

# Regulace dávkování surovin pro výrobu slínku - hlavní komponenty cementu

The regulation of the dose raw materials for the manufacture  
clinker - main component of the cement

Bc. Radek Žufan Tichý

---

Diplomová práce  
2010

 Univerzita Tomáše Bati ve Zlíně  
Fakulta aplikované informatiky

---

# ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Radek ŽUFAN TICHÝ**  
Osobní číslo: **A06646**  
Studijní program: **N 3902 Inženýrská informatika**  
Studijní obor: **Informační technologie**

Téma práce: **Regulace dávkování surovin pro výrobu slínku – hlavní komponenty cementu**

Zásady pro vypracování:

1. Vypracujte přehled problematiky optimalizace a výroby slínku.
2. Navrhněte vlastní postup a metodu optimalizace dávkování surovin pro výrobu slínku v závislosti na jejich chemickém složení.
3. Proveďte programovou realizaci aplikace.
4. Vyhodnoďte optimalizaci oproti stávajícímu stavu.
5. Zpracujte závěr.

Rozsah diplomové práce:

Rozsah příloh:

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

Seznam odborné literatury:

1. ZELINKA I., OPLATKOVÁ Z., OŠMERA P. ŠEDA M., VČELAŘ F.: Evoluční výpočetní techniky – principy a aplikace, BEN – technická literatura, Praha, 2008, ISBN 80-7300-218-3.
2. ZELINKA, Ivan. Umělá inteligence I. Volume 1. Zlín: Vutium, Brno, 1998, 126 p. ISBN 80-214-1163-5.
3. KVASNIČKA V., POSPÍCHAL J., TIŇO P. 2000, Evolučné algoritmy, STU Bratislava, 2000, ISBN 85-246-2000.
4. OPLATKOVÁ, Z.: Metaevolution – Synthesis of Optimization Algorithms by means of Symbolic Regression and Evolutionary Algorithms, Lambert-Publishing, 2009, ISBN 978-8383-1808-0.
5. DAVIS L.: Handbook of Genetic Algorithms, International Thomson Computer Press, 1996, ISBN 1850328250.
6. MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: Umělá inteligence, Academia, 1993, ISBN 80-200-0496-3.
7. MAŘÍK, V., ŠTĚPÁNKOVÁ, O., LAŽANSKÝ, J.: Umělá inteligence 4., Academia, 2003, ISBN 80-200-1044-0.
8. KIUSALAAS, Jaan, Numerical Methods in Engineering with Python, Cambridge University Press, 2005, ISBN 0521852870, 9780521852876.
9. REKTORYS, Karel, Přehled užití matematiky, třetí vydání, SNTL Praha, ISBN 04-001-73, 1973.

Vedoucí diplomové práce:

**Ing. Zuzana Oplatková, Ph.D.**

Ústav informatiky a umělé inteligence


Datum zadání diplomové práce:

**19. února 2010**

Termín odevzdání diplomové práce:

**8. června 2010**

Ve Zlíně dne 19. února 2010

  
prof. Ing. Vladimír Vašek, CSc.  
*děkan*



  
prof. Ing. Vladimír Vašek, CSc.  
*ředitel ústavu*

## ABSTRAKT

Diplomová práce se zabývá problematikou neuronových sítí pro predikci chemického složení slínku, který je hlavní komponentou cementu, s cílem optimalizovat výrobní proces a zlepšit ekonomiku výroby. Využití neuronových sítí je výhodné v podmínkách, kde je třeba postihnout složité vzájemné vztahy mezi procedurálními úkony. Kvalitní výsledky predikcí poměrného zastoupení chemických prvků ve slínku s využitím neuronových sítí jsou důsledkem toho, že aplikace neuronových sítí umožňuje nalezení vazeb mezi parametry procesu, které při použití jiných metod nelze vysledovat pro jejich vzájemné interakce, značné množství údajů, dynamiku a z toho plynoucí časovou náročnost. V teoretické části práce je popsána problematika výroby slínku, a způsob sledování a ovlivnění chemického složení slínku. Praktická část zahrnuje konkrétní vypracované sítě a jejich popis. Jmenovitě se jedná o vícevrstvou síť neuronovou síť s dopředným šířením signálu.

Klíčová slova: umělá neuronová síť, trénovací množina, neuronová síť s dopředným šířením signálu, Backpropagation

## ABSTRACT

The thesis deals with issues of neural networks using for predicting the chemical composition of clinker, which is the main component of cement, in order to optimize the production process and to improve the production economics. Exploitation of neural networks is advantageous in case of capturing the interrelationships among procedural data. Quality prediction results of the proportional representation of chemical elements in the clinker using neural networks is a consequence of neural networks makes it possible to find links between the process parameters, the amount of data, the dynamics of interaction and the time-consuming. The first part contains description of the clinker production, the production monitoring and the influencing of the chemical composition of clinker. The second part includes description of building the specific networks and their description. Concretely it concerns the multilayer neural network with a network of forward spread of the signal.

Keywords: artificial neural network, the training set, feed-forward neural network, Backpropagation

Děkuji Ing. Zuzaně Oplatkové, Ph.D., vedoucí diplomové práce, za inspiraci, odborné vedení, rady a v nemalé míře i psychickou podporu, které mi poskytovala při zpracování této diplomové práce. Nemalé poděkování patří také mé manželce, Ing. Vladimíře Žufanové, Ph.D., za maximální podporu, péči a trpělivost, kterou mě po celou dobu mých studií zahrnovala.

**Prohlašuji, že**

- beru na vědomí, že odevzdáním diplomové 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 práce bude uložena v elektronické podobě v univerzitním informačním systému dostupná k prezenčnímu nahlédnutí, že jeden výtisk diplomové práce bude uložen v příruční knihovně Fakulty aplikované informatiky Univerzity Tomáše Bati ve Zlíně a jeden výtisk bude uložen u vedoucího práce;
- byl jsem seznámen s tím, že na moji diplomovou 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 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 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 práce využít ke komerčním účelům;
- beru na vědomí, že pokud je výstupem diplomové 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**

<b>ÚVOD</b> .....	<b>9</b>
<b>1 CEMENT A JEHO VÝROBA</b> .....	<b>12</b>
1.1 Výrobní proces .....	13
1.2 Kontrola kvality .....	15
1.3 Výroba portlandského slínku .....	16
<b>2 ŘÍZENÍ SKLADBY SUROVIN PRO VÝROBU SLÍNKU</b> .....	<b>17</b>
2.1 Systém AMLAS.....	17
2.2 Konfigurace vzorku .....	18
2.3 Průběh zpracování.....	21
<b>3 SIMPLEXOVÁ METODA</b> .....	<b>23</b>
3.1 Řízení složení směsi simplexovou metodou .....	23
3.2 Nedostatky řešení simplexovou metodou.....	24
<b>4 NEURONOVÉ SÍTĚ</b> .....	<b>25</b>
4.1 Podstata neuronových sítí .....	25
4.2 Stanovení topologie sítě .....	26
4.3 Učení sítě.....	27
4.3.1 Trénovací množina .....	28
4.3.2 Algoritmus Backpropagation.....	28
4.3.3 Testování modelu.....	31
4.4 Použití neuronových sítí .....	31

<b>5 ROZBOR ÚKOLU .....</b>	<b>34</b>
<b>5.1 Vstupní data .....</b>	<b>34</b>
<b>5.2 Volba řešení optimalizace .....</b>	<b>36</b>
<b>5.3 Výpočet sítě v prostředí Microsoft Office Excel .....</b>	<b>37</b>
<b>5.4 Návrh a výpočet sítě v prostředí Statistica CZ 9.....</b>	<b>40</b>
<b>5.5 Testování dalších softwarových nástrojů .....</b>	<b>43</b>
<b>5.6 Návrh a vývoj softwarové aplikace pro predikci hodnot chemického složení surovin.....</b>	<b>46</b>
5.6.1 Návrh řešení .....	48
5.6.2 Volba vývojových nástrojů a běhových platforem .....	48
5.6.3 Databáze aplikace .....	49
5.6.4 Realizace vývoje aplikace.....	50
5.6.5 Popis uživatelského rozhraní aplikace PCSS.....	54
5.6.6 Příklad použití neuronové sítě pro trénování.....	56
5.6.7 Příklad použití neuronové sítě pro predikci.....	58
5.6.8 Praktické využití aplikace.....	60
<b>ZÁVĚR .....</b>	<b>61</b>
<b>CONCLUSION .....</b>	<b>62</b>
<b>SEZNAM POUŽITÉ LITERATURY.....</b>	<b>63</b>
<b>SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK.....</b>	<b>65</b>
<b>SEZNAM OBRÁZKŮ .....</b>	<b>66</b>
<b>SEZNAM TABULEK.....</b>	<b>68</b>
<b>SEZNAM PŘÍLOH.....</b>	<b>69</b>



## ÚVOD

Rozvoj vápenického a později cementářského průmyslu má v okolí Brna dlouholetou tradici, neboť předměstí Brna leží na jihu velkého ložiska vápenců. Koncem 19. století zde bylo vybudováno několik vápenek. V letech 1961 – 1968 byl vybudován nový závod v obci Mokrá, který vyrábí cement a vápno. Závod leží asi 15 km východně od Brna a je umístěn v zalesněné krajině mimo zemědělskou oblast. Závod postupně měnil formy, názvy a vlastníky až k datu 1.5.1998, kdy vznikla akciová společnost Českomoravský cement.

Společnost Českomoravský cement je největším výrobcem cementu v České republice. V provozovně Mokrá probíhá celý proces výroby cementu, od těžby vápence v lomu až po vlastní expedici cementu. Závod používá moderní technologie, celý provoz je řízen z jednoho místa, přičemž kvalita vyráběného cementu je sledována nepřetržitě prostřednictvím automatické laboratoře. Závody používá moderní technologie, které zaručují efektivní výrobu šetrnou k životnímu prostředí. Snahou Českomoravského cementu je další modernizace výrobních závodů zejména v oblasti rozšiřování možností využívání alternativních materiálů a paliv, kde je již samozřejmostí realizace hospodárných a preventivních opatření v oblasti spotřeby energie a surovin a využití odpadů [2].

Cement, který je finálním produktem závodu, je nejrozšířenější stavební pojivo. Jedná se o práškové hydraulické anorganické pojivo, které obsahuje zejména jemně semletý slínek. Výběrem, skladbou surovin a technologickým postupem výroby cementu lze ovlivnit jeho vlastnosti a tím jej předurčit pro co nejširší použití nebo naopak pro užití speciální. Pracovní postupy výroby a s ní spojené operace jsou pravidelně kontrolovány a vše je podřízeno udržování a rozvoji fungujícího systému řízení jakosti.

Výroba cementu je velice komplikovaný, technicky, časově i energeticky náročný proces, který zahrnuje několik fází [2].

1. **Těžba surovin.** Rozdrcená a rozemletá surovina postupuje přes homogenizační sila do zásobních sil. V této fázi jsou prováděny pravidelné analýzy chemického složení těžných hornin, na jejichž základě lze upravit např. složení suroviny nebo jemnost mletí.

2. **Výpal slínku.** Nejdůležitější část procesu výroby cementu. Surovinová moučka prochází výměníkem, kde dochází k predehřátí suroviny a její částečné dekarbonizaci, do rotační pece. Pálením vznikají umělé minerály, které se prudkým ochlazením stabilizují a tvoří portlandský slínek. Celý proces výpalu je řízen z převážné části automaticky s důrazem na stabilitu a malou variabilitu výsledných parametrů slínku.
3. **Mletí slínku a skladování.** Slínek se spolu s dalšími složkami mele na jemný prášek a skladuje v silech. Průběžně jsou kontrolovány významné parametry. Testování probíhá na moderních přístrojích, jako jsou laserový granulometr, automatický rentgenový analyzátor aj.
4. **Expedice.** Cement se expeduje buď volně ložený, nebo balený v papírových pytlích. Před samotnou expedicí cementu jsou prováděny zkoušky v souladu s českou technickou normou ČSN EN 197-1, jejichž výsledky jsou řádně zdokumentovány a archivovány.

Moderní řídicí systémy a použití výpočetní techniky používané při výrobě cementu jsou zárukou jeho stabilních vlastností. Významným přínosem k optimalizaci, stejnoměrnosti a kontrole celého procesu výroby cementu je automatická provozní laboratoř, jejímž výsledkem jsou automatizované odběry vzorků v pravidelných intervalech, analýzy a archivace výsledků s minimalizací vlivu lidského faktoru na kontrolní a zkušební postupy prováděné při výrobě cementu [2].

Předkládaná práce se soustředí na tu fázi výroby cementu, jejímž cílem je optimálně regulovat dávkování jednotlivých těžných surovin pro správné složení slínku. Pro optimalizaci dávkování budou použity metody umělé inteligence, které následně budou posouzeny z hlediska vhodnosti jejich implementace. Finálním produktem této práce (dílčím v rámci následného rozvoje) je softwarová aplikace pro doplnění optimalizačního procesu regulačních veličin v závislosti na chemickém složení výchozích surovin. Výsledkem začlenění vyvinuté aplikace má být zlepšená reakce na změny chemického složení vstupních surovin, která zajistí hospodárny chod výroby při dodržení kvality surovinové moučky v rámci povolených odchylek. Plánovaným finálním stavem vývoje bude nahrazení současného systému řízení a regulace surovin samostatně vyvinutým systémem řízení. To umožní nejen jeho následné rozšiřování vlastními silami, ale také cenově příznivější relace na rozvoj a údržbu systému.

## I. TEORETICKÁ ČÁST

## 1 CEMENT A JEHO VÝROBA

Cement je nejrozšířenější stavební pojivo. Jeho označení pochází z latinského slova "caementa", kterým bylo označováno zdivo z lomového kamene pojeného maltou. Cement je práškové hydraulické anorganické pojivo, jehož hlavní složkou je jemně semletý slínek. Cement po smíchání s vodou vytváří kaši, která tuhne a tvrdne, a to jak na vzduchu, tak i pod vodou. Po zatvrdnutí si zachovává svojí pevnost i pod vodou.


Cement je vyráběn v souladu s českou technickou normou ČSN EN 197–1 Cement, Část 1: Složení, specifikace a kritéria shody cementů pro obecné použití. Tato norma stanovuje požadavky na mechanické, fyzikální a chemické vlastnosti 27 druhů cementů, a mimo jiného určuje kritéria shody vlastností a postupy pro jejich stanovení [3].

Výroba cementu je komplikovaný, technicky, časově i energeticky náročný proces. Při těžbě suroviny se provádí analýzy chemického složení těžených hornin. Vytěžená, rozdrčená a rozemletá surovina je přemístěna do zásobních sil [2]. Surovinová moučka následně prochází výměníkem, kde dochází k přehřátí suroviny a její částečné dekarbonizaci, do rotační pece. Pálením suroviny v peci vznikají slínkové minerály, které se následným prudkým ochlazením stabilizují a tvoří portlandský slínek. Slínek se mele spolu s regulátorem tuhnutí a dalšími složkami v oběhových mlýnicích na jemný prášek, cement, a skladuje se v silech. Ze sil se cement expeduje zákazníkovi. Následně uvedený postup je zpracován s využitím materiálů a obrázků uvedených na internetové adrese [3].

Ve všech etapách dochází k odběru a kontrole mezivzorků a jsou prováděny laboratorní zkoušky.


## 1.1 Výrobní proces

Hlavními surovinami pro výrobu cementu jsou vápence a soality. Tyto materiály jsou těženy v lomech za pomoci odstřelů nebo pouze rypadlem za použití těžké techniky. Kolové nakladače a nákladní automobily dopravují surovinu do drtírny. V drtičích jsou velké kameny postupně rozdraceny zhruba na velikost silničního šterku.




Obr. 1: Těžba a drcení suroviny

Rozdracený materiál je za pomoci pásového dopravníku dopravován na skládku suroviny. Zde je surovina uskladněna v předhomogenizačním silu a homogenizována.



Obr. 2: Příprava suroviny – homogenizace


Požadovaná směs rozdracené základní suroviny a korekčních surovin (křemičitý písek, železitá korekce) je připravovaná za pomoci přesných měřících zařízení. Mlýnice s válcovými nebo kulovými mlýny rozemelou surovinovou směs na jemný prášek a současně ji vysuší. Poté je rozemletá surovina dopravena do sil uskladňujících tuto surovinovou moučku, a zde je dále homogenizována.



Obr. 3: Příprava suroviny – sušení a mletí


Výpál suroviny probíhá za teploty cca 1 450 °C v peci typu Lepol nebo v rotační peci s představeným tepelným výměníkem. Tyto typy pecí pracují rozdílnou metodou, přičemž hlavním rozdílem je způsob přípravy a předehřátí surovinové moučky. Díky chemickým

reakcím, při procesu známém jako slínování a následném prudkém zchlazení, vzniká nový produkt – portlandský slínek.




Obr. 4: Výpal

Hotový slínek je uskladněn ve slínkovém silu. Odtud je slínek dopravován do kulových nebo válcových mlýnů, kde je spolu se síranem vápenatým semlet na velmi jemný prášek. V průběhu mletí mohou být do mlýnice dodávány další složky (vysokopecní granulovaná struska, popílek...) v závislosti na požadovaném druhu cementu.



Obr. 5: Mletí cementu

Cement je uskladněn v oddělených cementových silech v závislosti na druhu a pevnostní třídě. Odtud je nakládán volně ložený buď do autocisteren, železničních vozů RAJ, nebo v případě možnosti i do nákladních lodí a dopravován k zákazníkovi. Mnohem menší objem cementu je k zákazníkovi dopravován balený. Balení probíhá na rotačních baličkách a pytle jsou skládány na palety pomocí automatické paletizační linky. Poté je nakládán na nákladní automobily nebo železniční vagony a dopravován k zákazníkovi.



Obr. 6: Nakládka a doprava cementu

## 1.2 Kontrola kvality

Pro provádění kontroly kvality jsou používány moderní řídicí systémy a výpočetní technika, které jsou zárukou stabilních vlastností cementu. Automatizované odběry vzorků v pravidelných intervalech, analýzy a archivace výsledků jsou prováděny v automatických provozních laboratořích, které zajišťují minimalizaci vlivu lidského faktoru. Následující tabulka uvádí vybraná vzorkovací místa pro kontrolu jakosti [3].

Místo odběru vzorků	Stupeň výroby	Vzorkovaný materiál	Četnost vzorkování	Způsob vzorkování	Druh zkoušky	Záznam
<b>lomy</b>	těžba suroviny	vrtná moučka	z každého vrtu	automatický vzorkovač	chemické složení	kniha (databáze)
<b>za drtičem suroviny</b>	drcení suroviny	předrcená surovina	podle potřeby	ruční odběr z pásů	granulometrie	databáze (kniha)
<b>za surovinovou mlýnicí</b>	mletí suroviny	surovinová moučka	min 1x za dvě hodiny	automatický vzorkovač (vzorkař)	chemické složení granulometrie	databáze (kniha)
<b>před vstupem do výměníku</b>	homogenizace	surovina na výpal	min 1x za dvě hodiny	automatický vzorkovač (vzorkař)	chemické složení	databáze kniha
<b>za drtičem slínku</b>	výpal slínku	slínek	min 1x za dvě hodiny	automatický vzorkovač (vzorkař)	chemické složení mechanicko-fyzikální vlastnosti	databáze kniha
<b>u vykládky komponentů</b>	komponenty cementu	struska, sádrovec, korekční suroviny	z každé dodávky	ruční odběr	chemické složení vlhkost	databáze (kniha)
<b>elevátor</b>	mletí cementu	namletý cement	min 1x za dvě hodiny	automatický vzorkovač (vzorkař)	chemické složení mechanicko-fyzikální vlastnosti	databáze (kniha)
<b>před expedicí cementu</b>	expedice cementu	jednotlivé cementy	min 2x za týden každý sortiment	ruční odběr	chemické složení mechanicko-fyzikální vlastnosti	databáze kniha

Tab. 1: Přehled míst a způsobů kontroly kvality vzorků

### 1.3 Výroba portlandského slínku

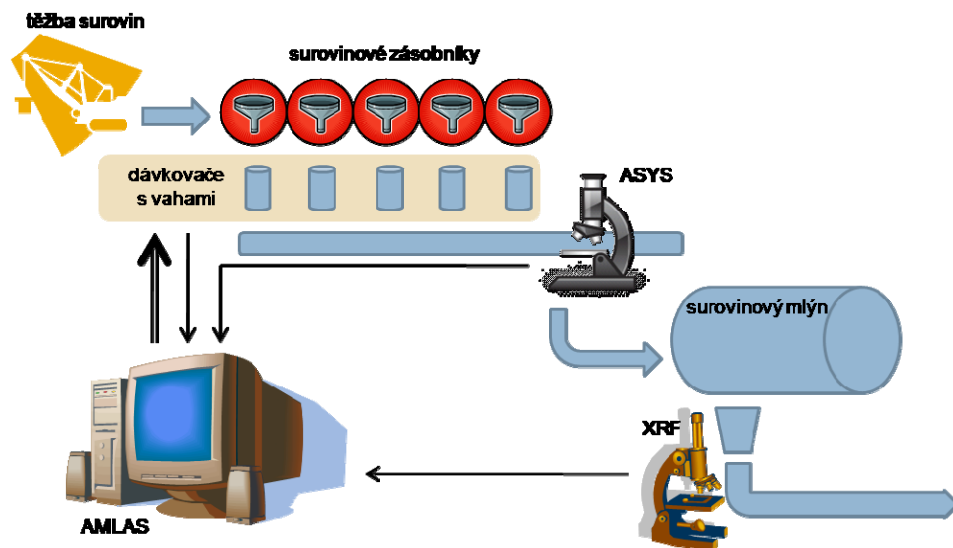
Slínek je základní surovinou pro výrobu cementu, jehož výroba začíná rozemletím vstupních surovin – vápence, slínů a slinitého vápence, hlinitých břidlic, křemičitého písku, kazivce nebo železné rudy. Suroviny jsou dávkovány na dopravní pás, který je monitorován kontinuálním analyzátozem chemického složení kameniva průběžně v celém objemu a čase. Dávkování jednotlivých surovin je stanoveno recepturou na výrobu surovinové moučky udávající jejich určitý poměr na vstupu do surovinového mlýna. Výsledné složení surovinové moučky je charakterizováno základními oxidy:  $\text{SiO}_2$ ,  $\text{Al}_2\text{O}_3$ ,  $\text{Fe}_2\text{O}_3$ ,  $\text{CaO}$ ,  $\text{SO}_3$  [3].

Na výstupu ze surovinového mlýna je každou ½ hodinu moučka podrobena RTG analýze chemického složení analyzátozem XRF. Kontrolovaným množstvím je 20 kg nashromážděné moučky, ze které se odebere 200 g. Z tohoto množství pak chemickou analýzou prochází vzorek o objemu 50 g. Surovinová moučka musí mít přesné složení, které lze ovlivnit ještě přidáváním dalších korigujících přísad. Moučka správného složení je na závěr dopravována do homogenizačního sila a následně do rotační pece k vypálení při teplotě minimálně 1 450 °C. Vypálením surovinové moučky při uvedené vysoké teplotě nastávají fyzikálněchemické reakce a vzniká slínek [3].



## 2 ŘÍZENÍ SKLADBY SUROVIN PRO VÝROBU SLÍNKU

Systém řízení skladby surovin pro výrobu slínku má několik komponent. K dosažení požadovaného složení surovinové moučky se používá automatizovaný mixovací řídicí systém AMLAS, který pracuje za podpory laboratorních jednotek ASYS a XRF. Následující text je zpracován dle [1].



Obr. 7: Schéma zapojení měřicích a řídicích jednotek

### 2.1 Systém AMLAS

Systém AMLAS (automatické řízení směsi) se používá pro dosažení požadovaného chemického složení výstupního materiálu z výrobního kroku (drtič, pec) postupem, kdy na základě vyhodnocení výstupního vzorku směsi dojde k přepočtu procentního složení vstupních komponent. Výpočet probíhá ve dvou krocích:

1. **Nastavení hrubého odhadu.** Měřené výsledky jsou vloženy do souboru PI-regulátorů, což je matice kontrolních prvků, obsahující hodnoty pro řízení proměnných (moduly).
2. **Vlastní výpočet směsi.** Hodnoty nastavené modulem jsou pomocí simplexového algoritmu vloženy do nového souboru s hodnotami procentního složení.

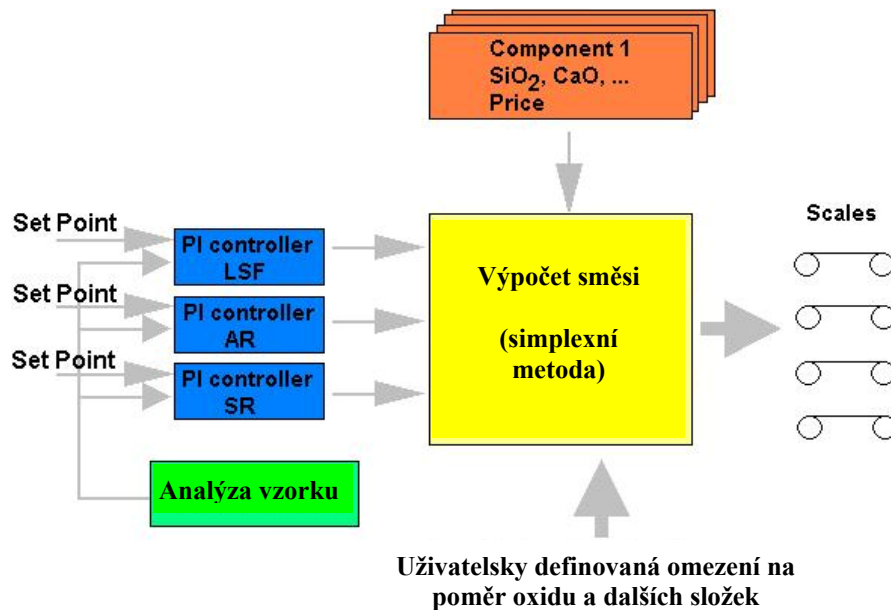
Toto automatické řízení směsi funguje v cyklech: analýza vzorku – výpočet vstupních hodnot – regulace vstupních hodnot.

Smyslem nastavování hodnot výpočtem v krocích je úprava výsledné hodnoty každé regulační proměnné tak, aby se postupně snižoval rozdíl mezi hodnotou vypočítanou z měřeného vzorku a hodnotou požadovanou.

Oprava aplikovaná na poslední použitou výslednou hodnotu je poznamenána, za účelem

minimalizace potenciální nadměrné reakce výrazného střídání kvality složek a/nebo nepřesností měření. V každém kroku výpočtu se počítá procentní podíl každé složky ingredience. Vypočtené hodnoty budou vyhovující, pokud pro ně bude platit, že:

- bude dosaženo požadovaných vlastností výsledné směsi (požadovaná hodnota),
- bude respektována dolní a horní hranice procentního podílu každé komponenty,
- budou splněny limity na obsah oxidu a poměr komponent.



Obr. 8: Schéma automatického řízení


Výpočtem může být kontrolováno až 14 parametrů. Jak matice prvků (PI-regulátory) tak i různé řídicí parametry jsou konfigurovatelné.

## 2.2 Konfigurace vzorku

Před automatickým řízením směsi se prověřuje nastavení. V podstatě je systém nakonfigurován ve 3 krocích:





- definice a nastavování PI-regulátorů,
- definice dalších podmínek, které odrážejí specifické požadavky,
- nastavení komponent matrice tak, aby odrážela chemické vlastnosti vstupních materiálů.

Parametrizace PI-regulátoru se provádí jednou (s možným doladěním po určité provozní zkušenosti). U systému lze nastavovat dodatečně i každý z parametrů matice. Pro nastavení je v systému dostupná tabulka parametrů (obr. 9).

Line	Active	Name	Action
1	<input checked="" type="checkbox"/>	MM	 
2	<input checked="" type="checkbox"/>	OM	
3	<input type="checkbox"/>	HMB	
4	<input type="checkbox"/>	HMM	
5	<input type="checkbox"/>	HS1	
6	<input checked="" type="checkbox"/>	KL	 
7	<input type="checkbox"/>	ZM 1	 
8	<input type="checkbox"/>	ZM 6	 
9	<input type="checkbox"/>	ZM 7	 
10	<input type="checkbox"/>	HS ZM	

nastavování jednotlivých regulátorů

vlastnosti vzorku

Controllers						
enabled	Name	KP	KI	KF	Comp.	Action
<input checked="" type="checkbox"/>	$K_{st} = \frac{100 \times CaO}{2.8 \times SiO_2 + 1.18 \times Al_2O_3 + 0.65 \times Fe_2O_3}$	0.3000	0.2000	0.0000	-	 
<input checked="" type="checkbox"/>	$TM = \frac{Al_2O_3}{Fe_2O_3}$	0.2000	0.1500	0.0000	-	 

vložení dodatečných regulátorů

editace funkce

funkce PI-regulátoru

Obr. 9: Konfigurace vzorků

Obr. 10: Nastavení regulátoru

Údaje získané z rentgenového vyhodnocení jsou vyplněny jako proměnné (oxidy SiO<sub>2</sub>, Al<sub>2</sub>O<sub>3</sub>, Fe<sub>2</sub>O<sub>3</sub>, CaO, SO<sub>3</sub>) v rovnici tak, aby se získaly smysluplné hodnoty (LSF), které charakterizují kvalitu výrobku, a to obvykle nastavením poměru přítomných oxidů. Výsledné hodnoty jsou použity jako vstupní parametry do PI-regulátoru. Tímto způsobem je nastavena hodnota každého z regulátoru. Rovnice parametrů je možné ručně sestavit z obecného modelu rovnice, do které jsou zahrnuty všechny složky (obr. 11).

$$K_{st} = \frac{100.0000 \times CaO + 0.0000 \times SiO_2 + 0.0000 \times Al_2O_3 + 0.0000 \times Fe_2O_3 + 0.0000 \times K_2O + 0.0000 \times MgO + 0.0000 \times Na_2O + 0.0000 \times SO_3}{0.0000 \times CaO + 2.8000 \times SiO_2 + 1.1800 \times Al_2O_3 + 0.6500 \times Fe_2O_3 + 0.0000 \times K_2O + 0.0000 \times MgO + 0.0000 \times Na_2O + 0.0000 \times SO_3}$$

Obr. 11: Sestavení rovnic proměnných

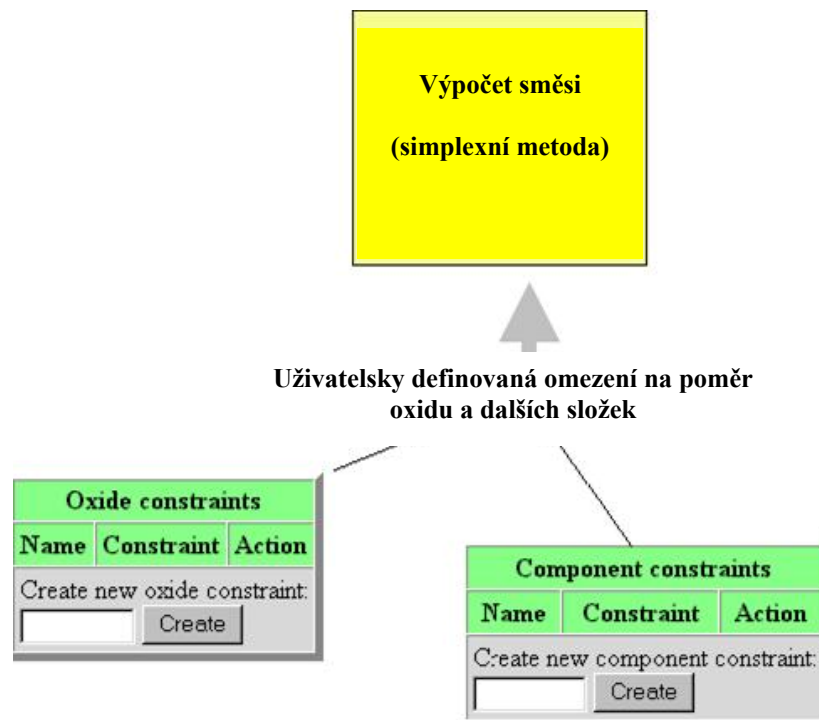
Celkový počet definovaných PI-regulátorů by měl být menší než je počet komponentních materiálů, které vstupují do výrobního procesu. Parametry asociované s konkrétním PI-regulátorem lze zobrazit a upravit (obr. 12).

Available	<input type="radio"/> off <input checked="" type="radio"/> on
Priority	mandatory
$W_{min}$ (Setpoint)	93.0
$W_{max}$ (Setpoint)	130.0
$X_{min}$ (actual value)	$W - 15.0$ %
$X_{max}$ (actual value)	$W + 15.0$ %
KP - Proportional	0.3000
Integral	KI 0.2000
	YI - Limit 20.0 %
KF - Feed-Forward	0.0000
Comp.-Line	Available <input type="radio"/> off <input checked="" type="radio"/> on
	A1 0.5000
	A2 0.2000
	A3 0.1500
	A4 0.1500

$Y_{min}$	5.0 %
$Y_{max}$	5.0 %

Obr. 12: Nastavení dalších podmínek

Další omezení lze definovat pomocí dvou masek. Tato omezení nejsou obsažena v cyklické kontrole složek, ale naopak mohou být použity ke zmapování dalších omezení vyplývajících z výrobního procesu nebo použitých zařízení.



Obr. 13: Zařazení dalších podmínek ve schématu automatického řízení

Každá ze vstupujících ingrediencí obsahuje určité procentní obsažení oxidů, které je v průběhu výpočtu neměnné. Vzhledem k tomu, že tyto poměry popisují složení ingrediencí (vstupních materiálů), musí na ně být ve výpočtu toto složení reflektováno.

Scale Nb.	Material	Oxide [%]								Price	Kst	TM	Scale		Ratio			
		SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	CaO	MgO	K <sub>2</sub> O	Na <sub>2</sub> O	SO <sub>3</sub>				Min [T/h]	Max [T/h]	Min [%]	Max [%]	Real [%]	Setpoint [%]
1	Eisenoxid	5.42	1.76	41.62	26.16	2.10	0.35	0.00	0.65	1.00	59.04	0.04	0.0	100.0	0.0	2.0	1.4	1.4
2	Sand	89.44	2.12	1.18	0.84	0.35	1.55	0.00	0.71	1.00	0.33	1.80	0.0	100.0	0.0	6.0	5.3	5.3
3	Schmelzen	8.88	3.32	1.21	44.75	1.11	0.29	0.00	0.93	1.00	151.35	2.74	0.0	100.0	0.0	100.0	93.3	93.3
4	Sondermaterial	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00	0.00	0.0	100.0	0.0	100.0	0.0	0.0

Obr. 14: Nastavení složení jednotlivých ingrediencí

### 2.3 Průběh zpracování

Automatická kontrola směsi je spuštěna až v okamžiku, kdy je prokázán stabilní provoz s eliminací předvídatelných poruch případně mimořádných okolností. Do té doby je funkční pouze ruční ovládání. V případě problémů má ruční ovládání vždy přednost. S automatickou kontrolou směsi lze za provozu částečně manipulovat úpravou parametrů, pokud dojde ke změně požadavků na výslednou směs.

Ihned po aktivaci automatického řízení směsi neprobíhají žádné přímé účinky na běžící operace. Bezprostřední automatický zásah totiž není vhodný, protože by pro automatickou regulaci mohl být použitý vzorek dat, ze kterého proběhne úvodní výpočet, zastaralý. Systém si nejdříve nastavuje odchylky PI-regulátorů, aby vypočetl očekávanou hodnotu Y každého regulátoru k aktuální hodnotě X získané z analýzy vzorku. To znamená, že se údaje každého PI-regulátoru nastavují tak, aby se požadovaná hodnota shodovala s měřenou. Ve skutečnosti už může mít operátor předem nastavené parametry (poměry složek surovin) lépe a to tak, aby odrážely vlastnosti vstupních materiálů, a systém už pouze zaregistruje vstup další sady vzorků dat.

Ani v tento okamžik ještě žádná bezprostřední akce ve změnách poměrů surovin neproběhne. Opět platí základní předpoklad, že pokud jsou změny hodnot v povolených odchylkách vlastností vstupního materiálu, systém pouze registruje získanou sadu vzorků. Následně proběhne stejná zpětná adjustace, která byla popsána pro úvodní zpracování.

Operátor může využívat takto definovaného hladkého startu jako charakteristické vlastnosti automatické regulace k tomu, aby uvedl regulaci do stabilního provozu. Pokud jsou automatické kontroly aktivované a systém pracuje ve stabilním režimu, jsou zaváděny pouze menší korekce vyplývající z řízení automatické regulace. Pokud se zdá působení

PI-regulátorů pomalé nebo naopak má vzrůstající oscilaci, může operátor stabilizovat činnost systému tak, že vyřadí automatické řízení, ručně nastaví váhy a opětovně automatické řízení povolí. Pokud jsou základní předpoklady v dopustných odchylkách s každým dalším přicházejícím vzorkem, pak jsou očekávány pouze velmi malé korekce, které vylučují nestabilitu systému.

Z hlediska automatického řízení směsi, může být v každá z vah ve třech možných stavech

- neřízená,
- ručně řízená,
- automaticky řízená.

Vždy, když je jedna z vah přímo řízena operátorem, pracuje se při výpočtu směsi s dodatečnými účinnými parametry tak, že se ručně zesiluje poměr naložené suroviny. V těchto případech je automatická kontrola vyřazena. Pokud je některá váha nefunkční, jsou všechny součásti ovládající podávání automaticky deaktivovány. Jestliže výpočet směsi není schopen získat soubor hodnot, které splňují veškeré předepsané parametry, jsou nastavení postupně deaktivována podle jejich priority. Pokud už nezbudou žádná nepovinná omezení (všechna zbývající omezení/podmínky jsou povinná), automatická kontrola směsi se ukončí.

### 3 SIMPLEXOVÁ METODA

Simplexová metoda je výpočetní postup, který slouží k nalezení optimálního řešení úlohy lineárního programování, pokud takové řešení úlohy existuje. Příkladem výpočtu může být optimalizace nákupu surovin, nutriční problém, jako zvláštní případ směšovacího problému, nebo dopravní problém zajištění optimalizace zásobování.

Výpočet výsledné hodnoty probíhá v postupných krocích, v prvním kroku se vypočte základní řešení, v následujících krocích pak nové základní řešení s lepší nebo stejnou – v případě maximalizace vyšší – hodnotou účelové funkce. Po konečném počtu kroků tento výpočetní postup vede k nalezení řešení s nejlepší hodnotou účelové funkce nebo ke zjištění, že takové řešení neexistuje. [9]

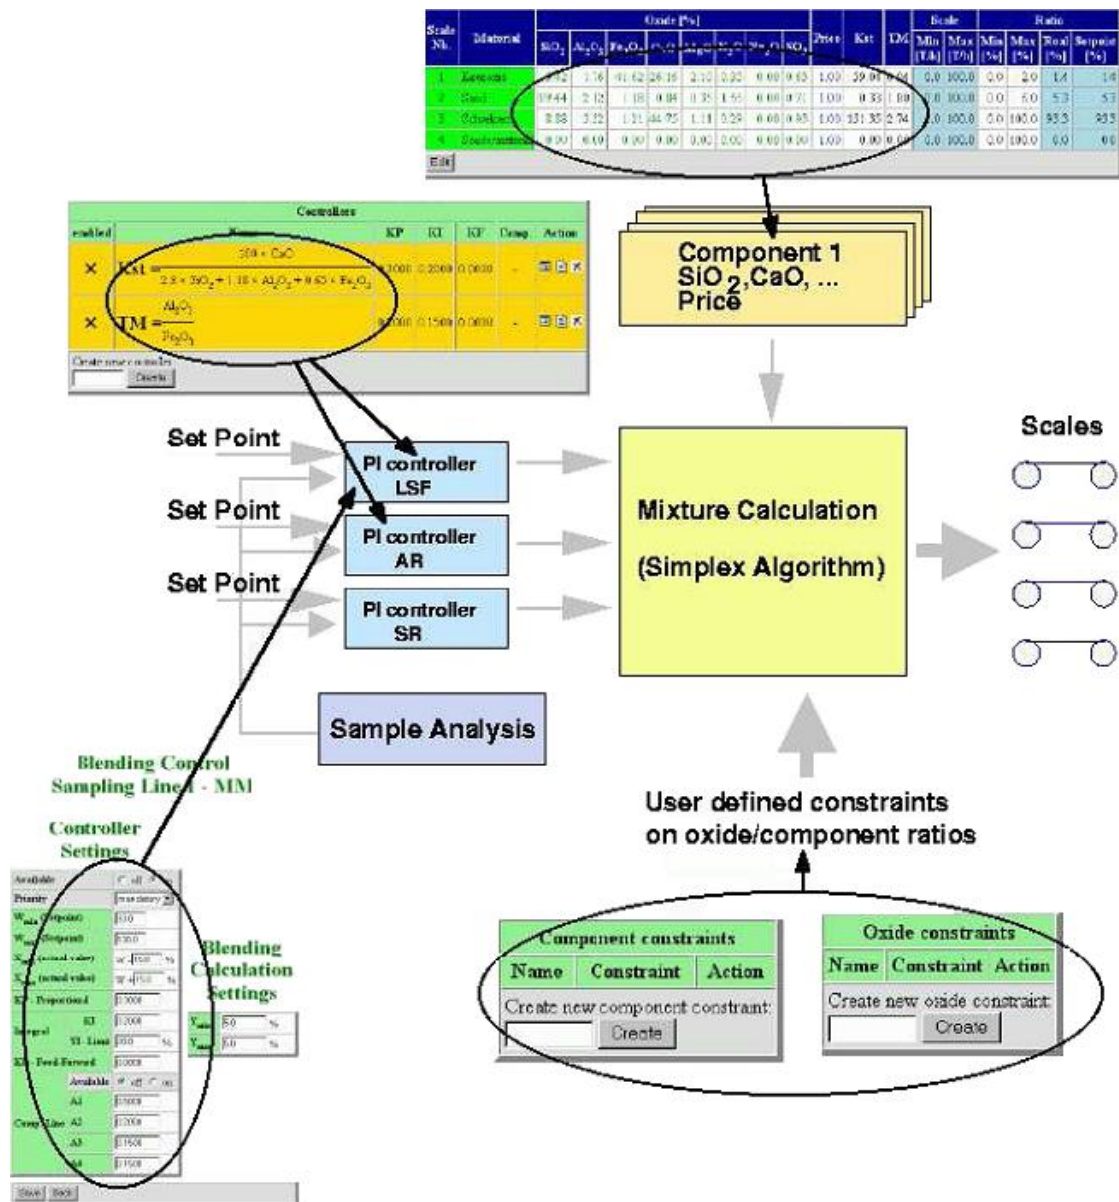
Postup výpočtu pomocí simplexové metody lze dělit na dvě fáze: nalezení výchozího základního řešení a iterační postup vedoucí k optimalizaci účelové funkce. Uvedený postup se označuje jako dvoufázová simplexová metoda. Dvoufázová metoda se používá, jestliže nejsou v úloze lineárního programování všechny omezující podmínky ve tvaru nerovnic, tzn., v první fázi se musí dopočítat základní výsledná hodnota. Pokud lze tuto I. fázi výpočtu vypustit, hovoří se o jednofázové simplexové metodě. Konkrétně se jedná o případy, kdy všechna vlastní omezení úlohy lineárního programování jsou definována jako nerovnice typu " $\leq$ ". Převedením takovéto soustavy nerovnic na ekvivalentní soustavu rovnic pomocí dalších proměnných se získá soustava rovnic v kanonickém tvaru. [9]

#### 3.1 Řízení složení směsi simplexovou metodou

Při řízení skladby surovin pro výrobu slínku se výpočet s využitím simplexové metody využívá ve fázi výpočtu směsi. [1]

Výpočet je prováděn systémem AMLAS (viz popis kapitola 2.1), kde se pomocí simplexové metody řeší soubor lineárních rovnic a nerovnic. Jednotlivé proměnné vstupující do výpočtu jsou upravovány na základě zjištěných hodnot předchozích rozborů. V případě, že výsledkem řešení je více než jedna sada hodnot, je jako platná vybraná ta, která splňuje neoptimálněji požadované parametry. Jak již bylo uvedeno dříve, výpočtem lze kontrolovat 14 parametrů, matice prvků (PI-regulátory) a řídicí parametry jsou konfigurovatelné.

Následující obrázek 15 zobrazuje komplexní vazby v systému výpočtu směsi, tak jak bylo v textu popisováno.



Obr. 15: Schéma zapojení nastavení parametrů a výpočtu směsi

### 3.2 Nedostatky řešení simplexovou metodou

Obecně není použití simplexové metody ve výpočtu špatnou volbou. Nedostatek tohoto řešení spočívá pouze ve skutečnosti, že složení směsi a následná korekce vah jednotlivých surovin na vstupu probíhá až na základě skutečně naměřených hodnot analyzátorů, který má zpoždění. Časový posun mezi vstupem suroviny do zpracování a zjištěním skutečného složení surovinové moučky laboratorní jednotkou je až 30 minut. Tento významný časový posun způsobuje, že změna chemického složení surovin je zachycena pozdě, a vynucuje následnou materiálově nákladnou úpravu surovinové moučky.

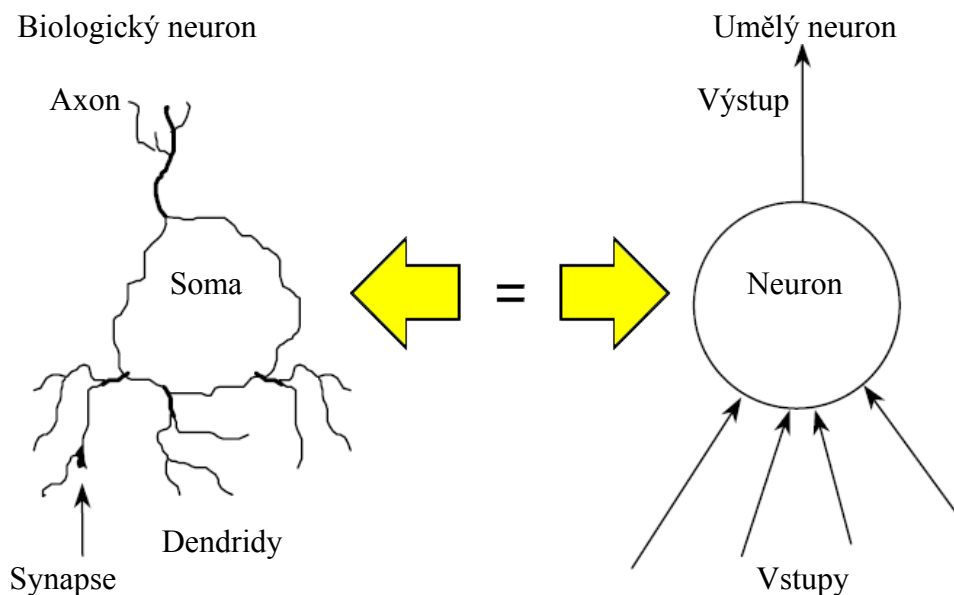


## 4 NEURONOVÉ SÍTĚ

Řešení pomocí neuronových sítí lze použít pro identifikaci signálů (radarových, sonarových...), predikci chování, klasifikaci prvků, optimalizaci chování, filtraci a mnohých dalších úlohách [8]. Neuronové sítě nepotřebují pro správnou klasifikaci žádný algoritmus, jejich vlastností je schopnost generalizovat znalosti na základě velkého počtu vzájemných spojů jednoduchých jednotek [4][14][16][18].

### 4.1 Podstata neuronových sítí


Neuronové sítě v technickém pojetí jsou obrazem nervové soustavy člověka, jeho mozku. Základním prvkem nervového systému člověka je neuron. V lidském mozku je zhruba  $10^{13}$ - $10^{15}$  neuronů, které jsou vzájemně propojeny a slouží k přenosu, zpracování a uchování informací. Průměrně má každý neuron 6000 somatických a dendritických spojení. Technický neuron jako základní prvek technické neuronové sítě je dle [18] „...jednotka, která ohodnotí všechny vstupy jejich vahami a takto získané hodnoty sečte. Výslednou hodnotu dosadí do přenosové funkce neutronu a výstup této funkce je výstupem z neutronu, který slouží jako vstup do neutronů dalších.“. Podobnost biologického a umělého neutronu je ve velmi hrubém zjednodušení zobrazena na obrázku 16.



Obr. 16: Podobnost biologického a umělého neutronu, zdroj [18]

Technická neuronová síť je prezentována jako síť složená z vrstev, kde se každá vrstva skládá z určitého počtu neuronů. Počet neuronů v jednotlivých vrstvách je variabilní a je ovlivněn problémem, který neuronová síť řeší. Stanovení počtu neuronů v jednotlivých

vrstvách vyplývá z konkrétní řešené problematiky. Existují popsané sítě o jedné vrstvě (Hopfieldova, Kohonenova...) nebo sítě o více vrstvách (sít' s algoritmem Backpropagation, Perceptron...) [4][5][8][14][16][17]. U vícevrstvých sítí existuje pravidlo v propojení každého neuronu s každým neuronem ve vyšší třídě, neurony v první vrstvě k sobě nemají vrstvu nižší, proto slouží pouze k distribuci vstupních hodnot. Propojení neuronů je následně ohodnoceno vahami, které klasifikují význam spoje pro daný neuron. Učení sítě spočívá v cyklické změně vah vazeb mezi neurony v jednotlivých vrstvách a docílení očekávaného výsledku.



Obr. 17: Příklad architektury vícevrstvé neuronové sítě, zdroj [16]

Sítě lze dělit podle způsobu učení na „učení s učitelem“ a „sítě bez učitele“. Pokud se sít' snaží učit tak, že se její výsledek přibližuje očekávané hodnotě nebo podmínce, mluví se o učení s učitelem. V případě, že požadovaná hodnota výstupu není známá, sít' funguje způsobem, že třídí informace na vstupu do skupin se společnou vlastností. V tomto případě se mluví o učení bez učitele.

Možnou klasifikací sítí je také styl učení. Rozeznávají se sítě s deterministickým stylem učení, kde se stanovují váhy výpočtem, a sítě se stochastickým stylem učení, ve kterých jsou váhy generovány jako náhodná čísla. Stochastický způsob pro stanovení vah je využíván zejména při startu sítě [6][16].

## 4.2 Stanovení topologie sítě

Určení optimální topologie sítě je problematika, která nemá jednoznačné řešení. Neexistuje jednoznačný vhodný systematický přístup pro správný návrh topologie, naopak se v této

oblasti zapojuje intuice a zkušenost řešitele. Příklady optimalizace topologie neuronové sítě existují většinou jen pro jednoduché problémy. Sestavení sítě je kreativní záležitost a návrhář sítě by měl být vybaven nejenom stabilními znalostmi, ale i dávkou představivosti pro uplatnění analogií [12]. Optimalizace topologie neuronové sítě zahrnuje volbu počtu skrytých vrstev, volbu počtu neuronů v jednotlivých vrstvách a stanovení vazeb mezi neurony, pro šíření signálu v síti se dále volí parametry přechodové funkce nebo parametry pro učení sítě pomocí zpětného šíření. Síť může být současně optimalizována také na rychlost učení, na malý počet spojení mezi neurony, nebo na nízký počet vnitřních neuronů.

Obecně při stanovování počtu vrstev platí, že čím je vyšší počet vrstev, tím je delší doba učení sítě a tím je nižší stabilita vývoje globální chyby. Běžné je sestavení sítě o 3 nebo 4 vrstvách. Problematika počtu neuronů v jednotlivých vrstvách je složitější. Na základě daných hodnot na vstupu a požadovaných hodnot na výstupu lze přesně určit počet neuronů vstupní a výstupní vrstvy, vedle toho je ale problémem určit správný počet neuronů ve vnitřních vrstvách. Ke stanovení počtu neuronů ve vnitřní vrstvě se využívají vzorce, které ovšem nelze považovat za univerzálně platné. Pro síť s jednou skrytou vrstvou lze použít vztah

$$N_{skryt} = \sqrt{N_{vstup} * N_{vystup}}, \quad (1)$$

pro síť se dvěma skrytými vrstvami lze použít vztahy

$$N_{skryt1} = N_{vystup} * \left( \sqrt[3]{\frac{N_{vstup}}{N_{vystup}}} \right)^2, \quad N_{skryt2} = N_{vystup} * \left( \sqrt[3]{\frac{N_{vstup}}{N_{vystup}}} \right), \quad (2)$$

kde  $N$  jsou počty neuronů ve vstupní a výstupní vrstvě [17].


### 4.3 Učení sítě

Každá neuronová síť projde dvěma etapami. Etapou učení a etapou vlastního fungování, učicí etapa se ještě dělí na fázi aktivační a fázi vybavovací. Jedná se o algoritmy, které na zadané trénovací množině vyladí výpočet tak, aby bylo dosaženo nejvhodnějšího řešení. Při učení s učitelem obsahuje trénovací množina hodnoty vstupní a výstupní, v síti bez učitele má trénovací množina pouze hodnoty vstupní.

V aktivační fázi se ze vstupních hodnot (vstupní vektor), vzájemných vztahů mezi neurony a ohodnocení těchto vztahů vypočte výsledná hodnota (výsledný vektor), která se porovná s očekávanou hodnotou, a z jejich rozdílu se určí lokální odchylka obou vektorů. V rámci

následné adaptační fáze pak dochází k postupnému přepočtu vah mezi jednotlivými neurony tak, aby se lokální odchylka minimalizovala. Fáze aktivační a adaptační se opakují tak dlouho, dokud odchylka vstupního a výstupního vektoru se nesníží pod zvolenou maximální povolenou hodnotu. Pro zvýšení kvality sítě se používá ještě bias, což je speciální neuron, který má váhovou hodnotu nastavenou na 1.

K přenosu hodnot vstupního vektoru (v aktivační fázi) v síti se používá přenosová funkce. Použitá přenosová funkce může být spojitá (lineární, sigmoida, hyperbolický tangens...) nebo nespojitá (binární funkce 0–1), současně se ale musí jednat o funkci monotónní. Nejčastěji používanou aktivační funkcí je sigmoida  $F(S)=1/(1+e^{-x})$ .



Obr. 18: Použití sigmoidy jako přenosové funkce, zdroj [18]

#### 4.3.1 Trénovací množina

Pro správné naučení neuronové sítě je důležitá také volba vhodné trénovací množiny. Formálně se za trénovací množinu považuje množina prvků (vzorů, vektorů), která v případě, že se jedná o učení s učitelem, obsahuje jak trénovací vektory, tak i jejich očekávané cílové hodnoty, nebo v případě, že se jedná o učení bez učitele, obsahuje klasifikaci prvků do tříd na základě shlukové analýzy. Trénovací množina by měla obsahovat reprezentativní množství prvků, které dokážou postihnout celou řešenou problematiku, v četnosti výskytu prvků odpovídající řešenému problému, hovoříme o tzv. „obrazu fyzikální reality“ [12].

Pokud se budeme věnovat síti s učením s učitelem, pak je důležitá také volba očekávaných výsledných hodnot. Při řešení jednoduchých lineárních řad, lze výsledek určit přesným výpočtem, při práci s časovými řadami je možným výsledkem vstupní hodnota následující etapy, při měření diskretních veličin se přibližujeme střední hodnotě vstupních hodnot.

#### 4.3.2 Algoritmus Backpropagation

Nejčastěji používaným učícím algoritmem adaptační fáze u vícevrstevných sítí patří algoritmus „Backpropagation“ (metoda zpětného šíření) [16]. Tento algoritmus patří do

kategorie učení s učitelem. Jeho adaptace spočívá v šíření informace o velikosti chyby od vyšších vrstev k nižším tak, že vypočítané hodnoty jsou srovnávány s výstupními hodnotami pro každý neuron. Výsledkem srovnání je chyba neuronové sítě, pro kterou je vypočítán faktor, odpovídající části chyby, která se šíří zpětně z neuronu ke všem neuronům předcházející vrstvy. Chyba  $E(vec)$  za jeden tréninkový vektor přes všechny prvky  $k=1, \dots, m$  je dána vztahem

$$E(vec) = \frac{\sum_{k=1}^m [z_k(vec) - Z_k(vec)]^2}{2}, \quad (3)$$

kde  $z_k(vec)$  je odezva na zvolený vstupní vektor,  $Z_k(vec)$  je validační výstupní vzor.

Následně chybu sítě (chyba za epochu) lze určit jako součet chyb tréninkových vektorů

$$E(net) = \sum_{vec=1}^N E(vec), \quad (4)$$

kde  $N$  je počet dvojic vektorů (opakování cyklu) v trénovací množině.

Jednotlivé kroky adaptačního algoritmu pro síť s jednou vnitřní vrstvou a přenosovou funkcí „sigmoidy“ jsou následující [15][16].

Krok 1: Inicializace vah vstupních hodnot  $X_i, i=1, \dots, n$  a biasu  $v_{0j}, j=1, \dots, p$

Krok 2: Aktivace vstupních neuronů  $X_i, i=1, \dots, n$

Krok 3: Výpočet vstupních hodnot vnitřních neuronů  $Y_{in_j}, j=1, \dots, p$

$$y_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (5)$$

Krok 4: Výpočet výstupních hodnot vnitřních neuronů  $Y_j, j=1, \dots, p$

$$y_j = f(y_{in_j}) = 1 / (1 + e^{-y_{in_j}}) \quad (6)$$

Krok 5: Výpočet vstupních hodnot výstupního signálu  $Z_{in_k}, k=1, \dots, m$

$$z_{in_k} = w_{0k} + \sum_{j=1}^p y_j w_{jk} \quad (7)$$

Krok 6: Výpočet skutečných výstupních hodnot signálu  $Z_k, k=1, \dots, m$

$$z_k = f(z_{in_k}) = 1 / (1 + e^{-z_{in_k}}) \quad (8)$$

Krok 7: Porovnání skutečných výstupních  $z_k$  hodnot signálu s očekávanou hodnotou  $t_k$ , určení rozdílu  $\delta_k, k=1, \dots, m$

$$\delta_k = (t_k - z_k) f'(z_{in_k}) = (t_k - z_k) \left( \frac{e^{z_{in_k}}}{(1 + e^{z_{in_k}})^2} \right) \quad (9)$$

Krok 8: Výpočet váhových korekcí  $\Delta w_{jk}$  a korekce biasu  $\Delta w_{0k}, j=1, \dots, p, k=1, \dots, m$

$$\Delta w_{jk} = \alpha \delta_k y_j \tag{10}$$

$$\Delta w_{0k} = \alpha \delta_k \tag{11}$$

Krok 9: Výpočet vstupních oprav vnitřních neuronů  $\delta_{in_j}, j=1, \dots, p$

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \tag{12}$$

Krok 10: Přepočítání oprav  $\delta_j, j=1, \dots, p$

$$\delta_j = \delta_{in_j} f'(y_{in_j}) = \delta_{in_j} \frac{e^{-y_{in_j}}}{(1+e^{-y_{in_j}})^2} \tag{13}$$

Krok 11: Výpočet váhových korekcí  $\Delta v_{ij}$  a korekce biasu  $\Delta v_{0i}, i=1, \dots, n, j=1, \dots, p$

$$\Delta v_{ij} = \alpha \delta_j x_i \tag{14}$$


$$\Delta v_{0i} = \alpha \delta_j \tag{15}$$

Krok 12: Aktualizace váhových hodnot a biasu ve výstupní vrstvě  $w^{+1}_{jk}, w^{+1}_{0k}$  i ve vnitřních vrstvách  $v^{+1}_{jk}, v^{+1}_{0k}, j=1, \dots, p, k=1, \dots, m$

$$w_{jk}^{+1} = w_{jk} + \Delta w_{jk} \tag{16}$$

$$v_{ij}^{+1} = v_{ij} + \Delta v_{ij} \tag{17}$$

Krok 13: Ukončení výpočtu v případě splnění předdefinované podmínky, jinak opakovat od kroku 3.



Obr. 19: Model vícevrstvé sítě, šíření signálu, zpracováno dle [16]

### 4.3.3 Testování modelu

Naučenou neuronovou síť je vhodné otestovat vůči reálným hodnotám. V podstatě je možné mít trénovací i testovací množinu totožnou, vhodnější je ovšem dostupná data rozdělit do skupiny trénovacích dat a skupiny testovacích dat, aby byly skupiny navzájem nezávislé a testování mělo určitou vypovídací hodnotu.

V oblasti testování se pak vyhodnocuje odchylka predikované hodnoty od skutečně naměřené hodnoty a hodnotí se kvalita predikce.

## 4.4 Použití neuronových sítí

Neuronové sítě mají své uplatnění v kognitivních vědách, lingvistice, neurovědě, při řízení procesů, v přírodních a společenských vědách, kde se pomocí nich modelují nejen procesy učení a adaptace, ale i široké spektrum různých problémů klasifikace objektů a také problémů řízení [16]. Nejvýznamnější podíl využití neuronových sítí je v oblasti klasifikace, autoasociace, predikce a řízení systémů [4][5][6][8][12][14][19].

V oblasti **klasifikace** se jedná o problematiku ohodnocení daného problému a jeho zařazení do příslušné třídy, široké uplatnění se nalézá například v oblasti kontroly jakosti výrobku. Sítě umožňují klasifikovat objekt binární (dvouhodnotovou) klasifikací 0–1, což je nejjednodušší kritérium, nebo klasifikací vícehodnotovou, která dovoluje zařadit objekt do několika tříd současně.

Další oblastí je **autoasociace**. Neuronové sítě se zde uplatňují ve zpracování přijatého signálu a jeho ladění, pokud je přenosem „poškozen“. Typickým příkladem je oblast rozpoznávání písma, filtrace přijímaného signálu nebo komprese dat pro přenos televizního či radiového signálu. Při zpracování v rámci autoasociace dochází k potlačení šumů, rozkódování přeneseného signálu, porovnání části přijatého signálu s jeho ideálním průběhem.

V oblasti **predikce** a **řízení systémů** jsou neuronové sítě využívány k odhadu co nejpřesnější budoucí hodnoty řešeného dynamického problému. Běžně se s predikováním pomocí neuronových sítí setkáváme při předpovědi počasí, obchodování s akciemi na burzách, hodnocení ekonomického vývoje firem nebo těžebním průmyslu. Bohužel ani neuronovými sítěmi nelze zajistit 100% úspěšnost predikce, úspěšnost je závislá na chování systému, jehož budoucnost predikujeme, zda se jedná o deterministický nebo chaotický systém, zda je chování systému možné popsat matematickými algoritmy, či zda

jsou k dispozici veškerá podstatná vstupní data. Nicméně ve srovnání s klasickými metodami predikce jsou neuronové sítě stabilnější a dosahují lepších výsledků.



## **II. PRAKTICKÁ ČÁST**

## 5 ROZBOR ÚKOLU

Diplomová práce se soustředí na problematiku správné regulace dávkování jednotlivých těžných surovin pro správné složení surovinové moučky – slínku, který je charakterizován základními oxidy:  $\text{SiO}_2$ ,  $\text{Al}_2\text{O}_3$ ,  $\text{Fe}_2\text{O}_3$ ,  $\text{CaO}$ ,  $\text{SO}_3$ . Vstupními surovinami jsou především vápenec, dále přísady jako jsou slíny a slinité vápence, křemičitý písek, kazivec nebo železná ruda.

Účelem diplomové práce není nahrazení stávajícího systému měření a regulace, ale ověření, zda je možné a vhodné nahradit použitou simplexovou metodu (řeší výpočet poměrů vah vstupních surovin) metodou umělé inteligence.

V první fázi projektu diplomové práce se doplní stávající systém měření veličin o odhad budoucích naměřených hodnot chemického složení surovin metodou umělé inteligence. Tyto odhady budou konfrontovány se skutečně naměřenými hodnotami a v případě vysoké úspěšnosti odhadu je možné přejít k manuálnímu zásahu do regulačních veličin, na základě kterých se stanovují příslušné poměry vstupních surovin.

Finální fázi, která již není obsahem diplomové práce, může být nahrazení stávajícího řešení komplexním systémem využívajícím metody umělé inteligence, řešící automatickou regulaci jednotlivých vstupních komponent.

### 5.1 Vstupní data

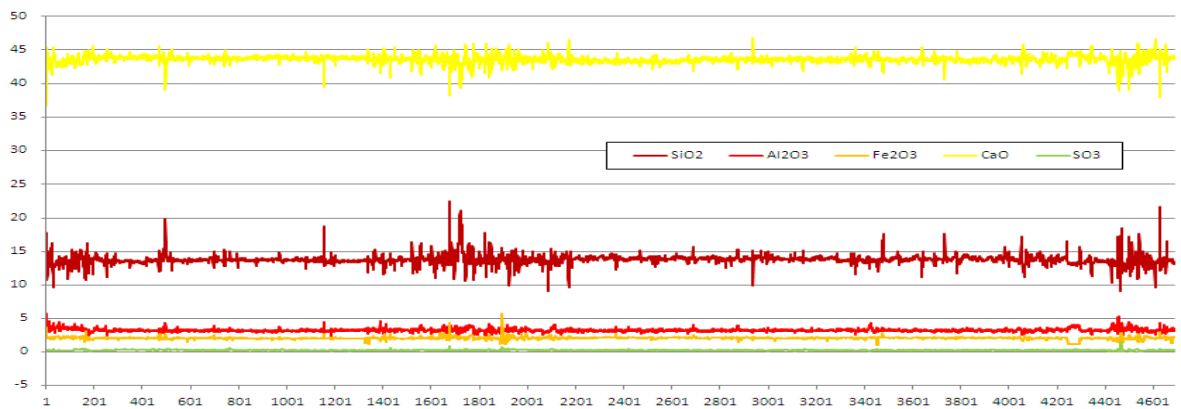
Základem pro rozhodnutí, jakým způsobem bude problematika řešena a následně jak bude konfigurována síť, jsou reálná data. Pro řešení diplomové práce byla ze strany společnosti Českomoravský cement poskytnuta data měření chemického složení surovin z období 4.12.2009 – 30.4.2010. Celkově bylo poskytnuto 4688 záznamů. Poskytnutá data byla surovým výstupem ze systému ASYS a obsahovala veškeré měřené údaje a k nim vypočtené hodnoty parametrů MS, MA, LSF. Pro snadnější orientaci byla data nahrána do programu MS Excel s barevným odlišením řešených parametrů. Ukázka dat je v tabulce 2.

Rozsáhlé množství zdrojových hodnot lze v rámci dalšího zpracování libovolně seskupovat do skupin dat určených k trénování neuronové sítě a k validaci trénovací skupiny. Kritéria třídění si libovolně určuje uživatel. Pro vlastní zpracování jsou užity pouze hodnoty oxidů  $\text{SiO}_2$ ,  $\text{Al}_2\text{O}_3$ ,  $\text{Fe}_2\text{O}_3$ ,  $\text{CaO}$ ,  $\text{SO}_3$ , kde uváděné hodnoty znamenají % zastoupení prvku v měřeném vzorku.

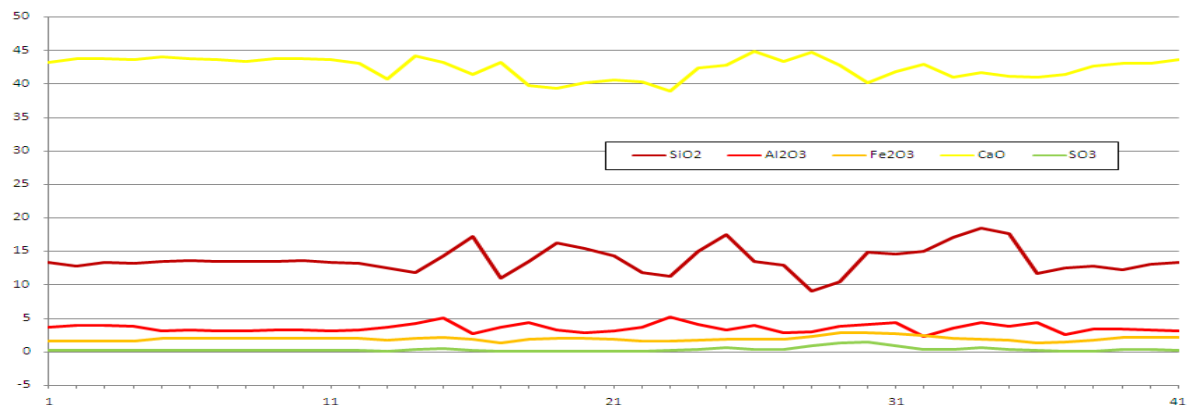
Id	Date	Hmotnost kg	SiO2	Al2O3	Fe2O3	CaO	MnO	TiO2	MgO	K2O	Na2O	SO3	Cl	Suma	Elem.H2O	šarže	Silo	A.E.	MS	MA	LSF
412844	4.12.2009 8:09	15530,8318	17,7	5,67	3,61	36,7	0,04	0,03	2,52	0,18	1,68	0,35	0,06	96,93	16,713	101375	201	1,798	1,9	1,57	62,65
412845	4.12.2009 8:33	50813,3318	10,7	3,22	1,87	45,4	0,02	0,01	0,99	0,21	0,7	0,13	0,02	98,65	8,3826	101375	201	0,838	2,11	1,72	129,6
412846	4.12.2009 9:03	34418,4141	10,8	3,32	1,91	44,9	0,02	0,02	1,26	0,27	0,83	0,12	0,02	98,34	8,696	101375	201	1,008	2,03	1,74	128,58
412849	4.12.2009 9:33	54439,9979	11,5	3,54	2,11	44,4	0,02	0,04	1,25	0,37	0,5	0,15	0,01	98,34	8,3366	101375	201	0,744	2,03	1,68	117,66
412852	4.12.2009 10:03	57430,0009	12	4,26	2,08	43,4	0,02	0,03	1,39	0,31	0,63	0,28	0,01	98,22	7,9055	101375	201	0,834	1,89	2,05	108,58
412855	4.12.2009 10:33	57506,6668	11,6	4,01	2,1	43,8	0,03	0,05	1,44	0,47	0,44	0,12	0,01	98,15	7,97	101375	201	0,749	1,9	1,91	113,35
412861	4.12.2009 11:03	57804,9997	11,8	3,83	2,07	43,8	0,02	0,05	1,49	0,41	0,55	0,18	0,01	98,09	7,9664	101375	201	0,82	1,96	1,85	114,42
412864	4.12.2009 11:33	57190,0014	13,1	3,93	2,12	43,1	0,02	0,07	1,26	0,46	0,59	0,19	0,01	98,32	8,21	101375	201	0,893	2,14	1,88	101,04
412865	4.12.2009 12:03	60121,6673	15	3,92	1,98	42	0,03	0,08	1,36	0,48	0,49	0,19	0,01	98,21	7,7706	101375	201	0,806	2,54	1,98	87,95
412867	4.12.2009 12:33	60383,3309	14,7	4,05	2	42,4	0,03	0,08	1,17	0,5	0,41	0,18	0,01	98,42	7,7755	101375	201	0,739	2,43	2,02	89,62
412868	4.12.2009 13:03	58310,0009	14	4,05	2,05	42,4	0,03	0,07	1,5	0,46	0,41	0,15	0,01	98,05	8,1082	101375	201	0,713	2,3	1,98	93,31
412871	4.12.2009 13:33	48663,4108	13,8	4,54	2,19	42,5	0,03	0,06	1,12	0,38	0,71	0,26	0,01	98,48	9,4977	201402	202	0,96	2,02	2,07	94,7
412872	4.12.2009 14:03	38528,395	12,7	3,59	2,15	43,3	0,04	0,05	1,55	0,41	0,46	0,14	0,02	97,99	9,3078	201402	202	0,73	2,21	1,67	105,25
412876	4.12.2009 15:23	17071,717	13,9	3,66	2,2	43,6	0,02	0,05	0,66	0,42	0,54	0,12	0,01	99	9,0171	201402	202	0,816	2,37	1,66	97,62
412877	4.12.2009 15:33	65783,3319	14,9	2,84	1,89	42,5	0,05	0,06	1,73	0,52	0,14	0,1	0	97,8	6,9575	201402	202	0,482	3,15	1,5	91,76
412878	4.12.2009 16:03	65291,6653	14,3	3,13	1,81	42,8	0,03	0,04	1,67	0,39	0,28	0,09	0	97,91	6,9996	201402	202	0,537	2,89	1,73	95,51
412880	4.12.2009 16:33	60836,6665	13,8	3,14	1,86	43,5	0,04	0,04	1,37	0,41	0,25	0,09	0,01	98,21	7,7616	201402	202	0,52	2,72	1,69	101,18
412882	4.12.2009 17:03	65195,0018	14,5	3,13	1,83	42,7	0,03	0,05	1,62	0,4	0,29	0,12	0	97,94	7,0608	201402	202	0,553	2,92	1,71	94,14

Tab. 2: Ukázka souboru vstupních dat

Pro jasnější představu o stavu měřených dat byly hodnoty zkoumaných oxidů zobrazeny do grafu. Z dlouhodobého hlediska (4688 záznamů, obr. 20) lze vysledovat oscilaci hodnot jednotlivých oxidů kolem určité střední hodnoty [15], skutečně reálně naměřená data se mohou od této hodnoty významně odchylovat (výběr 50 záznamů, obr. 21). Otázkou je, zda výrazná oscilace hodnot je způsobena výraznou změnou složení suroviny na vstupu, velkou prodlevou mezi vyhodnocením dat a automatickou úpravou požadovaného množství suroviny do přípravy směsi nebo pouze nevhodným zásahem obsluhy zařízení, způsobujícím totéž. V každém případě platí, že data nemají časovou závislost.



Obr. 20: Vývoj naměřených hodnot za celé sledované období




Obr. 21: Vývoj naměřených hodnot dne 25.4.2010

## 5.2 Volba řešení optimalizace


Rozhodnutí, která z metod umělé inteligence bude použita pro optimální řešení popsaného problému, se odvíjelo od požadovaného výstupu. Základním výstupem má být predikovaná hodnota jednotlivých veličin, která je dána kombinací vstupních surovin. Přestože se u vstupních hodnot nejedná o časově závislé údaje, lze je pro jisté zjednodušení považovat za spojitou funkci, protože je v každém měření díky daným těženým surovinám vždy obsažen každý z oxidů. K aproximaci libovolné spojitě funkce s libovolnou přesností se používají vícevrstvé sítě. Pro výpočet vícevrstevných neuronových sítí je nejčastěji používanou metodou síť s dopředným šířením signálu s algoritmem učení Backpropagation, proto bylo rozhodnuto o použití tohoto algoritmu a další pozornost byla věnována pouze nalezení optimální topologie sítě. Obecný popis fungování sítě s algoritmem Backpropagation je uveden v kapitole 4.3.2.

Volba topologie neuronové sítě by měla odpovídat složitosti řešeného problému. Příliš malá síť se může zastavit v lokálním minimu, vedle toho bohatá architektura sítě příliš zobecňuje tréninkové vzory a pro nenaučené vzory může dávat chybné výsledky. Proto bylo rozhodnuto o testování dvou typů sítě 5-5-5 a 25-5-5.

Vstupní synaptické váhy byly náhodně generovány v intervalu  $\langle -0,5 ; 0,5 \rangle$ .



Obr. 22: Typ sítě 5-5-5



Obr. 23: Typ sítě 25-5-5

### 5.3 Výpočet sítě v prostředí Microsoft Office Excel

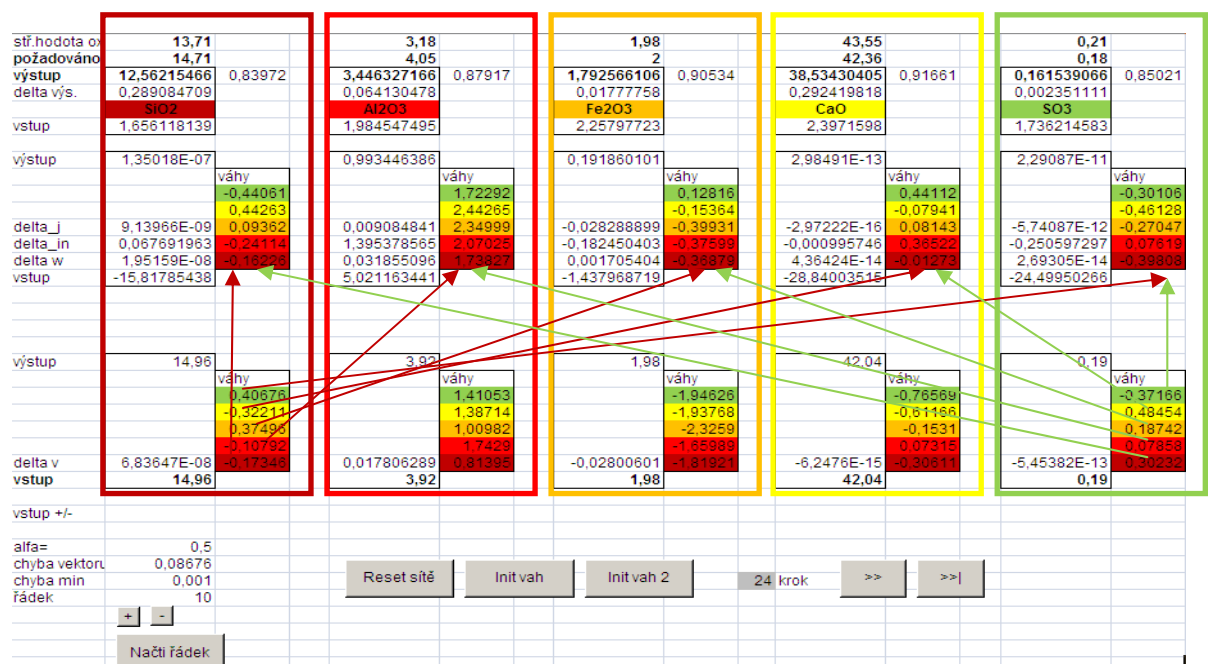
Pro síť typu 5-5-5 byl proveden nejprve jednoduchý výpočet v prostředí programu Microsoft Office Excel 2007 (Obr. 24). Program společnosti Microsoft je účinný nástroj pro analýzy, sdílení a správu dat, poskytuje bohatou vizualizaci dat a rychlejší způsob vytváření tabulek a grafů.

Získaná data byla vložena do souboru *BP\_analyza\_6m2010.xlsx* na první list pojmenovaný *ASYS* (Tab. 2). Vlastní výpočet je rozdělen do dvou fází, adaptace a predikce, z nichž každá probíhá v samostatném listu souboru *BP\_adaptace*, *BP\_predikce*. Pro zjednodušení výpočetních operací byla stanovena hodnota bias = 0, z uvedeného důvodu tato hodnota není obsažena ve výpočtu. Soubor *BP\_analyza\_6m2010.xlsx* je obsahem přílohy P IV.

#### Fáze adaptace

Učení sítě probíhá na listu *BP\_adaptace*, kde si lze načítat vstupní data volbou příslušného řádku z listu *ASYS*. Po načtení vstupních dat (*Načti řádek*) a inicializaci vah (*Init vah*) se postupně provádí jednotlivé cykly výpočtu (>>) a sleduje vývoj chyby vektoru. Výpočet je možné spustit také kontinuálně (>>I), pokud je zadán ukončující faktor, kterým v tomto případě byla zvolena nejnižší hodnota chyby spočteného vektoru (*chyba min*).

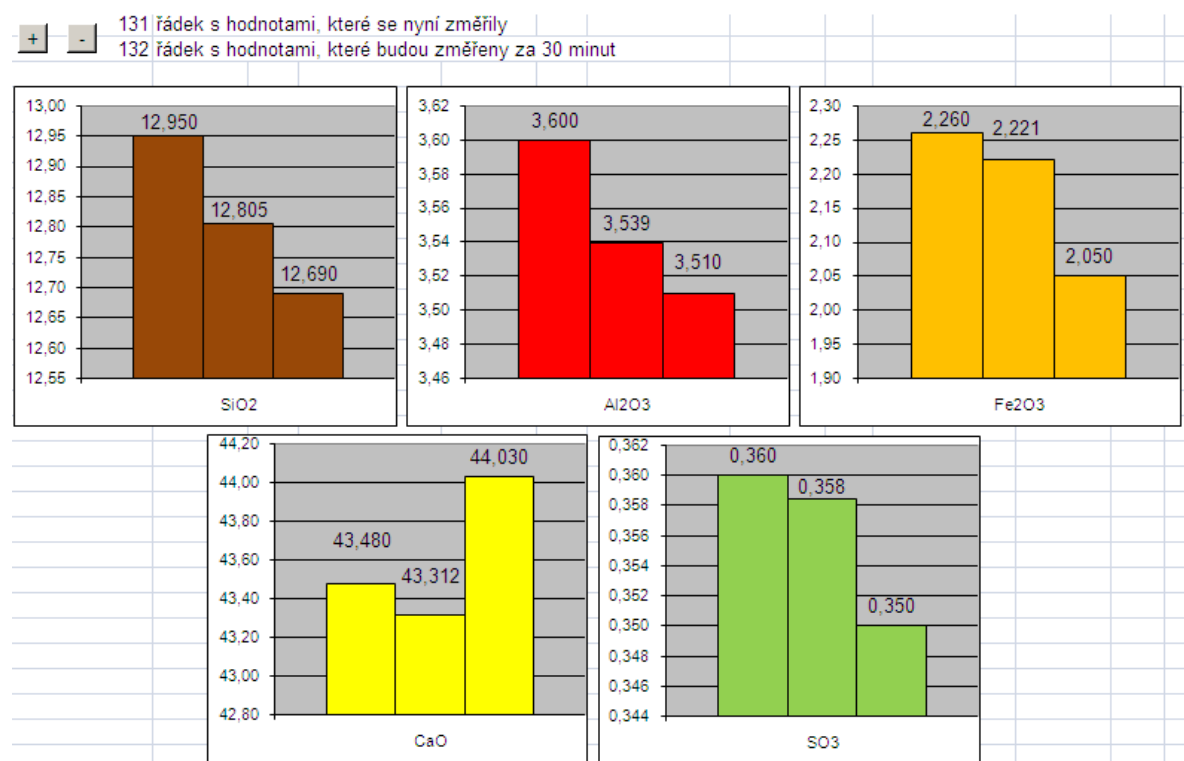
Po proběhnutí cyklu výpočtu lze načíst další řádek (+, -) nebo také řádek libovolný, a výpočet opakovat v dalším cyklu. Tester uváží, po kolika cyklech je možné považovat síť za naučenou.



Obr. 24: Ukázka výpočtu sítě 5-5-5 v prostředí MS Excel

### Fáze predikce

Výpočet predikovaných hodnot probíhá na listu *BP\_predikce* a vychází z naučené sítě z listu *BP\_adaptace*. Při predikování si tester zvolí libovolný řádek vstupních dat z listu *ASYS* a označí jej za poslední měřený, následně určí očekávanou hodnotu. Pro porovnání je na listu *BP\_predikce* možné okamžitě predikovanou hodnotu porovnat se skutečně změřenou hodnotou (řádek n+1 vstupních dat listu *ASYS*). Sledování správné predikce hodnoty je zobrazeno ve dvou typech grafů. Ve sloupcových grafech pro jednotlivé suroviny je zobrazena na vodorovné ose vstupní měřená hodnota, predikovaná hodnota a skutečná měřená hodnota (obr. 25), na svislé ose pak vlastní hodnota suroviny.



Obr. 25: Porovnání vstupních, predikovaných a skutečných hodnot

Vedle toho spojnicový graf (obr. 26) zobrazuje vývoj predikovaných a výstupních dat za posledních 11 cyklů a současně zobrazuje % odchylku predikce od skutečné hodnoty. Vodorovná osa zobrazuje pořadí měření tak, že nejnovější údaj se plní na první pozici, na levé svislé ose jsou uvedeny % odchylky predikované a skutečné hodnoty a na pravé svislé ose jsou uvedeny vlastní hodnoty suroviny. V tabulce před každým grafem jsou zobrazena zdrojová data pro graf. Hodnoty jsou uváděny tak, že na první pozici v tabulce se zobrazí vždy ta nejnovější. V dolní části tabulky je vypočtena průměrná % odchylka ze všech 11 měření [15].



Obr. 26: Vývoj predikovaných a skutečných hodnot

Testování v prostředí MS Excel sloužilo k pochopení fungování sítě s metodou Backpropagation a současně k ověření, jestli je možné a vhodné neuronovou síť typu 5-5-5 pro predikci chemického složení použít.

#### 5.4 Návrh a výpočet sítě v prostředí Statistica CZ 9

Možnost návrhu a výpočtu sítě byla ověřena také v aplikaci STATISTICA CZ 9. Motivací k jejímu vyzkoušení byla práce [5]. Na webových stránkách společnosti StatSoft CR s.r.o. je možné stáhnout 30-ti denní zkušební verzi programu STATISTICA 9 CZ. Tato trial verze neumožňuje používat modul pro práci s neuronovými sítěmi. V případě potřeby, zejména pro účely testování, je možné objednat časově omezenou verzi, a to za příznivých finančních podmínek. Pro testování byla získána od společnosti StatSoft CR s.r.o. za manipulační poplatek 200 Kč časově omezená verze programu s modulem *Automatizované neuronové sítě*.

STATISTICA je komplexní systém obsahující prostředky pro správu dat, jejich analýzu, vizualizaci a vývoj uživatelských aplikací. Poskytuje široký výběr základních i pokročilých speciálně vyvinutých technik. Modul *Automatizované neuronové sítě* obsahuje rozsáhlý výběr architektur sítě, trénovacích algoritmů, statistik, grafických výstupů. Modul lze využít pro různé typy analýz (regrese, klasifikace, časové řady, shluková analýza), automatický výběr nejvhodnější architektury sítě nebo vyhotovení analytických grafických výstupů.

Pro ověření byla data rozdělena do skupin trénovací, validační a testovací.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
	SiO2	Al2O3	Fe2O3	CaO	SO3	vSiO2	vAl2O3	vFe2O3	vCaO	vSO3	tSiO2	tAl2O3	tFe2O3	tCaO	tSO3	Subset
1	17,67	5,67	3,61	36,66	0,35	13,96	3,26	1,96	43,51	0,19	13,79	3,52	2,3	43,75	0,21	Validation
2	10,72	3,22	1,87	45,4	0,13	13,64	3,08	1,99	43,94	0,24	13,72	3,63	2,09	43,59	0,16	Train
3	10,64	3,32	1,91	44,94	0,12	13,73	3,08	1,97	43,61	0,18	13,37	4,03	2,04	43,1	0,21	Train
4	11,48	3,54	2,11	44,35	0,15	13,65	3,23	1,97	43,84	0,12	13,08	3,64	2,06	43,3	0,22	Train
5	12	4,26	2,08	43,41	0,28	13,71	3,22	1,99	43,94	0,11	13,83	3,97	2,15	43,06	0,15	Train
6	11,62	4,01	2,1	43,79	0,12	13,57	3,16	2	43,88	0,17	14,66	3,92	2,31	42,43	0,18	Train
7	11,58	3,83	2,07	43,81	0,18	12,69	2,87	1,9	44,18	0,13	14,63	3,77	2,4	42,39	0,15	Train

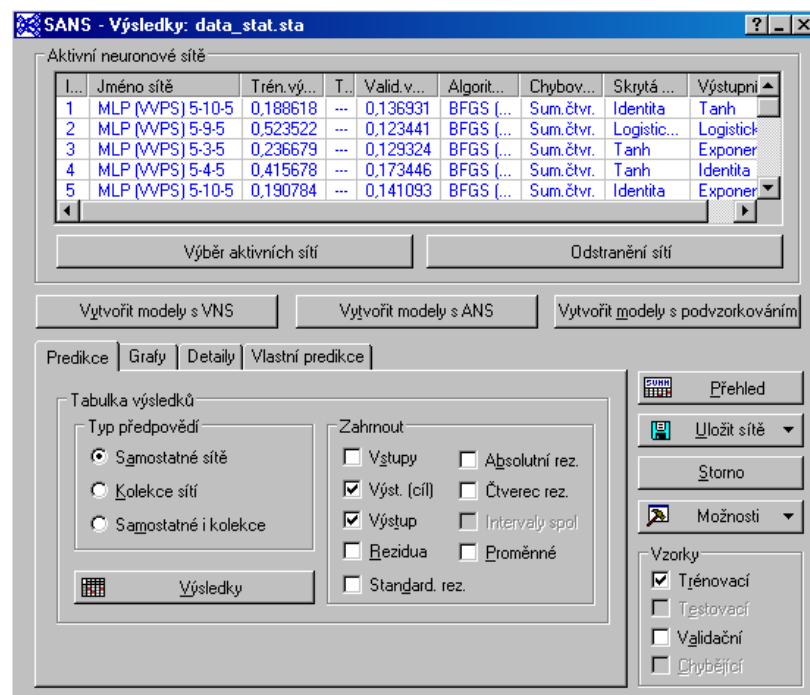
Obr. 27: Ukázka dat a jejich rozdělení

Program STATISTICA disponuje vlastní funkcí (*Statistica* → *Automatizované neuronové sítě*) pro automatické vygenerování neuronových sítí podle zadaných kritérií. Zadanými



kritérii jsou výběr trénovacích a validačních dat, druh sítě (*Regrese, Klasifikace, Časové řady-regrese, Časové řady-klasifikace, Shluková analýza*), typ sítě (*0 - 3vrstvá*), počet neuronů ve skryté vrstvě, počet trénovacích sítí, počet prezentovaných sítí, aktivační funkce (*Identita, Logistická, Atanh, Exponenciální, Sinus*). Z pohledu možností, jak ovlivnit případně měnit další parametry v programu, je výčet konečný. Dále se modul chová jako „černá skříňka“, která má za úkol podle interních předem stanovených kritérií vygenerovat jednu či více neuronových sítí.

Po zadání výběrových kritérií a zahájení zpracování bylo aplikací STATISTICA navrženo 15 modelů neuronových sítí, s různou strukturou a kvalitou návrhu. Výsledky návrhu neuronových sítí, jejich struktury, váhy a mnoho dalších statistik jsou k dispozici pomocí dialogu SANS - Výsledky: data\_stat.sta (obr. 28).



Obr. 28: Navržené sítě v programu STATISTICA

Pro každé neuronové spojení je možné zobrazit hodnoty vah naučených sítí (obr. 29).

Váhy sítí (data_stat.sta)						
ID vah	Spojení 1.MLP (VVPS) 5-10-5		Spojení 2.MLP (VVPS) 5-9-5		Spojení 3.MLP (VVPS) 5-3-5	
	Hodnoty vah 1.MLP (VVPS) 5-10-5		Hodnoty vah 2.MLP (VVPS) 5-9-5		Hodnoty vah 3.MLP (VVPS) 5-3-5	
1	SiO2 --> skrytý neuron 1	-0,100851	SiO2 --> skrytý neuron 1	387,42	SiO2 --> skrytý neuron 1	2,49
2	SiO2 --> skrytý neuron 2	-0,051986	SiO2 --> skrytý neuron 2	113,21	SiO2 --> skrytý neuron 2	-1,61
3	SiO2 --> skrytý neuron 3	-0,108876	SiO2 --> skrytý neuron 3	-64,15	SiO2 --> skrytý neuron 3	-1,41
4	SiO2 --> skrytý neuron 4	-0,176943	SiO2 --> skrytý neuron 4	271,54	Al2O3 --> skrytý neuron 1	1,12
5	SiO2 --> skrytý neuron 5	-0,056342	SiO2 --> skrytý neuron 5	-414,40	Al2O3 --> skrytý neuron 2	1,48
6	SiO2 --> skrytý neuron 6	0,236639	SiO2 --> skrytý neuron 6	-553,33	Al2O3 --> skrytý neuron 3	558,40
7	SiO2 --> skrytý neuron 7	0,138858	SiO2 --> skrytý neuron 7	755,09	Fe2O3 --> skrytý neuron 1	2059,86
8	SiO2 --> skrytý neuron 8	0,030598	SiO2 --> skrytý neuron 8	660,04	Fe2O3 --> skrytý neuron 2	1667,36
9	SiO2 --> skrytý neuron 9	0,161174	SiO2 --> skrytý neuron 9	260,93	Fe2O3 --> skrytý neuron 3	1007,40
10	SiO2 --> skrytý neuron 10	-0,086047	Al2O3 --> skrytý neuron 1	-1197,64	CaO --> skrytý neuron 1	-1366,93
11	Al2O3 --> skrytý neuron 1	-0,183642	Al2O3 --> skrytý neuron 2	-955,44	CaO --> skrytý neuron 2	-1670,66
12	Al2O3 --> skrytý neuron 2	0,067050	Al2O3 --> skrytý neuron 3	660,79	CaO --> skrytý neuron 3	-1271,78
13	Al2O3 --> skrytý neuron 3	-0,009558	Al2O3 --> skrytý neuron 4	922,61	SO3 --> skrytý neuron 1	-1084,80
14	Al2O3 --> skrytý neuron 4	0,024581	Al2O3 --> skrytý neuron 5	89,59	SO3 --> skrytý neuron 2	1306,89
15	Al2O3 --> skrytý neuron 5	0,010165	Al2O3 --> skrytý neuron 6	-1359,26	SO3 --> skrytý neuron 3	-52,36
16	Al2O3 --> skrytý neuron 6	0,017913	Al2O3 --> skrytý neuron 7	-50,30	vstup. strannost --> skrytý neuron 1	-1,53
17	Al2O3 --> skrytý neuron 7	-0,036491	Al2O3 --> skrytý neuron 8	163,80	vstup. strannost --> skrytý neuron 2	-1895,07
18	Al2O3 --> skrytý neuron 8	0,100617	Al2O3 --> skrytý neuron 9	511,64	vstup. strannost --> skrytý neuron 3	-509,85
19	Al2O3 --> skrytý neuron 9	0,239039	Fe2O3 --> skrytý neuron 1	399,88	skrytý neuron 1 --> vSiO2	0,03
20	Al2O3 --> skrytý neuron 10	0,168979	Fe2O3 --> skrytý neuron 2	184,75	skrytý neuron 1 --> vAl2O3	0,07

Obr. 29: Přehled vypočtených vah

Přehled parametrů navržených sítí slouží pro výběr nejvhodnější sítě. Kritériem výběru vhodné sítě může být parametr *Trén.výkon*, u kterého se pro volbu rozhoduje podle pravidla čím větší vypočtená hodnota, tím lepší výsledek sítě pro využití v predikci hodnot (obr. 30) [5].

Id	Jméno sítě	Trén.výkon	Valid.výkon	Trén.chyba	Te st	Validační chyba	Trénovací algoritmus	Chybová funkce	Aktivace skryt.vr.	Výstupní akt.fce
1	MLP (VVPS) 5-10-5	0,186618	0,136931	1,011091	1,026107	BFGS (Quasi-Newton) 64	Sum.čtvr.	Identita	Identita	Tanh
2	MLP (VVPS) 5-9-5	0,523522	0,123441	0,676037	1,376514	BFGS (Quasi-Newton) 10000	Sum.čtvr.	Logistická	Logistická	Logistická
3	MLP (VVPS) 5-3-5	0,236679	0,129324	1,000434	1,009616	BFGS (Quasi-Newton) 945	Sum.čtvr.	Tanh	Tanh	Exponenciální
4	MLP (VVPS) 5-4-5	0,415678	0,173446	0,852821	0,958979	BFGS (Quasi-Newton) 10000	Sum.čtvr.	Tanh	Tanh	Identita
5	MLP (VVPS) 5-10-5	0,190784	0,141093	1,011518	1,028228	BFGS (Quasi-Newton) 69	Sum.čtvr.	Identita	Identita	Exponenciální
6	MLP (VVPS) 5-3-5	0,367628	0,145580	0,896651	1,029505	BFGS (Quasi-Newton) 10000	Sum.čtvr.	Logistická	Logistická	Logistická
7	MLP (VVPS) 5-5-5	0,420392	0,090906	0,831540	1,084279	BFGS (Quasi-Newton) 10000	Sum.čtvr.	Tanh	Tanh	Identita
8	MLP (VVPS) 5-10-5	0,188943	0,137607	1,011145	1,027822	BFGS (Quasi-Newton) 52	Sum.čtvr.	Identita	Identita	Identita
9	MLP (VVPS) 5-8-5	0,449784	0,169142	0,831163	0,944616	BFGS (Quasi-Newton) 10000	Sum.čtvr.	Tanh	Tanh	Identita
10	MLP (VVPS) 5-3-5	0,332019	0,180890	0,924455	1,035346	BFGS (Quasi-Newton) 10000	Sum.čtvr.	Tanh	Tanh	Tanh
11	MLP (VVPS) 5-4-5	0,233129	0,109585	0,996799	1,049177	BFGS (Quasi-Newton) 6594	Sum.čtvr.	Exponenciální	Exponenciální	Logistická
12	MLP (VVPS) 5-6-5	0,466080	0,054014	0,776048	1,314767	BFGS (Quasi-Newton) 10000	Sum.čtvr.	Logistická	Logistická	Tanh
13	MLP (VVPS) 5-7-5	0,186618	0,136931	1,011091	1,026107	BFGS (Quasi-Newton) 61	Sum.čtvr.	Identita	Identita	Tanh
14	MLP (VVPS) 5-3-5	0,268024	0,121774	0,994453	1,067149	BFGS (Quasi-Newton) 10000	Sum.čtvr.	Exponenciální	Exponenciální	Identita
15	MLP (VVPS) 5-6-5	0,440157	0,206193	0,862319	1,010252	BFGS (Quasi-Newton) 10000	Sum.čtvr.	Logistická	Logistická	Logistická

Obr. 30: Přehled parametrů sítí navržených modulem *Automatizované neuronové sítě*

Podle hodnoty parametru *Trén.výkon* byla zvolena síť MLP (VVPS) 5-9-5 (řádek 2) jako jeden z modelů pro výpočet neuronové sítě ve vlastní aplikaci.

V programu STATISTICA se následně provádí i predikce hodnot veličin pomocí vybrané neuronové sítě. Pro načtení měřených hodnot se použije tlačítko **Vlastní vstupy**. Výsledky predikce k těmto vlastním vstupům se nachází na záložce **Vlastní predikce**, dialogu SANS - Výsledky: data\_stat.sta (obr. 31, tabulka vlevo dole).

The screenshot shows the STATISTICA software interface. The main window displays a data table with columns labeled 1 through 16, representing various chemical and physical parameters. Below the data table, there is a section for 'Aktivní neuronové sítě' (Active neural networks) with a list of models. A dialog box titled 'Vlastní vstupy' (Custom inputs) is open, showing a table for entering input values for four cases (Případ 1 to 4). The table has columns for SiO2, Al2O3, Fe2O3, CaO, and SO3. The dialog also includes 'OK' and 'Storno' buttons.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
	SiO2	Al2O3	Fe2O3	CaO	SO3	vSiO2	vAl2O3	vFe2O3	vCaO	vSO3	tSiO2	tAl2O3	tFe2O3	tCaO	tSO3	Subset
1	17,67	5,67	3,61	36,66	0,35	13,96	3,26	1,96	43,51	0,19	13,79	3,52	2,3	43,75	0,21	Validation
2	10,72	3,22	1,87	45,4	0,13	13,64	3,08	1,99	43,94	0,24	13,72	3,63	2,09	43,59	0,16	Train
3	10,64	3,32	1,91	44,94	0,12	13,73	3,08	1,97	43,61	0,18	13,37	4,03	2,04	43,1	0,21	Train
4	11,48	3,54	2,11	44,35	0,15	13,65	3,23	1,97	43,84	0,12	13,08	3,64	2,06	43,3	0,22	Train
5	12	4,26	2,08	43,41	0,28	13,71	3,22	1,99	43,94	0,11	13,83	3,97	2,15	43,06	0,15	Train
6	11,62	4,01	2,1	43,79	0,12	13,57	3,16	2	43,88	0,17	14,66	3,92	2,31	42,43	0,18	Train
											63	3,77	2,4	42,39	0,15	Train
											1,8	3,94	2,41	42,12	0,2	Train
											11	3,78	2,47	41,41	0,21	Validation

	SiO2	Al2O3	Fe2O3	CaO	SO3
Případ 1	13,83	3,97	2,15	43,1	0,15
Případ 2	14,66	3,92	2,31	42,4	0,18
Případ 3					
Případ 4					

Obr. 31: Ukázka predikce hodnot pomocí vygenerované neuronové sítě

## 5.5 Testování dalších softwarových nástrojů

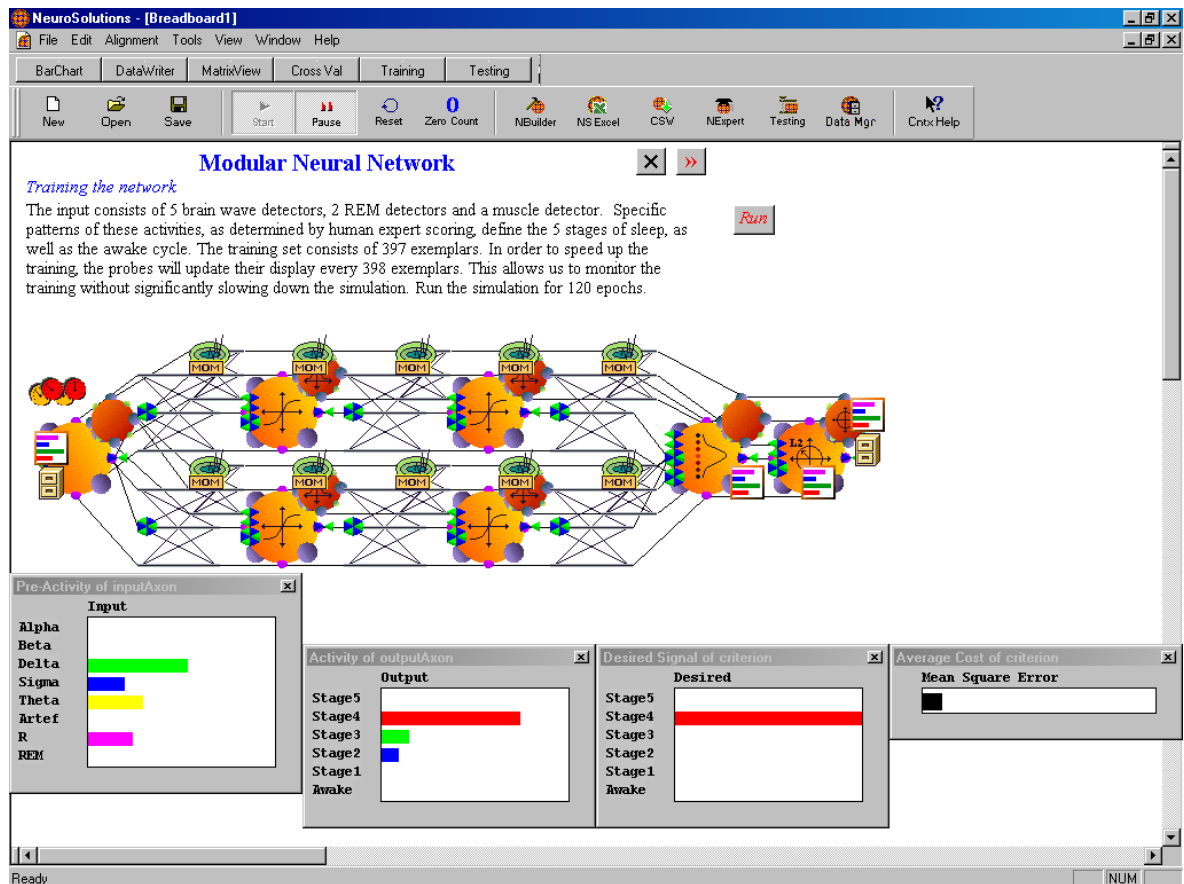
V rámci seznamování se s problematikou predikce budoucích hodnot veličin bylo testováno několik dalších softwarových nástrojů, které byly nalezeny při pátrání s využitím portálu Google. Za zmínku stojí následující:

### NeuralSolution

NeuroSolution 5.0, dostupné na adrese <http://www.neurosolutions.com>.

Jedná se o softwarový produkt pro modelování a testování neuronových sítí. Jeho výhodou je možnost implementace funkcí neuronových sítí jako doplňku do prostředí MS Excel a

vzájemné propojení prostřednictvím XLS tabulek. Ke konstrukci topologie neuronové sítě lze využít propracovaného průvodce, který uživateli předkládá formou dialogů dotazy na požadovaná kritéria, topologii a data budoucí neuronové sítě. Editor struktury neuronové sítě má vlastnosti WYSIWYG editoru (obr. 32).

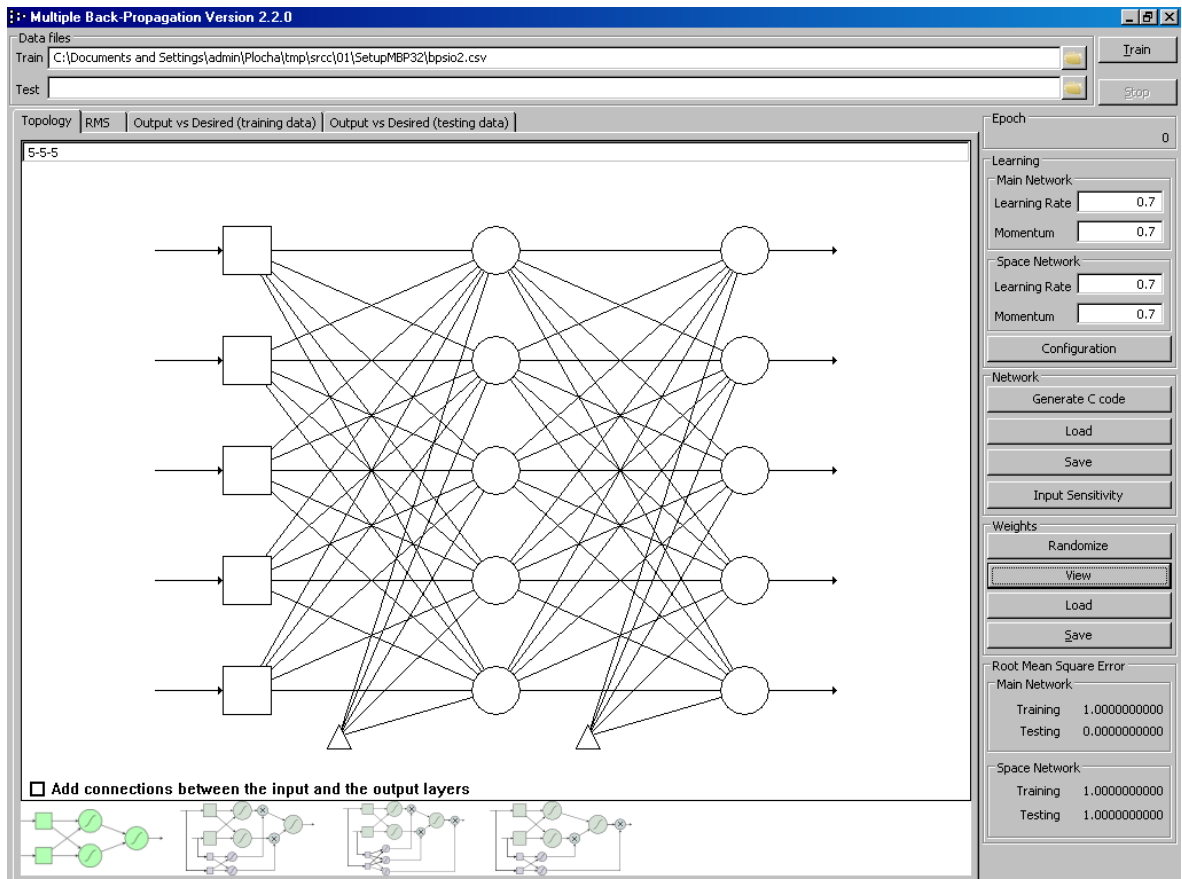


Obr. 32: Ukázkový příklad trénování neuronové sítě v prostředí NeuralSolution

### Multiple Back-Propagation

Multiple Back-Propagation Version 2.2.0, dostupné na adrese <http://dit.ipg.pt/MBP/>

Aplikace umožňuje realizaci pouze vícevrstevných neuronových sítí s využitím algoritmu Backpropagation. Vstupní a testovací množiny dat se získávají z předem připravených souborů formátu CSV. Konstrukce struktury sítě se navrhuje v rámci záložky **Topology** jednoduchým mnemotechnickým způsobem, např. 5-5-5 (obr. 33). V dolní části okna lze navíc určit složitost topologie a chování neuronové sítě. Editační plocha struktury dovoluje grafickou manipulaci s objekty struktury sítě, přidávání a ubírání neuronů, vah, anebo určování přenosových funkcí neuronů. Pravá strana aplikace slouží k nastavování různých parametrů a k ovládání navržené struktury neuronové sítě. Přidanou hodnotou aplikace je možnost exportu navržené neuronové sítě do zdrojového kódu jazyka C.

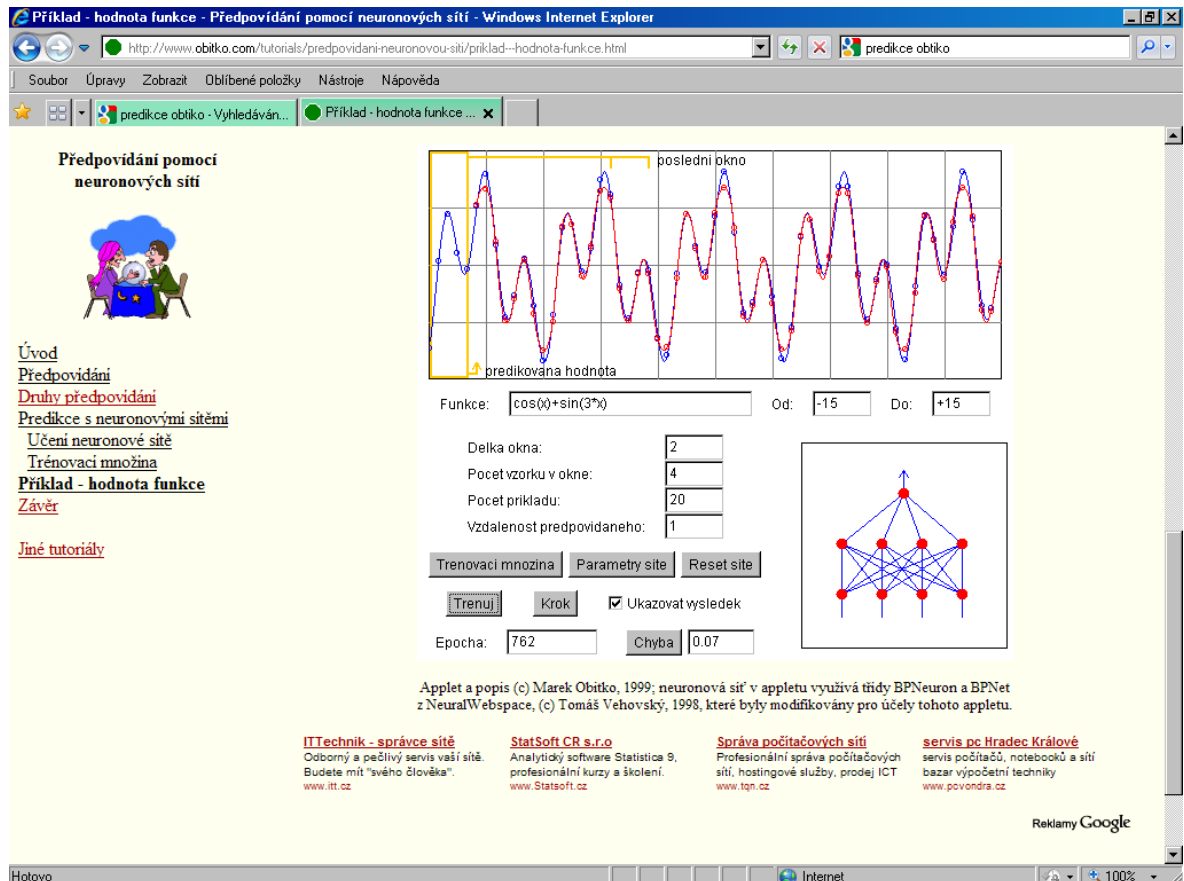


Obr. 33: Ukázkový příklad topologie neuronové sítě v prostředí Multiple Back Propagation

### Obtiko

Obtiko, webová stránka zabývající se problematikou předpovídání pomocí neuronových sítí, dostupná na adrese <http://www.obitko.com/tutorials/predpovidani-neuronovou-siti/uvod.html>.

Poslední neméně zajímavou aplikací je funkční model resp. JAVA applet neuronové sítě s algoritmem Backpropagation, který je dostupný na adrese <http://www.obitko.com/tutorials/predpovidani-neuronovou-siti/priklad---hodnota-funkce.html> (obr. 34).



Obr. 34: Ukázka modelu predikce hodnoty funkce na portálu <http://www.obitko.com/>

Uvedené softwarové aplikace byly testovány zejména pro pochopení problematiky predikce hodnot veličin pomocí neuronových sítí.

Na rozdíl od aplikace STATISTICA nebylo v uvedených softwarech možné realizovat testování na množině dat poskytnutých společností Českomoravský cement, a to kvůli různým omezením uvedených trial/shareware verzí softwarů.

## 5.6 Návrh a vývoj softwarové aplikace pro predikci hodnot chemického složení surovin

Cílem praktické části této práce a souvisejícího vývoje je doplnění stávajícího systému řízení výrobního procesu o softwarovou aplikaci pro predikci hodnot chemického složení výchozích surovin pro výrobu slínku.

Požadavek je vyvolán nedostatkem současného řešení v absenci dalšího prvku automatické kontroly, který by včas zasáhl do regulace vah vstupních surovin a ovlivnil výpočet poměrů surovin dříve, než je zpracovaná celá produkce v surovinovém mlýnu.

System výpočtu poměrů jednotlivých surovin a jejich dávkování na váhách je k dispozici operátorovi v řídicím centru prostřednictvím systému AMLAS. Operátor má mimo jiné za úkol sledovat kvalitu výroby, a to z grafické i numerické prezentace dat výroby. V případě zachycení nevhodného vývoje trendu může zvolit ze dvou řešení:

1. korekce pomocí nového návrhu programem AMLAS,
2. manuální nastavení regulátorů dle vlastního úsudku.

Dosavadní praxe ukazuje, že v prvním případě může automatický návrh vést k nevhodné volbě poměru vah a tedy i nepříznivému prosazování té které suroviny na úkor ceny, momentální dostupnosti, připravenosti, případně čistoty apod. Ve druhém případě se zásah do regulace může rovnat ruletě, kdy příznivý úsudek – odhad může vést ke správnému zregulování, ale také může představovat takový rozkmit systému, že následná korekce pomocí dodatečných úprav bude znamenat zvýšení výrobních nákladů, v horším případě k odpisu celé zpracovávané dávky.

Vzhledem k tomu, že vstupní suroviny přiváděné dopravníkem do dávkovačů prochází průběžným analyzátozem chemického složení ASYS, je možné s využitím dat z tohoto dlouhodobého měření predikovat budoucí chemické složení ještě dříve, než jsou rozdrčeny v surovinovém mlýnu.

Uvedené zjištění při analýze problému bylo zohledněno v návrhu řešení, které je založeno na softwarovém modelu vícevrstvé neuronové sítě s algoritmem učení Backpropagation. Pro regulaci resp. včasnou změnu poměrů vah jednotlivých surovin je dostačující časové okno 30 minut, tedy znalost budoucího chemického složení od posledního měření k následnému budoucímu. Pravidelné měření probíhá v intervalu 30 minut.

Softwarovou realizaci řešení nelze nasadit do ostrého provozu dříve, než bude dostatečně ověřeno dlouhodobým sledováním. Chybné řešení může znamenat velké finanční ztráty. Z tohoto důvodu bude nutné v rámci testování vycházet nejen z aktuálních měření, ale také z archivních měření minulých období. Hodnoty měření a predikované hodnoty se budou zaznamenávat do databáze aplikace. Součástí záznamů budou také údaje o uživateli (pravděpodobně dispečer výroby), a datum a čas měření. Tyto údaje včetně numerického a grafického vyhodnocení musí být k dispozici managementu výroby, vedoucímu laboratoře a dalším uživatelům, kteří mají na starost sledování kvality výroby. Proto byla zvolena třívrstvá architektura aplikace (aplikace – databáze – klient), která umožňuje její dostupnost širokému počtu uživatelů a jednotný přístup k databázi záznamů. Roli aplikace

plní softwarové řešení, které zajišťuje komunikaci mezi klientskou a databázovou částí a současně vlastní logiku predikce pomocí neuronových sítí. V roli databáze vystupuje SQL databázový stroj, roli klienta, který slouží jako prezentační vrstva pro zobrazování, příjem a odesílání dat, plní libovolný webový prohlížeč. Zvolené řešení zajišťuje dostupnost všech potřebných funkcionalit aplikace v intranetové síti podniku. Zvolené řešení bude po vyhodnocení úspěšnosti odhadu přijato nebo zamítnuto.

Aplikace byla pracovním označena názvem PCSS (Predikce chemického složení surovin).

### 5.6.1 Návrh řešení

Při návrhu řešení softwarové aplikace pro predikci hodnot chemického složení surovin se vycházelo z následujících požadavků:

- Jednoduché ovládání na straně klienta i serveru,
- dostupnost aplikace z libovolného místa,
- nezávislost klienta na platformě operačního systému,
- malé nároky na hardware serveru,
- technicky i cenově nenáročné vývojové prostředky, databázový stroj a operační systém serveru,
- minimální fragmentace aplikace a souvisejících komponent,
- snadná rozšiřitelnost o další funkce, objekty a služby,
- cenově přijatelná a technicky nenáročná bezpečnost a záloha dat.

### 5.6.2 Volba vývojových nástrojů a běhových platforem

Splnění požadovaných podmínek, které jsou uvedeny v předchozí kapitole, bylo určující pro výběr následujících nástrojů:

- Operační systém Linux pro server aplikace a databázi,
- libovolný prohlížeč WWW stránek, který podporuje jazyk HTML minimálně verze 3.2, a je schopen interpretovat příkazy jazyka JavaScript a atributy CSS,
- bezplatné nástroje a vývojové prostředky:
  - ConTEXT v0.98.6 (<http://www.contexteditor.org/>), editor pro zápis zdrojových textů aplikace PCSS, HTML formulářů a JavaScript procedur, tvořících klientskou část,



- překladač a pomocné soubory a knihovny jazyka C, program GDB k ladění programů napsaných v jazyce C a C++ (je součástí distribuce operačního systému Linuxu),
- dynamické knihovny, sada funkcí, serverová a klientská část databázového stroje MySQL 5.1.37 (zdroj instalace <http://dev.mysql.com/downloads/>).

Všechny uvedené nástroje podléhají GNU licenci (<http://www.gnu.org/licenses/>).

### 5.6.3 Databáze aplikace

Databáze aplikace je založena na databázovém systému MySQL. Databázový stroj MySQL je spolu s aplikací PCSS instalován na serveru. Jádro aplikace PCSS komunikuje s databází MySQL pomocí funkcí API rozhraní MySQL.

MySQL je multiplatformní databáze. Vnější komunikace s databází je založena na strukturovaném dotazovacím jazyce SQL. Pro komunikace s databázovým jádrem se využívá knihovna funkcí API rozhraní MySQL. [13]

MySQL má pro svou snadnou implementovatelnost, výkon a především díky tomu, že se jedná o volně šiřitelný software, vysoký podíl v současné době používaných databázích. Velmi oblíbená a často nasazovaná je kombinace MySQL, PHP a Apache jako základní software webového serveru [20].

Pro potřeby aplikace PCSS byla založena databáze „cnsbp“ a navrženy tabulky, které slouží pro uchovávání měřených (tabulka *mereni*) a predikovaných (tabulka *predikce*) dat, konfigurace neuronových sítí (tabulka *nsite*) a identifikace uživatelů (tabulka *users*) (obr. 35). Struktura a popis tabulek je uveden v příloze P III.

Databáze „cnsbp“ a její tabulky byly vytvořeny pomocí aplikace phpMyAdmin 3.2.0.1, která je součástí instalačního balíčku MySQL.


Table Name	Fields
cnsbp.users	<ul style="list-style-type: none"> <li>id : int(11)</li> <li>user : char(15)</li> <li>passwd : char(100)</li> <li>sid : int(5)</li> <li>uid : char(50)</li> <li>login_time : int(15)</li> <li>trans_time : int(15)</li> <li>trans_limit : int(8)</li> <li>remote_addr : char(18)</li> </ul>
cnsbp.mereni	<ul style="list-style-type: none"> <li>Id : int(10) unsigned</li> <li>Datum : datetime</li> <li>Hmotnost_kg : float unsigned</li> <li>SiO2 : float</li> <li>Al2O3 : float</li> <li>Fe2O3 : float</li> <li>CaO : float</li> <li>SO3 : float</li> <li>Silo : tinyint(3) unsigned</li> <li>MS : float</li> <li>MA : float</li> <li>LSF : float</li> <li>Operace : char(2)</li> <li>user : char(15)</li> </ul>
cnsbp.predikce	<ul style="list-style-type: none"> <li>datum_zapisu : timestamp</li> <li>nsid : varchar(15)</li> <li>uzivatel : char(15)</li> <li>m_SiO2 : float</li> <li>m_Al2O3 : float</li> <li>m_Fe2O3 : float</li> <li>m_CaO : float</li> <li>m_SO3 : float</li> <li>p_SiO2 : float</li> <li>p_Al2O3 : float</li> <li>p_Fe2O3 : float</li> <li>p_CaO : float</li> <li>p_SO3 : float</li> <li>tab : char(1)</li> </ul>
cnsbp.nsite	<ul style="list-style-type: none"> <li>Id : varchar(15)</li> <li>Velicina : varchar(15)</li> <li>Hodnota : float</li> <li>Stav : char(1)</li> </ul>

Obr. 35: Ukázka definovaných tabulek

#### 5.6.4 Realizace vývoje aplikace

Vývoj a testování aplikace probíhalo na počítačové sestavě s procesorem Intel Pentium 4 1.70GHz, 1 cores, pevným diskem o kapacitě 60GB ATA 133, operační paměti o velikosti 512MB SDRAM a integrovanou síťovou kartou 10/100Mbps, operačním systémem Debian Linux 5.0. Sestava slouží jako HTTP server pro webovou prezentaci na veřejné IP adrese.

Jádro aplikace PCSS tvoří dekodér transakcí přijímaných na rozhraní CGI (Common Gateway Interface [7], ve spolupráci s WWW serverem Apache. Aplikace PCSS přebírá data od uživatele prostřednictvím HTML stránek, zpracuje je a výsledky předá formou vygenerovaného nového obsahu zpět klientovi. Konfigurace WWW serveru, zejména určení cesty k CGI a povolení spuštění CGI aplikací bylo provedeno podle elektronického manuálu (Apache Manual), který je součástí instalačního balíčku WWW serveru Apache.



Obr. 36: Obsloužení požadavku CGI-skriptem, zdroj [7]

Vlastnosti aplikace PCSS z pohledu CGI:

1. program musí být spustitelný,
2. program musí být schopen přijmout a dekodovat data, která klient odešle prostřednictvím HTML formuláře.

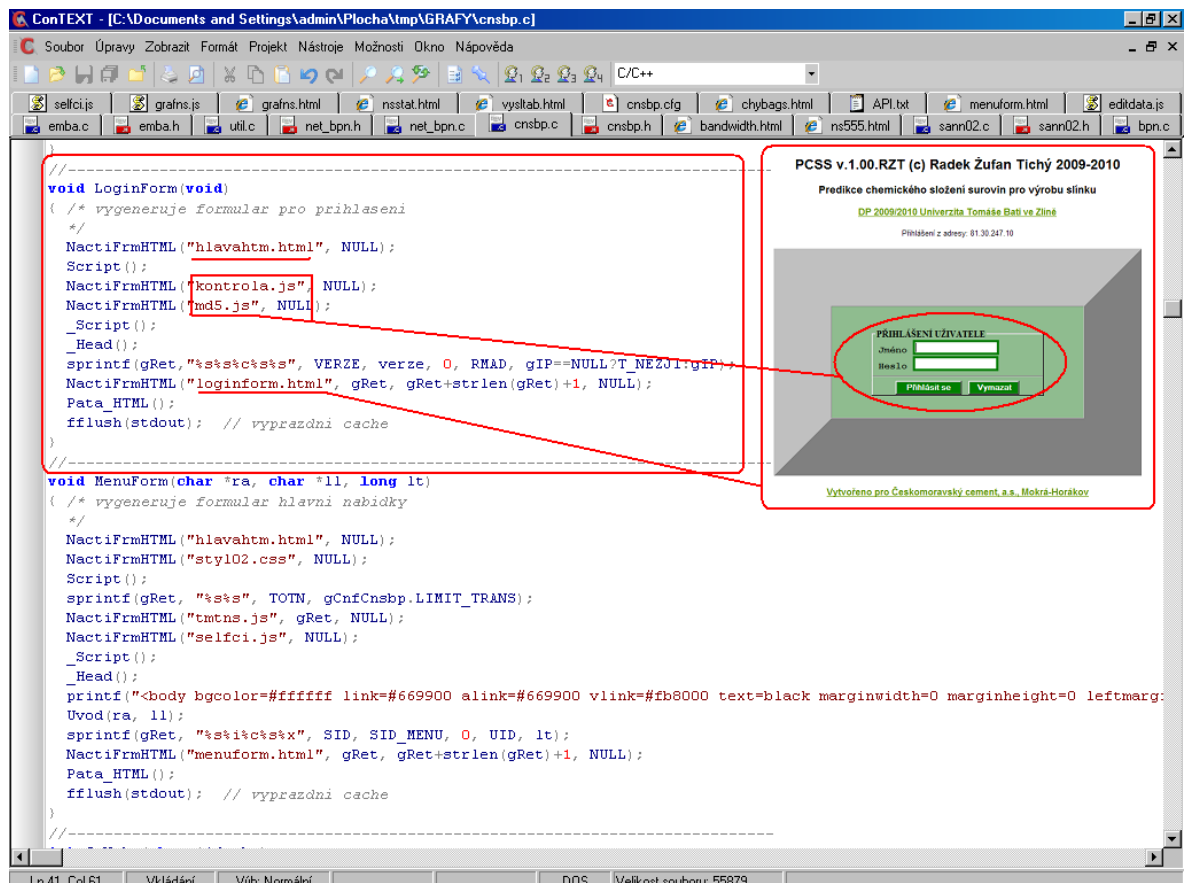
Podle použité metody (atribut METHOD elementu FORM) se rozlišuje způsob odeslání dat na [20]:

- i. GET, data jsou uložena v proměnné prostředí QUERY\_STRING, slouží pro přenos kratších informací, v aplikaci PCSS byla použita ve formuláři pro přihlášení uživatele,
- ii. POST, data jsou předána na standardní vstup CGI aplikace, slouží k přenášení většího objemu dat, v aplikaci PCSS byla použita pro většinu formulářů, které slouží k interakci s uživatelem.

Kompletní aplikace PCSS zahrnuje:

- **Výkonnou část** – CGI aplikace „cnsbp“, která komunikuje s WWW serverem Apache prostřednictvím CGI rozhraní a s databázovým serverem MySQL prostřednictvím rozhraní SŘBD (Systém Řízení Báze Dat). Jádrem aplikace je funkce *ProvedTransakci* (zdrojový kód cnsbp.c, příloha PV), jejíž úlohou je dekodování požadavků přicházejících od jednotlivých formulářů. Každý formulář je za tímto účelem ohodnocen jedinečným SID (serial ID – sériové číslo). Dále se do formulářů ukládá jedinečná identifikace uživatele (UID user ID), jejíž hodnota je vygenerována po korektním přihlášení a uložena ke konkrétnímu uživateli. Tímto má aplikace jednotlivé funkce, včetně uživatele, pod svojí kontrolou. Identifikace UID se kromě vazby na uživatele používá ke kontrole transakčních časů a limitů. Je-li čas poslední transakce starší než aktuální čas mínus hodnota limitu konkrétního uživatele, přejde aplikace do inicializace a vyvolá přihlašovací formulář (dojde k automatickému odhlášení). S každou zpracovanou transakcí se u přihlášeného uživatele aktualizuje čas poslední transakce (atribut *trans\_time*, tabulka *users*). Součástí zdrojových textů jsou podpůrné funkce v modulu *util.c* (příloha PV), kde se mimo jiné nachází rutiny pro dekodování CGI rozhraní s potřebnými bezpečnostními kontrolami na cesty a znaky, které by mohly vyvolat přerušeni shellu. Vzhledem k záměru víceuživatelského používání bylo nutné zajistit integritu dat. O tu se stará funkce *ZamZaz*, která zajišťuje zamykání tabulek v rámci aktualizáčních operací. Poslední významnou funkcí je *NactiFrmHTML*, která zajišťuje načítání potřebných formulářů (externích souborů), které jsou po aktualizaci (odrážka datová část - symbolické texty) odeslány klientovi. Kromě symbolických textů je funkce schopna rekurzivního načítání souborů podle řídicího znaku *,#‘*, za kterým se očekává název souboru. Tímto lze dosáhnout „řetězové výroby“ požadovaného výstupu z několika dokumentů [20].
- **Konfigurační soubor** *cnsbp.cfg*, kterým se nastavuje:
  - Jméno databáze, ke které se bude aplikace připojovat (proměnná *MY\_SQL\_DB*),
  - adresa, na které je dostupný MySQL server (proměnná *MY\_SQL\_HOST*),
  - jméno a heslo uživatele, který je oprávněn k přístupu na MySQL server (proměnné *MY\_SQL\_USER*, *MY\_SQL\_PASSWORD*),
  - číslo socket portu (proměnná *MY\_SQL\_PORT*, obvykle 3306),





Obr. 38: Ukázka zdrojového kódu pro tvorbu přihlašovacího formuláře

- **Databázi** – popis uveden v kapitole 5.6.3 a příloze P III.
- **Knihovnu JQUERY 1.4.2** – zajišťuje generování grafů ve formulářích predikce hodnot (<http://jquery.com/>).

Doplňující funkcí je rozhraní phpMyAdmin, které slouží k administraci databáze MySQL. Toto rozhraní je navázáno na funkci *Nastavení dat* a dává k dispozici mocný nástroj pro manipulaci dat, zejména pro přípravu trénovacích a testovacích množin neuronových sítí. Z bezpečnostního hlediska je použití této funkce přístupné pouze z konkrétní IP adresy (příloha P I).

### 5.6.5 Popis uživatelského rozhraní aplikace PCSS

Spuštění aplikace se provede zadáním URL adresy a jména CGI aplikace „cnsbp.cgi“ do URL řádku internetového prohlížeče, v tomto případě <http://www.mojefm.cz/cgi-bin/cnsbp.cgi>. Pokud jsou všechny související komponenty správně nastavené a funkční, zobrazí se formulář pro přihlášení uživatele (obr. 39).

**PCSS v.1.00.RZT (c) Radek Žufan Tichý 2009-2010**

Predikce chemického složení surovin pro výrobu slínku

[DP 2009/2010 Univerzita Tomáše Bati ve Zlíně](#)

Přihlášení z adresy: 81.30.247.10

**PŘIHLÁŠENÍ UŽIVATELE**

Jméno

Heslo

[Vytvořeno pro Českomoravský cement, a.s., Mokrá-Horákov](#)

Obr. 39: Přihlášení uživatele do aplikace PCSS

Po přihlášení uživatele se zobrazí stránka s nabídkou dostupných funkcí aplikace PCSS.

**PCSS v.1.00.RZT (c) Radek Žufan Tichý 2009-2010**

Uživatel: root přihlášení z adresy: 81.30.247.10  
Předchozí přihlášení: 05.06.2010 10:37 z adresy: 81.30.247.10

**SW aplikace pro predikci chemického složení surovin pro výrobu slínku - základní suroviny při výrobě cementu.**

K predikci budoucích hodnot chemického složení se využívá vícevrstvá neuronová síť s dopředným šířením a algoritmem učení Back Propagation. Vstupem do neuronové sítě (dále jen NS) jsou hodnoty z předchozích, dlouhodobých analýz chemického složení surovin, které jsou charakterizovány základními oxidy:  
SiO<sub>2</sub>, Al<sub>2</sub>O<sub>3</sub>, Fe<sub>2</sub>O<sub>3</sub>, CaO, SO<sub>3</sub>

Obr. 40: Ukázka formuláře pro výběr nabídky

V aplikaci jsou připraveny funkce pro predikování hodnot pomocí neuronové sítě typu 5-5-5, predikování hodnot pomocí neuronové sítě typu 25-5-5, predikování hodnot pomocí neuronové sítě navržené programem STATISTICA, nastavení databáze a odhlášení.

Nabídka **Predikce hodnot pomocí NS-BP 5-5-5** zobrazí formulář pro práci s neuronovou sítí, která má po 5 neuronech ve vstupní, skryté i výstupní vrstvě, a využívá algoritmus učení Backpropagation. Vstupní a výstupní vrstva neuronové sítě odpovídá pětici oxidů  $\text{SiO}_2$ ,  $\text{Al}_2\text{O}_3$ ,  $\text{Fe}_2\text{O}_3$ ,  $\text{CaO}$ ,  $\text{SO}_3$ .

Nabídka **Predikce hodnot pomocí NS-BP 25-5-5** zobrazí formulář pro práci s neuronovou sítí, která má po 25 neuronů ve vstupní vrstvě a po 5 neuronech ve skryté a výstupní vrstvě, a využívá algoritmus učení Backpropagation. Vstupní vrstva odpovídá pěti měření každého z pětice oxidů  $\text{SiO}_2$ ,  $\text{Al}_2\text{O}_3$ ,  $\text{Fe}_2\text{O}_3$ ,  $\text{CaO}$ ,  $\text{SO}_3$ , výstupní vrstva neuronové sítě odpovídá pětici predikovaných hodnot oxidů.

Nabídka **Predikce pomocí NS-STAT** zobrazí formulář pro práci s neuronovou sítí, která má po 5 neuronů ve vstupní vrstvě, 9 neuronů ve skryté vrstvě a 5 neuronů ve výstupní vrstvě, a algoritmem učení Backpropagation. Vstupní a výstupní vrstva neuronové sítě odpovídá pětici oxidů  $\text{SiO}_2$ ,  $\text{Al}_2\text{O}_3$ ,  $\text{Fe}_2\text{O}_3$ ,  $\text{CaO}$ ,  $\text{SO}_3$ .

Nabídka **Nastavení dat** umožní přechod na stránku phpMyAdmin pro administraci databáze MySQL, tedy i databáze „cnsbp“ aplikace PCSS (příloha P I).

Nabídkou **Odhlášení** se provede odhlášení z aplikace PCSS a přechod do formuláře pro přihlášení uživatele.

### 5.6.6 Příklad použití neuronové sítě pro trénování

Demonstračním příkladem je volba **Predikce hodnot pomocí NS-BP 5-5-5**. Kliknutím na uvedenou volbu se vyvolá formulář pro nastavení neuronové sítě.

V horní části formuláře se indikuje stav neuronové sítě a počet dat (řádků) pro trénovací a validační množiny, které jsou potřebné pro učení sítě. Výběr dat pro trénovací a validační množiny se provádí přes funkci **Nastavení dat**. Z obrázku je patrné, že síť není naučená, protože nejsou dostupné údaje vah.

Obr. 41: Formulář pro nastavení neuronové sítě 5-5-5

Nastavení trénování sítě se provede následujícími parametry:

- Parametr **Požadované hodnoty na výstup určit jako** znamená porovnání výstupního signálu z neuronů výstupní vrstvy se vzorem (požadovanou hodnotou) v rámci jednoho cyklu. Rozdíl porovnání se využívá pro zpětný přepočítání hodnot vah v rámci algoritmu Backpropagation. Možnosti nastavení jsou:
  - *střední hodnoty oxidů* ze všech předchozích měření,
  - *odpovídající řádky validačních dat* (tvoří komplementární dvojici vektoru pro trénování sítě), pokud je množství řádků pro validaci menší než



množství trénovacích řádků; chybějící řádky validační množiny jsou doplněny z hodnot posledního řádku validačních této množiny,

- hodnoty oxidů *následujícího řádku trénovacích dat* (tzv. „valivý efekt“).
- Parametr **Kritéria ukončení** znamená stanovení podmínky ukončení trénování. Možnosti nastavení jsou:
  - *chyba vektoru* – vstupní políčko této volby umožňuje nastavit hodnotu, která způsobí ukončení fáze trénování na úrovni cyklu, tedy v okamžiku, kdy se provádí srovnání výstupních signálů se vzory; pokud je chyba menší nebo se rovná stanovené hodnotě, dojde k zastavení trénování,
  - *chyba sítě* – vstupní políčko této volby umožňuje nastavit hodnotu, která způsobí ukončení fáze trénování na úrovni vývoje globální chyby sítě; pokud je globální chyba menší nebo se rovná stanovené hodnotě, dojde k zastavení trénování,
  - *počet cyklů* – vstupní políčko této volby umožňuje nastavit hodnotu, která způsobí penalizaci jednotlivých cyklů fáze trénování, každý cyklus je předčasně ukončen při dosažení nastavené hodnoty cyklu, trénovací množina se projde celá.
- Parametr **Rozsah pro inicializaci vah** znamená stanovení hodnot dolní a horní meze pro počáteční nastavení hodnot vah pomocí generátoru náhodných čísel.

Zahájení trénování se provede tlačítkem **Trénovat**. Po dokončení trénování resp. po naučení sítě je možné tlačítkem **Testovat** přejít do formuláře pro predikci hodnot (kapitola 5.6.7).

V případě modelu neuronové sítě 25-5-5 je použití analogické. Rozdíl je pouze ve způsobu výpočtu, kdy na vstupu do sítě vstupují hodnoty pěti měření za každý oxid zvlášť. V rámci trénovací a validační množiny se potom využívá současně pět řádků dat.

### 5.6.7 Příklad použití neuronové sítě pro predikci

Demonstračním příkladem je volba **Predikce pomocí NS-STAT**, analogicky popis platí i pro ostatní modely neuronových sítí. V ukázce je zpracovávaná neuronová síť navržená označená jako MLP (VVPS) 5-9-5. Uvedený model neuronové sítě resp. jeho zdrojový kód v jazyce C vznikl pomocí programu Statistica CZ 9 (kapitola 5.4). Po nezbytných úpravách byl tento model začleněn do zdrojového kódu aplikace PCSS.

#### Topologie NS: MLP VVPS 5-9-5

**Údaje neuronové sítě**

Automaticky vygenerovaná síť pomocí **SW STATISTICA CZ 9**  
 V aplikaci je implementovaný model 5-9-5 s přenosovou logistickou funkcí a učícím algoritmem Back-propagation.

**Stav neuronové sítě**

Síť je již naučená na množině dat z předchozích 4688 měření chemického složení, z období od 12/2009 do 04/2010.  
 Síť již neumožňuje zpětně upravovat váhy.

Do níže uvedených políček zapište aktuální měření oxidů, poté stiskněte tlačítko [Predikce]

Měření:	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	CaO	SO <sub>3</sub>
	<input style="width: 50px;" type="text" value="0.0"/>	<input style="width: 50px;" type="text" value="0.0"/>	<input style="width: 50px;" type="text" value="0.0"/>	<input style="width: 50px;" type="text" value="0.0"/>	<input style="width: 50px;" type="text" value="0.0"/>
Zadané:	13.610	4.540	2.190	42.510	0.260
Predikce:	13.452	3.217	1.961	43.722	0.189


Historie:

datum	záznamu	uživatel	měřené - predikované									
2010-06-05	10:09:12	root	13.25	3.58	1.96	42.95	0.13	13.57	3.23	1.98	43.63	0.19
2010-06-05	10:06:29	root	13.89	3.6	2.07	42.5	0.13	13.46	3.22	1.96	43.71	0.19
2010-06-05	10:06:57	root	14.02	3.64	2.03	42.3	0.11	13.18	3.06	1.87	44.05	0.19
2010-06-05	10:07:26	root	13.85	3.6	1.98	42.46	0.12	13.89	3.17	2	43.51	0.2
2010-06-05	10:03:03	root	13.27	3.54	2.21	42.99	0.17	13.45	3.22	1.96	43.72	0.19
2010-06-05	10:01:55	root	13.13	3.3	2.16	43.43	0.16	13.45	3.22	1.96	43.72	0.19
2010-06-05	10:05:24	root	13.61	3.7	2.08	42.68	0.11	13.45	3.22	1.96	43.72	0.19
2010-06-05	10:04:49	root	13.32	3.6	2.02	42.88	0.2	13.89	3.17	2	43.51	0.2
2010-06-05	10:02:25	root	12.84	3.69	2.25	43.17	0.17	13.45	3.22	1.96	43.72	0.19
2010-06-05	09:59:58	root	12.79	3.28	2.08	43.32	0.16	13.45	3.22	1.96	43.72	0.19


Obr. 42: Formulář predikce hodnot modelem neuronové sítě MLP VVPS 5-9-5

Na obrázku 42 je znázorněný příklad predikce, jejíž předchozí pokusy jsou zaznamenány v historii pod vstupním formulářem. Ve formuláři se nachází vstupní políčka pro zápis aktuálně změřených hodnot oxidů SiO<sub>2</sub>, Al<sub>2</sub>O<sub>3</sub>, Fe<sub>2</sub>O<sub>3</sub>, CaO, SO<sub>3</sub>. Po zadání konkrétních hodnot a stlačení tlačítka **Predikce** se v řádku *Predikce* zobrazí predikované hodnoty oxidů. Zároveň se automaticky do historie zaznamená měřený a predikovaný vektor,


uživatel a čas predikce. Na následujících obrázcích jsou znázorněny grafy vývoje měření a predikce pro každý oxid zvlášť.




Obr. 43: Vývoj měřené hodnoty a její predikce pro SiO<sub>2</sub>



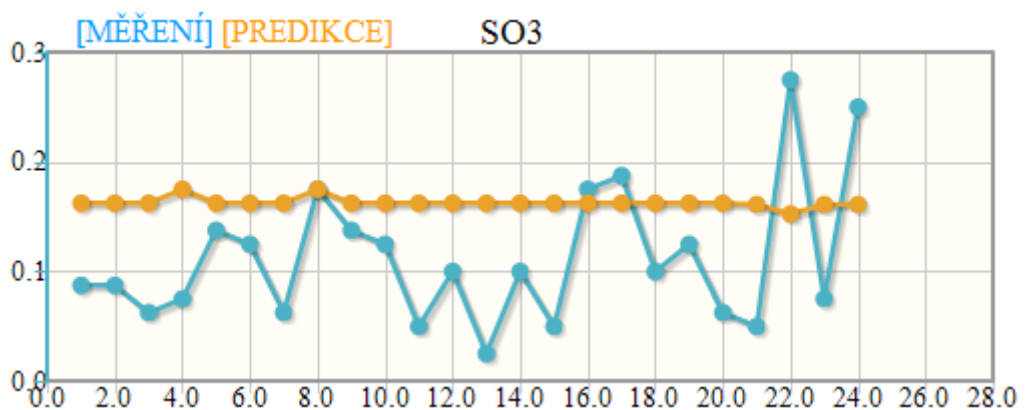
Obr. 44: Vývoj měřené hodnoty a její predikce pro Al<sub>2</sub>O<sub>3</sub>



Obr. 45: Vývoj měřené hodnoty a její predikce pro Fe<sub>2</sub>O<sub>3</sub>



Obr. 46: Vývoj měřené hodnoty a její predikce pro CaO

Obr. 47: Vývoj měřené hodnoty a její predikce pro SO<sub>3</sub>

### 5.6.8 Praktické využití aplikace

Aplikace PCSS je plně funkční pro nasazení do reálného provozu pro uživatele všech cílových skupin. Aplikaci lze provozovat v rámci podnikové infrastruktury. Ověření kvality predikce proběhne v období červenec-prosinec 2010. Součástí ověření bude statistické vyhodnocení kvality predikovaných hodnot.

## ZÁVĚR

Cílem diplomové práce bylo seznámit se s problematikou výroby slínku, který je hlavní surovinou pro výrobu cementu, s optimální skladbou slínku, se způsobem vyhodnocení jeho složení a se způsobem regulace tohoto složení. Následně byl zhodnocen způsob výpočtu dávkování surovin a úroveň optimalizace regulace tohoto dávkování.

Metody umělé inteligence jsou schopné nahradit běžné výpočetní algoritmy, stejně tak predikovat budoucí hodnoty na základě časové závislosti veličin nebo z dlouhodobých měření. Pro zjištění vhodnosti použití metod umělé inteligence byl vytvořen funkční model predikce chemického složení surovin pro výrobu slínku a otestován v programovém vybavení MS Excel a Statistica CZ 9. Finálním řešením bylo vytvoření vlastní aplikace, která dokáže využívat modelů neuronových sítí typu 5-5-5, 25-5-5 a 5-9-5, pro možnost nasazení do reálného provozu, jako souběžného výpočtu vedle stávajícího systému regulace a řízení. Pokud se dlouhodobým porovnáváním výsledků predikce a měření z reálného provozu prokáže vhodnost využití, může být aplikace zařazena do procesu řízení kvality výroby.

Z výsledků testovacích dat lze předběžně konstatovat, že využitím neuronové sítě pro predikci budoucího složení slínku, lze optimalizovat celý výrobní proces, zvýšit efektivitu provozu a snížit výrobní náklady.

## CONCLUSION

The objective of the theses was to get information about production of clinker, about optimum composition of clinker, about a way of evaluation of its composition and about a way of regulation of this composition. The clinker is main manufacturing component of cement.

Consequently, the method of calculation dosing of raw materials and the level of optimisation regulation of the dosage were evaluated.

Methods of artificial intelligence are capable to replace current algorithms, as well as predict future values based on the time dependence of variables or long-term measurements.

In order to verify the opportunities of using methods of artificial intelligence, it was created a functional model of prediction of the chemical composition of raw materials for production of clinker and it was tested in software the MS Excel and the Statistica CZ 9.

Final solution was to create a respective application that allows using the models of neural networks of type 5-5-5, 25-5-5 and 5-9-5. This application is capable of deployment into real business as parallel complement next to existing system of regulation and control.

As far as the possibility of using during by long comparing the results of prediction and measurement from real operation, then this application can be included into the process of production management.

The results of testing data suggest that using neural networks for predicting of the future composition of clinker, it is possible to optimise the entire production process, to increase operating efficiencies and reduce production costs.

**SEZNAM POUŽITÉ LITERATURY**

- [1] AMLAS. *MixtureCalculationUserGuide*. Uživatelská dokumentace k systému AMLAS, Poslední aktualizace 5.8.2004.
- [2] AUTOMA. *Měřicí technika při výrobě cementu a vápna*. Č. 2 (únor 2009). Praha: FCC PUBLIC s. r. o. Vychází měsíčně.  
URL: <[http://www.odbornecasopisy.cz/index.php?id\\_document=38616](http://www.odbornecasopisy.cz/index.php?id_document=38616)>
- [3] *Českomoravský cement*. [online] URL: <<http://www.heidelbergcement.cz/cement/>> [citováno 1.5.2009].
- [4] DAVIS, L. *Handbook of Genetic Algorithms*. International Thomson Computer Press, 1996. ISBN 1850328250.
- [5] JANČÍKOVÁ, Z. – MELECKÝ, J. – ŠVEC, P. *Aplikace metod umělé inteligence při predikci chemického složení rafinačních strusek*. In Sborník z konference Metal 2008, Hradec nad Moravicí, 2008.
- [6] KIUSALAAS, J. *Numerical Methods in Engineering with Python*. Cambridge University Press, 2005. ISBN 0521852870, 9780521852876.
- [7] KOSEK, J. *Aplikace na webu. Téměř vše o WWW* [online]. URL: <<http://www.kosek.cz/clanky/iweb/index.html>>, poslední aktualizace 2.2.1999 [citováno 12.5.2010].
- [8] KVASNIČKA, V. – POSPÍCHAL, J. – TIŇO, P. *Evoluční algoritmy*. 1. vydání. Bratislava: Vydavateľstvo STU, 2000. ISBN 80-227-1377-5.
- [9] LIŠKA, M. *Metody operačního výzkumu*. Distanční opora. Ostrava: Ostravská univerzita, 2002. Elektronický text. URL: <<http://www.informatika-osu.czechian.net/files/DIST-MOPV-12.pdf>>
- [10] MAŘÍK, V. - ŠTĚPÁNKOVÁ, O. - LAŽANSKÝ, J. *Umělá inteligence*. Academia, 1993, ISBN 80-200-0496-3.
- [11] MAŘÍK, V. - ŠTĚPÁNKOVÁ, O. - LAŽANSKÝ, J. *Umělá inteligence 4*. Academia, 2003, ISBN 80-200-1044-0.
- [12] MAŘÍK, V. - ŠTĚPÁNKOVÁ, O. - LAŽANSKÝ, J. *Umělá inteligence 5*. Academia, 2007, ISBN 978-80-200-1470-2.

- [13] MASLAKOWSKI, M. *Naučte se MySQL za 21 dní*. 1. vydání. Praha: Computer Press, 2001. ISBN 80-7226-448-6,.
- [14] OPLATKOVÁ, Z. *Metaevolution - Synthesis of Optimization Algorithms by means of Symbolic Regression and Evolutionary Algorithms*. Lambert-Publishing, 2009, ISBN 978-8383-1808-0.
- [15] REKTORYS, K. *Přehled užití matematiky*. 3. vydání, Praha, SNTL, 1973. ISBN 04-001-73.
- [16] VOLNÁ, E. *Neuronové sítě 1*. 2. vydání. Ostrava: Ostravská univerzita, 2008. Elektronický text. URL: <[http://albert.osu.cz/oukip/volna/materialy/NEURONOVE\\_SITE\\_1/XNES1.pdf](http://albert.osu.cz/oukip/volna/materialy/NEURONOVE_SITE_1/XNES1.pdf)>
- [17] ZELINKA, I. *Umělá inteligence I: Neuronové sítě a genetické algoritmy*. 1. vydání. Brno: VUTIUM, 1998. ISBN 80-214-1163-5.
- [18] ZELINKA, I. *Umělá inteligence*. 2. vydání. Zlín: UTB – Academia centrum, 2005. ISBN 80-7318-277-7.
- [19] ZELINKA I., OPLATKOVÁ Z., OŠMERA P. ŠEDA M., VČELAŘ F.: *Evoluční výpočetní techniky – principy a aplikace*. Praha, BEN – technická literatura, 2008. ISBN 80-7300-218-3.
- [20] ŽUFAN TICHÝ, R. *Elektronická správa obchodní agendy*. Bakalářská práce. Ostravská univerzita 2006.



**SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK**

AMLAS	system automatické řízení směsi
API	Application Programming Interface
ASYS	kontinuální rentgenový analyzátor chemického složení
CGI	Common Gateway Interface
CSV	Comma-Separated Values, hodnoty oddělené čárkami
GDB	GNU Debugger, nástroj na hledání chyb v programu
GNU	General Public Licence
HTML	HyperText Markup Language
LSF	nositel sycení
MA	aluminátový modul
MS	silikátový modul
NS	Neuronová Síť
PCSS	Predikce Chemického Složení Surovin
PHP	Hypertext Preprocessor
RMAD	zkratka symbolického textu pro hodnotou IP adresy posledního přihlášení
RTG	Radioisotope Thermoelectric Generator
SID	Seriál ID, symbolický text
SQL	Structured Query Language
SŘBD	System Řízení Báže Dat
UID	User ID, jedinečná identifikace uživatele
URL	Uniform Resource Locator
WYSIWYG	What You See Is What You Get
XLS	přípona souboru aplikace Microsoft Excel
XRF	přesný analyzátor chemického složení

## SEZNAM OBRÁZKŮ

Obr. 1: Těžba a drcení suroviny.....	13
Obr. 2: Příprava suroviny – homogenizace .....	13
Obr. 3: Příprava suroviny – sušení a mletí.....	13
Obr. 4: Výpal .....	14
Obr. 5: Mletí cementu .....	14
Obr. 6: Nakládka a doprava cementu.....	14
Obr. 7: Schéma zapojení měřicích a řídicích jednotek .....	17
Obr. 8: Schéma automatického řízení .....	18
Obr. 9: Konfigurace vzorků .....	19
Obr. 10: Nastavení regulátoru.....	19
Obr. 11: Sestavení rovnic proměnných.....	19
Obr. 12: Nastavení dalších podmínek.....	20
Obr. 13: Zařazení dalších podmínek ve schématu .....	20
Obr. 14: Nastavení složení jednotlivých ingrediencí.....	21
Obr. 15: Schéma zapojení nastavení parametrů a výpočtu směsi.....	24
Obr. 16: Podobnost biologického a umělého neutronu, zdroj [18].....	25
Obr. 17: Příklad architektury vícevrstvé neuronové sítě, zdroj [16] .....	26
Obr. 18: Použití sigmoidy jako přenosové funkce, zdroj [18].....	28
Obr. 19: Model vícevrstvé sítě, šíření signálu, zpracováno dle [16] .....	30
Obr. 20: Vývoj naměřených hodnot za celé sledované období .....	35
Obr. 21: Vývoj naměřených hodnot dne 25.4.2010.....	35
Obr. 22: Typ sítě 5-5-5 .....	36
Obr. 23: Typ sítě 25-5-5 .....	36
Obr. 24: Ukázka výpočtu sítě 5-5-5 v prostředí MS Excel.....	37
Obr. 25: Porovnání vstupních, predikovaných a skutečných hodnot .....	38
Obr. 26: Vývoj predikovaných a skutečných hodnot .....	39
Obr. 27: Ukázka dat a jejich rozdělení .....	40
Obr. 28: Navržené sítě v programu STATISTICA.....	41
Obr. 29: Přehled vypočtených vah.....	42
Obr. 30: Přehled parametrů sítí navržených modulem <i>Automatizované neuronové sítě</i> .....	42
Obr. 31: Ukázka predikce hodnot pomocí vygenerované neuronové sítě .....	43
Obr. 32: Ukázkový příklad trénování neuronové sítě v prostředí NeuralSolution .....	44

Obr. 33: Ukázkový příklad topologie neuronové sítě v prostředí Multiple Back Propagation.....	45
Obr. 34: Ukázka modelu predikce hodnoty funkce na portálu <a href="http://www.obitko.com/">http://www.obitko.com/</a> .....	46
Obr. 35: Ukázka definovaných tabulek .....	49
Obr. 36: Obsloužení požadavku CGI-skriptem, zdroj [7] .....	50
Obr. 37: Ukázka zdrojového kódu HTML formuláře s využitím symbolických textů.....	52
Obr. 38: Ukázka zdrojového kódu pro tvorbu přihlašovacího formuláře.....	53
Obr. 39: Přihlášení uživatele do aplikace PCSS .....	54
Obr. 40: Ukázka formuláře pro výběr nabídky .....	54
Obr. 41: Formulář pro nastavení neuronové sítě 5-5-5.....	56
Obr. 42: Formulář predikce hodnot modelem neuronové sítě MLP VVPS 5-9-5 .....	58
Obr. 43: Vývoj měřené hodnoty a její predikce pro $\text{SiO}_2$ .....	59
Obr. 44: Vývoj měřené hodnoty a její predikce pro $\text{Al}_2\text{O}_3$ .....	59
Obr. 45: Vývoj měřené hodnoty a její predikce pro $\text{Fe}_2\text{O}_3$ .....	59
Obr. 46: Vývoj měřené hodnoty a její predikce pro $\text{CaO}$ .....	60
Obr. 47: Vývoj měřené hodnoty a její predikce pro $\text{SO}_3$ .....	60

**SEZNAM TABULEK**

Tab. 1: Přehled míst a způsobů kontroly kvality vzorků .....	15
Tab. 2: Ukázka souboru vstupních dat.....	35

## **SEZNAM PŘÍLOH**

**PŘÍLOHA P I: ROZHRANÍ PHPMYADMIN – DATABÁZOVÉ TABULKY  
APLIKACE PCSS**

**PŘÍLOHA P II: ROZHRANÍ PHPMYADMIN – PŘIPRAVENÉ SQL DOTAZY  
PRO MANIPULACI S DATY**

**PŘÍLOHA P III: STRUKTURY TABULEK V DATABÁZI**

**PŘÍLOHA P IV: SOUBOR BP\_ANALYZA\_6M2010.XLSX**

**PŘÍLOHA P V: ZDROJOVÉ SOUBORY APLIKACE PCSS**

# PŘÍLOHA P I: ROZHRANÍ PHPMYADMIN – DATABÁZOVÉ TABULKY APLIKACE PCSS

## Tabulka MERENI

Server: localhost ▶ Databáze: cnsbp ▶ Tabulka: mereni

Zobrazeny záznamy 0 - 29 (4 688 celkem, Dotaz zabral 0.0035 sekund)

```
SELECT *
FROM `mereni`
LIMIT 0 , 30
```

Zobrazit: 30 řádků začínající od 30  
ve vodorovném režimu a opakovat hlavičky po 100 řádcích.  
Strana číslo: 1

Setřídít podle klíče: Žádná

Zkrácené texty  Relací klíč  Show binary contents  Skrýt Transformace při prohlížení  
 Celé texty  Položka k zobrazení v relacích  Show BLOB contents

	Id	Datum	Hmotnost_kg	SiO2	Al2O3	Fe2O3	CaO	SO3	Silo	MS	MA	LSF	Operace
<input type="checkbox"/>	412844	2009-12-04 08:09:00	15530.8	17.67	5.67	3.61	36.66	0.35	201	1.9	1.57	62.65	
<input type="checkbox"/>	412845	2009-12-04 08:33:40	50813.3	10.72	3.22	1.87	45.4	0.13	201	2.11	1.72	129.6	
<input type="checkbox"/>	412846	2009-12-04 09:03:30	34418.4	10.64	3.32	1.91	44.94	0.12	201	2.03	1.74	128.58	
<input type="checkbox"/>	412849	2009-12-04 09:03:30	54440	11.48	3.54	2.11	44.35	0.15	201	2.03	1.68	117.66	

## Tabulka PREDIKCE

Server: localhost ▶ Databáze: cnsbp ▶ Tabulka: predikce

Zobrazeny záznamy 0 - 29 (36 celkem, Dotaz zabral 0.0015 sekund)

```
SELECT *
FROM `predikce`
LIMIT 0 , 30
```

Zobrazit: 30 řádků začínající od 30  
ve vodorovném režimu a opakovat hlavičky po 100 řádcích.  
Strana číslo: 1

Setřídít podle klíče: Žádná

+ Nastavení

	datum_zapisu	nsid	uzivatel	m_SiO2	m_Al2O3	m_Fe2O3	m_CaO	m_SO3	p_SiO2	p_Al2O3	p.
<input type="checkbox"/>	2010-06-03 00:14:02	MLP_VVPS_5-9-5	oplatkova	13.42	3.14	2.16	44.11	0.22	13.45	3.22	
<input type="checkbox"/>	2010-06-03 00:15:14	MLP_VVPS_5-9-5	oplatkova	13.2	3.09	2.15	43.74	0.19	13.45	3.22	
<input type="checkbox"/>	2010-06-05 10:09:12	MLP_VVPS_5-9-5	root	13.25	3.58	1.96	42.95	0.13	13.57	3.23	
<input type="checkbox"/>	2010-06-05 10:06:29	MLP_VVPS_5-9-5	root	13.89	3.6	2.07	42.5	0.13	13.46	3.22	
<input type="checkbox"/>	2010-06-05 10:06:57	MLP_VVPS_5-9-5	root	14.02	3.64	2.03	42.3	0.11	13.18	3.06	
<input type="checkbox"/>	2010-06-05 10:07:26	MLP_VVPS_5-9-5	root	13.85	3.6	1.98	42.46	0.12	13.89	3.17	
<input type="checkbox"/>	2010-06-05 10:03:03	MLP_VVPS_5-9-5	root	13.27	3.54	2.21	42.99	0.17	13.45	3.22	
<input type="checkbox"/>	2010-06-05 10:01:55	MLP_VVPS_5-9-5	root	13.13	3.3	2.16	43.43	0.16	13.45	3.22	
<input type="checkbox"/>	2010-06-05 10:05:24	MLP_VVPS_5-9-5	root	13.61	3.7	2.08	42.68	0.11	13.45	3.22	

## Tabulka SETNS

www.mojefm.cz / localhost / cnsbp / nsite | phpMyAdmin 3.2.0.1 - Windows Internet Explorer

http://www.mojefm.cz/phpmyadmin/index.php?db=cnsbp&token=38243812f4293d0c77aae5f263b9736c

Soubor Úpravy Zobrazit Oblíbené položky Nástroje nápověda

phpMyAdmin Server: localhost Databáze: cnsbp Tabulka: nsite

Projít Struktura SQL Vyhledávání Vložit Export Import Úpravy Vyprázdnit Odstranit

Zobrazeny záznamy 0 - 29 (57 celkem, Dotaz zabral 0.0091 sekund)

```
SELECT *
FROM `nsite`
LIMIT 0 , 30
```

Profilování [ Upravit ] [ Vysvětlit dotaz ] [ Vytvořit PHP kód ] [ Obnovit ]

Zobrazit : 30 řádků začínající od 30 ve vodorovném režimu a opakovat hlavičky po 100 řádcích. Strana číslo: 1

Setřídít podle klíče: Žádná

+ Nastavení

	Id	Velicina	Hodnota	Stav
<input type="checkbox"/>	5-5-5	BIAS	1	
<input type="checkbox"/>	5-5-5	ALFA	0.5	
<input type="checkbox"/>	5-5-5	ERRVK	0	
<input type="checkbox"/>	5-5-5	ERRNS	0	
<input type="checkbox"/>	5-5-5	CYKLN	0	
<input type="checkbox"/>	5-5-5	RNDVO	-0.5	
<input type="checkbox"/>	5-5-5	RNDVD	0.5	
<input type="checkbox"/>	5-5-5	v0_1_1	0	
<input type="checkbox"/>	5-5-5	v0_1_2	0	
<input type="checkbox"/>	5-5-5	v0_1_3	0	
<input type="checkbox"/>	5-5-5	v0_1_4	0	
<input type="checkbox"/>	5-5-5	v0_1_5	0	
<input type="checkbox"/>	5-5-5	v0_2_1	0	

## Tabulka USER

www.mojefm.cz / localhost / cnsbp / users | phpMyAdmin 3.2.0.1 - Windows Internet Explorer

http://www.mojefm.cz/phpmyadmin/index.php?db=cnsbp&token=38243812f4293d0c77aae5f263b9736c

Soubor Úpravy Zobrazit Oblíbené položky Nástroje nápověda

phpMyAdmin Server: localhost Databáze: cnsbp Tabulka: users

Projít Struktura SQL Vyhledávání Vložit Export Import Úpravy Vyprázdnit Odstranit

Zobrazeny záznamy 0 - 3 (4 celkem, Dotaz zabral 0.0010 sekund)

```
SELECT *
FROM `users`
LIMIT 0 , 30
```

Profilování [ Upravit ] [ Vysvětlit dotaz ] [ Vytvořit PHP kód ] [ Obnovit ]

Zobrazit : 30 řádků začínající od 0 ve vodorovném režimu a opakovat hlavičky po 100 řádcích. Strana číslo: 1

Setřídít podle klíče: Žádná

+ Nastavení

	id	user	passwd	sid	uid	login_time	trans_time	trans_limit	remote_
<input type="checkbox"/>	1	root	2be8b9b78addc5bab742fb3b3d992df	10	4c0a0ce4	1275727076	1275727450	60	81.30.247
<input type="checkbox"/>	2	oplatkova	2190005bdd8dfbe922c48eb87bee5510	10	4c0739db	1275541979	1275542044	60	81.19.3.14
<input type="checkbox"/>	3	david	a7e31fa44e9d13e43ffa3e86e31139c	10	4c096d7d	1275686269	1275686299	60	81.30.247
<input type="checkbox"/>	4	lerch	8bb166833635d75cebc7a31cf629fe03	10	4c07496e	1275545966	1275546039	60	62.180.14

Zaškrtnout vše / Odškrtnout vše Zaškrtnuté:

Zobrazit : 30 řádků začínající od 0 ve vodorovném režimu a opakovat hlavičky po 100 řádcích.

Operace s výsledky dotazu

Náhled pro tisk Náhled pro tisk (s kompletními texty) Export CREATE VIEW

Přidat tento SQL dotaz do oblíbených

Název:   Umožnit všem uživatelům používat tuto položku

Přidat tento SQL dotaz do oblíbených

## PŘÍLOHA P II: ROZHRANÍ PHPMYADMIN – PŘIPRAVENÉ SQL DOTAZY PRO MANIPULACI S DATY

The screenshot shows the phpMyAdmin interface in a Windows Internet Explorer browser. The address bar shows the URL: `http://www.mojefm.cz/phpmyadmin/index.php?db=cnsbp&token=38243812f4293d0c77aae5f263b9736c`. The browser title is "www.mojefm.cz / localhost / cnsbp / mereni | phpMyAdmin 3.2.0.1 - Windows Internet Explorer".

The interface displays the following information:

- Server: localhost
- Databáze: cnsbp
- Tabulka: mereni

The main area shows a SQL query editor with the following query:

```
UPDATE `cnsbp`.`mereni` SET `Operace` = 't' WHERE Datum >= '2009-12-01 00:00:00' AND Datum <= '2009-12-31 23:59:00'
```

A dropdown menu is open over the table name 'mereni', listing the following operations:

- del\_trenovaci\_0912
- del\_trenovaci\_1001
- del\_trenovaci\_1002
- del\_trenovaci\_1003
- del\_trenovaci\_1004
- Počet\_trenovacich
- Počet\_validacnich
- SELECT\_OD\_DO\_Operace
- set\_trenovaci\_0912
- set\_trenovaci\_1001
- set\_trenovaci\_1002
- set\_trenovaci\_1003**
- set\_trenovaci\_1004
- set\_validacni\_0912
- set\_validacni\_1001
- set\_validacni\_1002
- set\_validacni\_1003
- set\_validacni\_1004
- ZRUSIT\_OPERACE
- ZRUSIT\_OPERACE\_VSTUPY

The table structure shows the following columns:

- Id
- Datum
- Hmotnost\_kg
- SiO2
- Al2O3

The interface includes a "Proved" button to execute the query and a "Zobrazuji oblíbený dotaz" notification.



## PŘÍLOHA P III: STRUKTURY TABULEK V DATABÁZI

### **Tabulka MERENI**

```
-- phpMyAdmin SQL Dump
-- version 3.2.0.1
-- http://www.phpmyadmin.net
--
-- Počítač: localhost
-- Vygenerováno: Sobota 05. června 2010, 12:03
-- Verze MySQL: 5.1.37
-- Verze PHP: 5.3.0

SET SQL_MODE="NO_AUTO_VALUE_ON_ZERO";
--
-- Databáze: `cnsbp`
--
-----
--
-- Struktura tabulky `mereni`
--
CREATE TABLE IF NOT EXISTS `mereni` (
  `Id` int(10) unsigned NOT NULL,
  `Datum` datetime NOT NULL,
  `Hmotnost_kg` float unsigned NOT NULL,
  `SiO2` float NOT NULL,
  `Al2O3` float NOT NULL,
  `Fe2O3` float NOT NULL,
  `CaO` float NOT NULL,
  `SO3` float NOT NULL,
  `Silo` tinyint(3) unsigned NOT NULL,
  `MS` float NOT NULL,
  `MA` float NOT NULL,
  `LSF` float NOT NULL,
  `Operace` char(2) COLLATE cp1250_croatian_ci NOT NULL,
  `user` char(15) COLLATE cp1250_croatian_ci NOT NULL,
  KEY `Id` (`Id`,`Datum`)
) ENGINE=MyISAM DEFAULT CHARSET=cp1250 COLLATE=cp1250_croatian_ci;
```

## **Tabulka PREDIKCE**

```
-- phpMyAdmin SQL Dump
-- version 3.2.0.1
-- http://www.phpmyadmin.net
--
-- Počítač: localhost
-- Vygenerováno: Sobota 05. června 2010, 11:51
-- Verze MySQL: 5.1.37
-- Verze PHP: 5.3.0

SET SQL_MODE="NO_AUTO_VALUE_ON_ZERO";
--
-- Databáze: `cnsbp`
--
-- -----
--
-- Struktura tabulky `predikce`
--
CREATE TABLE IF NOT EXISTS `predikce` (
  `datum_zapisu` timestamp NOT NULL DEFAULT CURRENT_TIMESTAMP ON
UPDATE CURRENT_TIMESTAMP COMMENT 'aktuální čas zápisu dat',
  `nsid` varchar(15) COLLATE cp1250_croatian_ci NOT NULL COMMENT
'identifikátor NS',
  `uzivatel` char(15) COLLATE cp1250_croatian_ci NOT NULL COMMENT
'uživatel, který provedl zápis dat',
  `m_SiO2` float NOT NULL COMMENT 'hodnota měření SiO2',
  `m_Al2O3` float NOT NULL COMMENT 'hodnota měření Al2O3',
  `m_Fe2O3` float NOT NULL COMMENT 'hodnota měření Fe2O3',
  `m_CaO` float NOT NULL COMMENT 'hodnota měření CaO',
  `m_SO3` float NOT NULL COMMENT 'hodnota měření SO3',
  `p_SiO2` float NOT NULL COMMENT 'hodnota predikce SiO2',
  `p_Al2O3` float NOT NULL COMMENT 'hodnota predikce Al2O3',
  `p_Fe2O3` float NOT NULL COMMENT 'hodnota predikce Fe2O3',
  `p_CaO` float NOT NULL COMMENT 'hodnota predikce CaO',
  `p_SO3` float NOT NULL COMMENT 'hodnota predikce SO3',
  `tab` char(1) COLLATE cp1250_croatian_ci NOT NULL COMMENT
'hodnota: "A" = použít do historie a grafu',
  KEY `datum_zapisu` (`datum_zapisu`),
  KEY `nsid` (`nsid`)
) ENGINE=MyISAM DEFAULT CHARSET=cp1250 COLLATE=cp1250_croatian_ci;
```

### **Tabulka NSITE**

```
-- phpMyAdmin SQL Dump
-- version 3.2.0.1
-- http://www.phpmyadmin.net
--
-- Počítač: localhost
-- Vygenerováno: Sobota 05. června 2010, 12:00
-- Verze MySQL: 5.1.37
-- Verze PHP: 5.3.0

SET SQL_MODE="NO_AUTO_VALUE_ON_ZERO";
--
-- Databáze: `cnsbp`
--
-- -----
--
-- Struktura tabulky `nsite`
--
CREATE TABLE IF NOT EXISTS `nsite` (
  `Id` varchar(15) CHARACTER SET cp1250 NOT NULL COMMENT
  'identifikace struktury NS',
  `Velicina` varchar(15) CHARACTER SET cp1250 NOT NULL COMMENT
  'veličina struktury NS',
  `Hodnota` float NOT NULL COMMENT 'hodnota veličiny NS',
  `Stav` char(1) COLLATE cp1250_croatian_ci NOT NULL COMMENT 'stav
  veličiny NS',
  KEY `Id` (`Id`)
) ENGINE=MyISAM DEFAULT CHARSET=cp1250 COLLATE=cp1250_croatian_ci;
```

## **Tabulka USER**

```
-- phpMyAdmin SQL Dump
-- phpMyAdmin SQL Dump
-- version 3.2.0.1
-- http://www.phpmyadmin.net
--
-- Počítač: localhost
-- Vygenerováno: Sobota 05. června 2010, 11:37
-- Verze MySQL: 5.1.37
-- Verze PHP: 5.3.0

SET SQL_MODE="NO_AUTO_VALUE_ON_ZERO";
--
-- Databáze: `cnsbp`
--
-- -----
--
-- Struktura tabulky `users`
--
CREATE TABLE IF NOT EXISTS `users` (
  `id` int(11) NOT NULL AUTO_INCREMENT COMMENT 'jednoznačné ID
  uživatele, využívá se při spolupráci aplikace a formulářů na
  straně klienta',
  `user` char(15) COLLATE cp1250_croatian_ci NOT NULL COMMENT
  'identifikace uživatele pro přihlášení do aplikace',
  `passwd` char(100) CHARACTER SET cp1250 COLLATE cp1250_bin NOT
  NULL COMMENT 'heslo uživatele, obsah je zakódovaný MD5 HASH',
  `sid` int(5) NOT NULL COMMENT 'jednoznačná identifikace
  transakce mezi aplikací a konkrétním formulářem na straně
  klienta',
  `uid` char(50) CHARACTER SET cp1250 COLLATE cp1250_bin NOT NULL
  COMMENT 'jednoznačná identifikace uživatele v rámci transakce
  mezi aplikací a konkrétním formulářem na straně klienta',
  `login_time` int(15) NOT NULL COMMENT 'čas přihlášení, využívá
  se při odměřování času poslední transakce a transakčního
  limitu',
  `trans_time` int(15) NOT NULL COMMENT 'čas poslední transakce',
  `trans_limit` int(8) NOT NULL COMMENT 'časový limit transakce',
  `remote_addr` char(18) COLLATE cp1250_croatian_ci NOT NULL
  COMMENT 'IP adresa posledního přihlášení',
  PRIMARY KEY (`id`),
  KEY `user` (`user`)
) ENGINE=MyISAM DEFAULT CHARSET=cp1250 COLLATE=cp1250_croatian_ci
AUTO_INCREMENT=5 ;
```

## PŘÍLOHA P IV: SOUBOR BP\_ANALYZA\_6M2010.XLSX

Pouze elektronicky

## PŘÍLOHA P V: ZDROJOVÉ SOUBORY APLIKACE PCSS

Pouze elektronicky

cnsbp.cfg	konfigurace aplikace PCSS
cnsbp.cgi	výkonný program CGI aplikace PCSS
editdata.js	JavaScript pro obsluhu tlačítka Ovládání dat
fjump.js	JavaScript pro obsluhu průchodů formuláři
grafns.html	předloha HTML formuláře přípravy grafů
grafns.js	JavaScript ovládací funkce pro práci s grafy
hlavahtm.html	předloha hlavičky HTML formuláře
chybags.html	HTML formulář pro oznámení chyby aplikace
kontrola.js	JavaScript pro kontrolu vstupů formuláře pro přihlášení
loginform.html	HTML formulář pro přihlášení do aplikace PCSS
md5.js	JavaScript pro hešování hesla při přihlášení
menuform.html	HTML formulář hlavní nabídky aplikace PCSS
ns555.html	HTML předloha formulářů neuronových sítí
nsstat.html	HTML předloha formuláře neuronové sítě NS-STAT
orderby.css	CSS styly pro HTML formuláře
ovlfce.js	JavaScript funkce pro obsluhu tlačítek HTML formulářů
selfci.js	JavaScript funkce pro obsluhu HTML formulářů NS
styl01.css	CSS styly pro HTML formuláře
styl02.css	CSS styly pro HTML formuláře
styl03.css	CSS styly pro HTML formuláře
styl04.css	CSS styly pro HTML formuláře
tmtns.js	JavaScript funkce pro časové značky CGI transakcí
vysltab.html	HTML předloha formuláře historie výsledku predikce
cnsbp.c	hlavní zdrojový kód aplikace PCSS

cnsbp.h	hlavičkový soubor souboru cnsbp.c
net_bpn.c	zdrojové kódy pro výpočet neuronových sítí 5-5-5, 25-5-5
net_bpn.h	hlavičkový soubor souboru net_bpn.c
sann02.c	zdrojový kód pro výpočet neuronových sítě NS-STAT
sann02.h	hlavičkový soubor souboru sann02.c
util.c	zdrojový kód různých podpůrných funkcí
util.h	hlavičkový soubor souboru util.c