

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Technická fakulta
Katedra technologických zařízení staveb



Nasazení neuronových sítí v inteligentních budovách

diplomová práce

Vedoucí diplomové práce:
Ing. Zdeněk Votruba

Autor práce:
Bc. Tomáš Kubálek

© 2014 Praha

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Katedra technologických zařízení staveb

Technická fakulta

ZADÁNÍ DIPLOMOVÉ PRÁCE

Kubálek Tomáš

Obchod a podnikání s technikou

Název práce

Nasazení neuronových sítí v inteligentních budovách

Anglický název

Neural network in intelligent building

Cíle práce

Cílem práce je posouzení vhodnosti využití prostředků neuronových sítí a neuronového modelování v návrhu integrace bezpečnostních systémů do tzv. inteligentních budov. Stanovit možné typy řešení, matematické modely a ověřit je v praxi.

Metodika

Na základě vlastních znalostí a literární rešerše posoudit technické a legislativní možnosti propojování bezpečnostních systémů mezi sebou a mezi dalšími informačními systémy intel. budovy. Navrhnout propojení pomocí neuronového chipu navrženého na základě neuronové sítě a otestovaného pomocí MatLab či obdobného nástroje. Prakticky otestovat navržené řešení.

Osnova práce

1. Literární rešerše
2. Popis možných interface bezpečnostních systémů
3. Popis komunikačních sběrnic intel. budov - jejich posouzení k možné integraci PZTS
4. Volba modelu neuronové sítě
5. Propojení PZTS a navrženého modelu - ověření funkce
6. Analýza výsledků a posouzení možného využití
7. Závěr a finanční náročnost



Rozsah textové části

50 stran textu včetně obrázků, grafů a tabulek

Klíčová slova

zabezpečovací systémy, neuronové sítě, inteligentní budovy, integrace

Doporučené zdroje informací

KŘEČEK, S.: Příručka zabezpečovací techniky, 2002, Criterus, 313 s. ISBN 80-902938-2-4.

KOCÁBEK, P.; KONÍČEK, T.: Bezpečné bydlení. ERA 2003, Brno

HERMAN, J., TRINKEWITZ, Z., et al.: Elektrotechnické a telekomunikační instalace, 2006, Verlag Dashofer, ISBN 80-86897-06-0.

časopisy Automa, Elektro a Security Magazin

BISHOP C. M.: Neural Networks for Pattern Recognition. Oxford University Press, New York, 1995, 498 s., ISBN 0-38-731073-8

FAUSETT, L.: Fundamentals of Neural Networks. Prentice Hall, New York, 1994, 404 s., ISBN 0-13-335186-0.

NOVÁK, M., et al.: Umělé neuronové sítě – teorie a aplikace, C.H.Beck, 1998, Praha, 382 s., ISBN 80-7179-132-6.

NÝVLT, O.: Přehled protokolů a systémů pro řízení inteligentních budov. Automatizace. Březen - duben 2010, roč. 53, č. 3-4, s. 121-124. Dostupný také z WWW: <http://www.automatizace.cz/article.php?a=2782>

MERZ, H., HANSEMANN, T., HÜBNER, Ch.: Automatizované systémy budov. 1. vydání. Praha: GRADA Publishing, 2008. 264 s. ISBN 978-80-247-2377-9

Vedoucí práce


Votruba Zdeněk, Ing.

Termín zadání

listopad 2012

Termín odevzdání

duben 2014


doc. Ing. Miroslav Příkryl, CSc.

Vedoucí katedry



V Praze 18.3.2013


prof. Ing. Vladimír Jurča, CSc.

Děkan fakulty

Čestné prohlášení

Prohlašuji, že jsem diplomovou práci na téma „*Nasazení neuronových sítí v inteligentních budovách*“ vypracoval samostatně pod vedením pana Ing. Zdeňka Votruby a použil jsem pramenů, které uvádím v příloženém seznamu použité literatury. Dále prohlašuji, že se diplomová práce v tištěné podobě úplně shoduje s prací v podobě elektronické.

Datum odevzdání práce: 4. dubna 2014

.....

podpis autora

Abstrakt

Cílem této diplomové práce je ověření možnosti, zda existuje způsob využití neuronové sítě v inteligentních budovách, která s rozvojem technologií naráží na legislativní bariéry. Současné normy neumožňují plně integrovat veškeré technologie, které inteligentní budovy pro svoji funkci, resp. provoz využívají. Neuronové sítě by mohly tuto překážku pomoci překlenout a posloužit k plnohodnotné integraci. V úvodu práce je obecný popis co lze za inteligentní budovu považovat a dále co od těchto budov očekáváme, jaké technologie jsou dnes pro provoz budov používány, jaké jsou dnešní legislativní úskalí při snaze plně integrovat veškeré systémy a subsystémů budov, zejména bezpečnostních a protipožárních systémů. Další část práce je zaměřena na neuronové sítě, tj. na stručné seznámení a přehled vybraných modelů včetně jejich dnešního využití v praxi. V následující části práce je diskutována otázka, zda je možné navrhnout takové řešení, které by pomohlo překlenout legislativní bariéry na zvoleném typu, resp. modelu neuronové sítě a tuto myšlenku v simulovaných podmínkách otestovat. V závěrečné části práce je posouzena náročnost, výsledky testování zvoleného modelu a zhodnocení tohoto řešení.

Klíčová slova

zabezpečovací systémy, neuronové sítě, inteligentní budovy, integrace

Abstract

The aim of this thesis is to explore the possibility and way the use of neural networks in intelligent buildings, which with the advancement of technology allude to legislative barriers. The current standard does not fully integrate all the technology of intelligent buildings and their functions. Neural networks could help to overcome this obstacle and to help full integration. The introduction is a general description of what can be considered intelligent building and what we expect from these buildings, what technologies are currently used, what are the pitfalls in today's legislative effort to fully integrate all systems and subsystems buildings, especially electronic security system and fire security system. Next part of thesis is focuses on the neural network and simply introduction inclusive overview of selected neural models and their use in practice. In the following part of the thesis is discussed the question if possible to design a solution that would help overcome legislative barriers on the chosen type of neural network - model and this idea simulate. In the final part of the thesis is assessed the results of testing model and evaluation of this solution.

Keywords

security systems, neural networks, intelligent buildings, integration

OBSAH

1.	Úvod	2
2.	Inteligentní budovy	3
2.1.	Historie.....	3
2.2.	Inteligentní budova.....	4
2.3.	Technické vybavení budov a technologie	6
2.4.	Integrované technologie budov	7
2.5.	Komunikace a sběrnice.....	9
2.5.1.	Sběrnice EIB	11
2.5.2.	Sběrnice KNX	13
2.5.3.	Sběrnice LonWorks.....	15
2.5.4.	Sběrnice M-Bus	16
2.5.5.	Protokol BACnet	17
2.6.	Problematika v integraci bezpečnostních systémů	18
3.	Neuronové sítě	21
3.1.	Topologie neuronové sítě	22
3.2.	Neuron	23
3.3.	Lineární separabilita.....	27
3.4.	Rozdělení umělých neuronových.....	29
3.5.	Vícevrstvý perceptron	31
3.5.1.	Učení vícevrstevných sítí	32
3.5.2.	Metoda back-propagation	33
3.6.	Kohonenova mapa.....	34
3.6.1.	Učení samoorganizujících map	36
3.7.	Hopfieldova síť.....	37
4.	Model neuronové sítě	41
4.1.	Vstupní data elektronické zabezpečovací signalizace (PZTS).....	41
4.2.	Vícevrstvá neuronová síť a software.....	44
4.3.	Nastavení modelu vícevrstvého perceptronu	45
5.	Závěr	49
6.	Seznam použité literatury	51
7.	Seznam zkratk	54
8.	Seznam obrázků	55

1. Úvod

Přirozeným rozvojem výpočetní techniky a rozvojem nových technologií byl v 80. letech základem myšlenky, uplatnit tyto inovace a novinky v automatizaci i v odvětvích a oblastech, které pro jejich uplatnění nebyly dosud atraktivní, popř. neumožňovaly plné uplatnění nových trendů. Tomuto faktu napomohl i přechod od mechanických systémů k automatickým a automatizovaným.

Mezi tyto oblasti, kde se tyto poznatky začaly uplatňovat je provoz, správa a údržba budov, které přirozeným vývojem daly vzniknout vyššímu stupni, který se dnes vžil pod termínem *inteligentní budova*, tzn. budova, jejíž jednotlivé izolované a nezávislé systémy jsou propojeny do kompaktního celku. Vlivem tohoto propojení, resp. integrace se otevřely nové možnosti při běžné správě objektů, tzn. zvýšení komfortu užívání, zkvalitnění služeb, údržby a provozu modernizovaných objektů.

Vhodnou formou integrace může vzniknout celek, který zkvalitní funkci kooperujících subsystémů, kde zjištěná data prvního systému mohou efektivně řídit, resp. dodávat řídicí data spřaženému systému a ten zpětnou provázaností může regulovat a ovlivňovat další řídicí data, tzn. pružně regulovat a reagovat na změny a nové podmínky.

Vlastní integrace našla inspiraci v analogii k živému organismu, který stejně jako objekt je souborem nezávislých systémů, které spolu v harmonii spolupracují a podporují se, popř. se dokáží dočasně zastoupit při výpadku jiného. Hlavní skupiny těchto systémů zajišťují např. dodávku energie, tepla, preventivní a imunitní funkce, dodávání a zpracování informací, komunikaci, řídicí funkce a další.

U budov, stejně jako tomu mohlo být při dlouhém vývoji živých organismů, narážíme na různé překážky, které integraci znesnadňují. Při integraci inteligentních budov se můžeme setkat s překážkami technického charakteru, např. volba typu integrace, komponenty, sběrnice, topologie, systém, popř. samotná realizace v daném objektu a další.

Naproti technickým překážkám existují překážky legislativní, které jsou zásadnější a neopomenutelné. Tyto překážky vychází z platných ČSN EN norem, které už jsou sice lety prověřeny a jsou funkční, avšak za podmínek, kdy byly zaváděny a pro dnešní stav jsou tyto normy zastaralé. Tyto normy jsou již beze změn v platnosti už několik desetiletí, a proto by zasloužily citlivou úpravu s ohledem na měnící se okolnosti, rozvoj nových technologií a trendů. Touto úpravou je myšlen jemný zásah, který by zohlednil předchozí normu a adaptoval ji na současné podmínky tak, aby nemohlo dojít k různému výkladu, nepochopení či hledání dvouznačností a skulin v předpisech.

Ve své práci se pokusím navrhnout a otestovat takového technické řešení, resp. navrhnout model neuronové sítě, který by umožnil při stávající legislativě a normách, uplatnit principy plné integrace, tzn. i těch systémů inteligentních budov, které jsou normami striktně ošetřeny nebo pro integraci limitovány.

2. Inteligentní budovy

2.1. Historie

Historicky první pokus o inteligentní budovu je znám ze začátku druhé poloviny 20. století v Japonsku. Jednalo se o koncepci s řídicí jednotkou, která ovládala všechny technologie centrálně, ale tento počín v té době nevzbudil velký zájem odborné veřejnosti. Pozornost této koncepci byla věnována až o několik let později. V 70. letech vlivem rostoucí ceny ropy na celosvětových trzích, energií a současně také díky snaze o hospodárný provoz a snižování spotřeby elektrické energie.

Za tímto účelem se spojilo několik společností, zejména v Německu, které vytvořily společné firmy a položily takto základ pro vzniku asociace *EIBA* (*European Installation Bus Association*) se sídlem v Bruselu. Snahou této asociace bylo, dodat jednotný instalační systém pro systém řízení budov, které by umožňoval jednoduchou instalaci, adaptabilitu na pozdější změny.

2.2. Inteligentní budova

Přesný termín, co je inteligentní budova, není ustálen. Za inteligentní budovu můžeme považovat takový objekt, který zajišťuje optimální provozní podmínky a současně komfort osob prostřednictvím technologií a techniky, řídicích systémů, služeb ovšem za podmínky, že jsou zajištěny energeticky, hospodárně a s možností budoucí rekonfigurace, tj. se schopností přizpůsobit se novým podmínkám a požadavkům.

Definice, které asi nejužitečněji zachycují podstatu inteligentních budov, jsou:

„Inteligentní budova je taková budova, která je schopná se přizpůsobit změnám ve způsobech jejího užívání a změnách životního stylu jejích obyvatel a nepřestává jim sloužit a vytvářet příjemné a odpovídající prostředí.“ [1]

„Inteligentní budovy kombinují inovace technologického i organizačního charakteru s lokálními i centrálními principy automatizovaného řízení tak, aby se maximalizovala rychlost návratu investic do budovy vložené.“ [1]

„Inteligentní budova je budovou plně vybavenou automatizační a informační a komunikační technikou, která slouží jednak přímo svým obyvatelům, jednak pro vytváření příjemného prostředí pro ně.“ [1]

„Inteligentní budovou je myšlen objekt, který dokáže dílčí subsystémy a technologie integrovat v jeden vzájemně komunikující logický celek.“

Hlavními požadavky, které inteligentní budova musí splňovat, jsou:

- efektivní vynaložení pořizovacích prostředků, tzn. návratnost,
- hospodárnost provozu,
- přizpůsobivost,
- bezpečnost.

Tyto požadavky musí samozřejmě odpovídat platným právním normám a předpisům, jakož by měla existovat i snaha o co nejvyšší stupeň integrace dostupných systémů, kterými je budova vybavena.

K dosažení výsledného efektu, tj. sladění zvolených požadavků a parametrů je nutno přistoupit už ve fázi návrhu konstrukce objektu resp. při projektu stavby architektem a to např. jeho orientací v terénu či zástavbě, vnitřní dispozicí, včleněním servisních a obslužných zón, prostupy v nosných konstrukcích, volbou materiálů a další. O 80 % budoucích provozních nákladů je rozhodnuto již v momentě, kdy první stavební stroje zahájí výkopové práce. Je zřejmé, že u starších budov je tato realizace náročnější, jelikož zásah do stávající konstrukce může být v rozporu se stávajícími stavebně technickými normami nebo možnostmi upravovaného objektu.

Budovy, které mohou být integrovány, můžeme obecně rozdělit na dvě hlavní skupiny. Na budovy *nekomerčního charakteru*, tj. rodinné domy, rezidence a jiné objekty určené k soukromému užívání a to převážně ve vlastnictví fyzických osob. Druhou skupinou jsou budovy *komerčního charakteru* (označovány jako účelové budovy), tj. kancelářské objekty, obchodní domy, nákupní a zábavní centra, finanční instituce, nemocnice a další. Obvykle jsou tyto objekty projektovány a realizovány developery za účelem následného odprodeje či pronájmu jako celek nebo po částech.

Integrace budov nekomerčního charakteru jsou spíše prezentací vlastníka a jeho otevřenosti a přístupnosti k novým technologiím a trendům či touze po vyšším komfortu. Návrhová pořizovací nákladů u těchto objektů je velice dlouhodobá a začíná až po 50 letech a déle.

U účelových objektů komerčního charakteru je doba návratnosti pořizovacích nákladů kratší, přibližně 20 let. Podstatný vliv na dobu návratnosti u komerčních objektů má využití objektu, tzn. snaha z provozu této budovy profitovat a generovat zisk.

Tyto objekty jsou obvykle účelově zaměřeny požadavkům koncového uživatele, popř. nájemce. Účelové objekty jsou specifické i tím, že jsou v nich kumulovány různé technologie a současně tyto objekty mají různý provozní režim, který odpovídá zaměření nájemce, tzn. různé zóny zabezpečení a řízený režim přístupu, koncentrace a pohyb cizích osob, pohyb vozidel, práce s daty a citlivými osobními údaji.

2.3. Technické vybavení budov a technologie

Jak již bylo zmíněno v úvodu, vlivem technického vývoje a automatizace lze v současnosti využívat technologie, které jsou nedílnou součástí infrastruktury každé moderní budovy a mezi tyto technologie patří zejména:

technická zařízení budov

- vzduchotechnika, klimatizace, vytápění a chlazení, popř. alternativní zdroje energie a tepla (ohřevu),
- zdroje elektrické energie a nouzové napájení včetně náhradních zdrojů,
- osvětlení a stínění,
- počítačové sály a strukturovaná kabeláž,
- výtahy a eskalátory,
- docházkové a stravovací systémy,
- telefonní ústředna a informační systémy včetně datové sítě,
- ozvučení a systém centrálního času,

protipožární systémy

- elektrická požární signalizace (EPS), která obsahuje soubor hlásičů požáru, ústředn, přenosových a doplňkových zařízení, která ve svém souhrnu vytvářejí systém, kterým je opticky nebo akusticky signalizováno ohnisko nebo již vzniklý požár,
- nouzový a evakuační rozhlas,

bezpečnostní systémy

- poplachové zabezpečovací a tísňové systémy (EZS, nyní PZTS), které jsou kombinovaným systémem určeným k detekci poplachu vniknutí a tísňového poplachu [2], tento systém se skládá ze souboru detektorů, tísňových hlásičů, ústředn resp. řídicích jednotek, prostředků poplachové signalizace, přenosových zařízení, zapisovacích zařízení a ovládacích zařízení, jejichž prostřednictvím je opticky nebo akusticky signalizováno na určeném místě narušení střeženého objektu nebo prostoru, [3]

- systém kontroly vstupů (ACS), které obsahují všechna konstrukční a organizační opatření včetně těch, která se týkají zařízení nutných pro řízení vstupu, [4]
- kamerové sledovací systémy (CCTV) neboli uzavřený televizní okruh je systém, který obsahuje kamerovou sestavu, zobrazovací a další přídatná zařízení nezbytná pro přenos signálu a obsluhu při sledování definované bezpečnostní zóny, [5]
- systémy přivolání pomoci (SAS).

2.4. Integrované technologie budov

Mezi zařízení či systémy, která jsou běžně a primárně integrovány, popř. automatizovány jsou technická zařízení budov, do kterých patří již zmíněné technologie vytápění, chlazení, ventilace, klimatizace, dodávka a řízení spotřeby elektrické energie, řízení osvětlení a stínění např. žaluziemi a markýzami, detekce a ohlašování požáru.

Dodatečně jsou integrovány technologie zajišťující detekci a ohlašování neoprávněného vstupu a vniknutí, sledování přístupu osob do budov, sledovací kamerový systémy, informační technologie a sítě, multimédia, výtahy, eskalátory, telefonní přístroje, údržba a systém vyúčtování úhrad.

Zvolené technologie lze integrovat a řídit systémem, který doznal vývoje. Původní koncepce nabízela možnost *centralizovaného* řízení, které bylo vlivem vývoje a nástupem progresivní miniaturizace mikropočítačových technologií a nárůstem výkonosti, nahrazeno koncepcí *distribuovaného* systému řízení a to hlavně u integrací budov komerční povahy.

Centralizovaný systém řízení


Hlavním prvkem centralizovaného systému je nadřazená centrální řídicí jednotka - počítač, která přijímá individuální zprávy ze snímačů a akčních členů systémem dálkového přenosu rozsáhlou a rozvětvenou sítí. Z hlediska možností ovládání je takový systém značně omezený. Komunikace s provozními instalacemi je především založena na systému výměny hlášení stavů a příka-

zů, eventuálně změřených hodnot a regulačních povelů v napěťových obvodech na základě proudových smyček. [6]

Nevýhodou tohoto systému řízení je složité řešení, zpracování funkcí se omezuje na jednotlivá zařízení, komplikované rozšíření systému o nové komponenty a hrozba výpadků sítě nebo centrálního počítače. Centralizované systémy řízení dnes nachází uplatnění spíše v menších instalacích např. v rodinných domech, resp. u nekomerčních budov.

Distribuovaný (decentralizovaný) systém řízení

U komerčních budov se upouští od koncepce centralizovaného řídicího systému, tj. od centrální nadřazené řídicí jednotky, počítače s lokální sítí. Důvody a nevýhody jsou uvedeny výše a současně k tomu přispěl i vývoj výkonnějších mikroprocesorů, řídicích počítačových modů, progresivní miniaturizace a vysoký nárůst výkonnosti, které umožňují samostatné zpracování úloh a rutin v bezprostřední blízkosti řízeného procesu, kterému jsou dle požadavků konstruovány na míru. Počítačové moduly mají stejné funkcionality jako volně programovatelné automaty používané k řízení výrobních procesů. Jsou vybaveny digitálním procesorem a pro těsné spojení s řízeným procesem dostaly označení *DDC* (*direct digital controller*).



Obr. 1. Technologické proměny automatizace systémů budov a) - centralizovaný systém, b) - distribuovaný systém, c) - výrazně decentralizovaný systém; DDC (*direct digital controller*) [6]

Spojení modulů s komunikačním rozhraním, resp. *interfacem* nahradily do té doby nezbytné rozsáhlé neautonomní sítě, napojované na centrální počítač. [6]

Dočasnou nevýhodou toho decentralizovaného řešení byly používané *uzavřené* komunikační protokoly poplatné výhradně specifickým řešením jednotlivých výrobců. Propojení jednotlivých komponent od různých výrobců bylo možné jen za cenu vysokých dodatečných nákladů na úpravy. Tato nevýhoda byla odstraněna po zveřejnění, resp. *otevření* komunikačních protokolů.

2.5. Komunikace a sběrnice

Komunikace integrovaných prvků a systému fyzicky probíhá po sběrnici, po fyzickém mediu. Vlastní datový přenos upravuje příslušný komunikační protokol. Všechny systémy využívají odlišné komunikační protokoly. Důvodem jistě není náladovost výrobců. Hlavním důvodem je především to, že každý výrobce nejčastěji implementuje do svého zařízení svůj vlastní vývojem ověřený protokol. [7]

Sběrnice (anglicky *bus*) je skupina signálových vodičů. U paralelní sběrnice lze tyto vodiče rozdělit na skupiny řídicích, adresových a datových vodičů. Druhou variantou je sériová sběrnice, která řídí a sdílí data na společném vodiči. Sběrnice zajišťuje přenos dat a řídicích povelů mezi dvěma a více elektronickými zařízeními. Přenos dat na sběrnici se řídí stanoveným protokolem. [7]

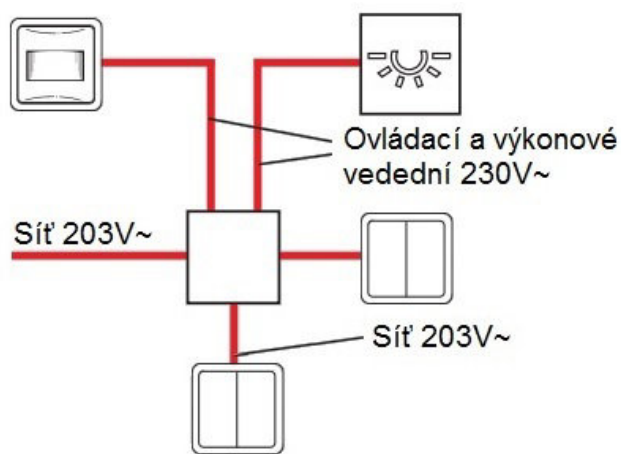
Protokol je soubor pravidel pro komunikaci mezi dvěma nebo více uzly např. systémy, regulátory.

Vznikly stovky různých sběrnicevých systémů, ať již pro využití v průmyslové automatizaci, palubní technice automobilů, lodí, letadel nebo v budovách. Pokaždé se museli vývojoví pracovníci vypořádat s následujícími otázkami:

- Jak přenést data?
- Jak má vypadat topologie?
- Jaká má být rychlost přenosu?
- Jak zabránit kolizi informací?
- Jak má vypadat software a hardware?

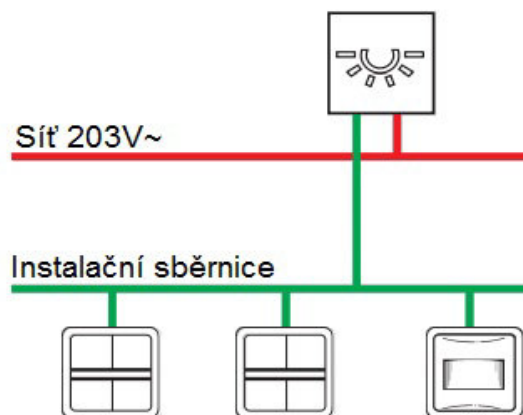
Nebylo by tedy lepší, kdyby všechny předchozí problémy vyřešil jeden stavební prvek, na němž by se následně budovaly požadované aplikace? [8]

V konvenční instalaci budov je ovládací, resp. řídicí vedení často realizováno zároveň i s vedeními silovými. Za příklad vezměme dvojici dvojitých střídavých přepínačů pro linii svítidel. Dodatečně je požadováno spínání prostřednictvím pohybových čidel. V takovém případě teče ovládacími vodiči i pracovní proud. Pro každou funkci je potřebné vlastní ovládací vedení (viz obr. 2). [9]



Obr. 2. Konvenční instalace [9]

Při sběrniovém systému přebírá všechny řídicí funkce jeden sběrniový kabel (viz obr. 3), který snižuje počet nutných ovládacích žil na pouhé dvě žíly



Obr. 3. Sběrniová instalace [9]


sběrnicového kabelu, který se instaluje paralelně se silnoproudým vedením. Tyto žíly paralelně propojují všechny přístroje a jsou schopny přenášet všechny řídicí signály pro silnoproudou elektroinstalaci. Spínače na sběrnici pomocí signálů připojují přístroje k napájení nebo spínají výkon uvnitř těchto přístrojů. [9] V současné době je na trhu několik sběrnicových systémů, které se vydobyli významné postavení pro své vlastnosti a přednosti.

2.5.1. Sběrnice EIB

Evropská instalační sběrnice *EIB (European Installation Bus)* je normovaný standart, který má decentralizovanou strukturu s liniovou, kruhovou nebo větvenou topologií. Maximální délka jedné větve/linky je 1000 m a může k ní být připojeno maximálně 64 zařízení, tzn. senzorů a aktorů.

Senzory snímají fyzikální veličinu nebo děj, převádějí ji na informaci, kterou je možno přenést po sběrnici a na sběrnici vysílají odpovídající telegram. Nejjednodušším dějem je stisk tlačítka na určitém tlačítkovém senzoru, ale senzory jsou schopny snímat nejrůznější veličiny, např. intenzitu osvětlení, teplotu nebo přijímat rádiové signály. [9]

Aktory vyhodnocují telegramy, které senzory vysílají, a mění je v povel pro mechanickou činnost. Touto činností může být spínání, stmívání nebo spuštění topení a další. [9]



Obr. 4. Struktura telegramu [10]

Telegramy jsou zprávy v předepsaném kódovaném formátu (viz obr. 4), kterými si senzory předávají, resp. vyměňují řídicí instrukce mezi připojenými prvky na sběrnici. Telegramy jsou ve formě digitálních pulsů.

Jednotkou přenosu je 1 bit, který může nabývat hodnoty logické 0 nebo logické 1. Pro binární přenos informací se využívá hexadecimálního kódování, což odpovídá 16 možným stavům. Při přenosu stavu zapnuto nebo vypnuto postačí vyjádření rozměru jen 1 bit. Stav nastavení např. výšky, úhlu natočení či otevření polovodičového ventilu stmívače se vyjadřují 256 kroky, tedy celkem 256 stavy, pro jejichž binární vyjádření je potřebných 8 bitů, tj. 1 byte. Stavů různých fyzikálních veličin se tak mohou vyjadřovat různě dlouhými daty s různými počty stavů. [10]

Pokud je připojeno ke sběrnici *EIB* více zařízení, je možné řešit tuto situaci variantou s nadřazenou linií a oddělovačem linií, spojek. Druhou variantou, která řeší tuto situaci je zapojení zesilovače či zesilovačů. Pomocí liniových spojek lze k pátevní síti připojit až 12 větví. Liniové spojky pak zajišťují, aby telegram putoval jen do té větve, pro kterou je určen. Důležitým signálům může být přidělena vyšší priorita a tyto jsou pak upřednostňovány, tzn. rychlejší postup celou sítí, kratší odezva. Systém *EIB* je otevřený pro všechny další obory, avšak primárně je určen pro elektroinstalaci. Pomocí signálových vodičů jsou jednotlivá zařízení propojena a také napájena. [7]

Programování jednotlivých účastníků a celého systému *EIB* se provádí počítačem pomocí programu *ETS (EIB Tool Software)*. Jako základní přenosové médium může být použito:

- krouceného páru vodičů,
- síťové vedení, tj. vedení elektrických rozvodů 230 V,
- přenos signálů rádiem,
- ethernet/IP, [7]
- optické vlákno.

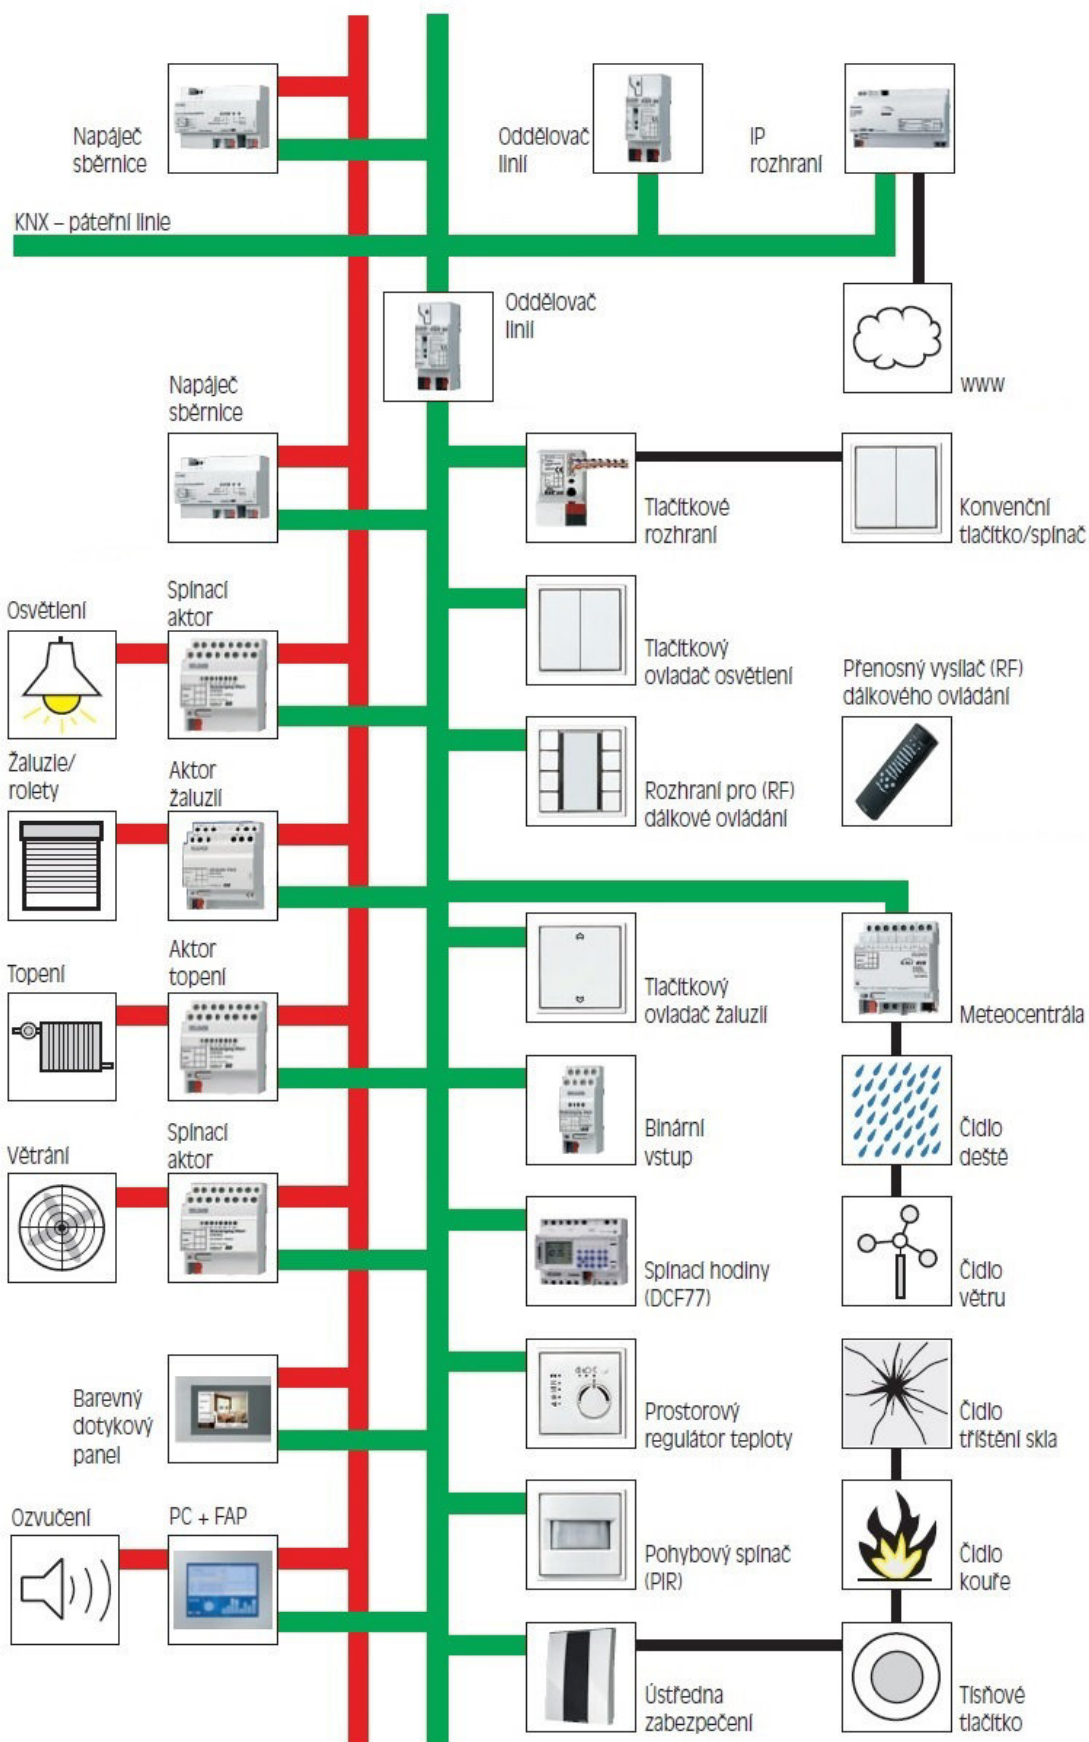
Výhodou sběrnice *EIB* je bezproblémové propojování zařízení různých výrobců, snadná instalace a uvedení do provozu, snadné přeprogramování umožňuje rychlou změnu dle dispozic, kompatibilita výrobků různých firem, jasná certifikace.

2.5.2. Sběrnice KNX

Základem pro mezinárodní standard *KNX* byla zvolena sběrnice *EIB* pro její technický charakter i úspěch na trhu. Veškeré výrobky a zařízení určené pro sběrnici *EIB* vyhovují automaticky standardu *KNX*. Standard *KNX* má oproti *EIB* mnohem větší objem funkcí, odpovídající požadovanému cíli, tj. spojení nejrůznějších přístrojů, možnost využití dalších přenosových médií, integrace různých zařízení, které slouží pro regulaci, spínání, měření, sledování stavů a předávání hlášení v budovách (viz obr. 5). [7]

Pomocí sběrnice *KNX* lze realizovat lze např.:

- řízení a regulace osvětlení, tj. manuální a automatické nastavení konstantní intenzity, spínání pohybovými čidly,
- řízení a regulace teploty individuálně v každé místnosti,
- ochrana a zabezpečení objektu proti narušení, tj. snímání tříštivých čidel a rozpínacích magnetických kontaktů a jejich hlášení,
- signalizace zvýšení teploty a indikace přítomnosti kouře,
- ovládání a regulace okenních žaluzií a markýz v závislosti na denní době, rychlosti větru, sluneční intenzitě,
- řízení ventilace, tj. spouštění ventilátorů popř. automatické otevírání oken,
- řízení centrálních časových režimů a funkcí, např. denní a noční provoz, popř. víkendový režim,
- spánkový režim vybraných skupin spotřebičů, např. kopírek při ukončení pracovní doby,
- optimalizace spotřeby energie dle pracovního režimu, popř. zapojení alternativních zdrojů energie, např. slunečních kolektorů,
- vytváření logických funkcí, např. otevřené okno - vypnout klimatizaci, topení a další.



Obr. 5. KNX sběrnicevá instalace [9]

2.5.3. Sběrnice LonWorks

Sběrnice *LON* je otevřený decentralizovaný sběrnice systém využívající sériového přenosu dat - zpráv. Skládá se z uzlů, resp. *regulátorů*, které si mezi sebou vyměňují informace. Každý regulátor obsahuje univerzální čip *Neuron*, obsahující neuronový čip a připojení na sběrnici. Neuronový čip obsahuje tři osmibitové procesory, paměti, časovací jednotku, vstupní/výstupní část a komunikační sběrnici. Použitý protokol se nazývá *LonTalk* a celá technika se označuje souborně jako *LonWorks*. Topologie je odvozena z počítačových sítí.

Digitální signál sběrnice *LON* je přenášen sériově ve tvaru zpráv resp. telegramů na různých přenosových mediích stejně jakou u sběrnice *EIB*, např. po krouceném pár vodičů, elektrorozvodné síti, vysokofrekvenčními rádiovými vlnami, infračerveným spojením, koaxiálním kabelem nebo skleněnými vlákny.

Přenosová rychlost se pohybuje mezi 600 bps až 1,25 Mbps v závislosti na druhu použitého přenosového media a délky spojení, tj. u krouceného páru vodičů je dosahováno rychlosti 10 kbps na vzdálenost 2700 m, zatímco na vzdálenost 1500 m až 78 kbps a na 130 m až 1,25 Mbps.

V systému *LON* je použit protokol *LonTalk*, který je součástí firemního programu resp. *firmware* a dnes je již otevřený a standardizován, takže jej lze implementovat i mikroprocesory nezávislými na čipu *Neuron*.

V praxi se sběrnice *LON* s výhodou využívá v aplikacích, kde je kladen nárok na délku sběrnice nikoliv na rychlost přenosu dat. Základní využití sběrnice je v případě propojování různých systémů např. vytápění, uzavřený televizní a kamerový okruh, přístupové systémy, řízení spotřeby energií, apod. Pro připojení sběrnice *LON* do PC je nutné využít vhodného adaptéru. Adaptérem jsou data transformována ze sběrnice do příslušného vizualizačního systému, který umožňuje data zobrazit. [7]

2.5.4. Sběrnice M-Bus

Tato sběrnice je určena pro aplikace sběru dat z měřičů odběru nejrůznějších médií. V praxi se jedná o sběr dat z měřičů spotřeby tepla, průtočného množství a odběru pitné a užitné vody, plynu, tepla, elektrické energie apod. Sběrnice musí zajistit propojení relativně velkého počtu zařízení, řádově několika set, na vzdálenost až několika kilometrů. Přenos dat musí být kvalitně zabezpečen proti chybám. Na druhé straně typickou vlastností aplikace je nepříliš časté odečítání naměřených hodnot s nízkými nároky na odezvy v reálném čas. Přenosové rychlosti se pohybují do 9600 Bd (baudů) a má obvykle i nízké požadavky měřičů na výpočetní výkon procesoru. [7]

Data na sběrnici *M-bus* jsou přenášena asynchronně s délkou 8 bitů a sudou paritou. Mezi jednotlivými znaky nesmí být časové mezery. Přenos dat na sběrnici odpovídá komunikaci *master/slave*. To znamená, že na sběrnici je vždy jedna řídicí jednotka - *master*, která posílá a přijímá data od jednotlivých účastnických stanic - *slave*. Přenos dat, resp. bitů mezi řídicí jednotkou a účastnickou stanicí odpovídá hodnotám logická 0 a logická 1, přičemž tyto logické úrovně jsou odlišeny hodnotami napětí. Logická 0 má napětí 24 V a logická 1 má napětí 36 V. Stanice odpovídá změnou proudu. Maximální počet stanic, které mohou komunikovat na sběrnici, je 250. [7]

Přenosová rychlost je úzce svázána s délkou kabelového segmentu a může se pohybovat v rozsahu 300 až 9600 Bd. Maximální délka kabelového segmentu nesmí překročit 1000 m (350 m pro 9600 Bd). Pro rozsáhlejší systémy je nezbytné přejít ke složitějším konfiguracím, kdy je celý systém rozdělen na tzv. zóny. Jednotlivé zóny se skládají ze segmentů připojených prostřednictvím vzdálených opakovačů a jsou řízeny tzv. řadiči zóny. [7]

Zařízení a měřiče jsou propojeny s řídicí jednotkou a dále prostřednictvím koncentrátoru jsou data ukládána do počítače, kde mohou být dále zpracovávána. Komunikace mezi koncentrátorem a počítačem probíhá prostřednictvím sériové linky RS-232. [7]

2.5.5. Protokol BACnet

V důsledku celosvětového rozšíření využívání internetu se komunikační protokol *BACnet* prosadil i v oblasti automatizace budov, kde podporuje protokol *IP (Internet Protocol)* a umožňuje tímto způsobem využívat globální síťové systémy. [6] Protokol je určen pro automatizační a operátorskou úroveň automatizace budov. Podstatou protokolu *BACnet* je formulace univerzálního popisu všech možných funkcí zařízení. Protokol je celosvětovou normou a výkonným standardem automatizace budov. Používá se bez licenčních poplatků. [7]

Přenos zpráv protokolem lze realizovat několika různými způsoby:

- prostřednictvím sítě ethernet/IP, kde je tato komunikace v systémech automatizace budov nejvyužívanější a přenos dat tímto médiem se pohybuje rychlostí od 10 MBps až do 100 MBps,
- prostřednictvím sítě RS-485, kde slouží sériová linka jako sběrnice s protokolem *MS/TP (master-slave/token-passing)*, která má jeden nebo více uzlů *master*, kteří spolupracují v logickém kruhu; sběrnice může mít i účastnické uzly *slave*, které ovšem nemohou vysílat zprávy bez jejich vyžádání masterem.

Protokol *BACnet* specifikuje tři hlavní části:

- *BACnet* objekty, tzn. fyzický resp. datový bod či skupiny, které splňují definované požadavky; jedná se o jednotlivá zařízení, snímače, přístroje a jiné,
- *BACnet* služby, tzn. příkazy v komunikaci klient-server; jedná se o služby hlášení a událostí, přístupy k objektům nebo souborům, vzdálenému přístupu a další,
- *BACnet* komunikace, tzn. vzájemná výměna zpráv mezi objekty s využitím již existujících komunikačních protokolů např. ethernet/IP, *LonTalk*, *BACnet*, *ARCNET*. [7]

Vzhledem k výše popsanému, je výhodné použití protokolu *BACnet* v aplikacích, kde se využívá komunikace po ethernet/IP, resp. internetového

připojení. Některá zařízení, která mají implementovanou komunikaci po protokolu *BACnet*, mají integrovaný webserver a je tedy možné k těmto zařízením přistupovat zadáním odpovídající IP adresy.

2.6. Problematika v integraci bezpečnostních systémů

Hlavní cílem integrace by mělo být úsilí propojit veškeré technologické prvky a systémy, kterými je budova vybavena, čímž se umocní efekt vynaložených pořizovacích nákladů na technologie a zvýší se jejich užitná hodnota v objektu. Realizováno bylo již velké množství projektů inteligentních budov, kde byly a jsou integrovány jen některé dílčí systémy.

Odpověď proč tomu tak je, lze nalézt v současné legislativní úpravě, resp. v právních předpisech a současně v českých technických normách (ČSN). Právní předpisy, resp. zákony jsou obecně závazné, zatímco české technické normy nemají takovou závaznost, ale mohou být zezávazněny, resp. nabývají *normované hodnoty*. Nabytím normované hodnoty se rozumí fakt, kdy povinnost dodržovat technické normy zakládají rovněž některé zákony či smluvní ujednání, která mají taktéž oporu v zákonech. [11]

Již z principu funkce inteligentní budovy je potřeba integrovat minimálně některé prvky bezpečnostních systémů pro plnou a korektní funkci inteligentních budov. Těmito prvky jsou:

- pasivní senzory (PIR), detektory a magnetické kontakty PZTS systémů,
- přístupové terminály ACS systémů,
- požární detektory systémů EPS,
- případně záznamy z kamer CCTV systému. [12]

Hlavní úskalí spočívá v integraci systémů PZTS a EPS s jinými systémy, resp. vstup do těchto uzavřených bezpečnostních systémů. PZTS a EPS jsou striktně definovány normami, např. musí být autonomní, nesmí být omezovány provozem jiných systémů, nesmí být ovlivněny a ovlivňovány jinými systémy a chybami vnějších systémů z čehož plyne i problematika propojení či napojení na již integrované systémy inteligentních budov. S ohledem stávajícím znění

norem ČSN 50131 a 50132 není možné systémy PZTS a EPS integrovat a současně dodržet předepsané požadavky norem.

U jednotlivých prvků systému PZTS či celku bývá vyžadována bezpečnostní třída a certifikace. Certifikace může být požadována právním předpisem, popř. normou ČSN, rozhodnutím státního orgánu, ale i zadavatelem ve smluvním ujednání - smlouvě o dílo. Pokud je do systému včleněn jediný prvek, který tyto podmínky certifikace nesplňuje, např. je certifikován na třídu bezpečnosti 1, splňuje celý systém bezpečnostní třídu 1 a to bez ohledu na všechny ostatní prvky, které splňují požadavky vyšší bezpečnostní třídy. Pro nekomerční objekty je tato problematika bezpečnostních tříd a certifikací méně palčivá, ačkoliv v případě pojistného plnění pojišťovnou může být pojistný nárok krácen z důvodů nesplnění pojistných podmínek pro ochranu majetku.

Snahou a reakcí na vývojový trend systémů inteligentních budov je nová norma ČSN 50398 přijatá roku 2009. Tato technická specifikace uvádí požadavky na poplachové systémy, které jsou kombinovány nebo integrovány s jinými systémy, které mohou a nemusí být poplachovými systémy. Dále definuje požadavky týkající se pravidel integrace s cílem zdůraznit význam jednotlivých aplikačních poplachových norem a objasnit případné rozpory. Poplachové přenosové systémy nejsou zahrnuty do této technické specifikace, [13] čímž je tato norma neruší, ale na stávající normy ČSN 50131 a 50132 navazuje.

Norma ČSN 50398 stanovuje typy konfigurace integrovaných systému (typ1, typ 2A, typ 2B) a pravidla, za kterých se mohou integrované systémy vzájemně ovlivňovat, resp. je tolerován vznik a průnik chyb vlivem integrace k jinému systému. [12][13] Pokud jsou v platnosti normy ČSN 50131 a 50132 v nezměněném znění, je tato norma pouze signálem snahy, řešit komplikovanou situaci v integraci bezpečnostních systému do souboru integrovaných systémů inteligentních budov, ale pro řešení této problematiky má malý přínos.

Budovy, které jsou vybaveny kamerovým systémem (CCTV), resp. uzavřeným kamerovým okruhem, jehož účelem je pořízení, záznam a uchování zvukového, obrazového nebo jiného záznamu ze sledovaných míst, formou

pasivního monitorování prostoru nebo pořizování cílených záběrů, resp. zachycování pohybu nebo reportážním způsobem plynou také zákonné povinnosti, zejména pokud je systém vybaven záznamovým zařízením na monitorování fyzických osob. Konfiguraci takového systému lze dle zákona na ochranu osobních údajů č. 101/2000 Sb. považovat vždy za systém zpracovávající osobní údaje. Jinak by to mu bylo v situaci, pokud by systém sloužil k pouhému monitorování sledovaných míst bez záznamu.

Záběry zachycující znaky umožňující odlišení fyzické osoby od jiné, zejména obličeje, vytvářejí ze záběru minimálně potenciální osobní údaj a jako s takovým by s ním mělo být nakládáno. Je zřejmé, že pořízení těchto záznamů a snímků je činěno právě se záměrem budoucího ztotožnění osob. Může být argumentováno, že pokud nebude záznam z kamerového systému možno doplnit dalšími informacemi o zaznamenané osobě - subjektu údajů, nelze údaje takto získané v obecné rovině vztáhnout k určitému nebo určitelnému subjektu údajů a tudíž se jednoznačně nejedná o osobní údaj. [14]

Povinnosti, které plynou z pořizování záznamů a při provozování kamerového systému vybaveného záznamovým zařízením jsou:

- kamerové sledování nesmí nadměrně zasahovat do soukromí,
- specifikace sledovaného účelu, např. ochranou majetku před krádeží popř. přípustnost využití záznamů pro jiný účel musí být omezena na významný veřejný zájem, např. boj proti pouliční kriminalitě,
- stanovit lhůtu pro uchování záznamů,
- řádně zajistit ochranu snímacích zařízení, přenosových cest a datových nosičů, na nichž jsou uloženy záznamy, před neoprávněným nebo nahodilým přístupem,
- subjekt údajů musí být o užití kamerového systému vhodným způsobem informován, např. nápisem umístěným v monitorované místnosti nebo objektu a současně je třeba garantovat další práva subjektu údajů, zejména právo na přístup k zpracovávaným datům a právo na námitku proti jejich zpracování, [14] [15]
- zpracování osobních údajů je třeba registrovat u Úřadu pro ochranu osobních údajů.

Bylo by bláhové vyčlenit z integrace tyto systémy (protipožární ochrany, resp. požární signalizace a bezpečnostní systém spolu s uzavřeným televizním okruhem), které se svými čidly disponují kvalitními vstupními informacemi, které jsou nezanedbatelnými vstupy pro řízení a regulaci, popř. automatizaci, dalších integrovaných subsystémů.

3. Neuronové sítě

Neuronové sítě jsou definovány jako nedeklarativní systémy umělé inteligence. Nedeklarativní jsou v tom smyslu, že nemusíme předem definovat pravidla, kterými se neuronová síť řídí. Pravidla řešení se stanovují až během učení [16], tzn. během procesu získávání znalostí a osvojování za pomoci množiny předkládaných vzorů bez nutnosti znalosti algoritmu řešení. Druhou skupinou jsou neuronové sítě, které nevyužívají množiny vzorů, resp. očekávaných výstupů, jelikož tyto vstupy nejsou doposud známy nebo zjištělné.

Neuronové sítě, které jsou dnes považovány za hlavního reprezentanta umělé inteligence, mají široké využití a objevují se stále nové oblasti, kde nacházejí uplatnění. Již od 60. let se umělé inteligentní systémy používají k vyhlazování signálů v telefonních a radiokomunikačních sítích. Běžně se dnes používají k rozpoznávání obrazů, snímků nebo psaného písma *OCR (Optical Character Recognition)*, známé jako optické rozpoznávání znaků. [17] Další využití neuronových sítí je v předpovědích zejména s pomocí časových řad (finanční trhy, plánování odbytu, výše skladových zásob, geologické a termální aktivity, atd.), při rozhodování, řízení technologických procesů, komprese dat např. obrazu a zvukových záznamů, hledání nejlepších řešení tzn. optimalizace, filtrace dat, dobývání znalostí (*data mining*) a mnoho jiných.

Neuronové sítě mají své opodstatněné využití v případech, kdy při řešení daného problému buď není možné matematicky popsat všechny vztahy a souvislosti, které ovlivňují sledovaný proces, nebo v případech, kdy se nám sice podaří exaktní matematický model sestavit, ale je tak složitý, že případná algoritmicizace úlohy je takřka nemožná. Rovněž také zjednodušené matematic-

ké popisy nemusí vést k žadoucím výsledkům zejména, pokud se jedná o složité nelineární systémy. [18]


3.1. Topologie neuronové sítě

Neuronová síť je struktura, pro distribuované paralelní zpracování dat. Model umělé neuronové sítě je charakterizován:

- *topologií* nebo také *architekturou*, resp. uspořádáním a hustotou uzlů a propojením mezi nimi, počtem vrstev, částečným či úplným propojením v síti, vazbami dopřednými (acyklickými) nebo rekurentními (cyklickými, zpětnovazebnými) viz obr. 6,
- algoritmem *učení*, resp. způsobem jakým jsou upravovány a nastavovány vstupní váhy (označovány jako synaptické váhy) v jednotlivých spojkách,
- *přechodovými funkcemi*, které modifikují signál, na synchronní a asynchronní. [19]

Neuronovou síť můžeme pomocí teorie grafů definovat takto:

„Neuronová síť je orientovaný graf s ohodnocenými hranami, kde rozeznáváme uzly vstupní, výstupní a skryté, a kde hrany reprezentují tok signálu. Hrany jsou ohodnoceny parametrem zpracování signálu, který je nazýván vahou.“ [20]



Obr. 6. Jednoduchý model umělé neuronové sítě [20]


Na obrázku je jednoduchý model umělé neuronové sítě, který zobrazuje vstupní neurony (1). Tyto neurony přijímají vstupní signály a dále je propouštějí do skryté vrstvy, označené (2, šedivá). Skrytých vrstev může být více dle topologie či zvoleného modelu neuronové sítě. Výstupní neurony jsou označeny (3). Jednotlivá spojení jsou značena pomocí úseček se šipkou, kde šipka znázorňuje směr toku informace. Vzájemná výměna informací může probíhat mezi neurony v cyklech, což znamená, že si několik neuronů může posílat informace cyklicky. Dále je možné, aby si jeden neuron posílal informaci sám sobě pro své vlastní budoucí použití. [20]

Hlavním cílem neuronové sítě je naučit ji, resp. nastavit jí tak, aby poskytovala co nejpřesnější výsledky, tzn. s co nejmenší chybou. Po dobu procesu učení jsou upravovány hodnoty jednotlivých vah. Váhy na vstupech neuronu reprezentují zkušenost - paměť. Po naučení a adaptaci vah neuronové sítě přechází síť ve stav vybavování a uplatnění nabytých zkušeností.

3.2. Neuron

Na tomto místě je důležité a nezbytné seznámit se se strukturou a funkcí jednotlivých výkonových prvků umělých neuronových sítí – s *umělým neuronem*, který označován také jako *formální neuron*.

Neurony se pro větší výpočetní sílu spojují a vrství, čímž tvoří s jinými strukturou neuronové sítě. Umělý neuron byl inspirován a sestaven dle předlohy neurobiologického modelu neuronu v lidském mozku. Jeho matematický model (viz obr. 7) sestrojili neurofyziolog a kybernetik McCulloch a psycholog Pitts v roce 1943.



Obr. 7. Umělý neuronu, model McCulloch & Pitts (MCP)

$x_1 \dots x_n$	vstupy, vstupní vektor
$w_1 \dots w_n$	synaptické váhy
θ	prahová hodnota
ξ	součet vstupních hodnot – potenciál,
$f(\xi)$	přechodová funkce
y	výstupní hodnota

Činnost umělého neuronu začíná příjmem vstupních informací, resp. signálů na vstupech ($x_1 \dots x_n$), kterých může být n-počet, soubor všech vstupních signálů je označován jako *vstupní vektor*. Každý jednotlivý vstup má vlastní hodnotu synaptické váhy ($w_1 \dots w_n$), kterou se upravuje přijatý signál. Upravený signál se uvnitř neuronu hromadí a vytváří *post-synaptický potenciál* (ξ), viz vztah (1).

$$\xi = \sum_{i=1}^n x_i w_i \quad (1)$$

Pokud celkový potenciál uvnitř neuronu dosáhne vyšší hodnoty, než je *prahová hodnota* (θ), která má obvykle zápornou hodnotu, vyšle neuron *výstupní signál* (y), který je transformován *přechodovou funkcí* ($f(\xi)$) na výstup. Matematicky lze tento proces vyjádřit vztahem (2). Při takové transformaci může neuron uplatnit i svoji lokální paměť, která je často reprezentována hodnotami váhových koeficientů u jednotlivých vstupů.

$$y = f \left(\sum_{i=1}^n x_i w_i + \theta \right) \quad (2)$$


Uvnitř neuronu pobíhají dva procesy, kde první vypočítává post-synaptický potenciál a druhý proces, který vypočítává výstupní hodnotu pomocí přechodové funkce, nejčastěji tzv. *sigmoidy*, viz vztah (3).

$$f(\xi) = \frac{1}{1 + e^{-k\xi}} \quad (3)$$

Každý neuron může mít vlastní přechodovou funkci, která může být buď spojitá, nebo diskrétní. Nejpoužívanějšími přechodovými funkcemi, které jsou označovány také jako *aktivační*, jsou:


Saturovaná lineární funkce

$$f(\xi) = \begin{cases} 1 & \xi > 1 \\ \xi & 0 \leq \xi \leq 1 \\ 0 & \xi < 0 \end{cases}$$




Ostrá nelinearita, skoková funkce

$$f(\xi) = \begin{cases} 1 & \xi \geq 0 \\ 0 & \xi < 0 \end{cases}$$




Logická sigmoidální funkce

$$f(\xi) = \frac{1}{1 + e^{-k\xi}}$$




Hyperbolická tangenciální funkce

$$f(\xi) = \frac{1 - e^{-\xi}}{1 + e^{-\xi}}$$



Radiální báze


$$f(\xi) = e^{-k\xi^2}$$



Přechodová funkce upravuje potenciál (ξ) na výstupní signál (y), který může být vstupním signálem pro další pracovní vrstvu, resp. skrytou, uvnitř vícevrstvé struktury neuronové sítě a stejným způsobem i pro další skryté vrstvy až k výstupní vrstvě. Přechodové funkce se dělí na prahové, lineární a nelineární, kde většina systémů je nelineárních.

3.3. Lineární separabilita

Použití lineární funkce je závislé na možnosti uplatnění lineární separability, tzn. na možnosti rozdělit množinu zjištěných hodnot přímkou na nadrovinu a podrovinu, přičemž jedna z množin nesplňuje požadovaná kritéria a je pro další výpočet nepoužitelná. Lineárně separovatelný problém je lépe zřejmý z příkladu a grafu níže (viz obr. 8). [21]



Obr. 8. Skupina mužů (modře) a žen (červená) dle délky vlasů cm a výšky postavy v cm [22]

U skupiny mužů a žen byly zjišťovány rozměry výšky postavy a délky vlasů. Pomocí vložené přímky klasifikujeme nadrovinu, do které patří převážně ženy a podrovinu, kam spadají převážně muži.

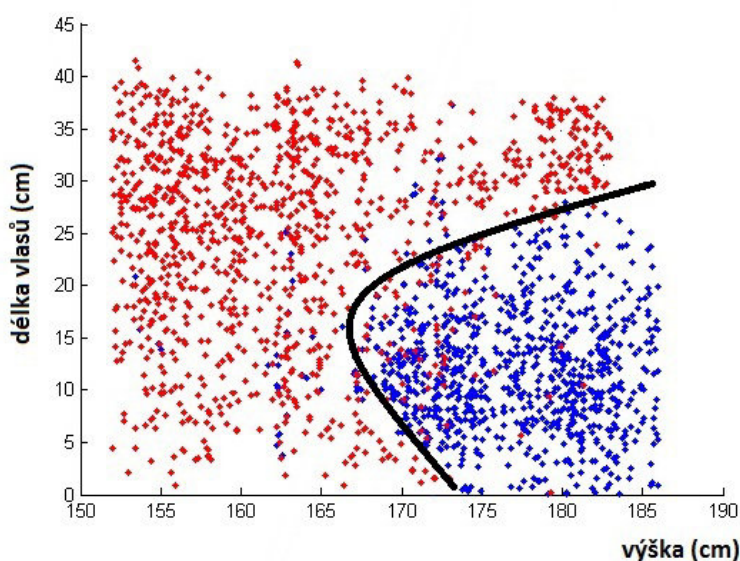
Pokud budeme nadále zjišťovat rozměrové údaje, tj. výšku postavy a délku vlasů, ale již nebudeme zjišťovat pohlaví nebo tento údaj nebude moci získat, lze dle dostupných údajů klasifikovat, zdali subjekt je muž či žena tím, zdali se nachází v množině před či za přímkou. Rozdělené množiny hodnot jsou označovány jako *separované klasifikační třídy*.

Neuron, který by tuto úlohu jednoduchou úlohu obsáhl a sám vyřešil, by měl pro vstupní hodnoty stanoveny váhy, tj. výšku a délku vlasů a dle potenciá-

lu by lineární přechodovou funkcí vyhodnotil, zdali se jedná o muže či ženu, přiřazením výstupní hodnoty 1 nebo 0. [22]


Z obrázku je zřejmé, že do množiny mužů nebo žen jsou zařazeni ne-
správně subjekty opačného pohlaví, které ovšem odpovídají parametrům. Proto
se tato řešení nehodí pro úlohy, kde nesmí být nejistota nebo chyba, což jsou
například finanční a konstrukční úlohy, účetnictví apod.

Výsledky řešení závisí na vstupní, skryté a výstupní vrstvě jako celku. Na
topologii sítě závisí způsob, jakým síť pracuje a jak rychle. [23]



Obr. 9. Lineárně neseparabilní množina hodnot

Jiný způsob řešení nastává, pokud řešení problému neumožňuje separo-
vat množinu hodnot lineárně (viz obr. 9). Takou úlohu nelze řešit pouze jedním
neuronem, ale skupinou propojených neuronů – vrstevnatou neuronovou sítí
(viz obr. 10).



Obr. 10. Vliv počtu vrstev neuronové sítě na schopnosti klasifikace [24]

1. ... jednovrstvý model neuronové sítě
2. ... dvouvrstvý model neuronové sítě
3. ... třívrstvý model neuronové sítě

3.4. Rozdělení umělých neuronových

Hlavní skupinami neuronových sítí jsou modely *neurologické* a modely *pro praktické aplikace*. Neurologické modely jsou sestavovány pro neurologické účely a nebudou dále diskutovány. Pro požadované účely budou diskutovány aplikační modely a jejich praktické uplatnění a využití.

Neuronová síť pracuje jako třídič vstupů. Třídy, které má síť rozpoznávat je nutno ji naučit. Učení neuronových sítí **s učitelem** (*supervised net*) probíhá pomocí trénovací množiny na vstupu, kde je definována vstupní hodnota a k ní je znám požadovaný výstup, výstupní hodnota. Síť s učitelem bývají užívány v oblastech určení a klasifikace vstupních hodnot s neúplnými či porušenými exempláři.

Zvláštní skupinou jsou sítě, které si třídy vytváří samy ze vstupních dat a jedná o **síť bez učitele** (*unsupervised net*), u kterých výstupní hodnoty nejsou zjistitelné nebo nemohou být zjištěny s předstihem. Síť *bez učitele* jsou aplikovány v oblasti redukce dat. [25]

Neuronové sítě můžeme dále rozdělit podle následujících hledisek:

podle vstupních signálů

- s binárním vstupem
 - s učitelem
 - bez učitele
- se spojitými (reálnými) vstupy
 - s učitelem
 - bez učitele

podle struktury sítě

- nestrukturované modely sítě obsahují neurony, kde si jsou všechny neurony rovnocenné a síť je homogenní, bez členění
- strukturované modely sítě obsahují podsítě a vrstvy
 - hierarchické modely obsahují vrstvy stejného typu,
 - kompetiční modely obsahují vrstvy, jež mají různý typ a mohou vykovávat různé funkce [25]

podle způsobu učení

- asociativní
- neasociativní

podle průběhu učení

- jednorázové
- periodické, po obdobích


podle váhové adaptability

- s pevnými váhami (LAM, BAM, Hopfieldova síť)
- s adaptabilními váhami

3.5. Vícevrstvý perceptron

Model umělého neuronu a neuronové sítě je příliš vzdálen od biologických neuronových sítí a jejich funkcí. Proto se stále hledají vhodnější modely, jedním z nich je *perceptron*. Perceptron je jednovrstvá síť, která sestává pouze z jednoho neuronu, která je schopna řešit jen omezený okruh problémů.

Model perceptronu patří k neznámějším a nejpoužívanějším modelům neuronových sítí. Základním prvkem je perceptron, popsany Frankem Rosenblattem už v roce 1957. Učící algoritmus pro tento model byly navrženy až vědci Rumelhaltem, Hintonem a Williamsem v roce 1986. Hlavní myšlenkou jejich řešení je nahrazení nespojité prahovací funkce, resp. skokové, funkcí spojitou (diferencovatelnou) např. sigmoidou, což umožňuje při učení použití gradientní metody optimalizace. Pro řešení rozsáhlejších úloh se uplatňují *vícevrstvé perceptronové sítě MLP (Multi-Layer perceptron)*, viz obr. 11.



Obr. 11. Vícevrstvý perceptron (MLP)

$x_1 \dots x_n$	vstupy, vstupní vektor
$w_1 \dots w_n$	váhy, váhový vektor
$y_1 \dots y_n$	výstup, výstupní vektor

Vícevrstvá perceptronová síť se skládá z několika vrstev a neurony jsou propojeny tak, že výstup jakéhokoliv neuronu vede do vstupů všech neuronů v následující vrstvě. Síť může obsahovat jednu nebo více skrytých vrstev. Jedná se o jednosměrné dopředné spojení. Počty vrstev a neuronů se přibližně

určují pomocí heuristik. Pokud je počet malý, potom síť není schopná zachytit všechny vazby v učicích datech. Pokud je počet vrstev příliš velký, pak se zvyšuje doba trénování sítě. Navíc může dojít k přeučení, kdy síť není schopná generalizace. [26]

Vícevrstvá perceptronová síť s dopředným šířením nachází hlavní využití v následujících případech:

- klasifikace, resp. určení možných tříd vstupů,
- predikce časových řad,
- aproximace,
- řízení. [25]

3.5.1. Učení vícevrstevných sítí

Základem pro učení jakékoliv neuronové sítě je *Hebbův zákon učení* z roku 1949, který popisuje algoritmus modifikace hodnot synaptických spojení v nervových systémech živých organismů. Založen je na předpokladu, že jestliže jsou dva spojené neurony v jednu chvíli aktivní, tak se vazba, resp. synaptická váha spojení mezi nimi zesiluje a naopak. Předpokládá, že neuron je buď aktivní, nebo neaktivní. [18]

Procesem učení vícevrstevných umělých sítí je snaha, nalézt hodnotu vah tak, aby byla minimalizována chyba u výstupných, požadovaných hodnot trénovací množiny, které jsou známy.

Vzhledem k diferencovatelnosti přechodových funkcí může být pro učení použita *gradientní metoda optimalizace*, která je založena na výpočtu gradientu ztrátové funkce a následném upravení všech vah ve směru gradientu. Úpravy se provádí pro každý vzorek z trénovací množiny tak dlouho, dokud není nalezeno vhodné řešení.

Pro učení neuronových sítí jsou nejčastěji používány tyto gradientní metody (algoritmy):

- *back-propagation*, označována jako zpětné učení nebo šíření chyby,
- *conjugate gradient descent*, algoritmus se snaží postupnými kroky dosáhnout minima,
- *quasi-Newton*, tento algoritmus se snaží nalézt maxima a minima zvolené funkce (vychází z Newtonových metod hledání stacionárních bodů s nulovým gradientem),
- *Levenberg-Marquardt*, minimalizuje funkci přes její parametry,
- *quickProp*,
- *delta-bar-delta*.

Mezi negradiční metody učení dále patří např. evoluční techniky (gnarl, sane, neat, HyperNeat a jiné techniky). [27] Za bližší zmínku stojí metoda *back-propagation*, která je nejpoužívanější a jedním z neúčinnějších nástrojů všech modelů neuronových sítí.

3.5.2. Metoda back-propagation

Základem pro využití této metody je vrstvená síť, kde nejsou žádné zpětné vazby, resp. acyklická struktura. Zpětné šíření chyby probíhá zpětně přes všechny vrstvy k první vrstvě a současně musí být známa vstupní a výstupní dvojice hodnot. Učení při této metodě probíhá v následujících třech krocích:

- síť je předložena trénovací množina, u které je po průchodu sítí na výstupu zjištěna odchylka od požadovaného výsledku trénovací množiny,
- zpětné šíření informace o této odchylce ve směru od výstupu ke vstupu, kde je zjištěna odchylka pro každý neuron v síti,
- adaptací vah se tato odchylka, resp. chyba minimalizuje.

Průběh učení lze i matematicky vyjádřit vztahem (4), kde vektor vah (w) je náhodně inicializován a následně iterativně zlepšován. V každé iteraci je určen vektor gradientu $g = (\nabla E)(w)$ a je učiněn krok proti jeho směru, kterým jeho chybovou funkci minimalizujeme. V nejjednodušší verzi můžeme úpravu vah na

novou hodnotu vah $w_{(t+1)}$, kde parametr (η) nazýváme *učící koeficient (learning rate)* a původní váha $w_{(t)}$ je v dalším kroku adaptována.

$$w_{(t+1)} = w_{(t)} + \eta \times g \quad (4)$$

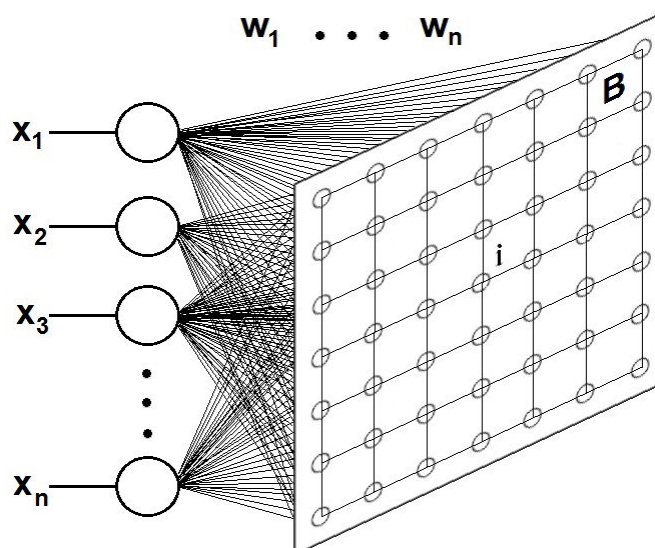
Tento druh učení má i několik nepříjemných vlastností. Chybová funkce je závislá na všech vahách, kterých může být velký počet a dále může existovat více lokálních minim, přičemž gradientní metoda je schopna nalézt nejbližší minimum, které nemusí být hledaným globální. Druhým problémem je vyšší počet parametrů, které nejsou striktně určeny algoritmem, ale přesto ovlivňují celkovou výši odchylky - chyby.

3.6. Kohonenova mapa

Hlavním představitelem a vybraným zástupcem samoorganizující neuronové sítě s dopředným šířením a učením bez učitele je Kohonenova mapa, která ke svému nastavování nepotřebuje ideální vzory, resp. nejsou zapotřebí učící, cílové hodnoty, tzv. *target*, které napomáhají učení síti s učitelem. Získání těchto cílových hodnot pro učení bývá často velkým problémem a právě v těchto případech jsou užitečné *samoorganizující mapy SOM (Self Organizing Maps)*, které tyto hodnoty nevyžadují. K učení sítě stačí jen velká skupina reálných signálů, z nichž některé mají určitou společnou vlastnost nebo naopak výrazné odlišnosti. [25][28]

Samoorganizující sítě nacházejí uplatnění při rozlišení, rozpoznávání, analyzování a třídění neznámých číslicových signálů a dat. Dokáží sami rozpoznávat shodné prvky nebo naopak rozdíly mezi signály a je možné s jejich pomocí zpracovat úplně neznámé signály a data. Dostačují je např. skupina nahraných řečových signálů a během učení si síť již sama nalezne společné znaky a odlišnosti, podle kterých se bude ve své aktivní činnosti rozhodovat. Tato schopnost je hlavní výhodou, pro kterou se stala často využívanou a velmi oblíbenou neuronovou sítí. [25][28]

Další uplatnění SOM nacházejí v oblasti rozpoznávání a zpracování obrazu, např. ručně psaného textu a jeho tištěnou formu nebo hledání a detekce osob podle fotografií v bezpečnostních systémech a aplikacích.




Obr. 12. Kohonenova mapa

$x_1 \dots x_n$	vstupy, vstupní vektor
$w_1 \dots w_n$	váhy, váhový vektor
i	vítězný neuron
B	kompetiční 2-D vrstva

Kohonenova mapa má nejčastěji strukturu jednovrstvé dvourozměrné sítě ve tvaru čtverce (viz obr. 12), obdélníku, hexagonu, ale může mít i tvar jedno-rozměrného vektoru. Tvar struktury a uspořádání neuronů má vliv na učení mapy.

Uspořádání neuronů má vliv na volbu tzv. *okolí neuronu* (Ne) viz obr. 13, které vymezuje jeho sousedy, tj. nejbližší postavené neurony. V maticovém uspořádání neuronů (čtvercovém nebo hexagonálním) je velikost okolí rovná počtu řad neuronů od centrálního neuronu. [28]



Obr. 13. Uspořádání neuronů v dvourozměrné kompetiční vrstvě s definicí okolí (Ne) a vítězného neuronu (i)

3.6.1. Učení samoorganizujících map

Matici neuronů, resp. kompetiční vrstvě jsou postupně předkládány vektory vstupního signálu ($x_1 \dots x_n$) tak, že se zvláště porovnává rozdíl příslušných hodnot vektoru vah ($w_1 \dots w_n$) každého neuronu s hodnotami vektoru každého vstupního signálu. K vyjádření rozdílu se může využít různých algoritmů, ale nejčastěji se dává přednost výpočtu *euklidovské vzdálenosti* (d), tj. součet rozdílů příslušných hodnot dle vzorce (5). [28]

$$d = (x_1 - w_1)^2 + (x_2 - w_2)^2 + \dots + (x_n - w_n)^2 \quad (5)$$

Výsledek je tedy počet hodnot (d), rovný počtu neuronů, ve struktuře (např. 100 hodnot v matici 10 x 10 neuronů). Následně se vybere jediný neuron s nejmenší hodnotou (d) a označí se jako tzv. vítěz (*winner*). Váhy tohoto neuronu totiž nejvíce ze všech odpovídají hodnotám právě předloženého signálu. Při předkládání první učícího vstupního vektoru se jeho hodnoty porovnávají s náhodně vygenerovanými hodnotami vah (w) jednotlivých neuronů. Váhy (W) vítězného neuronu se pak upravují, resp. adaptují, aby se co nejvíce přiblížily hodnotám právě předloženého vstupního vektoru (x).

Pro tento účel slouží vzorec (6), kde (α) je *učicí koeficient*, který vyjadřuje rychlost učení a může nabývat hodnot 0 až 1.

$$W_{(t+1)} = W_{(t)} + \alpha \times (x_{(t)} - W_{(t)}) \quad (6)$$

Při opětovném opakování dávky učících vektorů nebo postupným předkládáním dalších nových dávek se učicí koeficient obvykle snižuje. Spolu s vítězným neuronem se mění i učicí koeficient (α) v sousedním definovaném okolí ($Ne_1 \dots Ne_n$), viz obr. 13. Váhy sousedních neuronů se upravují stejným způsobem jako u vítěze, pouze s tím rozdílem, že koeficient (α) je nahrazen koeficientem (β), přičemž platí $\alpha < \beta$. Při opětovném opakování dávky učících vektorů se může provádět i snižování hodnoty okolí až na $N_e = 0$, adaptuje se pouze *vítěz*. [28] Pokud dochází ke změně vah, opakuje se tento proces pro všechny vstupní vektory až do fáze, kdy nebude možná změna vah.


Kohonenovy mapy, resp. samoorganizující mapy (SOM), jsou silným a kvalitním nástrojem pro identifikaci neznámých vlastností a parametrů, skrytých v digitalizovaných vzorcích libovolného signálu. V některých aplikacích mohou pracovat jako alternativa k jiným algoritmům a v některých aplikacích jsou již nenahraditelné. Schopnost neustálého doučování během činnosti umožňuje přizpůsobení funkce při dlouhodobě trvajících změnách. Tím se již blíží k samotné funkci našeho mozku, který též dokáže přizpůsobovat naše chování změně prostředí. Samoorganizace a samoučení je tedy základem opravdu inteligentní umělé inteligence. [28]

3.7. Hopfieldova síť

Hopfieldova síť byla navržena J. Hopfieldem v roce 1982 a vychází z původního konceptu sítě, který sestrojili pánové W. McCulloch a W. Pitts, tvůrci prvního modelu umělého neuronu.

Tento model neuronové sítě byl vytvořen jako asociativní paměť. Hopfieldův vylepšený model je krokem od neurobiologických struktur, protože používá symetrické vazby mezi neurony, kde jsou neurony propojeny každý s každým

a současně je každý neuron vstupním a současně výstupním. V přírodě takové struktury neexistují, což dokládá *Hebbovo* pravidlo, podle kterého se synaptické spojení (resp. váha) mezi dvěma současně aktivovanými neurony biologických struktur posiluje. Zde se váha spojení mění, i když jsou oba neurony neaktivní.



Obr. 14. Hopfieldova síť

$x_1 \dots x_n$ vstupy, vstupní vektor
 $y_1 \dots y_n$ výstupní, vstupní vektor

Hopfieldova síť je jednovrstvá zpětnovazebná cyklická síť s pevnými váhami. Vstupní signál, resp. vektory jsou binární a nabývají pouze hodnot 0 a 1 popř. bipolárních hodnot +1 a -1. Hodnoty výstupů jsou bipolární.

Propojení může být reprezentováno symetrickou maticí vah s nulovou hlavní diagonálou (viz obr. 15). Tato diagonála representuje vlastní vazbu neuronu sama se sebou, která u Hopfieldovy sítě neexistuje, resp. nelze ji aplikovat, a tudíž se rovná nule.

	$\textcircled{n_1}$	$\textcircled{n_2}$	$\textcircled{n_3}$	\dots	$\textcircled{n_n}$
$\textcircled{n_1}$	$\textcircled{0}$	$n_2 \triangleright n_1$	$n_3 \triangleright n_1$	\dots	$n_n \triangleright n_1$
$\textcircled{n_2}$	$n_1 \triangleright n_2$	$\textcircled{0}$	$n_3 \triangleright n_2$	\dots	$n_n \triangleright n_2$
$\textcircled{n_3}$	$n_1 \triangleright n_3$	$n_2 \triangleright n_3$	$\textcircled{0}$	\dots	$n_n \triangleright n_3$
\vdots	\vdots	\vdots	\vdots	$\textcircled{0}$	\vdots
$\textcircled{n_n}$	$n_1 \triangleright n_n$	$n_2 \triangleright n_n$	$n_3 \triangleright n_n$	\dots	$\textcircled{0}$

Obr. 15. Matice - Hopfieldova síť

Neurony mají dva stavy aktivovaný a neaktivovaný (dle vztahu 8) a provádějí prahový vážený součet, viz vztah (7).

$$y = f \left(\sum_{i=1}^n x_i w_i + \theta \right) \quad (7)$$

kde

$$f(\xi) = \begin{cases} 1: & \sum x_i w_i \geq 0 \\ -1: & \sum x_i w_i < 0 \end{cases} \quad (8)$$

Fáze učení bude začínat nastavením všech vah synaptických spojení na nulu. Neuronům přiřadíme hodnoty +1 a -1. Poté změňme všechny váhy podle následujícího pravidla a viz vztahu (8):


- jsou-li spojeny neurony se stejnou hodnotou, zvýšíme hodnotu váhy o jedničku,
- jsou-li spojeny neurony s rozdílnými hodnotami, hodnotu váhy o jedničku snížíme.

Tuto změnu vah je opakována u všech postupně přiložených vzorů. Postupným nastavováním vah model nepodstatné informace zapomíná a podstatné si čím dál tím více pamatuje, resp. posiluje vazby. Kladný popud vazbu zesiluje a záporný zeslabuje. Tento postup je opakován tak dlouho, až zůstanou jen potřebné vazby. Po naučení síť hodnota váhy každého neuronu vyjadřuje rozdíl počtu vzorů, ve kterých se spojené neurony svými hodnotami shodují a počtu vzorů, ve kterých se neshodují. [29]

Na rozdíl od vrstvených sítí perceptronů, které dávají odpověď ihned, Hopfieldův model potřebuje nějaký čas, aby se ustálil v určitém stabilním stavu. Kromě základního Hopfieldova modelu existují rozšířené varianty, které umožňují používat místo binárních hodnot hodnoty reálné, nebo které si místo jednotlivých stabilních stavů pamatují celé jejich sekvence. [29]

Asociativní paměti jako Hopfieldovy sítě jsou mocným nástrojem, který toleruje chyby a nachází hlavní využití v oblastech:

- kontroly pravopisu,
- rozpoznávání obrazu (např. 0 odpovídá bílé barvě a 1 černé),
- oprava neúplných nebo poškozených snímků a obrázků,
- spojitá varianta sítě se používá pro optimalizační řešení a odstraňování problémů.



Obr. 16. Příklad uspořádání Hopfieldovy sítě se 6 neurony [30]

4. Model neuronové sítě

Cílem této práce je oddiskutovat a otestovat možnost využití umělé neuronové sítě (resp. model) k odposlechu šifrované komunikace v PZTS systému, popř. v EPS. Funkci, jak by mohl takový „odposlech“ komunikace v systémech probíhat, by se dala přirovnat např. k situaci a obchodování brokerů na burze a to ještě v dobách, kdy neexistovaly elektronické burzy, ale burzovní domy s místy, kde se v hloučcích brokeři dohadovali a překřikovali o nákupech či odprodeji akcií ve prospěch klienta. Některé burzy ve Spojených státech do dnes ještě akcie takto obchodují (např. v Chicagu).

Brokeři pracují s vlastními utajenými informacemi, které pomocí vlastních signálů a gest předávají dále ve snaze tyto informace nevyzradit a realizovat obchod dříve než ostatní konkurenti. Ačkoliv jsou tyto gesta a signály nezávislému pozorovateli neznámy, lze z chování (nervozita, rychlost gest, výraz, frekvence, atd.) skupiny těchto obchodníků vyzpozorovat, popř. odhadnou zamýšlenou akci, popř. domyslet, co tuto reakci vyvolalo. Každý obchodník, jakož i v inteligentních budovách systém PZTS/EPS, je nebo jsou zdrojem vstupních informací pro naši neuronovou síť, které jsou šifrovány algoritmem a není snahou tyto informace dešifrovat či prolomit, ale z průběhu „chování“ komunikace v těchto systémech dospět k co nejpřesnějšímu závěru, resp. s co nejmenší chybou, odhalit příčinu tohoto stavu, který se mění v závislosti na okolnostech.

4.1. Vstupní data elektronické zabezpečovací signalizace (PZTS)

Pro potřeby naší simulace máme k dispozici data z komunikační sběrnice z ústředny elektrického zabezpečovacího systému (PZTS). Tato data obsahují záznam dvou různých situací zachycených bezpečnostním systémem, resp. dvě sady dat.

První sada dat hlásí klidový stav, tj. objekt je střežen – *nenapaden* (viz obr. 17). Druhá sada hlásí stav poplachu – *napadení* či *narušení* objektu (viz obr. 18). Tyto data poslouží jako vstupní data pro simulaci.

Soubor	Úpravy	Formát	Zobrazení	Nápověda
0000030055E0000B0B0B0B8B1F00E7000003010BD10000100010004				
00				
00				
0				
55C0000000				
0000030055E0000B0B0B0B8B1F00E7000003010BD00000000000000				
00				
00				
0				
58C0000000				

Obr. 17. Původní formát dat ze sběrnice a ústředny PZTS – **klidový stav**, ve tvaru telegramu (v souboru .txt)

Hlášení stavu zabezpečení je presentován sekvencí 55C0000000 nebo druhým hlášeným stavem 58C0000000, který je taktéž klidový (viz obr. 17).

Soubor	Úpravy	Formát	Zobrazení	Nápověda
0040030064E0400B0B0B0B8B2400A0004003013AD040C0000000000				
00				
00				
0				
4F40000000				
0040030064E0400B0B0B0B8B2400A0004003013AD140C0500014000				
00				
03				
0				
4A40000000				
0040030064E0400B0B0B0B8B2400A0004003013AD2405ACBB9020B0				
00				
00				
0				
7AC0000000				

Obr. 18. Původní formát dat ze sběrnice a ústředny PZTS – **poplachové hlášení o narušení objektu**, ve tvaru telegramu (v souboru .txt)

Takto upravená výstupní data z ústředny PZTS jsou již připravena a poslouží jako vstupní data pro další zpracování zvolenou neuronovou sítí, resp. modelem.

4.2. Vícevrstvá neuronová síť a software

Pro tuto simulaci byl zvolen model neuronové sítě, *vícevrstvý perceptron (MLP)* s dopřednými vazbami, dvěma skrytými vrstvami a zpětným šířením chyby (*back-propagation*). Tento typ neuronové sítě je vhodný ke klasifikaci, popř. kategorizaci tříd a stavů, které jsou prezentovány výstupními hodnotami, např.:

- zapnout, vypnout (ON/OFF),
- model, typ,
- zdravý, nemocný a další.

V tomto modelu jsou očekávány dvě hlavní třídy, ve kterých jsou prezentovány stavy:

- objekt narušen – not klid,
- objekt nenarušen - klid.

Pro tvorbu modelu byla zvolena aplikace **NeuroSolutions - verze 6.31** od společnosti *NeuroDimension Inc.*, se sídlem v Gainesville, Florida. Tato aplikace je využívána a vyvíjena od roku 1995 v 66 zemích pro vládní, vzdělávací i nevládní projekty (viz obr. 21).



Obr. 21. Hlavní uživatelé aplikací NeuroSolutions [31]

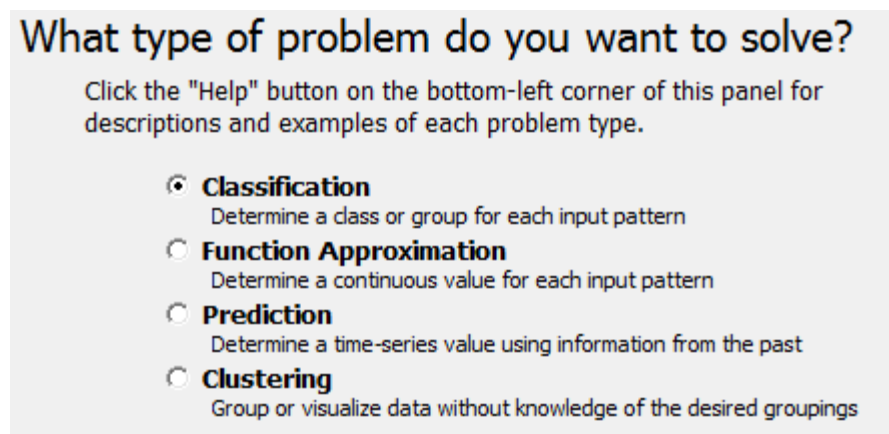
Tento software nabízí široké možnosti od výběru různých typů sítí, např. vícevrstvé perceptrony, modulární, RBF sítě, SOM až po vlastní konstrukci neuronové sítě, která vyžaduje již pokročilejší znalost tvorby neuronových sítí a vnitřních nastavení.

Další možností je využití průvodce, který zvolí doporučená nastavení všech komponentů neuronové sítě, které lze dodatečně dle potřeby upravovat, ale i tato varianta vyžaduje znalost a povědomí.

Zajímavou variantou využití *NeuroSolutions* je možnost čerpání vstupních a požadovaných dat z tabulkového procesoru - *Excel* od Microsoftu, kde jsou data upravována a na pozadí je současně spuštěna neuronová síť v *NeuroSolutions*. Tato varianta už je již placenou službou a nevztahuje se na verzi 30-denní bezplatnou testovací verzi.

4.3. Nastavení modelu vícevrstvého perceptronu


Zvolený model, v tomto případě vícevrstvý perceptron MLP, bude zpracovávat upravená data (resp. vstupní data) na požadovaná výstupní data. Pro tvorbu neuronové sítě byl zvolen průvodce, který v krátkém čase dokáže vytvořit model.



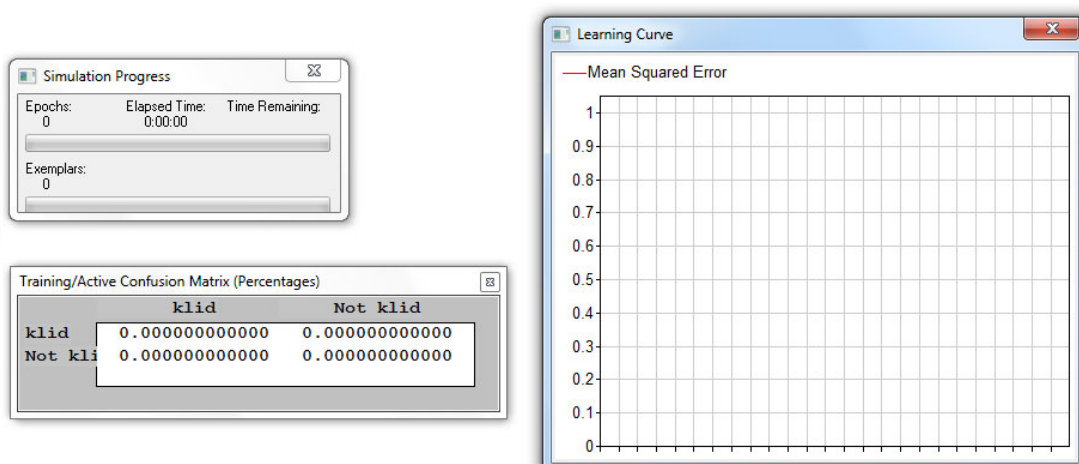
Obr. 22. Výběr problematiky pro řešení neuronovou sítí (s průvodcem) v prostředí *NeuroSolutions*, ver. 6.31

V následujících bodech je zvolen hlavní problém, který bude zpracováván a řešen, umístění vstupních dat a požadovaných výstupů na disku, volba

stupně komplexnosti (nižší úroveň odpovídá rychlejšímu zpracování dat a opačně). Po ukončení nastavení je automaticky sestrojena neuronová síť (viz obr. 23 a 24).



Obr. 23. Grafický model vícevrstvého perceptronu MLP v prostředí NeuroSolutions, ver. 6.31



Obr. 24. Nástroje a příslušenství v prostředí NeuroSolutions, ver. 6.31

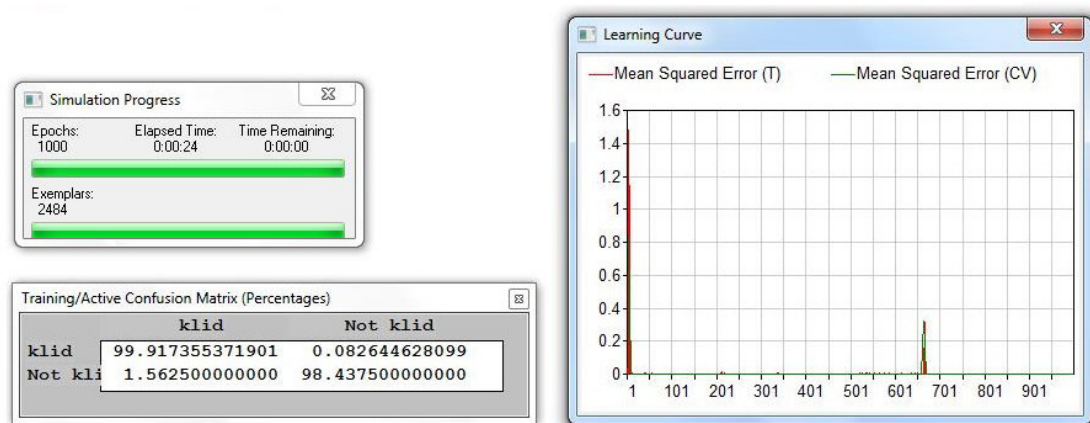
Popis uživatelského prostředí

Uživatelské prostředí se skládá z grafického modelu (viz obr. 23) a ukazatelů (resp. oken), trénovací matice v procentuálním vyjádření a grafu, který zobrazuje přepočítávanou *střední kvadratickou chybu* (MSE – Mean Squared Error), viz obr. 24. Po spuštění učení je průběh indikován měnícími se hodnotami a je vykreslována křivka.

Simulace

Po spuštění simulace probíhá vše automaticky dle předvoleného nastavení, kde jsou propočítávány prahovací hodnoty. Zpětným šířením chyby jsou propočítávány hodnoty synaptických vah. Pro Výpočet vah byla použita metoda *Levenberg-Marquardt*.

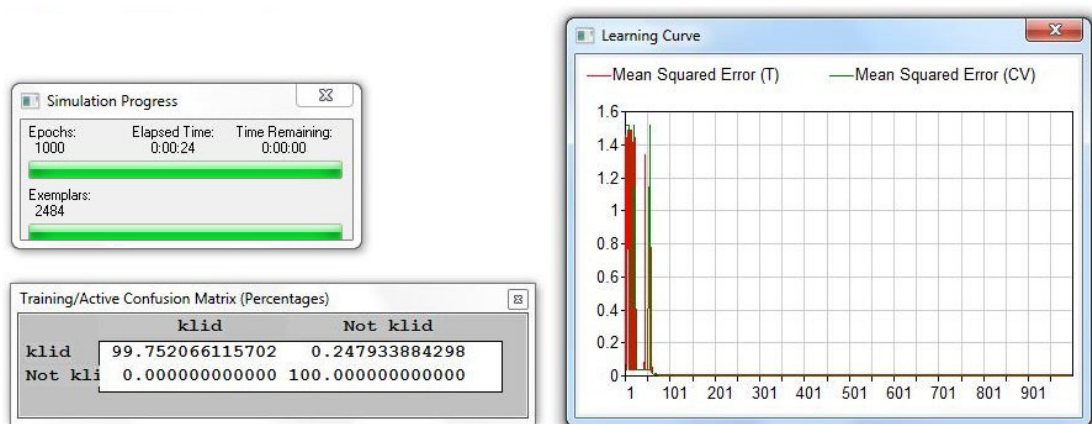
Učení probíhá ve zvoleném počtu opakování, resp. v počtu 1000 učicích epoch, které lze dle potřeby navýšit či snížit. V průběhu učení jsou upravovány procentuální hodnoty v matici a současně je vykreslována učicí křivka, která by měla mít klesající trend, resp. snižování střední kvadratické chyby (viz obr. 25)



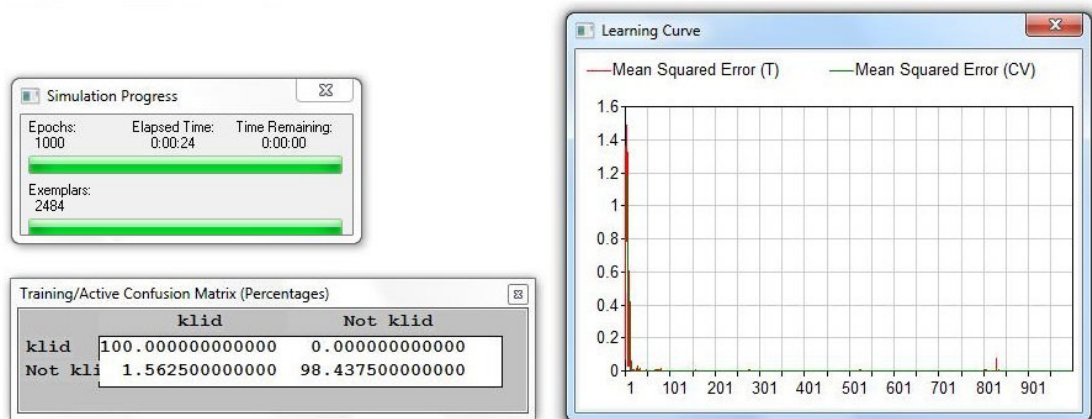
Obr. 25. Výstup z první simulace vícevrstvého perceptronu MLP, (klid 99,92 % a Not klid 98,44 %)

Dalšími drobnými úpravami váhových hodnot lze docílit lepšího poměru, resp. procentuálního vyjádření u sledovaných stavů: **klid**, **Not klid**. Z matice je možno odečíst hodnoty, které vyjadřují detekci požadovaného stavu a podíl chyby. V tomto případě (viz obr. 25 – matice/matrix) dokáže zvolený model detekovat na 99,92 % *klidový stav* (klid) a jiný stav (not klid - poplach, narušení či jiný) na 98,44 %.

Zmíněnými dalšími úpravami prahových hodnot byly získány lepší procentuální hodnoty stavů (viz obrázek 25 a 26) a tvar učicí křivky má jiný průběh.



Obr. 26. Výstup z druhé simulace vícevrstvého perceptronu MLP (klid 99,75 % a Not klid 100,00 %)



Obr. 27. Výstup z třetí simulace vícevrstvého perceptronu MLP (klid 100,00 % a Not klid 98,44 %)

Z výše doložených simulací je zřejmé, že lze pomocí neuronových sítí detekovat v sběrnice komunikaci inteligentních budov stavy, kdy je objekt napaden a kdy je v klidovém stavu.

Ačkoliv dle procentuálních hodnot bylo dosaženo velmi dobrých výsledků, průběh učící křivky by mohl mít hladší spojitější průběh, který by se dal upravit v nastavení, které už umožňuje pouze placená verze *NeuroSolutions* aplikace.

5. Závěr

Umělé neuronové sítě jsou dynamickými systémy, které se vyvíjí v čase, a jejich činnost se odvíjí od praktické aplikace. Neuronové sítě se uplatňují tam, kde nelze k řešení problému použít běžné metody algoritmizace nebo tam, kde se tyto metody pro složitost procesu či procesů nedají vůbec uplatnit. Podobnosti neuronových sítí s biologickými neurosystemy je předurčují k rozmanitým specifickým řešením, a ačkoliv jsou od své biologické předlohy zatím na hony vzdáleny, už dnes jsou hojně využívány a pomáhají při složitých procesech, výpočtech, simulacích a optimalizacích.

Od 80. let už jsou používány při zpracování grafiky a všude, kde je zapotřebí odstínit šum či zkreslení. V průmyslové oblasti nacházejí neuronové sítě uplatnění v robotice a automatizaci výroby, jakož i v jiných oblastech a odvětvích, např. lékařství, věda, logistika, finanční a bankovní sektor, obchod a další.

Oblastí, kde nacházejí neuronové sítě další praktické uplatnění je i diskutovaná problematika inteligentních budov. Nejedná se o alternativní řešení, kdy by bylo na výběr, ale o řešení, které je z pohledu konfliktu s legislativou a normami přijatelné a elegantní.

Toto technické řešení umožňuje s použitím umělých neuronových sítí integraci elektronického zabezpečení, popř. další problematických systémů (např. protipožární ochrany - EPS) s ostatními systémy v rámci inteligentních budov. Tímto způsobem lze nenásilně propojit veškeré technologie inteligentních budov a současně zachovat legislativní rovnováhu i při striktních a zastaralých ČSN normách, které jsou v oblasti zabezpečovací techniky stále v platnosti.

Pokud je v objektu, který se považuje za inteligentní budovu, instalována sběrníková instalace, je vlastní realizace jednoduchá a spočívá jen ve správném zvolení softwarové aplikace, která umožní sestavit model neuronové sítě. Ta je adaptována na příslušné podmínky a režim objektu. Drobná úskalí mohou být ve formátu dat, která ústředna elektronického zabezpečovacího systému (PZTS) po sběrnici zasílá. Tato data nemusí vždy odpovídat požadovanému

formátu dat, která podporuje aplikace provozující neuronovou síť. Na odstranění rozdílnosti přenášených dat stačí převodník, který automaticky převede, popř. zredukuje data do vhodného formátu. Fyzické napojení na sběrnici nevyžaduje nákladné prostředky.

Na startu projektu je nutné analyzovat stavy, které mohou nastat a současně zvolit i vhodnou aplikaci, která umožní práci s daty. Některé aplikace umožňují tuto analýzu a obsahují nástroje, které data diferencují koeficienty, popř. umí graficky znázornit třídy, shluky a trendy. Zde je nutné zdůraznit, že volba aplikace je velmi důležitá.

Důležitost spočívá v dalších možnostech práce s daty a sítí, kterou lze ladit, popř. paralelně vytvářet či spouštět jiný model, jiný typ neuronové sítě.

6. Seznam použité literatury

- [1] *Inteligentní budovy* [online]. Publikováno [cit. 2013-08-10]. Dostupné z: <http://www.inteligentni-budovy.cz/>
- [2] ČSN EN 50131-1 ED. 2. *Poplachové systémy - Poplachové zabezpečovací a tísňové systémy*. Praha: Český normalizační institut, 2007
- [3] ORSEC s.r.o., Portál: *ORSEC bezpečností portál* [online]. Publikováno [cit. 2014-02-08]. Dostupné z: <http://www.orsec.cz/cs/technika/produkty/ezs-i-has/>
- [4] ČSN EN 50133-1. *Poplachové systémy - Systémy kontroly vstupu pro použití v bezpečnostních aplikacích*. Praha: Český normalizační institut, 2000
- [5] ČSN EN 50132-7. *Poplachové systémy - CCTV sledovací systémy pro použití v bezpečnostních aplikacích*. Praha: Český normalizační institut, 1999
- [6] MERZ, Hermann; HANSEMANN, Thomas; HÜBNER, Christof. *Automatizované systém budov, sdělovací systémy KNX/EIB, LON a BACnet*. 1. vydání. Praha: Grada Publishing, 2008. 264 s. ISBN 978-80-247-2377-9.
- [7] MATZ, Václav. Portál: TZB-info. *Systémy používané v „inteligentních“ budovách - přehled komunikačních protokolů* [online]. Publikováno 25.10.2010 [cit. 2014-02-09]. Dostupné z: <http://vytapani.tzb-info.cz/mereni-a-regulace/6879-systemy-pouzivane-v-inteligentnich-budovach-prehled-komunikacnich-protokolu>
- [8] TOMAN, Karel. Portál: TZB-info. *Decentralizované sběrníkové systémy* [online]. Publikováno 2.7.2007 [cit. 2014-02-10]. Dostupné z: <http://www.tzb-info.cz/4213-decentralizovane-sbernicove-systemy>
- [9] ALBRECHT JUNG GMBH & CO. KG. *Inteligentní systém pro moderní budovy* [online]. Publikováno [cit. 2014-02-17]. Dostupné z: http://elektro-light.cz/sprava/wp-content/uploads/2012/01/Technicka_brozura_KNXEIB_CZ.pdf
- [10] KUNC, Josef. *ABB: Instalace KNX/EIB, komunikační telegramy a jejich stavba* [online]. Publikováno 20.11.2007 [cit. 2014-02-28]. Dostupné z: <http://elektrika.cz/data/clanky/abb-instalace-knx-eib-komunikacni-telegramy-a-jejich-stavba/view>
- [11] ŠEBESTA, Kamil; PROCHÁZKA, Jonáš. Portál: epravo.cz. *Technické normy a jejich využití v praxi* [online]. Publikováno 4.11.2010 [cit. 2014-02-17]. Dostupné z: <http://www.epravo.cz/top/clanky/technicke-normy-a-jejich-vyuziti-v-praxi-67931.html>
- [12] VOTRUBA, Zdeněk. *Perspektivy bydlení IV - Bezpečnostní systémy a chytré domy* [online]. Publikováno [cit. 2014-02-20]. Dostupné z: <http://www.odbornecasopisy.cz/konference-a-seminare-49831.html>

[13] ČSN EN CLC/TS 50398. *Poplachové systémy – Kombinované a integrované systémy - Všeobecné požadavky*. Praha: Praha: Úřad pro technickou normalizaci, metrologii a státní zkušebnictví, 2009. 20 s.

[14] ŠTĚPÁNKOVÁ Hana. Úřad pro ochranu osobních údajů. *Tisková zpráva 26. 1. 2006* [online]. Publikováno 26. 1. 2006 [cit. 2014-02-22]. Dostupné z: <http://www.uouu.cz/tiskova-zprava-26-1-2006/ds-1217/p1=1217>

[15] Zákon č 101/2000 Sb., *o ochraně osobních údajů a o změně některých zákonů*. Publikováno 4.2.2014 [cit. 2014-02-22]. Dostupné z: http://www.mpsv.cz/ppropo.php?ID=z101_2000o

[16] MELIŠKA, Michal. Portal: Technet.cz. *Neurony nejen v mozku (2)*. Publikováno 21.05.2002 [cit. 2014-03-01]. Dostupné z: http://notebooky.idnes.cz/neurony-nejen-v-mozku-2-07f-/tech-a-trendy-nb.aspx?c=A020513_5159195_tech-a-trendy-nb

[17] MELIŠKA, Michal. Portal: Technet.cz. *Neurony nejen v mozku*. Publikováno 20.05.2002 [cit. 2014-03-01]. Dostupné z: http://notebooky.idnes.cz/neurony-nejen-v-mozku-0ua-/tech-a-trendy-nb.aspx?c=A020513_5159194_tech-a-trendy-nb

[18] *Neuronové sítě a jejich využití* [online]. Publikováno [cit. 2014-03-10]. Dostupné z: <http://ivtbudanka.wz.cz/neuron.pdf>

[19] HLAVÁČ, Václav. Presentace: *Umělé neuronové sítě z pohledu rozpoznávání*. Publikováno [cit. 2014-03-03]. Dostupné z: <http://cmp.felk.cvut.cz/~hlavac/TeachPresCz/31Rozp/72UmeleNN.ppt>

[20] MELIŠKA, Michal. Portal: Technet.cz. *Neurony nejen v mozku (3)*. Publikováno 22.05.2002 [cit. 2014-03-01]. Dostupné z: http://notebooky.idnes.cz/neurony-nejen-v-mozku-3-07p-/tech-a-trendy-nb.aspx?c=A020513_5159196_tech-a-trendy-nb

[21] ŠÍMA, Jiří; NERUDA, Roman. *Teoretické otázky neuronových sítí*. 1. Vydání. Praha: Matfyzpress, 1996. 390 s. ISBN 80-85863-18-9.

[22] CHALUPNÍK, Vitalij. Portál: Root.cz – informace nejen za světa Linuxu. *Biologické algoritmy (4) - Neuronové sítě* [online]. Publikováno 25.4.2012 [cit. 2014-03-07]. Dostupné z: <http://www.root.cz/clanky/biologicke-algoritmy-4-neuronove-site/>

[23] NOVÁK, Mirko; et. al.. *Umělé neuronové sítě: teorie a aplikace*. 1. Vydání. Praha: C.H. Beck, 1998. 382 s. ISBN 80-7179-132-6.

KUKAL, Jaromír. FCC PUBLIC, s.r.o. Portal: AUTOMA. *Úvod do neuronových sítí*. Publikováno [cit. 2014-03-07]. Dostupné z: http://www.odbornecasopisy.cz/index.php?id_document=30255

- [24] SUZUKI, Kenji. *Artificial Neural Networks - Architectures and Applications (Chapter 10)*, Vydavatel: InTech. 256 s. ISBN 978-953-51-0935-8. Publikováno 16.1.2013 [cit. 2014-03-16]. Dostupné z: <http://www.intechopen.com/books/artificial-neural-networks-architectures-and-applications/applications-of-artificial-neural-networks-in-chemical-problems>
- [25] *Neuronové sítě*. Publikováno [cit. 2014-03-07]. Dostupné z: <http://cgg.mff.cuni.cz/~pepca/prg022/mucha/>
- [26] MAŘÍK, Vladimír; ŠTĚPÁNKOVÁ Olga; LAŽANSKÝ, Jiří a kol.: *Umělá inteligence (3)*. Praha: Academia, 2001. 328 s. ISBN: 80-200-0472-6
- MAŘÍK, Vladimír; ŠTĚPÁNKOVÁ Olga; LAŽANSKÝ, Jiří a kol.: *Umělá inteligence (4)*. Praha: Academia, 2003. 476 s. ISBN: 80-200-1044-0
- KRÖSE, Ben; Van der SMAGT, Patrick. *An itroduction to neural networks*. 8th Edition: University of Amsterdam, November 1996
- [27] ŘEHOŘEK, Tomáš. *Pokročilé metody učení neuronových sítí*. Publikováno [cit. 2014-03-019]. Dostupné z: https://users.fit.cvut.cz/~rehorto2/files/pokrocile_metody_uceni_neuronovych_si_ti.ppt
- [28] VOJÁČEK, Antonín. *Samoučící se neuronová síť - SOM, Kohonenovy mapy*. Publikováno 14.5.2006 [cit. 2014-03-03]. Dostupné z: http://www.kiv.zcu.cz/studies/predmety/uir/NS/Samouc_NN2.pdf
- VESELOVSKÝ, Michal. *Neuronové sítě*. Publikováno [cit. 2014-03-24]. Dostupné z: <http://avari.cz/uir/index.php?pg=uceni>
- [29] *Neuronové sítě – výuka2*. Publikováno [cit. 2014-03-025]. Dostupné z: <http://iss.unas.cz/NEURON-site-vyuka2.DOC>
- [30] *Hopfieldove siete*. Publikováno [cit. 2014-03-025]. Dostupné z: <http://neuron-ai.tuke.sk/cig/source/publications/books/NS2/html/node6.html>
- [31] *NeuroSolutions Product Summary*. Publikováno [cit. 2014-03-30]. Dostupné z: <http://www.neurosolutions.com/products/ns/>

7. Seznam zkratek

ACS	Access Control System (systém kontroly vstupů)
BAM	Bidirectional Associative Memory (obousměrná asociativní paměť)
CCTV	Closed Circuit TeleVision (uzavřený televizní okruh)
ČSN EN	Česká technická norma (původně Československá státní norma)
DDC	Direct Digital Controller
EIBA	European Installation Bus Assotiation
EIB	European Installation Bus
EPS	Elektrická požární signalizace
ETS	EIB Tool Software
EZS	Elektronická zabezpečovací signalizace (nahrazeno, nyní PZTS)
IP	Internet Protocol
LAM	Linear Associative Memory (lineární asociativní paměť)
MLP	Multi-Layer Perceptron (vícevrstvé perceptronové sítě)
MS/TP	Master – Slave / Token – Passing
OCR	Optical Character Recognition (optické rozpoznávání znaků)
PIR	Passive InfraRed sensor (pasivní infračervené čidlo)
PZTS	Poplachové zabezpečovací a tísňové systémy
SAS	Social Alarm Systems (systémy přivolání pomoci)
SOM	Self Organizing Maps (samoorganizující mapy)
RBF	Radial Basis Function (sítě s radiálně-bazickou přechodovou f.)
MSE	Mean Squared Error (střední kvadratická chyba)

8. Seznam obrázků

Obr. 1.	Technologické proměny automatizace systémů budov	8
Obr. 2.	Konvenční instalace	10
Obr. 3.	Sběrníková instalace	10
Obr. 4.	Struktura telegramu	11
Obr. 5.	KNX sběrníková instalace	14
Obr. 6.	Jednoduchý model umělé neuronové sítě	22
Obr. 7.	Umělý neuronu, model McCulloch & Pitts (MCP)	23
Obr. 8.	Skupina mužů (modře) a žen (červená) dle délky vlasů cm a výšky postavy v cm	26
Obr. 9.	Lineárně neseperabilní množina hodnot	27
Obr. 10.	Vliv počtu vrstev neuronové sítě na schopnosti klasifikace	28
Obr. 11.	Vícevrstvý perceptron (MLP)	31
Obr. 12.	Kohonenova mapa	33
Obr. 13.	Uspořádání neuronů v dvourozměrné kompetiční vrstvě s definicí okolí (N_e) a vítězného neuronu (i)	34
Obr. 14.	Hopfieldova síť	38
Obr. 15.	Maticе - Hopfieldova síť	39
Obr. 16.	Příklad uspořádání Hopfieldovy sítě se 6 neurony	40
Obr. 17.	Původní formát dat ze sběrnice a ústředny PZTS – klidový stav, ve tvaru telegramu (v souboru .txt)	42
Obr. 18.	Původní formát dat ze sběrnice a ústředny PZTS – poplachové hlášení o narušení objektu, ve tvaru telegramu (v souboru .txt)	42
Obr. 19.	Sekvence klidového hlášení po převodu do binárního formátu	43
Obr. 20.	Sekvence poplachového hlášení po převodu do binárního formátu	43
Obr. 21.	Hlavní uživatelé aplikací NeuroSolutions	44
Obr. 22.	Výběr problematiky pro řešení neuronovou sítí (s průvodcem) v prostředí NeuroSolutions, ver. 6.31	45
Obr. 23.	Grafický model vícevrstvého perceptronu MLP v prostředí NeuroSolutions, ver. 6.31	46
Obr. 24.	Nástroje a příslušenství v prostředí NeuroSolutions, ver. 6.31	46

Obr. 25. Výstup z první simulace vícevrstvého perceptronu MLP (klid 99,92 % a Not klid 98,44 %)	47
Obr. 26. Výstup z druhé simulace vícevrstvého perceptronu MLP (klid 99,75 % a Not klid 100,00 %)	48
Obr. 27. Výstup z třetí simulace vícevrstvého perceptronu MLP (klid 100,00 % a Not klid 98,44 %)	48