

Univerzita Pardubice
Fakulta ekonomicko-správní

**Modelování predikce ozónu pomocí dopředných
neuronových sítí**

Bc. Jan Štětina

Diplomová práce

2011

Univerzita Pardubice
Fakulta ekonomicko-správní
Akademický rok: 2010/2011

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Jan ŠTĚTINA**
Osobní číslo: **E090494**
Studijní program: **N6209 Systémové inženýrství a informatika**
Studijní obor: **Informatika ve veřejné správě**
Název tématu: **Modelování predikce ozónu pomocí dopředných neuronových sítí**
Zadávací katedra: **Ústav systémového inženýrství a informatiky**

Z á s a d y p r o v y p r a c o v á n í :

Analýza vstupních dat (parametrů) pro následující predikci.
Charakteristika dopředné neuronové sítě z hlediska aproximace a predikce.
Návrh modelu na predikci ozónu.
Verifikace navrhnutého modelu.
Analýza výsledků.

Rozsah grafických prací:

Rozsah pracovní zprávy:

Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam odborné literatury:

HAYKIN, S. Neural Networks: A Comprehensive Foundation. 2nd edition, New Jersey : Prentice Hall, 1999.

KVASNIČKA, V. a kol. Úvod do teorie neuronových sítí. Bratislava : Iris, 2007.

MEADOWSOVÁ, D. a kol. Překročení mezí : konfrontace globálního kolapsu s představou trvale udržitelné budoucnosti = Beyond the limits. Praha : Argo, 1995.

OLEJ, V. Modelovanie ekonomických procesov na báze výpočtovej inteligencie. Hradec Králové : Miloš Vognar - M&V, 2003.



Vedoucí diplomové práce:

prof. Ing. Vladimír Olej, CSc.

Ústav systémového inženýrství a informatiky

Datum zadání diplomové práce: **5. října 2010**


Termín odevzdání diplomové práce: **6. května 2011**



doc. Ing. Renáta Myšková, Ph.D.

děkanka

L.S.



doc. Ing. Jiří Křupka, Ph.D.

vedoucí ústavu

V Pardubicích dne 5. října 2010

Prohlašuji:

Tuto práci jsem vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámen s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorský zákon, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Souhlasím s prezenčním zpřístupněním své práce v Univerzitní knihovně.

V Pardubicích dne 28. 4. 2011

Bc. Jan Štětina

PODĚKOVÁNÍ

Na tomto místě bych chtěl poděkovat vedoucímu diplomové práce, panu prof. Ing. Vladimíru Olejovi, CSc. za odbornou pomoc, připomínky k obsahové i formální stránce, vedení a podporu při vypracovávání mé diplomové práce.

Rád bych dále poděkoval rodičům za jejich celoživotní podporu, pochopení a trpělivost, ale také za to, že mi umožnili studovat.

V neposlední řadě bych chtěl poděkovat přítelkyni Adéle za její velkou podporu při mém studiu.

ANOTACE

Tato diplomová práce se zabývá modelováním predikce ozónu pomocí dopředných a frontálních neuronových sítí. Jako vstupní hodnoty jsou použity ukazatele, kterými se zjišťuje kvalita ovzduší, dále doplňující meteorologická měření a také údaje o tom, v který den byly tyto hodnoty naměřeny. Tato data byla naměřena na sídlišti Dukla v Pardubicích. Je zde popsána problematika ozónové vrstvy Země a také jsou zde charakterizovány dopředné neuronové sítě a frontální neuronové sítě. Dále jsou zde navrženy modely na predikci ozónu, které jsou verifikovány ve Stuttgartském simulátoru neuronových sítí a nakonec jsou analyzovány jejich výsledky.

KLÍČOVÁ SLOVA

Ozón, ozónová vrstva Země, predikce, dopředné neuronové sítě, frontální neuronové sítě, JavaNNS.

TITLE

Prediction of Ozone Modelling by Feed-forward Neural Networks

ANNOTATION

This thesis deals with prediction of ozone modelling by feed-forward and frontal neural networks. As the inputs data are used the indicators which take quality of environment, below supplementary meteorological measurement and also information which day these data were measured. These data were measured at housing estate in Dukla Pardubice. There is described problems of Earth's ozone layer and there is characterized feed-forward neural networks and frontal neural networks. Below there are suggested models of prediction ozone which are verified in Stuttgart Neural Network Simulator and finally there are analyzed their results.

KEYWORDS

Ozone, Earth's ozone layer, prediction, feed-forward neural networks, frontal neural networks, JavaNNS.

OBSAH

| | |
|---|-----------|
| ÚVOD..... | 9 |
| 1 OZÓNOVÁ VRSTVA ZEMĚ..... | 10 |
| 1.1 Ultrafialového záření | 10 |
| 1.2 Charakteristika a vlastnosti ozónu | 11 |
| 1.3 Monitorování ozónové vrstvy | 13 |
| 1.4 Chemické látky poškozujících ozónovou vrstvu | 13 |
| 1.5 Mezinárodní dohody | 17 |
| 1.6 Česká legislativa | 19 |
| 1.7 Shrnutí kapitoly..... | 21 |
| 2 NEURONOVÉ SÍTĚ | 22 |
| 2.1 Základní pojmy | 22 |
| 2.2 Perceptron | 28 |
| 2.3 Dopředné neuronové sítě | 29 |
| 2.4 Frontální neuronové sítě | 32 |
| 2.5 Shrnutí kapitoly..... | 35 |
| 3 NÁVRH MODELU NA PREDIKCI OZÓNU | 36 |
| 3.1 Získání dat..... | 36 |
| 3.2 Popis datové matice | 38 |
| 3.3 Předzpracování dat..... | 40 |
| 3.4 Rozdělení dat na trénovací a testovací množinu..... | 42 |
| 3.5 Ukazatele přesnosti predikce | 44 |
| 3.6 Dopředná neuronová síť vhodná k predikci ozónu | 44 |
| 3.6.1 Výsledky procesu učení..... | 46 |
| 3.6.2 Nastavení vah synapsí, aktivačních hodnot a prahů neuronů..... | 49 |
| 3.7 Shrnutí kapitoly..... | 50 |
| 4 ANALÝZA VÝSLEDKŮ NAVRŽENÝCH MODELŮ..... | 51 |
| 4.1 Dopředné neuronové sítě | 51 |
| 4.1.1 Rozdělení dat na trénovací a testovací množinu v poměru 50:50... .. | 52 |
| 4.1.2 Rozdělení dat na trénovací a testovací množinu v poměru 60:40... .. | 53 |
| 4.1.3 Rozdělení dat na trénovací a testovací množinu v poměru 70:30... .. | 55 |
| 4.1.4 Rozdělení dat na trénovací a testovací množinu v poměru 80:20... .. | 55 |
| 4.1.5 Rozdělení dat na trénovací a testovací množinu v poměru 90:10... .. | 56 |

| | | |
|---------------------------------------|-------------------------------|-----------|
| 4.2 | Frontální neuronové síť | 57 |
| 4.3 | Shrnutí kapitoly..... | 62 |
| ZÁVĚR | | 63 |
| SEZNAM POUŽITÉ LITERATURY..... | | 64 |
| SEZNAM OBRÁZKŮ | | 67 |
| SEZNAM TABULEK..... | | 68 |
| SEZNAM PŘÍLOH..... | | 68 |
| SEZNAM ZKRATEK | | 69 |

ÚVOD

Je zřejmé, že dnešní celoplanetární ekologické problémy jsou způsobeny nejrůznějšími nevhodnými lidskými činnostmi. Patří k nim například odstraňování vegetace ze zemského povrchu, drastické snížení rozmanitosti živých organismů, znečišťování ovzduší emisemi plyných sloučenin způsobující kyselá deště, postupující eroze půdního pokryvu Země přecházející až v přeměnu v poušť, nadměrné emise skleníkových plynů, které mohou vést ke změně celkového klimatu, produkce nebezpečných látek a jejich ukládání do prostředí a v neposlední řadě také narušování ozónové vrstvy Země v důsledku nadměrné emise nízkomolekulárních organických látek obsahujících chlor a brom.

Ohrožení ozónové vrstvy Země patří k těm nejzávažnějším problémům. Bezprostřední velkoplošné ohrožení během několika příštích desetiletí by mohlo nastat nejen v polárních oblastech, ale i ve středních zeměpisných oblastech. O vážnosti tohoto problému není pochyb, neboť ozónová vrstva chrání povrch Země před průnikem krátkovlnného slunečního ultrafialového záření [8].

Cílem této diplomové práce je návrh modelu pro predikci ozónu pomocí dopředných a frontálních neuronových sítí. Dále je cílem práce verifikace navržených modelů v prostředí Stuttgartského simulátoru neuronových sítí a analýza dosažených výsledků. Jako vstupní data jsou použity ukazatele, kterými se zjišťuje kvalita ovzduší, dále doplňující meteorologická měření a také údaje o tom, v který den byly tyto hodnoty naměřeny. Tato data byla naměřena na sídlišti Dukla v Pardubicích.

Diplomová práce je rozdělena do čtyř hlavních kapitol. V první kapitole je popsána problematika ozónové vrstvy Země. Je zde vysvětlen dopad ultrafialové záření na Zemi, charakteristika a vlastnosti ozónu a způsoby monitorování ozónové vrstvy Země. Následuje popis chemických látek poškozujících ozónovou vrstvu Země a popis mezinárodních dohod ovlivňující výrobu těchto látek. Druhá kapitola se zabývá neuronovými sítěmi. Jsou zde vysvětleny základní pojmy z této oblasti a dále popsán perceptron, dopředné a frontální neuronové sítě. Ve třetí kapitole je proveden návrh modelu na predikci ozónu. Je zde také popsáno získání dat a popsána celá datová matice. V závěru kapitoly jsou uvedeny výsledky procesu učení neuronové sítě vhodné k predikci ozónu. Poslední čtvrtá kapitola se zabývá analýzou výsledků navržených modelů. Ve dvou podkapitolách jsou analyzovány zvláště výsledky dopředných a frontálních neuronových sítí a poté jejich porovnání.

1 OZÓNOVÁ VRSTVA ZEMĚ

Ozónová vrstva Země se vytvořila již v době, kdy se atmosféra Země začala obohacovat dvouatomovým kyslíkem v důsledku metabolismu živých organismů (řas a později zelených rostlin). Pro existenci současných forem suchozemského života je považována existence této vrstvy za základní podmínku. Ve stratosféře je vytvořen jakýsi přirozený štít z ozónové vrstvy chránící veškerý pozemský život před škodlivými účinky ultrafialového záření.

V této první kapitole diplomové práce je popsána problematika ozónové vrstvy Země. Postupně je vysvětlen dopad ultrafialové záření na Zemi, charakteristika a vlastnosti ozónu, dále způsoby monitorování ozónové vrstvy Země a to jak v minulosti, tak i v současnosti. Následuje popis chemických látek poškozujících ozónovou vrstvu Země a také popis mezinárodních dohod ovlivňující výrobu těchto látek. Na závěr je popsána legislativa České republiky týkající se ochrany ovzduší.

1.1 Ultrafialového záření

Ultrafialové záření (UV záření) je ta část elektromagnetického vlnění, která se nachází mezi viditelným světlem a rentgenovým zářením, s vlnovou délkou od 10 – 400 nm. S ohledem na biologický účinek UV záření se rozlišují ještě další menší rozsahy [8]:

- UV-A: 320 – 400 nm,
- UV-B: 280 – 320 nm,
- UV-C: 100 – 280 nm.

UV záření je rovněž obsaženo ve sluneční radiaci, ale jen malá část proniká až na povrch Země, neboť je ve výškách 20 – 30 km v délkách menších než 290 nm absorbováno silně ozónem a v délkách menších než 180 nm dvouatomovým kyslíkem obsaženým ve vzdušném obalu Země. Zrakové orgány mnoho zvířat, např. ptáků, včel, much, jsou schopny UV záření vnímat, zatímco lidské oko tuto schopnost nemá a je jím naopak poškozováno.

Vlivem intenzivního krátkovlnného UV-B záření mohou vznikat popáleniny, kožní nekrózy, ale také může dojít ke vzniku zhoubných onemocnění – melanomů (rakoviny), pokud je vliv záření dostatečně dlouhý. Zejména se pak objevuje u lidí se světlou pokožkou, kteří jsou značnou dobu vystaveni slunci. Nejvíce jsou postiženi

obyvatelé Austrálie, kde se určitá forma rakoviny kůže vyvine během života u dvou ze tří Australanů a u každého šedesátého člověka se vyvine nejzhoubnější typ – maligní melanom. Vedle kůže jsou působení UV-B záření nejvíce vystaveny oči. Může být popálena rohovka vlivem působení UV záření. Nejvíce jsou postiženi lyžaři a horolezci ve velkých nadmořských výškách.

UV-C záření se využívá k dezinfekci a ke sterilizaci nástrojů, prostoru atp., protože působí silně toxicky na nižší organizmy. Hloubka průniku do tekutin je malá.

Intenzita UV záření na povrchu Země je samozřejmě ovlivňována i dalšími faktory, než jen základní stavbou ovzduší. Jsou jimi roční doba, meteorologické faktory (oblačnost), stav znečištění ovzduší (vlivem přirozených nebo antropogenních zdrojů), vulkanismus, kouř, exhalace a aerosoly z průmyslu či dopravy, tvorba troposférického ozónu [8], [11].

1.2 Charakteristika a vlastnosti ozónu

Ozón, jehož chemická zkratka je O_3 , je modifikací kyslíku. Ozón neboli trikyslík je tvořen třemi atomy na rozdíl od běžného atmosférického kyslíku se dvěma atomy (označován O_2). Ozón se v plynném stavu spontánně rozkládá na molekulu dvouatomového kyslíku a jeden kyslíkový atom ($O_3 \rightarrow O_2 + O$), přičemž střední doba života ozónu při teplotě 20 °C je 3 dny, při -15 °C 8 dní, při -25 °C 18 dní a při -50 °C 3 měsíce.

V přírodě vzniká ozón v ovzduší z dvouatomového kyslíku různými fotochemickými procesy vlivem slunečního záření nebo také při přirozených elektrických výbojích. Pouze tři z deseti miliónů molekul ve vzduchu tvoří ozón. Z toho se asi 90 % nachází ve stratosféře s maximem výskytu ve výškách kolem 25 km, kde vzniká působením UV záření na dvouatomové molekuly kyslíku. Zbývajících zhruba 10 % ozónu se nachází ve výškách asi do 10 km v atmosférické vrstvě zvané troposféra, kde vzniká především společným působením oxidů dusíku (NO_x), těkavých organických látek a slunečního záření. V přízemních vrstvách je koncentrace ozónu mnohem menší než ve stratosféře. Ozón je tedy dělen na [3]:

- **stratosférický ozón** – plní funkci UV filtru, který zabraňuje pronikání škodlivého UV záření k zemskému povrchu, je tedy pozitivní pro život na Zemi,

- **troposférický ozón** (tzv. přízemní ozón) - produkt spalování fosilních paliv, působí škodlivě na živé organismy, poškozují dýchací orgány živočichů i rostlin.

Množství ozónu v jednotlivých vrstvách atmosféry je závislé na rovnováze procesů, které ozón produkují s procesy, které ho ničí. V poslední čtvrtině 20. století, bylo zjištěno, že stratosférického ozónu ubývá a naopak ozónu v troposféře přibývá. Od roku 1970 roste koncentrace přízemního ozónu v průměru o 1.2 % za rok, kdežto stratosférického ozónu naopak ve stejném období ubývá o 0.6 %. Nerovnováha těchto procesů způsobuje ztenčování ozónové vrstvy a vede ke vzniku ozónové díry [3].

Ozón se vyznačuje extrémně vysokou absorpcí slunečního záření v oblasti UV spektra elektromagnetického záření, silnější absorpcí než kterýkoliv kov ve viditelném světle. Proto stačí atmosférická vrstva ozónu ve stratosféře i přes jeho nepatrnou koncentraci dokonale chránit živou přírodu před UV zářením Slunce, zejména o vlnových délkách mezi 320 a 240 nm, jež je stejně jako záření o nižších vlnových délkách životu nebezpečné.

Množství naměřeného ozónu se udává v tzv. Dobsonových jednotkách (D.U.), které udávají množství ozónu ve vertikálním sloupci vzduchu nad povrchem Země. Jednotky byly pojmenovány po oxfordském profesorovi G. Dobsonovi. 1 Dobsonova jednotka představuje celkové množství ozónu ve vertikálním sloupci atmosféry, které by při tlaku 1013 hektopascalů a teplotě 15 °C vytvořilo vrstvu silnou 10^{-3} cm. Například při celkovém množství ozónu 300 D.U. by tato ozónová vrstva byla silná 3 mm. Celkové množství ozónu v sloupci atmosféry se pohybuje v rozmezí 250 až 380 D.U. Pokud v určitých oblastech je naměřeno celkové množství ozónu pod 220 D.U., pak se jedná o tzv. ozónovou díru. Ve sdělovacích prostředcích se pro jednoduchost množství ozónu v atmosféře často udává jako procentuální změna vzhledem k dlouhodobému průměrnému množství.

Z fyziologického hlediska je ozón vysoce jedovatým plynem, který působí nejprve dráždivě na oči a sliznice. K hlavnímu poškození však dojde při vdechování, kdy dochází k poruchám respirace, klesá vdechovaný objem vzduchu, později nastává krvácení z nosu, bronchitida, plicní edém. Při nižších koncentracích se objevuje bolest hlavy a na prsou [8].

1.3 Monitorování ozónové vrstvy

Nepřímá a bodová měření stratosférického ozónu byla prováděna již od dvacátých let minulého století na pozemních stanicích, kde byla měřena intenzita pronikajícího UV záření.

Měření ozónu v globálním měřítku za pomoci družic bylo zahájeno v říjnu 1978, kdy na palubě družice NIMBUS 7 byl přístroj, určený k měření celkového množství ozónu v atmosféře. Přístroj byl pojmenován jako TOMS (Total Ozone Mapping Spectrometer). Jednalo se o tzv. rozptyloměr, pomocí něhož byl měřen rozptyl slunečního záření v atmosféře v několika intervalech spektra. Protože UV záření je absorbováno ozónem, pak menší odraz UV záření na čidla detektorů je způsoben vyšším obsahem O₃ v atmosféře.

Přístroj TOMS byl od roku 1991 umístěn na družici Meteor-3 a od roku 1996 byl na družici Terra, která byla první ze série družic programu sledování povrchu Země a její atmosféry EOS (Earth Observing System). Od roku 2005 je ozón měřen pomocí přístroje OMI (Ozone Monitoring Instrument) na družici AURA, která byla další družicí projektu EOS.

Družicové sledování ozónové vrstvy a udržování databáze satelitních dat je zajišťováno Goddardovým střediskem vesmírných letů NASA v Greenbeltu v USA.

V České republice je měření ozónu prováděno Solárním a ozónovým oddělením v Hradci Králové, kde se již od roku 1962 provádí měření celkového ozónu pomocí Dobsonova spektrometru. Zdejší datová sada je považována za jednu z nejdelších v Evropě a celosvětově má z hlediska kvality referenční charakter [3], [8], [9].

1.4 Chemické látky poškozující ozónovou vrstvu

Chemické látky poškozující ozónovou vrstvu jsou nejčastěji freony a halony. Souhrnným pojmem freony se označují nízkomolekulární alifatické a cykloalifatické uhlovodíky, jejichž atomy vodíku jsou většinou úplně substituovány chlórem a fluorem (CFC). V některých freonech je obsažen nesubstituovaný vodík. Pokud je v těchto látkách obsažen brom, jedná se o halony.


Freony byly široce používány jako náplně do aerosolových rozprašovačů, hasicí prostředky a jako pracovní látky v chladírenské technice. Halony byly používány především v oblasti výroby a použití hasebních prostředků.

Chlorofluorouhlovodíky jsou netoxické a stabilní. Nehoří ani nereagují s jinými látkami, nezpůsobují korozi. Jsou vynikající jako izolanty, protože mají malou tepelnou vodivost. Chlorofluorouhlovodíky tvoří dobrá rozpouštědla pro čištění kovů, od složitých dutin o mikroskopických rozměrech v elektronických obvodech až k nýtům, které drží pohromadě letadla. Výroba CFC byla levná a všeobecně bylo myšleno, že mohou být bezpečně likvidovány pouhým vypouštěním plynů do atmosféry. Mezi nejrozšířenější CFC se řadily CFC-011 (monofluortrichlormetan) a CFC-012 (difluordichlormetan), jejichž výroba rychle rostla až do roku 1974, kdy se objevily první články předpokládající jejich negativní účinky na ozónovou vrstvu.

Chlorofluorouhlovodíky ničí stratosférický ozón. *„Molekuly CFC jsou vysoko ve stratosféře rozkládány UV zářením, přičemž se uvolňují volné atomy chlóru (Cl). Tyto atomy reagují s ozónem a vzniká oxid chlornatý (ClO). ClO může reagovat s atomem kyslíku a vzniká opět volný Cl, který může napadnout další molekulu ozónu. A tak dál [11].“*

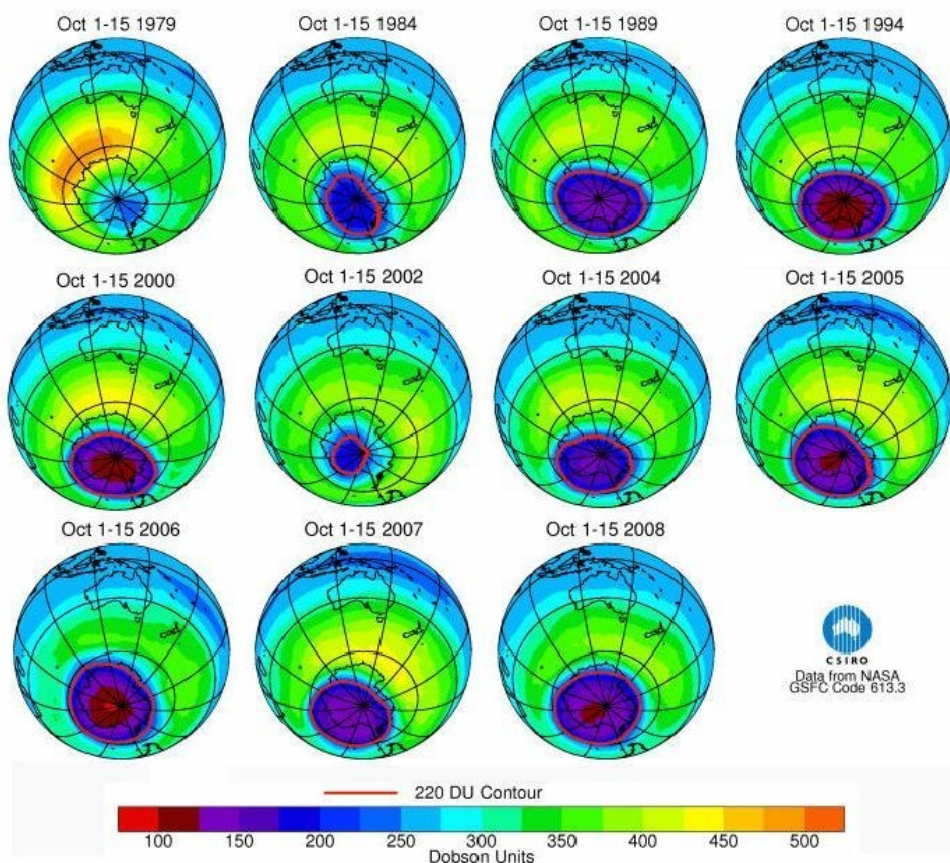
V říjnu 1984 byl naměřen nad pozorovacím stanovištěm Halley Bay v Antarktidě čtyřicetiprocentní pokles ozónu ve stratosféře. V květnu 1985 byl otištěn historický článek, oznamující existenci ozónové díry na jižní polokouli. Ihned zde byla kladena otázka, proč nebyl nikdy výrazný pokles ozónu oznámen satelitem Nimbus 7. Při zpětné kontrole bylo zjištěno, že počítače NASA byly naprogramovány tak, aby příliš nízké hodnoty ozónu vyřazovaly. Takové případy byly programem považovány za chybu přístroje. Naštěstí bylo možné všechny programem vyřazené měření obnovit. Těmito měřeními byla potvrzena pozorování z Halley Bay – také byl vykazován deset let trvající prudký pokles koncentrace ozónu nad jižním pólem [11].

Na obr. 1 je zachyceno průměrné množství ozónu nad stanicí Halley Bay v říjnu v letech 1955 až 2006 (zobrazeno tlustou čarou). Pomocí teček jsou zachyceny hodnoty koncentrace ozónu v měsících srpen až duben v jednotlivých letech [21].



Obr. 1: Průměrné množství ozónu nad stanicí Halley Bay v letech 1955 až 2006. Upraveno na základě [21]

Na obr. 2 je zobrazen vývoj ozónové díry nad Antarktidou v letech 1979 až 2008. Červenou čarou je znázorněna oblast ozónové díry.



Obr. 2: Ozónová díra nad Antarktidou v letech 1979 až 2008. Zdroj [20]

Na obr. 2 je tedy vidět rychlý vznik ozónové díry a její další zvětšování. V roce 1979 bylo ještě vše v pořádku, ale už za pět let v roce 1984 byla nad Antarktidou ozónová díra o velikosti kontinentální části USA, která se neustále zvětšovala. V roce

2002 byla naměřena o dost menší ozónová díra oproti roku 2000. Nejednalo se ale o to, že by se snížil během 2 let tak výrazně počet látek poškozujících ozón. Problém byl v tom, že je velké zpoždění mezi syntézou CFC lidmi a jeho příchodem do stratosféry. Při některých použitích (jakým je např. hnací plyn ve spreji) je CFC rychle uvolněn do ovzduší. V jiných případech (jako jsou chladničky a izolační pěny) dojde k uvolnění CFC do atmosféry až po několika letech nebo dokonce desetiletích. Přibližně po patnácti letech od uvolnění se molekuly CFC dostanou ze zemského povrchu do vrstev stratosféry, kde se rozpadnou a reagují s ozónem. Z toho tedy vyplývá, že kdykoli se naměří ztenčení ozónové vrstvy, jedná se o výsledky výroby a uvolnění CFC před patnácti nebo víc lety.

Otázkou proč se nachází ozónová díra zrovna nad Antarktidou, se zabývali vědci několik let, než se jim podařilo najít pro ozónovou díru vysvětlení. Antarktida je obklopena oceánem, a tak větry mohou kroužit okolo kontinentu nerušený vlivem pevniny. Během jižní zimy se vytváří cirkumpolární vír, který udržuje vzdušnou hmotu nad Antarktidou na místě, a tím je zabráněno míšení s ostatním vzduchem. Je tak vírem vytvořena izolovaná „reakční nádoba“ pro chemické látky přítomné nad pólem. Nad severním pólem se nevytváří tak silný vír, proto je severní ozónová díra mnohem menší. Největší ozónová díra do této doby byla naměřena v září 2006, kdy její velikost dosáhla velikosti kontinentu Afrika.

Použití, rozsahy výroby a doby prodlení v atmosféře důležitých chemických látek ničících ozón jsou uvedeny v tab. 1. Především dlouhá doba prodlení látek v atmosféře je alarmující. Dvě nejpoužívanější látky se i po 65 letech od vypuštění stále nachází v atmosféře. Je tedy jisté, že v celém 21. století se bude ochuzovat ozónová vrstva v důsledku vypouštění CFC v minulém století.

Od roku 1950 do roku 1975 se zvyšovala světová výroba CFC o 7 až 10 % za rok, tedy jednou za méně než 10 let se tato produkce zdvojnásobila. Do roku 1980 bylo na světě vyráběno milion tun CFC ročně. Spotřeba CFC se pohybovala kolem 0.85 kg na průměrného Američana či Evropana. Pro čím více společností v Severní Americe, Evropě, Sovětském svazu i Asii se CFC staly hlavním zdrojem příjmů. Pro mnoho dalších společností se CFC staly nezbytnou součástí jejich výrobního procesu [8], [11].

Tab. 1: Použití, rozsahy výroby a doby prodlení látek ničících ozón. Zdroj [11]

| Jméno sloučeniny | Chemické složení | Potenciál ničení ozónu | Použití | Světová produkce v roce 1985 (tuny) | Doba prodlení v atmosféře (roky) |
|------------------|-------------------------------------|------------------------|--|-------------------------------------|----------------------------------|
| CFC-011 | CFCl ₃ | 1.0 | chlazení, aerosoly, pěny | 298 000 | 65 – 75 |
| CFC-012 | CF ₂ Cl ₂ | 0.9 – 1.0 | chlazení, aerosoly, pěny, sterilizace, mražení potravin, detektory tepla, poplašná zařízení, kosmetika, kompresory | 438 000 | 100 – 140 |
| CFC-013 | CCl ₃ CF ₃ | 0.8 – 0.9 | rozpouštědla a kosmetika | 138 500 | 100 – 134 |
| CFC-114 | CClF ₂ CClF ₂ | 0.7 – 1.0 | chlazení | - | 300 |
| CFC-115 | CClF ₂ CF ₃ | 0.4 – 0.6 | chlazení, stabilizátor obalové drtě | - | 500 |
| HCFC-22 | CHClF ₂ | 0.05 | chlazení, aerosoly, pěny, hašení ohně | 81 200 | 16 – 20 |
| Halon 1301 | CBrF ₃ | 10 – 13.2 | hašení ohně | 2600 | 110 |
| Halon 1211 | CClBrF ₂ | 2.2 – 3.0 | hašení ohně | 2600 | 15 |
| metylchloroform | CH ₃ CCl ₃ | 0.15 | rozpouštědlo | 500 000 | 5.5 – 10 |
| tetrachlormetan | CCl ₄ | 1.2 | rozpouštědlo | 71 200 | 50 – 69 |

1.5 Mezinárodní dohody

Jak již bylo poznamenáno, v roce 1974 se objevily nezávisle na sobě dva vědecké články naznačující ohrožení ozónové vrstvy. Jeden z nich uvedl: „*Atomy chlóru ve stratosféře by mohly být významným ničitelem ozónu [11].*“ V druhém článku se psalo: „*Chlorofluorouhlovodíky se dostávají až do stratosféry, kde se rozpadají, uvolňující atomy chlóru [11].*“ V obou člancích bylo předpovídáno, že používáním CFC by se mohla spustit dosud netušená ekologická katastrofa. Autory byly vědci Rowland a Molina [14], pozdější nositelé Nobelovy ceny za tento objev.

Těmito dvěma články se odstartoval prudký rozmach výzkumu chemie stratosférického chlóru po celém světě a široká veřejnost se začala zajímat o nebezpečí plynoucí z výroby a použití CFC. O následný pokles se zasloužili aktivity různých ekologických hnutí proti aerosolovým sprejům obsahujícím CFC. V roce 1978 byly spreje na bázi CFC ve Spojených státech zakázány. Avšak ve většině ostatních částí světa byly aerosolové spreje obsahující CFC vyráběny a používání CFC k jiným účelům se zvyšovalo. V druhé polovině osmdesátých let bylo celosvětové používání CFC zpět na svém maximu z roku 1975.

I přesto, že jsou CFC jedny z nejužitečnějších látek, které kdy byly lidmi objeveny, bylo postupem času zřejmé, že je potřeba zakázat výrobu těchto látek na celém světě a pokusit se najít náhradu za tyto látky [8], [11].

Vídeňská úmluva

Mezinárodní diskuze o omezení výroby CFC byla zahájena od roku 1981. Ale až na konferenci svolané Programem Spojených národů pro životní prostředí (United Nations Environment Programme – UNEP) byla přijata Vídeňská úmluva o ochraně ozónové vrstvy [25]. Výsledkem bylo ovšem pouze alibistické prohlášení o tom, že národy by měly přijmout „přiměřená opatření“ pro ochranu ozónové vrstvy. Nebyl však připraven žádný časový plán a ani nebyly stanoveny žádné sankce.

Montrealský protokol

Dne 16. září 1987 na diplomatické konferenci byl přijat Montrealský protokol o látkách, které porušují ozónovou vrstvu [24]. Jedná se o prováděcí protokol k Vídeňské úmluvě. Oběma dokumenty byl poskytnut rámec pro globální akce vedoucí k postupnému omezování výroby a používání látek, které porušují ozónovou vrstvu.

V Montrealském protokolu bylo ujednáno, že světová výroba pěti nejpoužívanějších CFC nesmí překročit hodnoty z roku 1986. Dále bude tato produkce snížena o 20 % do roku 1993 a do roku 1998 o dalších 30 %. Dohoda byla podepsána 36 státy, včetně všech hlavních výrobců CFC.

Montrealský protokol je dohoda historického významu. Brzy se ale ukázalo, že snížení CFC, k němuž vyzývá, nestačí. Příčiny nedostatečnosti této dohody jsou pochopitelné. Dohoda nebyla podepsána většinou zemí třetího světa [18].

Londýnský dodatek

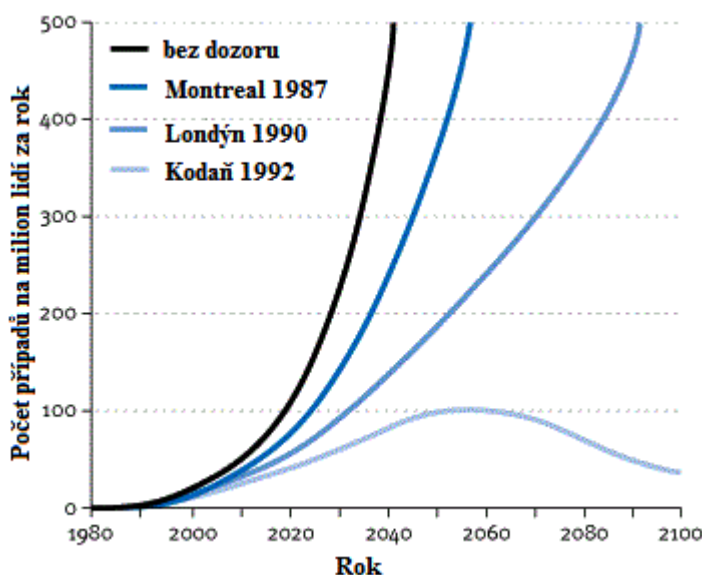
Po dalších jednáních, které byly opět vedené UNEP, se v roce 1990 sešly v Londýně vlády 92 zemí na II. zasedání stran Montrealského protokolu a dohodly se na ukončení výroby CFC do roku 2000. Byla podepsána listina „Změny a Dodatek k Montrealskému protokolu o látkách, které porušují ozónovou vrstvu.“ Také se rozšířil počet regulovaných látek protokolem z 5 na 15.

Ze začátku bylo odmítnuto podepsání dohody několika zeměmi třetího světa, pokud se nevytvoří mezinárodní fond, který by jim pomohl s technickým přechodem na alternativní látky. Dohoda se téměř rozplynula, když se USA rozhodly nepřispívat do tohoto fondu. Nakonec však tento fond zřízen byl a dohoda byla podepsána.

Kodaňský dodatek

Na IV. zasedání stran Montrealského protokolu v roce 1992 v Kodani byl přijat Dodatek Montrealského protokolu. Tímto dodatkem byla opět zkrácena doba ukončení výroby CFC, tentokrát z roku 2000 na 1. 1. 1996. Dále byl mezi regulované látky zařazen methylbromid, což je chemikálie, která se používá jako prostředek k ošetřování obilí.

Na obr. 3 je zachycen odhad výskytu rakoviny kůže v důsledku snižování ozónové vrstvy Země. Na obrázku je znázorněn účinek Montrealského protokolu a jeho dodatků, které postupem času navrátí počet případů rakoviny kůže na původní úroveň před rokem 1980. Avšak zhruba do roku 2060 se bude počet výskytů rakoviny kůže nadále zvyšovat jako následek poškozování ozónové vrstvy, které začalo v 80. letech minulého století [21].



Obr. 3: Vliv Montrealského protokolu a jeho dodatků na výskyt rakoviny kůže. Upraveno na základě [21]

1.6 Česká legislativa

Zapojení České republiky (ČR) do mezinárodního úsilí na ochranu ozónové vrstvy Země bylo započato ještě v době existence České a Slovenské Federativní Republiky (ČSFR). Dne 21. 6. 1990 vláda ČSFR schválila přistoupení k Vídeňské úmluvě a k Montrealskému protokolu. Následně byl chválen i Londýnský dodatek v roce 1992.

Prvním zákonem, který se zaměřoval na ochranu ozónové vrstvy Země v ČR, byl zákon č. 211/1993 Sb. Jeho kladem bylo, že stanovil termíny zákazu výroby a dovozu skupiny dvaceti nejvíce nebezpečných látek a výrobků takové látky

obsahujících a dále zavedl poplatky za dovoz a výrobu těchto látek. Uvedený zákon se však plně neshodoval s požadavky Montrealského protokolu, především jeho zpřísnujících dodatků. Proto byl Parlamentem ČR přijat dne 20. 4. 1995 nový zákon č. 86/1995 Sb., o ochraně ozonové vrstvy Země.

Spotřeba CFC v ČSFR a ČR se snižovala dokonce rychleji, než vyžadoval Kodaňský dodatek Montrealského protokolu, viz tab. 2.

Tab. 2: Srovnání povolené výroby CFC v ČR se skutečnou spotřebou. Zdroj [18]

| Rok | Povolená výroba (v tunách) | Skutečná výroba (v tunách) | Skutečná výroba (v % z povolené výroby) |
|------|-------------------------------|-------------------------------|--|
| 1986 | 5513.7 | 5513.7 | 100.0 |
| 1990 | 5513.7 | 5044.0 | 91.5 |
| 1992 | 5513.7 | 2790.0 | 49.0 |
| 1994 | 1378.0 | 674.0 | 48.9 |
| 1996 | 0 | 0 | 0 |

Dnes se problematika ochrany ozonové vrstvy Země v ČR řídí zákonem č. 86/2002 Sb., o ochraně ovzduší [16], který je plně kompatibilní s Montrealským protokolem a jeho zpřísnujícími dodatky. Také zahrnuje problematiku dodržování vyhlášené závazné regulace, problematiku povolování výjimek, ilegální obchod s látkami porušujícími ozonovou vrstvu. Kromě tohoto zákona je ochrana ovzduší dále v ČR regulována těmito vyhláškami a nařízeními [23]:

- **Vyhláška č. 337/2010 Sb.**, o emisních limitech a dalších podmínkách provozu ostatních stacionárních zdrojů znečišťování ovzduší emitujících a užívajících těkavé organické látky a o způsobu nakládání s výrobky obsahujícími těkavé organické látky,
- **Vyhláška č. 205/2009 Sb.**, o zjišťování emisí ze stacionárních zdrojů a o provedení některých dalších ustanovení zákona o ochraně ovzduší,
- **Vyhláška č. 13/2009 Sb.**, o stanovení požadavků na kvalitu paliv pro stacionární zdroje z hlediska ochrany ovzduší,
- **Nařízení č. 146/2007 Sb.**, o emisních limitech a dalších podmínkách provozování spalovacích stacionárních zdrojů znečišťování ovzduší,
- **Nařízení č. 372/2007 Sb.**, o národním programu snižování emisí ze stávajících zvláště velkých spalovacích zdrojů,
- **Nařízení č. 597/2006 Sb.**, o sledování a vyhodnocování kvality ovzduší,

- **Nařízení č. 615/2006 Sb.**, o stanovení emisních limitů a dalších podmínek provozování ostatních stacionárních zdrojů znečišťování ovzduší,
- **Vyhláška č. 362/2006 Sb.**, o způsobu stanovení koncentrace pachových látek, přípustné míry obtěžování zápachem a způsobu jejího zjišťování.

1.7 Shrnutí kapitoly

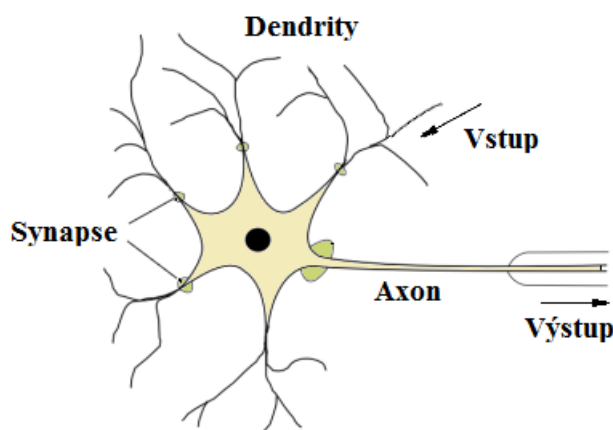
V této kapitole byla popsána základní problematika ozónové vrstvy Země. Nejdříve byl vysvětlen dopad UV záření na Zemi, dále byl charakterizován ozón a popsány jeho vlastnosti. Další podkapitola se zabývala způsobem monitorování ozónové vrstvy Země v minulosti i v současnosti. Následoval popis chemických látek poškozujících ozónovou vrstvu Země. Předposlední podkapitola se zabývala důležitými mezinárodními dohodami, pomocí kterých se podařilo snížit/zakázat výrobu látek poškozujících ozónovou vrstvu Země. Na závěr byla popsána legislativa České republiky týkající se ochrany ovzduší.

2 NEURONOVÉ SÍTĚ

Tato kapitola diplomové práce se zabývá umělými neuronovými sítěmi, které se běžně označují jen jako neuronové sítě (NS). V kapitole jsou nejdříve popsány základní pojmy z oblasti NS včetně grafického a matematického modelu umělého neuronu. Poté je popsán perceptron jako nejjednodušší forma NS, dále sítě vhodné k predikci časových řad, a to dopředné NS a na závěr také frontální NS.

2.1 Základní pojmy

Teorie NS vychází z neurofyzilogických poznatků. Snaží se vysvětlit chování na principu zpracování informací v nervových buňkách. Nervový systém se skládá z ohraničených buněk – neuronů. Neurony jsou navzájem pospojovány synapsi. Nervová buňka se skládá z těla a několika výběžků, které se mohou rozdělit na dva typy. Jedním jsou dendrity, které představují z infromatického hlediska vstupní část (přichází na ně vzruch z jiných buněk) a jeden axon, po kterém se vzruch šíří k jiným buňkám. Viz obr. 4 [7].



Obr. 4: Schéma nervové buňky. Upraveno na základě [4]

Neuronové sítě jsou jednou ze tří velkých oblastí výzkumu výpočetní inteligence, ve které se dále nachází fuzzy množiny a evoluční stochastické optimalizační algoritmy (především genetické algoritmy a evoluční postupy). Metody výpočetní inteligence jsou charakteristické [15]:

- **subsymbolická reprezentace znalostí** – představuje vyjádření a práci s reálnými čísly, obrazovou a akustickou informací,
- **paralelní zpracování** – zpracování dat, které může probíhat současně na několika procesorech,

- **dynamické systémy** – výpočetní inteligence představuje systémy s umělou inteligencí jako dynamické systémy.

Počátek NS se datuje k roku 1943, kdy W. S. McCulloch a W. Pitts definovali základní model neuronu. Byla jimi aplikována síť složená z tzv. formálních neuronů na symbolickou logiku, a výroky složené z elementárních logických operací (AND, OR, NOT). Tyto formální neurony byly vlastně jednoduché logické přepínače, jejichž přepínání probíhalo synchronně a v diskrétních časových intervalech. Hodnoty synaptických vah a prahů byly fixní [7].

Základními prvky NS jsou neurony a synapse. Neuronovou síť je možno popsat jako dvojici množin (U, H), kde U je množina uzlů NS, tedy neuronů, vstupů a výstupů a H je podmnožina množiny $N \times N$. Synapsím jsou přiřazeny váhy $w \in R$. Neurony představují nelineární jednotky, jejichž úlohou je agregace signálů ze vstupních synapsí a realizace dopředu určené nelineární funkce. Realizace této funkce musí být jednoduchá a rychlá vzhledem k velkému množství neuronů v NS. Nejčastějšími typy nelinearity jsou skoková funkce a sigmoidální nelinearita [15].


Graf propojení neuronů se nazývá topologie sítě. NS se podle topologie sítě rozděluje na [10]:

- **dopředné** – graf NS je acyklický a rozdělený do vrstev, přičemž výstupy neuronů jedné vrstvy slouží jako vstupy všech neuronů nejbližší vyšší vrstvy a jiné propojení mezi neurony sítě není, dolní vrstva celé sítě je vstupní a horní vrstva výstupní, příklad dopředné NS je zobrazen na obr. 11 v kapitole 2.3,
- **rekurentní** – graf NS je cyklický, tj. výstupy některých neuronů se vrací jako stimuly zpět do sítě. Příklad rekurentní NS je zobrazen na obr. 5.

Neuronové sítě se využívají v několika oblastech a nejčastěji jsou jimi řešeny především tyto dvě úlohy [10]:

- **predikce** – NS je schopna extrahovat v adaptačním procesu dobře zákonitosti dané časové řady a tím je schopna predikce,
- **klasifikace** – NS se na základě typických vstupů naučí klasifikovat. Ve většině případů NS klasifikují lépe než jiné metody, zejména ve smyslu generalizačních schopností. Základem klasifikace je, že dolní vrstvy provedou takovou kombinaci lineárních a nelineárních transformací vstupů, že ve výstupní vrstvě

se mohou uplatnit separující nadroviny i u množin, které samy o sobě nejsou lineárně separabilní.



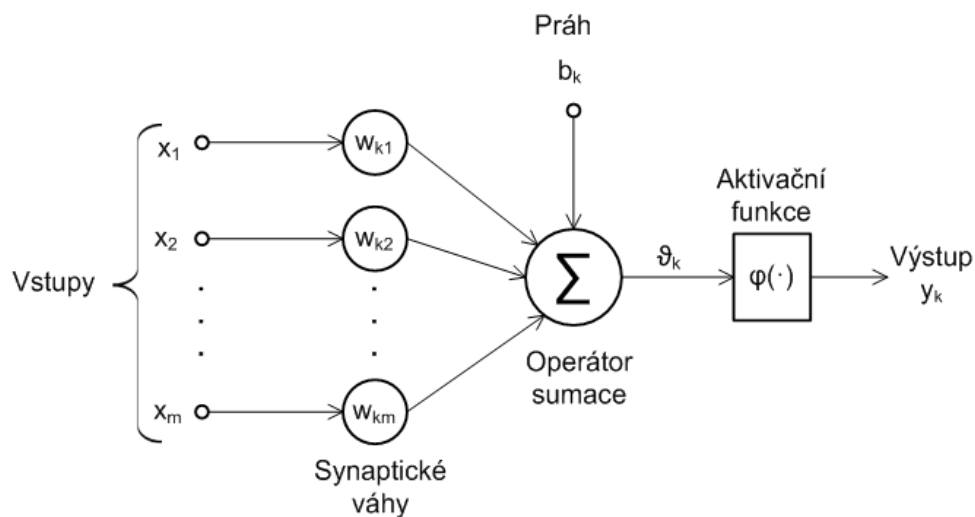
Obr. 5: Příklad rekurentní neuronové sítě. Zpracováno na základě [5]

Neuronové sítě se podle způsobu učení dělí na [10]:

- **učení s učitelem** – adaptace vah NS, při které se porovnává skutečná odezva sítě s odezvou žádanou, například dopředné NS se takto učí,
- **učení bez učitele (samoorganizace)** – nevyhodnocuje se výstup, není ani znám. Na vstup sítě jsou předkládány vzory, které jsou tříděny. Buď jsou tříděny do skupin a síť reaguje na typického zástupce nebo se přizpůsobí topologie vlastnostem vstupu. Příkladem je Kohonenova samoorganizující se mapa.

Na obr. 6 je pomocí blokového diagramu zachycen model neuronu, který ukazuje základní princip návrhu neuronových sítí. Jsou zde tři základní prvky modelu neuronu [5]:

- **Množina synapsí** – každá synapse je charakterizována svou vahou. Signál x_j na vstupu synapse j je spojen s neuronem k a je vynásoben synaptickou vahou w_{kj} .
- **Operátor sumace** – pro sčítání vstupních signálů, které mají váhu příslušné synapse neuronu. Zde popsané operace představují lineární kombinace.
- **Aktivační funkce** – pro omezení rozsahu výstupu neuronu. Aktivační funkce je označována také jako přenosová funkce, protože omezuje povolený rozsah výstupního signálu na nějakou konečnou hodnotu.



Obr. 6: Nelineární model neuronu. Zpracováno na základě [5]

Obvykle se rozsah výstupu neuronu nachází v uzavřeném intervalu $[0,1]$ nebo případně $[-1,1]$. Model neuronu také zahrnuje zevně používaný práh, který je označený b_k . Prah b_k se používá za účelem zvyšování nebo snižování aktivační funkce vstupu sítě. To záleží na tom, zda je aktivační funkce kladná nebo záporná. Neuron k může být popsán pomocí dvou matematických rovnic [5]

$$u_k = \sum_{j=1}^m w_{kj} \times x_j, \quad (2.1)$$

a

$$y_k = \varphi(u_k + b_k), \quad (2.2)$$

kde: x_1, x_2, \dots, x_m jsou vstupní signály,
 $w_{k1}, w_{k2}, \dots, w_{km}$ jsou synaptické váhy neuronu k ,
 u_k je lineární kombinace výstupu v důsledku vstupních signálů,
 b_k je práh,
 $\varphi(\cdot)$ je aktivační funkce,
 y_k je výstupní signál neuronu.

Práh b_k se používá za účelem provedení afinní transformace na lineární kombinaci výstup u_k v modelu, matematicky zapsáno

$$\vartheta_k = u_k + b_k, \quad (2.3)$$


ϑ_k je aktivační potenciál neuronu k a lineární kombinace výstupu u_k .

Pomocí aktivační funkce $\varphi(\vartheta)$ je určován výstup neuronu v rozmezí aktivačního potenciálu ϑ . Nejčastěji jsou používány tyto tři základní aktivační funkce [5]:

- **Skoková funkce** – tento typ aktivační funkce se matematicky zapisuje

$$\varphi(\vartheta) = \begin{cases} 1 & \text{když } \vartheta \geq 0 \\ 0 & \text{když } \vartheta < 0. \end{cases} \quad (2.4)$$

Výstup neuronu bude mít hodnotu 1, jestliže aktivační potenciál neuronu je nezáporný a 0 v jiném případě, viz obr. 7.




Obr. 7: Skoková aktivační funkce. Zpracováno na základě [5]

- **Po částech lineární funkce** – matematický zápis

$$\varphi(\vartheta) = \begin{cases} 1, & \vartheta \geq +\frac{1}{2} \\ \vartheta, & +\frac{1}{2} > \vartheta > -\frac{1}{2} \\ 0, & \vartheta \leq -\frac{1}{2}. \end{cases} \quad (2.5)$$

Tato podoba aktivační funkce může být považována za aproximace nelineárního zesílení. Na obr. 8 je zachycena grafická reprezentace této aktivační funkce.




Obr. 8: Po částech lineární aktivační funkce. Zpracováno na základě [5]

- **Sigmoidální funkce** – grafem této aktivační funkce je s-křivka. Jedná se o nejvíce používaný typ aktivační funkce při vytváření umělých NS. Je definována jako striktně rostoucí funkce, která představuje hladkou rovnováhu mezi lineárním a nelineárním chováním. Příkladem sigmoidální funkce je logistická funkce, vyjádřená matematicky

$$\varphi(\vartheta) = \frac{1}{1 + e^{-a\vartheta}}, \quad (2.6)$$

kde a je parametr strmosti sigmoidální funkce. Změnou tohoto parametru, se tedy získají sigmoidální funkce s různou strmostí, viz obr. 9. Pokud se parametr a přiblíží k nekonečnu, tak se sigmoidální funkce stane jednoduchou skokovou funkcí. Zatímco výsledkem skokové funkce je hodnota 0 nebo 1, výsledkem sigmoidální funkce je hodnota z uzavřeného intervalu $[0,1]$. Také je sigmoidální funkce diferencovatelná, zatímco skoková funkce není.



Obr. 9: Sigmoidální aktivační funkce. Zpracováno na základě [5]

Všechny tři aktivační funkce mají rozsah výstupu od 0 do +1. Někdy je ale vhodné, aby byl rozsah hodnot aktivační funkce od -1 do +1. V tomto případě aktivační funkce představuje nesymetrickou podobu původní funkce. Konkrétně skoková funkce je nyní definována jako

$$\varphi(\vartheta) = \begin{cases} 1 & \text{když } \vartheta > 0 \\ 0 & \text{když } \vartheta = 0 \\ -1 & \text{když } \vartheta < 0, \end{cases} \quad (2.7)$$

kteřá je obvykle značena jako signum funkce. Odpovídající funkcí pro sigmoidální funkci, kde rozsah hodnot bude v intervalu od -1 do +1, je funkce

hyperbolický tangens

$$\varphi(\vartheta) = \tanh(\vartheta). \quad (2.8)$$

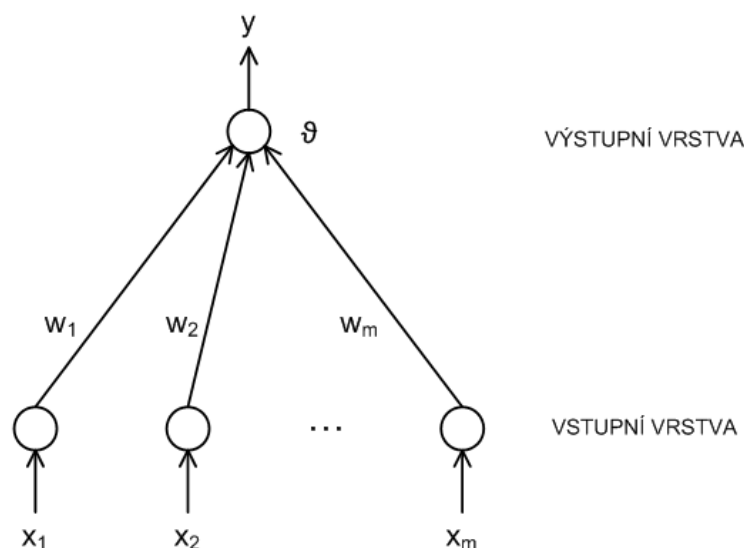
Povolení záporných hodnot sigmoidální aktivační funkce má analytické výhody.

2.2 Perceptron

V roce 1958 bylo dokázáno, že McCullochovi – Pittsovi síť s modifikovatelnými synaptickými vahami se dají natrénovat tak, aby uměli rozpoznat a klasifikovat objekty. Dokázal to Frank Rosenblatt a pojmenoval je perceptrony [17]. Trénovací procedura probíhá tak, že se nejdříve zaznamená odpověď každého formálního neuronu na daný podnět. Pokud se jedná o správnou odpověď, váhy se nemodifikují. Pokud se ale jedná o nesprávnou odpověď, potom se modifikují váhy všech aktivovaných vstupních synapsí, a to následujícím způsobem. Pokud má být neuron aktivní a není, zvětší se váha, a naopak, pokud má být na výstupu neuronu 0 a není, zmenší se váha. Rosenblattova trénovací procedura je založená na znalosti toho, které vzory patří do které třídy. Jeho myšlenka modifikace vah spojení na základě korekce chyb je základem mnoha algoritmů učení s pomocí učitele, které se používají dodnes.

V roce 1960 Widrow a Hoff použili podobné pravidlo učení pro jejich model neuronového klasifikátora, který byl pojmenován ADALINE (ADaptive LInear NEuron). Poprvé bylo ukázáno, že v procesu učení se minimalizuje suma čtverců chyb, tedy v době učení se minimalizuje nějaká globální funkce systému.

Perceptron je nejjednodušší forma NS, ve které jsou obsaženy jen dvě vrstvy, viz obr. 10. Spodní vrstva obsahuje m vstupních neuronů a horní vrstva obsahuje jen jeden výstupní neuron, to znamená, že perceptron neobsahuje skryté neurony. Orientované spoje jsou ohodnoceny váhovými koeficienty w_i (index i vyjadřuje index vstupního neuronu) a výstupní neuron je ohodnocený prahovým koeficientem ϑ .



Obr. 10: Perceptron. Zpracováno na základě [7]


V roce 1969 bylo poukázáno na omezení perceptronů v knize „Perceptrony: úvod do výpočetní geometrie“ od autorů Minsky a Papert. Bylo ukázáno, že sítě tohoto typu nejsou vůbec výpočtově univerzální a nedokáží řešit všechny třídy problémů, především perceptrony nejsou schopny řešit tzv. lineární neseparovatelné problémy. Tento problém byl vyřešen až v roce 1986, kdy autoři Rumelhart, Hinton a Williams zavedli pravidlo učení metodou zpětného šíření chyb pro vícevrstvé perceptrony. Formálně neurony v perceptronech nejsou jednoduché logické přepínače McCullochovo – Pittsovo typu, ale analogové elementy se spojitou vstupně-výstupní funkcí. Jsou schopné se učit na příkladech, a samy najít příznaky společné vzorům patří do téže třídy. Extrakce příznaků se provádí ve skryté vrstvě neuronů. Je však potřeba při učení znát, které vzory patří do které třídy. Vícevrstvé sítě jsou velmi vhodné i na aproximaci spojitých funkcí [7].

2.3 Dopředné neuronové sítě

Architektura dopředné NS je tvořena neurony uspořádanými minimálně do třech vrstev. Jsou jimi vstupní vrstva, jedna nebo více skrytých vrstev a výstupní vrstva. Skrytá vrstva je tvořena výpočetními uzly, které se nazývají skryté neurony. Funkce skrytých neuronů je dělat prostředníka mezi vstupy a výstupem sítě. Pokud se přidá jedna nebo více skrytých vrstev, tak síť dokáže zachytit více informací. To je obzvláště cenné v případě, že je vstupní vrstva velkého rozměru. Vstupem do neuronů ve vstupní vrstvě je vektor vstupních signálů. Neurony v každé další vrstvě sítě mají jako vstupy pouze výstupní signály předchozí vrstvy. Množina výstupních signálů neuronů

ve výstupní vrstvě NS představuje celkovou odezvu sítě na předkládané vzory ve vstupní vrstvě [5].

Na obr. 11 je znázorněna struktura dopředné NS s lineárními vstupními neurony a výstupním neuronem.



Obr. 11: Příklad dopředné neuronové sítě. Zpracováno na základě [15]

Výstup této dopředné NS může být vyjádřen takto [15]

$$Y = \sum_{k=1}^K \alpha_k \times d \left(\sum_{j=1}^J \beta_{jk} \times X_{jk} \right), \quad (2.9)$$

kde: Y je výstup NS,

α je vektor vah synapsí mezi neurony ve skryté vrstvě a výstupním neuronem,

β je vektor vah synapsí mezi vstupními neurony a neurony ve skryté vrstvě,

k je index neuronu ve skryté vrstvě,

K je počet neuronů ve skryté vrstvě,

d je aktivační funkce,

j je index vstupního neuronu,

J je počet vstupních neuronů na jeden neuron ve skryté vrstvě,

X je vstupní vektor NS.

NS pracují ve dvou fázích, které se nazývají fáze adaptivní a fáze vybavování. V procesu učení NS se mění hodnoty vah synapsí mezi neurony. Cílem je dosáhnout takového stavu NS, ve kterém bude dosaženo uspokojivé predikce. Vzhledem ke složitosti struktury NS neexistuje žádná metoda, která by byla schopná jednoznačně určit hodnoty vah synapsí definované úlohy. Nejčastěji se využívají gradientní metody, z nichž nejznámější je algoritmus zpětného šíření chyby (Back-Propagation algoritmus). Algoritmus je založený na minimalizaci součtu čtverců chyb s využitím poznatku o průběhu nelineární funkce v neuronech. Požaduje se, aby nelineární funkce byla spojitá. Uvedený algoritmus vyžaduje přítomnost učitele [15].

Na začátku procesu učení jsou váhy w_i nastaveny náhodně na hodnoty blízké 0. Cílem algoritmu Back-Propagation je minimalizovat chybu založenou na druhé mocnině rozdílu mezi skutečným a očekávaným výstupem sítě pro vstup x_i

$$Err(w_i) = \frac{1}{2} \sum_{v \in \text{výstupy}} (y_{i,v} - \hat{y}_{i,v})^2, \quad (2.10)$$

kde: $Err(w_i)$ je chybová funkce (střední kvadratická chyba) váhy w_i ,
 $y_{i,v}$ je skutečná hodnota,
 $\hat{y}_{i,v}$ je predikovaná hodnota.

Změna váhy vazby vedoucí od neuronu j k neuronu k se řídí gradientem funkce Err

$$\Delta w_{j,k} = -\eta \frac{\partial Err}{\partial w_{j,k}} = -\eta \frac{\partial Err}{\partial SUM_k} \frac{\partial SUM_k}{\partial w_{j,k}} = -\eta \frac{\partial Err}{\partial SUM_k} x_{j,k}, \quad (2.11)$$

kde: $\Delta w_{j,k}$ je změna váhy mezi neurony j a k ,
 η je rychlost učení,
 SUM_k je vážený součet vstupů do neuronu k .

Základem tohoto algoritmu je, že se vypočítá chyba na výstupech jednotlivých neuronů. Nejdříve se vypočítá chyba pro každý neuron v ve výstupní vrstvě

$$error_v = out_v(1 - out_v)(y_v - out_v), \quad (2.12)$$

kde: $error_v$ je chyba neuronu v ve výstupní vrstvě,
 out_v je predikovaná hodnota výstupu neuronu v ve výstupní vrstvě,
 y_v je skutečná hodnota výstupu neuronu v ve výstupní vrstvě.

Dále se pak zpětně spočítá chyba pro každý neuron s ve skryté vrstvě

$$\text{error}_s = \text{out}_s(1 - \text{out}_s) \sum_{v \in \text{výstup}} (w_{s,v} \text{error}_v), \quad (2.13)$$

kde: out_s je predikovaná hodnota výstupu neuronu s ve střední vrstvě,
 $w_{s,v}$ je váha vazby neuronu s ve střední vrstvě s neuronem v ve výstupní vrstvě.

Nakonec pro každou vazbu vedoucí od neuronu j do neuronu k se modifikují váhy vazby

$$w_{j,k} = w_{j,k} + \Delta w_{j,k}, \quad (2.14)$$

$$\text{a } \Delta w_{j,k} = \eta \times \text{error}_k \times x_{j,k},$$

kde: $x_{j,k}$ je j -tý vstup do k -tého neuronu,
 error_k je chyba neuronu k ve vstupní vrstvě [1].

Při zpětném šíření se při práci sítě informace (výsledky) šíří od vstupní vrstvy k vrstvě výstupní. V procesu učení jsou váhy modifikovány od vrstvy výstupní k vrstvě vstupní. Kritéria pro zastavení procesu učení se používají následující [1]:

- ustálení chybové funkce (v minimu),
- dosažení předem zadaného počtu iterací,
- pokles pod předem zadanou hodnotu chybové funkce.

2.4 Frontální neuronové sítě


Dalším typem NS vhodným k predikci časových řad jsou frontální NS. Jedná se o NS s časovým posunem, které jsou v angličtině označovány jako Time Delay Neural Network (TDNN). Poprvé byly TDNN popsány v článcích od autorů Lang, Hinton v roce 1988 a o rok později od Waibel.

Frontální NS jsou založeny na myšlence, že by o výstupu sítě neměl rozhodovat jen vstup sítě, ale i informace o historii předkládaných vzorů. Vícevrstvá síť se rozšíří o možnost reprezentovat časový kontext, aby tak mohlo být na základě předložené vstupu lépe rozhodnuto o výstupu.


Frontální NS poskytují vícevrstvé síti okno do minulosti, kromě momentálního vstupu (v čase t) vidí síť ještě i vstupy z minulých n kroků (v časech $t-1$, $t-2$, ..., $t-n$). Tuto síť je možné trénovat klasickou metodou zpětného šíření chyby

(Back-Propagation), přičemž je důležité zachovat pořadí trénovacích vzorů v trénovací množině [5], [7].

Při predikci se výstup NS stává funkcí času. Časová dimenze se může zabudovat do NS dvěma způsoby a to implicitně nebo explicitně. V explicitní reprezentaci času se čas stává plnohodnotným vstupním signálem. Implicitní reprezentace času představuje zabudování časové dimenze do struktury NS. V rámci dopředných NS v případě implicitní reprezentace času se využívají tzv. filtry, které používají krátkodobou paměť a operátor prostorové sumace. Prostorová sumace je sumace vstupních signálů. Na obr. 12 je znázorněna struktura frontální NS. Písmenem F je označen filtr NS. Filtr TDNN je znázorněn na obr. 13.



Obr. 12: Příklad frontální neuronové sítě. Zpracováno na základě [15]



Obr. 13: Filtr frontální neuronové sítě. Zpracováno na základě [15]

kde: $x(t)$ je hodnota vstupu filtru v čase t ,
 b je hloubka paměti filtru,
 χ jsou váhy synapsí v rámci filtru,
 z^{-1} je operátor jednotkového časového zpoždění,
 $xf(t)$ je výstup filtru pro hodnotu vstupu v čase t .

Při TDNN je celá krátkodobá paměť situována na začátku NS jako určitá předvrstva, která zpracovává časový kontext. V krátkodobé paměti se uchovávají poznatky o stavech okolí NS a jednotlivého neuronu v blízké minulosti. Existuje několik možných struktur krátkodobé paměti, z kterých se nejvíc používá právě paměť s konstantním počtem zpoždění. V této struktuře paměti se pracuje s diskrétním časem a s operátorem zpoždění z^{-b} , kde b je počet intervalů zpoždění. Operátor se chová tak, že pro hodnotu proměnné x v čase t se vrací hodnota proměnné x v čase $t - b$. Každá paměť je charakterizována svoji hloubkou, kterou určuje parametr b . Čím je paměť hlubší, tím více informací o minulých stavech okolí je uchováno [15].

Výstup TDNN s konstantní paměti všech filtrů, lineárním filtrem a lineárním výstupním neuronem se může vyjádřit takto [15]

$$Y = \sum_{k=1}^K \alpha_k \times d \left(\sum_{j=1}^J \beta_{jk} \times \sum_{i=1}^b \chi_{ijk} \times X_{ijk} \right), \quad (2.15)$$

kde: Y je výstup NS,
 α je vektor vah synapsí mezi neurony ve skryté vrstvě a výstupním neuronem,
 β je vektor vah synapsí mezi filtry a neurony ve skryté vrstvě,
 χ je vektor vah synapsí uvnitř filtru,
 k je index neuronu ve skryté vrstvě,
 K je počet neuronů ve skryté vrstvě,
 d je aktivační funkce,
 j je index filtru,
 J je počet filtrů na jeden neuron ve skryté vrstvě,
 i je index vstupu filtru,
 I je počet vstupů filtru,
 b je hloubka krátkodobé paměti filtru,
 X je vstupní vektor NS.

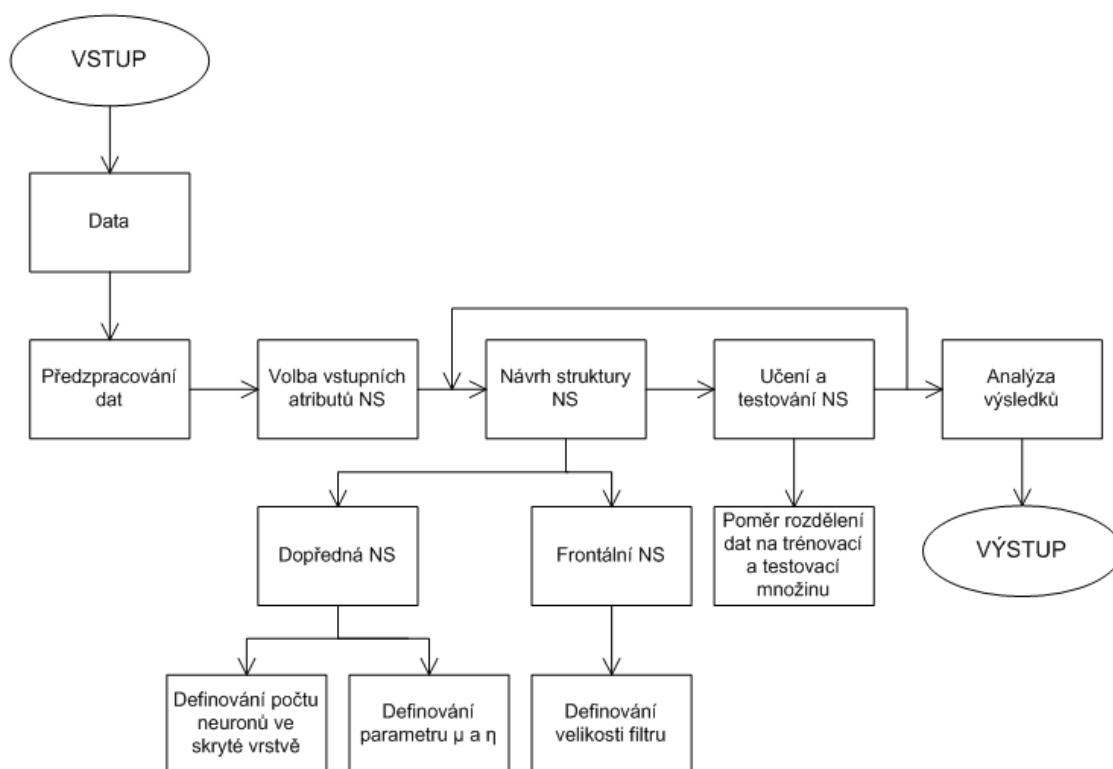
2.5 Shrnutí kapitoly

Tato kapitola diplomové práce se zabývala NS. V první podkapitole byly popsány základní pojmy z oblasti NS včetně grafického a matematického modelu umělého neuronu. V další podkapitole byl popsán perceptron jako nejjednodušší forma NS. Následující podkapitola se zabývala popisem dopředných NS. Byla zde popsána jejich struktura, matematický zápis výstupu a také zde byl popsán algoritmus Back-Propagation, který je základním algoritmem pro učení NS. V poslední podkapitole byly vysvětleny frontální NS, které jsou často používány k predikci časových řad stejně jako dopředné NS. Také zde byla popsána jejich struktura a matematický zápis výstupu.

3 NÁVRH MODELU NA PREDIKCI OZÓNU

V této kapitole je navržen model na predikci ozónu a v jednotlivých podkapitolách jsou popsány jeho dílčí kroky. Nejdříve je popsáno, jak byla získána data a kde byla naměřena. Další dvě podkapitoly se zabývají popisem této datové matice a jejím předzpracováním. Dále jsou popsány ukazatele, podle kterých může být hodnocena přesnost predikce ozónu. Následuje vlastní návrh dopředné NS vhodné k predikci ozónu a její verifikace v prostředí JavaNNS (Simulátor neuronových sítí napsaný v jazyce Java). Dále je zde popsáno nastavení jednotlivých parametrů v tomto programu. Na závěr jsou zobrazeny výsledky z prostředí JavaNNS.

Modelování predikce ozónu pomocí NS je založeno na několika fázích a podfázích zobrazených na obr. 14. Musí se věnovat dostatečná pozornost každé jednotlivé fázi, protože chyba v jedné fázi by ovlivnila výsledek celého modelu.

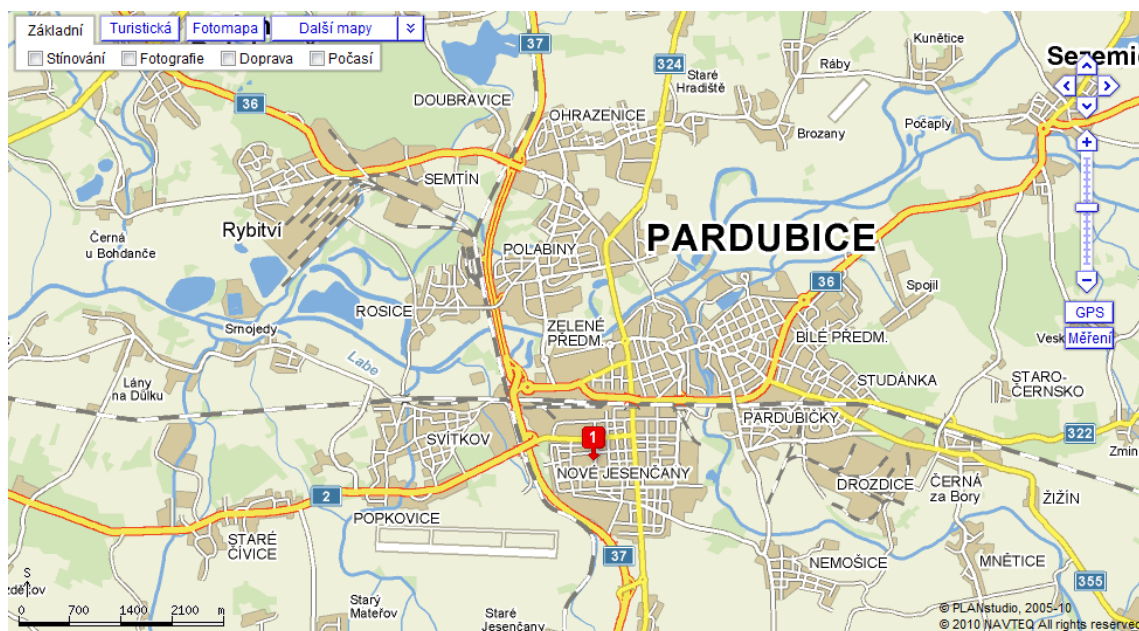


Obr. 14: Návrh modelu na predikci ozónu. Zdroj [vlastní]

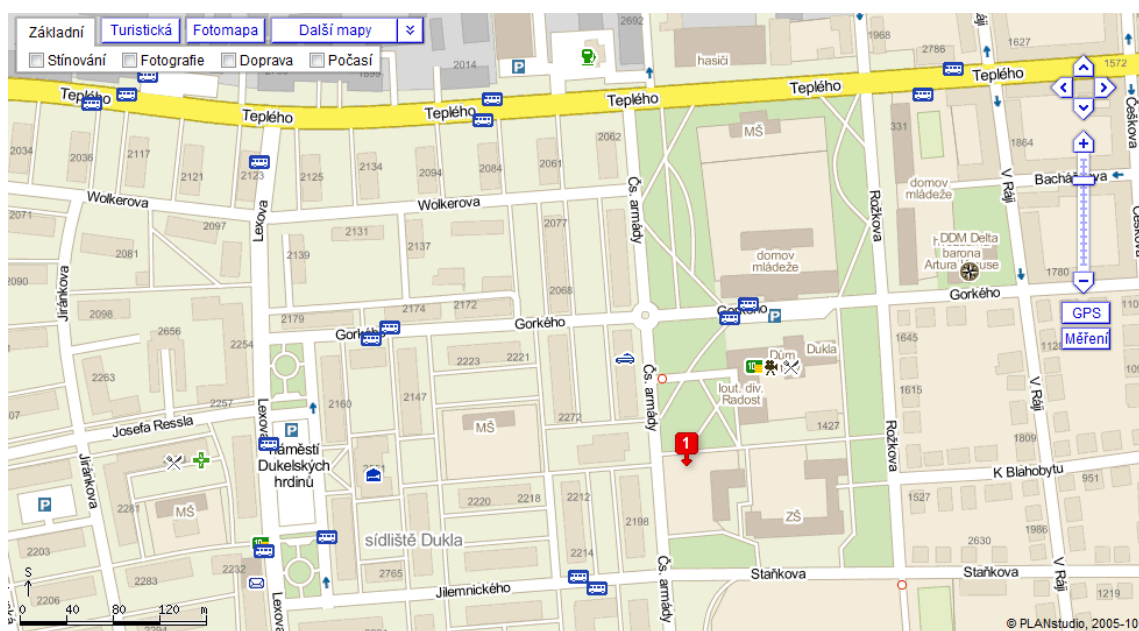
3.1 Získání dat

Data byla získána od Českého hydrometeorologického ústavu (ČHMÚ), který je vlastníkem automatizované měřicí stanice zajišťující informace o kvalitě ovzduší v Pardubicích. Automatizovaná měřicí stanice se nachází v areálu družiny základní

školy Staňkova v centru sídliště Dukla v Pardubicích, viz obr. 15 a obr. 16. Stanice se nachází ve výšce 239 m nad mořem a okolí je tvořeno velmi málo zvlněným terénem. Měřit kvalitu ovzduší se zde začalo 1. 2. 2001. V současné době zde probíhá 5 měřících programů, jejichž hlavním cílem je určení vlivu sledovaných veličin na zdravotní stav obyvatelstva. Součástí těchto programů je i doprovodné měření meteorologických veličin [2].



Obr. 15: Umístění automatizované měřící stanice v Pardubicích. Zdroj [19]



Obr. 16: Umístění automatizované měřící stanice v areálu ZŠ Staňkova v centru sídliště Dukla. Zdroj [19]

Český hydrometeorologický ústav poskytuje na svých webových stránkách část těchto dat online, přičemž jsou zaznamenávány hodnoty každou celou hodinu. Data

se nachází na webu http://portal.chmi.cz/files/portal/docs/uoco/web_generator/aqindex_slide1/mp_EPAUA_CZ.html (případně se k nim jde dostat přes úvodní stránku ČHMÚ <http://portal.chmi.cz>, kliknutím na tlačítko OVZDUŠÍ nad mapou a následně kliknutím na Pardubice Dukla na mapě). Data jsou dostupné v podobě přehledné tabulky se zvýrazněním překročených limitů u jednotlivých sledovaných veličin a dále v podobě grafů se zaznamenanými hodnotami za posledních 24 hodin [2].

Českým hydrometeorologickým úřadem byla poskytnuta datová matice o velikosti $m \times n$, kde m je počet řádků a n je počet sloupců. Konkrétně se jedná o datovou matici o velikosti 679×23 . Datová matice je tedy tvořena 23 sledovanými ukazateli, pro které bylo zaznamenáno 679 záznamů. Jednotlivé záznamy představují hodnoty naměřené v určitý den. Celkem tedy datová matice je tvořena záznamy z měření po dobu jednoho roku, deseti měsíců a deseti dnů.

3.2 Popis datové matice

Jak již bylo výše poznamenáno, datová matice o velikosti 679×23 je tvořena 23 atributy, které mohou mít vliv na naměřenou hodnotu ozónu. Mezi ně patří ukazatele, kterými se zjišťuje kvalita ovzduší, dále doplňující meteorologická měření a samozřejmě také údaje o tom, v který den byly tyto hodnoty naměřeny. Datová matice obsahuje následující atributy [12], [13]:

- **SO₂** – oxid siřičitý je bezbarvý štiplavý plyn, je nehořlavý a rozpouští se ve vodě za vzniku kyselého roztoku, přičemž jeho rozpustnost je silně závislá na teplotě, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **PM₁₀** – prachové částice menší než $10 \mu\text{m}$ se významně podílí na důležitých atmosférických dějích jako je vznik srážek a teplotní bilance Země, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **PM_{2,5}** – prachové částice menší než $2,5 \mu\text{m}$, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **NO_x** – oxidy dusíku jsou širokou skupinou látek, hlavním zdrojem emisí těchto látek jsou motorová vozidla, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **NO** – oxid dusnatý je bezbarvý plyn bez zápachu, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **NO₂** – oxid dusičitý je červenohnědý plyn štiplavého zápachu, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,

- **CO** – oxid uhelnatý je hořlavý a prudce jedovatý bezbarvý plyn bez zápachu, je hlavním produktem nedokonalého spalování materiálů s obsahem uhlíku, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **Den** – pořadové číslo dne, v kterém byly hodnoty naměřeny, rozsah hodnot je tedy 1 – 7 (kde: 1 = pondělí, 2 = úterý, ..., 7 = neděle),
- **Měsíc** – pořadové číslo měsíce, v kterém byly hodnoty naměřeny, rozsah hodnot je tedy 1 – 12 (kde: 1 = leden, 2 = únor, ..., 12 = prosinec),
- **Pracovní den** – atribut zaznamenávající skutečnost, zda byly hodnoty naměřeny v pracovní den či ne, hodnota 1 = pracovní den, hodnota 0 = nepracovní den,
- **Rychlost větru** – je vzdálenost, kterou urazí pohybující se vzduch za jednotku času, hodnoty jsou udávány v m/s,
- **Vlhkost** – vlhkost vzduchu je meteorologický prvek popisující množství vodní páry ve vzduchu, hodnoty jsou udávány v %,
- **Tlak** – tlak vzduchu je síla, která působí v daném místě atmosféry kolmo na libovolně orientovanou plochu, hodnoty jsou udávány v hPa (hektopascalech),
- **Sluneční svit** – délka slunečního svitu udávaná počet hodin, po které přímé sluneční záření dosahovalo zemského povrchu,
- **Teplota** – průměrné denní teploty, hodnoty jsou udávány ve $^{\circ}\text{C}$,
- **Směr větru** – směr, odkud vane vítr, je udáván v úhlových stupních (např. 90° = východní vítr, 180° = jižní vítr, 270° = západní vítr, 360° = severní vítr, 0° = bezvětří atp.),
- **O₃-1** – průměrná denní hodnota naměřeného ozónu v čase t , hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **O₃-2** – průměrná denní hodnota naměřeného ozónu v čase $t - 1$, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **O₃-3** – průměrná denní hodnota naměřeného ozónu v čase $t - 2$, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **O₃-4** – průměrná denní hodnota naměřeného ozónu v čase $t - 3$, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **O₃-5** – průměrná denní hodnota naměřeného ozónu v čase $t - 4$, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,
- **O₃-6** – průměrná denní hodnota naměřeného ozónu v čase $t - 5$, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$,

- O_3 – průměrná denní hodnota naměřeného ozónu v čase $t - 6$, hodnoty jsou udávány v $\mu\text{g}/\text{m}^3$.

3.3 Předzpracování dat

Data byla analyzována a předzpracována v prostředí Microsoft Excel 2007. Nejdříve zde byly vypočítány základní popisné statistiky atributů, jako jsou střední hodnota, chyba střední hodnoty, medián, modus, směrodatná odchylka, rozptyl výběru, špičatost, šikmost, variační rozpětí, minimum, maximum, součet a počet. Příloha A v této práci obsahuje tyto popisné statistiky datové matice.

Po zhlédnutí datové matice a popisné statistiky bylo rozhodnuto o provedení standardizace a normalizace dat. Standardizace dat byla provedena z důvodu rozdílných měrných jednotek jednotlivých atributů a normalizace dat z důvodu potlačení vlivu velikosti jednotlivých atributů.

Nechť je dána matice dat $\mathbf{Z} = (z_{ij})$ typu $m \times n$, kde m je počet řádků a n je počet sloupců matice. Dále je vypočítána střední hodnota \bar{z}_j a směrodatná odchylka s_j j -tého atributu z_j . Standardizované hodnoty x_{ij} byly vypočítány pomocí vztahu [6]

$$x_{ij} = \frac{z_{ij} - \bar{z}_j}{s_j}. \quad (3.1)$$

Nyní jsou tyto standardizované hodnoty atributů bezrozměrné, mají střední hodnotu 0 a rozptyl 1.

Následně byla provedena normalizace dat. Nejdříve byly vypočítány normy n_i všech m řádků pomocí vztahu [6]

$$n_i = \sqrt{\sum_{j=1}^n (x_{ij})^2}, \text{ pro } i = 1, 2, \dots, m \quad (3.2)$$

a pak byly vypočítány normalizované hodnoty n_{ij} datové matice pomocí vztahu [6]

$$n_{ij} = \frac{x_{ij}}{n_i}. \quad (3.3)$$

Dále byla provedena analýza závislosti atributů pomocí výpočtu korelačních koeficientů pro normalizovaná data. Korelační koeficienty jsou zapisovány do matice, která zachycuje závislost mezi jednotlivými dvojicemi atributů. Matice je symetrická,

a tak stačí vypočítat prvky pod hlavní diagonálou (případně pouze prvky nad hlavní diagonálou). Prvky ležící na hlavní diagonále se rovnají jedné, neboť je zjišťována závislost mezi dvěma identickými atributy. Hodnoty korelačních koeficientů se pohybují v uzavřeném intervalu $[-1;1]$. Hodnota korelačního koeficientu 1 znamená přímou závislost mezi atributy (zvyšuje-li se hodnota jednoho atributu, zvyšuje se i hodnota druhého). Hodnota korelačního koeficientu -1 znamená nepřímou závislost (čím více se zvyšuje hodnota jednoho atributu, tím více se zmenšuje hodnota druhého). Hodnota korelačního koeficientu 0 znamená, že mezi atributy není žádná lineární závislost. V tomto případě se říká, že jsou atributy nekorelované. Příloha B v této práci obsahuje vytvořenou korelační matici pro normalizovaná data.

Z výše uvedené korelační matice je zřejmé, že mezi daty jsou statisticky významné závislosti. Z tohoto důvodu nebylo nutné zahrnout všechny atributy jako vstupy do NS, protože by se NS předkládaly redundantní údaje, které by neposkytovaly žádné nové informace využitelné pro predikci. Na základě korelační matice bylo rozhodnuto takto:

- z korelované dvojice atributů $PM_{2,5}$ a PM_{10} se ponechá pouze atribut PM_{10} ,
- z korelované dvojice atributů NO a NO_x se ponechá pouze atribut NO_x ,
- z korelované dvojice atributů NO_2 a NO_x se ponechá pouze atribut NO_x ,
- z korelovaných dvojic atributů O_3-1 , O_3-2 , O_3-3 , O_3-4 , O_3-5 , O_3-6 a O_3 se ponechá pouze atribut O_3 . Příloha I zachycuje graf normalizovaných hodnot atributu O_3 (tj. naměřeného ozónu).

Příloha C zachycuje graf normalizovaných hodnot atributu SO_2 , příloha D atributu PM_{10} , příloha E atributu NO_x , příloha F atributu CO , příloha G atributu Vlhkost a příloha H atributu Teplota.

Důsledkem tohoto rozhodnutí se původní datová matice o velikosti 679×23 zredukovala na velikost 679×14 , kde číslo 14 představuje počet atributů (sloupců) a číslo 679 počet naměřených hodnot pro tyto atributy (řádky). Celá tato datová matice bude použita pro predikci ozónu. Bylo rozhodnuto, že již nebudou použity žádné adaptivní metody pro předzpracování časových řad jednotlivých atributů, ale že se pro predikci využijí normalizovaná data. Datová matice se tedy nyní skládá z těchto atributů a jejich záznamů:

- SO_2 ,
- NO_x ,
- Den,
- PM_{10} ,
- CO ,
- Měsíc,

- Pracovní den,
- Rychlost větru,
- Vlhkost,
- Tlak,
- Sluneční svit,
- Teplota,
- Směr větru,
- O₃.

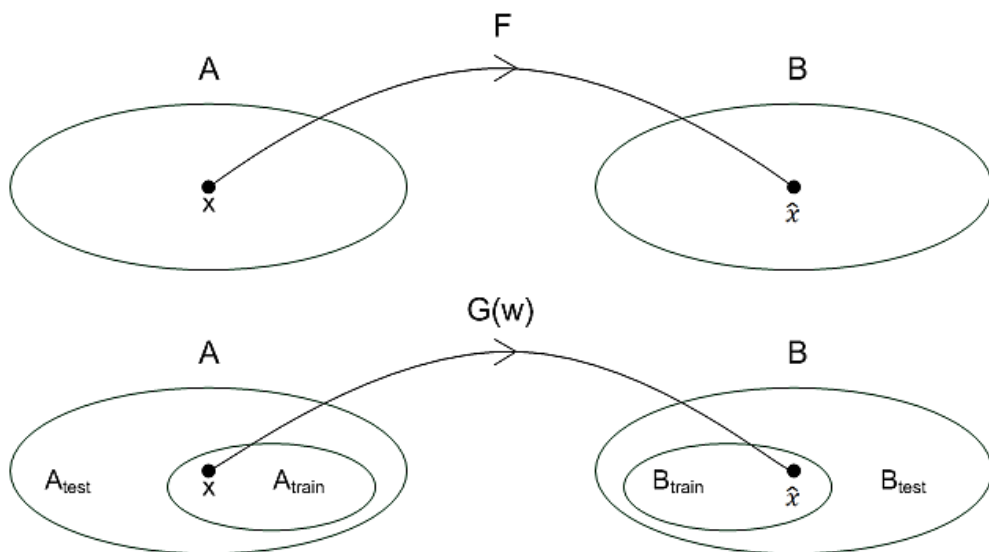
3.4 Rozdělení dat na trénovací a testovací množinu

Nechť je dána všeobecná formulace predikčního problému pomocí pojmu zobrazení – funkce definované nad dvěma množinami A a B . Potom tento přístup bude užitečný pro interpretaci NS jako prediktoru. Nechť $F(x)$ je funkce definovaná nad množinou A , která přiřadí každému elementu $x \in A$ funkční hodnotu z množiny B , $\hat{x} = F(x) \in B$ a

$$F: A \rightarrow B. \quad (3.4)$$

Dále nechť $G(x,w)$ je funkce, jejíž argumenty jsou z konečné podmnožiny $A_{train} = \{x_1, x_2, \dots, x_r\} \subset A$ (nazývané trénovací množina) a w je parametr (nebo parametry) zobrazení G , potom $\hat{x} = G(x,w) \in B_{train} \subset B$ (viz obr. 17) a

$$G(w): A_{train} \rightarrow B_{train}. \quad (3.5)$$



Obr. 17: Schematické znázornění zobrazení $F: A \rightarrow B$. Zpracováno na základě [7]

Potom je možné tvrdit, že zobrazení $G(w)$ je restrikce zobrazení $F(x)$ nad množinou $A_{train} \subset A$. Komplement A_{train} vzhledem k množině A je označený A_{test} (nazývaný testovací množina), $A_{test} = A \setminus A_{train}$. Nechť pro každé $x_i \in A_{train}$ je známá požadovaná funkční hodnota \hat{x}_i . Zúžením zobrazení $F: A \rightarrow B$ na podmnožinu A_{train} se získá nové modelové zobrazení $G(w)$, funkční tvar tohoto zobrazení je určený

parametrem (nebo parametry) w . Požadované funkční hodnoty \hat{x}_i jsou interpretované jako obrazy funkce F , platí tedy vztah

$$\hat{x}_i = F(x_i), \text{ pro } i = 1, 2, \dots, r \quad (3.6)$$

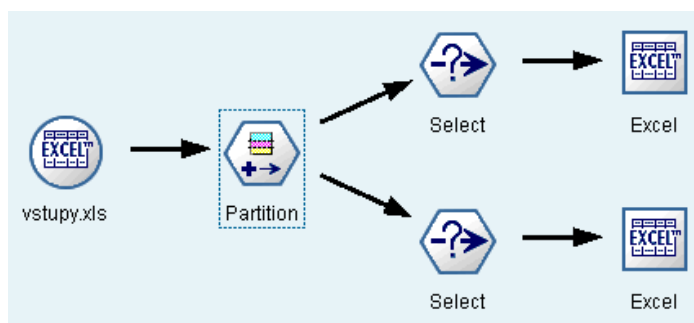
Cílem je najít takový parametr (nebo parametry) w funkce $G(x,w)$, aby funkční hodnoty argumentů z trénovací množiny A_{train} byly co nejbližším obrazem funkce $F(x)$, tedy požadovaným hodnotám. Necht' je definována účelová funkce

$$E(w) = \frac{1}{2} \sum_{i=1}^r [G(x_i, w) - \hat{x}_i]^2. \quad (3.7)$$

Tato funkce vyjadřuje sumu čtverců odchylek funkce $G(x,w)$ od požadovaných hodnot \hat{x} z trénovací množiny. Požadavek, aby vypočítané hodnoty $G(x,w)$ byly co nejbližší požadovaným hodnotám \hat{x} , je realizován pomocí požadavku minimalizace účelové funkce $E(w)$ vzhledem k parametru w . Funkce $G(x,w)$ je adaptována, když její parametr w je vybrán tak, aby se rovnal své optimální hodnotě, tj. ve kterém má účelová funkce globální minimum [7].

Pro potřebu zjišťování skutečnosti, jak jsou dané navržené modely na predikci ozónu kvalitní (tj. přesné), bylo tedy potřeba rozdělit datovou matici na část trénovací a část testovací. K této činnosti bylo využito programové prostředí SPSS Clementine 10.1. Byl vytvořen jednoduchý stream (viz obr. 18), kterým byla načtena datová matice uložená v souboru ve formátu excel. Pomocí uzlu Partition bylo provedeno náhodné rozdělení dat v požadovaném poměru a pomocí uzlů Select a Excel byla vyexportována rozdělená data do souborů ve formátu excel. Bylo provedeno rozdělení datové matice na trénovací a testovací množinu v následujících poměrech (trénovací množina : testovací množina):

- 50 : 50,
- 60 : 40,
- 70 : 30,
- 80 : 20,
- 90 : 10.



Obr. 18: Rozdělení dat na trénovací a testovací množinu. Zdroj [vlastní]

3.5 Ukazatele přesnosti predikce

Jak bylo výše zmíněno, je třeba zjišťovat přesnost navržených modelů, aby se mohlo rozhodnout, zda je navržený model schopný uspokojivé predikce nebo není. Nejčastěji se k tomu využívají střední chyba (Average Error – AVE), střední absolutní chyba (Mean Absolute Error – MAE), střední kvadratická odchylka (Mean Squared Error – MSE) a odmocnina střední kvadratické odchylky (Root Mean Squared Error – RMSE). Jejich výpočet se provádí následovně [15], [22]

$$AVE = \frac{\sum_{n=1}^N (y_n - y_{np})}{N}, \quad (3.8)$$

$$MAE = \frac{\sum_{n=1}^N |y_n - y_{np}|}{N}, \quad (3.9)$$

$$MSE = \frac{\sum_{n=1}^N (y_n - y_{np})^2}{N}, \quad (3.10)$$

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (y_n - y_{np})^2}{N}}, \quad (3.11)$$

kde: y_n je skutečná hodnota,

y_{np} je predikovaná hodnota,

N je počet predikovaných období.

V této práci budou k analýze přesnosti predikce ozónu využívány ukazatelé MSE a RMSE.

3.6 Dopředná neuronová síť vhodná k predikci ozónu


Navržená dopředná NS vhodná k predikci ozónu má neurony rozděleny do třech vrstev, které jsou navzájem plně propojeny, viz obr. 19. První vrstvou je vrstva vstupní, dále skrytá vrstva a poslední výstupní vrstva. Vstupní vrstva obsahuje 13 neuronů, skrytá vrstva 5 neuronů a výstupní vrstva 1 neuron, protože se jedná o predikční NS.

Vstupní vrstva je tvořena těmito 13 atributy:

- SO₂,
- PM₁₀,
- NO_x,
- CO,
- Den,
- Měsíc,
- Pracovní den,
- Rychlost větru,

- Vlhkost,
- Tlak,
- Sluneční svit,
- Teplota,
- Směr větru,

Výstupem této NS se strukturou 13-5-1 je predikovaná hodnota ozónu. Navržená dopředná NS vhodná k predikci ozónu byla verifikována v prostředí JavaNNS a je zobrazena na obr. 19.



Obr. 19: Dopředná neuronová síť vhodná k predikci ozónu. Zdroj [vlastní]

Nejdříve byly pomocí inicializační funkce Random Weights náhodně nastaveny počáteční váhy synapsí NS na hodnoty z intervalu $[-1;1]$.

Dále byla zvolena aktualizací funkce Topological order. Tato funkce je nejvíce oblíbenou pro dopředné NS. Pomocí této funkce neurony vypočítávají své nové aktivační hodnoty v pořadí daném strukturou NS. Nejdříve je tedy zpracována vstupní vrstva, dále skrytá vrstva a nakonec výstupní vrstva. Tímto způsobem se v procesu učení projde přes všechny neurony NS.


Pro učení této dopředné NS byl použit modifikovaný algoritmus zpětného šíření chyby. Jednalo se o algoritmus Back-Propagation Momentum. Tento algoritmus vyžaduje nastavení 4 parametrů [26]:

- η – parametr učení, udává délku kroku, který určuje rychlost učení. Čím je délka kroku větší, tím je proces učení rychlejší, ale může být přeskočeno optimální řešení. Typické hodnoty η jsou 0.1 ... 1.0. Pro tuto predikci bylo zvoleno $\eta = 0.2$.
- μ – moment učení, udává velikost změny staré váhy (vztaženo k 1), která je připočtena k aktuální změně. Typické hodnoty μ jsou 0 ... 1.0. Pro tuto predikci bylo zvoleno $\mu = 0.2$.
- c – konstanta, která je připočtena k derivaci aktivační funkce před vypočtením hodnoty pro zpětné šíření z každého neuronu. Zlepšuje odolnost sítě proti přeučení. Typické hodnoty c jsou 0 ... 0.25, nejčastěji se používá 0.1. Pro tuto predikci bylo zvoleno $c = 0.1$.
- d_{\max} – maximální rozdíl mezi učící hodnotou a hodnotou výstupního neuronu, který je tolerován, tj. který je šířen zpět s hodnotou 0. Pro tuto predikci bylo zvoleno $d_{\max} = 0.1$.


Dalším krokem bylo zvolení přemapovací funkce. Přemapovací funkce je prostředkem pro rychlou změnu požadovaného výstupu sítě bez nutnosti změny vstupů sítě. Na každou hodnotu předkládaného vzoru je aplikována přemapovací funkce ještě předtím, než je předkládána síti k učení. Pro tuto predikci byla zvolena přemapovací funkce Norm. Pomocí této přemapovací funkce jsou všechny vzory normalizovány, jsou přemapovány do vzoru délky 1. Tato funkce nemá žádné volitelné parametry [26].

3.6.1 Výsledky procesu učení

Každá NS se učí v tzv. cyklech. V každém cyklu jsou NS předloženy všechny trénovací a testovací vzory pouze jednou. Bylo rozhodnuto, že učení NS bude probíhat v 600 cyklech. Pro tuto predikci bylo použito rozdělení dat na trénovací a testovací množinu v poměru 50:50. Kvalita učení byla sledována pomocí RMSE testovací množiny. Průběh chyby trénovací a testovací množiny pro dopřednou NS se strukturou 13-5-1vhodnou k predikci ozónu je zobrazen na obr. 20 a obr. 21. Pro grafické zachycení průběhu chyb bylo použito programové prostředí Microsoft Excel 2007.



Obr. 20: Průběh testovací chyby dopředné neuronové sítě. Zdroj [vlastní]



Obr. 21: Průběh trénovací chyby dopředné neuronové sítě. Zdroj [vlastní]

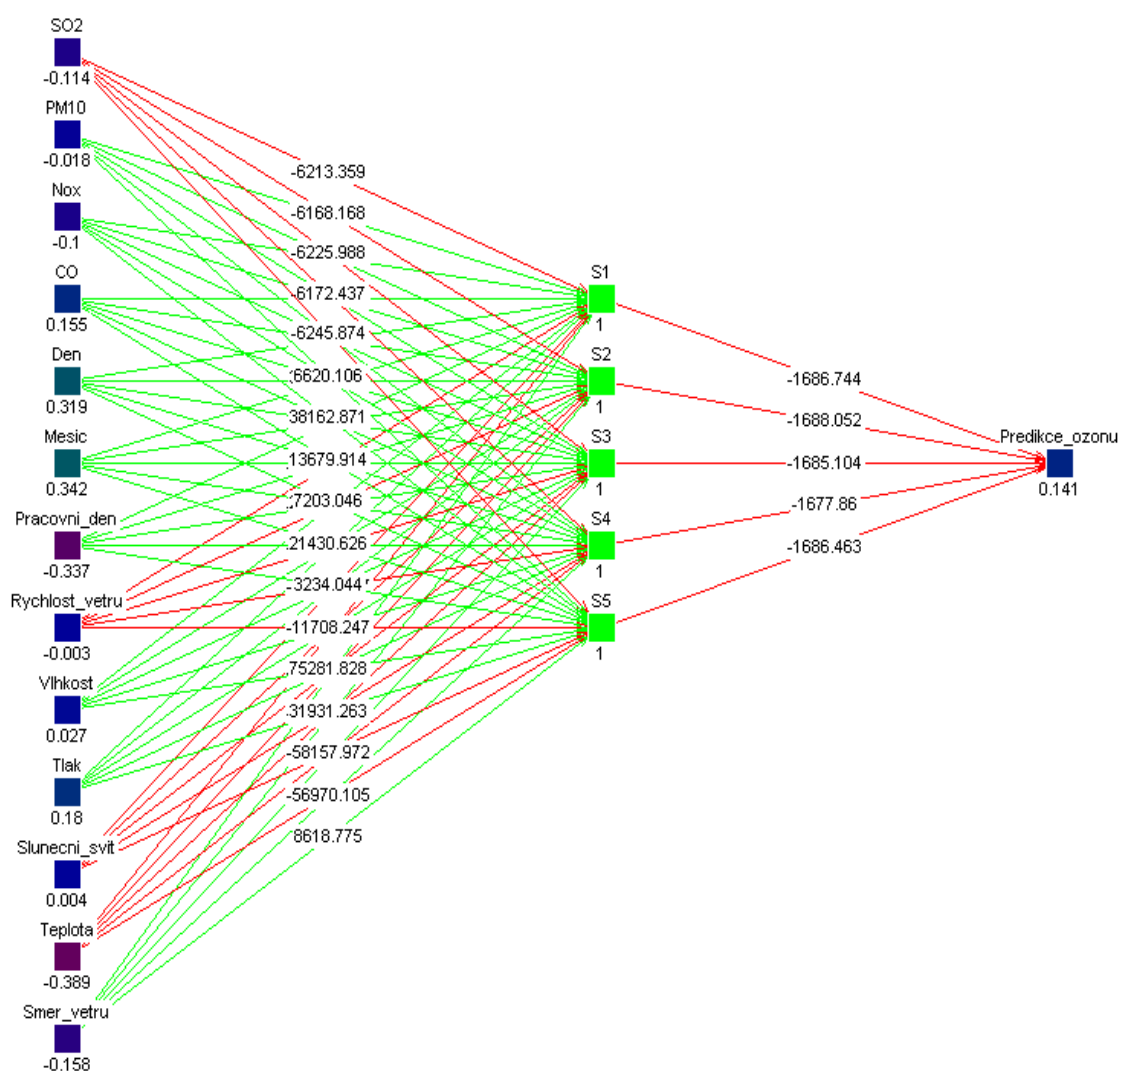
Chyba na testovací množině po 600 cyklech dosáhla hodnoty 0.184. K největšímu snížení RMSE došlo po 300 až 360 cyklech testování, kdy hodnota RMSE klesla o více než pět tisícín.

Z průběhu obr. 21 by se mohlo zdát, že trénovací chyba se v procesu učení NS stále zvyšovala. Není tomu ale tak, protože tento obrázek zachycuje chybu až od 60 cyklu. V prvních 20 cyklech se chyba rychle snižovala, ale poté se pomalu zvyšovala až na hodnotu 0.975. Bohužel nelze z prostředí JavaNNS získat hodnoty trénovacích a testovacích chyb po každém cyklu. Tab. 3 zobrazuje průběh učení a testování této dopředné NS.

Obr. 22 zachycuje dopřednou NS po procesu učení. Jsou zde tedy nastavené váhy synapsí a aktivační hodnoty jednotlivých neuronů včetně predikované hodnoty ozónu. Takto navrženou a natrénovanou dopřednou NS lze použít k predikci ozónu.

Tab. 3: Průběh učení a testování dopředné neuronové sítě. Zdroj [vlastní]

| Počet cyklů | Trénovací množina | | Testovací množina | |
|-------------|-------------------|---------|-------------------|---------|
| | MSE | RMSE | MSE | RMSE |
| 60 | 0.88171 | 0.93899 | 0.03653 | 0.19113 |
| 120 | 0.89032 | 0.94356 | 0.03642 | 0.19084 |
| 180 | 0.89032 | 0.94356 | 0.03642 | 0.19084 |
| 240 | 0.89032 | 0.94356 | 0.03578 | 0.18916 |
| 300 | 0.89822 | 0.94773 | 0.03578 | 0.18916 |
| 360 | 0.93352 | 0.96618 | 0.03375 | 0.18371 |
| 420 | 0.94120 | 0.97016 | 0.03395 | 0.18426 |
| 480 | 0.95096 | 0.97514 | 0.03395 | 0.18426 |
| 540 | 0.94976 | 0.97453 | 0.03379 | 0.18382 |
| 600 | 0.95112 | 0.97524 | 0.03379 | 0.18382 |



Obr. 22: Dopředná neuronová síť vhodná k predikci ozónu po procesu učení. Zdroj [vlastní]

3.6.2 Nastavení vah synapsí, aktivačních hodnot a prahů neuronů

SNNS network definition file V1.4-3D
 generated at Fri Nov 26 10:20:52 2010

network name : 13-5-1
 source files :
 no. of units : 19
 no. of connections : 70
 no. of unit types : 0
 no. of site types : 0

learning function : BackpropMomentum
 update function : Topological_Order

unit default section :

| act | bias | st | subnet | layer | act func | out func |
|--------|--------|----|--------|-------|--------------|--------------|
| 0.0000 | 0.0000 | h | 0 | 1 | Act_Logistic | Out_Identity |

unit definition section :

| no. | typeName | unitName | act | bias | st | position |
|-----|----------|----------------|----------|------------|----|----------|
| 1 | | SO2 | -0.11459 | -0.99750 | i | 1, 1, 1 |
| 2 | | PM10 | -0.01918 | 0.12717 | i | 1, 2, 1 |
| 3 | | Nox | -0.10014 | -0.61339 | i | 1, 3, 1 |
| 4 | | CO | 0.15501 | 0.61748 | i | 1, 4, 1 |
| 5 | | Den | 0.32038 | 0.17002 | i | 1, 5, 1 |
| 6 | | Mesic | 0.34262 | -0.04025 | i | 1, 6, 1 |
| 7 | | Pracovni_den | -0.33771 | -0.29942 | i | 1, 7, 1 |
| 8 | | Rychlost_vetru | -0.00387 | 0.79192 | i | 1, 8, 1 |
| 9 | | Vlhkost | 0.02754 | 0.64568 | i | 1, 9, 1 |
| 10 | | Tlak | 0.18076 | 0.49321 | i | 1,10, 1 |
| 11 | | Slunecni_svit | 0.00429 | -0.65178 | i | 1,11, 1 |
| 12 | | Teplota | -0.39095 | 0.71789 | i | 1,12, 1 |
| 13 | | Smer_vetru | -0.15883 | 0.42100 | i | 1,13, 1 |
| 14 | | S1 | 1.00000 | 1707.26587 | h | 8, 4, 1 |
| 15 | | S2 | 1.00000 | 1458.87378 | h | 8, 5, 1 |
| 16 | | S3 | 1.00000 | 1582.83179 | h | 8, 6, 1 |
| 17 | | S4 | 1.00000 | 1453.97534 | h | 8, 7, 1 |
| 18 | | S5 | 1.00000 | 1682.84460 | h | 8, 8, 1 |
| 19 | | Predikce_ozonu | 0.14072 | -1.95022 | o | 14, 6, 1 |

connection definition section :

| target | site | source:weight |
|--------|------|--|
| 14 | | 13:8673.45996, 12:-56974.93750, 11:-58102.93750, 10:31973.82617, 9:75224.62500, 8:-11692.75391, 7:3243.63452, 6:21509.74609, 5:7191.92676, 4:13657.02246, 3:38136.82422, 2:6582.67773, 1:-6213.35938 |
| 15 | | 13:8719.50293, 12:-57093.72266, 11:-58208.00391, 10:32362.65625, 9:75254.21875, 8:-11824.88867, 7:3302.47974, 6:21601.15820, 5:7149.01855, 4:13621.70801, 3:38324.12500, 2:6642.29102, 1:-6168.16895 |
| 16 | | 13:8615.75586, 12:-56989.29297, 11:-58177.16797, 10:31955.44922, 9:75320.92969, 8:-11702.38574, 7:3213.90332, 6:21454.33203, 5:7202.01758, 4:13710.91309, 3:38165.28906, 2:6632.11084, 1:-6225.98828 |
| 17 | | 13:8551.34180, 12:-56544.36719, 11:-57702.06641, 10:31702.04102, 9:74703.00000, 8:-11622.19727, 7:3216.46582, 6:21305.54297, 5:7104.46777, 4:13590.10156, 3:37887.18359, 2:6591.25879, 1:-6172.43701 |
| 18 | | 13:8618.77539, 12:-56970.10547, 11:-58157.97266, 10:31931.26367, 9:75281.82813, 8:-11708.24707, 7:3234.04443, 6:21430.62695, 5:7203.04688, 4:13679.91406, 3:38162.87109, 2:6620.10693, 1:-6245.87402 |
| 19 | | 18:-1686.46350, 17:-1677.86023, 16:-1685.10474, 15:-1688.05298, 14:-1686.74438 |

layer definition section :

| layer | unitNo. |
|-------|--------------------|
| 2 | 14, 15, 16, 17, 18 |
| 3 | 19 |

3.7 Shrnutí kapitoly

Tato kapitola diplomové práce se zabývala návrhem modelu na predikci ozónu. Byl zde vytvořen model a v jednotlivých podkapitolách byly popsány jeho dílčí kroky. Nejdříve bylo popsáno, jak byla získána data a kde byla naměřena. Další dvě podkapitoly se zabývali popisem této datové matice a jejím předzpracováním. Dále byly popsány ukazatele, podle kterých může být hodnocena přesnost predikce ozónu. Následoval vlastní návrh dopředné NS vhodné k predikci ozónu a jeho verifikace v prostředí JavaNNS. Dále zde bylo popsáno nastavení jednotlivých parametrů v tomto programu. Na závěr byly zobrazeny výsledky procesu učení z prostředí JavaNNS.

4 ANALÝZA VÝSLEDKŮ NAVRŽENÝCH MODELŮ

Tato závěrečná kapitola se zabývá analýzou výsledků navržených modelů. V první podkapitole jsou analyzovány výsledky navržených modelů dopředných NS a ve druhé podkapitole jsou analyzovány navržené modely frontálních NS. Závěrečná podkapitola se zabývá porovnáním výsledků modelů těchto dvou rozdílných typů NS.

Kvalita modelů NS je závislá na několika faktorech. Mezi tyto faktory patří typ NS, počet vrstev NS, počet neuronů v jednotlivých vrstvách NS a nastavení různých parametrů učení NS. Výsledek učení NS ovlivňuje také způsob a poměr rozdělení datové matice na trénovací a testovací množinu.

Všechny navržené modely dopředných NS pro predikci ozónu byly verifikovány v programovém prostředí JavaNNS a frontální NS byly verifikovány ve starší verzi Stuttgartského simulátoru, protože nová verze plně nepodporuje tento typ NS.

4.1 Dopředné neuronové sítě

Při návrhu dopředných NS bylo měněno několik faktorů, které mají vliv na kvalitu modelů predikce ozónu. Mezi tyto faktory patřilo:

- poměr rozdělení datové matice na trénovací a testovací množinu,
- počet neuronů ve skryté vrstvě NS,
- parametr η (rychlost učení),
- parametr μ (moment učení).


Ostatní parametry a funkce se neměnily. U všech navržených modelů byly použity takto nastavené parametry, funkce a struktura:

- počet neuronů ve vstupní vrstvě – 13, detailně popsány v kapitole 3.6,
- počet neuronů ve výstupní vrstvě – 1,
- inicializační funkce – Random Weights – náhodné váhy z intervalu $[-1;1]$,
- aktualizací funkce – Topological order,
- učící funkce – Back-propagation Momentum s parametry:
 - $c = 0.1$,
 - $d_{\max} = 0.1$,
- počet cyklů učení – 600,
- přemapovací funkce – Norm.

Kvalita navržených modelů na predikci ozónu byla posuzována pomocí velikosti RMSE testovací množiny. Čím byla chyba menší, tím se daný model lépe naučil, tj. poskytuje kvalitnější predikci.

4.1.1 Rozdělení dat na trénovací a testovací množinu v poměru 50:50

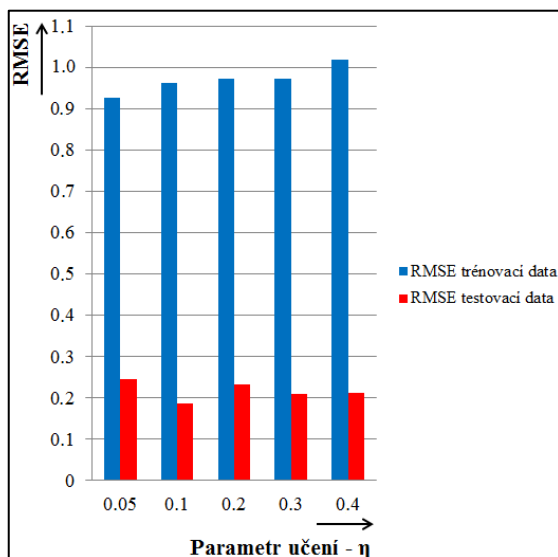
V této části práce jsou analyzovány výsledky navržených dopředných NS. U všech navržených modelů bylo pro trénování a testování použito rozdělení datové matice v poměru 50:50. Postupně byl měněn počet neuronů ve skryté vrstvě, parametr μ a parametr η . Celkem bylo navrženo 7 různých topologií dopředných NS. Na obr. 24 je zachycen vliv změny topologie na RMSE při konstantních parametrech $\mu = 0.5$ a $\eta = 0.2$.




Obr. 23: Vliv změny topologie na RMSE při poměru rozdělení dat 50:50 ($\mu = 0.5$, $\eta = 0.2$). Zdroj [vlastní]

Snižováním počtu neuronů ve skryté vrstvě se chyba o trochu zvětšovala, ale v některých případech byla úplně stejná (topologie 13-6-1 a 13-4-1) jako u modelu se strukturou 13-12-1. U modelu se strukturou 13-3-1 byla chyba dokonce ještě menší, ale model obsahuje pouze 3 neurony ve skryté vrstvě a to je málo na zachycení všech závislostí. Nejlépe se jevil model se strukturou 13-5-1, který má méně než poloviční počet neuronů ve skryté vrstvě oproti modelu 13-12-1, ale stále je dostatečný počet na zachycení nelineárních závislostí. Proto byly u modelu s touto strukturou měněny parametry μ a η za účelem dosažení ještě lepších výsledků. Na obr. 24 je zachycen vliv

změny parametru η na RMSE při konstantním parametru $\mu = 0.5$ a na obr. 25 při konstantním parametru $\mu = 0.2$.



Obr. 24: Vliv změny η na RMSE při poměru rozdělení dat 50:50 (topologie 13-5-1 a $\mu = 0.5$). Zdroj [vlastní]




Obr. 25: Vliv změny η na RMSE při poměru rozdělení dat 50:50 (topologie 13-5-1 a $\mu = 0.2$). Zdroj [vlastní]

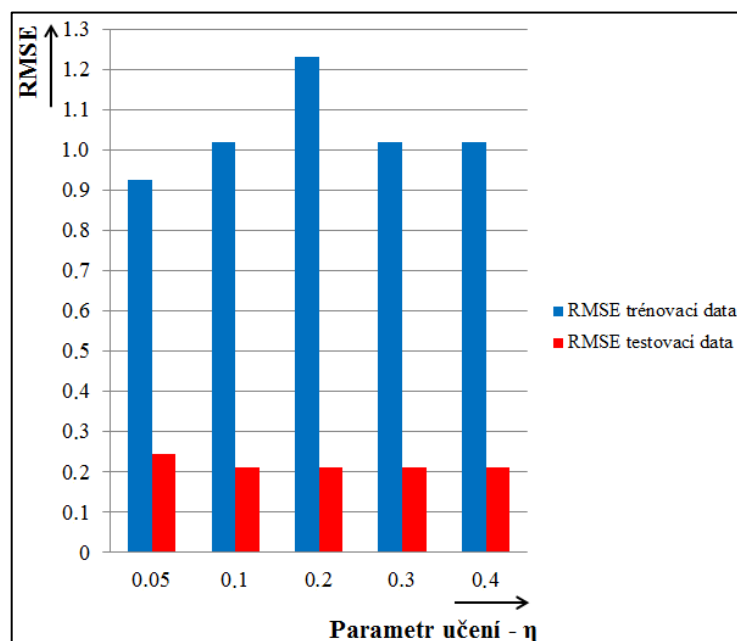
Zvyšující se hodnotou parametru η při konstantním parametru $\mu = 0.5$ i $\mu = 0.2$ se zvyšovala RMSE na trénovací množině. Nejlepšího výsledku pro parametr $\mu = 0.5$ dosáhl model 13-5-1 s parametrem $\eta = 0.1$, kde RMSE na testovací množině dosáhla hodnoty 0.187. Optimálním modelem k predikci ozónu je dopředná NS se strukturou 13-5-1 s nastavenými parametry $\mu = 0.2$ a $\eta = 0.2$, kde RMSE na testovací množině měla hodnotu 0.184. Příloha J zachycuje výsledky všech navržených modelů dopředných NS při použitím rozdělení datové matice v poměru 50:50.

4.1.2 Rozdělení dat na trénovací a testovací množinu v poměru 60:40

V této podkapitole jsou analyzovány výsledky navržených dopředných NS, kde pro jejich učení a testování bylo použito rozdělení datové matice v poměru 60:40. U těchto modelů byl měněn počet neuronů ve skryté vrstvě a rychlost učení, tj. parametr η . Opět bylo navrženo celkem 7 různých topologií dopředné NS s parametry $\mu = 0.5$ a $\eta = 0.2$. Na obr. 26 je zachycen vliv změny topologie na RMSE. Z obrázku vyplývá, že počet neuronů ve skryté vrstvě nemá téměř žádný vliv na velikost RMSE. Skoro všechny modely mají stejně velkou hodnotu RMSE na testovací množině kromě modelů s topologií 13-8-1 a 13-12-1, které ji mají o trochu větší. Pro model s topologií 13-5-1 byl ještě měněn parametr η , což zachycuje obr. 27.



Obr. 26: Vliv změny topologie na RMSE při poměru rozdělení dat 60:40 ($\mu = 0.5$, $\eta = 0.2$). Zdroj [vlastní]



Obr. 27: Vliv změny η na RMSE při poměru rozdělení dat 60:40 (topologie 13-5-1 a $\mu = 0.5$). Zdroj [vlastní]

Pro tři různé hodnoty parametru η – 0.1, 0.3 i 0.4 model vykazoval stejně velké RMSE. Pro $\eta = 0.2$ byla chyba větší a pro $\eta = 0.05$ byla chyba největší. Nejlepším modelem při použití rozdělení datové matice v poměru 60:40 je opět model s topologií 13-5-1 s nastaveným parametrem učení na 0.1, 0.3 nebo 0.4. Příloha K zachycuje výsledky všech navržených modelů dopředných NS při použití rozdělení datové matice v poměru 60:40.

4.1.3 Rozdělení dat na trénovací a testovací množinu v poměru 70:30

Dalšími verifikovanými modely byly dopředné NS, při jejichž učení a testování bylo využito rozdělení datové matice v poměru 70:30. Postupně byl měněn počet neuronů ve skryté vrstvě a parametr η . Tab. 4 zachycuje výsledky těchto navržených dopředných NS.

Tab. 4: Výsledky navržených dopředných NS při poměru rozdělení dat 70:30. Zdroj [vlastní]

| Model | μ | η | Trénovací množina | | Testovací množina | |
|---------|-------|--------|-------------------|---------|-------------------|---------|
| | | | MSE | RMSE | MSE | RMSE |
| 13-12-1 | 0.5 | 0.2 | 2.32843 | 1.52592 | 0.04643 | 0.21548 |
| 13-10-1 | 0.5 | 0.2 | 2.22635 | 1.49210 | 0.06709 | 0.25902 |
| 13-8-1 | 0.5 | 0.2 | 2.32843 | 1.52592 | 0.04643 | 0.21548 |
| 13-6-1 | 0.5 | 0.2 | 2.32843 | 1.52592 | 0.04643 | 0.21548 |
| 13-5-1 | 0.5 | 0.4 | 2.32843 | 1.52592 | 0.04643 | 0.21548 |
| 13-5-1 | 0.5 | 0.3 | 2.32843 | 1.52592 | 0.04643 | 0.21548 |
| 13-5-1 | 0.5 | 0.2 | 2.32843 | 1.52592 | 0.04643 | 0.21548 |
| 13-5-1 | 0.5 | 0.1 | 2.32843 | 1.52592 | 0.04643 | 0.21548 |
| 13-5-1 | 0.5 | 0.05 | 2.32843 | 1.52592 | 0.04643 | 0.21548 |
| 13-4-1 | 0.5 | 0.2 | 2.32843 | 1.52592 | 0.04643 | 0.21548 |
| 13-3-1 | 0.5 | 0.2 | 2.32843 | 1.52592 | 0.04643 | 0.21548 |

Pro 6 ze 7 různých navržených topologií dopředné NS bylo dosaženo úplně stejných výsledků. I při změně parametru η u modelu 13-5-1 se výsledky nezměnily. Došlo ovšem k podstatnému zvýšení chyby na trénovací množině oproti předchozím modelům, ve kterých bylo použito rozdělení datové matice v poměru 50:50 a 60:40.

4.1.4 Rozdělení dat na trénovací a testovací množinu v poměru 80:20

Dále následovala verifikace modelů dopředných NS, které k trénování a testování používali data rozdělená na množiny v poměru 80:20. U těchto modelů se opět měnil počet neuronů ve skryté vrstvě a u vybrané topologie také parametr η . Výsledky těchto modelů jsou zachyceny v tab. 5.

Znovu se nejlépe jevil model se strukturou 13-5-1, u kterého se změnou parametru η na 0.3 dosáhlo nejlepšího výsledku při tomto použitém rozdělení původní datové matice. Jako u předchozího poměru rozdělení datové matice se opět značně

zvýšily chyby na trénovací množině dat, a proto modely s rozdělením datové matice v tomto poměru nejsou vhodné k predikci ozónu.

Tab. 5: Výsledky navržených dopředných NS při poměru rozdělení dat 80:20. Zdroj [vlastní]

| Model | μ | η | Trénovací množina | | Testovací množina | |
|---------------|------------|------------|-------------------|----------------|-------------------|----------------|
| | | | MSE | RMSE | MSE | RMSE |
| 13-12-1 | 0.5 | 0.2 | 3.65068 | 1.91068 | 0.04542 | 0.21312 |
| 13-10-1 | 0.5 | 0.2 | 3.30031 | 1.81667 | 0.04390 | 0.20952 |
| 13-8-1 | 0.5 | 0.2 | 3.65068 | 1.91068 | 0.04542 | 0.21312 |
| 13-6-1 | 0.5 | 0.2 | 3.65068 | 1.91068 | 0.04542 | 0.21312 |
| 13-5-1 | 0.5 | 0.4 | 3.65068 | 1.91068 | 0.04542 | 0.21312 |
| 13-5-1 | 0.5 | 0.3 | 3.31860 | 1.82170 | 0.03735 | 0.19326 |
| 13-5-1 | 0.5 | 0.2 | 3.31731 | 1.82135 | 0.04506 | 0.21226 |
| 13-5-1 | 0.5 | 0.1 | 3.65068 | 1.91068 | 0.04542 | 0.21312 |
| 13-5-1 | 0.5 | 0.05 | 3.32041 | 1.82220 | 0.05157 | 0.22708 |
| 13-4-1 | 0.5 | 0.2 | 3.65068 | 1.91068 | 0.04542 | 0.21312 |
| 13-3-1 | 0.5 | 0.2 | 3.65068 | 1.91068 | 0.04542 | 0.21312 |

4.1.5 Rozdělení dat na trénovací a testovací množinu v poměru 90:10

Jako poslední byly verifikovány modely dopředných NS s datovou maticí rozdělenou na trénovací a testovací množinu v poměru 90:10. Také zde byl měněn počet neuronů ve skryté vrstvě a u modelu se strukturou 13-5-1 i parametr η . Výsledky těchto verifikovaných modelů jsou obsaženy v tab. 6.

Znovu bylo dosaženo identických výsledků u 6 ze 7 navržených struktur. Nejlepším modelem při tomto rozdělení dat byl model se strukturou 13-8-1, který tentokrát předčil i model 13-5-1, u kterého byl ještě měněn parametr η . Opět došlo k velmi výraznému zvýšení trénovací chyby oproti předchozímu poměru rozdělení dat. Proto nejsou tyto modely s rozdělením datové matice v poměru 90:10 vhodné k predikci ozónu.

Tab. 6: Výsledky navržených dopředných NS při poměru rozdělení dat 90:10. Zdroj [vlastní]

| Model | μ | η | Trénovací množina | | Testovací množina | |
|---------------|------------|------------|-------------------|----------------|-------------------|----------------|
| | | | MSE | RMSE | MSE | RMSE |
| 13-12-1 | 0.5 | 0.2 | 7.70513 | 2.77581 | 0.04807 | 0.21924 |
| 13-10-1 | 0.5 | 0.2 | 7.70513 | 2.77581 | 0.04807 | 0.21924 |
| 13-8-1 | 0.5 | 0.2 | 6.96070 | 2.63831 | 0.03950 | 0.19875 |
| 13-6-1 | 0.5 | 0.2 | 7.70513 | 2.77581 | 0.04807 | 0.21924 |
| 13-5-1 | 0.5 | 0.4 | 7.70513 | 2.77581 | 0.04807 | 0.21924 |
| 13-5-1 | 0.5 | 0.3 | 7.04067 | 2.65343 | 0.04010 | 0.20025 |
| 13-5-1 | 0.5 | 0.2 | 7.70513 | 2.77581 | 0.04807 | 0.21924 |
| 13-5-1 | 0.5 | 0.1 | 6.89695 | 2.62620 | 0.04505 | 0.21226 |
| 13-5-1 | 0.5 | 0.05 | 6.64040 | 2.57690 | 0.05437 | 0.23317 |
| 13-4-1 | 0.5 | 0.2 | 7.70513 | 2.77581 | 0.04807 | 0.21924 |
| 13-3-1 | 0.5 | 0.2 | 7.70513 | 2.77581 | 0.04807 | 0.21924 |

4.2 Frontální neuronové sítě

Frontální NS využívají časové zpoždění. Počet minulých vstupů je reprezentován velikostí časového zpoždění. Velikost časového zpoždění je určována délkou filtru. Struktura NS je determinována velikostí filtru. Jestliže je počet neuronů ve vstupní vrstvě NS konstantní, tak se mění počet neuronů ve skryté vrstvě podle velikosti filtru. Zvýšením délky filtru o jeden filtr, se sníží počet neuronů ve skryté vrstvě o jeden neuron.


Při návrhu frontálních NS byl postupně měněn filtr frontální NS od velikosti 2 až do velikosti 11. Zvyšováním velikosti filtru se současně snižoval počet neuronů ve skryté vrstvě. Všechny návrhy byly verifikovány s použitím datové matice rozdělené na trénovací a testovací množinu v poměru 50:50.

U všech navržených modelů byly použity takto nastavené parametry, funkce a struktura:

- počet neuronů ve vstupní vrstvě – 13, detailně popsány v kapitole 3.6,
- počet neuronů ve výstupní vrstvě – 1,
- inicializační funkce – Random Weights – náhodné váhy z intervalu $[-1;1]$,
- aktualizací funkce – Time Delay Order – aktualizací funkce pro frontální NS, jedná se o obdobu aktualizací funkce Topological order používanou pro dopředné NS,

- přemapovací funkce – Norm,
- učicí funkce – Time Delay Back-propagation s parametry:
 - $\eta = 0.2$,
 - $d_{\max} = 0.1$,
- počet cyklů učení – 600.

Na obr. 28 je zachycen vliv změny délky filtru na RMSE. Příloha L obsahuje kompletní výsledky navržených frontálních NS.




Obr. 28: Vliv změny délky filtru frontálních neuronových sítí na RMSE. Zdroj [vlastní]


Nejlepšího výsledku dosáhl model se strukturou 13-8-1, který obsahoval filtr o délce 6. Výsledky byly u všech modelů velmi podobné a nelze říct, že by se zvětšujícím filtrem klesala chyba.

Obr. 29 zachycuje průběh RMSE při učení frontální NS se strukturou 13-8-1 s hloubkou paměti filtru 6. K největšímu poklesu chyby došlo po 60 až 120 cyklech učení, kdy se snížila chyba z 1.442 na 0.869. Poté se ještě chyba pomalu snižovala až na hodnotu 0.853 po 600 cyklech učení.

Obr. 30 zachycuje průběh RMSE při testování frontální NS se strukturou 13-8-1 s hloubkou paměti filtru 6. K největšímu poklesu chyby došlo opět po 60 až 120 cyklech testování, kdy se snížila chyba z 1.025 na 0.394. Poté se chyba postupně o trochu zvyšovala až na hodnotu 0.432 po 600 cyklech testování.




Obr. 29: Průběh trénovací chyby frontální neuronové sítě. Zdroj [vlastní]



Obr. 30: Průběh testovací chyby frontální neuronové sítě. Zdroj [vlastní]

Obr. 31 zachycuje frontální NS se strukturou 13-8-1 s hloubkou paměti filtru 6 po procesu učení. Jsou zde tedy nastavené váhy synapsí a aktivační hodnoty jednotlivých neuronů včetně predikované hodnoty ozónu. Takto navrženou a natrénovanou frontální NS lze použít k predikci ozónu.



Obr. 31: Frontální neuronová síť se strukturou 13-8-1 po procesu učení. Zdroj [vlastní]

Nastavení vah synapsí, aktivačních hodnot a prahů neuronů

SNNS network definition file V1.4-3D
 generated at Sat Nov 27 15:43:09 2010

network name : 13-8-1
 source files :
 no. of units : 22
 no. of connections : 14
 no. of unit types : 0
 no. of site types : 0

learning function : TimeDelayBackprop
 update function : TimeDelay_Order

unit default section :

| act | bias | st | subnet | layer | act func | out func |
|---------|---------|----|--------|-------|--------------|--------------|
| 0.00000 | 0.00000 | h | 0 | 1 | Act_Logistic | Out_Identity |

unit definition section :

| no. | typeName | unitName | act | bias | st | position | |
|-----|----------|----------|----------|----------|----|----------|-----------------|
| 1 | | | -0.11459 | 1.00000 | i | 2, 2, 0 | Act_TD_Logistic |
| 2 | | | -0.01918 | 0.99998 | i | 2, 3, 0 | Act_TD_Logistic |
| 3 | | | -0.10014 | 0.99999 | i | 2, 4, 0 | Act_TD_Logistic |
| 4 | | | 0.15501 | 0.99998 | i | 2, 5, 0 | Act_TD_Logistic |
| 5 | | | 0.32038 | 0.99998 | i | 2, 6, 0 | Act_TD_Logistic |
| 6 | | | 0.34262 | 0.99999 | i | 2, 7, 0 | Act_TD_Logistic |
| 7 | | | -0.33771 | 0.99999 | i | 2, 8, 0 | Act_TD_Logistic |
| 8 | | | -0.00387 | 0.99997 | i | 2, 9, 0 | Act_TD_Logistic |
| 9 | | | 0.02754 | 0.99997 | i | 2,10, 0 | Act_TD_Logistic |
| 10 | | | 0.18076 | 0.99998 | i | 2,11, 0 | Act_TD_Logistic |
| 11 | | | 0.00429 | 0.99999 | i | 2,12, 0 | Act_TD_Logistic |
| 12 | | | -0.39095 | 0.99997 | i | 2,13, 0 | Act_TD_Logistic |
| 13 | | | -0.15883 | 0.99998 | i | 2,14, 0 | Act_TD_Logistic |
| 14 | | | 0.97601 | 1.12046 | h | 5, 2, 0 | Act_TD_Logistic |
| 15 | | | 0.85174 | 0.99997 | h | 5, 3, 0 | Act_TD_Logistic |
| 16 | | | 0.15283 | 0.99999 | h | 5, 4, 0 | Act_TD_Logistic |
| 17 | | | 0.86368 | 1.00000 | h | 5, 5, 0 | Act_TD_Logistic |
| 18 | | | 0.98399 | 1.00000 | h | 5, 6, 0 | Act_TD_Logistic |
| 19 | | | 0.93514 | 1.00000 | h | 5, 7, 0 | Act_TD_Logistic |
| 20 | | | 0.25716 | 0.99999 | h | 5, 8, 0 | Act_TD_Logistic |
| 21 | | | 0.11760 | 0.99998 | h | 5, 9, 0 | Act_TD_Logistic |
| 22 | | | 0.11800 | -0.43707 | o | 8, 2, 0 | Act_TD_Logistic |

connection definition section :

| target | site | source:weight |
|--------|------|---|
| 14 | | 6: 2.52316, 5: 6.27314, 4:-0.36743, 3:-1.80400, 2: 2.09360, 1: 3.24975 |
| 22 | | 21: 2.95177, 20:15.64448, 19:-5.69929, 18:-16.23965, 17:-7.52134, 16:-7.26128, 15:-1.19358, 14:10.69825 |

time delay section :

| no. | LLN | LUN | Toff | Soff | Ctype |
|-----|-----|-----|------|------|-------|
| 1 | 1 | 1 | 0 | 0 | 0 |
| 2 | 1 | 2 | -1 | 0 | 0 |
| 3 | 1 | 3 | -2 | 0 | 0 |
| 4 | 1 | 4 | -3 | 0 | 0 |
| 5 | 1 | 5 | -4 | 0 | 0 |
| 6 | 1 | 6 | -5 | 0 | 0 |
| 7 | 1 | 7 | -6 | 0 | 0 |

| no. | LLN | LUN | Toff | Soff | Ctype |
|------|-------|-------|-------|-------|-------|
| 8 | 1 | 8 | -7 | 0 | 0 |
| 9 | 1 | 9 | -8 | 0 | 0 |
| 10 | 1 | 10 | -9 | 0 | 0 |
| 11 | 1 | 11 | -10 | 0 | 0 |
| 12 | 1 | 12 | -11 | 0 | 0 |
| 13 | 1 | 13 | -12 | 0 | 0 |
| 14 | 2 | 1 | 0 | 0 | 1 |
| 15 | 2 | 2 | -1 | 1 | 1 |
| 16 | 2 | 3 | -2 | 2 | 1 |
| 17 | 2 | 4 | -3 | 3 | 1 |
| 18 | 2 | 5 | -4 | 4 | 1 |
| 19 | 2 | 6 | -5 | 5 | 1 |
| 20 | 2 | 7 | -6 | 6 | 1 |
| 21 | 2 | 8 | -7 | 7 | 1 |
| 22 | 3 | 1 | 0 | 0 | 1 |
| ---- | ----- | ----- | ----- | ----- | ----- |

4.3 Shrnutí kapitoly

Tato poslední kapitola diplomové práce se zabývala analýzou výsledků navržených modelů. V první podkapitole byly analyzovány výsledky navržených modelů dopředných NS a ve druhé podkapitole byly analyzovány navržené modely frontálních NS.

Nejlepším modelem dopředné NS byl model se strukturou 13-5-1 s nastavenými parametry učení $\eta = 0.2$ a $\mu = 0.2$. Pro trénování a testování této NS bylo použito rozdělení datové matice v poměru 50:50. RMSE této NS po 600 cyklech učení dosáhla hodnoty 0.975. RMSE po 600 cyklech testování byla 0.184.

Nejlepším modelem frontální NS byl model se strukturou 13-8-1 s hloubkou paměti filtru 6. Pro trénování a testování této NS bylo použito také rozdělení datové matice v poměru 50:50. Trénovací RMSE měla po 600 cyklech učení hodnotu 0.853 a testovací RMSE měla hodnotu 0.432.

Ze srovnání výsledků těchto dvou odlišných typů NS vyplývá, že frontální NS měla menší trénovací RMSE než dopředné NS, ale horší testovací RMSE. Proto je dopředná NS vhodnější k predikování ozónu, protože dosáhla lepších výsledků na datech, která nebyla předkládána v procesu učení.

ZÁVĚR

Cílem diplomové práce byl návrh modelu pro predikci ozónu pomocí dopředných a frontálních NS. Pro proces učení a testování NS byla použita data poskytnutá ČHMÚ. Tato data byla naměřena na sídlišti Dukla v Pardubicích. Vstupní data byla tvořena ukazateli, kterými se zjišťuje kvalita ovzduší, dále doplňujícími meteorologickými měřeními a také údaji o tom, v který den byly tyto hodnoty naměřeny. Výstupem byla predikovaná hodnota ozónu. Datová matice byla předzpracována v programovém prostředí Microsoft Excel 2007 a rozdělení na trénovací a testovací množinu proběhlo v SPSS Clementine 10.1. Dalším krokem byla verifikace modelů, která byla provedena ve Stuttgartském simulátoru NS. Posledním cílem byla analýza dosažených výsledků.

Při návrhu dopředných NS bylo měněno několik faktorů, které mají vliv na kvalitu modelů predikce ozónu. Mezi tyto faktory patřil poměr rozdělení datové matice na trénovací a testovací množinu, počet neuronů ve skryté vrstvě NS, parametr η (rychlost učení) a parametr μ (moment učení).

Při návrhu frontálních NS byl postupně měněn filtr frontální NS od velikosti 2 až do velikosti 11. Zvyšováním velikosti filtru se současně snižoval počet neuronů ve skryté vrstvě. Všechny návrhy byly verifikovány s použitím datové matice rozdělené na trénovací a testovací množinu v poměru 50:50. Kvalita navržených modelů byla hodnocena pomocí odmocniny střední kvadratické odchylky. Na základě analýzy výsledků byl vybrán optimální model pro predikci ozónu.

Z dosažených výsledků vyplynulo, že dopředné neuronové sítě jsou vhodným prostředkem k predikci ozónu. Optimálním modelem k predikci ozónu je dopředná neuronová síť, která obsahuje 13 neuronů ve vstupní vrstvě, 5 neuronů ve skryté vrstvě, 1 neuron ve výstupní vrstvě a nastavené parametry učení $\eta = 0.2$ a $\mu = 0.2$. Pro učení a testování tohoto modelu byla použita datová matice rozdělená na trénovací a testovací množinu v poměru 50:50.

Cíle definované v úvodu této diplomové práce se podařilo splnit.

SEZNAM POUŽITÉ LITERATURY

- [1] BERKA, P. *VŠE* [online]. 2009 [cit. 2011-03-11]. Neuronové sítě. Dostupné z WWW: <sorry.vse.cz/~berka/docs/izi456/kap_5.4.pdf>.
- [2] Český hydrometeorologický ústav. *Portál ČHMÚ* [online]. 2011 [cit. 2011-03-18]. Informace o kvalitě ovzduší v ČR. Dostupné z WWW: <http://portal.chmi.cz/files/portal/docs/uoco/web_generator/aqindex_slide1/mp_EPAUA_CZ.html>.
- [3] DOBROVOLNÝ, P., HERBER, V., HYNEK, A. *Výuka krajinné ekologie a DPZ* [online]. 2001 [cit. 2011-02-18]. Problematika ztenčování ozónové vrstvy. Dostupné z WWW: <http://www.sci.muni.cz/~dobro/ozon_1.htm>.
- [4] GOŁDA, A. *Akademia Górniczo-Hutnicza* [online]. 2005 [cit. 2011-03-04]. Introduction to neural networks. Dostupné z WWW: <<http://home.agh.edu.pl/~vlsi/AI/intro/>>.
- [5] HAYKIN, S. *Neural Networks – A Comprehensive Foundation*. 2nd edition. New Jersey: Prentice Hall. 1999. 842 s. ISBN 0-13-273350-1.
- [6] KELBEL, J., ŠILHÁN, D. *ČVUT v Praze* [online]. 2001 [cit. 2011-03-21]. 11 s. Shluková analýza. Dostupné z WWW: <<http://www.gerstner.felk.cvut.cz/biolab/X33BMI/slides/KMeans.pdf>>.
- [7] KVASNIČKA, V. a kol. *Úvod do teórie neurónových sietí*. Bratislava: IRIS, 1997. 262 s. ISBN 80-88778-30-1.
- [8] LIPPERT, E. a kol. *Ozonová vrstva Země : Vznik, funkce, poškození a jeho důsledky, možnosti nápravy*. Praha : Vesmír, 1995. 154 s. ISBN 80-901131-5-X.
- [9] MARTINEK, F. *Česká astronomická společnost* [online]. 2004 [cit. 2011-02-25]. AURA bude studovat zemskou atmosféru. Dostupné z WWW: <<http://www.astro.cz/clanek/1327>>.
- [10] MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J. *Umělá inteligence (I)*. Praha : Academia, 1993. 264 s. ISBN 80-200-0496-3.
- [11] MEADOWSOVÁ, D. H., MEADOWS, D. L., RANDERS, J. *Překročení mezí: konfrontace globálního kolapsu s představou trvale udržitelné budoucnosti*. Praha : Argo, 1995. 319 s. ISBN 80-85794-83-7.

- [12] *Meteocentrum.cz* [online]. 2011 [cit. 2011-03-20]. Encyklopedie meteorologie a klimatologie. Dostupné z WWW: <<http://www.meteocentrum.cz/encyklopedie/>>.
- [13] Ministerstvo životního prostředí ČR. *Integrovaný registr znečišťování* [online]. 2011 [cit. 2011-03-20]. Dostupné z WWW: <<http://www.irz.cz/>>.
- [14] MOLINA, M. J., ROWLAND, F. S. Stratospheric risk for chlorofluoromethanes: chlorine atom catalyses destruction of ozone. *Nature*. 1974, no. 249, s. 810-814.
- [15] OLEJ, V. *Modelovanie ekonomických procesov na báze výpočtovej inteligencie*. Hradec Králové : Miloš Vognar - M&V, 2003. 160 s. ISBN 80-903024-9-1.
- [16] *Portál veřejné správy ČR* [online]. 2011 [cit. 2011-02-23]. Zákon č. 86/2002 Sb. o ochraně ovzduší. Dostupné z WWW: <<portal.gov.cz/zakon/86/2002>>.
- [17] ROSENBLATT, F. The Perceptron, A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*. 1958, vol. 65, no. 6, s. 386 - 408. Dostupný také z WWW: <http://www.ling.upenn.edu/courses/Fall_2007/cogs501/Rosenblatt1958.pdf>.
- [18] ŘEHÁČEK, V. Ochrana ozonové vrstvy Země v České republice. *Chemické listy*. 1998, č. 92, s. 767 - 771. Dostupný také z WWW: <www.chemicke-listy.cz/docs/full/1998_10_767-771.pdf>. ISSN 1213-7103.
- [19] *Seznam.cz. Mapy.cz* [online]. 2011 [cit. 2011-03-19]. Dostupné z WWW: <<http://www.mapy.cz/>>.
- [20] *State of the Environment Tasmania 2009* [online]. 2010 [cit. 2011-02-22]. Changes in the ozone hole, Antarctic. Dostupné z WWW: <<http://soer.justice.tas.gov.au/2009/image/1407/index.php>>.
- [21] SYKTUS, J., JEFFREY, S. *The State of Queensland (Department of Environment and Resource Management)* [online]. 2007 [cit. 2011-02-24]. Atmosphere stratospheric ozone depletion . Dostupné z WWW: <http://www.derm.qld.gov.au/environmental_management/state_of_the_environment/state_of_the_environment_queensland_2007/state_of_the_environment_queensland_2007_contents/atmosphere_stratospheric_ozone_depletion.html>.

- [22] TOPUZ, T. *Quality assessment of data-based metamodels for multi-objective aeronautic design optimisation* [online]. 2007 [cit. 2011-03-20]. Dostupný z WWW: <http://www.few.vu.nl/en/Images/stageverslag-topuz_tcm39-90709.pdf>.
- [23] *TZB-info* [online]. 2011 [cit. 2011-02-24]. Zákon č. 86/2002 Sb. - o ochraně ovzduší a související předpisy. Dostupné z WWW: <<http://www.tzb-info.cz/pravni-predpisy/zakon-c-86-2002-sb-a-souvisejici-predpisy>>. ISSN 1801-4399.
- [24] UNEP. *Handbook for the Montreal Protocol on Substances that Deplete the Ozone Layer* [online]. Eighth edition. Nairobi : UNON, 2009 [cit. 2011-02-23]. Dostupné z WWW: <http://ozone.unep.org/Publications/MP_Handbook/MP-Handbook-2009.pdf>. ISBN 9966-7319-0-3.
- [25] UNEP. *Handbook for the Vienna Convention for the Protection of the Ozone Layer* [online]. Eighth edition. Nairobi : UNON, 2009 [cit. 2011-02-23]. Dostupné z WWW: <http://ozone.unep.org/Publications/VC_Handbook/VC-Handbook-2009.pdf>. ISBN 9966-7319-1-1.
- [26] ZELL, A. a kol. *University of Tübingen* [online]. 1998 [cit. 2011-03-25]. SNNS - User Manual, Version 4.2. Dostupné z WWW: <<http://www.ra.cs.uni-tuebingen.de/downloads/SNNS/SNNSv4.2.Manual.pdf>>.

SEZNAM OBRÁZKŮ

| | |
|--|----|
| Obr. 1: Průměrné množství ozónu nad stanicí Halley Bay v letech 1955 až 2006..... | 15 |
| Obr. 2: Ozónová díra nad Antarktidou v letech 1979 až 2008 | 15 |
| Obr. 3: Vliv Montrealského protokolu a jeho dodatků na výskyt rakoviny kůže..... | 19 |
| Obr. 4: Schéma nervové buňky..... | 22 |
| Obr. 5: Příklad rekurentní neuronové sítě..... | 24 |
| Obr. 6: Nelineární model neuronu | 25 |
| Obr. 7: Skoková aktivační funkce..... | 26 |
| Obr. 8: Po částech lineární aktivační funkce | 26 |
| Obr. 9: Sigmoidální aktivační funkce | 27 |
| Obr. 10: Perceptron..... | 29 |
| Obr. 11: Příklad dopředné neuronové sítě | 30 |
| Obr. 12: Příklad frontální neuronové sítě | 33 |
| Obr. 13: Filtr frontální neuronové sítě | 33 |
| Obr. 14: Návrh modelu na predikci ozónu | 36 |
| Obr. 15: Umístění automatizované měřící stanice v Pardubicích..... | 37 |
| Obr. 16: Umístění automatizované měřící stanice v areálu ZŠ Staňkova v centru sídliště Dukla | 37 |
| Obr. 17: Schematické znázornění zobrazení $F: A \rightarrow B$ | 42 |
| Obr. 18: Rozdělení dat na trénovací a testovací množinu | 43 |
| Obr. 19: Dopředná neuronová síť vhodná k predikci ozónu | 45 |
| Obr. 20: Průběh testovací chyby dopředné neuronové sítě | 47 |
| Obr. 21: Průběh trénovací chyby dopředné neuronové sítě..... | 47 |
| Obr. 22: Dopředná neuronová síť vhodná k predikci ozónu po procesu učení | 48 |
| Obr. 23: Vliv změny topologie na RMSE při poměru rozdělení dat 50:50 ($\mu = 0.5$, $\eta = 0.2$)..... | 52 |
| Obr. 24: Vliv změny η na RMSE při poměru rozdělení dat 50:50 (topologie 13-5-1, $\mu = 0.5$)..... | 53 |
| Obr. 25: Vliv změny η na RMSE při poměru rozdělení dat 50:50 (topologie 13-5-1, $\mu = 0.2$)..... | 53 |
| Obr. 26: Vliv změny topologie na RMSE při poměru rozdělení dat 60:40 ($\mu = 0.5$, $\eta = 0.2$)..... | 54 |

| | |
|---|----|
| Obr. 27: Vliv změny η na RMSE při poměru rozdělení dat 60:40 (topologie 13-5-1, $\mu = 0.5$)..... | 54 |
| Obr. 28: Vliv změny délky filtru frontálních neuronových sítí na RMSE | 58 |
| Obr. 29: Průběh trénovací chyby frontální neuronové sítě..... | 59 |
| Obr. 30: Průběh testovací chyby frontální neuronové sítě..... | 59 |
| Obr. 31: Frontální neuronová síť se strukturou 13-8-1 po procesu učení..... | 60 |

SEZNAM TABULEK

| | |
|---|----|
| Tab. 1: Použití, rozsahy výroby a doby prodlení látek ničících ozón..... | 17 |
| Tab. 2: Srovnání povolené výroby CFC v ČR se skutečnou spotřebou | 20 |
| Tab. 3: Průběh učení a testování dopředné neuronové sítě..... | 48 |
| Tab. 4: Výsledky navržených dopředných NS při poměru rozdělení dat 70:30..... | 55 |
| Tab. 5: Výsledky navržených dopředných NS při poměru rozdělení dat 80:20..... | 56 |
| Tab. 6: Výsledky navržených dopředných NS při poměru rozdělení dat 90:10..... | 57 |

SEZNAM PŘÍLOH

| | |
|--|------|
| Příloha A: Popisná statistika datové matice..... | I |
| Příloha B: Koeficienty korelace normalizovaných dat | II |
| Příloha C: Normalizované hodnoty naměřeného oxidu siřičitého..... | III |
| Příloha D: Normalizované hodnoty naměřených prachových částic | IV |
| Příloha E: Normalizované hodnoty naměřeného oxidu dusíku | V |
| Příloha F: Normalizované hodnoty naměřeného oxidu uhelnatého..... | VI |
| Příloha G: Normalizované hodnoty naměřené vlhkosti..... | VII |
| Příloha H: Normalizované hodnoty naměřené teploty | VIII |
| Příloha I: Normalizované hodnoty naměřeného ozónu | IX |
| Příloha J: Výsledky navržených dopředných NS při poměru rozdělení dat 50:50..... | X |
| Příloha K: Výsledky navržených dopředných NS při poměru rozdělení dat 60:40..... | XI |
| Příloha L: Výsledky navržených frontálních neuronových sítí | XI |

SEZNAM ZKRATEK

| Použité zkratky | Vysvětlení |
|-------------------|--|
| AVE | Average Error – střední chyba |
| CFC | Chlorofluorouhlovodíky |
| Cl | Chlór |
| ClO | Oxid chlornatý |
| CO | Oxid uhelnatý |
| ČHMÚ | Český hydrometeorologický ústav |
| ČR | Česká republika |
| ČSFR | Česká a Slovenská Federativní Republika |
| D.U. | Dobsonova jednotka – jednotka měření ozónu |
| EOS | Earth Observing System – program sledování povrchu Země a její atmosféry |
| JavaNNS | Simulátor neuronových sítí napsaný v jazyce Java |
| MAE | Mean Absolute Error – střední absolutní chyba |
| MSE | Mean Squared Error – střední kvadratická odchylka |
| NO | Oxid dusnatý |
| NO ₂ | Oxid dusičitý |
| NO _x | Oxidy dusíku |
| NS | Neuronová síť |
| O ₂ | Kyslík |
| O ₃ | Ozón, trikyslík |
| PM _{2,5} | Prachové částice menší než 2,5 μm |
| PM ₁₀ | Prachové částice menší než 10 μm |
| RMSE | Root Mean Squared Error – odmocnina střední kvadr. odchylky |
| SO ₂ | Oxid siřičitý |
| TDNN | Time Delay Neural Network – frontální neuronová síť |
| TOMS | Total Ozone Mapping Spectrometer – přístroj na měření ozónu |
| UNEP | Program Spojených národů pro životní prostředí |
| UV | Ultrafialové |

PŘÍLOHY


Příloha A: Popisná statistika datové matice. Zdroj [vlastní]

| | Střední hodnota | Chyba střední hodnoty | Medián | Modus | Směr. odchylka | Rozptyl výběru | Špičatost | Šikmost | Variační rozpětí | Minimum | Maximum | Součet | Počet |
|-------------------|-----------------|-----------------------|--------|-------|----------------|----------------|-----------|---------|------------------|---------|---------|----------|-------|
| SO ₂ | 8.0 | 0.2 | 6.5 | 4.2 | 5.6 | 31.8 | 9.8 | 2.4 | 49.5 | 1.4 | 50.9 | 5440.7 | 679 |
| PM ₁₀ | 32.3 | 0.8 | 26.6 | 16.2 | 21.5 | 464.4 | 16.3 | 2.9 | 225.5 | 6.0 | 231.5 | 21954.4 | 679 |
| PM _{2.5} | 20.6 | 0.5 | 16.8 | 14.8 | 14.3 | 204.7 | 15.0 | 2.8 | 139.3 | 3.5 | 142.8 | 13963.9 | 679 |
| NO _x | 31.1 | 0.9 | 24.5 | 15.1 | 22.3 | 496.1 | 9.1 | 2.7 | 161.8 | 7.0 | 168.8 | 21140.8 | 679 |
| NO | 6.9 | 0.3 | 3.7 | 2.6 | 8.9 | 80.0 | 13.5 | 3.4 | 65.9 | 0.5 | 66.4 | 4677.5 | 679 |
| NO ₂ | 20.1 | 0.4 | 18.3 | 19.9 | 9.5 | 89.4 | 3.7 | 1.5 | 65.0 | 4.8 | 69.8 | 13638.8 | 679 |
| CO | 571.7 | 9.5 | 555.1 | 658.2 | 248.1 | 61548.1 | 1.1 | 0.9 | 1497.8 | 108.7 | 1606.5 | 388174.4 | 679 |
| Den | 4.0 | 0.1 | 4.0 | 2.0 | 2.0 | 4.0 | -1.3 | 0.0 | 6.0 | 1.0 | 7.0 | 2716.0 | 679 |
| Měsíc | 6.8 | 0.1 | 7.0 | 3.0 | 3.3 | 10.6 | -1.1 | 0.0 | 11.0 | 1.0 | 12.0 | 4603.0 | 679 |
| Pracovní den | 0.7 | 0.0 | 1.0 | 1.0 | 0.5 | 0.2 | -1.1 | -1.0 | 1.0 | 0.0 | 1.0 | 485.0 | 679 |
| Rychlost větru | 2.7 | 0.1 | 2.3 | 2.0 | 1.7 | 2.9 | 2.4 | 1.4 | 11.0 | 0.0 | 11.0 | 1854.3 | 679 |
| Vlhkost | 76.5 | 0.4 | 78.0 | 82.0 | 11.6 | 133.6 | -0.3 | -0.4 | 64.0 | 35.0 | 99.0 | 51951.0 | 679 |
| Tlak | 990.5 | 0.3 | 990.4 | 982.7 | 8.3 | 69.5 | 0.2 | -0.2 | 50.2 | 963.0 | 1013.2 | 672516.9 | 679 |
| Sluneční svit | 4.7 | 0.2 | 4.4 | 0.0 | 4.1 | 16.8 | -1.4 | 0.3 | 12.6 | 0.0 | 12.6 | 3203.4 | 679 |
| Teplota | 10.0 | 0.3 | 10.8 | 11.3 | 7.7 | 58.8 | -0.7 | -0.3 | 35.2 | -10.2 | 25.0 | 6805.3 | 679 |
| Směr větru | 17.9 | 0.3 | 18.0 | 26.3 | 7.9 | 62.2 | -1.2 | -0.1 | 34.0 | 0.0 | 34.0 | 12126.7 | 679 |
| O ₃ -1 | 51.4 | 1.0 | 49.2 | 56.8 | 24.8 | 613.1 | -0.6 | 0.2 | 121.8 | 3.6 | 125.4 | 34931.3 | 679 |
| O ₃ -2 | 51.3 | 0.9 | 49.1 | 56.8 | 24.7 | 611.9 | -0.7 | 0.2 | 121.8 | 3.6 | 125.4 | 34824.2 | 679 |
| O ₃ -3 | 51.4 | 0.9 | 49.2 | 56.8 | 24.7 | 608.4 | -0.7 | 0.2 | 121.8 | 3.6 | 125.4 | 34888.6 | 679 |
| O ₃ -4 | 51.2 | 0.9 | 49.1 | 73.5 | 24.5 | 600.5 | -0.7 | 0.2 | 121.8 | 3.6 | 125.4 | 34778.6 | 679 |
| O ₃ -5 | 50.7 | 0.9 | 48.8 | 56.8 | 24.3 | 588.1 | -0.7 | 0.2 | 121.8 | 3.6 | 125.4 | 34452.1 | 679 |
| O ₃ -6 | 50.5 | 0.9 | 48.8 | 56.8 | 24.0 | 576.9 | -0.6 | 0.2 | 121.8 | 3.6 | 125.4 | 34310.7 | 679 |
| O ₃ | 50.4 | 0.9 | 48.8 | 56.8 | 23.7 | 561.8 | -0.6 | 0.2 | 121.8 | 3.6 | 125.4 | 34230.5 | 679 |


Příloha B: Koeficienty korelace normalizovaných dat. Zdroj [vlastní]

| | SO ₂ | PM ₁₀ | PM _{2,5} | NO _x | NO | NO ₂ | CO | Den | Měsíc | Pr. den | Rych. větru | Vlhkost | Tlak | Sl. svit | Teplota | Směr větru | O ₃ -1 | O ₃ -2 | O ₃ -3 | O ₃ -4 | O ₃ -5 | O ₃ -6 | O ₃ | |
|-------------------|-----------------|------------------|-------------------|-----------------|-------|-----------------|-------|-------|-------|---------|-------------|---------|-------|----------|---------|------------|-------------------|-------------------|-------------------|-------------------|-------------------|-------------------|----------------|--|
| SO ₂ | 1.00 | | | | | | | | | | | | | | | | | | | | | | | |
| PM ₁₀ | 0.18 | 1.00 | | | | | | | | | | | | | | | | | | | | | | |
| PM _{2,5} | 0.22 | 0.94 | 1.00 | | | | | | | | | | | | | | | | | | | | | |
| NO _x | 0.17 | 0.50 | 0.57 | 1.00 | | | | | | | | | | | | | | | | | | | | |
| NO | 0.07 | 0.40 | 0.43 | 0.92 | 1.00 | | | | | | | | | | | | | | | | | | | |
| NO ₂ | 0.27 | 0.55 | 0.64 | 0.84 | 0.59 | 1.00 | | | | | | | | | | | | | | | | | | |
| CO | -0.07 | 0.34 | 0.32 | 0.26 | 0.20 | 0.25 | 1.00 | | | | | | | | | | | | | | | | | |
| Den | -0.04 | 0.05 | 0.04 | 0.10 | 0.10 | 0.08 | 0.02 | 1.00 | | | | | | | | | | | | | | | | |
| Měsíc | 0.06 | -0.12 | -0.14 | -0.08 | -0.03 | -0.11 | -0.35 | 0.00 | 1.00 | | | | | | | | | | | | | | | |
| Pr. den | 0.01 | -0.04 | -0.04 | -0.06 | -0.07 | -0.03 | -0.02 | -0.76 | 0.01 | 1.00 | | | | | | | | | | | | | | |
| R. větru | 0.10 | -0.41 | -0.36 | -0.26 | -0.23 | -0.30 | -0.11 | 0.00 | -0.08 | -0.04 | 1.00 | | | | | | | | | | | | | |
| Vlhkost | 0.13 | 0.09 | 0.13 | 0.26 | 0.25 | 0.24 | 0.14 | 0.02 | 0.11 | 0.00 | -0.05 | 1.00 | | | | | | | | | | | | |
| Tlak | 0.14 | 0.30 | 0.31 | 0.28 | 0.22 | 0.34 | -0.03 | -0.02 | 0.03 | 0.03 | -0.33 | -0.03 | 1.00 | | | | | | | | | | | |
| Sl. svit | -0.14 | 0.15 | 0.07 | -0.13 | -0.10 | -0.12 | 0.00 | -0.02 | -0.10 | -0.02 | -0.27 | -0.68 | 0.17 | 1.00 | | | | | | | | | | |
| Teplota | -0.28 | -0.21 | -0.36 | -0.48 | -0.36 | -0.53 | -0.09 | 0.02 | 0.01 | 0.00 | -0.10 | -0.44 | -0.25 | 0.45 | 1.00 | | | | | | | | | |
| S. větru | 0.33 | -0.44 | -0.39 | -0.14 | -0.15 | -0.13 | -0.13 | 0.03 | 0.02 | -0.02 | 0.49 | 0.18 | -0.18 | -0.33 | -0.02 | 1.00 | | | | | | | | |
| O ₃ -1 | -0.03 | -0.18 | -0.23 | -0.34 | -0.33 | -0.28 | -0.02 | -0.02 | -0.20 | -0.01 | 0.04 | -0.43 | -0.22 | 0.33 | 0.46 | 0.03 | 1.00 | | | | | | | |
| O ₃ -2 | -0.02 | -0.18 | -0.23 | -0.31 | -0.32 | -0.24 | -0.01 | 0.02 | -0.21 | -0.02 | 0.04 | -0.39 | -0.20 | 0.30 | 0.44 | 0.08 | 0.76 | 1.00 | | | | | | |
| O ₃ -3 | -0.04 | -0.17 | -0.21 | -0.28 | -0.30 | -0.21 | -0.01 | 0.05 | -0.21 | -0.03 | 0.05 | -0.35 | -0.21 | 0.28 | 0.43 | 0.08 | 0.64 | 0.76 | 1.00 | | | | | |
| O ₃ -4 | -0.02 | -0.13 | -0.17 | -0.27 | -0.29 | -0.21 | 0.02 | 0.02 | -0.22 | -0.01 | 0.03 | -0.38 | -0.22 | 0.29 | 0.44 | 0.06 | 0.59 | 0.62 | 0.76 | 1.00 | | | | |
| O ₃ -5 | -0.03 | -0.12 | -0.16 | -0.28 | -0.31 | -0.21 | 0.01 | 0.00 | -0.21 | 0.04 | 0.05 | -0.44 | -0.24 | 0.32 | 0.45 | 0.04 | 0.55 | 0.59 | 0.63 | 0.76 | 1.00 | | | |
| O ₃ -6 | -0.07 | -0.12 | -0.17 | -0.36 | -0.40 | -0.27 | -0.01 | -0.04 | -0.20 | 0.05 | 0.15 | -0.52 | -0.27 | 0.37 | 0.48 | 0.03 | 0.54 | 0.55 | 0.58 | 0.62 | 0.76 | 1.00 | | |
| O ₃ | -0.07 | -0.10 | -0.14 | -0.47 | -0.49 | -0.40 | -0.04 | -0.04 | -0.20 | 0.01 | 0.14 | -0.67 | -0.26 | 0.57 | 0.51 | -0.08 | 0.58 | 0.55 | 0.55 | 0.57 | 0.63 | 0.75 | 1.00 | |


Příloha C: Normalizované hodnoty naměřeného oxidu siřičitého. Zdroj [vlastní]




Příloha D: Normalizované hodnoty naměřených prachových částic menších než 10 µm. Zdroj [vlastní]




Příloha E: Normalizované hodnoty naměřeného oxidu dusíku. Zdroj [vlastní]




Příloha F: Normalizované hodnoty naměřeného oxidu uhelnatého. Zdroj [vlastní]




Příloha G: Normalizované hodnoty naměřené vlhkosti. Zdroj [vlastní]



Příloha H: Normalizované hodnoty naměřené teploty. Zdroj [vlastní]



Příloha I: Normalizované hodnoty naměřeného ozónu. Zdroj [vlastní]



Příloha J: Výsledky navržených dopředných NS při poměru rozdělení dat 50:50. Zdroj [vlastní]

| Model | μ | η | Trénovací množina | | Testovací množina | |
|---------------|------------|------------|-------------------|----------------|-------------------|----------------|
| | | | MSE | RMSE | MSE | RMSE |
| 13-12-1 | 0.5 | 0.2 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-10-1 | 0.5 | 0.2 | 0.97898 | 0.98943 | 0.06849 | 0.26171 |
| 13-8-1 | 0.5 | 0.2 | 0.94960 | 0.97447 | 0.05463 | 0.23373 |
| 13-6-1 | 0.5 | 0.2 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-5-1 | 0.8 | 0.4 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-5-1 | 0.8 | 0.3 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-5-1 | 0.8 | 0.2 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-5-1 | 0.8 | 0.1 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-5-1 | 0.8 | 0.05 | 0.95836 | 0.97896 | 0.06201 | 0.24902 |
| 13-5-1 | 0.5 | 0.4 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-5-1 | 0.5 | 0.3 | 0.94282 | 0.97099 | 0.04340 | 0.20833 |
| 13-5-1 | 0.5 | 0.2 | 0.94463 | 0.97192 | 0.05450 | 0.23345 |
| 13-5-1 | 0.5 | 0.1 | 0.92415 | 0.96133 | 0.03482 | 0.18660 |
| 13-5-1 | 0.5 | 0.05 | 0.85624 | 0.92533 | 0.06003 | 0.24501 |
| 13-5-1 | 0.2 | 0.4 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-5-1 | 0.2 | 0.3 | 0.94902 | 0.97418 | 0.05389 | 0.23214 |
| 13-5-1 | 0.2 | 0.2 | 0.95112 | 0.97525 | 0.03379 | 0.18382 |
| 13-5-1 | 0.2 | 0.1 | 0.92775 | 0.96320 | 0.05878 | 0.24245 |
| 13-5-1 | 0.2 | 0.05 | 0.85118 | 0.92259 | 0.06530 | 0.25554 |
| 13-4-1 | 0.5 | 0.2 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-3-1 | 0.5 | 0.2 | 0.98825 | 0.99411 | 0.04061 | 0.20152 |

Příloha K: Výsledky navržených dopředných NS při poměru rozdělení dat 60:40. Zdroj [vlastní]

| Model | μ | η | Trénovací množina | | Testovací množina | |
|---------------|------------|------------|-------------------|----------------|-------------------|----------------|
| | | | MSE | RMSE | MSE | RMSE |
| 13-12-1 | 0.5 | 0.2 | 1.39444 | 1.18086 | 0.04815 | 0.21954 |
| 13-10-1 | 0.5 | 0.2 | 1.51481 | 1.23078 | 0.04500 | 0.21213 |
| 13-8-1 | 0.5 | 0.2 | 1.38799 | 1.17813 | 0.04809 | 0.21932 |
| 13-6-1 | 0.5 | 0.2 | 1.51481 | 1.23078 | 0.04500 | 0.21213 |
| 13-5-1 | 0.5 | 0.4 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-5-1 | 0.5 | 0.3 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-5-1 | 0.5 | 0.2 | 1.51481 | 1.23078 | 0.04500 | 0.21213 |
| 13-5-1 | 0.5 | 0.1 | 1.03904 | 1.01933 | 0.04460 | 0.21119 |
| 13-5-1 | 0.5 | 0.05 | 0.85624 | 0.92533 | 0.06004 | 0.24495 |
| 13-4-1 | 0.5 | 0.2 | 1.51481 | 1.23078 | 0.04500 | 0.21213 |
| 13-3-1 | 0.5 | 0.2 | 1.51481 | 1.23078 | 0.04500 | 0.21213 |

Příloha L: Výsledky navržených frontálních neuronových sítí. Zdroj [vlastní]

| Model | Délka filtru | Trénovací množina | | Testovací množina | |
|---------------|--------------|-------------------|----------------|-------------------|----------------|
| | | MSE | RMSE | MSE | RMSE |
| 13-12-1 | 2 | 0.71007 | 0.84266 | 0.21664 | 0.46545 |
| 13-11-1 | 3 | 0.70765 | 0.84122 | 0.18897 | 0.43471 |
| 13-10-1 | 4 | 0.70308 | 0.83850 | 0.19268 | 0.43895 |
| 13-9-1 | 5 | 0.70613 | 0.84032 | 0.20817 | 0.45626 |
| 13-8-1 | 6 | 0.72691 | 0.85259 | 0.18676 | 0.43216 |
| 13-7-1 | 7 | 0.70298 | 0.83844 | 0.21882 | 0.46778 |
| 13-6-1 | 8 | 0.69569 | 0.83408 | 0.20925 | 0.45744 |
| 13-5-1 | 9 | 0.69678 | 0.83473 | 0.19801 | 0.44498 |
| 13-4-1 | 10 | 0.67511 | 0.82165 | 0.21146 | 0.45985 |
| 13-3-1 | 11 | 0.70501 | 0.83965 | 0.23569 | 0.48548 |