, že stanice DBC, které jsou si geograficky nejbližší se navzájem ovlivňují a mají podobné charakteristiky, např. DBC 660 (Doubrava- Žleby) a DBC 580 (Novohradka- Úhřetice) dosahují korelačního koeficientu 0,94 jsou od sebe vzdáleny přibližně 42 km.

5.1.2 Výpočet indikátoru SPEI

Stejně jako pro výpočet SPI byla i zde použita pro výpočet data srážková. V tabulce 5.5 jsou uvedeny korelační koeficienty pro SPEI mezi všemi pozorovanými povodími, nejvíce korelována jsou povodí DBC 180 (Metuje- Hronov) a DBC 170, (Metuje- Maršov nad Metují) zde dosahuje korelační koeficient hodnoty 0,99. Naopak nejnižší koeficient 0,42 je mezi DBC 170 (Metuje- Hronov) a DBC 1430 (Volyňka- Nemětice).

Nejnižší hodnoty SPEI pro extrémní sucho se vyskytují v povodí Volyňky (DBC 130) a v povodí Vydry (DBC 1350), avšak průměrné SPEI u všech povodí jsou přibližně -0,001.

5.1.3 Výpočet indikátoru SSI

Pro výpočet SSI je nutno znát hodnoty o obsahu vody v půdě, zde bylo počítáno s vodou ve vrstvě 0-100 cm, nejvíce vody se tak vyskytovalo u DBC 1350 (Vydra- Modrava), kde jsou i velmi vysoké údaje o úhrnu srážek a DBC 910 (Jizera- Železný Brod). Nejméně vody se vyskytovalo u DBC 250 (Divoká Orlice- Nekoř) a u DBC 1790 (Radbuza- Staňkov), která má i nejnižší průměrnou měsíční sumu srážek, hodnoty o průměrném obsahu vody v půdě jsou uvedeny v tabulce 5.1.

Korelační koeficienty vypočtených indikátorů SSI mezi všemi povodími jsou nejnižší mezi DBC 1790 (Radbuza- Staňkov) a DBC 580 (Novohradka- Úhřetice), kde je hodnota koeficientu (0,10) a nejvyšší hodnota (0,97) je mezi DBC 580 (Novohradka- Úhřetice) a DBC 660 (Doubrava- Žleby). Ostatní hodnoty jsou uvedeny v tabulce 5.6.

Nejnižší hodnoty SSI jsou v DBC 840 (Jizera- Vilémov), DBC 900 (Kamenice- Bohuňovsko- Jesenný) a DBC 850 (Jizerka- Dolní Štěpanice), kde přesahují hodnotu -4,2. Průměrné hodnoty SSI jsou -0,002. Zbytek výsledků je uveden v tabulce 5.2.

V tabulce 5.1 je uvedeno, jak jsou mezi sebou vypočítané indikátory korelovány, grafické znázornění je na obrázku 5.1. Indikátory SPI a SPEI vykazují vysoký stupeň korelace, 0,961.

5.2 Neuronové sítě

Po spočítání všech indikátorů sucha, byla udělána jejich předpověď pomocí MLP modelu neuronové sítě. Předpověď byla provedena pro každé ze čtrnácti povodí. V této práci byl testován autoregresní model. Pro výpočet byla zvolena vrstevnatá síť s dvěma skrytými vrstvami s dopředným šířením signálu učená algoritmem zpětného šíření chyby. Bylo nastaveno deset opakování neuronové sítě. Vstupní neurony se měnily od 1 do 12, nejlepší modely pro každé povodí určitého indikátoru jsou uvedeny v tabulkách 5.8, 5.9 a 5.10. Posouzení bylo provedeno dle kritérií. Nejlépe vycházely modely pro indikátor SSI.

Při simulaci byla časová řada rozdělena na dvě části, první část byla použita na kalibraci a druhá na validaci. Grafické zobrazení pozorovaných dat s výsledky simulace pro indikátor SPI je zobrazeno pro každé povodí na obrázcích 5.9 až 5.22, pro indikátor SPEI jsou výsledky zobrazeny na obrázcích 5.23 až 5.36 pro indikátor SSI jsou výsledky na obrázcích 5.37 až 5.51.

Výsledky práce ukazují, že indikátory SPEI a SPI jsou si velmi podobné, jak nám ukazují korelace, takové malé změny mezi indikátory poukazují na fakt, že teplotní trendy jsou zde zanedbatelné. Simulace hodnot všech indikátorů využívající multivrstevnatou síť zde vycházejí celkem úspěšně, nejspíš díky výběru modelu s dvěma skrytými vrstvami s celkem vysokým počtem neuronů.

5.3 Diskuze

Z časových řad, uvedených na obrázcích 5.2 až 5.8 jsou zjevná 3 velmi suchá období pro všechna hodnocená povodí stejně, mezi tato období můžeme zařadit roky: 1983, 1992 a 2003, avšak nejvýraznější změnu je možno pozorovat na přelomu let 2002 a 2003, např. v grafu na obrázku ?? je vidět výrazný skok hodnot SPI, která přesahuje v roce 2002 hodnoty 3 a následně klesne až na hodnotu téměř -2, což už je považováno za závažné sucho na hranici s extrémním suchem. Dle výroční zprávy ČHMÚ můžeme toto sucho potvrdit [Tolasz et al., 2004].

Dlouhodobá předpověď indikátoru SPI pomocí neuronové sítě bylo provedeno i na řece Awaš v Etiopii. Práce porovnává předpověď pomocí

tradičního stochastického modelu (ARIMA), neuronových sítí a "support vector regression" (SVR). Výsledky zde byly porovnány pomocí kritérií RMSE, MAE a R^2 . Umělé neuronové sítě a SVR se zde prokázaly mnohem účinnější než model ARIMA, nejspíš protože jsou efektivnější v modelování non-lineárních složek časového souboru. Přesnější výsledky byly při předpovědi SPI pro předpověď 24 měsíců než u předpovědi na 12 měsíců [Bel, 2014].

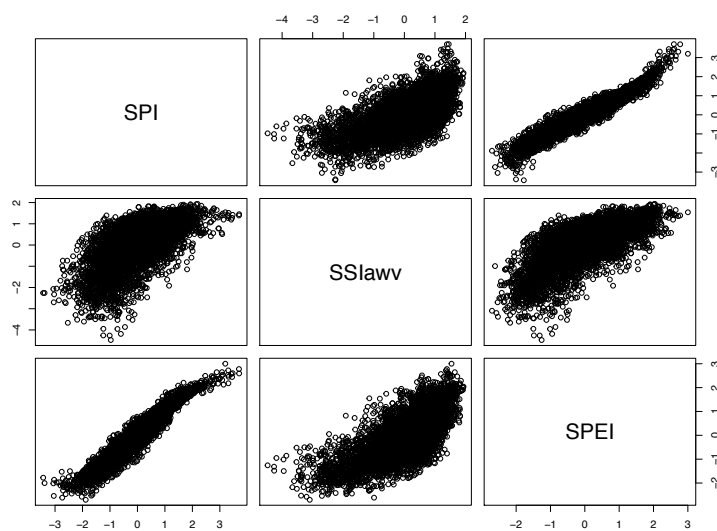
V další práci se autoři shodují, že indikátor SPI není vhodný pro krátkodobou predikci, konkrétně pro 1 měsíc, neboť může podávat zavádějící informace [Singleton, 2012].

Velmi podobné výsledky závislosti mezi indikátory SPI a SPEI jsou uváděny i v jiné práci, hodnota korelace mezi oběma indikátory dosahuje hodnoty 0,98, předpověď byla prováděna na řece Leaf (Mississippi, USA) a další na Santa Ysabel (Kalifornie, USA), kde je hodnota dokonce 0,99. Zde je i zmiňováno, že tato závislost mezi indikátory poukazuje na to, že teplota je zanedbatelná [Maca and Pech, 2016].

Indikátor SPI byl také srovnáván s indikátorem EDI, předpověď byla prováděna na iránském letišti Mehrabad v Teheránu. Výsledky byly lepší u indikátoru EDI. Předpověď zde byla prováděna pomocí neuronových sítí, nejlepší model ANN, pro oba indikátory, měl velmi jednoduchou architekturu: 3 vrstvy a maximálně 6 neuronů ve skryté vrstvě. Nejlepší modely dosáhly hodnot R^2 0,66 (SPI) a 0,79 (EDI) [Mishra and Singh, 2010].

Tabulka 5.1: Statistika vstupních dat pro výpočet indikátorů

DBC	Prům. měs. suma srážek [mm]	Obsah vody v půdě [mm]	Teplota[C°]
170	64,86	128,37	6,95
180	63,96	133,54	7,12
250	84,87	97,27	6,41
580	58,08	116,79	8,37
660	60,40	113,54	8,29
840	108,84	133,35	5,05
850	99,57	143,32	5,39
900	97,97	156,44	6,00
910	87,97	163,89	6,46
1020	57,88	133,63	8,56
1350	101,53	179,83	4,69
1430	63,30	127,53	7,12
1510	63,10	117,66	7,50
1790	57,69	99,59	8,30



Obrázek 5.1: Korelace mezi indikátory

Tabulka 5.2: Statistika indikátorů pro jednotlivá povodí

DBC	Indikátor	Min.	1. kvantil	Medián	Průměr	3.kvantil	Max.	Sd
170	SPI	-2,418	-0,671	-0,078	0,0002	0,627	2,725	0,968
	SPEI	2,273	-0,768	-0,058	0,004	0,791	2,128	0,982
	SSI	-2,775	-0,570	0,174	-0,001	0,770	1,631	0,992
180	SPI	-2,484	-0,699	-0,063	0,0002	0,671	2,774	0,969
	SPEI	-2,132	-0,806	-0,056	0,003	0,756	2,159	0,981
	SSI	-2,77200	-0,54900	0,13180	-0,00128	0,76410	1,69600	0,993
250	SPI	-2,534	-0,651	-0,066	-0,002	0,651	2,447	0,964
	SPEI	-2,268	-0,671	-0,011	0,0010	0,713	2,226	0,977
	SSI	-3,664	-0,464	0,230	-0,004	0,749	1,582	1,064
580	SPI	-3,060	-0,631	0,053	-0,001	0,673	2,201	0,986
	SPEI	-2,229	-0,630	0,009	-0,003	0,655	2,151	0,981
	SSI	-2,738	-0,534	0,032	-0,001	0,703	1,935	0,988
660	SPI	-3,430	-0,546	0,005	-0,002	0,709	2,327	0,999
	SPEI	-2,073	-0,637	0,023	-0,006	0,639	2,288	0,983
	SSI	-2,325	-0,542	0,207	-0,001	0,674	1,850	0,999
840	SPI	-2,486	-0,685	-0,074	-0,003	0,708	2,395	0,963
	SPEI	-2,375	-0,721	-0,0484	-0,002	0,731	2,110	0,975
	SSI	-4,4750	-0,457	0,282	-0,003	0,765	1,448	1,055
850	SPI	-2,545	-0,713	-0,113	-0,002	0,731	2,429	0,960
	SPEI	-2,411	-0,740	-0,031	-0,001	0,729	1,988	0,976
	SSI	-4,259	-0,472	0,255	-0,003	0,762	1,361	1,063
900	SPI	-2,945	-0,661	0,024	-0,00	0,699	2,503	0,980
	SPEI	-2,253	-0,738	0,001	-0,008	0,695	2,325	0,973
	SSI	-4,264	-0,399	0,272	-0,003	0,748	1,483	1,058
910	SPI	-2,683	-0,726	-0,011	-0,004	0,729	2,477	0,967
	SPEI	-2,261	-0,748	-0,001	-0,005	0,693	2,231	0,973
	SSI	-3,531	-0,451	0,207	-0,003	0,734	1,665	1,019
1020	SPI	-2,330	-0,604	-0,010	-0,004	0,548	2,626	0,971
	SPEI	-2,486	-0,669	0,013	-0,003	0,652	2,270	0,976
	SSI	-2,611	-0,723	0,125	-0,003	0,733	1,734	0,972

Tabulka 5.3: Statistika indikátorů pro jednotlivá povodí

DBC povodí	Indikátor	Min.	1. kvantil	Medián	Průměr	3.kvantil	Max.	Sd
1350	SPI	-3,045	-0,665	-0,079	-0,004	0,632	3,086	0,979
	SPEI	-2,613	-0,741	-0,029	-0,002	0,684	2,510	0,981
	SSI	-3,412	-0,437	0,327	-0,005	0,649	1,491	1,058
1430	SPI	-2,394	-0,650	-0,020	-0,001	0,548	3,702	0,995
	SPEI	-2,703	-0,658	0,037	0,002	0,696	2,604	0,983
	SSI	-3,096	-0,656	0,020	-0,001	0,786	1,822	0,999
1510	SPI	-2,707	-0,662	-0,031	-0,002	0,619	3,696	0,997
	SPEI	-2,574	-0,669	-0,013	-0,001	0,687	2,777	0,983
	SSI	-3,201	-0,629	0,080	-0,001	0,730	1,923	0,995
1790	SPI	-2,717	-0,576	0,038	-0,002	0,658	3,199	0,987
	SPEI	-2,194	-0,705	0,021	-0,007	0,637	3,002	0,981
	SSI	-2,853	-0,750	0,143	-0,001	0,710	1,772	0,984

Tabulka 5.4: Korelace SPI mezi povodími

	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14
P1	1,0	0,99	0,83	0,69	0,60	0,78	0,79	0,76	0,80	0,71	0,60	0,34	0,42	0,64
P2	0,99	1,0	0,87	0,73	0,64	0,81	0,80	0,78	0,82	0,73	0,64	0,37	0,46	0,67
P3	0,83	0,87	1,0	0,84	0,77	0,87	0,84	0,85	0,87	0,73	0,75	0,48	0,54	0,67
P4	0,69	0,73	0,84	1,0	0,94	0,70	0,70	0,69	0,70	0,70	0,67	0,60	0,64	0,63
P5	0,60	0,64	0,77	0,94	1,0	0,68	0,72	0,67	0,70	0,82	0,66	0,64	0,68	0,63
P6	0,79	0,81	0,87	0,70	0,68	1,0	0,96	0,97	0,98	0,83	0,68	0,40	0,49	0,64
P7	0,79	0,80	0,84	0,70	0,72	0,96	1,0	0,91	0,96	0,83	0,67	0,41	0,49	0,67
P8	0,75	0,78	0,85	0,69	0,67	0,97	0,91	1,0	0,98	0,86	0,65	0,41	0,50	0,63
P9	0,80	0,82	0,87	0,70	0,70	0,98	0,96	0,98	1,0	0,89	0,70	0,43	0,53	0,70
P10	0,71	0,73	0,73	0,69	0,73	0,83	0,83	0,86	0,89	1,0	0,64	0,49	0,60	0,74
P11	0,60	0,64	0,75	0,67	0,66	0,68	0,67	0,65	0,70	0,64	1,0	0,80	0,83	0,81
P12	0,34	0,37	0,48	0,59	0,64	0,40	0,41	0,41	0,43	0,49	0,80	1,0	0,98	0,71
P13	0,42	0,46	0,54	0,64	0,68	0,49	0,49	0,50	0,53	0,60	0,83	0,97	1,0	0,80
P14	0,64	0,67	0,67	0,63	0,63	0,64	0,67	0,63	0,69	0,74	0,81	0,71	0,80	1,0

Tabulka 5.5: Korelace SPEI mezi povodími

	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14
P1	1,00	0,99	0,83	0,71	0,64	0,78	0,81	0,75	0,81	0,74	0,59	0,42	0,50	0,65
P2	,99	1,00	0,87	0,75	0,67	0,81	0,82	0,78	0,83	0,76	0,62	0,45	0,52	0,67
P3	0,83	0,87	1,00	0,82	0,75	0,88	0,85	0,86	0,88	0,73	0,75	0,52	0,56	0,65
P4	0,71	0,75	0,82	1,00	0,95	0,69	0,70	0,70	0,72	0,76	0,68	0,65	0,70	0,68
P5	0,64	0,67	0,75	0,95	1,00	0,67	0,71	0,69	0,71	0,78	0,70	0,68	0,72	0,70
P6	0,78	0,81	0,88	0,69	0,67	1,00	0,96	0,98	0,98	0,80	0,69	0,43	0,50	0,64
P7	0,81	0,82	0,85	0,70	0,71	0,96	1,00	0,93	0,96	0,80	0,69	0,45	0,50	0,67
P8	0,76	0,78	0,86	0,70	0,69	0,98	0,93	1,00	0,98	0,85	0,67	0,45	0,52	0,64
P9	0,81	0,83	0,88	0,72	0,71	0,98	0,96	0,98	1,00	0,87	0,71	0,47	0,55	0,69
P10	0,74	0,76	0,73	0,76	0,78	0,80	0,80	0,85	0,87	1,00	0,65	0,55	0,65	0,78
P11	0,59	0,62	0,75	0,68	0,70	0,69	0,69	0,67	0,71	0,65	1,0	0,82	0,85	0,81
P12	0,42	0,45	0,52	0,65	0,68	0,43	0,45	0,45	0,47	0,55	0,82	1,0	0,98	0,74
P13	0,50	0,52	0,56	0,70	0,72	0,50	0,50	0,52	0,55	0,65	0,85	0,98	1,0	0,82
P14	0,65	0,67	0,65	0,68	0,70	0,64	0,67	0,64	0,69	0,78	0,81	0,74	0,82	1,0

Tabulka 5.6: Korelace SSI mezi povodími

	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14
P1	1,0	0,93	0,86	0,83	0,78	0,77	0,81	0,80	0,87	0,80	0,62	0,61	0,66	0,72
P2	0,93	1,0	0,88	0,85	0,81	0,76	0,82	0,80	0,88	0,80	0,62	0,61	0,66	0,72
P3	0,86	0,88	1,0	0,81	0,80	0,84	0,89	0,83	0,89	0,70	0,68	0,68	0,70	0,63
P4	0,83	0,85	0,81	1,0	0,97	0,70	0,73	0,72	0,79	0,82	0,69	0,70	0,74	0,71
P5	0,78	0,81	0,80	0,97	1,0	0,72	0,73	0,74	0,81	0,83	0,78	0,71	0,75	0,75
P6	0,77	0,76	0,84	0,69	0,72	1,0	0,97	0,97	0,94	0,66	0,71	0,59	0,68	0,66
P7	0,81	0,82	0,89	0,73	0,73	0,97	1,0	0,93	0,95	0,66	0,69	0,60	0,67	0,67
P8	0,80	0,80	0,83	0,72	0,74	0,97	0,93	1,0	0,97	0,75	0,72	0,62	0,71	0,69
P9	0,87	0,88	0,89	0,79	0,81	0,94	0,95	0,97	1,0	0,83	0,72	0,65	0,73	0,74
P10	0,80	0,80	0,70	0,82	0,83	0,66	0,66	0,75	0,83	1,0	0,62	0,61	0,70	0,76
P11	0,62	0,62	0,68	0,69	0,78	0,71	0,69	0,72	0,72	0,62	1,0	0,78	0,81	0,73
P12	0,61	0,61	0,68	0,70	0,71	0,59	0,60	0,62	0,65	0,61	0,78	1,0	0,96	0,64
P13	0,66	0,66	0,70	0,74	0,75	0,68	0,67	0,71	0,73	0,70	0,81	0,96	1,0	0,74
P14	0,72	0,72	0,63	0,10	0,75	0,66	0,67	0,69	0,74	0,76	0,73	0,64	0,74	1,0

Tabulka 5.7: Korelace


	SPI	SSI	SPEI
SPI	1,000	0,619	0,961
SSI	0,619	1,000	0,717
SPEI	0,961	0,717	1,000

Tabulka 5.8: Nejlepší modely SPI pro povodí a jejich kritéria


DBC	LAG	Kalibrace				Validace			
		ME	MAE	RMSE	R^2	ME	MAE	RMSE	R^2
170	11	0,00	0,29	0,37	0,85	0,09	0,38	0,50	0,60
180	10	0,00	0,29	0,37	0,85	0,09	0,38	0,49	0,65
250	10	0,00	0,30	0,38	0,85	0,08	0,37	0,46	0,59
580	9	0,00	0,32	0,43	0,89	0,03	0,34	0,45	0,79
660	8	0,00	0,32	0,43	0,83	0,03	0,29	0,40	0,77
840	12	0,00	0,30	0,40	0,81	0,06	0,42	0,53	0,74
850	10	0,00	0,29	0,39	0,83	0,00	0,43	0,54	0,68
900	11	0,00	0,29	0,37	0,82	0,06	0,29	0,37	0,78
910	9	0,00	0,31	0,40	0,80	0,03	0,43	0,54	0,75
1020	8	0,00	0,30	0,37	0,81	-0,05	0,39	0,53	0,82
1350	9	0,00	0,33	0,42	0,81	0,15	0,35	0,48	0,77
1430	10	0,00	0,29	0,38	0,86	0,06	0,36	0,49	0,72
1510	11	0,00	0,29	0,37	0,87	0,04	0,36	0,47	0,74
1790	9	0,00	0,30	0,38	0,86	0,06	0,34	0,45	0,75

Tabulka 5.9: Nejlepší modely SPEI pro povodí a jejich kritéria


DBC	LAG	Kalibrace				Validace			
		ME	MAE	RMSE	R^2	ME	MAE	RMSE	R^2
170	9	0,00	0,29	0,38	0,86	0,01	0,38	0,49	0,58
180	8	0,00	0,30	0,39	0,84	0,03	0,35	0,47	0,66
250	10	0,00	0,31	0,39	0,83	0,07	0,42	0,52	0,55
580	7	0,00	0,32	0,43	0,80	0,00	0,32	0,43	0,80
660	9	0,00	0,31	0,42	0,82	0,00	0,34	0,44	0,77
840	10	0,00	0,32	0,43	0,78	0,04	0,45	0,58	0,67
850	11	0,00	0,31	0,41	0,81	0,02	0,46	0,57	0,66
900	8	0,00	0,33	0,43	0,78	0,01	0,39	0,54	0,79
910	10	0,00	0,33	0,42	0,79	0,040	0,33	0,42	0,68
1020	9	0,00	0,31	0,40	0,80	-0,04	0,37	0,51	0,80
1350	8	0,00	0,35	0,44	0,80	0,09	0,35	0,44	0,78
1430	9	0,00	0,30	0,41	0,83	0,02	0,33	0,47	0,77
1510	8	0,00	0,30	0,40	0,84	0,02	0,32	0,45	0,78
1790	8	0,00	0,31	0,40	0,84	0,01	0,33	0,45	0,75




Obrázek 5.2: Časová řada pro DBC 170 a 180; modrá linie: SPI, zelená linie: SPEI, oranžová: SSI




Obrázek 5.3: Časová řada pro DBC 250 a 580; modrá linie: SPI, zelená linie: SPEI, oranžová: SSI




Obrázek 5.4: Časová řada pro DBC 660 a 840; modrá linie: SPI, zelená linie: SPEI, oranžová: SSI




Obrázek 5.5: Časová řada pro DBC 850 a 900; modrá linie: SPI, zelená linie: SPEI, oranžová: SSI



Obrázek 5.6: Časová řada pro DBC 910 a 1020; modrá linie: SPI, zelená linie: SPEI, oranžová: SSI




Obrázek 5.7: Časová řada pro DBC 1350 a 1430; modrá linie: SPI, zelená linie: SPEI, oranžová: SSI




Obrázek 5.8: Časová řada pro DBC 1510 a 1790; modrá linie: SPI, zelená linie: SPEI, oranžová linie: SSI

Tabulka 5.10: Nejlepší modely SSI pro povodí a jejich kritéria

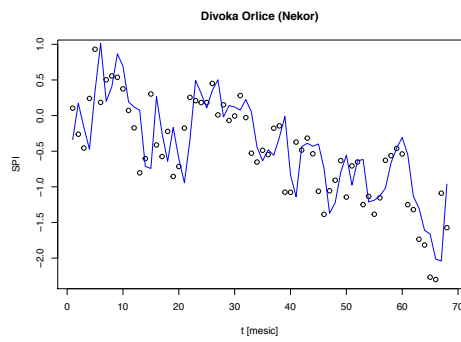
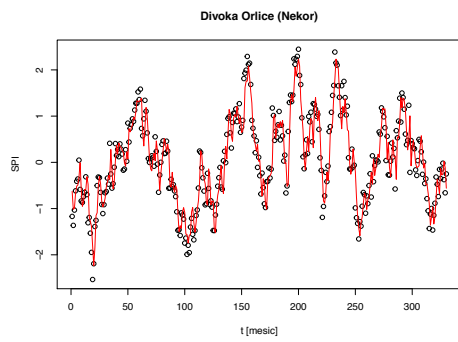
DBC	LAG	Kalibrace				Validace			
		ME	MAE	RMSE	R^2	ME	MAE	RMSE	R^2
170	8	0,00	0,11	0,15	0,98	-0,01	0,10	0,15	0,94
180	8	0,00	0,10	0,15	0,94	0,00	0,11	0,15	0,98
250	9	0,00	0,15	0,21	0,96	0,02	0,16	0,23	0,90
580	7	0,00	0,13	0,17	0,97	0,00	0,13	0,17	0,96
660	6	0,00	0,13	0,17	0,97	0,00	0,11	0,15	0,95
840	10	0,00	0,16	0,24	0,95	-0,01	0,14	0,21	0,80
850	9	0,00	0,15	0,23	0,96	0,00	0,14	0,21	0,88
900	8	0,00	0,14	0,21	0,96	-0,01	0,12	0,18	0,94
910	11	0,00	0,13	0,18	0,97	0,00	0,12	0,19	0,93
1020	9	0,00	0,11	0,14	0,98	-0,04	0,12	0,17	0,96
1350	8	0,00	0,15	0,21	0,96	0,01	0,16	0,24	0,94
1430	10	0,00	0,14	0,19	0,97	0,02	0,12	0,17	0,97
1510	8	0,00	0,14	0,18	0,97	-0,02	0,13	0,18	0,96
1790	7	0,00	0,13	0,17	0,97	-0,03	0,16	0,23	0,92



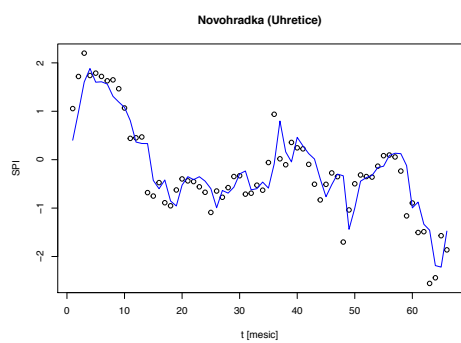
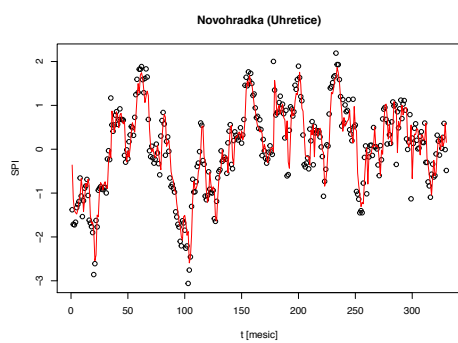
Obrázek 5.9: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



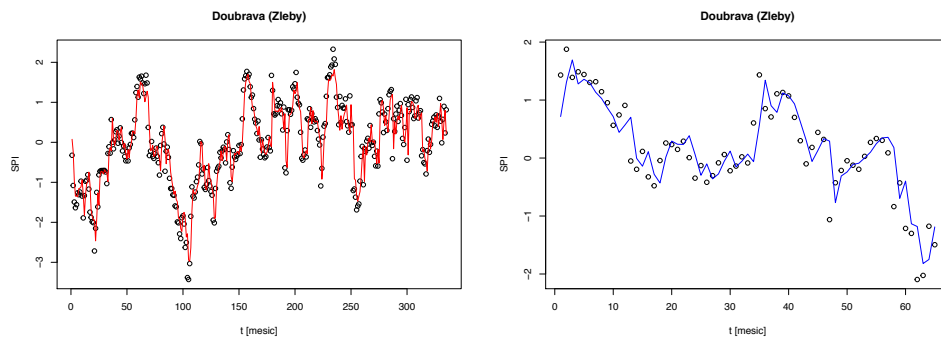
Obrázek 5.10: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



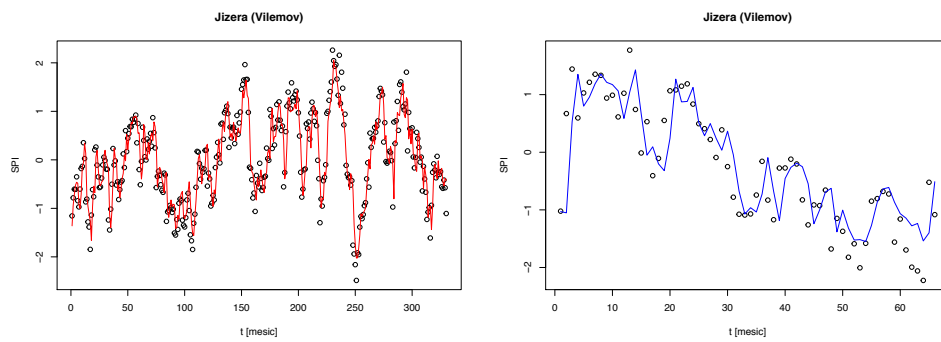
Obrázek 5.11: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



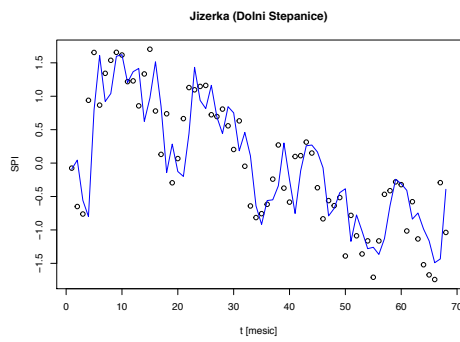
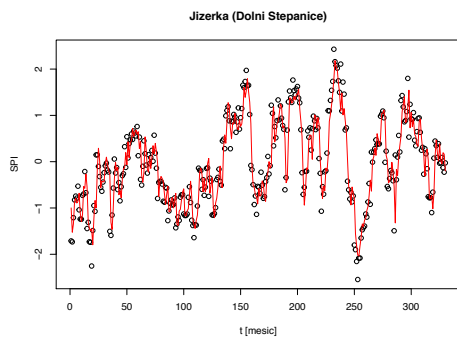
Obrázek 5.12: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



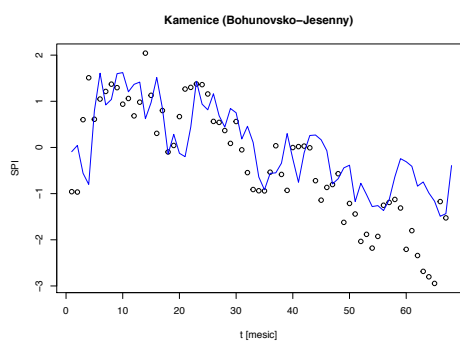
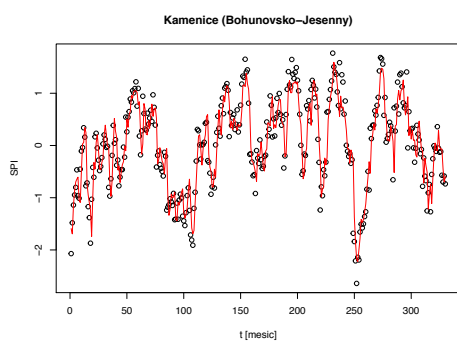
Obrázek 5.13: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



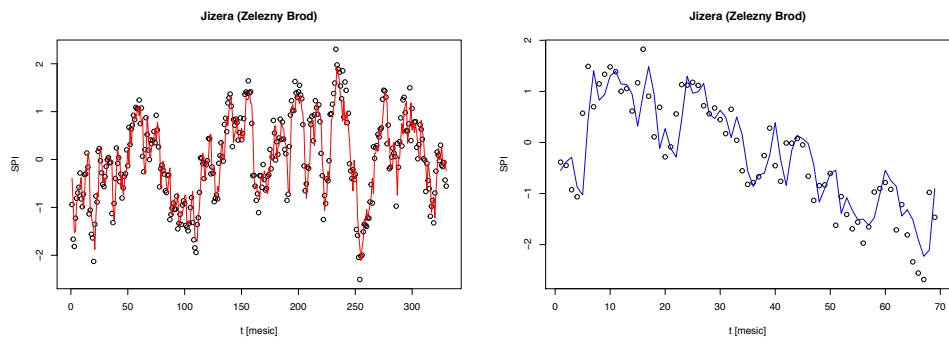
Obrázek 5.14: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




Obrázek 5.15: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



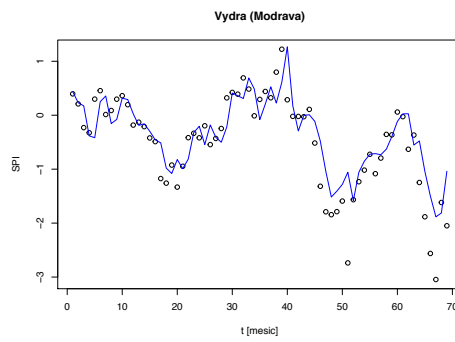
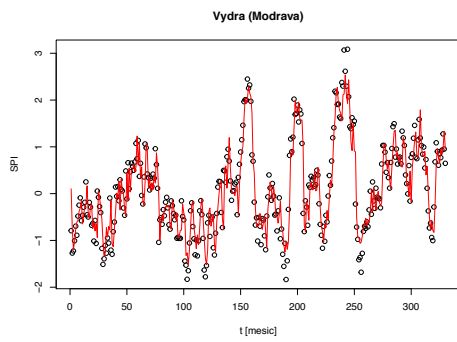
Obrázek 5.16: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



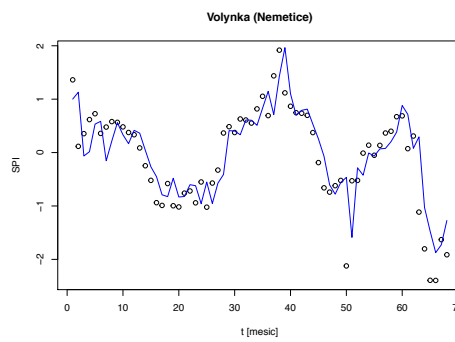
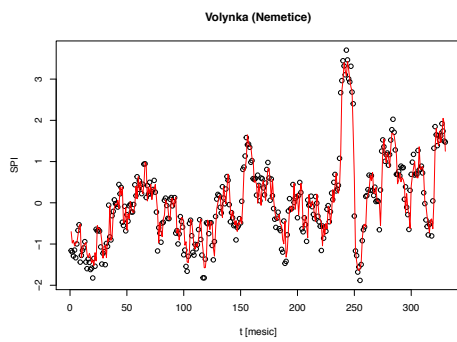
Obrázek 5.17: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




Obrázek 5.18: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



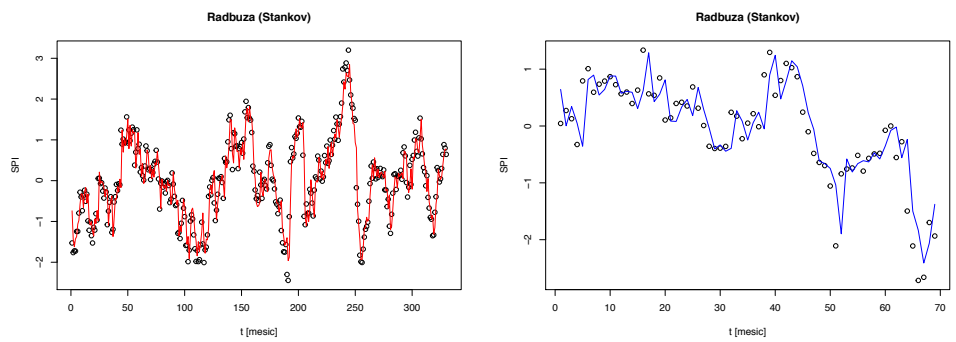
Obrázek 5.19: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



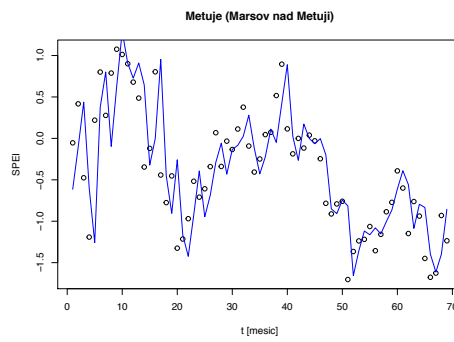
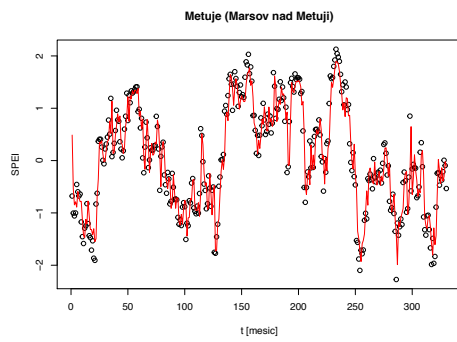
Obrázek 5.20: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



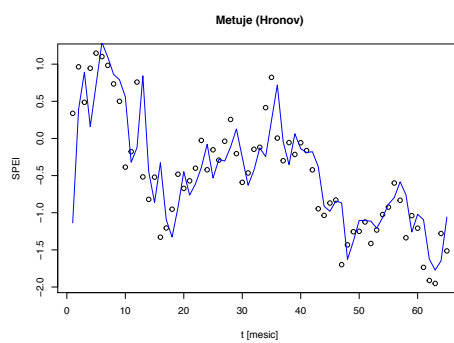

Obrázek 5.21: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




Obrázek 5.22: Simulace předpovědi indikátoru SPI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



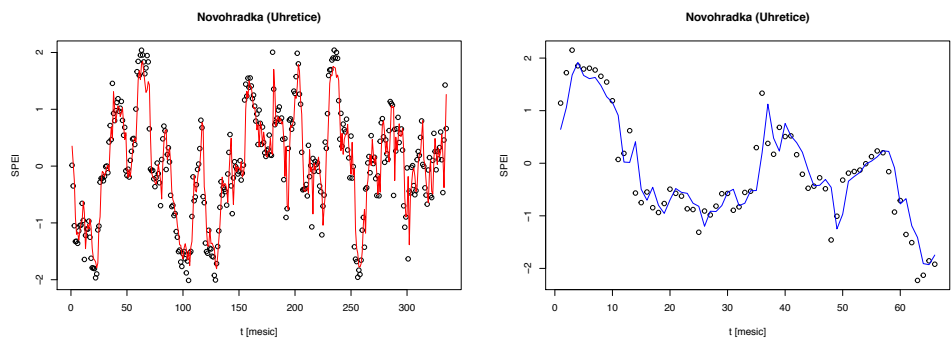
Obrázek 5.23: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



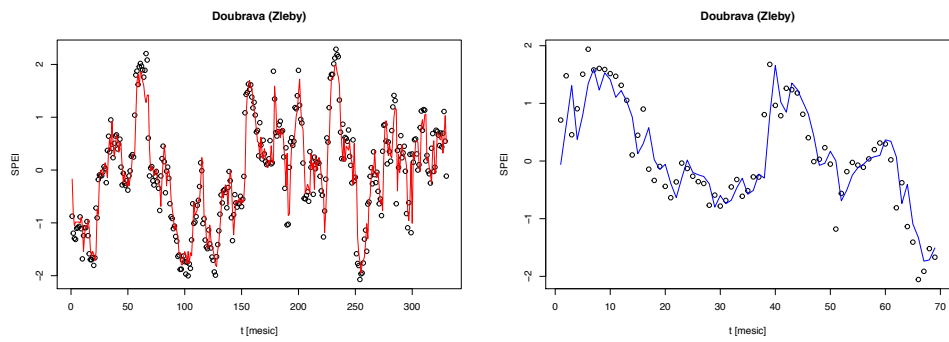
Obrázek 5.24: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




Obrázek 5.25: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




Obrázek 5.26: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



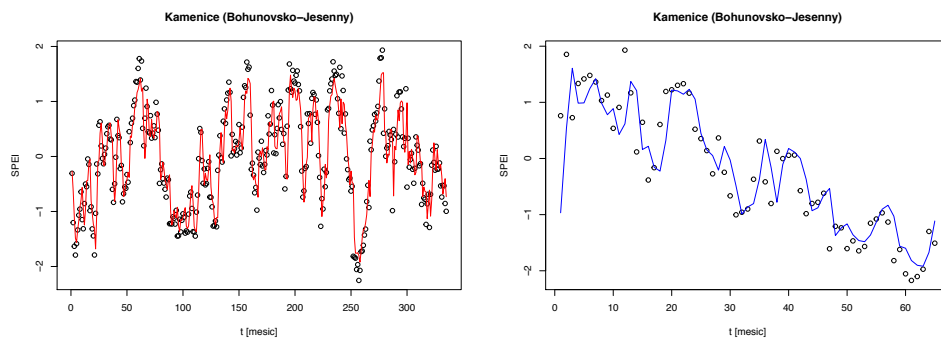
Obrázek 5.27: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




Obrázek 5.28: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




Obrázek 5.29: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



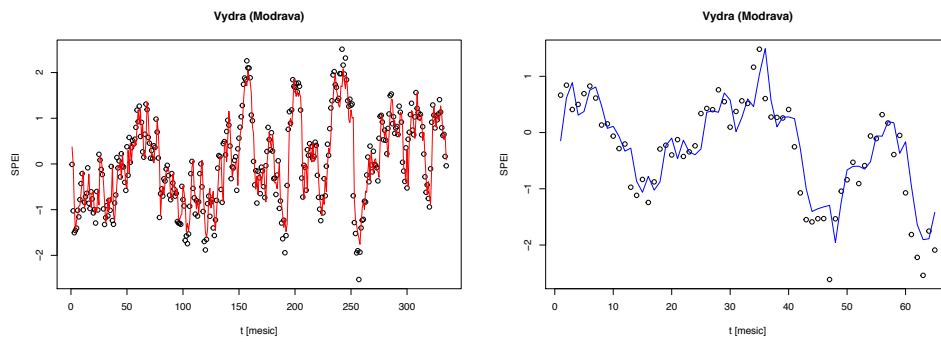
Obrázek 5.30: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



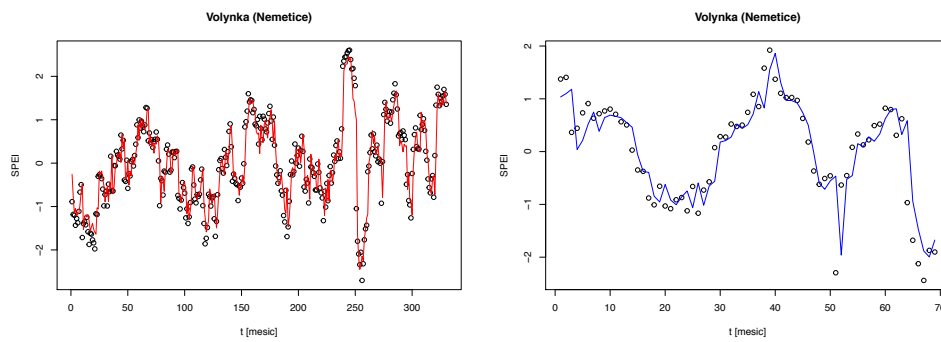
Obrázek 5.31: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.32: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.33: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




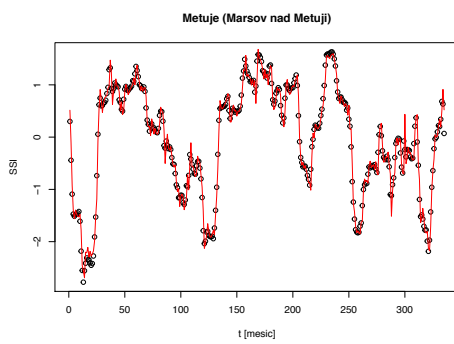
Obrázek 5.34: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.35: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.36: Simulace předpovědi indikátoru SPEI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.37: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.38: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.39: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



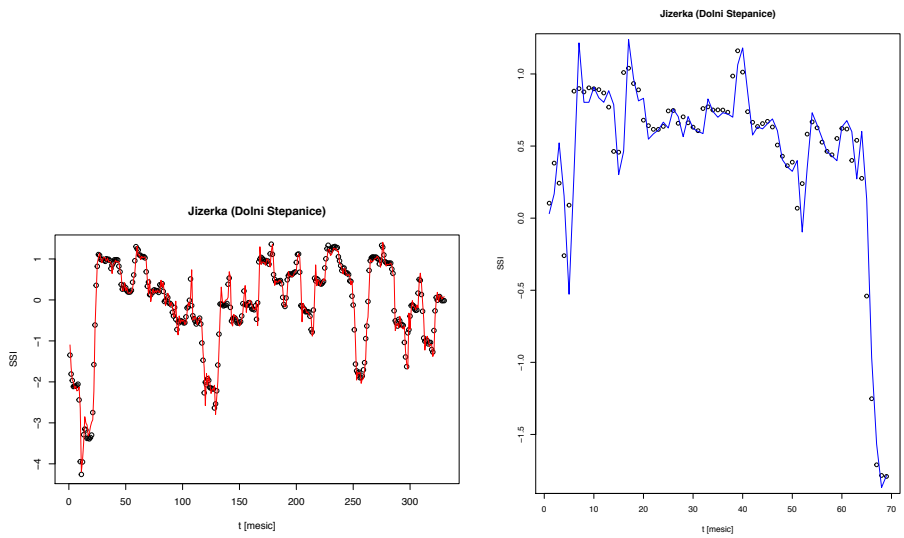
Obrázek 5.40: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




Obrázek 5.41: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




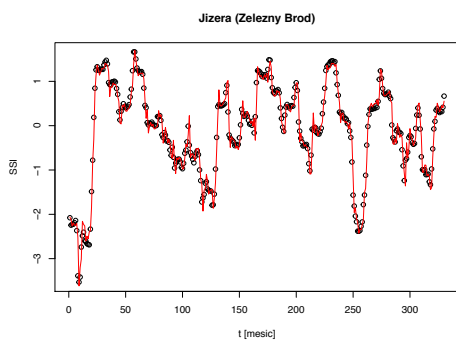
Obrázek 5.42: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.43: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.44: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.45: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.46: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data





Obrázek 5.47: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data




Obrázek 5.48: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



Obrázek 5.49: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



Obrázek 5.50: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data



Obrázek 5.51: Simulace předpovědi indikátoru SSI, červená linie: simulace, modrá linie: validace, tečky: pozorovaná kalibrační data

Kapitola 6

ZÁVĚR

Z definice sucha, která je uvedena na začátku práce vyplývá, že v každém regionu se musí k výběru správných indikátorů přistupovat obezřetně. Povodí, která jsou zde použita se nacházejí všechna v České republice, tudíž ve stejných klimatických podmínkách, závislost mezi povodími je tedy velmi úzká.


Výchozí datový soubor, který byl použit pro výpočet indikátorů, obsahoval data z období od 1.ledna 1981 do 1.prosince 2015, tedy dostatečně dlouhý. Vypočtené indikátory byly zobrazeny v časových řadách a popsány základní statistikou.

Pro předpověď byly vybrány indikátory SPI, SPEI a SSI. Výsledky práce ukazují, že indikátory SPEI a SPI jsou si velmi podobné, jak nám ukazují korelace, takové malé změny mezi indikátory poukazují na fakt, že teplotní trendy jsou zde zanedbatelné. Výsledky všech indikátorů dopadly velmi dobře na všech čtrnácti vybraných povodí.


V této práci byl testován autoregresní model, pro výpočet byla zvolena vrstevnatá síť (MLP) s dvěma skrytými vrstvami s dopředným šířením signálu učená algoritmem zpětného šíření chyby. Model použité neuronové sítě se prokázal jako velmi efektivní nástroj pro předpověď indikátorů sucha. Dle kritérií vyšly výsledky pro všechny indikátory velmi dobře, nejlépe pro indikátor SSI.

Kapitola 7


PŘÍLOHY




Obrázek 7.1: Histogramy indikátoru SPI pro DBC 170 a DBC 180




Obrázek 7.2: Histogramy indikátoru SPI pro DBC 250 a DBC 580




Obrázek 7.3: Histogramy indikátoru SPI pro DBC 660 a DBC 840




Obrázek 7.4: Histogramy indikátoru SPI pro DBC 850 a DBC 900



Obrázek 7.5: Histogramy indikátoru SPI pro DBC 910 a DBC 1020



Obrázek 7.6: Histogramy indikátoru SPI pro DBC 1350 a DBC 1430



Obrázek 7.7: Histogramy indikátoru SPI pro DBC 1510 a DBC 1790

LITERATURA

- Long-term {SPI} drought forecasting in the awash river basin in ethiopia using wavelet neural network and wavelet support vector regression models. *Journal of Hydrology*, 508:418 – 429, 2014. [5.3](#)
- A AghaKouchak. A baseline probabilistic drought forecasting framework using standardized soil moisture index: application to the 2012 united states drought. *Hydrology and Earth System Sciences*, 18(7): 2485–2492, 2014. [2.4.1](#)
- S Beguería and SM Vicente-Serrano. Spei: calculation of the standardised precipitation-evapotranspiration index. r package version 1.6, 2013. [4.1](#)
- Christopher M Bishop. *Neural networks for pattern recognition*. Oxford university press, 1995. [3](#)
- Petr Blinka. Klimatologické hodnocení sucha a suchých období na území ČR v letech 1876–2003. 2004. [1.1](#), [2.1](#)
- Gavin J Bowden, Graeme C Dandy, and Holger R Maier. Input determination for neural network models in water resources applications. part 1—background and methodology. *Journal of Hydrology*, 301(1): 75–92, 2005. [3.2.1](#)
- M Castejón-Limas, J ORDIERES MERÉ, FJ Martínez de Pisón Ascacibar, AV Pernía Espinoza, F Alba Elías, A González Marcos, et al. The amore package: A more flexible neural network package. *R package*, <http://cran.r-project.org>, 2009. [4.2](#)
- Václav David and Tereza Davidová. Assessment of summer drought in 2015 using different indices in the catchment of blanice river. *Procedia Engineering*, 162:45–55, 2016. [1.1](#)

- L Elleder. Hydrologické hodnocení a parametry sucha v roce 1904. *SUCHO A JAK MU ČELIT*, page 5, 2013. [1.1](#), [2.4.1](#)
- Milan Gocic and Slavisa Trajkovic. Spatiotemporal characteristics of drought in serbia. *Journal of Hydrology*, 510:110–123, 2014. [2.4.1](#)
- Richard R Heim Jr. A review of twentieth-century drought indices used in the united states. *Bulletin of the American Meteorological Society*, 83(8):1149–1165, 2002. [2.4.1](#)
- Michael J Janis, Michael B Johnson, and Gloria Forthun. Near-real time mapping of keetch-byram drought index in the south-eastern united states. *International Journal of Wildland Fire*, 11(4):281–289, 2002. [2.4.1](#)
- John Keyantash and John A Dracup. The quantification of drought: An evaluation of drought indices. *Bulletin of the American Meteorological Society*, 83(8):1167–1180, 2002. [2.4](#)
- Petr Maca and Pavel Pech. Forecasting spei and spi drought indices using the integrated artificial neural networks. *Computational intelligence and neuroscience*, 2016:14, 2016. [5.3](#)
- Holger R Maier and Graeme C Dandy. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental modelling & software*, 15(1):101–124, 2000. [3.2](#)
- Ashok K Mishra and Vijay P Singh. A review of drought concepts. *Journal of Hydrology*, 391:202–216, 2010. [5.3](#)
- Petr Máca. Hydrologické modely a automatická optimalizace parametrů. *ČZU*, 2015. [3.2.1](#)
- Stefan Niemeyer et al. New drought indices. *Options Méditerranéennes. Série A: Séminaires Méditerranéens*, 80:267–274, 2008. [2.4.1](#)
- Jooyoung Park and Irwin W Sandberg. Universal approximation using radial-basis-function networks. *Neural computation*, 3(2):246–257, 1991. [3.2.2](#)

- Shraddhanand Shukla and Andrew W Wood. Use of a standardized runoff index for characterizing hydrologic drought. *Geophysical Research Letters*, 35(2), 2008. [2.4.1](#)
- A Singleton. Forecasting drought in europe with the standardized precipitation index. an assessment of the performance of the european centre for medium range weather forecasts. variable resolution ensemble prediction system. *JRC Scientific and technical reports. EUR*, 25254, 2012. [5.3](#)
- Lena M Tallaksen and Henny AJ Van Lanen. Hydrological drought: processes and estimation methods for streamflow and groundwater, 2004. [2.2.3](#), [2.3](#)
- EL Tate and Alan Gustard. Drought definition: a hydrological perspective. In *Drought and drought mitigation in Europe*, pages 23–48. Springer, 2000. [2.2.2](#), [2.2.3](#), [2.2.4](#)
- Charles Warren Thornthwaite. An approach toward a rational classification of climate. *Geographical review*, 38(1):55–94, 1948. [2.1](#)
- Radim Tolasz, Jaroslav Rožnovský, Jaroslav Valter, Mojmír Kohut, and Ivan Kott. Hodnocení sucha roku 2003 na území ČR evaluation of drought in 2003 on the territory of the czech republic. In *Extrémny počasí a podnebí, Sborník z konference, Brno*, volume 11, 2004. [5.3](#)
- MP Van Rooy. A rainfall anomaly index independent of time and space. *Notos*, 14(43):6, 1965. [2.4.1](#)
- R. Vlnas, M Hanel, and A Vizina. Možnosti predikce sucha. *V.Ú.V. Tomáše G. Masaryka, v.v.i.*, 2014. [1.1](#)
- Ivo Vondrák. Umělá inteligence a neuronové sítě. *TU Ostrava*, 1995. [3.2.3](#)
- Donald A Wilhite. Drought as a natural hazard: concepts and definitions. 2000. [2.1](#), [2.2.1](#)
- Donald A Wilhite and Michael H Glantz. Understanding: the drought phenomenon: the role of definitions. *Water international*, 10(3): 111–120, 1985. [2.2](#)

Dorald A Wilhite. Drought planning: A process for state government. *JAWRA Journal of the American Water Resources Association*, 27(1): 29–38, 1991. [2.1](#)

Hong Wu, Michael J Hayes, Albert Weiss, and Qi Hu. An evaluation of the standardized precipitation index, the china-z index and the statistical z-score. *International journal of climatology*, 21(6):745–758, 2001. [2.4.1](#)

Mauricio Zambrano-Bigiarini. hydrogof: Goodness-of-fit functions for comparison of simulated and observed hydrological time series. *R package version 0.3-8*. Disponível em: Acesso em, 28, 2014. [4.3](#)

ČHMÚ. ČhmÚ, 2017. URL http://voda.chmi.cz/hr14/pdf/sez_p1_4_1.pdf. online. [4.1](#), [4.1](#)