

Detekce a rozpoznávání znaků registrační značky s využitím neuronové sítě

Detection and Recognition of License Plate Characters Using
Neural Network

Bc. Jaromír Seidl

Diplomová práce
2012

 Univerzita Tomáše Bati ve Zlíně
Fakulta aplikované informatiky

Univerzita Tomáše Bati ve Zlíně
Fakulta aplikované informatiky
akademický rok: 2011/2012

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Jaromír SEIDL**
Osobní číslo: **A10338**
Studijní program: **N 3902 Inženýrská informatika**
Studijní obor: **Bezpečnostní technologie, systémy a management**

Téma práce: **Detekce a rozpoznání znaků registrační značky s využitím neuronové sítě**

Zásady pro vypracování:

1. Popište typy a principy činnosti obrazových snímačů.
2. Popište kroky při předzpracování získané obrazové informace (filtrace, morfologická analýza, analýza histogramu).
3. Vysvětlete funkci a princip OCR.
4. Navrhnete možné řešení rozpoznávání znaků na registračních značkách automobilů.
5. Návrh aplikujte na automatické čtení a ukládání značek při vjezdu do objektu.

Rozsah diplomové práce:

Rozsah příloh:

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

Seznam odborné literatury:

1. ZELINKA, Ivan, Zuzana OPLATKOVÁ a Roman ŠENKEŘÍK. Aplikace umělé inteligence. Zlín: Univerzita Tomáše Bati ve Zlíně, 2010. 151 s. ISBN 978-80-7318-898-6.
2. MAŘÍK, Vladimír. Umělá inteligence. 1. vyd. Praha: Academia, 2007, 544 s. ISBN 978-802-0014-702.
3. OLEJ, Vladimír a Petr HÁJEK. Úvod do umělé inteligence: klasická umělá inteligence : distanční opora. Vyd. 1. Pardubice: Univerzita Pardubice, 2009, 112 s. ISBN 978-807-3952-419.
4. BÍLA, J. Umělá inteligence a neuronové sítě v aplikacích. Vyd. 1. Praha: Vydavatelství ČVUT, 1998, 115 s. ISBN 80-010-1275-1.
5. POKORNÝ, Miroslav. Umělá inteligence v modelování a řízení. Vyd. 1. Praha: BEN, 1996, 188 s. ISBN 80-901-9844-9.
6. ŠIMA, Jiří a Jan NERUDA. Teoretické otázky neuronových sítí. 1996. Prague: MATFYZPRESS, 1996. ISBN 80-85863-18-9. Dostupné z: <http://www2.cs.cas.cz/sima/kniha.html>.

Vedoucí diplomové práce:

Ing. Petr Skočík

Ústav elektroniky a měření

Datum zadání diplomové práce:

24. února 2012

Termín odevzdání diplomové práce:

15. května 2012

Ve Zlíně dne 24. února 2012

prof. Ing. Vladimír Vašek, CSc.
děkan



doc. RNDr. Vojtěch Křesálek, CSc.
ředitel ústavu

ABSTRAKT

Abstrakt česky

Téma diplomové práce pojednává o problematice zaměřené k detekci a rozpoznávání registračních značek automobilů, zachycených na snímku, které jsou zaznamenány prostřednictvím snímacího zařízení na parkovišti.

Práce je rozdělená do dvou základních částí. Teoretická část se zabývá vyhledáváním registrační značky v obraze na základě neuronové sítě. Praktická část se zabývá návrhem řešení a postupem pro rozpoznání registrační značky. Řešení je postaveno na základě předzpracovaného obrazu, segmentace regionů a optickém rozpoznávání obrazu. Digitální obraz, který byl identifikován, rozpoznán, vykreslen je následně přenesen a uložen do databáze.

Klíčová slova:

Detekce registračních značek, OCR, segmentace, zpracování obrazu, neuronová síť

ABSTRACT

Abstrakt ve světovém jazyce

Thesis is aimed on car license plate recognition and detection, capturing images through a scanning device in the car park. Work is divided to two basic parts. Theoretical part is aimed on searching car licence plate in view based on neural network. Practical part is aimed on solution design and procedure for license plate recognition. The solution is based on the pre-processed image, region segmentation and optical view recognition. Digital view is subsequently transferred and stored into the database based on identification and recognition.

Keywords:

Car license plate recognition, Optical Character Recognition, segmentation, image processing, neural network

Poděkování, motto

Poděkování patří Ing. Petrovi Skočíkovi – vedoucímu diplomové práce, za odborné vedení, rady a pozornost, která byla věnována při zpracování diplomové práce.

Při vypracování diplomové práce náleží poděkovat i blízkým osobám, kteří se podíleli, jakoukoliv mírou a schopnosti psychické podpory.

„Kdo chce stavět vysoké věže, musí se dlouho věnovat základům.“

Prohlašuji, že

- beru na vědomí, že odevzdáním diplomové/bakalářské práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb. o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších právních předpisů, bez ohledu na výsledek obhajoby;
- beru na vědomí, že diplomová/bakalářská práce bude uložena v elektronické podobě v univerzitním informačním systému dostupná k prezenčnímu nahlédnutí, že jeden výtisk diplomové/bakalářské práce bude uložen v příruční knihovně Fakulty aplikované informatiky Univerzity Tomáše Bati ve Zlíně a jeden výtisk bude uložen u vedoucího práce;
- byl/a jsem seznámen/a s tím, že na moji diplomovou/bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3;
- beru na vědomí, že podle § 60 odst. 1 autorského zákona má UTB ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- beru na vědomí, že podle § 60 odst. 2 a 3 autorského zákona mohu užít své dílo – diplomovou/bakalářskou práci nebo poskytnout licenci k jejímu využití jen s předchozím písemným souhlasem Univerzity Tomáše Bati ve Zlíně, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše);
- beru na vědomí, že pokud bylo k vypracování diplomové/bakalářské práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tedy pouze k nekomerčnímu využití), nelze výsledky diplomové/bakalářské práce využít ke komerčním účelům;
- beru na vědomí, že pokud je výstupem diplomové/bakalářské práce jakýkoliv softwarový produkt, považují se za součást práce rovněž i zdrojové kódy, popř. soubory, ze kterých se projekt skládá. Neodevzdání této součásti může být důvodem k neobhájení práce.

Prohlašuji,

- že jsem na diplomové práci pracoval samostatně a použitou literaturu jsem citoval. V případě publikace výsledků budu uveden jako spoluautor.
- že odevzdaná verze diplomové práce a verze elektronická nahraná do IS/STAG jsou totožné.

Ve Zlíně

.....
podpis diplomanta

OBSAH

ÚVOD	9
I TEORETICKÁ ČÁST	10
1 PROBLEMATIKA	11
1.1 PROBLEMATIKA RZ V REÁLNÉM PROSTŘEDÍ	11
1.2 PŘÍZNAKY PŘEDCHÁZEJÍCÍ DANÝ PROBLÉM.....	12
2 OBRAZOVÝ SNÍMAČ	14
2.1 TYPY OBRAZOVÝCH SNÍMAČŮ	14
2.2 TECHNOLOGIE OBRAZOVÝCH SNÍMAČŮ	15
2.2.1 Technologie CCD snímače	15
2.2.2 Technologie CMOS snímače	16
2.3 PRINCIP OBRAZOVÉ SNÍMAČE CCD	16
2.3.1 Implantované čočky na povrchu snímače CCD	17
2.3.2 RGB (Red, Green, Blue)	18
2.3.3 Expoziční doba.....	18
2.3.4 Důležité parametry pro citlivé CCD snímače	19
3 PŘEDZPRACOVÁNÍ OBRAZU	21
3.1 MORFOLOGICKÁ ANALÝZA (OPERACE).....	21
3.1.1 Dilatace	21
3.1.2 Eroze (Erosion)	22
3.1.3 Uzavření (Closing) a otevření (Opening).....	22
3.2 ODSÍN ŠEDÉ	22
3.2.1 Histogram	23
4 SEGMENTACE OBRAZU	24
4.1 DETEKCE HRAN	24
4.2 PRAHOVÁNÍ.....	24
4.2.1 SIS metoda	25
5 ROZPOZNÁVÁNÍ ČÍSLIC A PÍSMEN	26
5.1 NORMALIZACE	26
5.2 ZÁKLADNÍ ROZDĚLENÍ RZ.....	26
5.2.1 Administrativní RZ v ČR a krajské kódy.....	29
5.2.2 Rozdělení RZ v ČR podle krajů	29
6 NEURONOVÁ SÍŤ - NN	31
6.1 HISTORIE NEURONOVÝCH SÍTÍ	31
6.2 TEORIE NN.....	32
6.2.1 PC x Lidský mozek	35
6.2.2 NN x PC	35
6.3 FUNKCE -PRINCIP	37
6.4 SYNAPSE	37
6.4.1 Princip, funkce synapse.....	38
6.4.2 Využití neuronových sítí	39

6.5	PERCEPTRON	41
6.5.1	Přenosová funkce:	41
6.6	HOPFIELDOVÁ SÍŤ	43
6.6.1	Příklad – Hopfieldovi síť	43
6.7	KOHONENOVÁ SÍŤ	44
6.7.1	Struktura Kohonenovy síť.....	44
6.7.2	Adaptační funkce	45
6.8	PROBLEMATIKA NEURONOVÝCH SÍŤÍ.....	46
6.9	SOFTWAREVÉ PROSTŘEDÍ PRO TVORBU NEURONOVÝCH SÍŤÍ	46
6.9.1	Matlab Neural Network Toolbox	46
6.9.2	Práce v NN-Tolboxu	47
6.9.3	STATISTIKA Neuronové síť	50
7	OPTICKÉ ROZPOZNÁVÁNÍ ZNAKŮ – OCR	51
II	PRAKTICKÁ ČÁST	53
8	NAVRHNĚTE MOŽNÉ ŘEŠENÍ ROZPOZNÁVÁNÍ ZNAKŮ NA REGISTRAČNÍCH ZNAČKÁCH AUTOMOBILŮ	55
8.1	ZÁKLADNÍ PROBLÉMY PŘI IDENTIFIKACI	56
8.2	PŘEDPOKLADY	56
8.3	KONCEPT REALIZACE RZ NA PARKOVIŠTI	56
8.4	VÝVOJOVÝ DIAGRAM VOZIDEL URČENÉ K IDENTIFIKACI RZ.....	58
9	NÁVRH APLIKACE NA AUTOMATICKÉ ČTENÍ A UKLÁDÁNÍ ZNAČEK PŘI VJEZDU DO OBJEKTU.....	60
9.1	INTEGRACE DATABÁZE.....	60
9.1.1	Naplnění Tabulek	63
9.2	DETEKCE RZ POMOCI HOPFIELDOVÉ SÍŤE	65
9.3	INTERAKTIVNÍ SIMULÁTOR NEURONOVÝCH SÍŤÍ - ISNS.....	65
9.3.1	Typy dat, komprese	71
9.3.2	Ukázková tabulka databáze v integraci s OCR – implementace:	72
	ZHODNOCENÍ.....	76
	ZÁVĚR	78
	ZÁVĚR V ANGLIČTINĚ.....	79
	SEZNAM POUŽITÉ LITERATURY.....	80
	SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK.....	83
	SEZNAM OBRÁZKŮ	84
	SEZNAM TABULEK.....	87
	SEZNAM PŘÍLOH.....	88

ÚVOD

Dnešní doba přináší, resp. nabízí neskutečné množství řešení při zaznamenání obrazů pořízené z bezpečnostních kamer. Na bezpečnostní kamery (CCTV – sledovací kamerový systém) lze narazit, v kterémkoliv odvětví. Obyčejně tam, kde se setkáme se sledovacím kamerovým systémem bude oblast doprava a okolní integrita (kontrola vjezdu a výjezdu z objektu, kontrola rychlosti na pozemních komunikacích, popř. integrace s městskými radary).

CCTV tvoří podstatnou část záznamového videa nebo digitálního obrazu, která je nezbytně nutná jako důkazová část pro majitele osobních automobilů, nákladních vozů či silničních motocyklů, kteří porušili pravidla silničního provozu (např. povolená rychlosti, zákaz vjezdu do objektu, projetí křižovatkou na červenou, nedání přednosti v jízdě). Všechny tyto úkony mohou způsobit vážnou dopravní nehodu na úkor právě nedodržení silničního provozu.

Prostřednictvím bezpečnostních kamer, které nabízí pomoc při odhalení pachatele u závažného činu (např. při krádeži, vloupání či odcizení cizích předmětů) stále narůstá. V návaznosti na daný problém se nabalují i jiné možnosti využití bezpečnostních kamer, které vždy nemusí být umístěny pouze ve vnitřním prostředí, nýbrž mohou celé situaci předcházet už ze strany vnější.

V minulosti při zpracování BP jsem se zabýval problematikou a návrhem zabezpečovacích systémů stacionárních parkovišť. Na předcházející BP navážu, na konkrétním prvku ohledně zpracování obrazu a identifikaci registrační značky na principu umělé neuronové sítě OCR (Optical Character Recognition). Statické snímky pořízené záběrem CCTV se stanou základním prvkem, zdrojem pro jednotlivé rozpoznávání znaků na registračních značkách. Cílem této práce bude návrh řešení optického rozpoznávání znaků a aplikace na automatické čtení a ukládání značek do databáze při vjezdu do objektu.

I. TEORETICKÁ ČÁST

1 PROBLEMATIKA

1.1 Problematika RZ v reálném prostředí

V této části kapitoly a zcela především v celé diplomové práci si musíme definovat základní problém, který poukazuje na počáteční nedostatky při řešení procesu identifikaci RZ. Nejčastější využití k detekci a identifikaci registrační značky nalezneme ve dvou základních kategoriích. Kde na něj narazíme?

První kategorie, kde zcela jistě narazíme na detekci RZ bude při měření rychlosti na silničních komunikacích. Pro identifikaci registrační značky na základě měření rychlosti je nezbytně nutné použít stacionární radary neboli pevné radary (Obr. 1.). Druhým typem, jaký lze radar využít pro změření rychlosti a následně vyhodnocení dopravního přestupku je radar mobilní - přenosný radar tzv. ruční, umístěný na vozidlech. Třetím typem a často využívaným radarem jsou radary pro úsekové měření, např. ve městě Zlín (Obr. 2). Úsekové měření se zakládá na dvou kamerách umístěné za sebou, které po zachycení snímku vozidla vyhodnotí čas průjezdu vozidla mezi dvěma body a na základě této doby průjezdnosti dojde ke stanovení rychlosti vozidla ve stanoveném úseku. Radary, kterými Policie ČR (obecní policie, vojenská policie) disponuje, musí odpovídat zákonu č. 505/1990 SB., o metrologii a jeho prováděcím vyhláškám.



Obr. 1. Stacionární radary



Obr. 2. Úsekové radary

Navíc radary musí být v pravidelných časových obdobích kalibrovány a mít platné typové schválení. Velice problematickou otázkou u radaru se poukazuje na povolenou odchylku pro průjezd obcí a jeho povolené rychlosti. Dle dopravních předpisů známe, že povolenou rychlosti pro obec ČR je 50km/h. Odchylka je stanovena pro strážníky dopravní policie $\pm 3\text{km/h}$ (tzn. 53km/h). Z toho nám vyplývá, že dopravní přestupek způsobíme za překročení rychlosti přesahující 53 km/h. Na základě překročení rychlosti se detekce registrační značky (digitální fotografie) ukládá do databáze, které překročili povolenou

dovolenou rychlost. Kromě rychlosti zobrazuje i směr jízdy, datum a čas měření. Na totožném principu, pracují i ostatní radary. Úhel mezi kamerou a registrační značkou může být $\pm 30^\circ$. V reálném čase výsledná rozpoznaná značka vozidla je bezprostředně k dispozici do 1sec. [12]

Druhou kategorií, která je podstatným tématem diplomové práce nazývám detekci a identifikaci registrační značky určené při vjezdu a výjezdu na parkoviště. Snímaná scéna před vjezdem na parkoviště je nedílnou součástí problematického celku, tudíž lokalizace RZ ve snímku je o něco jednodušší. Oproti první části, kde jsme řešili stacionární radary a snímání RZ při plné rychlosti je nyní lokalizace trochu odlišná. V této pozici automobil (osobní vůz) přijíždí přímo před hlavní část parkoviště (na předepsané místo před závoru), kde nezbytně nutně potřebujeme k vjezdu do areálu mít povolení (abonentní karta, identifikační karta, popř. detekci RZ která ji následně vyhodnotí a umožní vjezd do objektu). Polohu mohou ještě zpřesnit detektory zabudována přímo v zemi. Důsledkem, nebo základním rozdílem je ten, že zde osobní vůz má nulovou rychlost, tudíž snímání, detekce, identifikace pořizovacího snímku není nikterak tak složitá, jako u pojižděcích vozidel. Zcela určitě, lze předpokládat, že RZ bude mít obrys obdélníku, jehož strany jsou takřka rovnoběžné s osami obrázku.

1.2 Příznaky předcházející daný problém

Obecně lze říci, že rozměr registrační značky nemusí být vždy stejně velký a rovněž nemusí obsahovat tvar obdélníku nebo čtverce. Podrobnější rozdělení RZ podle užití rozebereme v kapitole č. 5. Důležitým faktorem pro danou lokalizaci RZ je nejen velikost, ale i vzdálenost fotografie po kterých byla segmentována RZ. Tento postup bude dále rozebrán v kapitole „SEGMENTACE OBRAZU“.

Prvkem, který výrazně snižuje výkonnost celého systému, nastává za předpokladu zhoršení světelných podmínek. Objasnění celé situace spočívá v tom, že za nepříznivé světelných podmínek mohou být vržený stíny, nejrušnější odlesky (blesk fotoaparátu, zapadající slunce, osvětlení vozidla a jiné povětrnostní podmínky). Řidiči se často dokážou bránit a to tím, že využívají nelegálních přípravků, které jsou na tolik dokonalé, že dokážou vykazat vysokou odrazivost. Následně RZ je zcela kompletně nečitelná. Při využití přisvícení bleskem nastává zlepšení obrazu. V problematice v reálném prostředí bylo poukázáno na stacionární radary. Zde je nutné si uvědomit, že kromě statických scén fotografií jsou zde

i další (např. pořízené z mobilních radarů), kde musíme brát v úvahu, že budou i některé rozmazané.

V úvahu musíme taky předpovídat a to zcela dle logického úsudku, že registrační značka není vždy úplně čistá (bláto, popř. součástky typu šrouby apod.). Součásti RZ bývají i samolepky (např. EU, STK).

Z těchto několika různých příčin, které nabývají danou platnost problematiky je zcela zřejmé, že k vytvoření univerzálního systému (jednotného systému) pro více států dohromady je to víceméně složitá záležitost.



Obr. 3. Zaprášená RZ


2 OBRAZOVÝ SNÍMAČ

Obrazový snímač je nedílnou součástí bezpečnosti kamery, kterou zodpovídá za převod světla do elektrických signálů. Při konstrukci neboli realizaci bezpečnostní kamery bývá zejména podstatný návrh, kde se rozhoduje výběrem ze dvou technologií obrazových snímačů. V praxi se setkáváme s CCD nebo CMOS snímači. [21]

- **CCD** - Charged Coupled Device
- **CMOS** - Complementary Metal Oxide Semiconductor

2.1 Typy obrazových snímačů

Obrazový snímač tvoří základní ne-li dokonce podstatnou část bezpečnostní kamery. Rozeznáváme základní typ snímačů CCD a CMOS, které mají funkci podobnou jako digitální film u analogového fotoaparátu. Pro bezpečnostní kamery v oblasti ochrany osob, identifikace osob, střežení objektu, střežení vjezdů i výjezdu z průmyslového areálu či objektu jsou navrženy prostřednictvím speciálních technologií, kde nacházejí uplatnění především CCD snímače. Naopak CMOS snímače využívají určitého standartu při výrobě, která se využijí k výrobě paměťových čipů, jenž je součástí PC. V současnosti, co dnešní doba nabízí, jsou daleko více upřednostňovány CCD snímače než CMOS snímače. Za připomenutí stojí říci, že CMOS snímače svou kvalitou obrazu dohánění CCD snímače, ovšem i přes tento posun ke zlepšení dokonalosti snímače, nejsou stále vhodné pro bezpečnostní průmysl, kde by našli uplatnění.



Obr. 4. Základní koncepce bezpečnostní kamery obsahující snímač [21]

V porovnání těchto snímačů může rozhodovat kvalita, cena nebo výkon - kvalita obrazu. Nižší cenu v kategorii bezpečnostních kamer pochopitelně nalezneme u kamer obsahující snímač CMOS. Například využití s CMOS snímačem zcela jistě najde uplatnění u základní řady síťových kamer, při nichž kvalita a velikost obrazu k vůči přenosu dat do úložiště databáze nebude dostatečně odpovídající. V případě problematiky u identifikace RZ bych z vlastního hlediska zcela evidentně využil CCD snímač pro konstrukci bezpečnostní kamery. [21]

2.2 Technologie obrazových snímačů

Definice: **Jak funguje snímač?**

„Snímač je soustava do pravoúhlé mřížky uspořádaných fotobuněk. Jednotlivé buňky přeměňují dopadající světlo na elektrický náboj, který se převádí v A/D převodníku na digitální záznam. Buňky reagují pouze na intenzitu světla a nerozeznávají jeho barvu. Proto se před sousední buňky dávají tři různě barevné filtry. Každá z nich pak "vidí" pouze jednu složku barevného spektra a výsledná barva bodu se dopočítá (interpoluje) za pomoci údajů z okolních buněk. Pro zesílení světla se často nad filtry umisťují ještě malé čočky“.[23]

2.2.1 Technologie CCD snímače

V části technologie CCD snímače si rozebereme senzor dle technických parametrů. K výhodám snímače s využitím koncepce CCD se přikládá zejména světelná citlivost (Lux). Pro zobrazující kvalitu obrazu potřebujeme takový snímač, který vylepší a zaručí svou světelnou citlivostí i tak nedokonale nasvícený, nasvětlený obraz popř. registrační značku. Problémem při špatném osvětlení mohou být především povětrnostní podmínky snůh, mlha, déšť apod. Z tohoto úsudku a podle popisu parametrů, právě CCD snímač splňuje určité kritéria, které napomůžou k správné identifikaci RZ.




Obr. 5. CCD snímač [21]

Nevýhody převládají spíše v cenové relaci, kde při zabudování snímače do kamery bývá složitějším technologickým procesem. Po technické stránce nastává problém tehdy, když se v záběru zobrazí velmi světlý objekt (způsobené slunečním zářením, ostrým osvětlením, vyzařováním), poté snímač se snímač neúplně rozteče, jehož důsledkem jsou třeba pruhy zobrazené v objektu. Odborně nazývaná taky skvrna (smear). [21]

2.2.2 Technologie CMOS snímače

V úvodní části kapitoly technologii obrazových snímačů byl upřesněn vývoj CMOS snímače, v porovnání s druhým typem snímačů CCD. CMOS snímače nemají dostatečnou kvalitu pro zobrazující obraz pořízený z bezpečnostní kamery. Výhodou je cenová kvóta (relace), kde „velké snímače“ využívají hlavně v několika MPX rozlišení pro IP kamery, dále jednoduchá konstrukce, s nichž jsou spojeny nízké náklady na výrobu. Oproti CCD snímačů mohou dosáhnout až k 100 Mpx (snímky v HD rozlišení) při nichž budou mít nižší spotřebu energie. Z technického směru, zde poukazuje na hlavní nevýhodu špatná citlivost. Výsledkem špatného osvětlení nastane tmavý obraz, v němž se vykreslí tzv. plný šum. Plný šum, bude rozebrán v následujících kapitolách, popisující detekci registrační značky. [21]

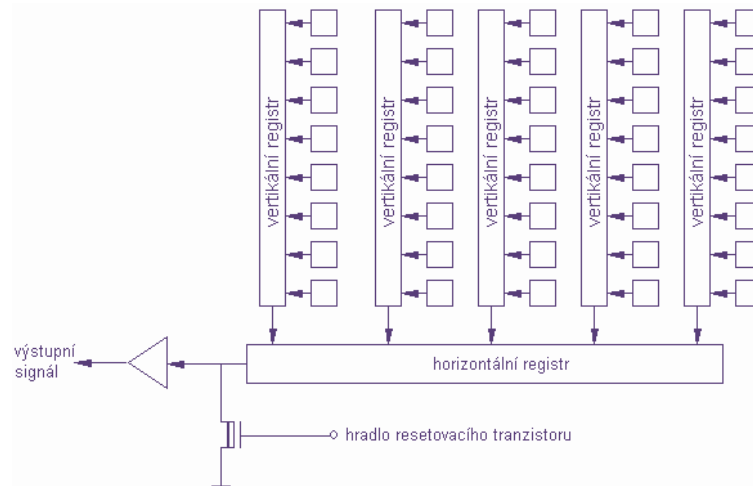


Obr. 6. CMOS snímač [21]

2.3 Princip obrazové snímače CCD

Konstrukce CCD snímač se skládá z několika elementárních snímacích prvků (řádově μm). Snímací prvky nepatrné velikosti bývají označovány aktivním fotoelektrickým jevem. U prvků při nichž se převádí energii fotonů na elektrický náboj, vzniká přímá úměra v závislosti na intenzitě dopadajícího světla (doba svitu – expoziční doba). Posléze je nutné náboj zpracovat. Ke zpracovávání nábojů využíváme implementované analogové bloky. Bloky se skládají z horizontálních a vertikálních paměťových registrů, dále operační zesilovač, resetovací tranzistor a další už méně podstatné součástky. Po ukončení expoziční doby se do paměťových registrů přenáší skrytý obraz (v praxi označován


latentní), který se dále posouvá k převodníku elektrického náboje na napětí. V konečné části fotoelektrického jevu na výstupu převodníku je napěťová úroveň zesilována, dále už pokračuje na analogový výstup daného snímače (čipu).



Obr. 7. Blokové schéma CCD snímače [22]

2.3.1 Implantované čočky na povrchu snímače CCD

Za připomenutí lze připomenout, že potřebujeme zabránit ztrátám předcházející detekci světla způsobené neregistrovanými fotony, které dopadají na zastíněné plošky. Tak aby se předešlo ke ztrátě detekci světla, implementujeme na povrch CCD snímače miniaturní čočky (viz. Obr. 8.). Čočky mají za funkci částečného lámaného světla, které jsou přeměřovány pouze do citlivé části.



Obr. 8. Implantované čočky na povrchu CCD snímače [22]

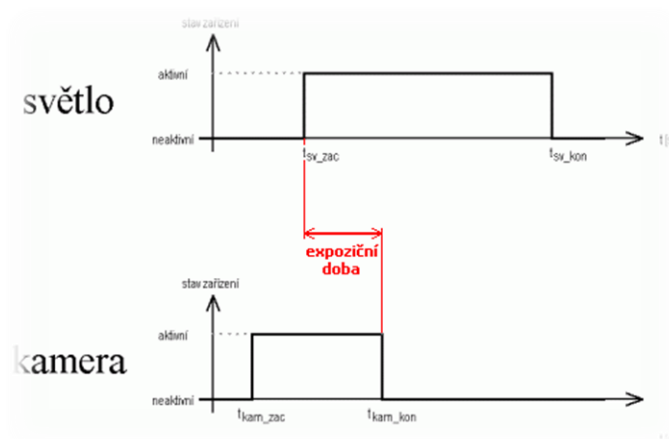
V současné době při vývoji nejnovějších aplikací, systému na úkor infromatickému růstu, tak i v oblasti bezpečnostních sledovacích zařízení (CCTV) potřebujeme kvalitně, efektivně a zejména barevně snímat obraz. Oproti klasickému snímači CCD je potřebné doplnit snímač o barevné filtry (RGB). Tyto filtry propouští pouze určitou barvu, tudíž jsou ve spektru rozloženy do tří barev (R – red, G – green, B – blue), které přičemž zpětně skládání původní obraz.

2.3.2 RGB (Red, Green, Blue)

- Tradiční kombinace (R – red, G – green, B – blue) má určitou nevýhodu ve filtru, kde každá barva pokrývá jen 1/3 světelného spektra => pouze 1/3 energie světla prochází
- Výhodou je jednoduchá výroba a dokonalé barevné podání opětovně složeného obrazu

2.3.3 Expoziční doba

Expozice je podána kombinací expoziční doby kamery, intenzitou světla a doby záblesku světla, která může být konstantní nebo proměnná. Objekty charakteristické přibližně stejnými světelnými vlastnostmi mohou být snímány kamerou s konstantní expoziční dobou a použitím zdroje světla s konstantní intenzitou záření (v případě nepřetržitého osvětlení) nebo ještě navíc se stálou dobou záblesku. [22]




Obr. 9. Expoziční doba [22]

2.3.4 Důležité parametry pro citlivé CCD snímače

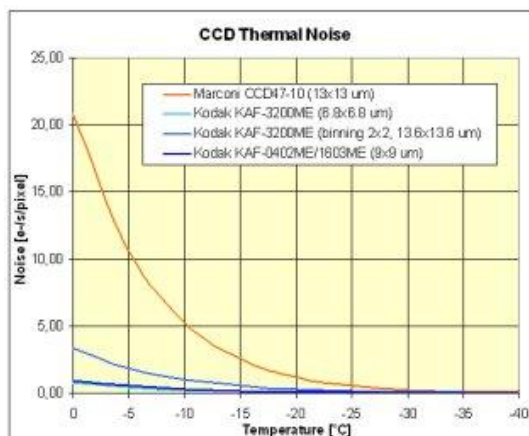
V první části kapitoly „technologie obrazových snímačů“ bylo poukázáno na jednotlivé rozlišení snímačů v Mpx (počet pixelů) pro IP kamery. Docela pochopitelně nemusí být rozlišení až tak podstatné, nýbrž uplatnění CCD snímače se využije i na základě dalších parametrů [24]:

- **Účinnost EQ [%]** - vyjadřuje schopnost cíle zachytit, vyčerpat a zužitkovat energii dopadajícího světla



Obr. 10. Účinnost (EQ) CCD snímače v závislosti na vlnové délce [24]

- **Temný proud (Dark Current) [počet elektronů za sekundu na pixel - e/s/px]**
- udává změnu náboje v potenciálové jámě pixelů vlivem úniku elektronů



Obr. 11. Závislost temného proudu na CCD snímač [24]

- **Čtecí šum CCD snímače (Read noise) [průměrný počet elektronů - e RMS]**
 - vyjadřuje s jakou přesností lze náboj z pixelů vyčíst
- **A/D převodník - počet bitů převodníku [bity]**
 - udává, na jaký počet úrovní kvantuje úroveň nábojů

U klasických, běžných obrazových snímačů CCD využívané v oblasti zabezpečovacích zařízeních patří tyto důležité prvky:

- Průběh záznamu obrazu za určitou kvalitu scény v daném rozlišení (Mpx)
- Rychlost zpracování / ukládání snímku do databáze
- Zmíněnou světelnou citlivost
- Kvantová účinnost snímač

3 PŘEDZPRACOVÁNÍ OBRAZU

Otázkou, proč se provádí předzpracování obrazu, může být zcela jednoduchá. Základním obrazem se nazývá obraz zdrojový, který je nutný získat pro následnou analýzu a další zpracování. Dalším faktorem bývá, pro jakou aplikaci má být předzpracovaný obraz připraven a zcela nutné je prvotní potlačení šumu a zkreslení vzniklého digitálního obrazu. Cílem může být převod na binární obraz, detekce hran, extrakce barevné složky.

3.1 Morfologická analýza (operace)

Morfologická analýza se zařazuje mezi tzv. normativní prognostické metody vyznačované tím, že na počátku zadáváme nastávající požadavky nebo cíle a na tomto principu jsou identifikovány okolnosti, opatření nebo technologie, potřebné k dosažení. Morfologická operace (analýza) zpracovává digitální obraz využívající k extrakci části obrazu. Dále, kde morfologickou operaci lze uplatnit je především k předzpracování obrazu, jakou se nazývá morfologická filtrace.

Součástí analýzy jsou i určité disciplíny s cílem dosažení rozšířeného nadhledu k řešení, které už v tento moment existují. Systém založený na morfologické analýze se zabývá hlavně tvarem disciplíny. Morfologickou analýzu využívá oblast technologického prognózování pro vývoj nových, stávajících produktu. [25]

- Analýza nejreálnějších možností vzhledem k dostupnosti zdroje
- Analýza, formulace a definice problému
- Identifikace, popis a charakteristika faktorů
- Tvorba matice (vícerozměrné), součástí matice – všechna reálná řešení
- Vyhodnocení dosažených cílů podle předpokládaných faktorů

3.1.1 Dilatace

Základním prvkem operátoru dilatace je postupné zvětšování určité hranice objektu na černobílém obraze. Danou operací vytvoříme v danou chvíli, kdy bílé plochy budou zvětšeny a černé mezery mezi nimi budou zmenšeny. Používána pro zaplnění malých děr a úzkých zálivů. Dilatace využívá dvou vstupních dat. První z nich je zdrojový obrázek, druhým vstupním datem se nazývá tvořící element (Structuring element). Úkolem tvořícího elementu je především určující vlastní rozšíření znaků v objektech. Dané rozšíření znaků je za účelem právě k vyznačení ne-li zvýraznění registrační značky. Obecně lze říci, že okolí

RZ po určitém provedení operace dostaneme jednotnou skupinu pixelů. Což pro další vyhodnocení detekce se stane mnohem příznivější než obraz bez transformace dané dilatace.

3.1.2 Eroze (Erosion)

Eroze neboli nazývané taky Erosion je přesným opakem dilation. Z tohoto vyplývá, že posluhuje k odfiltrování samotných tříd pixelů, pro které je typický šum v obraze. Obdobně jako u dilation využívá filtru Structuring element (tvořící element). Eroze vytváří převod velikosti objektů, kde se snaží odstranit obrazy s částečnou odchylkou, při nichž je menší než vytvářející element.

3.1.3 Uzavření (Closing) a otevření (Opening)

Otevření - pro operaci opening (otevření) je zcela základní odstranění šumu v obraze, kde ovšem velikost objektu (znaků) je zachována. Využití operace - otevření je velice vhodná pro odstranění šumových pixelů, vyhlazování kontur, k odstranění úzkých čár (linek) nebo k přerušení tenkých propojení mezi jednotlivými znaky v objektech.

Uzavření – zde se aplikuje na obraz filtr dilatace následovaným filtrem Eroze. Při využití této operace (uzavření) filtr vyhledá obrysy objektů zaznamenané na obraze. Dalšími vlastnostmi, které funkce využívá je především spojitost blízkých objektů a vyplnění (zacelení) malých mezer v obraze mezi znaky.

3.2 Odstín šedé

Pro přínos práce není potřeba pracovat s barevným polem, tudíž je velmi vhodné a účinné převést obraz do pole dvourozměrného. Zde využíváme funkci jasu, která je rozebrána v kapitole histogram. Odstín šedé bude využit při detekci hran a prahováním.




Obr. 13. Původní (in) obraz



Obr. 12. Odstín šedi (out)

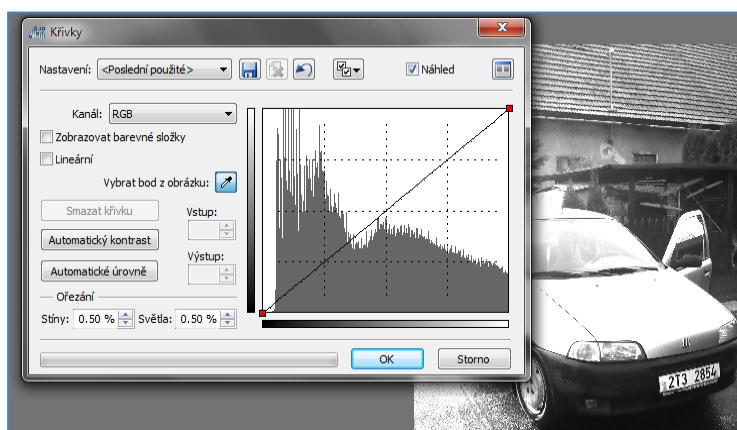
3.2.1 Histogram

Histogram je určitý graf z konkrétního digitálního obrazu, který definuje rozložení jasů v obraze přecházející od černé barvy (vlevo) po barvu bílou (vpravo). Pro analýzu histogramu odpovídá využití statistiky grafu na základě vylepšení obrazu (transformace obrazu).



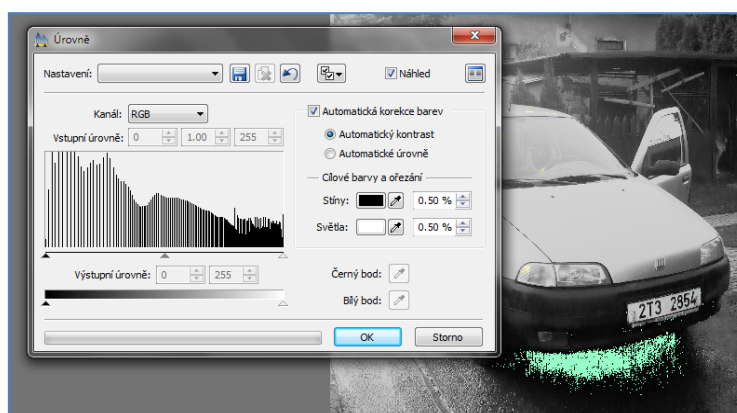
Obr. 14. Graf histogramu

Histogram v odstínu šedé:



Obr. 15. Původní obraz-histogram

Vyrovnaní histogramu:



Obr. 16. Transformovaný obraz-histogram

4 SEGMENTACE OBRAZU

Velice důležitým krokem ke zpracování obrazové informace je segmentace. Pojednává o nejtěžším kroku ohledně zpracování objektů v obraze. K tomu, abychom dokázali rozeznat objekt, popř. tvar, tak je potřeba v digitálním obraze docílit určitým charakteristickým symbolů. V současné době k vyhledávání vlastnosti v obraze lze nalézt několik určitých metod (např. detekce bodu, hran, regionu nebo čar).

4.1 Detekce hran

Hrana v obraze signalizuje určitý úsek (oblast), při nichž nastává náhlá změna hodnoty jasu v obraze. Z tohoto pohledu potřebujeme naleznout prostor, kde se jasová složka razantně mění. U detekce hran je využité kritérium využívající velikost první nebo druhé derivace intenzity jasu.

Za výsledkem první derivace dvou proměnných se považuje gradient, kde gradient představuje vektor. Vektor zaručuje kolmost na hranu, tudíž lze zde využít k detekci hrany. Princip gradientu se zakládá na sloužící operátory určené pro detekci hran. Operátory samotné používají tzv. konvoluční masky. Masky umožňují detekovat hrany ve vertikálním, horizontálním či diagonálním směru.

4.2 Prahování

Prahování nazývané taky v cizojazyčném jazyce jako thresholding, které je velice významnou součástí u segmentace obrazu. Z kapitoly předzpracování obrazu byl proveden přechod ze základního (původního) obrazu na obraz v odstínu šedi. Prahování plní funkci převodu obrazu v odstínu šedi na černobílý obraz. V prahování určujeme hodnotu prahu (threshold), jehož označení bývá písmen T. Vlastnost prahu - threshold porovnává jednotlivé pixely v obraze. Prahovaný obraz je častokrát pojmenovaný jako binární. U digitálního obrazu při prahování kontrolujeme ne-li porovnááme jasovou složku pixelů s hodnotou prahu. Je-li hodnota prahu větší než jasová složka přiřazuje se k pixelu hodnota 0 (bílá), pakliže je to opačně přiřazujeme hodnotu 1 (černá).

4.2.1 SIS metoda

Metoda SIS určuje práh T , stejně jako metody Otsuova nebo Iterativní metoda. Rozdílem oproti dalším metodám je dán výsledek, který se zakládá na jednoduché statistice obrazu. Výsledkem oproti ostatním metodám se zakládá na detekci objektu RZ s pozadím. Nutno podotknout, že výsledek pozadí není nikterak zastíněné. Pro určení prahu T je zapotřebí vypočítat pro každý pixel v obraze dva gradienty ve vertikálním a horizontálním směru.



Obr. 17. Vstupní obraz – odstín šedé – černobílý obraz

5 ROZPOZNÁVÁNÍ ČÍSLIC A PÍSMEN

Po segmentaci a prahováním přichází další významná část. Následně potřebuje identifikovat daný objekt (digitální obraz). Pro registrační značku je prvotní určitý tvar číslic a písmen. Písmena a číslice jsou popsány a zobrazeny v další části kapitole. U číslice se jedná o množinu čísel (0,1,2,3 ...9). Výjimkou u písmen je písmeno O, které je lehce zaměnitelné s číslicí 0. Pro zaměnitelnost nebylo písmeno O zařazeno pro označení ke krajskému organu RZ.

5.1 Normalizace

Normalizace odkazuje na definovanou, zadávající velikost obrazu. Rozměry pro normalizaci se mohou různě měnit. Zpravidla nazývané jako „normalizační tvar“, vystihující tvar čtvercový (např.30x 30). Postupným cílem, jak dosáhnout rozpoznání číslic je rozložením na určité pod obrázky, na nichž mohou být zobrazeny písmena nebo čísla. Faktorem pro rozpoznání číslic podle určité předlohy označujeme pod pojmem klasifikátor. K tomu, a bychom číslici rozpoznali podle předlohy, potřebujeme atributy číslic (výška, šířka). Výška znaku je pevně předurčena. Šířka znaku se liší na různorodosti dané množiny číslic. Pro danou situaci k rozpoznání číslic u RZ je především důležité přizpůsobit výšku znaku, naopak šířka znaku je nezbytná k dopočítání podle prvotního poměru stran.

5.2 Základní rozdělení RZ

Registrační značky můžeme rozdělit do několika skupin, v nichž můžeme řešit jiné skutečnosti. Velmi častým problémem je řešená situace na pozici písma (font). Velice dobře je známo, že ve světě narazíme na různé druhy písma, s kterými se setkáme i na poznávacích značkách na kterémkoliv světadíle. U typu písma není jen řešen konkrétní typ písma, ale i další charakteristiky (velikost, sklon, barva atd.). Pro následnou ukázkou přiřazují i ostatní typ RZ na světě podle kontinentů více v příloze PI.[21]

1. Podle typu písma

- Latinkové písmo
 - i. Nelatinkové pravosměrné
 1. Řecké písmo
 2. Slovanské písmo – azbuka, bulharské, srbské
 - ii. Nelatinkové levosměrná
 1. Písmo arabské
 2. Hebrejské písmo
- Exotické písmo
 - i. Čínské
 - ii. Japonské
 - iii. Barmské
 - iv. Hidské

Vlastnosti písma:

- Velikost
- Sklon
- Řez – úzká, široká, obyčejná
- Tloušťka – hubená, polotučná, tučná
- Barva – písma, pozadí, stínu

2. Podle typu vozidla

- Osobní
- Nákladní
- Sportovní – R – označení pro sportovní vozidla
- Veteránské – V – označení pro veteránské (historické vozidla)
- Moto – motocykly (silniční, mopedy)


3. Podle velikosti

- Jednořádkové registrační značky – pro osobní vozidla



Obr. 18 Jednořádkové RZ [16]

- Dvouřádkové registrační značky – pro osobní vozidla



Obr. 19. Rozměry dvouřádkové RZ [16]

Historie a současnost RZ v ČR:

- **Období 1994 -2001** (starší verze RZ)



Obr. 20. RZ Brno-západ (označení pro rok 1994-2001) [16]

- **Období 2001-2004** (RZ bez označení EU)



Obr. 21. Moravskoslezský kraj - T (označení pro rok 2001 – 2004) [16]

- **Období od roku 2004** (RZ s popruhem EU)



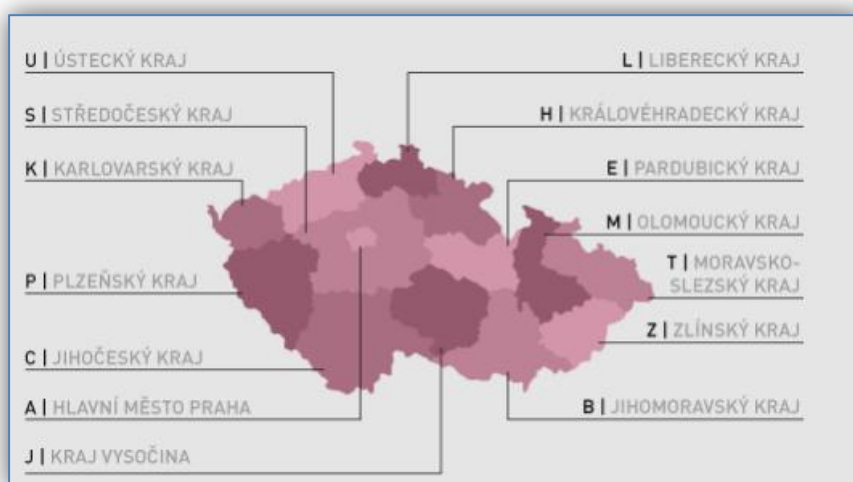
Obr. 22. RZ od roku 2004 do současnosti [16]

4. RZ podle kontinentů:

Názorné ukázky registračních značek z ostatních kontinentu nalezneme v příloze PI.

5.2.1 Administrativní RZ v ČR a krajské kódy

Registrační značky byly v historii přiřazovány k okresnímu dopravnímu inspektorátu ČR. Od července 1. 1. 2001 nabírá platnost RZ rozdělení podle krajů. Z celkového počtu 77 okresů vzniklo 13 krajů, kde čtrnáctým krajem je hlavní město Praha.



Obr. 23. Rozdělení ČR do krajů

Pro zaměnitelnost s nulou se nevyužívá písmeno O. Písmena G, Q a W nejsou zařazeny do zobrazovacích znaků příslušné k zobrazení na RZ v ČR. Nebylo tomu ani v historii RZ. Písmeno D zůstává doposud volné.

1234567890 ABCDEFHIJKLMPRSTUVXYZ

Obr. 24. Vyobrazení podle přístupných znaků

5.2.2 Rozdělení RZ v ČR podle krajů

Pro změnu, která nastala při změně RZ se zohledňuje na určitý fakt. Označení písmen pro krajská města na RZ jsou zcela odlišné od staršího modelu (viz. Obr. 15.) poznávací značky. Písmena jednotlivých krajů jsou řazena na druhé místo, jehož důvodem je právě se vyhnout zaměnitelnosti s okresními značkami. Pro posouzení od uplynulé doby můžeme říci, že z hlediska efektivnosti, atraktivnosti a zapamatovatelnosti se tyto značky stali

největší slabinou reformy. Poznávací značka může být sestavena z libovolného počtu číslic a písmen, podmínkou akorát zůstává, že první písmeno zleva musí být krajské.

Kód	Kód	Význam	Krajské město	Kód	Kód	Význam	Krajské město
A	1	Hlavní město Praha	Praha	N		volné	-
B	2	Jihomoravský kraj	Brno	O		není v seznamu	-
C	3	Jihočeský kraj	České Budějovice	P	10	Plzeňský kraj	Plzeň
D		volné	-	Q		není v seznamu	-
E	4	Pardubický kraj	Pardubice	R		Sportovní značky	-
F		Zkušební značky	-	S	11	Středočeský kraj	Praha
G		není v seznamu	-	T	12	Moravskoslezský kraj	Ostrava
H	5	Královéhradecký kraj	Hradec Králové	U	13	Ústecký kraj	Ústí nad Labem
I		volné	-	V		Veteránské značky	-
J	6	Kraj Vysočina	Jihlava	W		není v seznamu	-
K	7	Karlovarský kraj	Karlovy Vary	X		volné	-
L	8	Liberecký kraj	Liberec	Y		volné	-
M	9	Olomoucký kraj	Olomouc	Z	14	Zlínský kraj	Zlín


Obr. 25. Označení RZ podle krajů

6 NEURONOVÁ SÍŤ - NN


NS nazýváme takovou strukturu, která slouží pro rozprostřené paralelní zpracování informací, která se skládá z velmi vysokého počtu N výkonných prvků. Každý výkonný prvek může současně přijímat libovolný počet různých vstupních informací a po jejich zpracování předávat shodné informace na konečný počet výstupů. Transformace vstupního signálu na výstupní se děje podle přenosové funkce. Na výstup má vliv i lokální paměť, které je reprezentována hodnotami váhových koeficientů u jednotlivých vstupů. [7]

6.1 Historie neuronových sítí

Vznik neuronových sítí se objevuje v první polovině 20. století. První publikace o neuronech a jednotlivých modelech byla zmíněna Američanem W. S. McCullochem. V období 40. let 20. století W. S. McCullochem vypracoval se studentem W. Pittsem model neuronu, který se aplikuje i v dnešní době při výuce.[1]



Obr. 26. Model neuronu [1]



Obr. 27. Výsledek f-ce [1]

První funkční síť, která byla vytvořena v roce 1958 F. Roseblattem nese název perceptronová síť. Nedostatkem sítě byl ten, že dokázala řešit pouze problém, který byl lineárně separabilní. Od konce 60. let do poloviny 80. let 20. století poklesl zájem o neuronové sítě téměř až k nule. V polovině 80. let došlo k znovuzrození neuronových sítí, kdy v současné době a budoucnosti se s ní budeme setkávat v několika různých odvětvích. [3]

V rozvoji vědy se koncem 80. let objevují a vznikají i další vícevrstvé sítě:

- Hopfieldová síť
- Kohonenova síť
- Grossbergova ART síť
- RBF síť – síť s radiální bází

6.2 Teorie NN

Neuronová síť se skládá z formálních neuronů, které jsou vzájemně propojené tak, že výstup neuronu je vstupem obecně více neuronů podobně, jako terminály axonu biologického neuronu jsou přes synaptické vazby spojeny s dendrity jiných neuronů. Počet neuronů a jejich vzájemné propojení v síti určuje tzv. architekturu (topologii) neuronové sítě.

Z hlediska využití rozlišujeme neurony v síti vstupní, pracovní (skryté, mezilehlé) a výstupní. Zjednodušeně, v neurofyziologické analogii vstupní neurony odpovídají receptorům. Výstupní neurony se přiřazují efektorům a třetí typ neuronů pracovní vytváří příslušné dráhy, po kterých se šíří vlastní vzruchy. V matematickém modelu se nazývají cesty. Zpracování a šíření informace na cestě v síti je umožněno změnou stavů neuronů ležících na této cestě. Stav neuronů v síti určují „stav neuronové sítě“ a synaptické váhy spojů představují tzv. konfiguraci sítě. [6]

Neuronová síť je neustále v daném čase vyvíjena. Jednotlivé propojení a stav neuronů je základní změnou sítě, co se týká vývinu, kde je nezbytné adaptovat váhy. Vlivem změn těchto charakteristik v určitém čase (okamžiku) dělíme dynamiku neuronové sítě na tři části dynamik. Se změnou dynamik je nepostradatelné zmínit režimy práce:

- Organizační – změna topologie
- Aktivní – změna stavu
- Adaptivní – změna konfigurace

Dynamika neuronové sítě bývá zadávána počátečním stavem a matematickou rovnicí. Pravidla, určující rovnice sítě se nazývají a jsou spojeny s topologií, stavem a konfigurací v čase.

Architektura – uspořádání uzlů a propojení mezi nimi

- Propojení sítě
 - úplné
 - částečné
- Vazby
- Nejpoužívanější a nejvyužívanější šíření směrem dopředu (feedforward) nebo zpětné šíření, které je bez zpětné vazby a přitom silně stabilní
- zpětnovazební (rekurzivní) síť, problémy se stabilitou

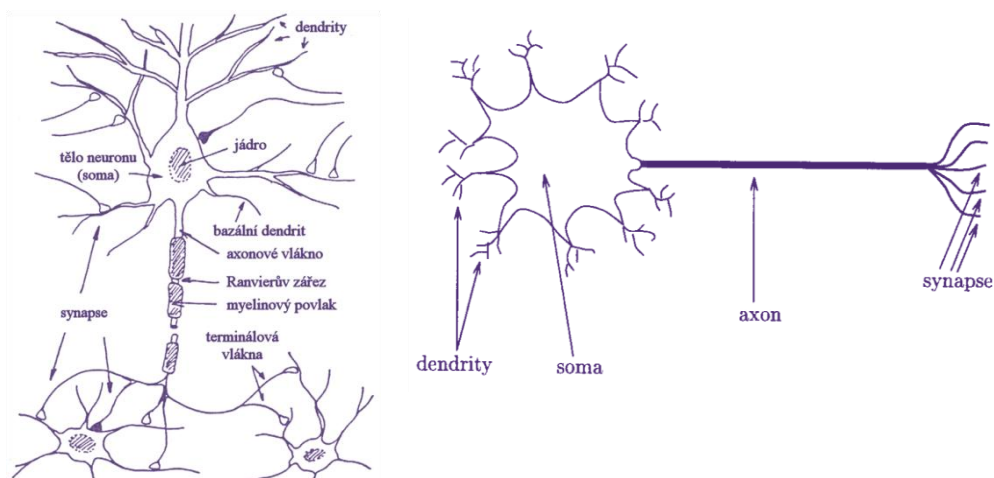
Algoritmus učení

- Postup, jakým se nastavují váhy v jednotlivých spojeních

Aktivační funkce

- Postup, jakým se ze vstupů uzlů počítá jeho výstup
 - synchronní
 - asynchronní

Lidský mozek spotřebovává 20 - 30 % energie těla, jelikož i přesto, že představuje z celkové váhy těla cca 2%. [1]

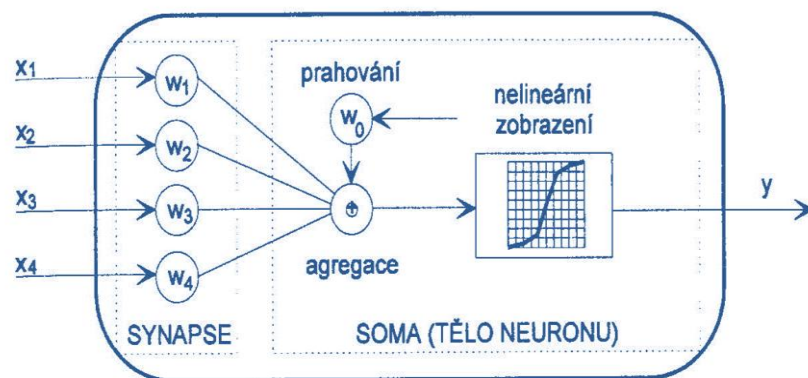


Obr. 28. Biologie neuronu [1]

Základní složení biologického neuronu:

Biologický neuron je složen z těla buňky neboli somy. Velikost somy respektive těla buňky je 1 až 3 μm . Ze somy vybíhá 100 až 10000 výběžku nazývaní dendrity. Dendrity tvoří vstupy neuronu a kromě toho ještě jedno vlákno - axon, které vytváří výstup neuronu. Axon v porovnání s dendrity může mít délku až okolo 60 cm. Axonové vlákno se na konci délky dělí na několik dalších větví. Toto větvení nazýváme synapse (stykové jednotky). Stykové jednotky jsou přiléhány na dendrity jiných neuronů, kde tím vytváří vazbu jednotlivých neuronů. Počet nových synaptických spojů vzniká v průběhu života, kde proces je závislý na učení organismu.

Obecně může mít neuron více výstupů (axonové vlákno je na konci rozvětveno), ačkoli informace zpracovaná neuronem se nedělí, z čehož vyplývá, že každý výstup přenáší stejnou informaci. Schéma funkce neuronu je znázorněna následovně:



Obr. 29 Blokové schéma matematického modelu neuronu [1]

$x_1 \div x_N$ vstupní signály z N spolupracujících s neurony,

Σ sumační funkce,

f obecně nelineární přenosová funkce,

y výstupní signál,

w_i váhové činitele reprezentující působení jednotlivých synapsí,

Tab. 1. Legenda k matematickému modelu neuronu

6.2.1 PC x Lidský mozek

	Počítač	Lidský mozek
Výpočetní jednotka	1 CPU	10^{11} buněk
Paměť	10^9 bitů RAM, 10^{11} bitů na disku	10^{11} neuronů, 10^{14} synapsí
Délka cyklu	10^{-8} sekundy	10^{-3} sekundy
Šířka pásma	10^9 bitů za sekundu	10^{14} bitů za sekundu
Rychlost obnovy	10^9 výpočetních elementů	10^{14} neuronů za sekundu

Tab. 2. Počítač x Lidský mozek

Mozek je velice složitá část lidského těla, kterému člověk těžko chápe a je obtížné pochopit jednotlivé buňky, jestliže mají úlohu pro zpracování informace. Buňky v lidském mozku vlastní spousty dalších prvků k určitému chování, tak aby zůstali na živu.

6.2.2 NN x PC

Základním rozdílem mezi NN a počítačem (PC) je vytvoření programu, pro řešení daného problému. K vytvoření programu potřebuje kvalifikovaného programátora, který je schopen sestavit program splňující podmínky a instrukce na základě daného úkolu splňující formu problému. Program řeší určitý problém, který nastane způsobem, že nejprve je obsluha (administrátor, programátor) informována o problému (vyskytnutí neznámého případu, který byl odložen bokem), kde následně nutně musí být program upraven programátorem.

V opačném případě při použití neuronové sítě nemusíme používat žádný programovací algoritmus. K tomu, abychom tomu předešli je nezbytná vhodná konfigurace, neboť právě neuronová síť zareaguje tím správným způsobem a zařadí novou informaci s velkou pravděpodobností do správné třídy. Oproti programu tvořený programátorem nepotřebuje úpravy sítě.

Přikládám tabulku (Tab. 3.), kde jsou zobrazeny nejdůležitější rozdíly mezi PC a NN.

Neuronová síť	PC
Určena nastavováním vah, prahů a struktury	Programování instrukcemi <ul style="list-style-type: none"> • if, then, go to
Toleruje odchylky od originálních informací	Netolerující odchylky
Samorganizace – v průběhu učení	Neměnnost programu
Paralelismus	Sekvenčnost
Paměťové a výkonné prvky – uspořádány spolu	Proces a paměť = separace

Tab. 3. NS x PC

Pro objasnění celé situace a přizpůsobení k detekci poznávací značky uvedu příklad:

1. Programátor musí určit algoritmus, který určí, do jaké třídy daný prvek patří. Tím prvkem se může myslet zejména typ dopravní značky. Dopravní značka může být ve čtvercovém nebo obdélníkovém provedení. Důležitějším, rozdílnějším faktorem je typ písma, zdali se jedná o latinskou formu textu, nebo o nelatinkovou formu. Nelatinková forma se nám dělí na pravosměrná (řecké písmo, slovanská písma – azbuka, bulharské, srbské) nebo levosměrná písma (arabské nebo hebrejské).
2. Důležitým krokem je správně značku roztrždit a zařadit. Prvním prvkem rozlišení bude, o který stát se jedná. Dále dělíme značky podle států (USA), krajů (ČR) popř. regionů (SK).
3. U neuronové síti s velkou pravděpodobností bude provedeno správné vyhodnocení.


6.3 Funkce -Princip

Na funkci neuronu mají vliv

- Topologie synapsí – propojení, matice
- Přenosové vlastnosti – vliv vah synapsí a prahování signálu
- Přenosová funkce – lineární, nelineární, skoková
- Funkční vlastnosti – pamatování, změna koeficientů učení, potlačení učení

6.4 SYNAPSE


V neuronu se zpracovává informace především v somatu, jelikož somat (tělo buňky) je součástí neuronu. Po zpracování informace přenáší axon na výkonný orgán. Činnost v somatu v neuronu je pro funkci přenosu zcela základní ne-li zásadní. [7]



Obr. 30 Biologická inspirace

Při překročení hodnoty se na vstupní podnět objeví až po odezvě překročení prahu, když víme, že každý neuron má svůj práh.

Každý neuron má svůj práh, ze kterého nám vyplývá, že odezva neuronu na vstupní podnět se objeví až po překročení této hodnoty. Odezva je přenášena po axonu opět ve formě potenciálové vlny (viz Obr. 32.). Axon (vlastní výstup) je rozvětvený a spojen s dendrity (vstupy) dalších neuronů pomocí spojek „synapse“. [1]



Obr. 31. Schéma synapse

Synapse působí nejen jako mezineuronová rozhraní, ale také přispívají na vytváření paměťových stop. [2]

Na funkci neuronu má tedy vliv topologie synapsí

- Vzájemné propojení mezi vstupními a výstupními branami, obvykle popisované řídkou maticí
- Přenosové vlastnosti (předávání množství z přijaté informace je proměnné s časem, frekvencí a je charakterizováno váhovými koeficienty synaptické plasticity)
- Funkční vlastnosti (pamatování - možnost změn koeficientů s procesem učení)

Popis jednotlivých částí neuronů


- Synapse
 - Zásadní pro činnost neuronů
 - Vytváří mezineuronová rozhraní
 - Vytváří paměťové elementy, funkce – učí se na základě informací přicházejících z okolních neuronů
 - Hrubá aproximace skutečných synapsí
 - Spojitě adaptují své hodnoty a ukládají získané zkušenosti
- Soma
 - Zpracovává informaci
 - Obsahuje 2 základní operace
 - Agregace (sčítání vstupů – sloučení signálů z dendritů)
 - Prahování - aktivace neuronu při minimální hodnotě vstup

6.4.1 Princip, funkce synapse


Jak funguje synapse v přenosu informací?

Často se synapse přirovnává k ventilu. Ventil tvořící dvojí režim. Tím prvním režimem je excitačním (budícím) a druhý inhibičním (tlumícím). Otázkou jaká bude odezva (excitace, inhibice) záleží na transmiterech. Transmitter se považuje za nosiče informace – acetylcholin, glutamát (excitace), glycin a GABA (inhibice). Které jsou uvolněny v presynaptické části axonu. V průběhu zkoumání synapsí se přišlo, že transitory působící krátkodobě zodpovídají za přenos funkce a transitory působící dlouhodobě jsou naopak zodpovědné paměť. [4]

Jestliže bychom si promítli odezvu neuronu na časovou osu (t), potom zjistíme, že potenciálové vlny tvoří sled informací 250 – 1000 impuls/s.



Obr. 32 Tvar impulsů vyslané do axonů ze synapse



Obr. 33. Tvar impulsů vyslané do axonů ze synapse

6.4.2 Využití neuronových sítí

Neuronová síť má rozsáhlé využití v praxi, které se s vývojem techniky a studijním metod stále více rozvíjí. [30]

V současnosti můžeme použít při:

- Identifikaci radarových nebo sonarových signálů
- Predikci chování
- Klasifikaci
- Filtraci

V současnosti nacházejí umělé neuronové sítě uplatnění často jako pomocné nástroje uvnitř funkčních systémů. Tyto nástroje slouží pro potlačování šumu v datech, pro rozložení obrazu na více částí, pro výběr reprezentantů (např. pro zmenšování počtu barev či naopak obarvování černobílých filmů)- zde nalezne uplatnění Kohonenová síť. Další využití pomocných nástrojů využijeme pro optické rozpoznávání znaků OCR (s nichž je právě spojena detekce RZ), potom analyzátoři provozu na internetu a aplikace jiných systémů, které za uživatele mohou být schopny dělat třeba i špionážní práci. Když shrneme, kde všude by neuronové sítě našly uplatnění, tak se dostaneme do systémů, kde případná chyba až tak nemusí vadit. Úspěšnost neuronových sítí je cca 95 %. Algoritmus, který NN využívají je příliš náročný, jak po stránce finanční (hardware, experti), tak i po stránce časové (nutnost rychlých rozhodnutí). Neuronové sítě mají několik typu a každý z nich je obzvláště určen pro jiný typ funkce, který má plnit danou část úlohy. Zatímco samostatný jeden neuron dokáže rozlišit prvky do dvou skupin (lineárně separabilních), vrstevnaté NN umí rozdělit do libovolného množství skupin, kde výhodou oproti samostatnému neuronu je, že nemusí být lineárně separabilní. [9]

Nejrozšířenější a nejpoužívanější sítí současnosti je vrstevnatá neuronová síť (např. *NETtalk*). Potažmo, další možnosti využití NN je v letecké dopravě (systém AMT-sloužící pro rezervaci letenek). Zaobírá se poptávkou po volných místech (v této fázi právě je využita neuronová síť). Uvedené možnosti nejsou konečné, jednou z možností je uplatnění ve zdravotnictví – při filtraci EKG signálu (EKG křivka dokáže odhalit nemoci), dále při podávání antibiotik (NN pracuje 4x přesněji než lékaři), druhá možnost je ve finančnictví, která je daleko častější popř. lákavější (predikace při změně kurzů jednotlivých měn nebo akcií. V porovnání s klasickou metodou, kde úspěšnost byla 55%, je při využití neuronové sítě o 20 - 30% vyšší. Poslední možná situace, při níž NN byla aplikovaná a nainstalovaná byla součástí reakce na určité podněty od „učitele – experti“. Při dostatečné nauce, byla síť schopná reagovat správně i na neznámé podněty (využití např. v atomových elektrárnách, pivovarech, pokusy při řízení automobilů, kdy síť reagovala jako řidič – plyn, brzda popř. rychlá, agresivní nebo pomalá jízda). [8]

Využití neuronové sítě v souladu s úlohou:

Úloha	Vhodné neuronové sítě
logické obvody	HEBB, HAMM, MLP1
odstranění šumu	MLP1, MLP2, RBF, MOD
řeč a výslovnost	MLP2, SOM
komprese	COUNT
dolování dat (data mining)	OLAM, HEBB, SOM
optické rozpoznávání znaků	HEBB, OLAM, HAMM, MLP1, MLP2, RBF, SOM

Tab. 4 Použití neuronových sítí

6.5 Perceptron

Topologie: Pro praktické znázornění využijeme program pro tvorbu přenosové funkce, která zobrazuje průběhy jednotlivých funkcí, při nichž se nastavují vstupní data. [4]

6.5.1 Přenosová funkce:

Definice:

„Přenosová funkce neuronu je funkce, která transformuje vstupní signál na signál výstupní v intervalech 0 až 1 a -1 až +1. Tato funkce může být skoková či spojitá a musí být monotónní (tzn., že přiřazení odezev výstupu na vstup je jednoznačné).“

Velmi důležitá věc pro přenosovou funkci je zvolit správný chod neuronu a neuronové sítě. Přenosová funkce poukazuje na odezvu ohledně výstupu k vstupnímu podnětu. Nejčastější využíváme funkce v intervalu +1 a -1, kterou nazýváme spojitá (sinoida, hyperbolický tangens), druhým intervalem je klasická binární funkce 0-1 (což je nespojitá funkce). Použijeme funkci spojitou, pak musíme rozhodnout, jaká hodnota je této funkce (např. 0,8, 0,9).

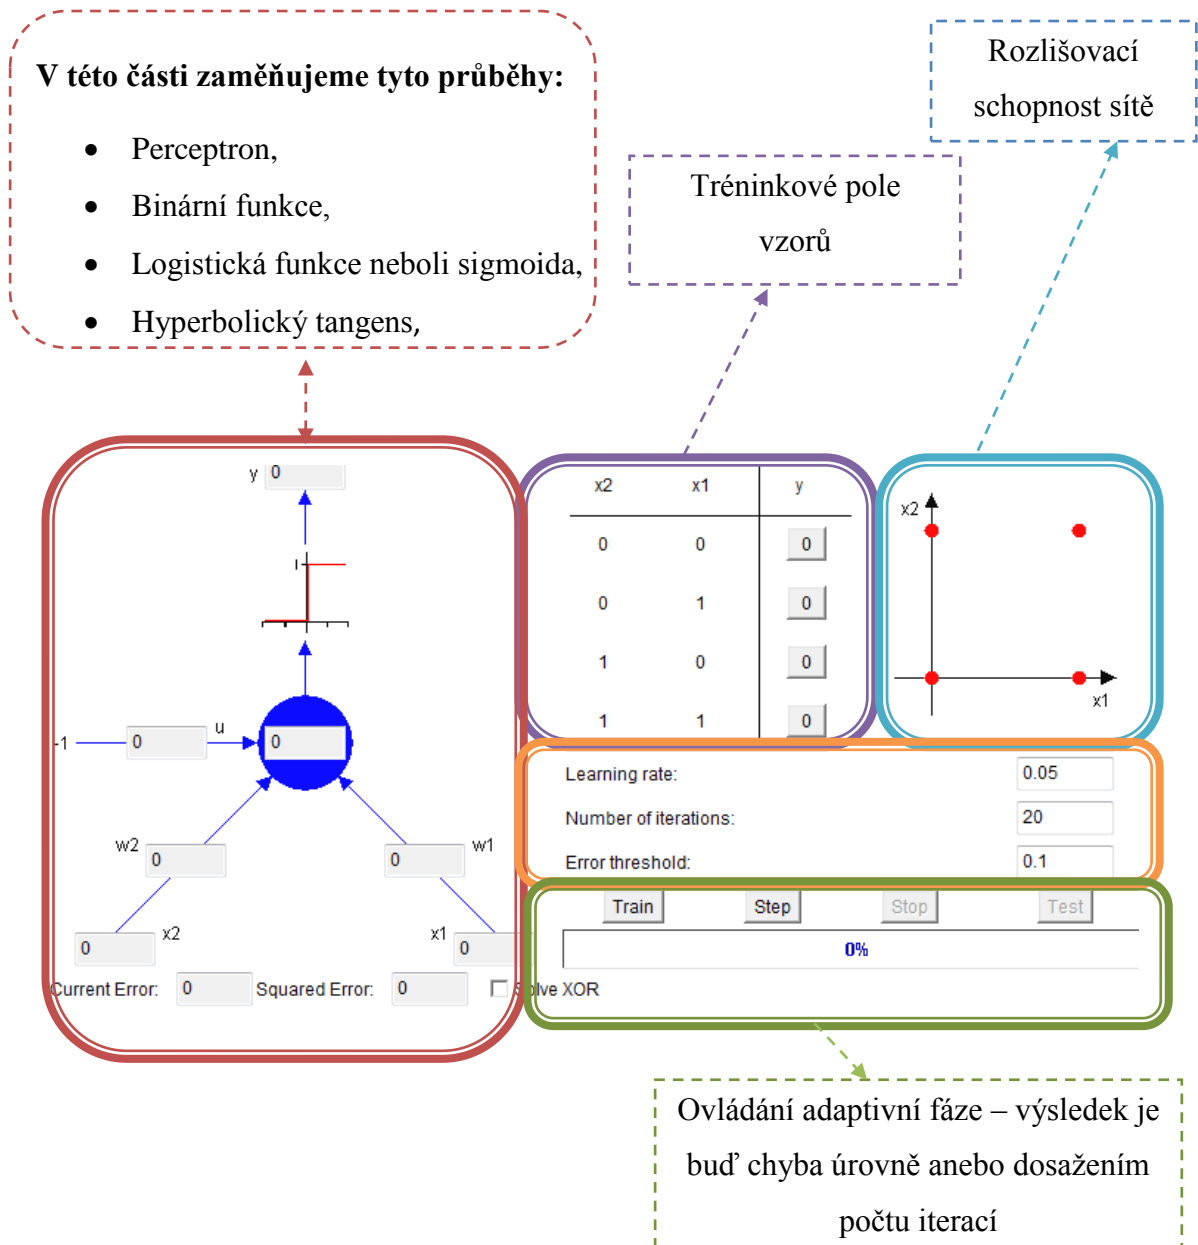
Názorné a vypracované ukázky nejpoužívanějších funkcí perceptronu nalezneme v zadní části této diplomové práce pod názvem příloha PII.

Zde si uvedeme popis programu pro vygenerování jednotlivých funkcí (perceptronu, binární funkce, logistická funkce neboli sigmoida a funkce hyperbolický tangens). Na Obr. 35. JavaApplet – Perceptron máme kompletně znázorněnou funkci perceptronu. Obdobně byly zpracovány i ostatní funkce, které lze shlédnout v Příloze PII.

Adaptivní fáze jsou předpokládány vzory funkcí:

- Vstupy – x_1, x_2
- Výstup – y
- Vnitřní práh – u
- Váhy w_1, w_2

Na základě těchto konstant chceme, aby správně dokázala vyhodnotit či rozpoznat vzory funkcí. Je nezbytně nutné učit síť, aby podle předlohy rozpoznala správný vzor.




Obr. 34. JavaApplet – Perceptron [5]


6.6 Hopfieldová síť

Hopfieldová síť má jednu vrstvu neuronů propojených vzájemně „každý s každým“. Vstupy neuronů mohou být kvantitativní, ale z počátku vývoje byla tato síť představovaná s kvalitativními vstupy a výstupy (-1; +1). [4]

- Navržena J. Hopfieldem v roce 1982
- Autoasociativní paměť
- Pracuje s bipolárními (binárními) hodnotami vstupů/výstupů
- Spojitá varianta Hopfieldové sítě se používá k řešení optimalizačních problémů




Obr. 36. Hopfieldová síť



Obr. 35. Topologie tříprvkové HS

6.6.1 Příklad – Hopfieldovi síť

Ukázka průběhu při analyzování jednotlivých číslic v praxi.




Obr. 37. Grafické znázornění Hopfieldovi síť [4]

6.7 Kohonenová síť

Kohonenova síť patří k sítím s topologií stromu (lesu) a je navržena ve smyslu rozvinutí úvahy soustředěných v perceptronu. Základní návržení sítě je předpokládána v roli neuronů (logické prahové elementy), uspořádané v jednorozměrném nebo dvourozměrné struktúře s propojením sousedních prvků. Kohonenová síť je součástí z jedné mnoha forem asociativní paměti. [4]

- Provádí pouze analýzu vstupních dat -> druh shlukové analýzy
- Obsahuje jedinou vrstvu radiálních neuronů, které mohou být uspořádaný do tzv. mřížky (matice)
- Síť je možné rozšířit tak, aby byla schopna klasifikace (Learning Vector Quantization – LVQ)

6.7.1 Struktura Kohonenovy sítě



Obr. 38. Kohonenová síť

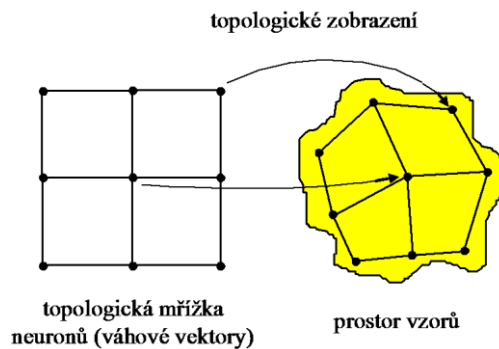
$$d_j = \sum_{i=1}^m (x_i - w_{ij})^2$$

Rov. 4.

$$d_{j^*} = \min_i (d_{j_i})$$


Rov. 3.

- Topologické zobrazení Kohonenovy sítě



Obr. 39. Topologické zobrazení [4]


- Proces učení (adaptace vah) – názorná ukázka adaptace vah



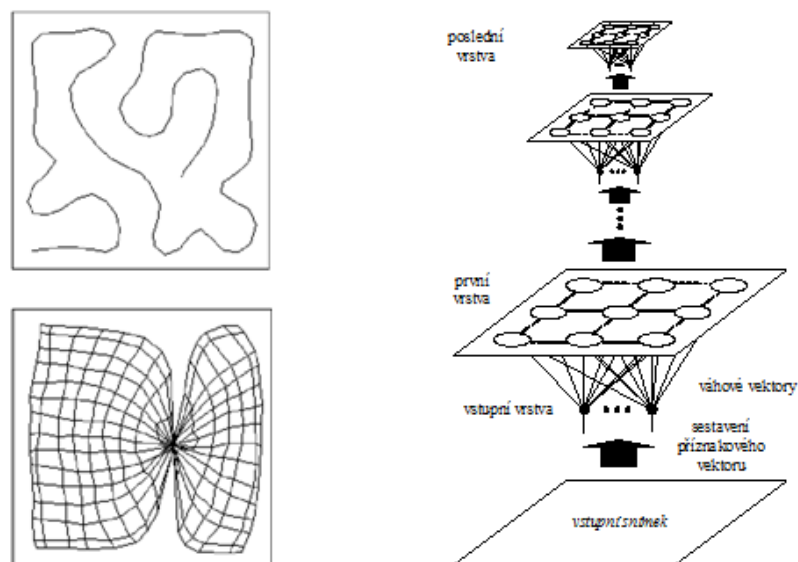
Obr. 40. Adaptace vah [4]

6.7.2 Adaptační funkce

Kohonenová neuronová síť lze rozšířit tak, aby mohla klasifikovat => vektorová kvantizace (Learning Vector Quantization – LVQ).



Princip spočívá v přiřazení ohodnocení třídy neuronům na základě četností s jakou se vyskytují v dominantní skupině. [2]



Obr. 41. Adaptační f-cc [2]

6.8 Problematika neuronových sítí

Soustava poznatků neuronových sítí je nevyhnutelná k poznávání struktury mozku i pro realizaci umělých neuronových sítí. Modelování, simulování neuronových sítí lze provádět na počítačích, pomocí elektronických, optických, optoelektronických a molekulárně - elektronických prvků. [7]

Základní problematikou neuronových sítí je:


- Modelování
- Otázky učení neuronových sítí

6.9 Softwarové prostředí pro tvorbu neuronových sítí

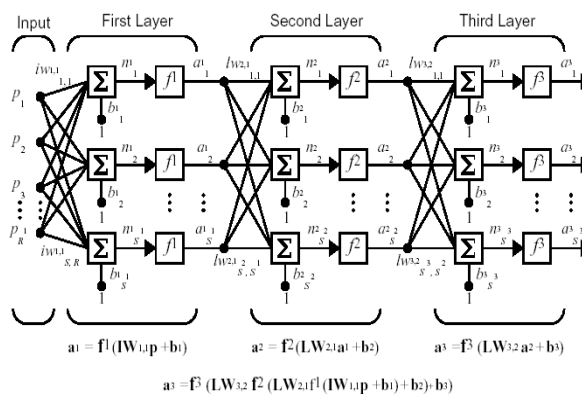
Při navrhnutí neuronové sítě je zapotřebí vědět přesný typ sítě pro danou aplikaci a typ přenosové funkce, zda se jedná o klasifikaci nebo identifikaci. Z jedné dalších rozhodnutí je rozhodnutí zda řešíme lineární nebo nelineární problém.

6.9.1 Matlab Neural Network Toolbox

Neural Network Toolbox TM poskytuje nástroj pro navrhování, provádění, vizualizaci, simulaci neuronových sítí. Neuronové sítě se používají pro aplikace, kde formální analýza by byla obtížná až nemožná, jako je rozpoznávání, identifikace a kontrola nelineárního systému. [20]



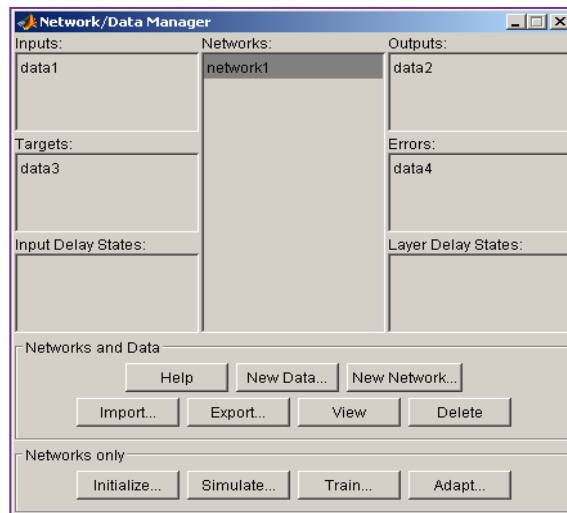
Obr. 42. Vícevrstvá dopředná neuronová síť



Obr. 43. Feed-Forward NN

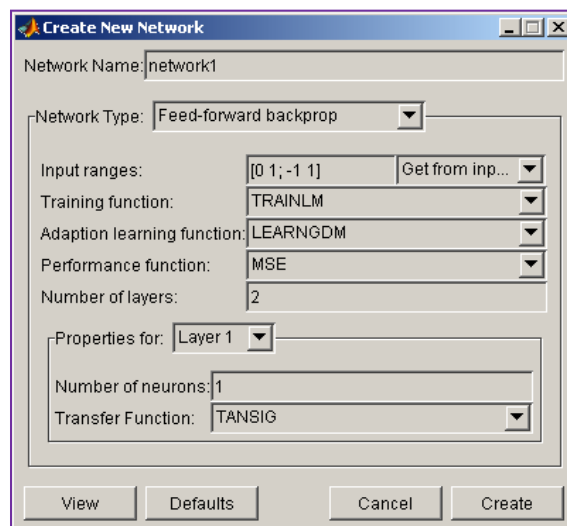
6.9.2 Práce v NN-Toolboxu

Neuronová síť v NN-Toolboxu se vytváří na příkazovém řádku Matlab commanderu. Tento způsob zápisu je typickým pro Matlab, zápis do *. m souboru a následné spuštěním programu. [20]



Obr. 44. Tvorba Neuronové sítě

Neuronová síť vytvářená v programu Matlab commanderu se musí po celou dobu své existence stále učit a vyvíjet.



Obr. 45. Vytvořená nová NN „network1“

- Vytvoření obecné prázdné struktury NN sítě nazvanou „network1“:

```
net = NETWORK(...)
```

Příkazy, které vytvoří před-definovanou prázdnou strukturu NN sítě nazvanou „network1“:

```
net = NEWP([min max; ...;min max],n);

net = NEWLIND(P,T);

net = NEWLIN([min max; ...;min max],n);


net = NEWFF ([min max; ...;min max],[ n1 n2],{'tansig','purelin'},'trainlm');
```

- Nastavení osy (x, y) a základních funkcí pro vytvoření „New Network“ :

<code>x = [0 1 2 3 4 5 6 7 8];</code>
<code>y = [0 0.84 0.91 0.14 -0.77 -0.96 -0.28 0.66 0.99];</code>
<code>Net =newff([0,8],[10,1],{'logsig','purelin'},'traingd');</code>
<code>net.trainParam.epochs = 2000;</code>
<code>net.trainParam.goal = 0.001;</code>
<code>Net = train(net,x, y);</code>


Tab. 5. Matlab nastavení NN

Naučenou síť lze vygenerovat i jako blok do Simulinku. Více ke schématu a nastavení příkazu Gensim nalezneme ve spodní části této kapitoly.



Obr. 46. Zadávání nových dat do sítě „network 1“

Grafické vyjádření neuronové sítě:



Obr. 47. Výstupní graf vytvořené neuronové sítě „network1“

- **Inicializace sítě:**

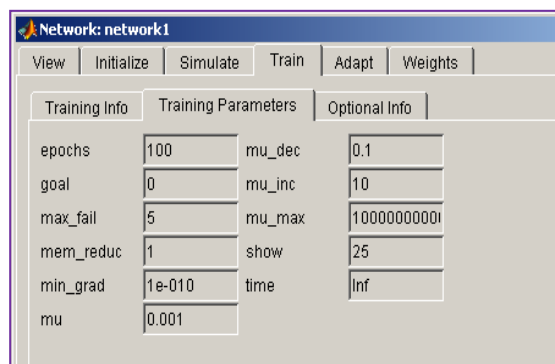
```
net = INIT(net);
```

- **Trénování sítě:**

- Váhy a prahy neuronů se nastavují po proběhnutí celé sekvence všech vektorů vstupů

```
[net , e] = TRAIN(net,P,T);
```

⇒ Vrací vektor výstupu a chybu



Obr. 48. Trénovací proces sítě network1

Legenda:

- net – Network,
- P - Network inputs,
- T - Network targets

- **Spuštění provozu sítě v Matlab commanderu:**


```
y=SIM(net,P);
```

⇒ vrací vektor výstupu

- **Generování sítě do Simulinku:**

```
GENSIM(net,dt);
```

Gensim generuje navrženou neuronovou síť „network1“ do Simulinku



Obr. 49. Schéma a příkaz GENSIM v Simulinku

6.9.3 STATISTIKA Neuronové sítě

STATISTICA Automatizované neuronové sítě (SANS) podporuje nadmíru významných tříd z neuronových sítí, pro řešení problémů k tomu určené.

SANS se zaměřuje především pro:

- Vícerozměrné perceptrony
- RBF sítě
- Samoorganizované mapy

Výše uvedené architektury mohou být použity pro regresi, klasifikaci, regresi v časových řadách, klasifikaci v časových řadách a shlukovou analýzu. Při návrhu neuronové sítě je zapotřebí správný výběr proměnných a následná optimalizace architektury sítě. Tento princip je založený na heuristickém vyhledávání. Součástí heuristického vyhledávání zahrnuje typ NN, velikost NN, architekturu neuronové sítě, aktivační funkce nebo i chybové funkce. Chybovou funkci a další poznatky ze softwarového prostředí STATISTIKA určené k vytváření neuronové sítě nalezneme uvedené v příloze PIII.

7 OPTICKÉ ROZPOZNÁVÁNÍ ZNAKŮ – OCR

V posledních letech pozorujeme, eventuálně zcela rozhodně zaznamenáváme dokonalostí vzestup bezpečnostních kamerových zařízení a příslušenství sloužící k CCTV. Ve spojitosti s OCR (Optical Character Recognition) využíváme kamery s IR-přísvitom, popř. s externím IR-přísvitom. Důvodem proč jsou kamery vybaveny IR-přísvitom, je zcela zásadní. RZ na nejstarším kontinentu jsou značky konstruovány reflexně, tudíž lesk a odraz při snímání zaručuje problém k detekci RZ. Uplatnění OCR nalezne uplatnění nejen ke sledování vozidel, ale i k identifikaci osob, tváří, dopravních značek atd. V budoucnosti s rozvojem vědy budeme moci detekovat kteroukoliv věc, která bude sloužit k účelům v oblasti bezpečnosti státu a nemusí se jednat jenom o dopravní oddělení.

Důležitým krokem pro život je osobní doprava. Doprava, je nedílnou součástí každého z nás, kde pomoci dopravy se přesunujeme během celého dne i života z místa na místo. Pomoci dopravy se přesunují i nebezpečné složky mezi nimi můžou patřit osoby podezřelé z páchání trestných činů nebo taky nejvíce nebezpečná skupina teroristů. V porovnání před 20 až 30-ti lety víme, že dnešní trend 21. století má rostoucí technologický proces. Koncepce, na nichž je zastřešena celá akce, už není monitorována jednotlivými agenty, nýbrž shromažďováním dat pořízené pomocí bezpečnostních monitorovacích zařízení určené k dopadení pachatele. Lze tedy tuto skutečnost definovat, jako skutečný přísun informací, které jsou filtrovány. Co znamená filtrace? Filtrovaná data mají často označení pro skutečné informace, které byly vybrány k odhalení skutečné události (čas, místo, typ vozidla, tvař apod.). Jelikož víme, že denně zaznamenáváme desítky, stovky, tisíce průjezdů vozidel na parkovišti, na silnici I. třídy nebo na dálnici po celé EU. Důležitou složkou tedy je správné vybrání potřebné informace z databáze. Z tohoto důvodu využijeme OCR i při vjezdu a odjezdu z parkoviště.

Optické rozpoznávání znaků je postup, pomocí kterého dokážeme např. digitalizovat tištěný text a dále s ním pracovat jako s elektronickým textem. Pro vjezd do objektu (na parkoviště) nedostačuje pouze detekce RZ vozidel zobrazující danou část obrazu, ale potřebujeme porovnat s databází vozidel. V BP jsem poukázal na problémové parkoviště u ZS Luďka Čajky ve Zlíně. Při návrhu zabezpečení parkoviště jsem zcela vymezil prostor pro osoby blízké spojeny s klubem. Na základě tohoto úsudku navrhuju pouze vjezd pro vozidla, v nichž jsou registrační značky v databázi uloženy.

Při této příležitosti využijeme optické rozpoznávání znaků OCR, kde je nejprve v první řadě znaky segmentovat a následně data analyzovat. V praxi se nabízí široká řada nabídek k OCR modulu. Ovšem všechny moduly nedokážou rozpoznat různé typy RZ po celém světě. Standarty RZ se různě liší. V ČR se zaobíráme standardem stanoveny EU, který nastavil stejný typ RZ po Evropě. Velice dobře si lze uvědomit, že americký standart je zcela odlišný od evropské normy a ne jinak tomu bude i v Asii či Austrálii. Proto dnešní technologie v oblasti detekce RZ má zájem realizovat celoplošnou síť RZ, který by dokázal rozpoznat typy RZ z celého světa.

OCR systém detekuje RZ v malém rozlišení (od 10pxl) a se speciální syntaxí. Pro OCR klasifikátory je nutné postupné doplňování vzorků, tak aby byl klasifikátor připraven pro kterýkoliv font (latinská abeceda a další vzory písma). [15]



Obr. 50. Celosvětová ukázka RZ [19]

II. PRAKTICKÁ ČÁST


ÚVOD DO PRAKTICKÉ ČÁSTI

Pro určení a správné rozpoznávání znaků podle předlohy je potřeba správně analyzovat objekt. Podle kritérií, která přivádí na možné problémy při identifikaci, může mít vliv i okolní prostředí. K správnému a účinnému algoritmu je zapotřebí identifikovat problémy při snímání registrační značky.

Pro praktickou část práce jsou určeny předpoklady k správnosti a funkčnosti procesu. Pro dané parkoviště bylo zkonstruováno schéma konceptu v obrazovém prostoru 2D. Pomocí těchto předloh, analýz byla navrhována a implementována databáze PARKOVISTE, která svou charakteristikou a integrací je spojena právě s optickým rozpoznáváním registračních značek dle předlohy. Registrační značky jsou dále ukládány do databáze, fungující jako předlohy pro další vjezdy těchto vozidel do objektu. Výsledek činnosti by měl urychlit odbavení ze ZS.

8 NAVRHNĚTE MOŽNÉ ŘEŠENÍ ROZPOZNÁVÁNÍ ZNAKŮ NA REGISTRAČNÍCH ZNAČKÁCH AUTOMOBILŮ

Prvním krokem praktické části diplomové práce je výběr, posouzení a analýza objektu určené k detekci RZ. Objekt lze charakterizovat či zařadit jako menší parkovací plocha, obsahující přibližně 30 parkovacích míst. Na základně architektského návrhu byla stanovena kapacita vozidel v areálu zimního stadionu ve Zlíně. Letecký snímek (Obr. 51.) byl převzatý ze zdroje pořízené společnosti Mapy.cz [26]. K rozšíření působnosti při vjezdu a výjezdu byl navržen druhý vjezd/výjezd. Pro zcela základní lokalizaci RZ potřebujeme umístit na každé straně před vjezdem do areálu záznamové zařízení CCTV.



Obr. 51. Letecký záběr parkoviště ZS ve Zlíně

Druhým krokem přecházíme k návrhu parkoviště po rekonstrukci. Za pomoci technického programu ArchiCad a AutoCad, bylo navrženo cca 30 parkovacích míst uspořádané ke kolmému a svislému zaparkování. Softwarem bylo implantováno snímací zařízení CCTV. V příhraničním objektu je umístěno pouliční osvětlení. Dané osvětlení není určeno k nasvětlení - sloužící k detekci RZ. Okolní osvětlení deklaruje na bezpečnost personálu popř. vozidel, které jsou stanoveny na parkovišti nebezpečným zákoutím.

8.1 Základní problémy při identifikaci

- Přírodní vlivy: hustý déšť, mlha, sněžení
- Technické problémy: špatně umístěná, nastavená kamera
- Praskliny na RZ, šrouby

8.2 Předpoklady

V databázi rozlišujeme 3 typy RZ v ČR:

- Verze RZ do roku 1994
- Verze RZ od roku 1994
 - bez EU proužku 1994 – 2001
 - s EU proužkem od 2001

Dalším předpokladem navrhuji správný - odpovídající úhel α (stejný) a vzdálenost záběru l , při určité výšce h kamerového zařízení. Záběry značek by měli být nejmenší odchylku ohledně daného náklonu. Tvar registračních značek je zkonstruovaný pouze pro obdélníkový tvar (čtvercová RZ nebyla vyskytnutá). Důvodem, proč je využit jen obdélníkový tvar spočívá na základě vozidel zpřístupněných do areálu. Povolený přístup do objektu mají pouze vozidla hokejového oddílu. Obzvláště se jedná o vozidla spadající mezi nejpodstatnějšími sponzory daného sdružení. Značky k detekci by měli být co nejvíce čitelné a nejméně poškozené. Nečitelné značky, které mohou být přelepené v našem případě, tj. u stacionárního parkoviště nesetkáme.

Navrhované záznamové zařízení:


Pro navrhovaný systém byl navrhnout, využít IR kamery s přísvitom, popř. s externím IR přísvitom => důvodem je hliníková konstrukce RZ, na nichž je polep z reflexní fólie. Lesklost a veliká odrazivost se projevuje především u RZ z členských států EU.

8.3 Koncept realizace RZ na parkovišti

Pro skutečný záznam potřebujeme pořídit digitální obraz, který je počátečním vstupem struktury systému. Tento skutečný návrh, aplikovaný v praxi je zařazen na příslušné místo umožňující vjezd do objektu. Prvotním místem se přiřazuje pozice, při nichž vozidlo přijíždí rychlostí do 15km/h k bezpečnostní závoři, která povolí vjezd do objektu. Téměř by se dalo uvést, že rychlost je nulová, která ovšem zaručuje daleko lepší snímatelnou RZ,

než třeba sejmutí obrazu při úsekovém měření. Nutno podotknout, že při snímání vozidla na rychlostní komunikaci první třídy je průměrná rychlost cca ± 90 km/h.

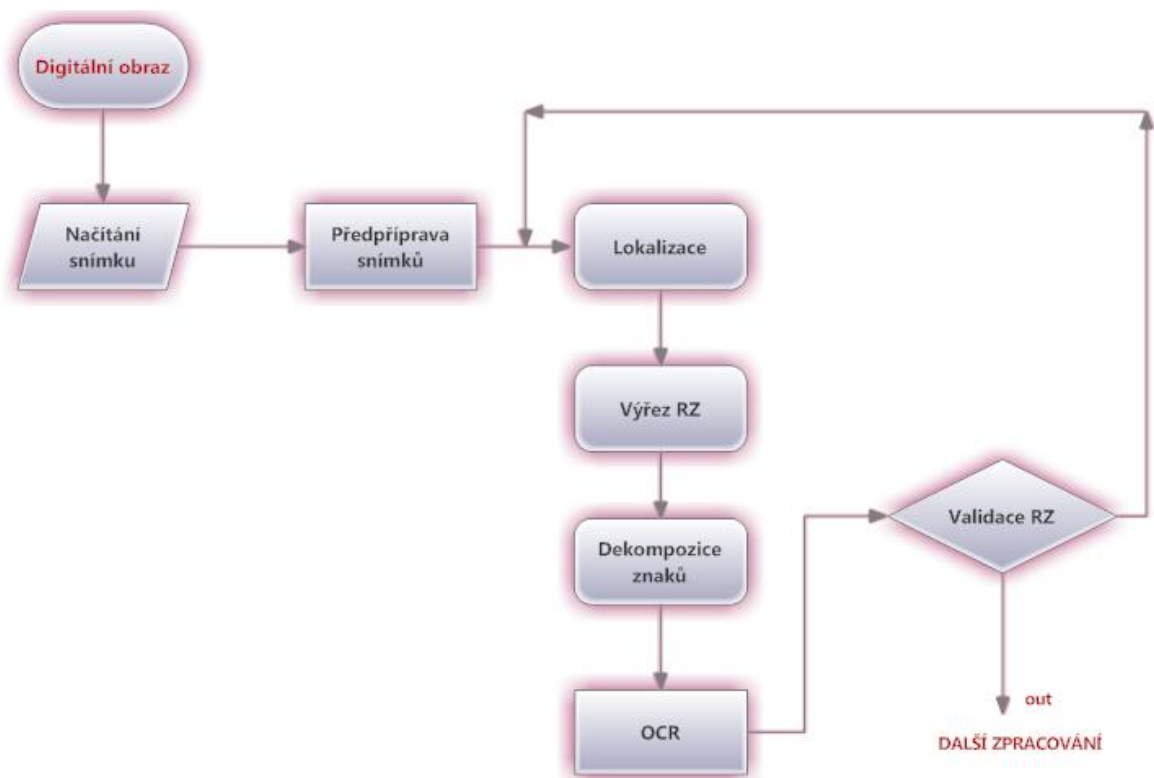
Důležitým afektem při realizaci stacionárního parkoviště je správné rozmístění CCTV zařízení. Podle navrženého konceptu parkoviště (Obr. 52.), by snímací zařízení mělo svírat úhel $\pm 30^\circ$ s vozovku (vjezd do objektu). K výpočtu úhlu se stává důležitým fyzikálním parametrem vzdálenost, podle nichž se dopočítává optimální výška. Výška kamery byla navržena ± 10 m.



Obr. 52. Koncept parkoviště ve struktuře 2D

8.4 Vývojový diagram vozidel určené k identifikaci RZ

Před samotným návrhem vývojového diagramu je důležité si určit, pro kterou část snímacího zařízení bude využita. Teoretická část vybízí ke třem základním možnostem. První z nich je úsekové měření, další rozšířenou možností jsou mýtné brány. Třetí část, kde lze využít detekci snímacího zařízení nastává právě v tomto případě - detekce, lokalizace a identifikace RZ pro vjezd do objektů. K bezproblémové funkčnosti daného systému, lze zaručit správným návrhem pro kompletní rozložení jednotlivých částí určující ke zpracování. Spolehlivost systému je zakládána na akceptovatelném určení závěrečných výsledků při vyhodnocení.



Obr. 53. Struktura systému rozpoznávání RZ vozidel

Prvotní koncept s danou charakteristikou parametru, v němž byl proveden záznam obrazu byla rozebrána. Druhým krokem je správná lokalizace polohy RZ, které ještě předchází zpracování (předpříprava) obrazu. Lokalizace zahrnuje řadu přínosných elementů. Pomocí lokalizace byla určena přesná poloha jednotlivých znaků, z kterých je RZ složena. Prvkem navazující na lokalizaci nazýváme výřez. Výřezem lze chápat jako danou část předúpravy registrační značky, symbolizující písmena a číslice. Do předúpravy samotné spadá ořez

RZ, natočení - rotace RZ, průběh (histogramu) jasové funkce obrazu RZ. Tady je možno naleznout i další úpravy z pohledu případného zkreslení, rozmazání apod. Předúprava obrazu je velice prospěšná pro následující kroky vedoucí k její segmentaci a analýze znaků. Upravený obraz (výřez) za pomoci konstrukční prvku SW je v nadcházející části zpracování důležitý pro dekompozici znaků. Zda-li se setkáme s obrazem, který bude mít z většiny části znaků nerozeznatelných, pak právě na principu dekompozice budou tyto nevyhovující prvky odstraněny.

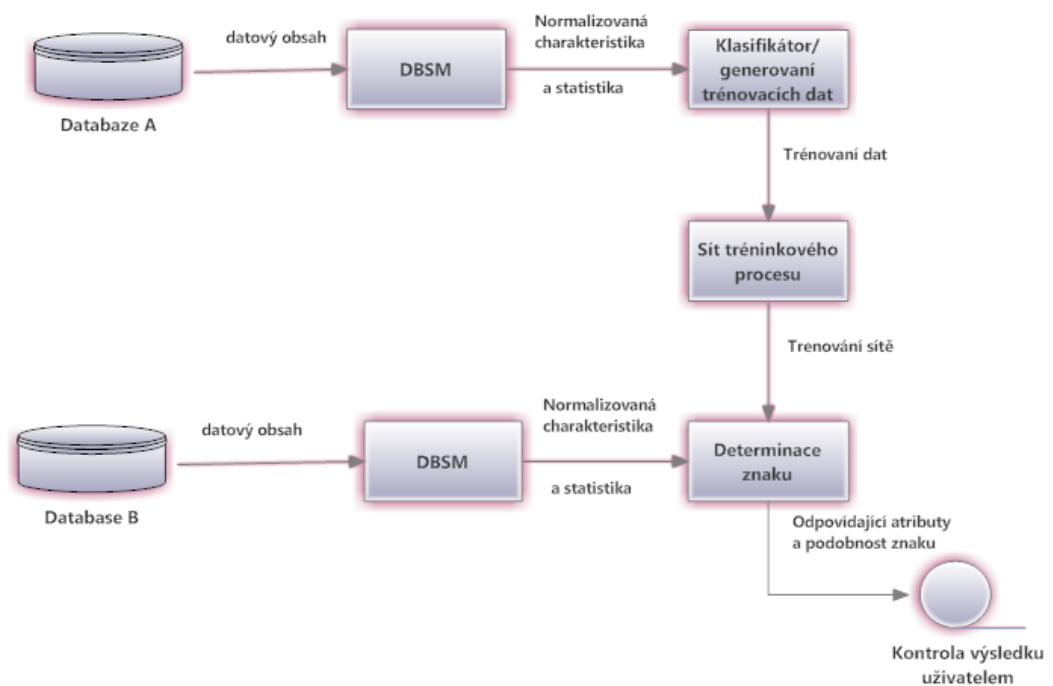
Jednotlivé znaky rozdělené na RZ jsou dále rozpoznávány pomocí optického rozpoznávání obrazu. Způsobu jak rozpoznat znaky je velká řada. Z pohledu RZ je potřeba vytvořit určitou síť. Pro detekci RZ pro tvorbu diplomové práce byla využita Hopfieldová síť.

9 NÁVRH APLIKACE NA AUTOMATICKÉ ČTENÍ A UKLÁDÁNÍ ZNAČEK PŘI VJEZDU DO OBJEKTU

9.1 Integrace databáze

Návrhem této metody se dostáváme k vygenerování atributových shluků referenční databáze. V praxi označované taky jako trénovací databáze. V trénovací databázi je zkoumán každý atribut, kde k atributu přiřazujeme částečný stupeň „fuzzy“ jednotlivých shluku. Tímto krokem vytvoříme schéma spojující databáze. Pro úplnost lze říci, že vývojovým diagramem je naučena a vytvořena neuronová síť.

„Fuzzy přístup v DBS označuje snahu o využití snahy logiky pro reprezentaci, ukládání a získávání komplexních nepřesně definovaných informací z objektově orientovaných DBS.“

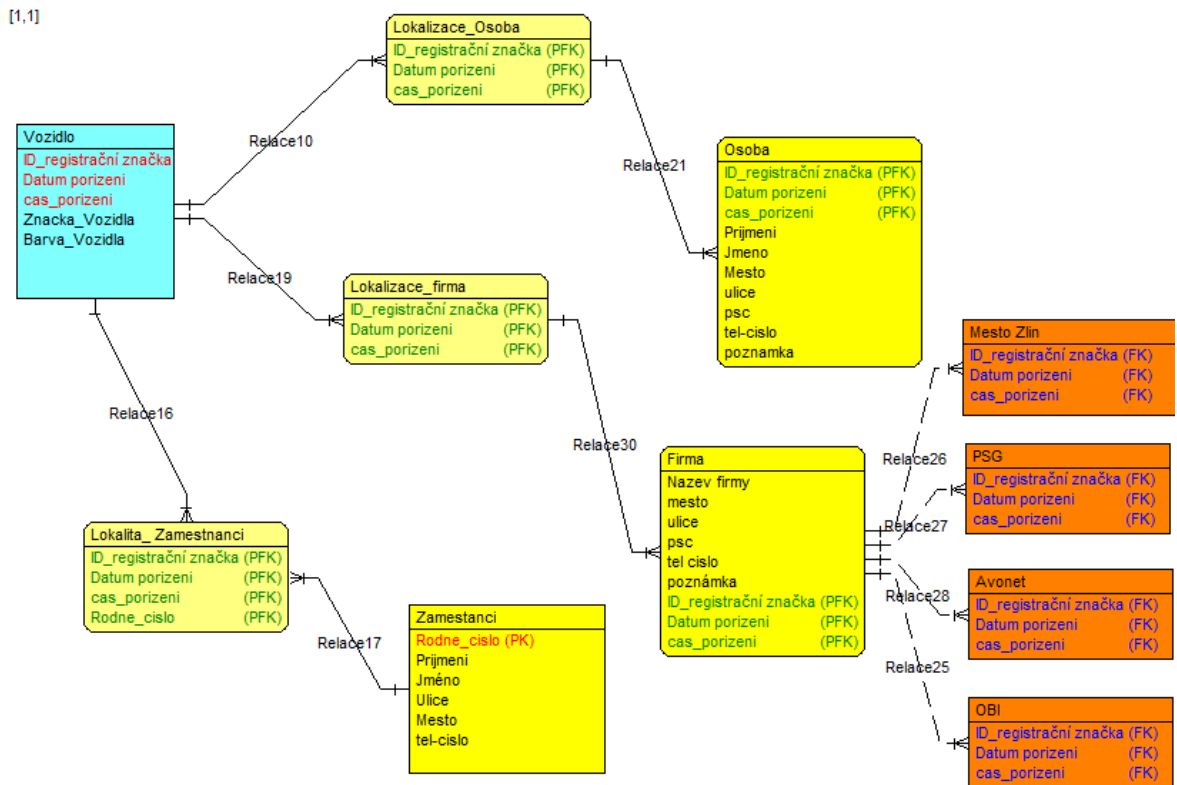


Obr. 54. Integrace DBS s neuronovou sítí

V druhé části schématu se jakékoliv atributy z odlišných databází prezentují a následně se přiřazuje stupeň fuzzy - příslušnost k atributovým shlukům. V závěrečné části uživatel kontroluje správnost shluku, upřesňující rozpoznatelnost znaku. Shluky jsou nadále předávány NS jako výstup trénovací množiny. Neuronové sítě se předkládají i trénovací vzory, sloužící k jejich uložení do databáze. V dalším průběhu kroku jsou na naučených NS testovány atributy z ostatních databází. K jednoduššímu pochopení, lze říci, že RZ

uloženy v databázi jsou příslušnými šablonami v databázi B porovnávány a základě shody shluku jsou vozidla vpouštěny do objektu.

Typ relace: M:N



Obr. 55. E-R diagram databáze parkoviště

Vytvoření tabulek:

Např.:

```
CREATE TABLE [Osoba] ([id_registracni_znacka] INT PRIMARY KEY, [jmeno]
VARCHAR(25) NOT NULL, [prijmeni] VARCHAR(25) NOT NULL, [jmeno] INT NOT
NULL, [mesto] INT NOT NULL, [ulice] VARCHAR(25),)
```

```

25
26 Create table Vozidlo (
27   ID_registra_n_zna_ka Char(20) NOT NULL,
28   Datum_porizeni Datetime NOT NULL,
29   cas_porizeni Time NOT NULL,
30   Znacka_Vozidla Varchar(20) NOT NULL,
31   Barva_Vozidla Varchar(20) NOT NULL,
32   Primary Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni)) ENGINE = MyISAM;
33
34 Create table Osoba (
35   ID_registra_n_zna_ka Char(20) NOT NULL,
36   Datum_porizeni Datetime NOT NULL,
37   cas_porizeni Time NOT NULL,
38   Prijmeni Char(20) NOT NULL,
39   Jmeno Char(20) NOT NULL,
40   Mesto Char(20) NOT NULL,
41   ulice Char(20) NOT NULL,
42   psc Date NOT NULL,
43   tel_cislo Date NOT NULL,
44   poznamka Char(20) NOT NULL,
45   Primary Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni)) ENGINE = MyISAM;
46
47 Create table Firma (
48   Nazev_firmy_sponzor Char(20) NOT NULL,
49   mesto Char(20) NOT NULL,
50   ulice Char(20) NOT NULL,
51   psc Char(20) NOT NULL,
52   tel_cislo Int NOT NULL,
53   poznamka Char(20) NOT NULL,
54   ID_registra_n_zna_ka Char(20) NOT NULL,
55   Datum_porizeni Datetime NOT NULL,
56   cas_porizeni Time NOT NULL,
57   Primary Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni)) ENGINE = MyISAM;
58
59 Create table Lokalizace_Osoba (
60   ID_registra_n_zna_ka Char(20) NOT NULL,
61   Datum_porizeni Datetime NOT NULL,
62   cas_porizeni Time NOT NULL,
63   Primary Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni)) ENGINE = MyISAM;
64
65 Create table PSG (
66   ID_registra_n_zna_ka Char(20) NOT NULL,
67   Datum_porizeni Datetime NOT NULL,
68   cas_porizeni Time NOT NULL) ENGINE = MyISAM;
69
70 Create table Avonet (
71   ID_registra_n_zna_ka Char(20) NOT NULL,
72   Datum_porizeni Datetime NOT NULL,
73   cas_porizeni Time NOT NULL) ENGINE = MyISAM;
74
75 Create table OBI (
76   ID_registra_n_zna_ka Char(20) NOT NULL,
77   Datum_porizeni Datetime NOT NULL,
78   cas_porizeni Time NOT NULL) ENGINE = MyISAM;
79
80 Create table Zamestanci (
81   Rodne_cislo Int NOT NULL,
82   Prijmeni Char(20) NOT NULL,
83   Jm_no Char(20) NOT NULL,
84   Ulice Char(20) NOT NULL,
85   Mesto Char(20) NOT NULL,
86   tel_cislo Date NOT NULL,
87   Primary Key (Rodne_cislo)) ENGINE = MyISAM;
88
89 Create table Lokalita_Zamestnanci (
90   ID_registra_n_zna_ka Char(20) NOT NULL,
91   Datum_porizeni Datetime NOT NULL,
92   cas_porizeni Time NOT NULL,
93   Rodne_cislo Int NOT NULL,
94   Primary Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni,Rodne_cislo)) ENGINE = MyISAM;
95
96 Create table Lokalizace_firma (
97   ID_registra_n_zna_ka Char(20) NOT NULL,
98   Datum_porizeni Datetime NOT NULL,
99   cas_porizeni Time NOT NULL,
100  Primary Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni)) ENGINE = MyISAM;
101
102 Create table Mesto_Zlin (
103   ID_registra_n_zna_ka Char(20) NOT NULL,
104   Datum_porizeni Datetime NOT NULL,
105   cas_porizeni Time NOT NULL) ENGINE = MyISAM;
106

```

```

107
108 Alter table Lokalizace_Osoba add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Vozidlo (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;
109 Alter table Lokalita_Zamestnanci add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Vozidlo (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;
110 Alter table Lokalizace_firma add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Vozidlo (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;
111 Alter table OBI add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Firma (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;
112 Alter table Mesto_Zlin add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Firma (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;
113 Alter table PSG add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Firma (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;
114 Alter table Avonet add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Lokalizace_Osoba (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;
115 Alter table Osoba add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Lokalizace_Osoba (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;
116 Alter table Lokalita_Zamestnanci add Foreign Key (Rodne_cislo) references Zamestanci (Rodne_cislo) on delete restrict on update restrict;
117 Alter table Firma add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Lokalizace_firma (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;
118

```

Obr. 56. Tvorba tabulek a atributu

9.1.1 Naplnění Tabulek

Připravené tabulky byly naplněné daty.

```
insert into Vozidlo (ID_registracni_znacka, datum_porizeni, cas_porizeni, znacka_vozidla, barva_vozidla)
```

```
values
```

```
(2L9 5262, '2012-3-15', '15:30:20', FORD, modra),  
(2Z3 6344, '2012-3-15', '15:31:58', AUDI, seda),  
(4T2 6587, '2012-3-15', '15:37:35', SKODA, zluta),  
(1Z1 2681, '2012-3-15', '15:45:12', CITROEN, bila),
```

```
insert into OSOBA (prijmeni, jmeno, mesto, ulice, psc, tel-cislo, poznamka)
```

```
values
```

```
(Zajíc, Karel, 'Zlín', 'Podlesí I', 760 05, 777 777 777),  
(Kamas, Jaroslav, 'Zlín', 'Bartosova', 760 05, 777 777 776),  
(Okal, Miroslav, 'Vsetín', 'Lidicka', 760 05, 777 777 778),
```

```
insert into Firma (ID_registracni_znacka, datum_porizeni, cas_porizeni, Nazev firmy, mesto, ulice, psc, tel-cislo, poznamka)
```

```
values
```

```
(1,106,3, '2011-06-15',14),  
(2,111,1, '2011-08-10',7),  
(17,113,4, '2011-07-05',9),
```

```
insert into Zamestanci(prijmeni, jmeno, mesto, ulice, psc, tel-cislo, poznamka)
```

```
values
```

```
(Balastik, Karel, 'Zlín', 'Podhoří I', 760 05, 777 777 775),  
(Leska, Jaroslav, 'Zlín', 'Vrsava', 760 05, 777 777 774),  
(Cajánek, Miroslav, 'Vsetín', 'Stefanikova', 760 05, 777 777 773),
```

K vytvoření tabulek byl použit příkaz CREATE TABLE, následnému naplnění tabulek dat napomohl příkaz INSERT INTO. Na základě vytvořené databáze PARKOVISTE můžeme pracovat s uloženými daty, které máme kdykoliv k nahlédnutí. Pomocí základních dotazů ve strukturovaném jazyce SQL lze dospět k rychlejší, přesnější informacím a záznamům pomocí vytvořené databáze.

Základní fáze dotazu v SQL:

Select ...výběr atributu z tabulky

From ... výběr databáze

Where ...podmínka dotazu

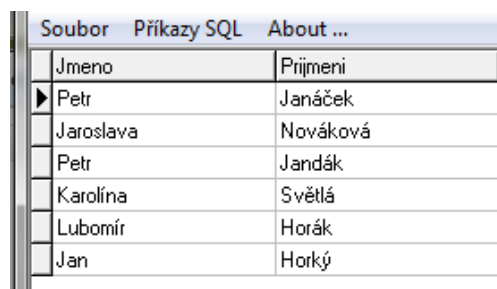
Order by ... setřídění podle abecedy

Např.:

```
select ID_registracni_znacka, datum_porizeni, cas_porizeni, Nazev_firmy, mesto, ulice, psc, tel-cislo  
from parkoviste  
where sponzor ='PSG'  
order by prijmeni
```

Názorná jednoduchá ukázka vygenerovaného dotazu na základě atributu- jméno, příjmení zobrazena v databázi parkoviště. K zobrazení registrační značky, stačí přiřadit atribut ID_registracni_znacka. Následně budou vygenerovány všechny RZ zaznamenané v databázi. V jazyce SQL existuje řada dotazů. Pro tento typ databáze velice rádi využijeme časové dotazy. Časový dotaz je založen na datu příjezdu vozidla do objektu a taky časovému rozhraní. Ke každé registrační značce je plně přiřazena informace o příjezdu či odjezdu.

Jedná se o hierarchické uspořádání databáze. Souhrnný výpis dat nalezneme v příloze PIV.



Jmeno	Prijmeni
Petr	Janáček
Jaroslava	Nováková
Petr	Jandák
Karolína	Světlá
Lubomír	Horák
Jan	Horký

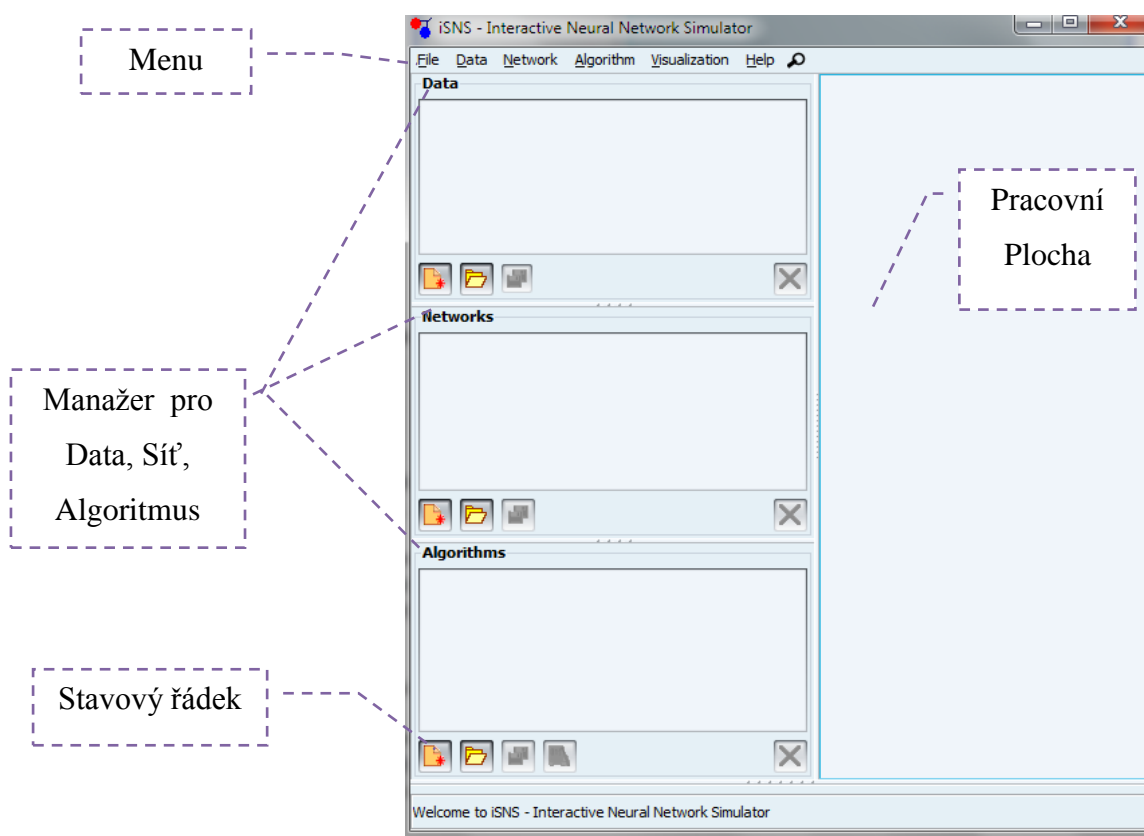
Obr. 57. Select dotazu v SQL

9.2 Detekce RZ pomoci Hopfieldovi sítě

K navržení neuronových sítí byl použit program určený jako interaktivní simulátor NS. Vycházeno bylo ze základních teoretických poznatků, při nichž byly rozepsány individuální neuronové sítě. Pro výběr neuronové sítě byly navrženy podle předpokladu pro Hopfieldovou síť. Tato síť je nadefinovaná k vytváření znaků využitelných na registračních značkách. Prvními kroky po vytvoření a nastavení sítě se ukládají šablony nadefinovaných znaků (písmena a číslice). Podrobnou strukturu těchto šablon a vytvoření sítě se dozvíte v následujících krocích praktické části diplomové práce.

9.3 Interaktivní simulátor neuronových sítí - iSNS


Program pro tvorbu neuronových sítí obsahuje základní menu, manažery dat - sítí a uživatelských algoritmů. Po otevření programu je možnost vytvoření vždy nového projektu. Podobně jako u ostatních programů lze ukládat a otevírat nadefinované sítě na disk určené k detekci a lokalizaci RZ.



Obr. 58. iSNS základní pracovní plocha

Důvodem proč byla vybrána právě Hopfieldovu síť se zakládá na své charakteristice. Hopfieldová síť pracuje jako autosociativní paměť. Tento charakteristický rys pojednává o zapamatovatelnosti informací resp. digitálních obrázků. Výhodou této sítě spočívá ve vybavení obrazu, které je neúplné nebo částečně poškozené. V porovnání se šablonou, předlohou dokáže vykryštalizovat jednotlivé písmena a číslice registrační značky. Nastane-li případ, v němž předloha je velmi nečitelná, dochází k tomu, že neuronová síť nenalezne v šablonách programu uloženou registrační značku v databázi. Sled těchto procesů a kroků spočívá v několika sekundách. Bude-li značka nečitelná, kamerové zařízení provede opětovný úkon, ve kterém provede nový záznam a přešle k OCR do databáze. Kapacita sítě je určena pomocí výpočtu, který lze vypočítat. Do paměti, která je zkonstruována lze uložit cca 50 vzorů. Kapacita závisí na vlastnostech jednotlivých vzorů. Z toho vyplývá, že pro registrační značky odpovídá předepsaná kapacita.

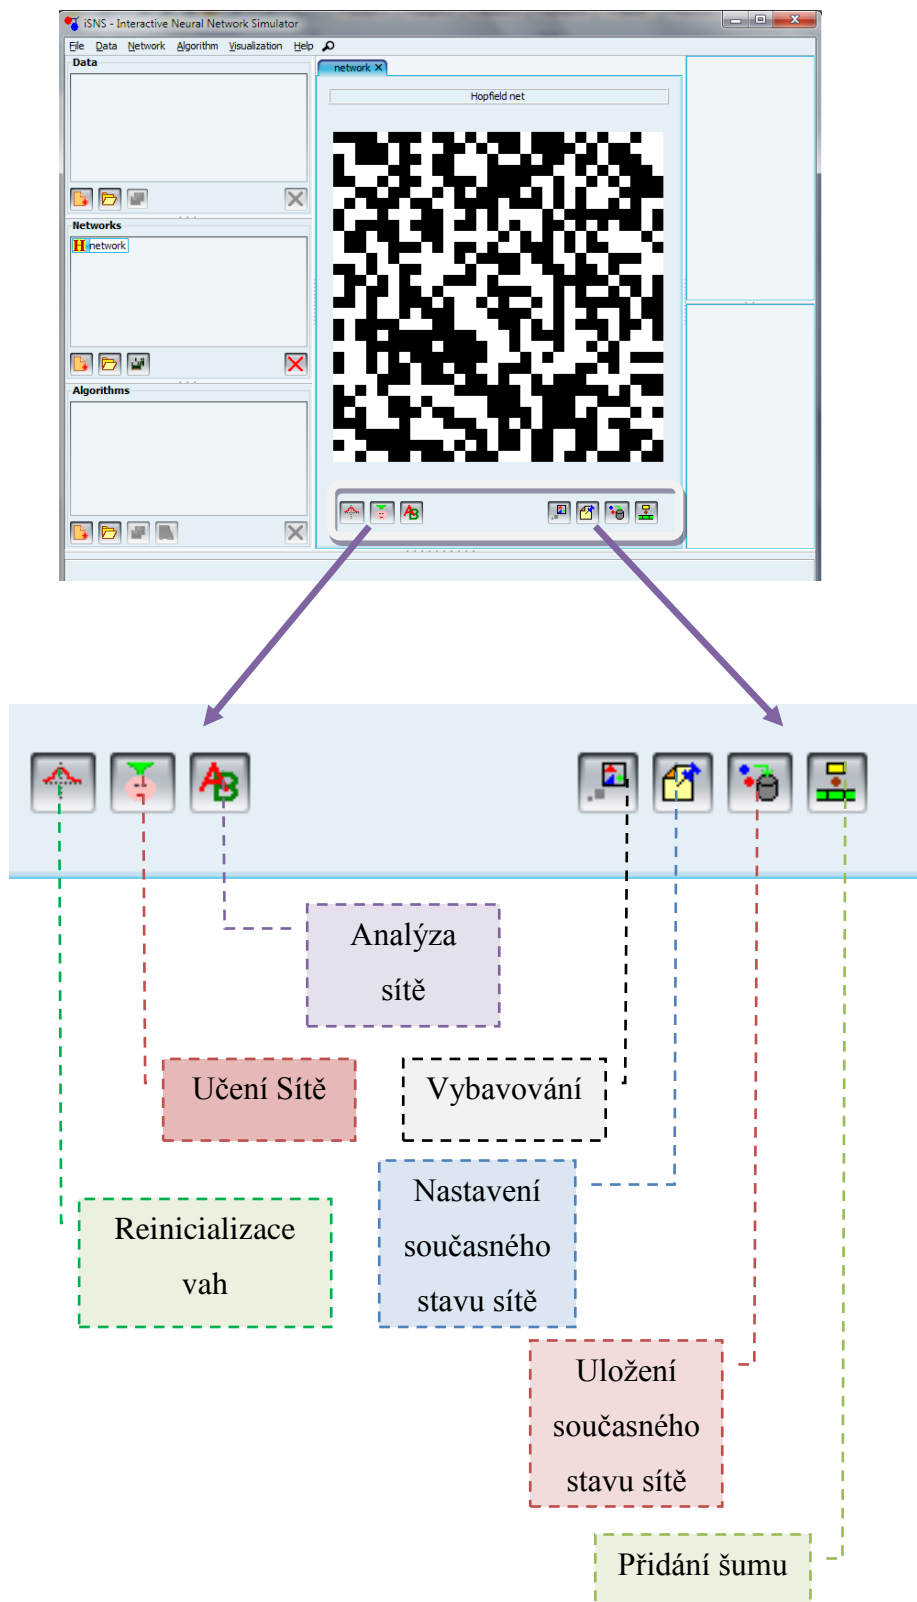
Základním prvkem je potřeba vytvoření už dříve zmiňované sítě Hopfield. V menu, kde se rozkryje tabulka s výběrem neuronových sítí, vybereme síť Hopfield_net. Danou síť si pojmenujeme Hopfield_SEIDL. K vytvoření této sítě potřebujeme zadat ještě výšku a šířku obrázku, v našem případě jednotlivých regionů RZ. Nejvíce používaným rozměr je 30x30.



Obr. 59. Vytvoření Hopfieldové sítě

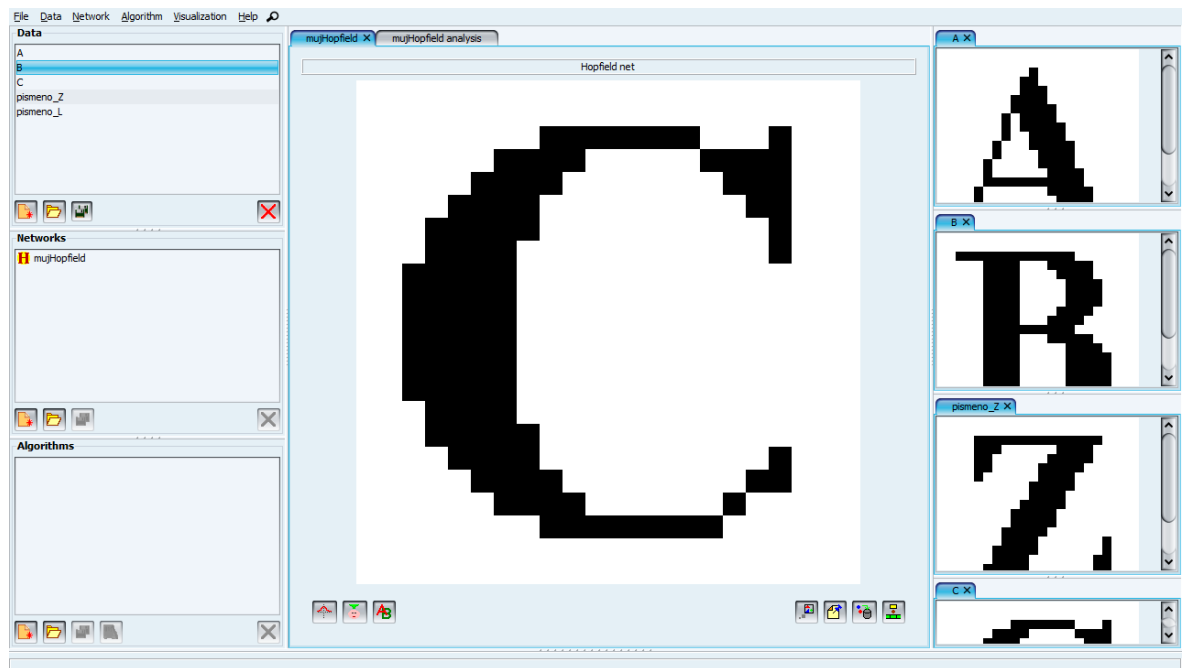
Dialog new net:

- **Name** - uživatelské jméno sítě,
- **Model** - zde je možné zvolit model sítě, tedy nyní Hopfield net,
- **Height /width of neuron grid** – výška/šířka obrázku používaného pro zobrazení současného stavu sítě,

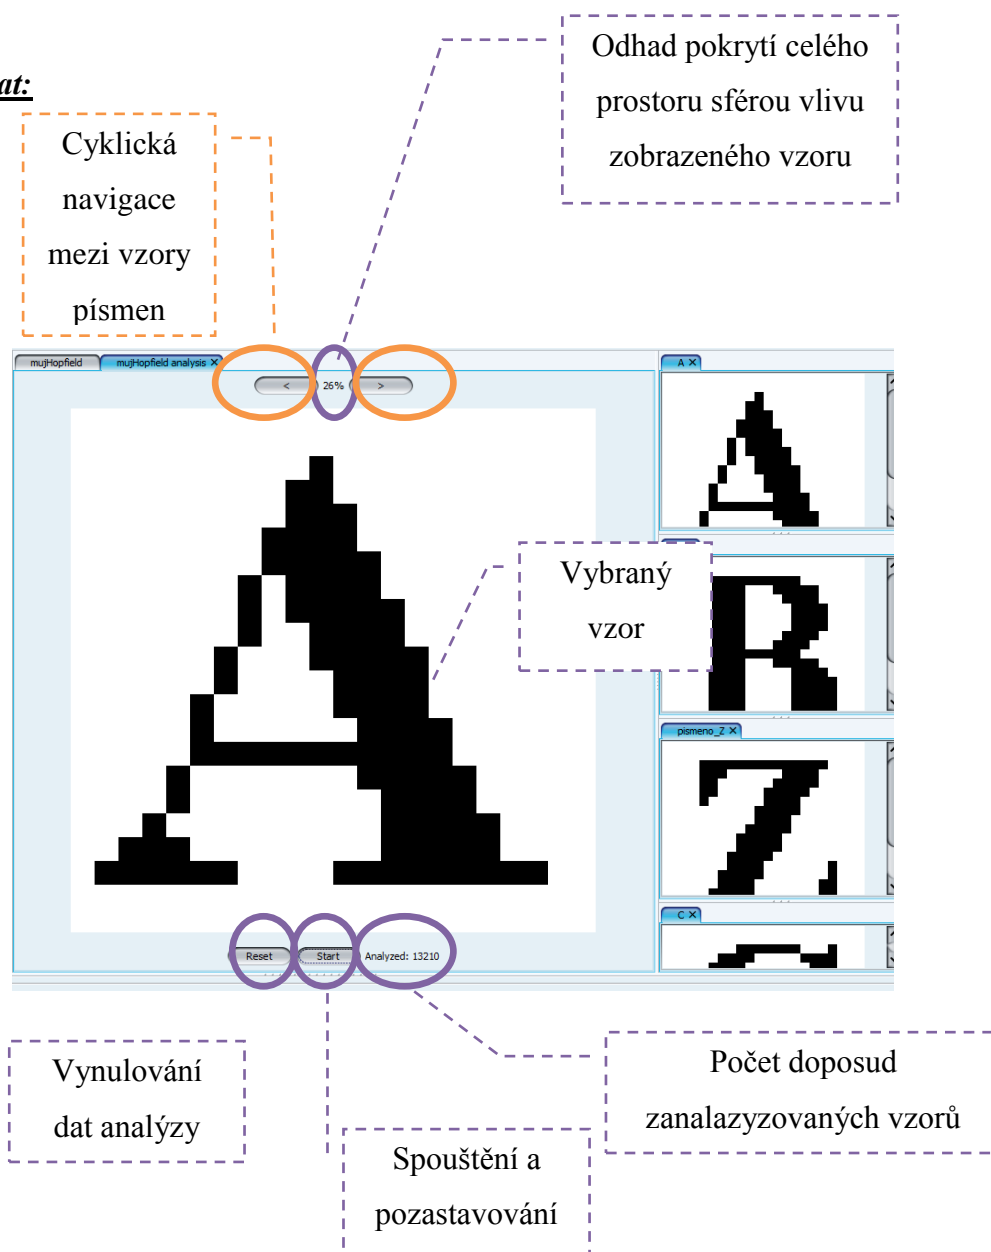


Obr. 60. Hlavní panel sítě Hopfield

V nově vytvořené síti lze vidět jednotlivé stavy neuronů jako náhodné. Z tohoto důvodu na začátku práce se síť zobrazuje šum. V průběhu, kdy síť budeme vybavovat jednotlivými písmeny přejde k určitým změnám na pozice šablon. Pro doladění písmen a číslic je možno jednoduše doopravit ručně. Pixel obrázku neuronu se dá snadno přepnout z aktivního režimu do neaktivního a naopak. Reinicializace vah plní funkci vynulování matic vah a vektoru prahů – kdykoliv při práci se sítí.



Obr. 61. Vytváření šablony znaků RZ

Analýza dat:

Obr. 62. Analýza znaků - Hopfieldovi síť

Princip analýzy je na statickém, ne-li místním postupu. Algoritmus vygeneruje vzor, který nastaví jako současný stav sítě. Dále je spuštěna podprocedura algoritmu, tak aby byl najit stabilní stav, v němž síť dokonverguje podle daného vzoru.

Algoritmus znaku:

Algoritmus, který byl použit MyRecollection je vestavěný a pevně přednastavený. Pro svůj úsudek jsem vyzkoušel i originální algoritmus. Možnost tvorby dalších algoritmů se nevyklučuje, nabídka je široká.



Obr. 63. Algoritmus
MyRecollection

```

double res = 0;

int size = hopfNet.getSize();
double[] x = hopfNet.curVec;
double[] w = hopfNet.weights;
double[] b = hopfNet.biases;

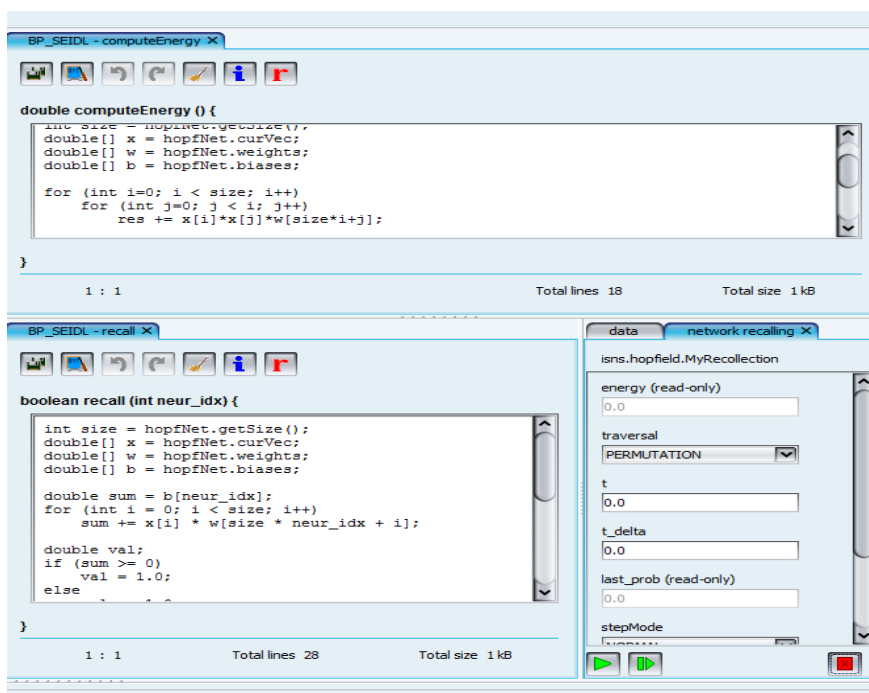
for (int i=0; i < size; i++)
    for (int j=0; j < i; j++)
        res += x[i]*x[j]*w[size*i+j];

    res *= -1.0;

for (int i=0; i < size; i++)
    res += b[i]*x[i];

return res;

```



Obr. 64. Krokování algoritmu

9.3.1 Typy dat, komprese

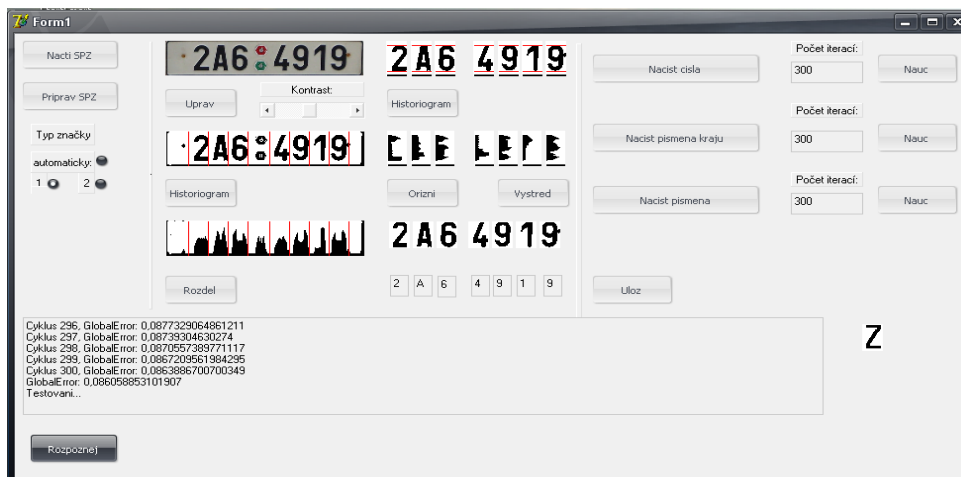
V této práci pracujeme celou dobu s obrázky, znaky a s číslicemi. Z takového množství informací je přiváděno i na fakt, že objem dat bude vzhledem k rozlišení dostatečně veliký. K tomu, abychom zmenšili data tvořené obrázky je potřeba provést kompresi dat. Mezi známé grafické formáty patří např. *JPEG*, *GIF* a nebo *PNG* - konkrétní vypočítání závisí na podpoře těchto formátů běhovým prostředím Javy (JRE), pod kterým program iSNS běží. V případě, že načítaný obrázek není pouze černobílý, budou všechny pixely nečerné barvy převedeny na bílé.

Datové proměnné typu obraz lze navíc, vedle výše popsaných způsobů, také načítat ze souborů grafických formátů a ukládat do souborů formátu *PNG*.

- Pro importování dat stačí zvolit v menu *Data -> Import data -> Picture* a vybrat soubor některého z podporovaných grafických formátů. Bude tak vytvořena nová datová proměnná typu obrázek s daty vybraného souboru.
- Pro exportování dat je třeba mít označenou datovou proměnnou typu obrázek, jejíž obsah se bude exportovat; v menu zvolit *Data -> Export data -> Picture* a zadat název souboru (s příponou *png*), kam se obsah proměnné uloží.

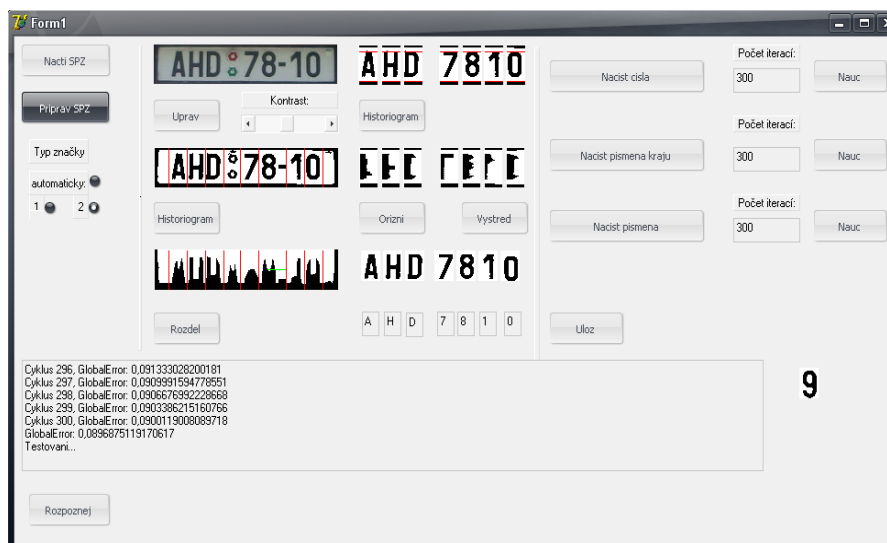
9.3.2 Ukázková tabulka databáze v integraci s OCR – implementace:

V menu databázové struktury jsou zobrazeny jednotlivé části práce, kterými byla práce zabývána. V prvním obrázku (Obr. 78.) jsou zobrazeny digitální data, pořízené ze záznamového zařízení. Digitální obraz přeneseny do databáze následně je porovnáván pomocí funkce segmentace znaku jednotlivých regionů. Tímto postupem trénujeme a učíme nové prvky neuronovou síť, která se zabývá touto rozlišovací možností.



Obr. 65. Nový typ RZ – rozdělení podle krajů

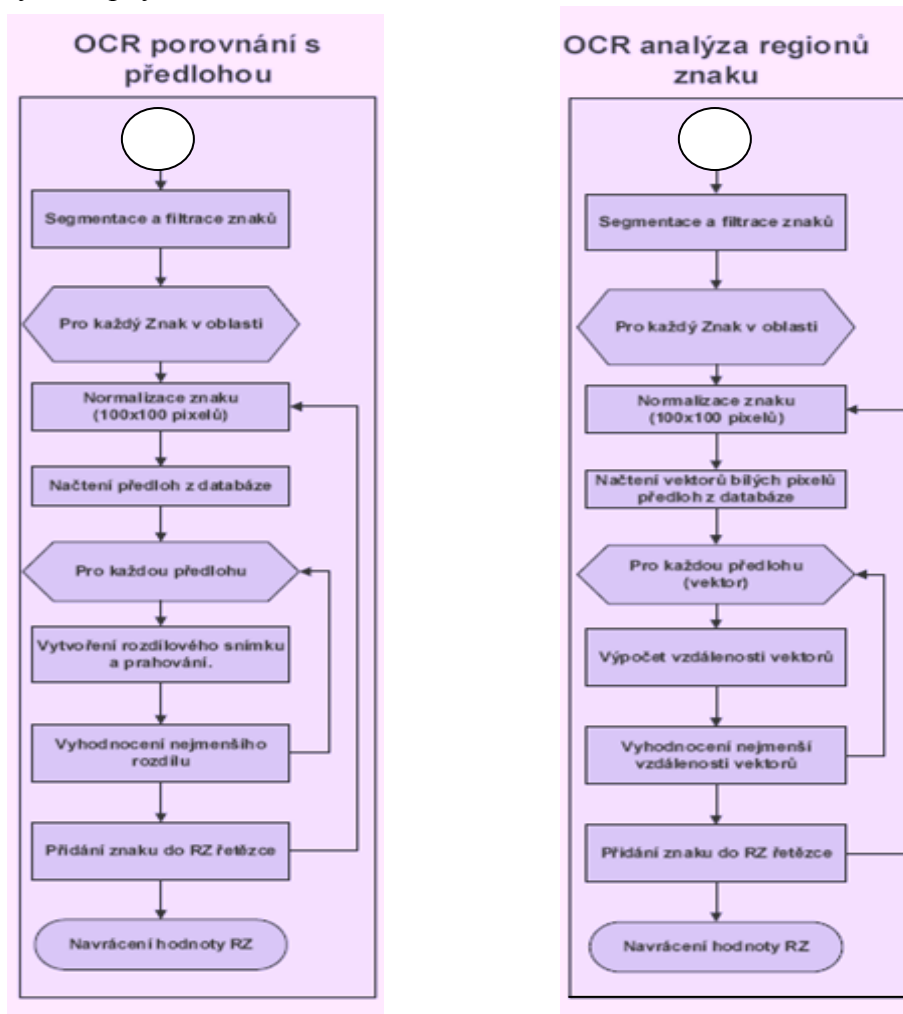
U architektury sítě nelze opomenout i na starší typ RZ používané v ČR. Oproti první verzi, kde stromová architektura byla stanovena číslo – písmeno - číslo a další čtyři čísla. Naopak starší typ RZ je skládán ze tří písmen a čtyř číslic (Obr. 66.).



Obr. 67. Starý typ RZ – Rozdělení podle okresů


- Testování OCR
 - OCR - optické rozpoznávání znaků

S testováním RZ ve větší míře nedocházelo k problémům. I špatně nasvětlený, rozmazaný obraz byl schopný k identifikaci RZ.



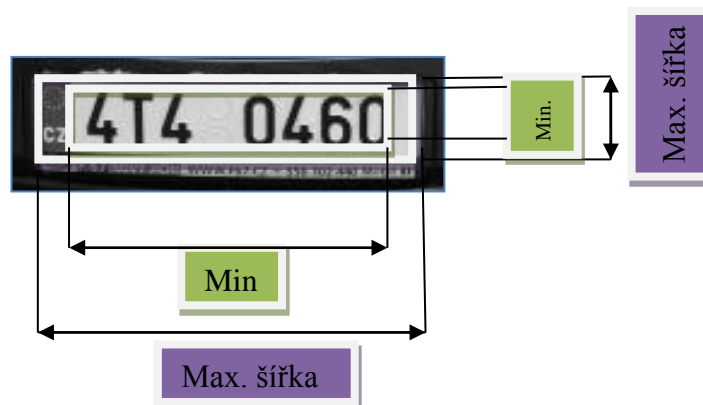
Obr. 68. Struktura OCR

Zde můžeme vidět převádění digitalního obrazu do znakové podoby s kterou je následně ukládán do databáze. Algoritmus regionu se zakládá na maximálních a minimálních hranicích obdélníku.



Obr. 69. Testování RZ pomoci OCR

- **Regiony**
 - Pouze regiony, které mají opsaný obdélník, v této detekční oblasti se dále podrobují dalším testům na rozpoznání RZ a optickému rozlišení znaku.



Obr. 70. Parametry RZ určené k identifikaci


- **Technické parametry záznamového zařízení CCTV:**

Pomocí snímacího zařízení byl prováděn záznam obrazu, kdy snímací frekvence vyhotovila i 32 snímků za sekundu. Z toho vyplývá, že počty snímků, které jsou zpracovány budou dosahovat i velké účinnosti správně identifikovaných znaků. Rozlišení kamery v pixelech činí 1294 x 964. Snímač, který byl navržen na základě teoretických poznatku byl i zakomponován v praktické části. Obrazový snímač CCD s velikostí 1/3“ pokrývá i okolní prostor parkoviště ke střežení objektu. Ohnisková vzdálenost objektivu se určuje na základě elevace a minimálním počtu obrazových pixelů (bodů) na šířku RZ. Úhel (elevace) byl stanoven na 30°. Nastavíme-li kameru na nižší elevaci, dojde k určitým problémům. Snímací vzdálenost je závislá na vzdálenosti a úhlu od místa určeného.

Prvním problémem je zakrytí vozidel jedoucích za sebou. V případě této práce, ale daná událost nehrozí, neboť právě vozidla přijíždí samostatně k bezpečnostním závorám. Zde zakrytí vozidel za sebou nehrozí.

Druhým problémem zcela zásadní nastane tehdy, když kameru umístíme do vyšší polohy. Při nadměrné výšce odpovídá výpočtu úhlu, kde může dojít k časté deformaci znaků. Potom dochází k špatnému vyhodnocení znaků a čísel, pomocí kterých by nebyl umožněn přístup na parkoviště, ačkoli by tyto šablony RZ byly uloženy v databázi PARKOVIŠTĚ.

Průměrná rychlost vyhodnocení jednoho obrázku pro detekční část 1294 x 964 pixelů čítá 0.09s. Nutné je uvést i parametry procesoru s frekvencí 1.8 GHz. Signál z CCTV je veden přímo do útrobu ZS, nejlépe do místnosti s HW prostředky umožněné k obsluze a vybavenou pracovní plochou k jejímu dohledání. Druhý signál je určen pro ovládání závoř. Vyskytne-li se déšť, mlha, sněžení popř. další nepříjemné povětrnostní podmínky, potom bezpečnostní kamera využívá IR - přísvecení, která je napájena z transformátoru umístěné v těsné blízkosti kamery.



Obr. 71. Parkoviště s osazenými RZ na pozici jimi vyhrazeny

ZHODNOCENÍ

Koncept záznamového zařízení CCTV s využitím na principu neuronových sítí mi přinesl velmi široký rozsah teoretických poznatků.

Prvotní částí bylo posouzení stávajícího objektu. Pro daný segment parkoviště nevyhovovala řada věcí k splnění základních kritérií. V areálu parkoviště ZS jsem zaznamenal nedostatky způsobené např. zastíněním CCTV prostřednictvím stromů a dalších porostů. K inovaci parkoviště jsem vytvořil koncept struktury parkoviště za pomoci softwaru Archi, Auto Cadu v rovině 2D. Součásti přestavby byly navrženy a zaimplementovány bezpečnostní řádkové kamery.

Další oblasti pro správný vývoj dané struktury bylo vytvoření databáze PARKOVISTE. K datové relaci jednotlivých entit a vazeb jsem využil služeb SW prostředku Case Studio. Základ databáze tvoří vytvořené tabulky za pomoci strukturovaného databázového jazyku SQL. Pro integraci snímacího zařízení s databází byl navržen přenos jednotlivých digitálních obrazů. Systém záznamových kamer a vyhodnocovacího SW převádí skenovaný obraz RZ vozidla do datové (.png) podoby. U obrazu v samotné výsledné části musí být provedena komprese. Důvodem je příliš velký objem dat.

Navrhnutí sítě proběhlo za pomoci softwarového prostředku iNSN určeného k trénování a simulací neuronových sítí. Základní fází bylo navrhnutí neuronové sítě. Z teoretických poznatků jsem se zaměřil na Hopfielodovou síť. Důvodem je rozdělení digitálního obrazu na jednotlivé regiony, na základě kterých byla prováděna segmentace obrazu. Pro Hopfielodovou síť bylo důležité nastavit rozměry jednotlivých znaků na RZ. Stanoveny byly rozměry 30x30. Vygenerované znaky abecedy (písmena) a číslic byly vytvořeny a následně uloženy jako vzory v databázích. Šablony s písmeny uloženy v DBS slouží jako následné porovnávání znaků na RZ. Načtené RZ v DBS jsou následně pouštěny do objektu automaticky. Všechny data byly prozkoušeny jednotlivými klasifikátorkami za pomoci analýzy znaku. Celá operace přitom postupuje max. v jednotkách sekund. Jedná se tedy o vysoce výkonný systém, který lze použít na parkovištích, garážích, vjezdech do areálů firem nebo dalších místech.

U interaktivního simulátoru neuronových sítí byl největším problémem algoritmus. Algoritmus MyRecollection je vestavěný a pevně přednastavený. Pro svůj úsudek jsem vyzkoušel i originální algoritmus. K doladování algoritmu se nám vybírá samotné podokno. Velice těžce definovaný problém nastal zvláště při lokalizaci obrázku ne-li segmentu podle různého typu fontů, tj. písma. Problémem k snímání byla zejména nečitelnost RZ. Důvodem bylo její znečištění, popř. povětrnostní podmínky, které mají zásadní vliv na snímatelnost RZ. Byla-li značka nečitelná, kamerové zařízení provede opětovný úkon, ve kterém provede nový záznam - přešle data pro optické rozpoznání znaků a následně uloží do databáze.

ZÁVĚR

Cíl práce pojednává o detekci a rozpoznání znaků registrační značky s využitím neuronové sítě. Práce popisuje teoretickou část i praktickou část s vlastním návrhem možného řešení na rozpoznávání znaků registračních značek automobilů.

Teoretická část práce je zaměřena především na analýzu objektu a všechny možné nedostatky k snímání obrazu. Výběrem lokality parkoviště bylo vycházeno z bakalářské práce. Po provedení analýzy objektu a architektského návržení konceptu parkoviště, byly za pomoci softwaru implementovány bezpečnostní prvky určené k detekci, lokalizaci a segmentaci obrazu.

Potřebné metody a postupy pro snímání digitálního obrazu registrační značky, zakládající se na principu neuronové sítě, byly podrobně rozebrány v teoretické části diplomové práce. K načerpání těchto velice potřebných základních informací byly rozepsány následující okruhy. Rozbor obrazového snímače (CCD nebo CMOS), předzpracování obrazu, segmentace obrazu, rozpoznávání číslic a písmen, neuronová síť a optické rozpoznávání znaku.

Praktická část se zabývá realizací rozpoznávání znaků na registračních značkách automobilů. Z pohledu na danou problematiku byla vyhodnocena základní ustanovení, na základě kterých probíhaly další předpoklady k funkční detekci registrační značky. Pro danou část byla navržena a i zpracována databáze. V této databázi jsou ukládána daná data o uživatelích vozidel, které by měli mít přístup do prostor tohoto areálu. Velice význačným krokem a důsledkem vyhotovení této činnosti je určitá integrace ve spojení jednotlivých praktických částí.

Z vlastního úsudku a posouzení dané části okruhu neuronových sítí, zakládající se na optickém rozpoznávání znaků, můžu vyzdvihnout rychlou odezvu přenosu digitálního obrazu do databáze záznamového zařízení. Velikým příslibem do budoucnosti nebo výzkumem by mohlo zaujmout rozpoznání registrační značky ve videosnímčích, na místo pouze jednoho snímaného obrazu. Pro rozšíření databáze by naopak bylo ještě přínosné identifikovat obličeje řidiče, kde by docházelo k rozpoznávání obličejů společně s databází hledaných osob. Z hlediska navrhovaného objektu ovšem tato činnost by nebyla využita.

ZÁVĚR V ANGLIČTINĚ

Purpose of the study deals with the detection and license plate character recognition using neural networks. This thesis describes both theoretical part and practical part with its own proposal of possible solutions to character recognition license plate of cars.

The theoretical part is focused on building and analyzing all the possible shortcomings of the imaging. Parking site selection was based on the thesis. After analyzing the architect designing the building and parking concept was implemented with the help of software security features designed to detect, locate and image segmentation.

The necessary methods and procedures for capturing digital image registration marks, based on the principle of neural networks have been extensively discussed in the theoretical part of the thesis. To get these very basic information it was necessary to write them in the following areas. Analysis of the image sensor (CCD or CMOS), image pre-processing, image segmentation, recognition of numbers and letters, neural network and optical character recognition.

The practical part deals with the implementation of character recognition registration plates on cars. From the view on the subject was evaluated basic provisions, which took place under other conditions to the registration mark detection function. Database was developed and designed for the given part. This database stores data about users of vehicles that should have access to the premises of this area. A very important step and a result of this activity is to copy a link in the integration in the individual practical parts.

From my own judgment and assessment of the range of neural networks based on optical character recognition, I emphasize quick response to the transmission of digital video recording device into the database. Great promise for future research should take car licence plate recognition in video frames instead of only one scanned image. To extend the database on the other hand it should be useful to identify the driver's face, where there was a face recognition in conjunction with a database of wanted persons. In terms of the proposed building was not this activity used.

SEZNAM POUŽITÉ LITERATURY

- [1] ZELINKA, Ivan, Zuzana OPLATKOVÁ a Roman ŠENKERŮ. UNIVERZITA TOMÁŠE BATI VE ZLÍNĚ. FAKULTA APLIKOVANÉ INFORMATIKY. *Aplikace umělé inteligence*. Zlín: Univerzita Tomáše Bati ve Zlíně, 2010. 151 s. ISBN 978-80-7318-898-6.
- [2] MAŘÍK, Vladimír. *Umělá inteligence*. 1. vyd. Praha: Academia, 2007, 544 s. ISBN 978-802-0014-702.
- [3] OLEJ, Vladimír a Petr HÁJEK. *Úvod do umělé inteligence: klasická umělá inteligence: distanční opora*. Vyd. 1. Pardubice: Univerzita Pardubice, 2009, 112 s. ISBN 978-807-3952-419.
- [4] BÍLA, J. *Umělá inteligence a neuronové sítě v aplikacích*. Vyd. 1. Praha: Vydavatelství ČVUT, 1998, 115 s. ISBN 80-010-1275-1.
- [5] POKORNÝ, Miroslav. *Umělá inteligence v modelování a řízení*. Vyd. 1. Praha: BEN, 1996, 188 s. ISBN 80-901-9844-9.
- [6] ŠIMA, Jiří a Jan NERUDA. *Teoretické otázky neuronových sítí*. 1996. Prague: MATFYZPRESS, 1996. ISBN 80-85863-18-9. Dostupné z: <http://www2.cs.cas.cz/~sima/kniha.html>.
- [7] ČERNÝ, Matěj. *Rozpoznávání registračních značek motorových vozidel*. Pardubice, 2010. Dostupné z: <http://dspace.upce.cz/handle/10195/38077>. Diplomová práce. Univerzita Pardubice.
- [8] KAČENKA, Petr. *Neuronové sítě Historie, využití neuronových sítí a často používané typy sítí*. Mariánská, © 1998. Dostupné z: <http://mks.mff.cuni.cz/library/library.php?categ=60&supcats=10>
- [9] AUTOMA: Úvod do neuronových sítí. KUKAL, Jaromír. [online]. vyd. FCC-public, © 2012 [cit. 2012-05-08]. Dostupné z: http://www.odbornecasopisy.cz/index.php?id_document=30255
- [10] Geoinformatika: Expertní a neuronové systémy. *INSTITUT GEOLOGICKÉHO INŽENÝRSTVÍ Hornicko-geologická fakulta VŠB - Technická univerzita Ostrava* [online]. ©2012 [cit. 2012-05-08]. Dostupné z: <http://geologie.vsb.cz/geoinformatika/kap07.htm>

- [11] FEUEREISL, Dalibor. RZ: Sdružení přátel značek. RZ, o.s. *Czech-plate* [online]. ©2008 [cit. 2012-05-08]. Dostupné z: <http://www.czech-plate.cz/html/odkazy.htm>
- [12] Camea image and signal processing. *Camea* [online]. © 2012 [cit. 2012-05-08]. Dostupné z: <http://www.camea.cz/>
- [13] Perceptron Learning Applet. *Algorithm* [online]. © 2012 [cit. 2012-05-08]. Dostupné z: <http://lcn.epfl.ch/tutorial/english/perceptron/html/index.html>
- [14] European License Plates. *Authentic European Plates* [online]. [8 May 2012]. [cit. 2012-05-09]. Dostupné z: <http://www.licenseplates.tv>
- [15] Makeuseof. *Cool Websites, Software and Internet Tips* [online]. © 2012 [cit. 2012-05-09]. Dostupné z: <http://www.makeuseof.com/>
- [16] Espézetka: fenomén motorismu. HÁJEK, Michal. *České registrační značky* [online]. © 2007–2012 [cit. 2012-05-09]. Dostupné z <http://www.3260.cz>
- [17] World license plates. *LICENSE PLATES OF THE WORLD* [online]. © 2012 [cit. 2012-05-09]. Dostupné z: <http://www.worldlicenseplates.com/>
- [18] ROTTENSTEINER, Peter. Einige meiner Radtouren. *Peter Rottensteiner Bruck* [online]. ©2001-2012 [cit. 2012-05-09]. Dostupné z: <http://www.rottens.salzburg.at>
- [19] Eyedea Recognition: Čtení poznávacích značek pro statické kamery. *Čtení poznávacích značek* [online]. Eyedea Recognition, & 2010 [cit. 2012-05-09]. Dostupné z: <http://eyedea.cz/>
- [20] Umělá inteligence a neuronové sítě v aplikacích: NN-Toolbox, Higher Order Nonlinear Neural Unit. BUKOVSKÝ, Ing. Ivo. *Ivo Bukovský UI* [online]. © 2006 - [cit. 2012-05-09]. Dostupné z: <http://www.fsid.cvut.cz>
- [21] Encyklopedie síťového videa. *Obrazové snímače CCD vs. CMOS* [online]. © 2011 [cit. 2012-05-09]. Dostupné z: <http://www.netcam.cz/encyklopedie-ip-zabezpeceni/obrazove-snimace-ccd-cmos.php>

- [22] Elektro revue. HORÁK, Ing. Karel a Ing. Ilona KALOVÁ. *Řízení expoziční doby CCD kamery* [online]. 06. 04. 2006 [cit. 2012-05-09]. Dostupné z: <http://www.elektrorevue.cz/clanky/06019/index.html>
- [23] Digi-aréna. *Technologie CCD snímáče - 2 .kapitola* [online]. © 2004-2012 [cit. 2012-05-10]. Dostupné z: http://digiarena.e15.cz/technologie-ccd-snimace_2/ch-47238
- [24] Automatizace: Měření a regulace. *Principy a málo známé vlastnosti CCD snímačů obrazu* [online]. © 1997 - 2009 [cit. 2012-05-10]. Dostupné z: <http://automatizace.hw.cz/clanek/2006041001>
- [25] LAUCKÝ, Vladimír. *Bezpečnostní futurologie*. Vyd. 1. Zlín: Univerzita Tomáše Bati ve Zlíně, 2007, 93 s. ISBN 978-80-7318-560-2.
- [26] Seznam. *Mapy.cz* [online]. © 2001 - 2012 [cit. 2012-05-11]. Dostupné z: <http://www.mapy.cz/>

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

SPZ	Státní poznávací značka
RZ	Registrační značka
OCR	Optical Character Recognition – neuronová síť
UNS	Rozpoznávání pomocí umělé neuronové sítě
NN	Neural network – neuronová síť
PC	Personal Computer – počítač pro osobní užití
STK	Státní technická kontrola
EU	Evropská unie
CCD	Charged Coupled Device – obrazový snímač
CMOS	Complementary Metal Oxide Semiconductor
CCTV	Closed Circuit Television – Kamerový systém
DBS	Databázové systémy
SQL	Strukturovaný databázový jazyk
NN	Neural Network – Neuronová síť
RBF	Radial Basis Function – síť s radiální bází
DBS	Databázové systémy
iNSN	Simulátor neuronových sítí
2D	Dvourozměrný obraz
IR	Infračervený přísvit
ZS	Zimní stadión
SANS	Statistika automatizované neuronové sítě

SEZNAM OBRÁZKŮ

Obr. 1. Stacionární radary	11
Obr. 2. Úsekové radary	11
Obr. 3. Zaprášená RZ.....	13
Obr. 4. Základní koncepce bezpečnostní kamery obsahující snímač [21].....	14
Obr. 5. CCD snímač [21]	15
Obr. 6. CMOS snímač [21]	16
Obr. 7. Blokové schéma CCD snímače [22].....	17
Obr. 8. Implantované čočky na povrchu CCD snímače [22]	17
Obr. 9. Expoziční doba [22].....	18
Obr. 10. Účinnost (EQ) CCD snímače v závislosti na vlnové délce [24].....	19
Obr. 11. Závislost temného proudu na CCD snímač [24]	19
Obr. 12. Odstín šedi (out)	22
Obr. 13. Původní (in) obraz	22
Obr. 14. Graf histogramu	23
Obr. 15. Původní obraz-histogram.....	23
Obr. 16. Transformovaný obraz-histogram	23
Obr. 17. Vstupní obraz – odstín šedé – černobílý obraz.....	25
Obr. 18 Jednořádkové RZ [16]	27
Obr. 19. Rozměry dvouřádkové RZ [16].....	28
Obr. 20. RZ Brno-západ (označení pro rok 1994-2001) [16].....	28
Obr. 21. Moravskoslezský kraj - T (označení pro rok 2001 – 2004) [16].....	28
Obr. 22. RZ od roku 2004 do současnosti [16].....	28
Obr. 23. Rozdělení ČR do krajů	29
Obr. 24. Vyobrazení podle přístupných znaků	29
Obr. 25. Označení RZ podle krajů.....	30
Obr. 26. Model neuronu [1].....	31
Obr. 27. Výsledek f-ce [1]	31
Obr. 28. Biologie neuronu [1].....	33
Obr. 29 Blokové schéma matematického modelu neuronu [1]	34
Obr. 30 Biologická inspirace	37
Obr. 31. Schéma synapse.....	37
Obr. 32 Tvar impulsů vyslané do axonů ze synapse.....	39

Obr. 33. Tvar impulsů vyslané do axonů ze synapse.....	39
Obr. 35. JavaApplet – Perceptron [5]	42
Obr. 36. Topologie tříprvkové HS	43
Obr. 37. Hopfieldová síť	43
Obr. 38. Grafické znázornění Hopfieldovi sítě [4]	43
Obr. 39. Kohonenová síť	44
Obr. 40. Topologické zobrazení [4].....	44
Obr. 41. Adaptace vah [4].....	45
Obr. 42. Adaptační f-ce [2]	45
Obr. 43. Vícevrstvá dopředná neuronová síť	46
Obr. 44. Feed-Forward NN.....	46
Obr. 45. Tvorba Neuronové sítě	47
Obr. 46. Vytvořená nová NN „network1“	47
Obr. 47. Zadávání nových dat do sítě „network 1“	48
Obr. 48. Výstupní graf vytvořené neuronové sítě „ network1“.....	49
Obr. 49. Trénovací proces sítě network1	49
Obr. 50. Schéma a příkaz GENSIM v simulinku	50
Obr. 51. Celosvětová ukázka RZ [19]	52
Obr. 52. Letecký záběr parkoviště ZS ve Zlíně	55
Obr. 53. Koncept parkoviště ve struktuře 2D	57
Obr. 54. Struktura systému rozpoznávání RZ vozidel.....	58
Obr. 55. Integrace DBS s neuronovou sítí	60
Obr. 56. E-R diagram databáze parkoviště	61
Obr. 57. Tvorba tabulek a atributu.....	62
Obr. 58. Select dotazu v SQL	64
Obr. 59. iSNS základní pracovní plocha.....	65
Obr. 60. Vytvoření Hopfieldové sítě	66
Obr. 61. Hlavní panel sítě Hopfield	67
Obr. 62. Vytváření šablony znaků RZ	68
Obr. 63. Analýza znaků - Hopfieldovi sítě	69
Obr. 64. Algoritmus MyRecollection	70
Obr. 65. Krokování algoritmu.....	70
Obr. 66. Nový typ RZ – rozdělení podle krajů	72

Obr. 68. Starý typ RZ – Rozdělení podle okresů.....	72
Obr. 69. Struktura OCR	73
Obr. 70. Testování RZ pomocí OCR	73
Obr. 71. Parametry RZ určené k identifikaci.....	74
Obr. 72. Parkoviště s osazenými RZ na pozici jimi vyhrazeny	75
Obr. 73. RZ – Velká Británie (Anglie) [14]	89
Obr. 74. RZ Colorado – USA [15].....	89
Obr. 75. RZ Accra-Ghana[15]	89
Obr. 76. RZ Nagasaki – Japonsko [15].....	89
Obr. 77. RZ Jižní Austrálie – Adelaide [15].....	89
Obr. 78. Perceptron.....	90
Obr. 79. Skoková funkce	90
Obr. 80. Logistická funkce (Sigmoida)	90
Obr. 81. Hyperbolický tangens	90
Obr. 82. NN – základní menu	91
Obr. 83. NN - architektura	91
Obr. 84. NN – Maximální chyba při učení	92

SEZNAM TABULEK

Tab. 1. Legenda k matematickému modelu neuronu.....	34
Tab. 2. Počítač x Lidský mozek.....	35
Tab. 3. NS x PC	36
Tab. 4. Použití neuronových sítí	41
Tab. 5. Matlab nastavení NN	48

SEZNAM PŘÍLOH

- PI RZ Rozdělení podle kontinentů**
- PII PERCEPTRON – přehled Funkcí**
- PIII STATISTICA Automatizované neuronové sítě – SANS**
- PIV Databáze SQL**

PŘÍLOHA P I: RZ ROZDĚLENÍ PODLE KONTINENTŮ

- Evropa – UK



GB = Great Britain

Obr. 72. RZ – Velká Británie (Anglie) [14]

- Amerika – USA (SA), BR (JA)



circa 1985, 1992 sticker



circa 1995, 2000 sticker



2000 (current) base

Obr. 73. RZ Colorado – USA [15]

- Afrika – Ghana, JAR



Obr. 74. RZ Accra-Ghana[15]

- Asie – Irák, Saúdská Arábie, Japonsko



Obr. 75. RZ Nagasaki – Japonsko [15]

- Austrálie




Obr. 76. RZ Jižní Austrálie – Adelaide [15]

PŘÍLOHA P II: PERCEPTRON – PŘEHLED FUNKCÍ

Nejpoužívanější funkce jsou:

- Perceptron – v síti perceptronu je využita lineární funkce
 - Tím, že je síť lineární je schopna řešit problémy lineárně separabilní




Obr. 77. Perceptron

$$F(P) = x \quad \forall x > 0 \quad \text{jinak } x = 0$$

Rov. 5.

- Binární – skoková funkce




Obr. 78. Skoková funkce

$$F(B) = 1 \quad \forall x > 0 \quad \text{jinak } x = 0$$

Rov. 6.

- Logistická (sigmoida) – nejpoužívanější




Obr. 79. Logistická funkce (Sigmoida)

$$F(S) = \frac{1}{1 + e^{-x}}$$

Rov. 7.

- Hyperbolický tangens – lze také použít jako přenosová funkce



Obr. 80. Hyperbolický tangens

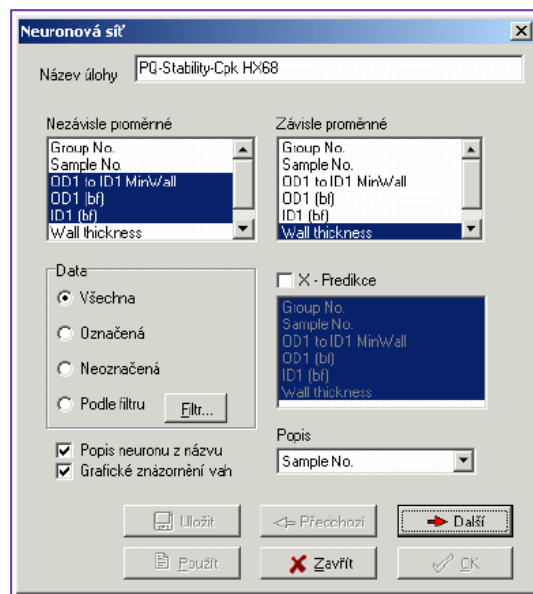
$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Rov. 8

PŘÍLOHA P III: STATISTICA

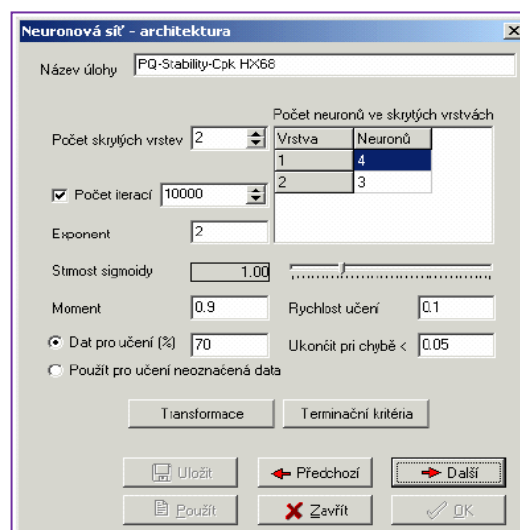
STATISTICA Automatizované neuronové sítě (SANS) podporuje mnoho důležitých tříd z neuronových sítí pro řešení problémů reálného světa včetně vícerozměrných perceptronu, RBF sítí a dalších NN.

- Okno pro zadání dat



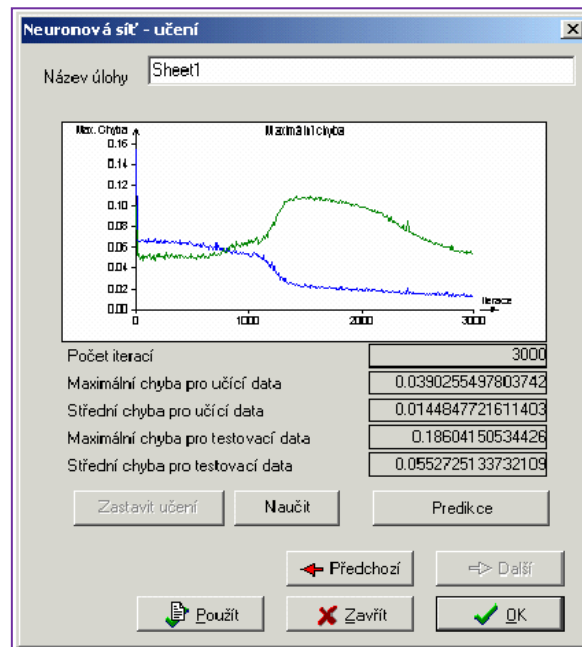
Obr. 81. NN – základní menu

- Okno pro definice neuronové sítě - zde navrhujeme základní vrstvu NN a počet neuronu v jednotlivých vrstvách



Obr. 82. NN - architektura

- Optimalizace neuronové sítě - vykreslení maximální chyby neuronové sítě při trénování dat



Obr. 83. NN – Maximální chyba při učení

PŘÍLOHA P IV: DATABÁZE SQL

/*

Created 5.32012
Modified 15.3.2012
Project Databaze_Parkoviště

Model

drop table IF EXISTS Mesto_Zlin;
drop table IF EXISTS Lokalizace_firma;
drop table IF EXISTS Lokalita__Zamestnanci;
drop table IF EXISTS Zamestanci;
drop table IF EXISTS OBI;
drop table IF EXISTS Avonet;

Create table Vozidlo (

ID_registra_n_zna_ka Char(20) NOT NULL,
Datum_porizeni Datetime NOT NULL,
cas_porizeni Time NOT NULL,
Znacka_Vozidla Varchar(20) NOT NULL,
Barva_Vozidla Varchar(20) NOT NULL,

Primary Key
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni))
ENGINE = MyISAM;

Create table Osoba (

ID_registra_n_zna_ka Char(20) NOT NULL,
Datum_porizeni Datetime NOT NULL,
cas_porizeni Time NOT NULL,
Prijmeni Char(20) NOT NULL,
Jmeno Char(20) NOT NULL,
Mesto Char(20) NOT NULL,
ulice Char(20) NOT NULL,
psc Date NOT NULL,
tel_cislo Date NOT NULL,
poznamka Char(20) NOT NULL,

Primary Key
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni))
ENGINE = MyISAM;

Company SEIDL
Author Seidl Jaromír
Version
Database mySQL 5

*/

drop table IF EXISTS PSG;
drop table IF EXISTS Lokalizace_Osoba;
drop table IF EXISTS Firma;
drop table IF EXISTS Osoba;
drop table IF EXISTS Vozidlo;

Create table Firma (

Nazev_firmy_sponzor Char(20) NOT NULL,
mesto Char(20) NOT NULL,
ulice Char(20) NOT NULL,
psc Char(20) NOT NULL,
tel_cislo Int NOT NULL,
poznamka Char(20) NOT NULL,
ID_registra_n_zna_ka Char(20) NOT NULL,
Datum_porizeni Datetime NOT NULL,
cas_porizeni Time NOT NULL,

Primary Key
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni))
ENGINE = MyISAM;

Create table Lokalizace_Osoba (

ID_registra_n_zna_ka Char(20) NOT NULL,
Datum_porizeni Datetime NOT NULL,
cas_porizeni Time NOT NULL,

Primary Key
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni))
ENGINE = MyISAM;

Create table PSG (

ID_registra_n_zna_ka Char(20) NOT NULL,
Datum_porizeni Datetime NOT NULL,
cas_porizeni Time NOT NULL) ENGINE =

MyISAM;

```

Create table Avonet (
    ID_registra_n_zna_ka Char(20) NOT NULL,
    Datum_porizeni Datetime NOT NULL,
    cas_porizeni Time NOT NULL) ENGINE =
MyISAM;

Create table OBI (
    ID_registra_n_zna_ka Char(20) NOT NULL,
    Datum_porizeni Datetime NOT NULL,
    cas_porizeni Time NOT NULL) ENGINE =
MyISAM;

Create table Zamestanci (
    Rodne_cislo Int NOT NULL,
    Prijmeni Char(20) NOT NULL,
    Jm_no Char(20) NOT NULL,
    Ulice Char(20) NOT NULL,
    Mesto Char(20) NOT NULL,
    tel_cislo Date NOT NULL,
    Primary Key (Rodne_cislo)) ENGINE = MyISAM;

Create table Lokalita__Zamestnanci (
    ID_registra_n_zna_ka Char(20) NOT NULL,
    Datum_porizeni Datetime NOT NULL,
    cas_porizeni Time NOT NULL,
    Rodne_cislo Int NOT NULL,
    Primary Key
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni,Rodne_c
islo)) ENGINE = MyISAM;

Create table Lokalizace_firma (
    ID_registra_n_zna_ka Char(20) NOT NULL,
    Datum_porizeni Datetime NOT NULL,
    cas_porizeni Time NOT NULL,
    Primary Key
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni))
ENGINE = MyISAM;

Create table Mesto_Zlin (
    ID_registra_n_zna_ka Char(20) NOT NULL,
    Datum_porizeni Datetime NOT NULL,
    cas_porizeni Time NOT NULL) ENGINE =
MyISA

```

```

Alter table Lokalizace_Osoba add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Vozidlo
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;

```

```

Alter table Lokalita__Zamestnanci add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Vozidlo
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;

```

```

Alter table Lokalizace_firma add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Vozidlo
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;

```

```

Alter table OBI add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Firma
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;

```

```

Alter table Mesto_Zlin add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Firma
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;

```

```

Alter table PSG add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Firma
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;

```

```

Alter table Avonet add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Firma
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;

```

```

Alter table Osoba add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Lokalizace_Osoba
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;

```

```

Alter table Lokalita__Zamestnanci add Foreign Key (Rodne_cislo) references Zamestanci (Rodne_cislo) on delete restrict on update
restrict;

```

```

Alter table Firma add Foreign Key (ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) references Lokalizace_firma
(ID_registra_n_zna_ka,Datum_porizeni,cas_porizeni) on delete restrict on update restrict;

```

```

/* Users permissions */

```