

**Vysoká škola báňská - Technická univerzita Ostrava**  
Fakulta metalurgie a materiálového inženýrství  
Katedra automatizace a počítačové techniky v metalurgii

Název disertační práce:

***Využití umělých neuronových sítí při predikci  
chemického složení rafinační strusky***

Student: Ing. Pavel Švec  
Studijní program: Řízení průmyslových systémů  
Vedoucí disertační práce: prof. Ing. Zora Jančíková, CSc.  
Rok: 2010

**Poděkování:**

Zde bych velice rád poděkoval své školitelce paní prof. Ing. Zoře Jančíkové, CSc. za její vynikající vedení, velkorysou vstřícnost a předání zkušeností z oblasti problematiky umělých neuronových sítí, v průběhu zpracování předložené disertační práce. Dále bych rád poděkoval všem spolupracovníkům z Katedry automatizace a počítačové techniky v metalurgii za jejich ochotu a pomoc při mém studiu. A považuji za nutné, také poděkovat celé mé rodině, která mi byla velkou oporou při celém průběhu doktorského studia.

## ANOTACE

ŠVEC, P. *Využití umělých neuronových sítí při predikci chemického složení rafinační strusky*. Disertační práce, Ostrava: VŠB – TU Ostrava, 2010, 90 s.

Předložená disertační práce se zabývá predikcí chemického složení rafinačních strusek. K predikci bylo využito umělých neuronových sítí. Z výsledných umělých neuronových sítí byl sestaven predikční model, který byl vložen do uživatelského programu. Práce využívala provozní data provozu pánvové pece v ArcelorMittal Ostrava, a.s. Teoretická část práce popisuje technologický proces výroby oceli a základní poznatky o problematice umělých neuronových sítí. V praktické části byly navrženy a ověřeny jednotlivé varianty umělých neuronových sítí a byly porovnány jejich výsledky predikce. Byl sestaven funkční model pro predikci chemického složení rafinačních strusek, který byl začleněn do uživatelského programu.

**Klíčová slova: umělé neuronové sítě, predikce, model, program, struska.**

## ANNOTATION

ŠVEC, P. *Artificial neural networks in predicting the chemical composition of the refining slag*. Ph.D. thesis, Ostrava: VŠB - TU Ostrava, 2010, 90 p.

This dissertation deals with predictions of chemical composition of the refining slag. Artificial neural networks were used for prediction. The prediction model was created by artificial neural network. This prediction model is presented in user program environment. The operational data of ladle furnace in ArcelorMittal Ostrava, a.s. were used in this work. Theoretical part of the work describes technological process of steel production and the basic knowledge about artificial neural networks problems. In the practical part particular variants of neural network were designed and their prediction results were compared. A functional model for prediction of chemical composition of the refining slag, which was included to the user program, was created.

**Keywords: artificial neural networks, prediction, model, program, slag.**

## Seznam použitého značení:

TP	tandemová pec
ZPO	zařízení plynulého odlévání
hm. %	hmotnostní procenta
$x_i$	vstupy do umělého neuronu
$y_i$	výstupy do umělého neuronu
$w_i$	synaptická váha
h	prahová hodnota umělého neuronu
z	vnitřní potenciál umělého neuronu
$\sigma$	aktivační funkce umělého neuronu
$\Theta$	práh umělého neuronu
$\oplus$	konfluence umělého neuronu
u	agregační funkce umělého neuronu
G	operátor agregace umělého neuronu
$\mathbf{x}^p$	vektor vstupu umělé neuronové sítě
$\mathbf{y}^p$	vektor požadovaných výstupních hodnot umělé neuronové sítě
T	transformace vstupních hodnot na výstupní
P	trenovací množina umělé neuronové sítě
P	počet vzorů trenovací množiny
E	energetická chybová funkce
$\eta$	koeficient učení umělé neuronové sítě
RMS	predikční chyba umělé neuronové sítě [hm. %]
REL_RMS	relativní predikční chyba umělé neuronové sítě [%]
PRUM_RSO	průměrná relativní odchylka umělé neuronové sítě [%]
PRUM_RPRVS	průměrný rozdíl predikované a reálné výstupní chemické složky [hm. %]
$y_i$	predikovaný výstup z umělé neuronové sítě [hm. %]
$o_i$	reálná hodnota výstupu chemické složky [hm. %]
n	počet vzorů pro testování
A3	Al drát [kg]
A5	Al granulát [kg]
A9	Alcaten [kg]

S5	FeSi [kg]
CS	plněný profil CaSi [kg]
Vb	vápno [kg]

## Obsah

1	Úvod.....	1
1.1	Cíle disertační práce.....	3
2	Technologický proces výroby oceli.....	4
2.1	Primární metalurgie - tandemové pece.....	4
2.1.1	Konstrukce tandemové pece.....	7
2.2	Mimopecní zpracování ocelí (sekundární metalurgie).....	9
2.3	Pánvová pec.....	10
2.3.1	Popis pánvové pece.....	10
2.3.2	Postup zpracování ocelí v pánvové peci.....	11
2.3.3	Technologické postupy zpracování ocelí v pánvové peci.....	11
2.4	Struska.....	12
2.4.1	Rafinační strusky v pánvové peci.....	13
2.4.2	Zařízení pro plynulé odlévání oceli.....	15
2.5	Pánvová pec a zařízení plynulého lití v ArcelorMittal Ostrava, a.s.....	17
3	Modelování chemického složení strusek.....	19
3.1	Modelování.....	19
3.2	Matematický model neuronu.....	19
3.2.1	Aktivační funkce neuronu.....	23
3.3	Umělá neuronová síť.....	25
3.3.1	Topologie umělé neuronové sítě – organizační dynamika.....	26
3.3.2	Druhy sítí.....	28
3.3.3	Učení s učitelem.....	29
3.3.4	Učení bez učitele.....	34
3.4	Predikční chyby umělých neuronových sítí.....	34
3.5	Tvorba umělých neuronových sítí v disertační práci.....	36
4	Tvorba predikčního modelu pomocí umělých neuronových sítí.....	37
4.1	Postup práce.....	37
4.2	Úprava dat.....	39
4.3	Tvorba umělých neuronových sítí.....	41
4.4	Popis a vyhodnocení jednotlivých variant.....	43
4.4.1	Zkušební varianta.....	43
4.4.2	První varianta.....	45

4.4.3	Druhá varianta.....	49
4.4.4	Třetí varianta.....	54
4.4.5	Čtvrtá varianta.....	59
4.4.6	Pátá varianta.....	63
4.4.7	Šestá varianta .....	68
4.5	Výsledný model predikce rafinační strusky.....	73
4.5.1	Řešení predikčního modelu jedinou umělou neuronovou sítí .....	73
4.5.2	Řešení predikčního modelu soustavou umělých neuronových sítí.....	74
5	Uživatelský program pro prezentování modelů predikcí rafinační strusky.....	76
5.1	Vývoj uživatelského programu .....	76
5.2	Tvorba uživatelského programu pro disertační práci.....	78
5.3	Vývoj testovací a finální verze uživatelského programu .....	79
6	Závěr .....	84
7	Použitá literatura .....	87
8	Seznam publikací doktoranda .....	89

## 1 Úvod

V dnešní době je kladen hlavní důraz na kvalitu finálních produktů, zejména pak v metalurgii, kde hlavním výstupem je ocel. Ta musí mít určité fyzikální vlastnosti, kterým odpovídá správný poměr chemických látek v oceli. V současné době se to dosahuje tak, že se provádí chemické rozbory oceli během jejího zpracování a podle toho se určují další legující přísady tak, abychom dostali požadované složení oceli a tím dosáhli požadovaných vlastností.

Cílem disertační práce je navržení a ověření funkčního modelu pro predikci chemického složení rafinační strusky. Struskový řád na pánvové peci má zásadní význam pro homogenitu chemického složení oceli a její čistotu. Pokud struska udrží správné termodynamické a kinetické podmínky, tak se do strusky absorbuje optimální množství struskotvorných látek a vměsků vyplouvajících z oceli. Nevytvoří-li struska svým chemickým složením vhodné termodynamické podmínky a nejsou-li zajištěny dostatečné kinetické podmínky k promísení rafinační strusky s kovem (například argonováním), může negativně ovlivnit výslednou čistotu a odsíření oceli.

V současné době se osádky pánvové pece ve svém rozhodování řídí znalostí chemického složení příjezdových strusek, pokud jsou k dispozici. Na základě zkušeností s příslušnou značkou oceli, požadavků na odsíření oceli a charakteru a množství příjezdové pecní strusky jsou přidávána množství struskotvorných přísad a granulovaného hliníku. Granulovaný hliník slouží zejména k redukci lehce redukovatelných oxidů ( $\text{FeO}$ ,  $\text{MnO}$ ,  $\text{Fe}_2\text{O}_3$ ,  $\text{P}_2\text{O}_5$ ,  $\text{Cr}_2\text{O}_3$  atd.) a jeho přidávané množství je odvislé od jejich celkových obsahů a množství vyteklé pecní strusky z tavicího agregátu – tandemové pece. V případě tandemového procesu totiž dochází k poměrně značnému výtoku oxidické pecní strusky do odlévací pánve, kterou je nutno na počátku rafinačního procesu v pánvové peci redukovat a vytvořit tak příznivé termodynamické podmínky pro odsíření oceli. Veškeré přídavky tedy závisí na zkušenosti osádek, čili na lidském faktoru.

K vyloučení lidského faktoru je nutno vytvořit řídicí model, který by dokázal určit chemické složení strusky podle předem určených přísad. Takový řídicí model musí postihnout všechny děje, které se odehrávají při výrobě oceli a správně je zkombinovat



mezi sebou. To je poměrně náročné, neboť některé děje neumíme úplně popsat. Model musí správně reagovat na změnu hodnot legujících přísad. Jednou z možností je užití regresních modelů, které určí, jak bude vypadat chemické složení při znalosti vstupních údajů. Aby regresní model co nejpřesněji předpovídal reálné hodnoty, je nutné správně určit typy funkcí použitých v regresním modelu.

Druhou možností je tvorba modelů předpovědi chemického složení s využitím metod umělé inteligence. Pomocí umělých neuronových sítí můžeme vhodně modelovat chování složitých soustav. Hlavní vlastností umělých neuronových sítí je schopnost učení se na naměřených datech a schopnost zevšeobecňování. Díky své vnitřní struktuře jsou umělé neuronové sítě vhodné pro modelování a řízení složitých nelineárních systémů.

Umělé neuronové sítě nepopisují klasické fyzikální a chemické děje v procesu výroby oceli, ale jsou schopny modelovat chování systémů s velmi složitou vnitřní strukturou a s poměrně komplikovanými vnějšími projevy, kdy analytický popis je značně složitý, případně vůbec neexistuje. Vytvořeny neuronový predikční model pak umožňuje získat informaci, kolik legujících přísad se má přidat, abychom dosáhli požadované kvality strusky.

## 1.1 Cíle disertační práce

Cíle disertační práce vychází z výše uvedeného hodnocení současné situace v dané problematice. Hlavním cílem disertační práce je vytvořit predikční model, který predikuje chemické složení rafinačních strusek pomocí umělých neuronových sítí. Tento predikční model by vedl k úspoře struskotvorných přísad, snížení počtu analytických stanovení a v konečném důsledku k zefektivnění výroby oceli.

Jednotlivé cíle práce jsou uvedeny v následujících bodech:


- Předzpracování vstupních dat získaných z ArcelorMittal Ostrava, a.s.
- Vytvoření umělých neuronových sítí pro predikci chemického složení rafinačnickv strusek pomocí programu STATISTICA Neuronové sítě.
- Vytvoření uživatelského programu pro predikci chemického složení rafinačních strusek pomocí jazyku C++.
- Ověření predikčních schopností navržených umělých neuronových sítí a výběr nejvhodnějšího predikčního modelu.

## 2 Technologický proces výroby oceli

Ocel se vyrábí ve dvou krocích:

- primární metalurgie (výroba oceli v konvertorech, tandemových a elektrických pecích)
- sekundární metalurgie (úprava ocelí na požadovanou kvalitu)

Technologický proces výroby oceli ve společnosti ArcelorMittal Ostrava, a.s., kde byla disertační práce zpracovávána, je znázorněn na obrázku 2.1. Její primární část je zastoupena čtyřmi tandemovými pecemi a sekundární metalurgie pánvovými pecemi s obloukovým ohřevem (mimopecní rafinací). Po zpracování na pánvové peci se ocel odlévá na zařízení plynulého lití, zde konkrétně na ZPO1.




Obrázek 2.1: Technologický proces výroby, mimopecního zpracování a odlévání oceli ve společnosti ArcelorMittal Ostrava, a.s.

### 2.1 Primární metalurgie - tandemové pece

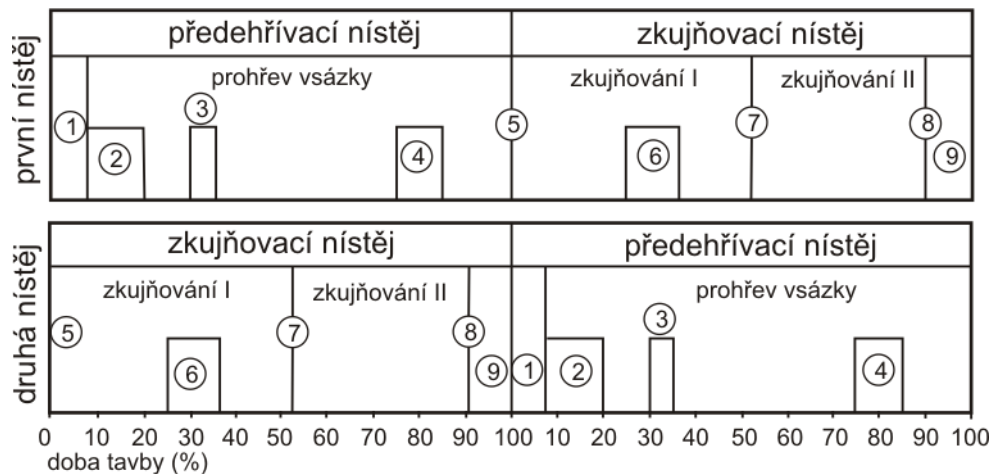
Jak vyplývá z názvu tandemového pochodu výroby oceli, jedná se o typ dvounístežové pece (obrázek 2.2), kde v jedné nísteži probíhají pochody typické pro kyslíkový proces výroby oceli a v druhé nísteži pochody tepelně energetické, jako je

spalování odpadních plynů a sdílení tepla, jejichž cílem je co nejvíce prohřát pevnou vsázku. Proto musí být tandemová pec konstrukčně řešena tak, aby účinně plnila úlohy jak metalurgické, tak tepelně energetické. Těmto úkolům musí být podřízeno i optimální řešení potřebných obslužných zařízení. [19]



Obrázek 2.2: Princip tandemového pochodu

Po každém odpichu se funkce obou nístějí vymění a tím se zkracuje doba do dalšího odpichu oceli.



Obrázek 2.3: Harmonogram tandemového pochodu

Jednotlivé operace znázorněné na obrázku 2.3 mají tento význam [16]:

**1** Prohlídka pece.

Po každé tavbě je nezbytné prohlédnout nístěj. Výsledkem prohlídky je rozhodnutí, zda je možno pokračovat v cyklování funkce nístějí bez mezitavbové opravy.

**2** Sázení ocelového odpadu.

Po prohlídce pece následuje období sázení pevné vsázky. U 200 tunové pece se obvykle vsazují dvě velkoobjemové bedny, každá obsahuje kolem 28 tun pevné kovonosné vsázky. Zbytek ocelového odpadu se přisazuje pomocí tzv. korýtek. Celkové množství pevné kovonosné vsázky tvoří cca 1/3 z celkového množství kovové vsázky.

**3** Sázení vápna.

Pro zajištění rychlé tvorby primární strusky je nutno první dávku vápna použít již do vsázky. Z organizačních důvodů se obvykle sázení vápna provádí okamžitě po nasázení ocelového odpadu. Množství vápna do vsázky se určuje podle obsahu křemíku v surovém železe. Pohybuje se od 4 tun (při obsahu křemíku pod 0,5 hm. %) do 8 tun (při obsahu křemíku nad 1,0 hm. %). Kvůli ochraně bazické vyzdívky v nístějích se dnes používá dolomitické vápno.

**4** Nalévání surového železa.

Celkové množství tekutého surového železa se pohybuje kolem 150 až 155 tun. Nalévání nemá začít dříve než při odběru první zkoušky na vedlejší nístěji, a to proto, aby byl zajištěn dostatečný prohřev pevné vsázky. Avšak nalití surového železa má být ukončeno před začátkem odpichu na vedlejší nístěji, aby nevznikly prostoje. Údobí mezi operací 3 a 4 se nazývá prohřev vsázky.

**5** Začátek dmýchání kyslíku.

Před touto operací je nutno zavést zkujňovací trysky do pracovní polohy. Kyslík se začíná dmýchat nejdříve při začátku odpichu na vedlejší nístěji.

**6** Stahování pěnivé strusky.

Údobí mezi operací 5 a 6 se nazývá první část zkujňování I.

### **7 Odběr prvního zkušební vzorku.**

Odebírá se vzorek kovu, u vybraných jakostí i vzorek strusky a změří se teplota roztavené lázně. Údobí mezi operacemi 6 a 7 se nazývá druhá část zkujňování I a údobí mezi operacemi 5 a 7 je označováno jako zkujňování I.

### **8 Odběr posledního zkušební vzorku.**

Provádí se po ukončení zkujňování, při předpokládaném odpichovém obsahu uhlíku a předpokládané odpichové teplotě a po splnění podmínky dostatečně nízkých obsahů fosforu a síry. Odebírá se vzorek kovu, vzorek strusky a měří se teplota lázně. Údobí mezi operacemi 7 a 8 se nazývá zkujňování II.

### **9 Odpich.**


Po obdržení informací o teplotě kovu a obsahu uhlíku a při jistotě, že obsah síry a fosforu bude odpovídat požadavkům vyráběné jakosti oceli, lze přistoupit k odpichu kovu z pece do odlévací pánve. Údobí mezi operacemi 8 a 9 se nazývá úprava kovové lázně, popř. strusky. V tomto údobí se např. vnáší do pece legovací a dezoxidační přísady u jakostí, které vyžadují značná množství těchto přísad. Zbývající dávka se pak přisazuje do pánve. Po každém odpichu je nutné provést reverzaci uzavíracích zařízení odtahových traktů. Po reverzaci se změni směr proudění spalin a ze zkujňovací nístěje se stává nístěj přehřívací.

## **2.1.1 Konstrukce tandemové pece**

Z obrázku 2.4 vyplývá, že obě nístěje jsou geometricky a konstrukčně shodné. V jedné z nich probíhá zkujňování lázně technicky čistým kyslíkem. Pro přívod kyslíku do lázně slouží zkujňovací trysky. Vznikající plynné zplodiny zkujňování, bohaté na CO, s teplotou kolem 1500 °C se převádějí ze zkujňovací nístěje do přehřívací nístěje. K tomuto účelu slouží převáděcí kanál. Ke spalování CO v přehřívací nístěji je nutno přivést oxidační médium, a to kyslík či směs kyslíku a vzduchu. Proto jsou zde zabudovány dospalovací trysky. Jelikož funkce nístějí se periodicky mění, musí být zkujňovacími i dospalovacími tryskami vybaveny obě nístěje. [16], [18], [19]


Spaliny z přehřívací nístěje vstupují do odtahového traktu. Ten musí být vybaven uzavíracím zařízením, které se po tabbě střídavě otevírají a uzavírají a určuje

směr proudění spalin podle toho, která z nístějí je předehřívací. U odtahových šachtic je umístěna strusková komora k zachování větších částic strhávané strusky a prachu změnou směru a rychlosti proudění plynů. Rovněž se zde používá chlazení plynů vodní sprchou ke snížení teploty spalin pod bod výbušnosti, obvykle pod 500°C. Jelikož odpadní plyny jsou značně znečištěny prachem, což je typické pro všechny kyslíkové pochody výroby oceli, je dalším důležitým uzlem čistírna plynů. [16], [18], [19]



- 1 - tandemová pec,
- 2 - zkujňovací tryska,
- 3 - dospalovací tryska,
- 4 - převáděcí kanál,
- 5 - odtahová šachtice,
- 6 - mechanické sklápěcí zařízení,
- 7 - přívod a odvod chladicí vody,
- 8 - hutní úroveň ± 0 m

Obrázek 2.4: Schématické znázornění tandemové pece – podélný řez [18]



- 1 - tandemová pec,
- 2 - sázecí otvor,
- 3 - velkoobjemová sázecí nádoba,
- 4 - odpichový otvor,
- 5 - dospalovací tryska,
- 6 - jeřábové dráhy,
- 7 - sklápěcí mechanismus s elektrickým pohonem,
- 8 - hydraulický válec pro zvedání pece na úroveň pecní plošiny + 8,5 m

Obrázek 2.5: Schématické znázornění tandemové pece – příčný řez [18]

Vlastní pec tvoří nístěj (obrázek 2.5), dále pak stěny a klenba, které jsou zpravidla sestaveny z panelů pro rychlou výměnu vyzdívky. V přední stěně jsou sázecí otvory, jeden pro každou nístěj. Tyto otvory jsou zakryty pohyblivými dvířky. Při stanovení rozměrů nístěje bylo nutno brát ohled na tepelnou práci pece. Užitečné teplo tandemové pochodu, a tím i podíl odpadu je za daného složení a teploty surového železa

tím vyšší, čím menší jsou tepelné ztráty stěnami obou nístějí. V zadní stěně tandemové pece je umístěn odpichový otvor. [16], [18], [19]

## 2.2 Mimopecní zpracování ocelí (sekundární metalurgie)

Mimopecní zpracování ocelí (označované jako pánvová metalurgie, sekundární metalurgie) plní dnes funkci spojovacího článku mezi výrobním agregátem – tandemovými pecemi a odléváním tekuté oceli na ZPO (zařízení plynulého odlévání) s vysokými požadavky na exaktnost vstupů. Tato úprava oceli se vyvinula jako odezva na stále rostoucí požadavky na jakost oceli a vedla k podstatnému růstu produktivity přesunem dezoxidace a legování při metalurgickém rafinačním procesu mimo tavící agregát (primární metalurgii). [12], [13]

Lze konstatovat, že bez mimopecní metalurgie lze obtížně dodržet potřebnou jakost, tj. zejména čistotu a homogenitu oceli. Obsah a záměry mimopecní metalurgie jsou podstatně širší, než je zde naznačeno. Homogenizaci a korekci chemického složení oceli i rafinační strusky lze ovšem považovat za obecný a společný rys všech postupů mimopecního zpracování oceli, které jsou při plynulém zpracování oceli základní kvalitativní podmínkou. [12], [13]

Hlavní úkoly sekundární metalurgie jsou následující:

- míchání a homogenizace,
- úprava chemického složení v mezích analytické tolerance,
- úprava teploty pro následný proces odlévání,
- odkysličení,
- odstranění nežádoucích plynů jako jsou vodík a dusík,
- zlepšení čistoty oxidace oddělením nekovových příměsí.


Tyto pochody probíhají v pánvové peci nebo v pánvi ve vakuu nebo v účelově konstruovaných pecích. V našem případě se jedná o pánvovou pec.



## 2.3 Pánvová pec

### 2.3.1 Popis pánvové pece

Pánvová pec (obrázek 2.6) je zařízení, kde je elektrickým obloukem ohřívána ocel v lící pánvi pod syntetickou struskou. Lící pánev s bazickou vyzdívkou je uložena na převážejícím pánvovém voze. Vůz s tekutou ocelí v lící pánvi zajede pod víko pánvové pece. [16]



Obrázek 2.6: Schéma pánvové pece [16]

Vodou chlazené víko se spustí na pánev. Ocel v lící pánvi je prodmychávána inertním plynem ( $\text{Ar}$ ,  $\text{N}_2$ ) v množství 1 - 5 l/min.t, který je foukán porézní tvárnici ve dně lící pánve. [16]

Ocel v lící pánvi je ohřívána elektrickým obloukem, který hoří mezi třemi grafitovými elektrodami a hladinou oceli. Elektrody mají průměr 300 mm. K dosažení potřebného proudu a napětí slouží pecní transformátor o výkonu 10 MVA. [16]

Pro úpravu chemického složení oceli v pánvi je pánvová pec vybavena osmi zásobníky legujících přísad ( $\text{FeMn}$ , granulovaný  $\text{Al}$ ,  $\text{CaO}$  ve formě briket, Alcaten – ředicí přísada na bázi  $\text{Al}_2\text{O}_3$ ,  $\text{FeTi}$ ,  $\text{FeSi}$ ,  $\text{FeCr}$ ,  $\text{C}$  ve formě kalcinovaného smolného koksu). Přísady jsou do pánve podávány mechanicky. Dávkování jednotlivých přísad provádí obsluha pánvové pece ve velínu dle předepsaných technologických postupů

(směrnic) a dále pak koriguje obsah přísad podle výsledků chemického složení oceli a strusky při oděru vzorků. [16]

### 2.3.2 Postup zpracování ocelí v pánvové peci

Po spuštění víka na pánev se nejdříve provede ohřev strusky elektrickým obloukem, přičemž na základě obsahů FeO a dalších lehce redukovatelných prvků (MnO, Fe<sub>2</sub>O<sub>3</sub>, P<sub>2</sub>O<sub>5</sub>, Cr<sub>2</sub>O<sub>3</sub> apod.), se přidává potřebné množství granulovaného hliníku za účelem jejich redukce. Následují přídavky vápenných briket a ředící přísady Alcaten v požadovaném množství s cílem zajistit dostatečné množství bazické a tekuté rafinační strusky. Přitom grafitovými elektrodami ponořenými ve strusce se ocel ohřívá za současného dmýchání argonu dnem pánve. Během procesu se odebírají vzorky oceli a strusky a analyzuje se jejich chemické složení, měří se rovněž teplota oceli a aktivita kyslíku v oceli. V závěru rafinace se provádí úprava tvaru vměstků vstřelováním CaSi nebo CaFe drátu s následným čerčením oceli. Proces obvykle končí zahuštěním rafinační strusky vápennými briketami pro snížení tepelných ztrát při přepravě a při odlévání. Posléze se odlévací pánev dopraví na lící stojan zařízení plynulého odlévání oceli, kde probíhá lití. [16]

### 2.3.3 Technologické postupy zpracování ocelí v pánvové peci

*Ohřev taveniny spojený s legováním a desoxidací lázně [16]:*

- provádí se s menším množstvím strusky s hlavním cílem dosáhnout optimální lící teplotu. Uplatňuje se hlavně v případech kombinovaného zpracování tekuté oceli v pánvi.
- Ohřev s rafinací oceli zahrnující rafinační působení strusky na taveninu, tj. zejména odsíření oceli. Současně s tím se provádí i legování a desoxidace taveniny. Používá se větší množství syntetické strusky, které závisí na požadavku na odsíření.

*Dosažené stavy v pánvové peci [16]:*

- zvýšení teploty taveniny a regulace lící teploty v úzkém rozmezí,
- rafinace taveniny působením syntetické strusky, zejména snížení obsahu síry, kyslíku a nekovových vměstků,
- zvýšení výrobnosti ocelářských pecí převedením využitím rafinace, legování a dezoxidace oceli do pánve.

## 2.4 Struska

Téměř všechny ocelářské pochody probíhají za aktivní účasti strusky, která má nejen pokrývat souvislou vrstvou kovovou lázeň, ale také vázat zplodiny rafinačních reakcí, tzv. vměstky a vytvářet optimální podmínky pro přenos tepla a zajišťovat potřebný zdroj kyslíku. Ocelářské strusky z fyzikálně–chemického hlediska představují vícesložkovou určitou strukturu. Chemické složení a teplota podstatně ovlivňují jejich strukturu, na které závisí řada fyzikálních vlastností např. viskozita, povrchové a mezifázové napětí, hustota aj. Z chemických vlastností závisí na uvedených faktorech zejména rafinační působení na kov z hlediska odstraňování nežádoucích složek (síra, fosfor, kyslík) z oceli a korozního působení na keramické vyzdívky pecí. Složení a množství strusky má dále vliv na spotřebu dezoxidovadel, obsahu železa ve strusce, výtěžek oceli, spotřebu žáruvzdorného materiálu a délku tavby. [10], [11], [12]

Ocelářské strusky dělíme na kyselé a zásadité. Tyto dvě skupiny strusek se od sebe velmi odlišují, a to nejen chemickým složením, ale i fyzikálními vlastnostmi.

Zásadité strusky – přechází z vyzdívky především CaO a MgO


Kyselé strusky – přechází z vyzdívky především SiO<sub>2</sub>

Tyto přechody z vyzdívky do ocelářské strusky mají negativní vliv na životnost vyzdívek, proto se musí přidávat do vsázky příslušných taveb struskotvorné přísady, aby se tento proces podstatně zpomalil, a tím se snížil stupeň opotřebení vyzdívek. U zásaditých strusek je to vápenec a vápno a u kyselých strusek je to křemičitý písek. [10], [11], [12]

Disertační práce se bude zabývat rafinační struskou v pánvové peci, která je silně bazická (zásaditá).

### 2.4.1 Rafinační strusky v pánvové peci

Rafinační strusky v pánvové peci mají rozhodující význam pro mimopecní zpracování oceli. Čistota oceli a obsah síry ve vyráběné oceli závisí především na chemickém složení rafinačních strusek, jejich množství a na kinetice promísení strusky s kovem. Důležitým faktorem je samozřejmě doba zpracování oceli.



Obrázek 2.7: Ternární diagram CaO-Al<sub>2</sub>O<sub>3</sub>-SiO<sub>2</sub> [1]

Rafinační strusky jsou bazické, mají redukční charakter a jejich hlavními složkami jsou následující oxidy: CaO, Al<sub>2</sub>O<sub>3</sub>, SiO<sub>2</sub> a MgO. Jelikož množství MgO pochází vesměs z vyzdívek odlévacích pánví (pokud nejsou používána dolomitická vápna), závisí jeho obsah zejména od opotřebení vyzdívek, přičemž se pohybuje v rafinačních struskách převážně v rozmezí 7 až 10 hm. %. Zásadním požadavkem pro dobré odsíření oceli jsou co nejnižší obsahy lehce redukovatelných oxidů, tj. zejména

FeO, Fe<sub>2</sub>O<sub>3</sub>, MnO, P<sub>2</sub>O<sub>5</sub>, Cr<sub>2</sub>O<sub>3</sub>, apod. Jejich sumární obsah by neměl přesahovat 4 hm. %.


Chemické složení strusek má zásadní vliv na teploty likvidu, a tudíž na rychlost jejich tvorby a tekutost. Toto je zřejmé z ternárního diagramu CaO-Al<sub>2</sub>O<sub>3</sub>-SiO<sub>2</sub> – viz obrázek č. 2.7.

V průběhu zpracování oceli na pánvové peci na ocelárně společnosti ArcelorMittal Ostrava, a.s. jsou přidávány základní dvě struskotvorné přísady, a to vápenné brikety a ředící přísada na bázi Al<sub>2</sub>O<sub>3</sub> (Alcaten). Tímto způsobem je prováděna úprava chemického složení, případně množství rafinační strusky. Obsahy SiO<sub>2</sub> ve strusce jsou závislé hlavně na složení oceli a vnosech z jednotlivých dezoxidačních, legujících a struskotvorných přísad.

Doposud jsou množství struskotvorných přísad přidávána na základě znalostí chemického složení tzv. příjezdových strusek na pánvovou pec, resp. znalosti složení strusek odebraných po odpichu z odlévací pánve. Tyto jsou ovšem často heterogenní, což mnohdy vede ke zkreslenému rozhodnutí o množstvích přidávaných struskotvorných přísad. Pro posouzení optimálních přídavek uvedených přísad byly u konečných (odjezdových) strusek z pánvové pece stanovovány obsahy tzv. „volného“ vápna a porovnávány měrné spotřeby vápenných briket na shodné poklesy síry v rafinované oceli za srovnatelných podmínek a u stejných značek oceli. Rozbor ukázal, že poměrně dost taveb má určitý podíl nezreagovaného (volného) vápna, což svědčí o nadbytečném množství přísazovaného vápna. Rovněž odchylky v měrných spotřebách vápna na odstranění 0,001 hm. % síry z oceli ukázaly, že existují rezervy v odhadovaných množstvích, zejména struskotvorných přísad. To byl jeden z důvodů, který vedl k rozhodnutí posoudit možnosti aplikace umělých neuronových sítí pro predikci chemického složení rafinačních strusek, což by ve svém důsledku vedlo k úspoře struskotvorných přísad a počtu analytických stanovení.

## 2.4.2 Zařízení pro plynulé odlévání oceli

Při plynulém odlévání (obrázek 2.8) se ocel odlévá z pánve přes mezipánev do vodou chlazeného krystalizátoru, který slouží jako kokila. V krystalizátoru ztuhne povrchová vrstva oceli. Na výstupu krystalizátoru je teplota předlitku kolem 1200 °C a jádro předlitku je ještě tekuté. Dále postupuje předlitek do oblasti sekundárního ochlazování, kde se pomocí trysek přivádí na povrch předlitku voda v podobě jemné mlhy. Pohyb předlitku je zajištěn tažnými válečky. Jakmile je předlitek ztuhlý v celém průřezu, rozřezává se na kusy o požadované délce pomocí kyslíko-acetylenového řezacího hořáku. Ten se synchronizovaně pohybuje spolu s předlitkem a po odřezání se vrací do výchozí polohy. Rozřezané předlitky se dále dopravují výklopníkem, dopravními válečky a výtahem k místu dalšího zpracování, např. válcování. [16], [17]

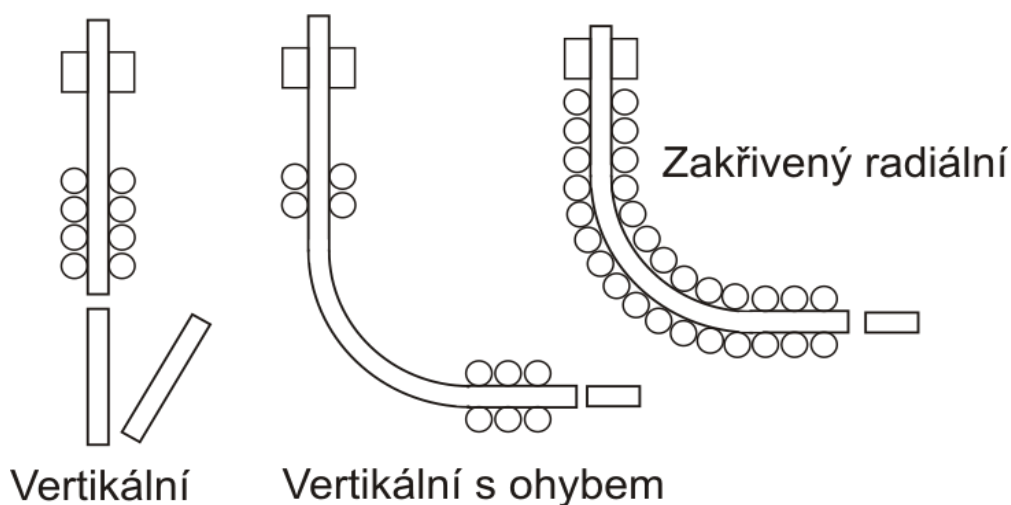


Obrázek 2.8: Schéma zařízení plynulého odlévání [17]

Plynulé odlévání nabízí několik významných přínosů [16]:

- úspory energie, nižší emise a menší potřebu vody následkem eliminace válcování bran a sochorových tratí,
- zlepšené pracovní podmínky,
- vysoké podíly výtěžnosti, větší než 95 %,
- vysokou produktivitu.

Existují rozličné typy strojů (obrázek 2.9) na kontinuální odlévání, označované jako vertikální typ, ohýbací a rovnací typy, obloukový typ a stroje typu oválného prohnutí, a to v závislosti na jejich uspořádání.




Obrázek 2.9: Typy odlévání ZPO

Krystalizátory jsou na zařízení pro plynulé odlévání základními technologickými součástmi. Jsou vyráběny ze slitin mědi nebo z elektrolytické mědi o vysoké čistotě.

Krystalizátor splňuje tyto funkce [16]:

- stabilitu lití
- odvod tepla z tuhnoucí oceli a tím i tvorbu utuhlé kůry
- rychlost lití a rychlost tažení předlitku



Obrázek 2.10: Chlazení oceli

Chlazení oceli (obrázek 2.10) probíhá ve třech stupních. Primární oblast chlazení zahrnuje chlazení oceli v krystalizátoru, který je intenzivně chlazen vodou. Odvádí se

10 až 30 % veškerého tepla vznikajícího v předlitku. V důsledku intenzivního odvodu tepla se postupně vytvoří kůra utuhlé oceli, která má snahu se smršťovat a tím vytvářet mezeru mezi povrchem předlitku a stěnami krystalizátoru. Dosáhne-li kůra dostatečné tloušťky a pevnosti, předlitek vystoupí z krystalizátoru do sekundární oblasti chlazení, kde lze intenzitu chlazení zvýšit přímým odstříkáváním povrchu předlitku chladicí vodou z trysek, umístěných v bezprostřední blízkosti. V terciální oblasti chlazení je prakticky ukončen přímý nástřik vody nebo vodovzdušné směsi na povrch předlitku a chlazení se dále realizuje vlivem okolní atmosféry. Teplo obsažené v předlitku je tedy odváděno do okolního vzduchu převážně sáláním, v menší míře přirozenou konvekcí a také vedením do vodících, tažných, rovnacích válců a chladícího lože. [16]

## **2.5 Pánvová pec a zařízení plynulého lití v ArcelorMittal Ostrava, a.s.**

Provozní zobrazení pánvové pece č. 1 na ocelárně společnosti ArcelorMittal Ostrava, a.s., kde probíhaly provozní experimenty popsané v disertační práci, je zřejmé z obrázku 2.12. Pánvová pec je tvořena víkem s třemi elektrodami, odsávacím a filtračním zařízením, zavážecím systémem legujících, struskotvorných přísad a ředidel, manipulátorem pro měření teploty, aktivity kyslíku a odběr vzorků, vstřelovacím zařízením pro podávání hliníkového drátu a plněných profilů, systémem pro dmýchání inertního plynu - argonu do dna pánve, havarijní argonovací tryskou pro dmýchání argonu do licí pánve vrchem a převážecím vozem. Úkolem pánvové pece je připravit tavbu (chemická a teplotní homogenita) na ZPO s cílem zajistit odlévatelnost dané značky oceli.

Po zpracování oceli na pánvové peci č. 1, následuje odlévání na zařízení ZPO 1 – viz obrázek č. 2.11, zde je zobrazeno provozní zařízení kontinuálního odlévání oceli. Po otevření licí pánve začíná plnění mezipánve, která slouží jako zásobník tekuté oceli a pro její rozvod do šesti licích proudů. Po naplnění mezipánve a otevření výtokových uzlů proudů je kontislitek vytahován pomocí tažných a rovnacích stolic za současného intenzivního vodního chlazení.





Obrázek 2.11: ZPO č.1



Obrázek 2.12: Provozní zobrazení  
pánvové pece č.1

### 3 Modelování chemického složení strusek

#### 3.1 Modelování

Modelování je proces tvorby modelů, v němž se v konvekčních přístupech využívá matematicko-fyzikální analýza i experimenty. Model je definován jako zobrazení existujících stránek reálného systému. Identifikace je pak proces ztotožnění modelu s objektem.

Identifikace a modelování jsou procesy, které se prolínají. Strukturu modelu odhadneme pomocí matematicko-fyzikální analýzy a vhodně volenými experimenty odhadujeme metodami identifikace hodnoty parametrů systému. Cílem modelování a identifikace je vytvořit takový model systému, jehož chování by se co nejlépe shodovalo s reálným systémem za stejných provozních podmínek. [2]

Základním modelem při modelování jsou modely konvenční. Jsou to matematické modely vyjádřené matematickými a fyzikálními vztahy, jednoznačně popisující reálný proces nebo jev. Pokud tyto modely splňují obecně platné přírodní zákony, jsou tyto modely precizní. Problém vzniká při vytvoření modelu složité, těžko popsatelné nebo obtížné měřitelné soustavy. Při takových soustavách se využívá matematické statistiky. Tato metoda je poměrně efektivní, ale má i mnoho omezení, nejčastěji vzniká problém s daty. Je-li příčinou selhání matematického modelu nedostatek informací o vyšetřované soustavě, lze využít metod umělé inteligence. [2]

Principy přístupů umělé inteligence spočívají ve využití poznatků založených nikoliv na platnostech obecných, objektivních přírodních zákonů, ale na znalostech subjektivních a heuristických a znalostech experta (lidské znalosti). [2]

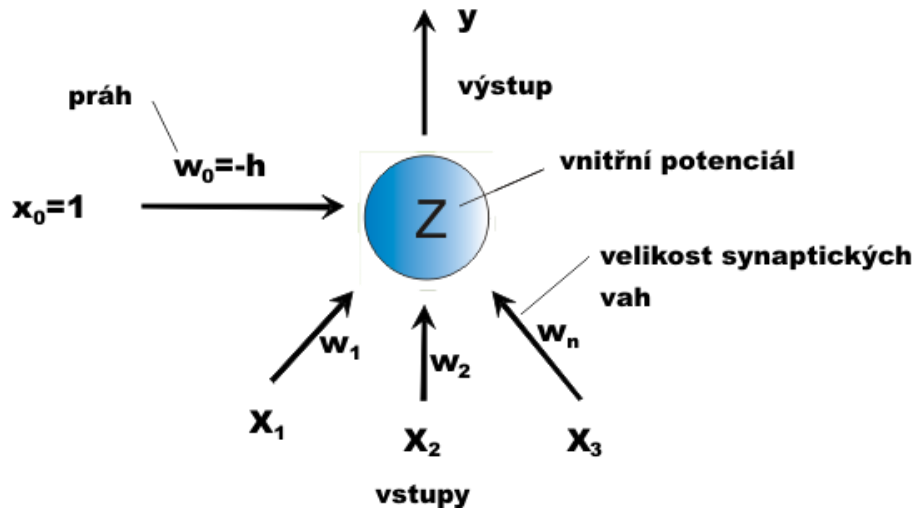
V případě této disertační práce byla modelována soustava, která predikuje chemické složení strusky na výstupu z pánvové pece. Pro modelování této soustavy, bylo využito modelování pomocí umělých neuronových sítí.

#### 3.2 Matematický model neuronu

Umělé neuronové sítě jsou inspirovány biologickými neuronovými sítěmi. Jejich hlavním úkolem je simulovat a implementovat některé funkce lidského mozku a nervové soustavy, především schopnost adaptace (učení) a schopnost generalizace

(zevšeobecňování). Je zřejmé, že vytvoření umělého lidského mozku se všemi jeho funkcemi a schopnostmi je věc velmi těžce řešitelná. Naskýtá se však šance simulovat alespoň některé elementární funkce lidského myšlení.

Základem umělé neuronové sítě je umělý formální neuron (obrázek 3.1), který je považován za zjednodušené matematické vyjádření funkce biologického neuronu.



Obrázek 3.1 Formální neuron

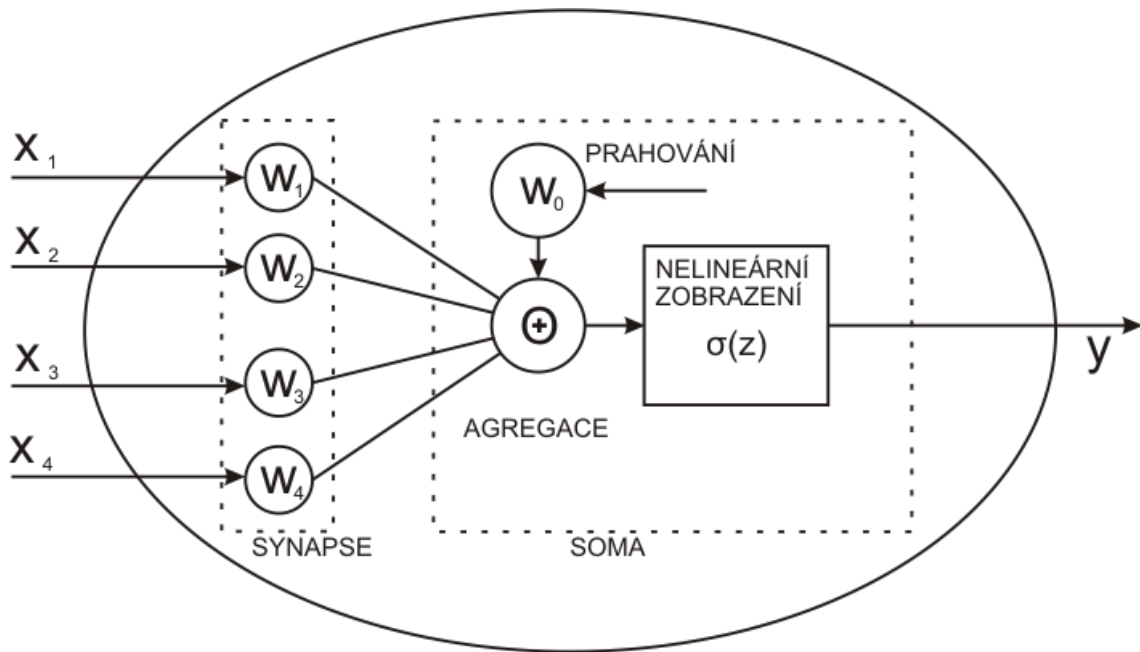
Formální neuron má  $n$  obecně reálných vstupů  $x_1, \dots, x_n$  odpovídající dendritům. Všechny vstupy jsou ohodnoceny příslušnými synaptickými váhami  $w_1, \dots, w_n$ , které určují míru propustnosti vstupního signálu. Zvážená suma vstupních hodnot představuje vnitřní potenciál neuronu  $z$ :

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

Hodnota vnitřního potenciálu  $z$  po dosažení tzv. prahové hodnoty  $h$  indikuje výstup neuronu  $y$ , který modeluje elektrický impuls axonu. Nárůst výstupní hodnoty je dán obecně nelineární přenosovou funkcí  $\sigma$ , při dosažení prahové hodnoty potenciálu  $h$ , jejímž argumentem je vnitřní potenciál  $z$ :

$$y = \sigma(z) \quad (2)$$

Podíváme-li se na formální neuron z hlediska matematického modelu, můžeme model překreslit tak, jak je na obrázku 3.2.



Obrázek 3.2 Matematický neuron

Vstupní veličiny  $x_i$  představují soubor konkrétních hodnot, které mohou být buď kvalitativní, nebo v kvantitativní formě. Kvalitativně vyjádřené vstupní veličiny obvykle nabývají booleovských hodnot ve smyslu ano nebo ne. Každý vstup se váže k vyjádření určité vlastnosti a konkrétní kvalitativní hodnoty vyjadřují, zdali tato vlastnost v systému existuje či nikoliv (např. 0 znamená, že modelovaný objekt dané vyjádření nemá, 1 znamená, že ji má).[8]

Kvantitativně je hodnota vstupní veličiny vyjádřena reálným číslem. Toto číslo představuje skutečné hodnoty měřených veličin. Do kategorie kvantitativních vstupů počítáme také fuzzy hodnoty jazykových proměnných.

Váhy  $w_i$  spojení ovlivňují jednotlivé vstupy do neuronů a tím i celou umělou neuronovou síť. Každý vstup do neuronu je ohodnocen určitou hodnotou příslušné váhy spojení. Tato hodnota reprezentuje citlivost, s jakou příslušný vstup působí na výstup z neuronu. Vzhledem k tomu, že v umělé neuronové síti většina vstupů jsou výstupy z jiných neuronů, mají váhy význam propustnosti synaptických tělísek biologických nervových buněk. Váhy spojení neuronu jsou vyjadřovány obvykle reálnými čísly, jejichž hodnoty vypovídají o průchodnosti, případně o důležitosti daného spojení. Váhy patří do skupiny parametrů, jejichž změnou je možné v procesu učení dosáhnout shody mezi výstupy zkoumaného procesu a výstupy umělé neuronové sítě. Právě výpočty

aktuálních hodnot vah a jejich postupné ladění představují podstatnou část učících algoritmů neuronových sítí. [8]

Konfluence (synapse) je závislost mezi různými kombinacemi vstupů  $x_i$  neuronu a příslušnými váhami  $w_i$ , lze ho popsat následující rovnicí:

$$z_i(t) = x_i(t) \oplus w_i(t) \quad (3)$$

V případě popisovaného základního modelu neuronu se uvažuje lineární hodnota zmíněného operátora  $\oplus$ . Je tedy možné obecný operátor konfluence nahradit prostým součinem hodnot  $x_i$  a  $w_i$ . pak vztah (3) můžeme přepsat na:

$$z_i(t) = x_i(t) \cdot w_i(t) \quad (4)$$

Prahová hodnota znamená bariéru, kterou musí vstupní signál neuronu překonat, aby se mohl dál šířit umělou neuronovou sítí. Hodnota prahu tedy určuje, kdy je neuron aktivní nebo neaktivní. Je-li hodnota vstupního signálu neuronu nižší než hodnota prahová, je na výstupu z neuronu signál odpovídající pasivnímu stavu neuronu. Jakmile dojde k překročení prahové hodnoty (je třeba poznamenat, že tato prahová hodnota se může během procesu rovněž měnit), stává se neuron aktivním a výstupní signál z neuronu roste až do určité maximální hodnoty. Ta je dána oborem hodnot příslušné aktivační funkce (viz kapitola 3.2.1). V modelech umělých neuronů je práh často používán k tomu, aby posouval signál při vstupu do aktivační funkce. Práh obecně představuje bariéru na vstupu do neuronu z okolního světa, nikoliv z jiných neuronů. Následkem toho již výsledná přenášená hodnota není zmenšena o práh (jako v případě biologického neuronu), ale prahová hodnota se aktivně podílí na výstupu z neuronu. [8]

Agregační funkce neuronu si klade za úkol sloučit určitým způsobem vstupní signály  $x_i$  neuronu. To znamená transformovat vstupní vektor  $\mathbf{x}_i$  ( $i = 0, 1, \dots, n$ ) na skalární signál  $u(t)$ , který dále pokračuje na vstup aktivační funkce neuronu.

Stejně tak, jako byl definován zobecněný operátor konfluence  $\oplus$ , bude zaveden zobecněný operátor agregace  $G$ . Potom lze proces agregace popsat následující obecnou rovnicí:

$$u(t) = \mathbf{G} z_i(t) \quad (5)$$

Po dosazení do rovnice (3) za  $z_i(t)$  dostaneme výsledek:

$$u(t) = \bigoplus_{i=1}^n x_i(t) \oplus w_i(t) \quad (6)$$

V případě použití výše definovaného základního modelu neuronu se může operátor agregace  $G$  nahradit operací sumace  $\Sigma$ . Po provedení této náhrady a zavedení prahu v přecházejícím vztahu (6) vyplyne tvar:

$$u(t) = \sum_{i=1}^n x_i(t) \cdot w_i(t) + \Theta \quad (7)$$

Práh lze formálně považovat za speciální případ váhy, jehož výstup má trvale hodnotu +1, resp. -1. Pak lze zavést substituci:

$$\Theta = w_0 \cdot x_0 \quad (8)$$


Po této substituci bude zapsána agregační funkce ve tvaru:

$$u(t) = \sum_{i=1}^n x_i(t) \cdot w_i(t) \quad (9)$$


### 3.2.1 Aktivační funkce neuronu

Úkolem aktivační funkce neuronu je převést hodnotu vstupního potenciálu na výstupní hodnotu z neuronu. Konkrétní tvary přenosových funkcí bývají velmi různorodé. V principu se dají tyto funkce rozdělit na lineární a nelineární, případně na spojité a diskrétní. Výběr vhodné přenosové funkce je závislý na konkrétním typu řešené úlohy, případně na konkrétní poloze neuronu v umělé neuronové síti. Běžně používají jiné aktivační funkce pro neurony ve skrytých vrstvách a jiné aktivační funkce pro neurony ve vrstvě výstupní (viz dále). Výběr vhodné přenosové funkce rovněž ovlivňuje náročnost technické nebo programové realizace navržené umělé neuronové sítě. [8] Lze využít hlavně tyto přenosové funkce – nelineární skokové, lineární, saturační, sigmoidální a hyperbolický tangent.

Jako první aktivační funkce (obrázek 3.3) byla použita nelineární skoková funkce. Výstup z neuronu měl jen dva stavy, což je pro většinu aplikací nedostatečné. [2]




Obrázek 3.3: Skoková funkce




Obrázek 3.4: Saturační aktivační funkce

Saturační aktivační funkce (obrázek 3.4) omezuje velikost vstupního signálu v rozsahu hodnot 0 až +1. Funkce kopíruje vstupní hodnoty na výstupu funkce, pouze při záporných vstupních hodnotách je na výstupu funkce vždy 0.

Lineární přenosová funkce (obrázek 3.5) má vztah mezi vstupní a výstupní hodnotou neuronu. Ve většině umělých neuronových sítí se využívá jako aktivační funkce poslední výstupní vrstvy sítě.



Obrázek 3.5: Lineární aktivační funkce




Obrázek 3.6: Sigmoidální aktivační funkce

Sigmoidální aktivační funkce (obrázek 3.6) se velmi často využívá v mnohovrstvých perceptronových sítích, a to z důvodu, že je to funkce diferencovatelná.

Vstupní hodnoty sigmoidální funkce nabývají celého rozsahu platnosti reálného čísla a výstupem neuronu je sigmoidální funkce, která nabývá hodnot v rozsahu 0 až 1.

Aktivační funkce hyperbolický tangens (obrázek 3.7) nabývá na rozdíl od výše uvedené aktivační funkce výstupních hodnot neuronu v rozsahu hodnot -1 až +1.



Obrázek 3.7: Aktivační funkce hyperbolický tangens

### 3.3 Umělá neuronová síť

Za umělou neuronovou síť se obecně považuje taková struktura pro distribuované paralelní zpracování dat, která se skládá z jistého, obvykle velmi vysokého počtu vzájemně propojených výkonných prvků – umělých neuronů. Obdobně jsou terminály axonu biologického neuronu přes synaptické vazby spojeny s dendrity jiných neuronů. Počet neuronů a jejich vzájemné propojení v síti určuje architekturu (topologii) umělé neuronové sítě. Z hlediska využití rozlišujeme v umělé neuronové síti vstupní, pracovní (skryté, mezilehlé, vnitřní) a výstupní neurony. Šíření a zpracování informace v umělé neuronové síti je umožněno změnou stavů neuronů ležících na cestě mezi vstupními a výstupními neurony. Stavů všech neuronů v síti určují stav a synaptické váhy všech spojů představují konfiguraci umělé neuronové sítě. [6], [9]

Umělá neuronová síť se v čase vyvíjí, mění se stav neuronů a adaptují se váhy. V souvislosti se změnou těchto charakteristik v čase je účelné rozdělit celkovou dynamiku umělé neuronové sítě do tří dynamik a pak tři režimy práce sítě jsou organizační (změna topologie), aktivní (změna stavu) a adaptivní (změna konfigurace). Uvedené dynamiky umělé neuronové sítě jsou obvykle zadány počátečním stavem a matematickou rovnicí,



resp. pravidlem, které určuje vývoj příslušné charakteristiky sítě (topologie, stav, konfigurace) v čase. Změny, které se řídí těmito zákonitostmi, probíhají v odpovídajících režimech práce umělé neuronové sítě. [9]

K nejdůležitějším vlastnostem umělých neuronových sítí patří:


- Využívají distribuované paralelní zpracování informace při provádění výpočtů, tzn., že ukládání, zpracování a předávání informace probíhá většinou prostřednictvím celé umělé neuronové sítě než pomocí paměťových míst. Paměť je tedy spíše globální než lokální a je reprezentována hodnotami synaptických vah mezi neurony.
- Učení je základní a podstatná vlastnost. Učení se realizuje nastavováním synaptických vah mezi neurony. Na rozdíl od principů klasických informačních technologií zde odpadá tvorba algoritmu úlohy, která transformuje vstupní množinu dat na výstupní. Tento proces je nahrazen předložením učících vzorů, tzv. trénovací množiny umělé neuronové sítě a jejím učením.
- Znalosti jsou ukládány především prostřednictvím síly synaptických vazeb mezi neurony. Vazby mezi neurony vedoucí ke „správné odpovědi“ jsou posilovány a naopak vazby vedoucí ke špatné odpovědi jsou oslabovány pomocí opakovaného předkládání učících vzorů.
- Mají generalizace, tato schopnost si pamatuje nejen všechny vzorové příklady dané trénovací množinou, ale umí zobecňovat jejich zákonitosti. Jsou tedy schopny na základě naučeného dát správnou odpověď i na to, co se v procesu učení neučily.
- Základní vlastnosti umělých neuronových sítí udává jejich paradigma. Paradigmatem rozumíme topologii, způsoby učení a vybavování umělých neuronových sítí. Paradigmat je známo několik desítek a stále se objevují další.

### 3.3.1 Topologie umělé neuronové sítě – organizační dynamika


Topologie specifikuje architekturu umělé neuronové sítě a její případnou změnu. Změna topologie se většinou uplatňuje v rámci adaptivního režimu tak, že síť je v

případě potřeby rozšířena o další neurony a příslušné spoje. Převážná část umělých neuronových sítí má pevnou architekturu (tj. takovou architekturu, která se již v čase nemění). Rozlišujeme dva typy architektury: cyklická (rekurentní) a acyklická (dopředná) síť. [2], [4], [9]

V případě cyklické topologie existuje v síti skupina neuronů, která je spojena v kruhu (tzv. cyklus). To znamená, že v této skupině neuronů je výstup prvního neuronu vstupem druhého neuronu, jehož výstup je opět vstupem třetího neuronu atd., až výstup posledního neuronu v této skupině je vstupem prvního neuronu. Nejjednodušším příkladem cyklu je zpětná vazba neuronu, jehož výstup je zároveň jeho vstupem. Nejvíce cyklů je v úplné topologii cyklické umělé neuronové sítě, kde výstup libovolného neuronu je vstupem každého neuronu. Příklad obecné cyklické neuronové sítě je uveden na obrázku 3.8, kde jsou vyznačeny všechny možné cykly. [2], [4], [9]




Obrázek 3.8: Příklad cyklické architektury [9]



Obrázek 3.9: Příklad acyklické architektury [9]

V acyklických sítích naopak cyklus neexistuje a všechny cesty vedou jedním směrem. Příklad acyklické sítě je na obrázku 3.9, kde je vyznačena nejdelší cesta.

U acyklické neuronové sítě lze neurony vždy (disjunktně) rozdělit do vrstev, které jsou uspořádány (např. nad sebou) tak, že spoje mezi neurony vedou jen z nižších vrstev do vrstev vyšších (obecně však mohou přeskočit jednu nebo i více vrstev). Speciálním případem takové architektury je vícevrstvá neuronová síť. [2], [4], [9]



Obrázek 3.10: Příklad architektury vícevrstvé neuronové sítě 3-4-3-2 [9]

V této síti je první (dolní), tzv. vstupní vrstva tvořena vstupními neurony a poslední (horní), tzv. výstupní vrstva je složena z výstupních neuronů. Ostatní, tzv. skryté (mezilehlé, vnitřní) vrstvy jsou složeny ze skrytých (vnitřních) neuronů. V topologii vícevrstvé sítě jsou neurony jedné vrstvy spojeny se všemi neurony bezprostředně následující vrstvy. Proto architekturu takové sítě lze zadat jen počty neuronů v jednotlivých vrstvách (oddělených pomlčkou), v pořadí od vstupní k výstupní vrstvě. Také cesta v takové síti vede směrem od vstupní vrstvy k výstupní, přičemž obsahuje po jednom neuronu z každé vrstvy. Příklad architektury třívrstvé neuronové sítě 3-4-3-2 s jednou vyznačenou cestou je na obrázku 3.10, kde kromě vstupní a výstupní vrstvy jsou i dvě skryté vrstvy. [9]

### 3.3.2 Druhy sítí

Umělé neuronové sítě se dělí podle několika kritérií [2]:

#### Podle počtu vrstev

- s jednou vrstvou (Hopfieldova síť, Kohonenova síť, ...)
- s více vrstvami (ART síť, Perceptron, klasická vícevrstvá síť s algoritmem Backpropagation)

#### Podle algoritmů učení

- s učitelem (síť s algoritmem Backpropagation, ...)
- bez učitele (model ART)

Podle stylu učení na síti

- s učením deterministickým (např. algoritmus Backpropagation)
- s učením stochastickým (náhodné nastavování vah).

**3.3.3 Učení s učitelem**

Učení s učitelem můžeme popsat následujícím jednoduchým způsobem. Předložíme-li na vstupy umělé neuronové sítě zadání některého problému, síť na výstupech zareaguje podle momentálního nastavení vah a prahových úrovní. Výstup můžeme porovnat s požadovaným řešením a stanovit chybu. Na jejím základě se budeme snažit změnit váhy tak, aby při dalším řešení stejného zadání byla velikost chyby menší. Pro zobecnění řešení je potřeba stanovit trénovací množinu vstupních vzorů. Princip učení živých organismů je podobný, i když pozice učitele nebývá vždy jednoznačně určena (bývají to nejčastěji různé okolní vlivy působící jako zpětná vazba). [9], [7]

Máme-li vícevrstvou síť s  $m$  vstupními neurony  $x_1, \dots, x_m$  a  $n$  výstupními neurony  $o_1, \dots, o_n$ , můžeme trénovací množinu zapsat jako:

$$T = \{[x^1, y^1], [x^2, y^2], \dots \dots [x^p, y^p]\} \quad (10)$$

$\mathbf{x}^p = (x_1^p, \dots, x_m^p)$  - vektor vstupních hodnot.

$\mathbf{y}^p = (y_1^p, \dots, y_n^p)$  - vektor požadovaných výstupních hodnot  $p$ -tého příkladu,

$T$ - značí transformaci vstupních hodnot na výstupní, tedy lze symbolicky předcházející vztah zapsat jako:

$$T = [x, y] \quad (11)$$

Trénovací množina obsahuje  $P$  příkladů, které se síť musí naučit; platí  $p \leq P$ . Pak celková střední kvadratická odchylka sítě (nejčastěji používaná metoda vyhodnocení) je dána vztahem:

$$E = \frac{1}{2} \sum_{p=1}^p \left( \sum_{k=1}^k (y_k^p - o_k^p) \right)^2 \quad (12)$$

$o_k^p$  - skutečný výstup  $k$ -tého neuronu ve výstupní vrstvě při předložení vstupu  $p$ -tého příkladu na neurony vstupní vrstvy,

$E$  - je chybová funkce,

$(y_k^p - o_k^p)$  - rozdíl požadovaného a očekávaného výstupu.

Umělá neuronová síť se může naučit i to, co nechceme. Dáváme-li například prvky trénovací množiny stále ve stejném pořadí, může si síť mezi nimi vytvořit souvislost.

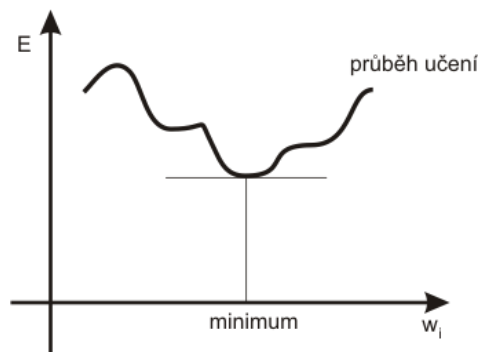
Chybová funkce  $E$  závisí na vstupech a na vahách sítě. Považujeme-li vektor vstupů (tj. trénovací množinu) za konstantní, stává se střední kvadratická odchylka jen funkcí vah umělé neuronové sítě. Po úpravě vah je tedy funkce  $E$  pro stejnou trénovací množinu zase jen závislá na nastavení vah. Pomocí nastavování vah se snažíme chybovou funkci  $E$  minimalizovat. Vzhledem k tomu, že aktivační funkce neuronů jsou derivovatelné, je i  $E$  derivovatelná podle jednotlivých vah. Dále zavedeme parametr učení sítě, který označíme  $\eta$  a který budeme nazývat rychlostí učení. Tento parametr také určuje délku kroku iterace. Pak pro změnu váhy (gradientní metoda) platí:

$$\Delta w_i = -\eta \left( \frac{\partial E}{\partial w_i} \right) \quad (13)$$

Tento vztah lze nahradit přibližným vztahem, ve kterém jsou za derivace dosazeny podíly diskretních čísel kde pravá strana je v čase  $t$ :

$$(\Delta w_i)_{t+1} = -\eta \left( \frac{\Delta E}{\Delta w_i} \right) \quad (14)$$

Bude-li hodnota parametru  $\eta$  příliš vysoká, budou se vlastnosti sítě měnit rychle, ale bude i větší riziko, že přeskočíme hledané minimum chyby. Naopak, jestliže je hodnota  $\eta$  příliš nízká, je učení pomalejší a síť se stává více náchylná k uváznutí v lokálním minimu chybové funkce (obrázek 3.11).




Obrázek 3.11: Učení umělé neuronové sítě

### 3.3.3.1 Back Propagation

Algoritmus zpětného šíření (obrázek 3.12) chyby je nejzákladnějším a nejpoužívanějším algoritmem pro učení umělých neuronových sítí. Základem je vrstvená síť, kde nejsou žádné zpětné vazby. Chyba se šíří zpětně přes všechny vrstvy k první vrstvě. Musí ale být známa vstupní a výstupní dvojice hodnot. Pro přenosovou funkci se u těchto sítí opět používá sigmoida a hyperbolický tangens. Učení podle tohoto algoritmu probíhá ve třech fázích [2], [7]:

- V první fázi je předloženo zadání. Na toto zadání reagují neurony jednotlivých vrstev sítě, postupně od vstupní vrstvy až po výstupní. Jakmile síť vrátí výstupní hodnoty, je možné zjistit chybu výstupu.
- Ve druhé fázi dochází k šíření informací o chybě, a to směrem od výstupní vrstvy zpět. Chybu neuronů ve skryté vrstvě určuje součet chyb neuronů následující vrstvy vynásobených odpovídajícími váhami. U vstupní vrstvy není třeba chybu zvažovat, neboť vstupní vrstva pouze distribuuje vstupní hodnoty.
- Ve třetí fázi, kdy už je pro každý neuron chyba známá, je možné podle pravidla učení adaptovat váhy.



Obrázek 3.12: Metoda Back-propagation. Černé šipky ukazují směr šíření signálu, červené směr šíření chyby.

Realizace výpočtu chyby a nastavení vah se provádí připojením další části sítě k dané síti tak, aby umožnila šíření informace od výstupu ke vstupu. Pak ale při provozu se musí tato část sítě odpojit (pokud se nejedná o stále se učící síť). Další způsob je

realizace sítě na počítači, kdy se obvykle provádí výpočet změny vah mimo síť. Programy tak vypočtou nové koeficienty, které se poté u sítě nastaví.

Učící cyklus je tvořen jednotlivými iteracemi popsány výše. Každý vzor je během cyklu předložen umělé neuronové síti právě jednou. Zkušenosti ukazují, že v případě, kdy jsou trénovací vzory navzájem nezávislé, není vhodné, jak již bylo řečeno, vzory předkládat ve stále stejném pořadí. V opakujících se sekvencích by totiž síť mohla nacházet nežádoucí závislosti. [7], [9]

Back-propagation má několik nepříjemných vlastností. Především je to skutečnost, že chybová funkce je závislá na všech vahách a díky tomu je to funkce velice složitá, tedy má mnoho lokálních minim. Gradientní metoda vede vždy do nejbližšího minima, které nemusí být globální.

Druhým problémem je množství učících parametrů, které nejsou algoritmem určeny, a přitom na nich závisí úspěšná konvergence chybové funkce. Vhodné nastavení těchto parametrů může značně ovlivnit úspěšnost učení.

Tato metoda konverguje relativně pomalu, zejména pro velké váhy, kde jsou změny sigmoidy velmi malé.

Back-propagation není algoritmem, který používá pro učení síti příroda. Jeho výpočet je sice lokální, ale lokálnost je pro biologickou implementaci podmínkou nutnou, nikoliv však postačující. Problém spočívá v obousměrnosti spojů, kdy se po nich zpětně šíří chyba. Reálné axony nejsou v žádném případě obousměrné.

### 3.3.3.2 Hopfieldův model


Hopfieldův model je krok směrem od biologické reality. Používá totiž symetrické spoje mezi neurony, které v přírodě neexistují.

Hopfieldův model neuronové sítě byl vytvořen jako asociativní paměť. Ta je tvořena neurony propojenými symetrickými spoji každý s každým (obrázek 3.13). Propojení může být reprezentováno symetrickou maticí vah s nulovou hlavní diagonálou. [7], [9]

Neurony mají dva stavy +1 (aktivovaný) a -1 (neaktivovaný) a provádějí prahový vážený součet, kde:

$$\text{sing}(a) \begin{cases} 1, \text{pro } a \geq 0 \\ -1, \text{pro } a < 0 \end{cases}$$

Postupným nastavováním vah model nepodstatné informace zapomíná a podstatné čím dál tím víc pamatuje (posiluje vazby). Kladný popud zesiluje vazbu, záporný zeslabuje. Postupuje se tímto způsobem tak dlouho, až zůstanou jen potřebné vazby. [7], [9]



Obrázek 3.13: Hopfieldova síť

Fáze učení bude začínat nastavením všech vah synaptických spojení na nulu. Neuronům přiřadíme hodnoty  $\{+1, -1\}$ . Potom změníme všechny váhy podle následujícího pravidla: jsou-li spojeny neurony se stejnou hodnotou, zvýšíme hodnotu váhy o jedničku, pokud jsou spojeny neurony s rozdílnými hodnotami, hodnotu váhy o jedničku snížíme.

Váha se zde mění, i když oba neurony jsou neaktivní  $[-1, -1]$ , což neexistuje u biologických neuronů, jejichž funkce je popsána Hebbovým pravidlem, podle kterého se synaptické spojení mezi dvěma současně aktivovanými neurony posiluje.

Tuto změnu vah opakujeme u všech postupně přiložených vzorů. Po naučení sítě hodnota váhy každého neuronu vyjadřuje rozdíl počtu vzorů, ve kterých se spojené neurony shodují svými hodnotami a počtu vzorů, ve kterých se neshodují.

Stav Hopfieldovy sítě je binární číslo a má tedy konečný počet stavů. Při změně svého stavu klesá její energetická funkce, a proto nemůže dojít k jejich zacyklení. To znamená, že po konečném počtu kroků se musí dostat do stabilního stavu, kdy už žádné změny neuronů nemohou proběhnout.



Na rozdíl od vrstvených sítí perceptronů, které dávají odpověď ihned, Hopfieldův model potřebuje nějaký čas, aby se ustálil v určitém stabilním stavu. Kromě základního Hopfieldova modelu existují rozšířené varianty, které umožňují používat místo binárních hodnot hodnoty reálné nebo které si místo jednotlivých stabilních stavů pamatují celé jejich sekvence. [7], [9]

### 3.3.4 Učení bez učitele

Učení bez učitele (učení samoorganizací - třídění) není založeno na vyhodnocování výstupu. Tato metoda vytváří zobecněný výstup jen na základě použitých vstupních vzorů. Před trénováním je obsah výstupu neznámý. Při učení bez učitele dostává síť na vstup množinu podnětů, které si sama utřídí. Například rozdělí podněty do skupin podle podobnosti a určí typického zástupce skupiny (model ART), nebo začne svojí konfigurací vah a tím topologií vystihovat vlastnosti vstupů. [7], [9]

U tohoto typu učení dělíme paměť na dlouhodobou (LTM – long term memory) a krátkodobou (STM – short term memory). Dlouhodobá paměť je tvořena nastavením synaptických vah, které se pomalu mění. Kdežto krátkodobá paměť je tvořena okamžitým stavem vzruchů, které se každým okamžikem proměňují. [7], [9]

Učením sítě se vybírají charakteristické rysy daných vzorů. Po určité době trénování lze dospět do stavu, kdy síť rozpoznává s dostatečnou spolehlivostí vstupy v aktivním režimu. Při dalším trénování může nastat situace, kdy dojde k takzvanému přetrénování sítě. To znamená, že charakteristické rysy už nejsou obecné, ale odpovídají spíše jen trénovací sadě. To se projeví zvýšenou chybovostí v aktivním režimu. Proto je vhodné použít po každé iteraci testovací sadu znaků, která nemění nastavené váhy, abychom zjistili optimální nastavení vah. Pokud by se chybovost zvýšila, vrátíme se ke stavu, kde byla ideální. [7], [9]

## 3.4 Predikční chyby umělých neuronových sítí

Disertační práce prezentuje predikční chyby umělých neuronových sítí, které se charakterizují mírou nepřesnosti mezi predikovanou hodnotou výstupu umělé

neuronové sítě a skutečnou hodnotou výstupu. V technických aplikacích se chyba převážně vyjadřuje následujícími vztahy [4]:

- vztah pro výpočet chyby RMS (Root Mean Squared) - nekompenzuje použité jednotky:

$$RMS = \sqrt{\frac{\sum_{i=0}^{i=n-1} (y_i - o_i)^2}{n - 1}} \quad [hm. \%] \quad (15)$$

- relativní chyby REL\_RMS - kompenzuje použité jednotky:

$$REL\_RMS = \sqrt{\frac{\sum_{i=0}^{i=n-1} (y_i - o_i)^2}{\sum_{i=0}^{i=n-1} (y_i)^2}} \quad (16)$$

Další vztahy, které byly prezentovány chyby umělých neuronových sítí:

- vztah pro výpočet průměrné relativní střední odchylky:

$$PRUM\_RSO = \left| \frac{\sum_{i=0}^{i=n-1} \frac{(y_i - o_i)}{o_i}}{n} \right| \quad (17)$$

- vztah pro výpočet průměrného rozdílu predikované a reálné výstupní složky:

$$PRUM\_RPRVS = \left| \sum_{i=0}^{i=n-1} \frac{(y_i - o_i)}{n} \right| [hm. \%] \quad (18)$$

Pro všechny vztahy platí že:

$n$  - počet vzorů trénovací nebo testovací množiny,

$y_i$  - predikované hodnoty výstupu umělé neuronové sítě,

$o_i$  - reálné hodnoty výstupu.

### 3.5 Tvorba umělých neuronových sítí v disertační práci

Umělé neuronové sítě byly vytvořeny v programovém prostředí STATISTICA – Neural Networks. Tento systém umožňuje mimo jiné vytvoření skupiny rozdílných umělých neuronových sítí a výběr nejvhodnější sítě s nejlepším výkonem. Obsahuje také výkonné vyšetřovací a analytické techniky umožňující volbu vhodných vstupních proměnných pro analýzu vyšetřovaných dat (algoritmy pro výběr vlastností vstupů). Dále umožňuje získat souhrnné popisné statistiky, provádět citlivostní analýzu a vytvářet odezvové grafy. Okno s parametry vytvořených umělých neuronových sítí v systému STATISTICA - Neural Networks je znázorněno na obr. 3.13.

The screenshot shows the STATISTICA Neural Networks interface. The main window displays a data table with columns for various chemical elements (Feo, Blaz, P2O5, MgO, SiO2, Al2O3, CaO, Cl2O3, MnO, Fe2O3, S, SS, A3, A5, VB) and rows for different samples (1-4). An inset window titled 'Přehled modelů (tavby\_vse.sta)' shows a table of neural network models with the following columns: Číslo, Zamknuto, Odkazů, Typ sítě, Trén. výkon, Valid. výkon, Test. výkon, Trén. chyba, Valid. chyba, Test. chyba, and Trénování.

Číslo	Zamknuto	Odkazů	Typ sítě	Trén. výkon	Valid. výkon	Test. výkon	Trén. chyba	Valid. chyba	Test. chyba	Trénování
1	0		RBF 17-17-11-11	0.988644	0.937071	0.926153	17.94585	36.88471	22.16183	KM KN PI
2	0		ZRNS 17-17-30-12-11-11	0.031335	0.735928	1.086048	0.76837	36.48129	21.07487	SS
3	0		ZRNS 17-17-30-12-11-11	0.036551	0.735174	1.079378	0.88453	36.47927	20.99960	SS
4	0		ZRNS 17-17-30-12-11-11	0.040489	0.734534	1.074675	0.97081	36.47888	20.94995	SS
5	0		RBF 17-17-2-11-11	0.827964	0.813280	0.763108	16.50072	35.74617	19.61700	KM KN PI
6	0		RBF 17-17-4-11-11	0.718053	0.720049	0.708411	11.11852	29.95303	23.21076	KM KN PI
7	0		Lineární 17-17-11-11	0.369477	0.869287	1.031040	0.08610	0.27042	0.28337	PI
8	0		VVPS 17-17-12-11-11	0.574052	0.882046	0.741463	0.12574	0.24253	0.28222	ZŠ100.SG37b
9	0		VVPS 17-17-13-11-11	0.515598	0.717363	0.935836	0.12703	0.23633	0.26724	ZŠ100.SG30b
10	0		VVPS 17-17-17-11-11	0.494582	0.661368	0.968014	0.15944	0.23437	0.30770	ZŠ68b

Obrázek 3.13: Program STATISTICA – prezentace výsledků umělých neuronových sítí

Všechny umělé neuronové sítě byly učeny pomocí učitele. Výsledné sítě se lišily stavbou neuronů a použitou aktivační funkcí.

Typy sítí:

- Lineární síť.
- Perceptronová síť.
- RBF síť s radiální bází.
- Třívrstvá a čtyřvrstvá perceptronová síť.

## 4 Tvorba predikčního modelu pomocí umělých neuronových sítí

### 4.1 Postup práce

Práce byla rozdělena na několik částí:

1. Kontrola a selekce dat pro umělé neuronové sítě.
2. Testovací program.
  - Tvorba testovacího programu.
  - Úprava testovacího programu.
3. Implementace, testování a vyhodnocení umělých neuronových sítí.
4. Tvorba uživatelského programu a implementace vybraných umělých neuronových sítí.
5. Testovací provoz.

Část jedna zahrnuje vhodnou úpravu vstupních a výstupních dat podle stanovených pravidel.

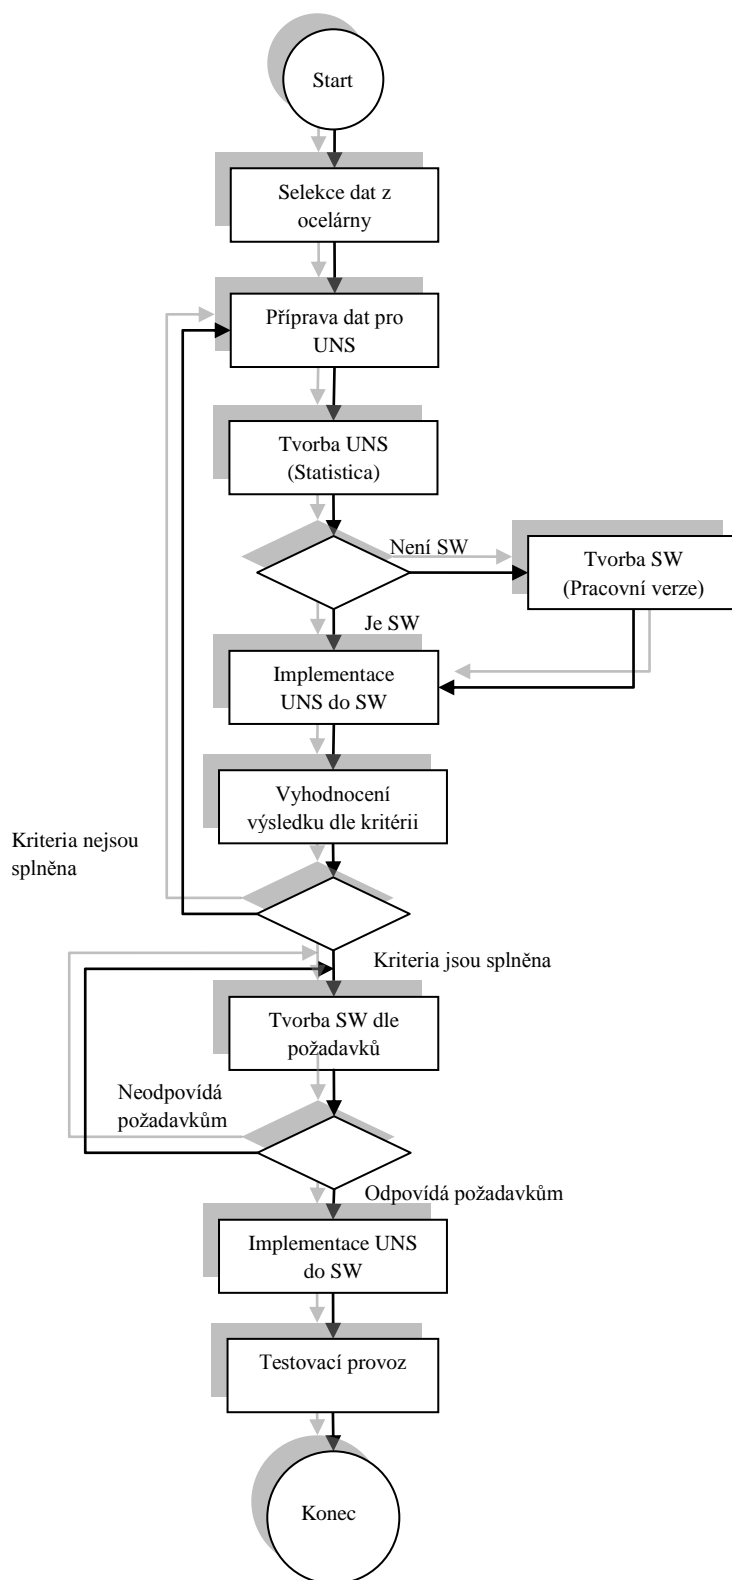
Část dvě se provádí ve dvou krocích. V prvním kroku se jedná o naprogramování jednoduchého programu pro testování umělých neuronových sítí vygenerovaného v programu STATISTICA. Testovací program je po grafické stránce jednoduchý a ovládání a výstup vyhovuje potřebám testování. Druhý krok pak zahrnuje úpravu již vytvořeného testovacího programu podle požadavku uložení vstupních a výstupních dat do souboru.

V třetí části probíhá testování a vyhodnocení umělé neuronové sítě podle definovaných kritérií.

Části jedna až tři se opakují v cyklech, tzn., že po vyhodnocení testování na testovací množině proběhla konzultace s technologem ohledně důležitosti vstupů a výstupů.

Ve čtvrté části se programuje již finální uživatelský program. Spolupracuje se s budoucími uživateli uživatelského programu, aby se přizpůsobil daným požadavkům.

V poslední části se program dává k testování na ocelárnu, kde bude po určené době vyhodnocen jeho provoz.



Obrázek 4.1: Vývojový diagram postupu práce

## 4.2 Úprava dat

Praktická aplikace umělých neuronových sítí byla zkušebně provedena ve společnosti ArcelorMittal Ostrava, a.s. v oddělení Q – Výzkum. Byla zde využita provozní data z ocelárny. Data pro predikci chemického složení strusky byla vybrána z pánvové pece číslo 1. Na této peci je větší koncentrace technologických prostředků k analýze a provádějí se zkoušky chemického složení strusek. Značky ocelí, které se na pánvové peci č. 1 připravují, zde mají podobný technologický postup.

Před samotným návrhem umělé neuronové sítě pro predikci chemického složení rafinačních strusek bylo nutné provést analýzu a úpravu dat. Vstupní data obsahují chemické složení příchozí strusky do pánvové pece a množství jednotlivých legur, které jsou přidávány do tavby v pánvové peci. Výstupní data jsou z poslední zkoušky na pánvové peci, než se přesouvá ocel na kontinuální liti. Data byla zapsána na různých listech sešitu v MS Excel. Jednotlivá vstupní a výstupní data musela být vyfiltrována do samostatného souboru v MS Excel. V tomto souboru byla data dále zpracována. Data se kontrolovala z důvodu výskytu častých chyb a neúplnosti. Při filtraci se přenášely celé sloupce z různých listů sešitu MS Excel. Proto se ve výsledném souboru vyskytovaly neúplné či prázdné řádky, které musely být odstraněny. V dalším kroku bylo nutné zkontrolovat, zda vstupní data (příjezdová analýza + legující složky) a výstupní data (poslední analýza na pánvové peci) jsou ze stejné tavby. Data se následně kontrolovala podle jednotlivých taveb. Zde se kontrolovaly chemické složky dle následujícího klíče:

- vstupní a výstupní data složek musí být různá,
- obsah FeO vstupu je větší než výstupu,
- bazicita vstupu je menší než výstupu,
- obsah CaO vstupu je menší než výstupu,
- obsah S vstupu je menší než výstupu.

Tento klíč musí být dodržován u všech dat tj. u všech značek oceli, které byly dodány ke zpracování a tvorbě umělých neuronových sítí. Nedodržení těchto podmínek vedlo k vyřazení celé tavby z dalšího zpracování.

Po profiltrování dat výše uvedeným klíčem se nacházely v datech ještě chyby, které se vyskytovaly v zápisech jednotlivých taveb. Tyto chyby byly ojedinělé a jejich výskyt byl nepravidelný, proto nebyly zařazeny do výše uvedeného klíče. Tato data se dala po odborné konzultaci s technologem upravit a tavba se tak nemusela vyřazovat z databáze a byla zahrnuta do množiny pro tvorbu umělých neuronových sítí.

Problémem byl výskyt nezaznamenaného nebo neplatného údaje. Nejčastěji se vyskytoval u složek FeO a Fe<sub>2</sub>O<sub>3</sub>. Tavba nebyla zařazena do vstupních dat, pokud vzniklá chyba byla u složky FeO, i když celá tavnice byla v pořádku. Chyba se totiž vyskytovala na vstupu i výstupu, tudíž nebylo možno doplnit chybné údaje ani přibližnou hodnotou. U složky Fe<sub>2</sub>O<sub>3</sub> byla chyba na výstupu (většinou nesmyslné číslo 100) a vstupní hodnoty byly v pořádku, pak se po konzultaci s technologem výstupní údaje vhodně změnily. Další chyby v zápisech byly u legujících složek A3(Al drát) a S5, zde nebyla často žádná hodnota, to znamená, že tyto legury nebyly přidány do tavnice a hodnoty byly nastavené na 0. Další chyby byly charakterizovány stejnými vstupními a výstupními daty, tato data byla také vyřazena.

Vyskytl se zde ještě jeden problém a to, že součet všech složek chemického složení strusek přesahoval nebo nedosahoval hodnotu 100 %. Tento rozdíl však nebyl nikdy vyšší než 7 %. Po domluvě s technologem byla tato tavnice brána za bezchybnou.

Byly předány celkem čtyři sešity dat. První sešit se týkal jen značky oceli T70, na kterých bylo provedeno nejvíce chemických analýz strusky. Tento sešit obsahoval nejvíce dat pro zpracování. Druhý a třetí sešit se týkal různých značek ocelí, které byly zpracované podobným technologickým postupem. Čtvrtý sešit byl dodán během prací a obsahoval data z různých značek ocelí. Tato data byla využita k následnému testování umělých neuronových sítí.

V prvním sešitě bylo celkem 980 taveb, z toho u 260 byla prováděna analýza strusky. V 260 tavních bylo 74 vstupních a výstupních dat shodných, tedy špatných. Ve zbývajících 186 tavních bylo 92 analýz chybných podle dalších bodů výše uvedeného klíče. Takže vhodná data pro tvorbu umělé neuronové sítě tvoří 94 bezchybných analýz (obrázek č. 4.2).

Druhý a třetí sešit se zpracovával stejně. Z obou dvou sešitů zbylo po selekci 60 analýz vhodných k tvorbě umělých neuronových sítí.

Obrázek 4.2: Ukázka výsledné filtrace dat v MS Excel

Dalším krokem bylo náhodně vybrat data k testování umělých neuronových sítí. Důvodem bylo vytvořit skupinu dat, která nebudou vůbec zahrnuta do učení umělé neuronové sítě. Je to z toho důvodu, že nemá smysl zkoušet naučenou síť na datech, na kterých se učila. Výsledek odhadu a tím i ověření funkčnosti sítě by byl zkraslený. Tímto krokem se dá před samotným testováním na ocelárně objektivně zhodnotit kvalita naučené umělé neuronové sítě.

V posledním sešitě s daty byla u všech taveb chyba u chemické složky FeO, opakovalo se stále stejné číslo. Po odborné konzultaci s technologem byla tato skupina taveb, která po úpravě dat měla celkem 96 taveb, využita k testování umělých neuronových sítí.

### 4.3 Tvorba umělých neuronových sítí

Učení umělých neuronových sítí bylo navrženo do několika kroků. Prvním krokem bylo nejdříve odzkoušet, zda je umělá neuronová síť schopna předpovědi chemického složení rafinační strusky za určitých kritérií. Poté bylo nutné dosáhnout



předem stanovených kritérií. Při tomto zkoumání bylo vytvořeno šest různých variant učících dat pro umělé neuronové sítě.

Tyto varianty jsou:

- Zkušební varianta je tvořena daty jen značky oceli T70, jen pro ověření, zda je možné předpovídat chemické složení rafinační strusky.
- První varianta je tvořena jen daty značky oceli T70 a legur. Varianta byla navržena jako první, protože nejvíce analýz strusek je právě v této značce oceli.
- Druhá varianta byla tvořena daty různých značek ocelí. Varianta charakterizuje technologii výroby na pánvové peci tzn. i když jsou to různé značky ocelí, tak tato data jsou si z pohledu technologického procesu výroby příbuzná.
- Třetí varianta se skládá ze dvou skupin dat a jejím výstupem jsou dvě umělé neuronové sítě. Data byla rozdělena na složky, které mají svou numerickou hodnotu (hm. %) větší než deset a menší než deset. V první skupině jsou složky  $\text{Al}_2\text{O}_3$ ,  $\text{CaO}$ ,  $\text{SiO}_2$  a  $\text{MgO}$  (dominantní složky). Druhá skupina se skládá ze složek  $\text{FeO}$ ,  $\text{P}_2\text{O}_5$ ,  $\text{Cr}_2\text{O}_3$ ,  $\text{MnO}$ ,  $\text{Fe}_2\text{O}_3$  a  $\text{S}$  (zbylé složky).
- Čtvrtá varianta se skládá z devíti skupin. Každá skupina je jedna složka strusky kromě bazicity, která se počítá. Výstupem pak je opět jen tato složka.
- Pátá varianta je obdobná jako varianta druhá, ale z dat jsou odstraněna i data, která byla schválena jako dobrá (např. součet všech složek je větší než 100 %) a byla odstraněna data, kde se vyskytovala ve složkách hodnota nula.
- Šestá varianta eliminuje všechny zbylé složky jak na vstupu i výstupu. Vstupní data budou jen dominantní složky a legury a výstupem budou jen dominantní složky.

Postupně budou jednotlivé varianty představeny, zdůvodněn jejich výběr a vyhodnoceny výsledky jednotlivých umělých neuronových sítí.


Na základě takto upravených dat bylo zahájeno učení umělých neuronových sítí v programu STATISTICA (viz 3.5). Pro každou variantu bylo vybráno z 300 naučených umělých neuronových sítí jen 10 s nejlepšími parametry. Z deseti navržených umělých neuronových sítí, byly vybrány dvě až pět sítí s nejmenší trénovací chybou a největším výkonem ve všech případech. Sítě byly vygenerovány v jazyku C++. Tento kód byl vhodně upraven a implementován do připraveného testovacího programu. V tomto

programu byly umělé neuronové sítě testovány na testovací množině dat. Výsledky testování budou v disertační práci předloženy. Výsledky budou prezentovány jen dominantními složkami, a to v grafech, které porovnávají jednu reálnou a predikovanou dominantní složku rafinační strusky, dále zde je prezentován histogram reziduí, tento graf ukazuje četnost výskytu rozdílů predikovaných a reálných výstupních hodnot jednotlivých dominantních chemických složek rafinační strusky. Kromě zkušební varianty budou výše uvedené grafy u všech šesti variant.

#### 4.4 Popis a vyhodnocení jednotlivých variant

##### 4.4.1 Zkušební varianta

Tato varianta měla jen ukázat, zda je možné s určitou přesností pomocí umělých neuronových sítí, odhadovat chemické složení strusek. K dispozici bylo jen omezené množství dat. Použitá data byla ze značky oceli T70. Jako vstupní data byly použity všechny sledované složky chemické analýzy. Do vstupních dat nebyly zařazeny legury, neboť zatím nebyly k dispozici. Na obrázku 4.3 je znázorněna struktura vstupních a výstupních složek.

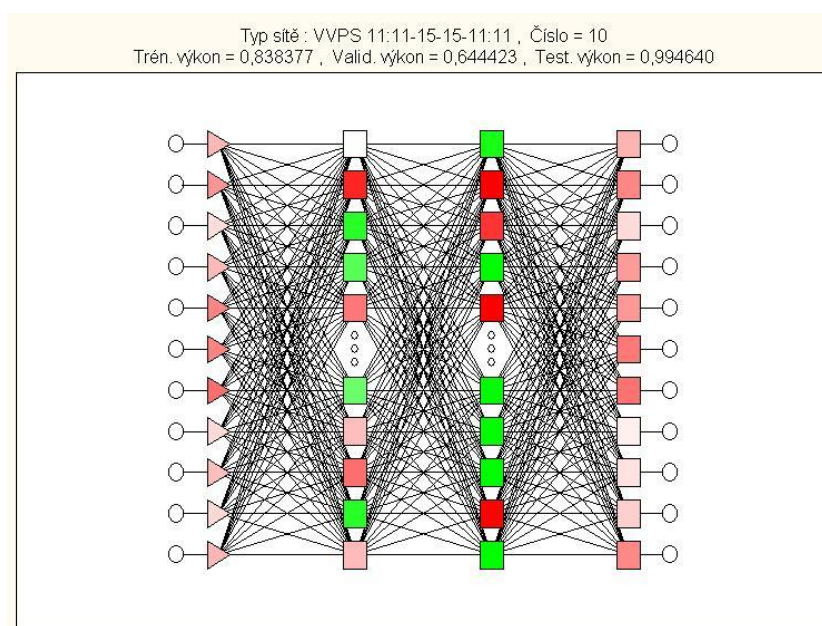


Obrázek 4.3: Struktura vstupních a výstupních dat pro učení

V této fázi šlo o pokus, a proto výsledky měly určit, jak se k tomuto problému postavit. Program na prezentaci byl vytvořen C++ a vygenerován pro konzolovou verzi tj. pod systém DOS (viz kapitola 5.2).

Postup práce byl následující. Celkově bylo k dispozici 35 taveb. Ty byly rozděleny na 25 taveb, které budou zahrnuty do učení umělé neuronové sítě. Deset taveb bylo nachystáno na testování naučených umělých neuronových sítí. Kriterium pro predikci, které bylo nastaveno, nemělo přesáhnout rozdíl mezi predikovanou a reálnou hodnotou jednotlivých složek o 35 %. Tak vysoké kritérium bylo zvoleno pro první orientaci.

Na obrázku 4.4 je znázorněna struktura umělé neuronové sítě, která byla použita. Je zde vidět jak jsou provázány mezi sebou jednotlivé neurony ve dvou skrytých vrstvách.



Obrázek 4.4: Struktura umělé neuronové sítě

Výsledky byly podrobeny jen vizuální kontrole, proto zde nejsou prezentovány. Výsledky ukázaly, že z tak malého množství dat nemůžeme naučit kvalitní umělé neuronové sítě. Přesto výsledky naznačily, že vytyčený směr se jeví jako správný. Důvod pro toto tvrzení je, že při tvorbě druhé umělé neuronové sítě byly navýšeny tavyby pro učení z 25 na 35, i když se testovaly na stejných datech, tak se výsledky zlepšily.

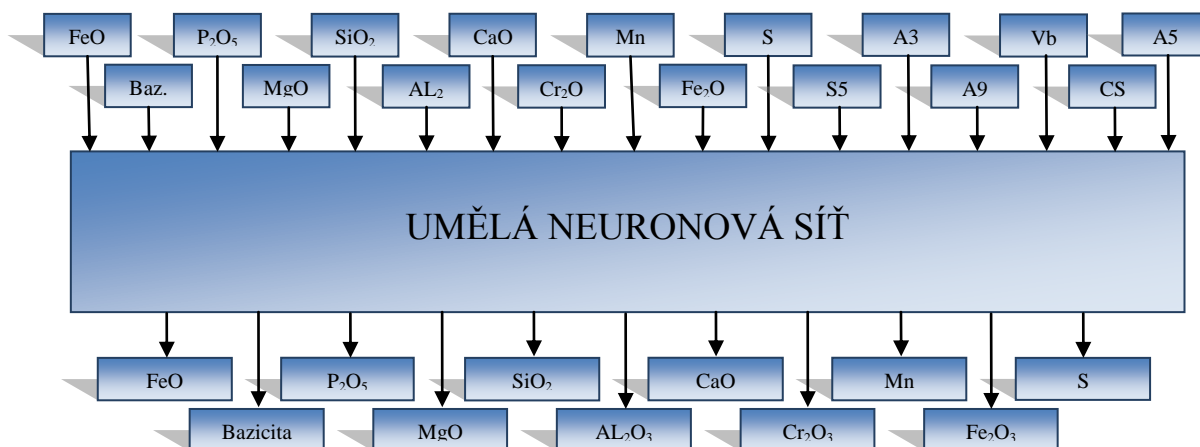
Závěr z této zkušební verze:

- Zkvalitnit vstupní veličiny.
- Navýšit počet taveb pro učení umělých neuronových sítí.

- Navýšit počet testovacích taveb pro objektivitu.
- Vytvořit nový uživatelský program pro rychlejší testování umělých neuronových sítí.

#### 4.4.2 První varianta

Tato varianta je tvořena daty značky oceli T70. Varianta byla navržena jako první, protože první soubor obsahoval jen tuto značku. Tato značka byla nejčastěji vyráběnou ocelí na pánvové peci, kde se započalo pravidelnými chemickými rozbory rafinační strusky. Do vstupních dat již byly zahrnuty legury, které ovlivňují rafinační pochod výroby oceli.



Obrázek 4.5: Struktura vstupních a výstupních dat pro učení


Na obrázku 4.5 je znázorněna struktura vstupů a výstupů umělé neuronové sítě. Takto vypadající vstupní i výstupní data splňují požadavky, které byly nadefinovány pro tuto disertační práci. Tato struktura je základní, pro další testování se jen upravovaly vstupy a výstupy dle potřeby.

Celkem bylo k učení použito 94 taveb. Umělá neuronová síť se testovala ve dvou fázích výzkumu. V první fázi byla testovací data i data učící. Jiná data nebyla při tvorbě k dispozici. Tyto výsledky nebudou v práci prezentovány, vzhledem k malému

počtu testovacích dat. Pro druhou fázi bylo požádáno o nová data, aby nedocházelo ke zkresleným výsledkům.

V druhé fázi se již testovalo na datech, které nebyly zahrnuty do procesu učení umělé neuronové sítě. Tato data byla použita u všech šesti variant na testování umělých neuronových sítí. Počet taveb k testování byl 96. Tato varianta splnila požadavky, které byly stanoveny v závěru zkušební varianty. Kriteria průměrné relativní střední odchylky byla nastavena na 25 % chybu u dominantních složek rafinační strusky. Chyba se snížila oproti zkušební verzi o 10 %.


Na obrázku (obrázek 4.6) je vidět naučená umělá neuronová síť s jednou skrytou vrstvou o 17 neuronech, která byla použita pro testování.




Obrázek 4.6: Struktura umělé neuronové sítě

Výsledky jsou prezentovány ve všech případech v grafech a tabulce chyb, kde jsou chemické složky  $\text{Al}_2\text{O}_3$ ,  $\text{SiO}_2$ ,  $\text{CaO}$ , které se používají k vykreslování ternárního diagramu. V grafech jsou porovnávány predikované a reálné hodnoty chemických složek rafinační strusky. Sloupcové grafy prezentují histogramy reziduí, tyto grafy ukazují četnost výskytu rozdílů predikovaných a reálných výstupních hodnot jednotlivých dominantních chemických složek rafinační strusky. K níže uvedeným grafům se váže relativní predikční chyba, průměrná relativní střední odchylka a průměrný rozdíl predikovaných a reálných výstupních hodnot, které jsou pro každou dominantní složku uvedeny v tabulce. V tabulkách u všech variant je i složka  $\text{MgO}$ ,

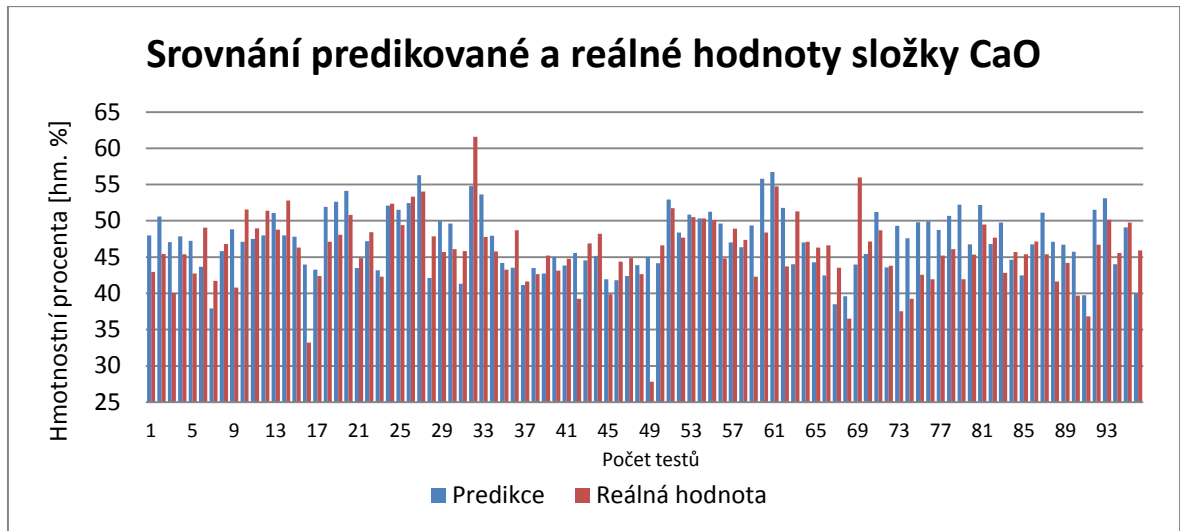
kteřá je zahrnuta do dominantních složek. V následujících grafech jsou prezentovány jen dominantní složky  $\text{Al}_2\text{O}_3$ ,  $\text{SiO}_2$  a  $\text{CaO}$ , jelikož jsou to složky, na nichž se vykresluje ternární diagram. Ostatní složky  $\text{FeO}$ ,  $\text{P}_2\text{O}_5$ ,  $\text{Cr}_2\text{O}_3$ ,  $\text{MnO}$ ,  $\text{Fe}_2\text{O}_3$  budou ve všech variantách podrobeny jen vizuální kontrole. Cíl této disertační práce nezahrnuje jejich přesnou predikci. V grafech 4.1, 4.2 a 4.3 je prezentováno 96 testů pro každou dominantní složku rafinační strusky. Z grafů je vizuálně dobře čitelné, jak se umělá neuronová síť naučila predikovat vybrané dominantní složky.



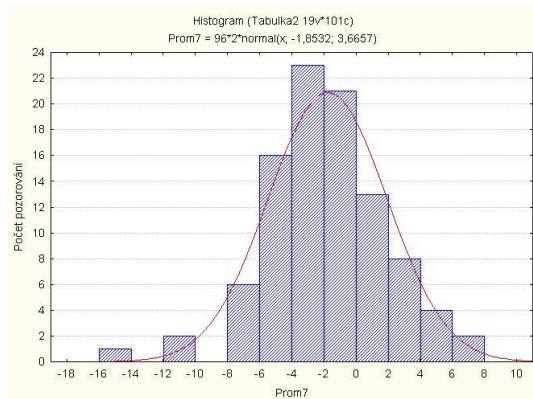


Graf 4.1: Srovnání predikované a reálné hodnoty složky  $\text{Al}_2\text{O}_3$



Graf 4.2: Srovnání predikované a reálné hodnoty složky  $\text{SiO}_2$



Graf 4.3: Srovnání predikované a reálné hodnoty složky CaO

Graf 4.5: Histogram reziduí chemické složky  $\text{Al}_2\text{O}_3$ Graf 4.6: Histogram reziduí chemické složky  $\text{SiO}_2$ 

Graf 4.7: Histogram reziduí chemické složky CaO

K výše uvedeným grafům odpovídají hodnoty chyb uvedené v tabulce 4.1.



Tabulka 4.1: Chyby umělé neuronové sítě

	REL_RMS [%]	PRUM_RSO [%]	PRUM_RPVS [hm. %]
Al <sub>2</sub> O <sub>3</sub>	20,6	17,4	3,4
SiO <sub>2</sub>	20,9	17,1	3,3
CaO	10	8,0	3,8
MgO	28,7	23,1	1,8

Výsledky splnily očekávání a chyba se snížila pod potřebnou úroveň 25 %. Ukázalo se, že i když byla umělá neuronová síť naučena daty pro jednu značku oceli, tak uspokojivě zpracovala data z různých značek ocelí. Nejlepší predikce je u složky CaO, poté následují složky Al<sub>2</sub>O<sub>3</sub> a SiO<sub>2</sub>. Zde se ukazuje, že čím větší podíl složky ve strusce, tím lepší predikce. Podle průměrného rozdílu vstupu a výstupu je ale pořadí opačné.

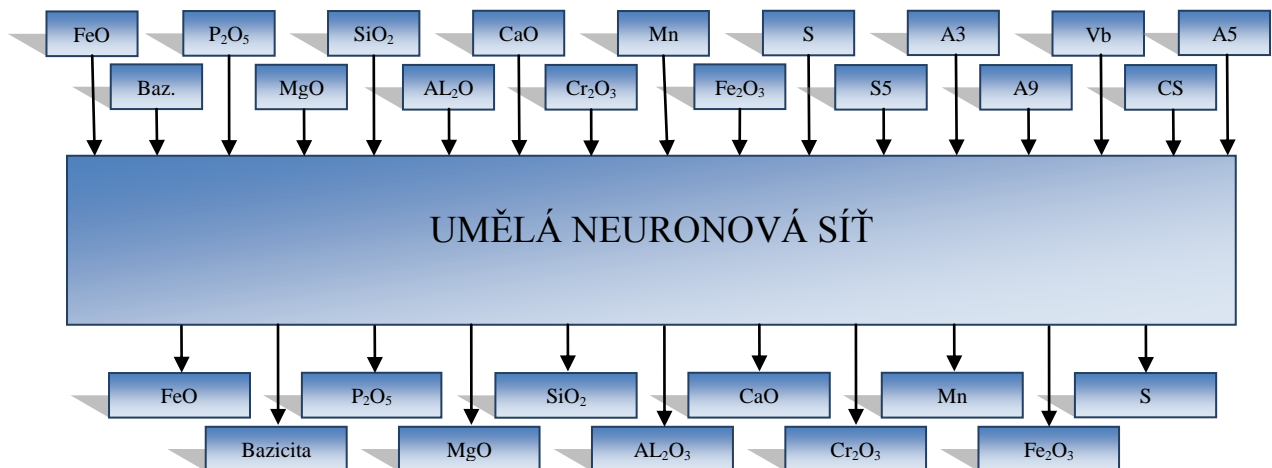
Závěr z této verze:

- Odstranit data s nulou v chemických složkách (ne legury).
- Zaměřit se na predikci těchto složek Al<sub>2</sub>O<sub>3</sub>, SiO<sub>2</sub>, CaO.
- Zkvalitnit výstup z uživatelského programu.

#### 4.4.3 Druhá varianta


Druhá varianta byla tvořena daty různých značek ocelí. Tato varianta charakterizuje technologii výroby na pánvové peci. I když jsou to různé značky ocelí, tak tato data jsou si z pohledu technologického procesu výroby příbuzná. Tato varianta a všechny následující zahrnovaly již jen na predikci dominantních prvků. Struktura vstupů a výstupů (obrázek 4.7) zůstala stejná jako u první varianty.






Obrázek 4.7: Struktura vstupních a výstupních dat pro učení

Počet vstupních taveb se pro učení zmenšil. Důvodem byla mnohonásobná převaha dat značky oceli T70 a obava, že síť bude ve výsledcích preferovat tuto značku oceli. Celkem bylo použito 65 taveb k učení. I s takto relativně malým počtem dat lze umělou neuronovou síť kvalitně naučit. Data byla rovnoměrně sestavena ze všech dostupných značek ocelí. K testování bylo použito 96 taveb. Kriterium průměrné relativní střední odchylky zůstalo nastavené na maximální chybu 25 % u dominantních prvků. Protože se změnila vstupní hodnoty, změnila se i struktura umělé neuronové sítě (obrázek 4.8).




Obrázek 4.8: Struktura umělé neuronové sítě


Výsledky jsou prezentovány v grafech a tabulce chyb, kde jsou chemické složky  $\text{Al}_2\text{O}_3$ ,  $\text{SiO}_2$ ,  $\text{CaO}$  rafinační strusky. V grafech jsou porovnávány predikované a reálné hodnoty chemických složek a sloupcové grafy prezentují histogramy reziduí. K níže uvedeným grafům se váže relativní predikční chyba, průměrná relativní střední odchylka a průměrný rozdíl predikovaných a reálných výstupních hodnot, které jsou pro každou dominantní složku uvedeny v tabulce.



Graf 4.8: Srovnání predikované a reálné hodnoty složky  $\text{Al}_2\text{O}_3$






Graf 4.9: Srovnání predikované a reálné hodnoty složky  $\text{SiO}_2$



Graf 4.10: Srovnání predikované a reálné hodnoty složky CaO

Z výše uvedených grafů vyplývá, že umělá neuronová síť se zlepšila, což se projevilo na níže uvedených histogramech. Ve všech třech grafech histogramů reziduí (grafy 4.11, 4.12, 4.13) je patrné, že umělá neuronová síť má menší rozptyl predikcí než předcházející varianta. Nejlepší predikce je u složky CaO, po té následují složky SiO<sub>2</sub> a Al<sub>2</sub>O<sub>3</sub>. U složky CaO je z histogramu patrné, že oproti složkám SiO<sub>2</sub> a Al<sub>2</sub>O<sub>3</sub> má větší rozptyl reziduí, ale v konečném výsledku je predikována nejlépe. Prezentace chyb je uvedena v tabulce 4.2.

Graf 4.11: Histogram reziduí chemické složky Al<sub>2</sub>O<sub>3</sub>Graf 4.12: Histogram reziduí chemické složky SiO<sub>2</sub>



Graf 4.13: Histogram reziduí chemické složky CaO

Tabulka 4.2: Chyby umělé neuronové sítě

	REL_RMS [%]	PRUM_RSO [%]	PRUM_RPVS [hm. %]
Al <sub>2</sub> O <sub>3</sub>	19,7	14,1	2,3
SiO <sub>2</sub>	17	13,1	2,8
CaO	8,2	5,9	2,7
MgO	18,3	13,6	1,2

Výsledky ukázaly, že síť se naučila predikovat lépe než předcházející dvě varianty. Z toho vyplývá, že pro univerzálnost modelu můžeme použít všechna dostupná data taveb pro učení umělé neuronové sítě. Důležité je se hlavně zaměřit na kvalitu dat pro učení umělé neuronové sítě. V tomto případě to znamená vynechat bazicitu, která se počítá podílem z predikovaných složek CaO a SiO<sub>2</sub>. Výsledky ukázaly, že u složky CaO můžeme zpřísnit kritérium více než u složek SiO<sub>2</sub> a Al<sub>2</sub>O<sub>3</sub>, kde bylo zlepšení nižší.

Závěr z této verze:

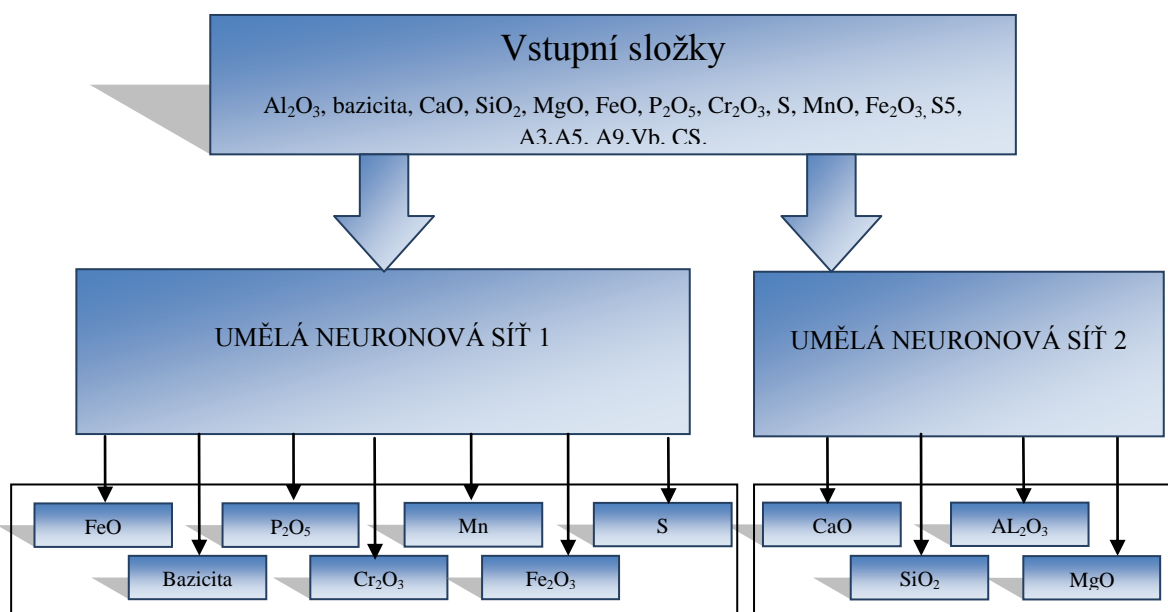
- Sloučení dat, která jsou momentálně k dispozici. Odstranit data, která byla původně schválena technologem pro učení. Tím se zlepší data pro učení umělé neuronové sítě.
- Dále pokračovat s daty, které obsahují více značek ocelí (zajistí univerzálnost modelu).
- Začít posuzovat kritéria pro jednotlivé složky zvlášť.
- Zaměřit se už jen na predikci složek Al<sub>2</sub>O<sub>3</sub>, SiO<sub>2</sub>, CaO.
- Vynechat bazicitu na výstupu pro učení umělé neuronové sítě.

- Vytvořit si zjednodušený program na testování sítí.

#### 4.4.4 Třetí varianta

Třetí varianta se skládá ze dvou nezávisle predikujících umělých neuronových sítí. Vstupní data byla pro obě umělé neuronové sítě stejná. V první umělé neuronové síti jsou výstupní složky  $\text{Al}_2\text{O}_3$ ,  $\text{CaO}$ ,  $\text{SiO}_2$  a  $\text{MgO}$  (dominantní složky). Tyto dominantní složky mají své numerické zastoupení v rafinační strusce větší než 10 hm. %. V druhé umělé neuronové síti jsou výstupní složky  $\text{FeO}$ ,  $\text{P}_2\text{O}_5$ ,  $\text{Cr}_2\text{O}_3$ ,  $\text{MnO}$ ,  $\text{Fe}_2\text{O}_3$  (zbylé složky), jejichž zastoupení v rafinační strusce je menší než 2 hm. %. Z obrázku 4.9 vyplývá, že model pro predikci bude složen ze dvou rozdílných umělých neuronových sítí.

Je testováno, jaký bude výsledek, když budou od sebe odděleny výstupní složky, které se řádově liší. Z výsledků předcházejících sítí vyplývá, že při vyšší chybě dominantních složek byla menší chyba u zbylých složek rafinační strusky. Tento poznatek ukazuje, že by se mohly výstupy takto ovlivňovat. Je možné, že se predikce přikloní k numericky vyšším nebo k numericky nižším složkám rafinační strusky. Tato varianta ověří, zda se numericky rozdílná čísla ovlivňují při predikci umělé neuronové sítě.




Obrázek 4.9: Struktura vstupních a výstupních dat pro učení -varianta 3


Data pro učení umělé neuronové sítě se sloučila s daty značky oceli T70. Po tomto sloučení dat bylo 159 taveb pro učení umělé neuronové sítě. K testování této varianty se použilo 97 taveb, které nebyly zahrnuty do procesu učení. Kritéria průměrné relativní střední odchylky byly nastaveny jen pro dominantní složky, a to:

- $\text{Al}_2\text{O}_3$ ,  $\text{SiO}_2$  na 17 % chybu
- $\text{CaO}$  na 11 % chybu
- $\text{MgO}$  na 19 % chybu

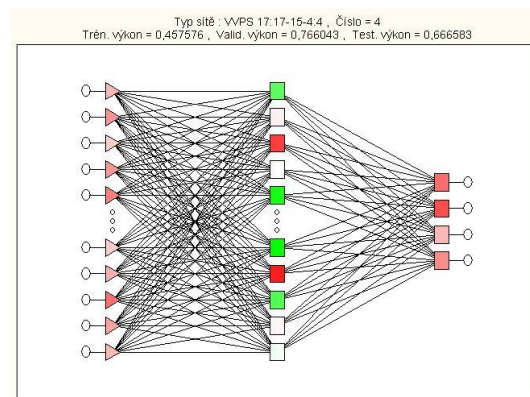
Na obrázcích 4.10, 4.11 a 4.12 jsou znázorněny použité umělé neuronové sítě. U dominantních složek byly pro testování vybrány dvě varianty, které mají rozdílnou strukturu sítě, i když se učily na stejných datech. Zbylé složky jsou zde prezentovány jednou umělou neuronovou sítí. Zbylé složky byly podrobeny jen vizuální kontrole a žádné kritéria nebyly nastaveny.



Obrázek 4.10: Struktura umělé neuronové sítě. Zbylé složky.




Obrázek 4.11: Struktura umělé neuronové sítě. Dominantní složky verze 1.




Obrázek 4.12: Struktura umělé neuronové sítě. Dominantní složky verze 2.

Výsledky jsou prezentovány v grafech a tabulce chyb, kde jsou prezentovány chemické složky rafinační strusky  $\text{Al}_2\text{O}_3$ ,  $\text{SiO}_2$ ,  $\text{CaO}$ . V grafech jsou porovnávány predikované hodnoty obou umělých neuronových sítí a reálné hodnoty chemických složek rafinační strusky. Sloupcové grafy prezentují histogramy reziduí obou umělých neuronových sítí. K níže uvedeným grafům se váže relativní predikční chyba, průměrná relativní střední odchylka a průměrný rozdíl predikovaných a reálných výstupních hodnot, které jsou pro každou dominantní složku uvedeny v tabulce.

V grafech jsou prezentovány najednou výsledky z obou verzí umělých neuronových sítí dominantních složek, V histogramech jsou prezentovány výsledky zvlášť pro každou dominantní složku z obou verzí.




Graf 4.14: Srovnání predikované a reálné hodnoty složky  $\text{Al}_2\text{O}_3$







Graf 4.15: Srovnání predikované a reálné hodnoty složky  $\text{SiO}_2$






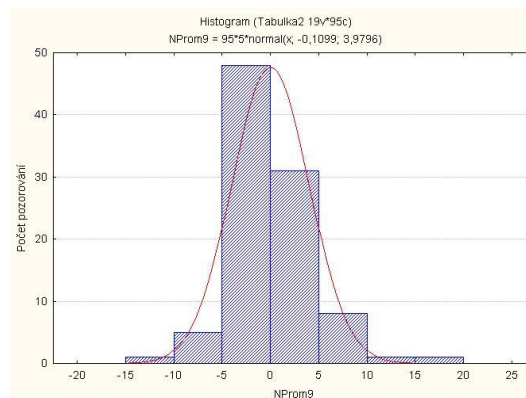
Graf 4.16: Srovnání predikované a reálné hodnoty složky CaO

Graf 4.17: Histogram reziduí chemické složky Al<sub>2</sub>O<sub>3</sub>. Verze 1.Graf 4.18: Histogram reziduí chemické složky Al<sub>2</sub>O<sub>3</sub>. Verze 2.Graf 4.19: Histogram reziduí chemické složky SiO<sub>2</sub>. Verze 1.Graf 4.20: Histogram reziduí chemické složky SiO<sub>2</sub>. Verze 2.





Graf 4.21: Histogram reziduí chemické složky CaO. Verze 1.



Graf 4.22: Histogram reziduí chemické složky CaO. Verze 2.

Výše uvedeným grafům a histogramům odpovídají hodnoty chyb uvedené v tabulce 4.3.

Tabulka 4.3: Chyby umělých neuronových sítí

	REL_RMS [%]		PRUM_RSO [%]		PRUM_RPVS [hm. %]	
	Ver. 1	Ver. 2	Ver. 1	Ver. 2	Ver. 1	Ver. 2
<b>Al<sub>2</sub>O<sub>3</sub></b>	18,5	26,9	15,3	20,6	2,8	2,7
<b>SiO<sub>2</sub></b>	21,5	22,4	17,7	19,3	3,4	3,6
<b>CaO</b>	12,6	8,6	10,2	6,0	4,5	2,8
<b>MgO</b>	24,7	18,8	20,4	14,6	1,7	1,4

Tato varianta prokázala mírné zhoršení oproti druhé variantě. U výsledků složky Al<sub>2</sub>O<sub>3</sub> v druhé variantě umělé neuronové sítě bylo mírné zlepšení průměrného rozdílu predikované a reálné výstupní složky oproti první variantě, i když má ostatní chybové výpočty větší než první varianta. Z histogramu reziduí je patrné, že tuto chybu zkresluje několik špatně predikovaných taveb. Při bližší kontrole bylo zjištěno, že soubor dat, kterými je testována umělá neuronová síť, má několik hodnot mimo standardní rozsah. Po konzultaci s technologem byla tato data nadále v testovacím souboru ponechána. Důvod tohoto rozhodnutí je že, tyto údaje mohou za určitých okolností být pravdivé. Je nutné analyzovat, z jakého důvodu toto navýšení reálných hodnot vzniklo. Podle výsledku této technologické analýzy se zvažuje zachování takových dat v trénovací množině. Tato data mohou výrazně ovlivnit výsledek naučené umělé neuronové sítě.

Tato varianta ukázala další směr zkoumání, a to zkoumat více umělých neuronových sítí a vybrat ty, které mají nejlepší predikční výsledky u jednotlivých

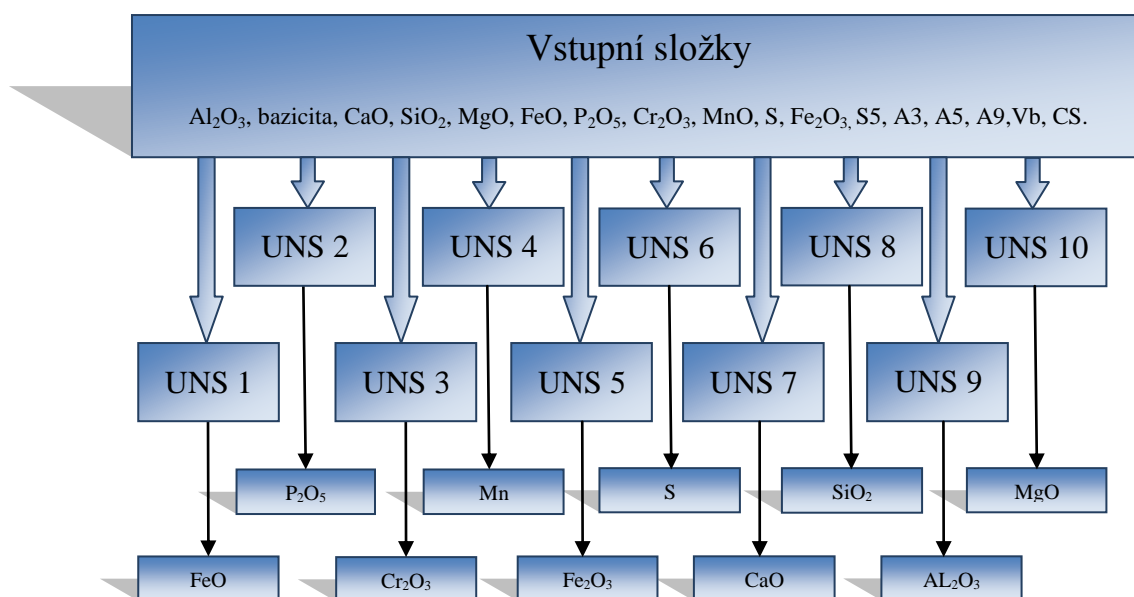
složek. Tyto umělé neuronové sítě dále zahrnovat do modelu a programově určit, která složka se má zobrazovat. Takto postavené modely zlepšují výsledky celé predikce, a to jak u dominantních i zbylých složek.

Závěr z této verze:

- Určité vazby mezi výstupy se vyskytují, ale zásadní význam nemají.
- Zaměřit se na prezentaci chyb.
- Zaměřit se více na validitu výstupních dat reálné složky.
- Rozložení výsledků do více umělých neuronových sítí.

#### 4.4.5 Čtvrtá varianta

Čtvrtá varianta se skládá z deseti nezávislých umělých neuronových sítí. Každá výstupní chemická složka rafinační strusky má svou vlastní umělou neuronovou síť (obrázek 4.13) kromě bazicity, která se počítá. Vstupní data byla pro všechny umělé neuronové sítě stejná. Tato varianta vychází ze závěrů třetí varianty a rozšiřuje předchozí variantu o úplné eliminování výstupních numerických vazeb mezi jednotlivými chemickými složkami rafinační strusky. Teoreticky by měla pokračovat v trendu mírného zlepšení predikce umělé neuronové sítě.



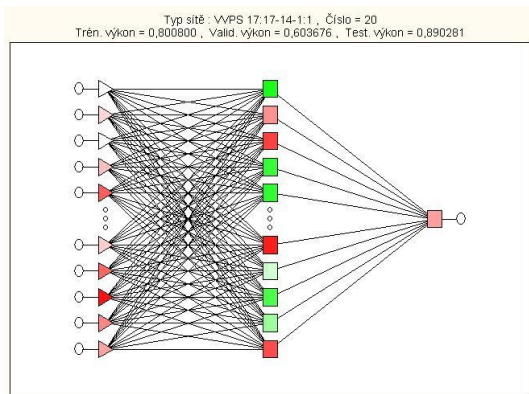
Obrázek 4.13: Struktura vstupních a výstupních dat pro učení. Varianta 4.

Data pro učení umělé neuronové sítě se shodovala s daty z minulé verze. Data pro učení umělé neuronové sítě byla ze 159 taveb. K testování bylo použito 96 taveb, které nebyly zahrnuty do procesu učení. Kritéria průměrné relativní střední odchylky byly mírně zpřísněny, a to:


- $\text{Al}_2\text{O}_3$ ,  $\text{SiO}_2$  na 15 % chybu
- $\text{CaO}$  na 9 % chybu
- $\text{MgO}$  na 18 % chybu

Umělé neuronové sítě byly vytvořeny pro všechny výstupní chemické složky. Všechny sítě byly zahrnuty do predikčního modelu. Zbylé složky byly podrobeny vizuální kontrole.

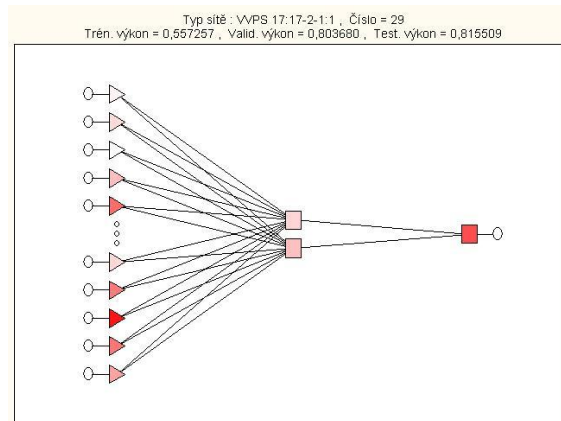
U této varianty byly vybrány ty umělé neuronové sítě, které měly nejlepší výsledky při testování. Z obrázků 4.14, 4.15 a 4.16 vyplývá, že pro každou složku rafinační strusky má umělá neuronová síť jinou strukturu stavby.



Obrázek 4.14: Struktura umělé neuronové sítě. Složka  $\text{Al}_2\text{O}_3$ .




Obrázek 4.15: Struktura umělé neuronové sítě. Složka  $\text{SiO}_2$ .




Obrázek 4.16: Struktura umělé neuronové sítě. Složka  $\text{CaO}$ .

Výsledky jsou prezentovány v grafech a tabulce chyb, kde jsou chemické složky  $\text{Al}_2\text{O}_3$ ,  $\text{SiO}_2$ ,  $\text{CaO}$  rafinační strusky. V grafech jsou porovnávány predikované a reálné hodnoty chemických složek a sloupcové grafy prezentují histogramy reziduí. K níže uvedeným grafům se váže relativní predikční chyba, průměrná relativní střední odchylka a průměrný rozdíl predikovaných a reálných výstupních hodnot, které jsou pro každou dominantní složku uvedeny v tabulce.


Z grafu kde se srovnávají hodnoty predikované a reálné složky, již vizuálně vyplývá, že predikce oproti minulým variantám je zhoršená.






Graf 4.23: Srovnání predikované a reálné hodnoty složky  $\text{Al}_2\text{O}_3$



Graf 4.24: Srovnání predikované a reálné hodnoty složky  $\text{SiO}_2$



Graf 4.25: Srovnání predikované a reálné hodnoty složky CaO

Graf 4.26: Histogram reziduí chemické složky  $\text{Al}_2\text{O}_3$ Graf 4.27: Histogram reziduí chemické složky  $\text{SiO}_2$ 

Graf 4.28: Histogram reziduí chemické složky CaO

K výše uvedeným grafům odpovídají hodnoty chyb uvedené v tabulce 4.4.

Tabulka 4.4: Chyby umělé neuronové sítě

	REL_RMS [%]	PRUM_RSO [%]	PRUM_RPVS [hm. %]
Al <sub>2</sub> O <sub>3</sub>	23,3	19,8	3,6
SiO <sub>2</sub>	24,9	19,8	3,7
CaO	12,1	9,9	4,1
MgO	22,3	18,2	1,5

Výsledky se místo zlepšení zhoršily, tedy varianta nesplnila původní předpoklad. Zhoršení bylo poměrně výrazné u Al<sub>2</sub>O<sub>3</sub>, SiO<sub>2</sub> a CaO složek rafinační strusky oproti předcházejícím variantám. Tímto se potvrdilo, že výstupní složky mají na sebe částečný vliv. Tato síť naopak vyhovuje zbylým složkám a složce MgO.

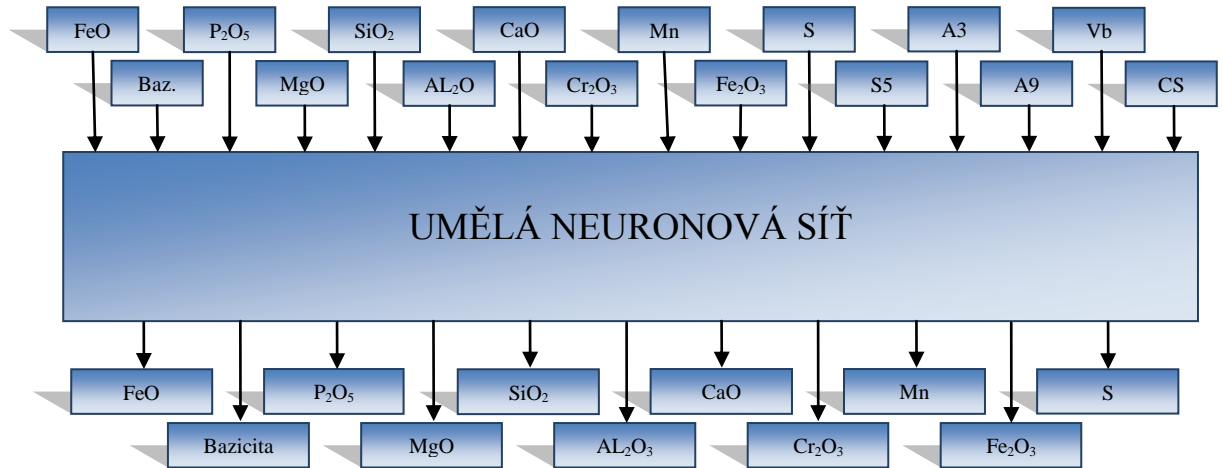
Z této varianty vyplývá, že výstupní data dominantních složek musí být pokaždé zahrnuta do učení umělé neuronové sítě. Tyto chemické složky mají výrazný vliv na kvalitu učení.

Závěr z této verze:

- Více výstupů z umělých neuronových sítí je nutností. Jejich vliv mezi sebou je důležitý a ovlivňuje přesnost predikce.
- Zaměřit se na vstupní data pro učení.

#### 4.4.6 Pátá varianta

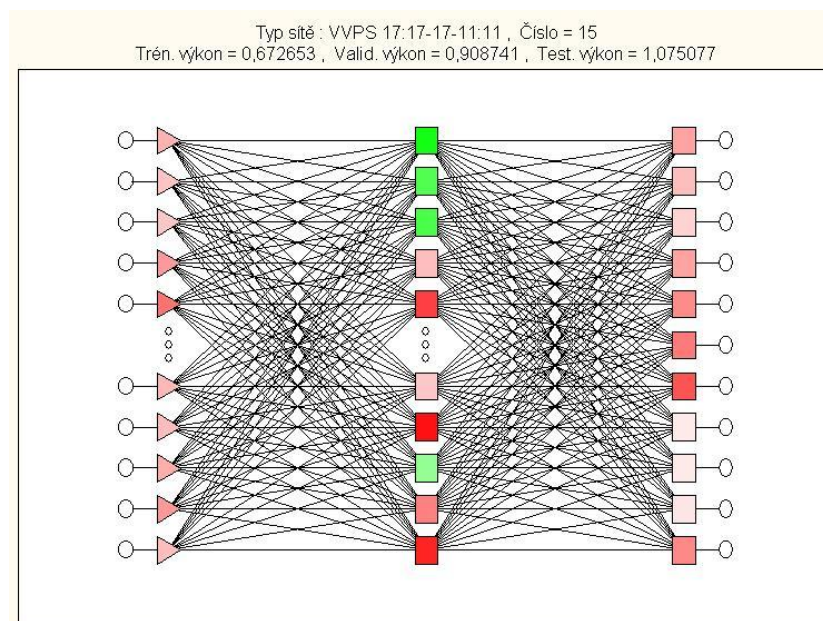
Pátá varianta je obdobná jako varianta druhá. Data pro učení měla stejné složení (obrázek 4.17). Oproti druhé variantě nejsou zahrnuta data, která byla schválena technologem jako dobrá. Dále byla odstraněna data, kde se vyskytovala nula ve vstupních i výstupních chemických složkách rafinační strusky. Vždy byla vyřazena celá tavba. Dále byly vyřazeny tavby, kde se legující složky rovnaly nule. Předpokladem je, že nula má negativní vliv na učení umělé neuronové sítě. Tento pokus měl vyvrátit předpoklad, že učením na stále stejných datech nemůžeme výrazně zlepšit predikci umělé neuronové sítě.



Obrázek 4.17: Struktura vstupních a výstupních dat pro učení

Po výše uvedené filtraci zbylo 45 taveb pro učení umělé neuronové sítě. Tavyby přesně charakterizují technologii výroby ocelí na pánvové peci. Pro testování bylo použito 96 taveb. Kriteria průměrné relativní střední odchylky zde nebyla nastavena. Výsledky se budou jen porovnávat s ostatními variantami.


Bylo vygenerováno 200 umělých neuronových sítí, z nichž bylo vybráno pět s nejlepšími parametry, a dvě se podrobily testování. Prezentována bude jen ta lepší varianta umělé neuronové sítě. Struktura je stejná jako u zkušební varianty (obrázek 4.18).




Obrázek 4.18: Struktura umělé neuronové sítě



Výsledky jsou zobrazeny v grafech a tabulce chyb, kde jsou prezentovány chemické složky rafinační strusky  $\text{Al}_2\text{O}_3$ ,  $\text{SiO}_2$ ,  $\text{CaO}$ . V grafech jsou porovnávány predikované a reálné hodnoty chemických složek. U složky  $\text{Al}_2\text{O}_3$  můžeme pozorovat, že umělá neuronová síť dokáže nejlépe predikovat nestandardní data z testovací množiny, je to vidět na grafu 4.29.



Graf 4.29: Srovnání predikované a reálné hodnoty složky  $\text{Al}_2\text{O}_3$






Graf 4.30: Srovnání predikované a reálné hodnoty složky  $\text{SiO}_2$





Graf 4.31: Srovnání predikované a reálné hodnoty složky CaO

Graf 4.32: Histogram reziduí chemické složky  $\text{Al}_2\text{O}_3$ Graf 4.33: Histogram reziduí chemické složky  $\text{SiO}_2$ 

Graf 4.34: Histogram reziduí chemické složky CaO

K výše uvedeným histogramům a grafům se váže relativní predikční chyba, průměrná relativní střední odchylka a průměrný rozdíl predikovaných a reálných výstupních hodnot, které jsou pro každou dominantní složku uvedeny v tabulce 4.5.

Tabulka 4.5 : Chyby umělé neuronové sítě

	REL_RMS [%]	PRUM_RSO [%]	PRUM_RPVS [hm. %]
Al <sub>2</sub> O <sub>3</sub>	19,7	16,3	2,5
SiO <sub>2</sub>	17,7	14,0	3,0
CaO	10,8	7,6	3,4
Mgo	28,1	25,5	2,5

Výsledky ukazují zlepšení oproti variantě 3 a 4, ale mírné zhoršení oproti variantě 2. Zlepšení vychází z kvalitních dat pro učení umělých neuronových sítí, ale zhoršení predikce z jejich malého počtu. I zde se ukázalo, že kvalitní vstupní a výstupní data v malém počtu dokáží uspokojivě naučit umělou neuronovou síť. U složky MgO naopak vychází nejhorší výsledek.

Tento pokus ukázal, že předpoklad o učení umělé neuronové sítě na stále stejných datech nepřinese radikální zlepšení, je pravdivý. Bylo nutné najít jinou možnost pro zlepšení predikovaných složek. Na výběr je několik možností:

➤ Datové řešení:

- Získání nových dat. Je časově náročné a jejich sběr a organizaci nemohu konkrétně ovlivnit. Přestože je to nejjednodušší a nejlogičtější řešení, vzhledem k výše uvedenému, tuto variantu zde nedoporučuji.
- Snížit počet vstupních chemických složek pro učení umělé neuronové sítě. Touto změnou dostaneme novou strukturu, nové vazby mezi jednotlivými vrstvami umělé neuronové sítě, tím i odlišné váhy. Takto provedená změna může ovlivnit hodnoty výstupních chemických složek ve větším měřítku než předchozí varianty. Samozřejmě změna může být i negativní. Ale v této situaci tuto možnost doporučuji.

- Vytvořit pro každou značku oceli zvlášť umělou neuronovou síť. Nedoporučuji pro nedostatek dat pro učení.
- Softwarové řešení:
  - Vytipovat umělé neuronové sítě s nejlepší predikcí u jednotlivých chemických složek ze všech odzkoušených variant. Programově se může implementovat do uživatelského programu libovolný počet umělých neuronových sítí. Tato volba je ideální a doporučuji ji provést, docílí se tím nejmenší chybovost celé predikce.
  - Nalézt provázanost mezi vstupními chemickými složkami a umělými neuronovými sítěmi. Tato možnost je časově náročná a hlavně je potřeba k její realizaci velké množství kvalitních dat, na kterých by se testovala. Princip vychází z toho, že by se hledala jakákoliv vazba mezi jednotlivými chemickými složkami, pokud je predikce přesná. Poté by se vytvořil algoritmus, který by zpracovával tyto údaje a volal správnou umělou neuronovou síť. Tuto variantu za stávajících podmínek nedoporučuji, ale je to další možnost jak zlepšit celou predikci.

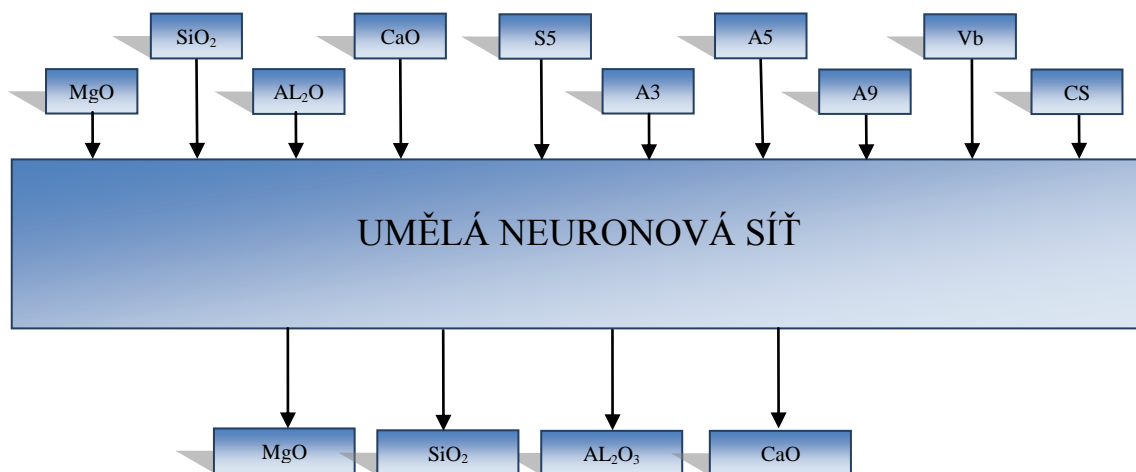
Závěr z této verze:

- Lepší výsledky predikce se stále opakujícími daty pro učení již nedostaneme.
- Zaměřit se na změny v návrhu vstupních chemických složek.
- Vložit více umělých neuronových sítí do uživatelského programu a zobrazovat vybraný predikovaný výstup.

#### 4.4.7 Šestá varianta

Při této variantě se vycházelo z předchozích nabídnutých možností. První změnou je eliminovat všechny zbylé složky, jak na vstupu, tak i výstupu. Vstupní data budou jen dominantní složky a legury a výstupem budou jen dominantní složky (obrázek 4.19). Tato volba zjednoduší strukturu sítě a eliminuje vliv zbylých složek na vstup do umělé neuronové sítě. Druhým krokem je testovat více umělých neuronových sítí a nalézt z těchto sítí nejlepší výsledek pro danou dominantní složku. Tyto sítě pak

budou zahrnuty do jednoho predikčního modelu. U této varianty byl očekáván nejlepší výsledek aspoň u jedné dominantní složky.

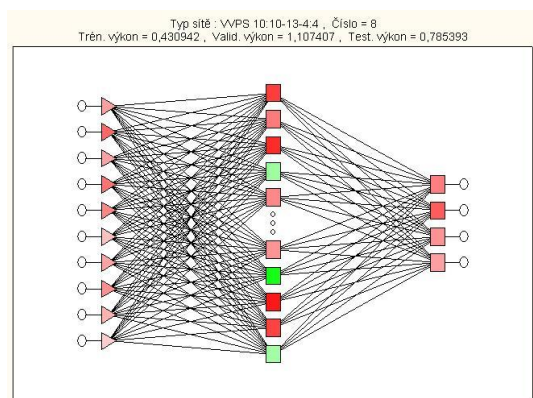


Obrázek 4.19: Struktura vstupních a výstupních dat pro učení

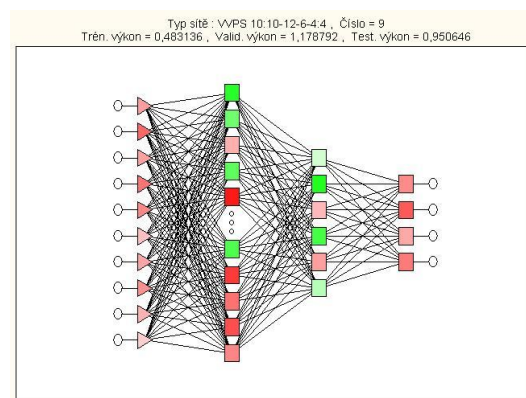
Data pro učení byla použita stejná jako u varianty 3. V těchto datech je provedena opětovná filtrace a vyřazeny jsou celé tavby, které obsahovaly nulu ve vstupních a výstupních chemických složkách rafinační strusky. Do této úpravy nebyly zahrnuty legury, protože v některých případech se do tavby nepřidávaly. Taveb pro učení umělé neuronové sítě bylo 88. Pro testování bylo použito 96 taveb. Kritéria zde byla nastavena nejpřísněji ze všech variant. Kritéria průměrné relativní střední odchylky jsou:

- Al<sub>2</sub>O<sub>3</sub>, SiO<sub>2</sub> pod 15 % chybu
- CaO na 7 % chybu
- MgO na 17 % chybu


Testováno bylo 7 umělých neuronových sítí. Z těchto sítí jsou vybrány na ukázkou tři. Každá varianta se prezentuje rozdílnými výsledky a mají rozdílnou strukturu stavby umělé neuronové sítě. Varianta 8 (obrázek 4.20) má jednu skrytou vrstvu se 13-ti neurony, varianty 9 (obrázek 4.21) a 10 (obrázek 4.22) se dvěma skrytými vrstvami. U varianty 9 to je 12 neuronů v první skryté vrstvě a 6 neuronů v druhé skryté vrstvě a u varianty 10 je 16 neuronů v první skryté vrstvě a 6 neuronů v druhé skryté vrstvě.



Obrázek 4.20: Struktura umělé neuronové sítě. Verze 8.





Obrázek 4.21: Struktura umělé neuronové sítě. Verze 9.




Obrázek 4.22: Struktura umělé neuronové sítě. Verze 10.

Výsledky prezentované v grafech jsou jen z verze 9 a 10. Výsledky obou umělých neuronových sítí jsou téměř totožné, jak je vidět z níže uvedených grafů. Verze 8 je uváděna z důvodu kvalitního naučení chemické složky MgO.


Graf 4.35: Srovnání predikované a reálné hodnoty složky  $\text{Al}_2\text{O}_3$




Graf 4.36: Srovnání predikované a reálné hodnoty složky SiO<sub>2</sub>




Graf 4.37: Srovnání predikované a reálné hodnoty složky CaO




Graf 4.38: Histogram reziduí chemické složky Al<sub>2</sub>O<sub>3</sub>




Graf 4.39: Histogram reziduí chemické složky Al<sub>2</sub>O<sub>3</sub>




Graf 4.40: Histogram reziduí chemické složky SiO<sub>2</sub>



Graf 4.41: Histogram reziduí chemické složky SiO<sub>2</sub>



Graf 4.42: Histogram reziduí chemické složky CaO



Graf 4.43: Histogram reziduí chemické složky CaO

Histogramy ukazují, jak jednotlivé verze predikují. Opět je patrné u složky SiO<sub>2</sub> ve verzi 9, jak se výrazně navýšila průměrná relativní střední odchylka oproti verzím 8 a 10. Důvodem je opět několik chybných predikcí.

K výše uvedeným histogramům a grafům se váže tabulka chyb pro každou dominantní složku zvláště příslušné verze umělé neuronové sítě (tabulka 4.5).

Výsledky ukazují mírné zlepšení oproti všem variantám u všech testovaných složek. S druhou variantou mají shodné výsledky u složky CaO. U složky Al<sub>2</sub>O<sub>3</sub> dosáhla umělá neuronová síť verze 10 lepšího výsledku, ale složku SiO<sub>2</sub> predikuje s mírným zhoršením.



Tabulka 4.6: Chyby umělých neuronových sítí

	PRUM_RSO [%]			PRUM_RPVS [hm. %]			PRUM_RSO [%]		
	Ver.8	Ver.9	Ver.10	Ver.8	Ver.9	Ver.10	Ver.8	Ver.9	Ver.10
<b>Al<sub>2</sub>O<sub>3</sub></b>	24,2	19,8	18,5	16,7	14,3	12,7	2,4	2,4	2,1
<b>SiO<sub>2</sub></b>	22,8	18,6	17,3	15,9	21,2	14,1	3,4	3,2	3,0
<b>CaO</b>	9,1	8,9	8,6	6,4	6,3	5,9	3,0	2,9	2,7
<b>MgO</b>	19,3	22,6	24,0	15,2	18,3	22,4	1,3	1,6	1,77

V tomto okamžiku již dále není možno manipulovat s daty pro učení umělé neuronové sítě. Změna vstupních dat nedokáže zlepšit vlastnosti umělé neuronové sítě na současných datech. Jakákoliv další snížení počtu vstupních dat nepopisuje většinové chemické složení rafinační strusky. Již tento pokus s redukcí vstupních dat je na pokraji kritéria, které je pro tuto disertační práci nastaveno.

#### 4.5 Výsledný model predikce rafinační strusky

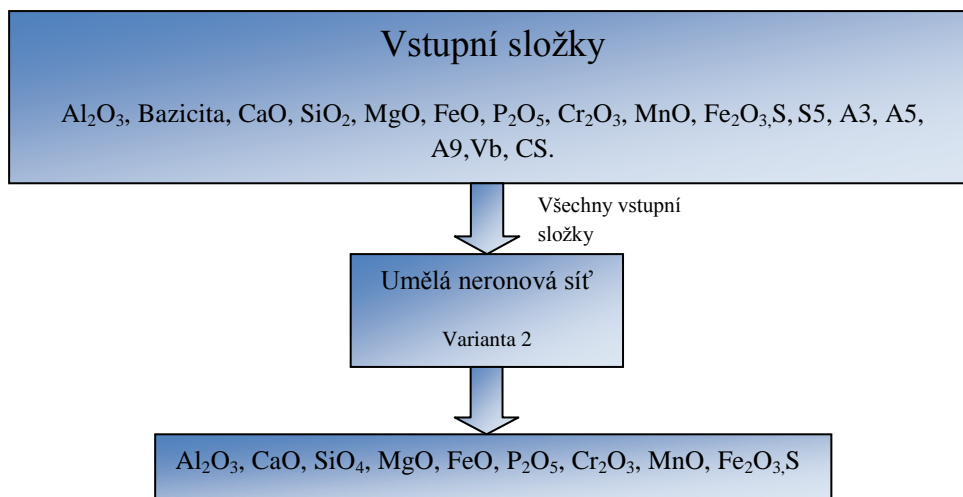
Z výše uvedených rozsáhlých výsledků a poznatků z jednotlivých variant vyplývají dvě možnosti řešení. První je řešit model predikce rafinačních strusek jedinou umělou neuronovou sítí a druhá možnost je řešit model predikce rafinačních strusek soustavou umělých neuronových sítí.

##### 4.5.1 Řešení predikčního modelu jedinou umělou neuronovou sítí

Toto řešení využívá umělou neuronovou síť z varianty 2. Na obrázku 4.23 je znázorněn model predikce rafinační strusky.

Tento predikční model má výslednou tabulku chyb pro dominantní chemické složky stejnou jako varianta 2 (tabulka 4.2).





Obrázek 4.23: Model č. 1 predikce rafinační strusky

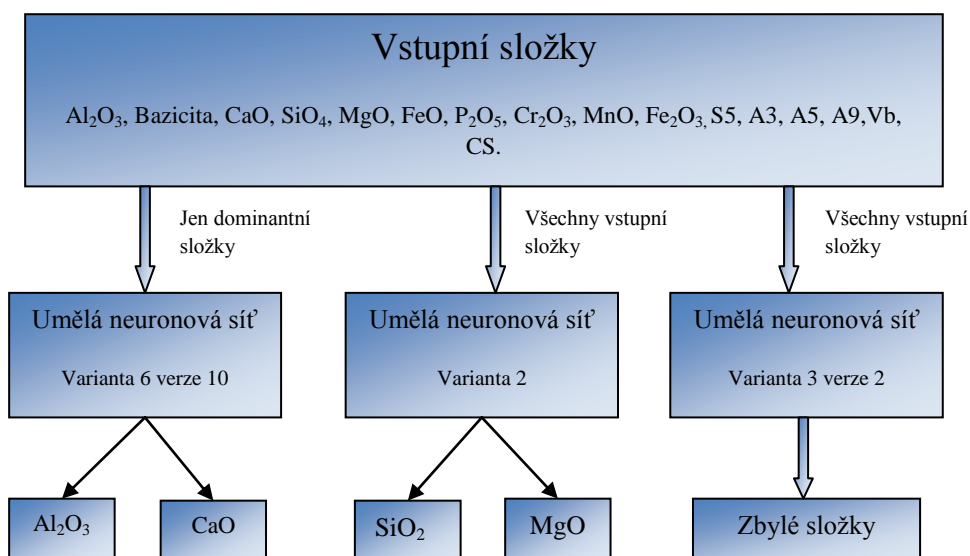
#### 4.5.2 Řešení predikčního modelu soustavou umělých neuronových sítí

Při tomto řešení je více možností kombinací umělých neuronových sítí. Výsledný model bude vycházet z variant 2, 3 a 6. Tyto varianty zaznamenaly nejlepší výsledky u všech testovaných chemických složek rafinační strusky.

Model se bude skládat z těchto umělých neuronových sítí pro jednotlivé chemické složky rafinačních strusek:

- $\text{Al}_2\text{O}_3$  – umělá neuronová síť z varianty 6 verze 10.
- $\text{SiO}_2$  – umělá neuronová síť z varianty 2.
- $\text{CaO}$  – umělá neuronová síť z varianty 6 verze 10 nebo varianty 2.  
Zvolena varianta 6 verze 10.
- $\text{MgO}$  – umělá neuronová síť z varianty 2 nebo varianta 6 ver. 8.  
Zvolena varianta 2.
- Zbylé složky – umělá neuronová síť z varianty 3 verze 2 nebo varianta 2.  
Zvolena varianta 3 verze 2.

Model je znázorněn na obrázku 4.24 a jeho chybové hodnoty znázorněny v tabulce 4.7.



Obrázek 4.24: Model č. 2 predikce rafinační strusky

Tabulka 4.7: Chyby umělé neuronové sítě

	REL_RMS [%]	PRUM_RSO [%]	PRUM_RPVS [hm. %]
<b>Al<sub>2</sub>O<sub>3</sub></b>	18,5	12,7	2,1
<b>SiO<sub>2</sub></b>	17	13,1	2,8
<b>CaO</b>	8,6	5,9	2,7
<b>Mgo</b>	18,3	13,6	1,2

Pro objektivní hodnocení jsou oba modely zaimplementovány do uživatelského programu, aby bylo možné jejich výsledky vzájemně porovnávat a ukládat.

## 5 Uživatelský program pro prezentování modelů predikcí rafinační strusky

### 5.1 Vývoj uživatelského programu

Rozsáhlý experimentální materiál popsany v kapitole 4 byl nutnou podmínkou pro vytvoření uživatelského programu (jeden z cílů této disertační práce), ve kterém budou prezentovány predikční výsledky vybrané umělé neuronové sítě. K naprogramování uživatelského programu je nutné vhodně navrhnout postup práce a prostředí, ve kterém se program bude vyvíjet. Protože práce probíhá ve dvou fázích, bylo navrženo vypracování dvou samostatných uživatelských programů, jeden pro testování a druhý pro obsluhu pánvové pece v ocelárně.

První uživatelský program je uzpůsoben pro experimenty popsané v práci a uzpůsoben pro studenty, kteří se zabývají problematikou umělých neuronových sítí.

Druhý uživatelský program je složitější a při jeho vývoji bylo nutné spolupracovat se zadavatelem (zákazník), který měl na uživatelský program určité nároky. Na začátku musí být vize zadavatele, co od uživatelského programu očekává a v jakém rozsahu by měl být zpracován. Další krok již záleží na dodavateli (programátor), jak dokáže převést vize zadavatele do reálného systému. Je nutné dodržovat základní pravidla při realizaci, tyto pravidla jsou obecná, ale jejich význam je důležitý pro správnou tvorbu uživatelského programu. Při jejich dodržení se vyhneme zbytečným nedorozuměním se zadavatelem a následně složitým předěláváním již hotové práce.

Vytváření uživatelských programů se řídí několika základními pravidly. Jedná se hlavně o [31]:

- Představu zadavatele (zadavatel by měl definovat např. vzhled, ovládání, vstup, výstup atd.).
- Analýzu prostředí u zákazníka (seznámení s prostředím a základními principy výroby, kdo s tímto programem bude pracovat atd.).
- Vytvoření pilotního projektu, ujasnění požadavku jak ze strany zadavatele tak i dodavatele (představení vize a upřesnění dalších požadavků, které by měl ještě program splňovat).

- Začátek realizace uživatelského programu.
- Zkušební verze uživatelského programu (tzv. beta verze programu, simulace).
- Připomínky zadavatele k beta verzi uživatelského programu (provede zadavatel, analýza beta verze ze strany zadavatele a návrhy k její změně). Opakuje se dokud je potřeba.
- Dokončení uživatelského programu do finální fáze, zapojení do reálného světa, zaškolení obsluhy, dlouhodobý test (doba se dohodne se zadavatelem).
- Po uplynutí testovací doby se uskuteční vyhodnocení chodu uživatelského programu a odstranění nalezených chyb.
- Konečné předání uživatelského programu i s příslušnou dokumentací.

Při samotné realizaci musí programátor citlivě vyřešit další vlastnosti uživatelského programu. Je třeba si uvědomit, že uživatelský program je vyvíjen pro obsluhu pánvové pece a ta bude jejím hlavním uživatelem. Je důležité, aby uživatelský program zbytečně nezatěžovala práci obsluhy pánvové pece. Proto má mít uživatelský program tyto vlastnosti [31]:

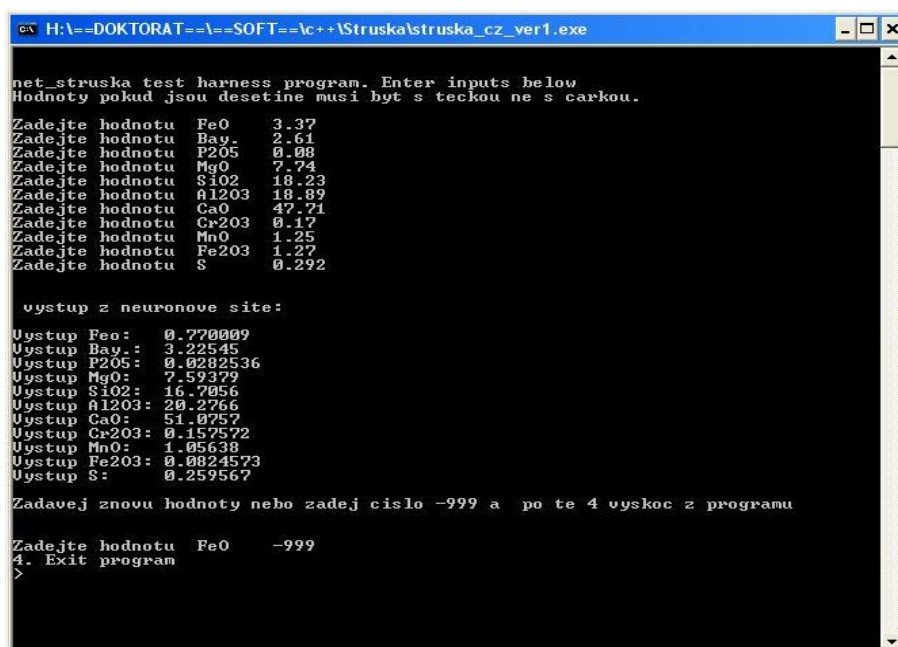
- Přehlednost.
- Jednoduché ovládání.
- Vyvážené zobrazování veličin.
- Odolnost proti chybám.

Pokud má tyto podmínky splňovat uživatelský program, musí se jeho vývoj konzultovat a testovat s uživateli. Konzultace jsou důležité hlavně kvůli přehlednosti a ovládání. Vývojový pracovník a zadavatel mají obvykle odlišnou představu o ovládání a prezentaci výsledků než obsluha uživatelského programu. V těchto případech je důležité vytvářet dílčí zkušební verze uživatelského programu a dát je k dispozici uživatelům k odzkoušení. Dále je nutné po odzkoušení s uživateli konzultovat chod uživatelského programu a hledat kompromis v jeho ovládání a prezentaci výsledků. Tato komunikace je často opomíjena a spousta obdobných programů není kladně přijata a posléze bojkotována obsluhou.

Odolnost proti chybám musí testovat jak zadavatel, tak i nezávislý tester (tj. nezaujatý člověk). Výstupem těchto testů je nalezení chyb při nestandardním používáním uživatelského programu. Programátor musí nalezené problémy vyřešit.

## 5.2 Tvorba uživatelského programu pro disertační práci

K aplikaci a možnosti odzkoušení umělých neuronových sítí vytvořené programu STATISTICA bylo využito programovacího jazyku C++, do jehož kódu byla umělá neuronová síť vygenerována.



```
H:\==DOKTORAT==\==SOFT==\c++\Struska\struska_cz_ver1.exe
net_struska test harness program. Enter inputs below
Hodnoty pokud jsou desetiny musí byt s tečkou ne s carkou.
Zadejte hodnotu Fe0 3.37
Zadejte hodnotu Bay 2.64
Zadejte hodnotu P205 0.08
Zadejte hodnotu Mg0 7.74
Zadejte hodnotu S102 18.23
Zadejte hodnotu A1203 18.89
Zadejte hodnotu Ca0 47.71
Zadejte hodnotu Cr203 0.17
Zadejte hodnotu Mn0 1.25
Zadejte hodnotu Fe203 1.27
Zadejte hodnotu S 0.292

vystup z neuronove site:
Vystup Fe0: 0.770009
Vystup Bay: 3.22545
Vystup P205: 0.082536
Vystup Mg0: 7.59379
Vystup S102: 16.7056
Vystup A1203: 20.2766
Vystup Ca0: 51.0757
Vystup Cr203: 0.157572
Vystup Mn0: 1.05638
Vystup Fe203: 0.0824573
Vystup S: 0.259567

Zadevej znovu hodnoty nebo zadej cislo -999 a po te 4 vyskoc z programu
Zadejte hodnotu Fe0 -999
4. Exit program
>
```

Obrázek 5.1: První aplikace neuronové sítě do programu

U zkušební a první varianty byl uživatelský program vytvořen ve freeware programu od firmy Bloodshed Software Dev C++. Tento program pracoval pod systémem MS-DOS a ve MS Windows pracoval v konzolovém režimu (okno příkazový řádek). Pro přehlednost musel být uživatelský program dále upraven zásahem do kódu programu. Tento uživatelský program nebyl programově ošetřen (zachytávání nestandardního zacházení s programem). Každá veličina se musela zadávat ručně. Výstup se zobrazoval na obrazovce a nikam se neukládal (obrázek 5.1).

Často se stávalo, že při špatném zadání veličin se program zacyklil a musel být restartován. I když tento program je uživatelsky nevyhovující, tak jeho úpravy pomohly

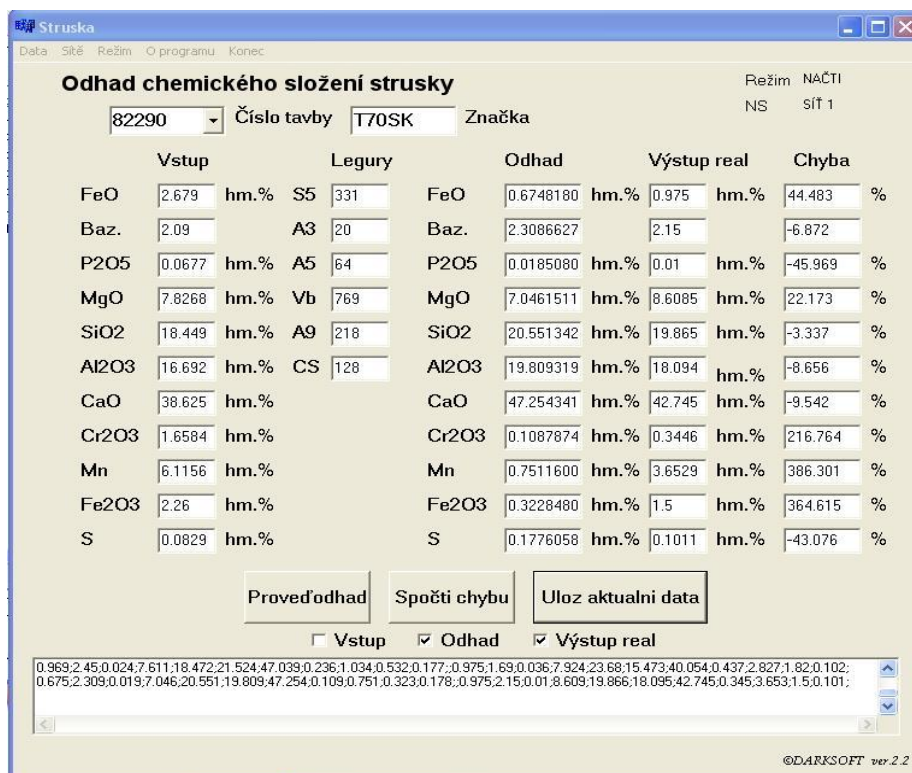
pochopit stavbu vygenerovaného kódu. Tyto zkušenosti jsou využity při další tvorbě uživatelského prostředí a dále i v pedagogické práci.

### 5.3 Vývoj testovací a finální verze uživatelského programu

Pro další vývoj uživatelské programu a docílení vyššího standardu, byl použit softwarový produkt Borland C++ Builder 6. V tomto prostředí se vytváří programy spustitelné pod systémem MS Windows. Uživatelský program má v sobě implementován kód vybraných umělých neuronových sítí pro predikci chemického složení rafinačních strusek. Kód je vygenerovaný v jazyku C++ programem STATISTICA. Vygenerovaný kód se pro samotnou implementaci do uživatelského programu musel vhodně upravit. Tato úprava zahrnovala smazání části kódu a vhodné přizpůsobení pro kód uživatelského programu.

Uživatelské programy, které se zde vyvíjely, jsou dvojího typu. První typ byl pro testování vygenerovaných umělých neuronových sítí v laboratorních podmínkách (pro vlastní potřebu). Tento testovací program byl uzpůsoben tak, aby se zde dal jednoduše implementovat upravený kód umělé neuronové sítě. Grafická zobrazení testovacího programu obsahuje jen to nejnutnější pro ovládání. V tomto případě se jedná o načtení, uložení dat, predikce, výpočet chyby umělé neuronové sítě a výběr sítě (obrázek 5.2). V testovacím programu nebylo nutné zobrazovat ternární diagram. Byly potřebné jen vstupní predikované hodnoty jednotlivých chemických složek rafinační strusky. Výsledky se ukládaly do souboru CSV, který je kompatibilní s MS Excel, kde se data dále vyhodnocovala.

V tomto testovacím programu jsou implementovány tři umělé neuronové sítě. Tak nízký počet umělých neuronových sítí je prevencí vůči vzniku chyb v kódu. Jedna vygenerovaná síť má totiž v kódu přibližně 150 až 200 řádků, takže snahou bylo eliminovat chybu již při zápisu programu. Každá varianta má svůj testovací program. Důvodem jsou rozdílné vstupní a výstupní veličiny kódů umělých neuronových sítí.



Obrázek 5.2: Testovací program

Druhý typ uživatelského programu (obrázek 5.3) je pro praktické použití pro obsluhu pánvové pece. Svými funkcemi odpovídá požadavkům zadavatele. Hlavní funkce uživatelského programu jsou:

- Načítání dat z MS Excel (data musí být předpřipravená).
- Ruční režim zadávání vstupních dat (načítání dat z MS Excel je vypnuto).
- Výběr ze dvou modelů pro predikci.
- Výpočet hmotnosti strusky.
- Vykreslování ternárního diagramu.
- Možnost výběru, která data se mají zobrazovat v uživatelském programu.
- Možnost výběru, která data se mají ukládat.
- Výběr typu souboru pro uložení.
- Otevření posledního uloženého souboru.

The screenshot shows the 'Struska' software window with the title 'Odhad chemického složení strusky'. It displays input and output data for various chemical elements and alloys.

Vstup	Legury	Hmotnost	Odhad	Výstup real	Chyba	
FeO	2,679 hm.% S5	331	26,743 kg	0,6748180 hm.%	0,975 hm.%	44,483 %
Baz.	2,09 A3	20	2,094	2,3086627	2,15	-6,872
P2O5	0,0677 hm.% A5	64	0,676 kg	0,0185080 hm.%	0,01 hm.%	-45,969 %
MgO	7,8268 hm.% Vb	769	78,131 kg	7,0461511 hm.%	8,6085 hm.%	22,173 %
SiO2	18,449 hm.% A9	218	535,976 kg	20,551342 hm.%	19,865 hm.%	-3,337 %
Al2O3	16,692 hm.% CS	128	455,547 kg	19,809319 hm.%	18,094 hm.%	-8,656 %
CaO	38,625 hm.%		1204,617 kg	47,254341 hm.%	42,745 hm.%	-9,542 %
Cr2O3	1,6584 hm.%		16,555 kg	0,1087874 hm.%	0,3446 hm.%	216,764 %
Mn	6,1156 hm.%		61,049 kg	0,7511600 hm.%	3,6529 hm.%	386,301 %
Fe2O3	2,26 hm.%		22,56 kg	0,3228480 hm.%	1,5 hm.%	364,615 %
S	0,0829 hm.%		0,828 kg	0,1776058 hm.%	0,1011 hm.%	-43,076 %
Celková		2404,776	kg			

Additional parameters: Výška strusky: 3,63 cm; Koefficient na 1cm: 275 kg; Režim: NACTI; Vybraná NS: S171.

Obrázek 5.3: Úplné zobrazení všech veličin

Vstupními veličinami jsou jednotlivé chemické a legující složky z příjezdové analýzy a dále je vstupem číslo tavby a typ oceli. Pokud by se analyzovalo zpětně, může být i vstupem odjezdová analýza z pánvové pece. Vstup dat do uživatelského programu načítáme z MS Excel (obrázek 5.4), může se zadávat počet načítaných řádků ze souboru. Pro úplné manuální zadávání dat je nutné přepnout na ruční režim. Legující složky se mohou zadávat nebo měnit během predikce ručně v obou režimech.

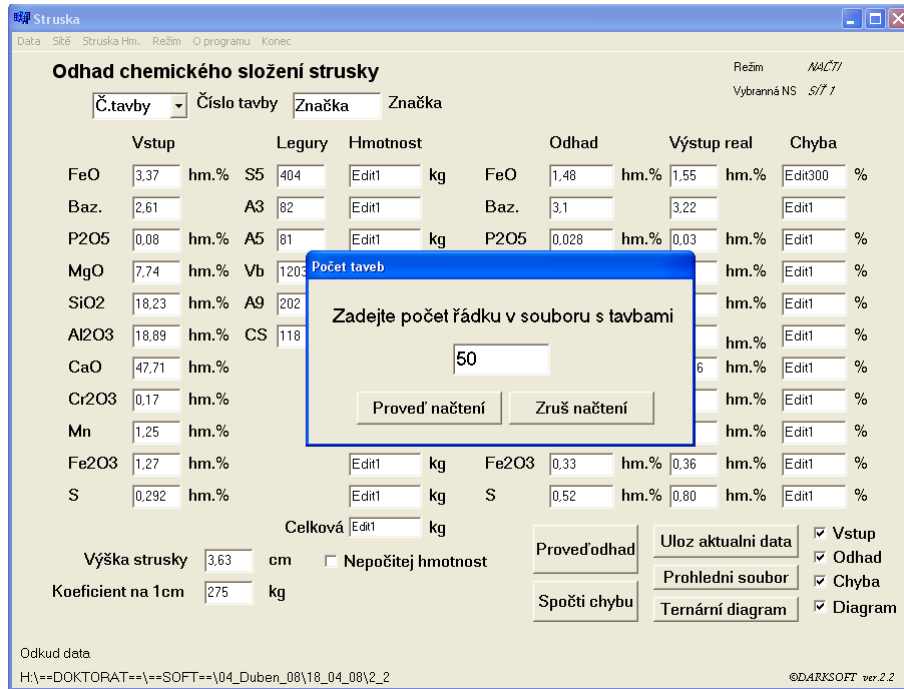
Výstupy z uživatelského programu jsou dva. Jeden je početní a počítá hmotnost strusky z popsanych chemických rovnic. Pak se dopočítává hmotnost pro jednotlivé chemické složky rafinační strusky pomocí těchto veličin:

- Odhadovaná celková hmotnost strusky.
- Výška strusky v pánvi a koeficient hmotnosti na 1 cm výšky strusky.

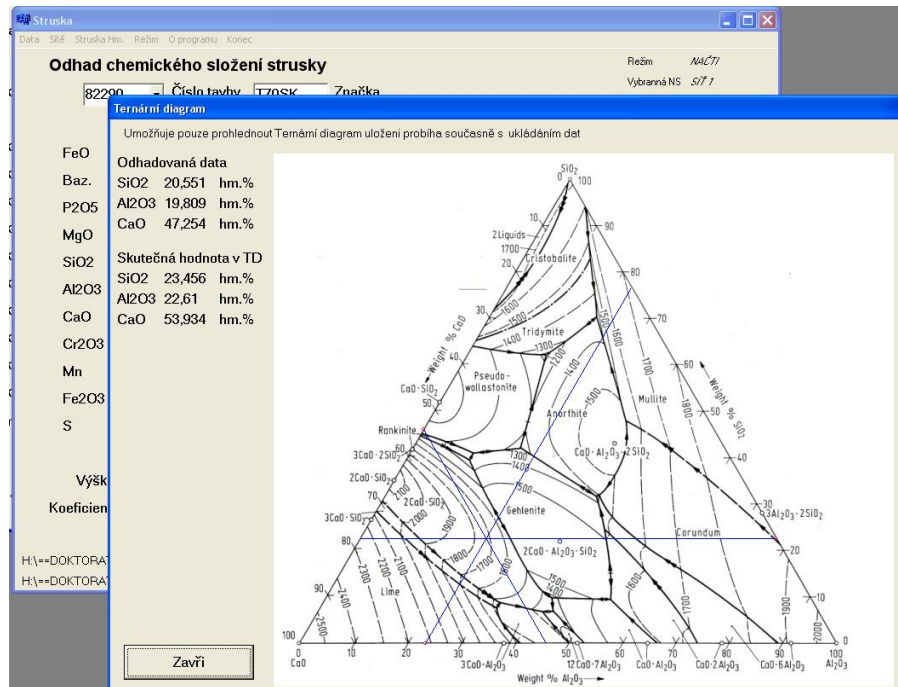
Druhý a hlavní výstup je predikce jednotlivých chemických složek a vykreslení teploty v ternárním diagramu ze složek  $Al_2O_3$ ,  $SiO_2$ ,  $CaO$  (obrázek 5.5). Presentace výstupů má dvě varianty. První varianta je uložení do dvou výsledných souborů, výstupní data jednotlivých chemických složek a hmotnost jsou uloženy do datového souboru CSV, který je kompatibilní s MS Excel a ternární diagram je v obrázkovém souboru JPG. Oba názvy souboru nesou číslo tavby a číslo modelu, který byl aplikován.



Druhá varianta je uložení do jednoho výsledného souboru MS Excel, a to jak data, tak obrázek ternárního digramu.



Obrázek 5.4: Načítání dat z MS Excel, volba počtu řádků



Obrázek 5.5: Zobrazení ternárního diagramu

U obou variant uložení výsledků je možné nastavit, jaká data se mají ukládat. Uživatelský program je vyvíjen pro konkrétní pracoviště, byl zde vytvořen i Help (tj. popisuje ovládání a možnosti nastavení), který má za úkol vést uživatele při nečekaných událostech při obsluze uživatelského programu. Ten se upravuje po každém provedeném zásahu do ovládání nebo jiné zásadní změně v chodu uživatelského programu.

Z poznatků implementace umělých neuronových sítí se vytváří uživatelský program pro výuku umělých neuronových sítí. V programu se nastaví počet vstupů a výstupů a nahraje se do něj příslušný soubor s umělou neuronovou sítí z programu STATISTICA. Program je schopen sám upravit dodaný kód a spustit jej.

## 6 Závěr

Předložená disertační práce se zabývá problematikou predikce v metalurgických procesech. Práce je zaměřena na vytvoření predikčního modelu chemických složek rafinační strusky podle předem určených vstupních chemických složek s využitím umělé neuronové sítě. Při zpracovávání disertační práce bylo spolupracováno s firmou ArcelorMittal Ostrava, a.s.

Práce je rozdělena do třech hlavních částí. První část popisuje technologii výroby oceli a problematiku umělých neuronových sítí. Druhá část se zabývá tvorbou a prezentací jednotlivých umělých neuronových sítí. Třetí část ukazuje vývoj uživatelského programu, ve kterém budou implementovány vybrané predikční modely složené z umělých neuronových sítí.

Model predikce složení strusky je typickým příkladem případu, kdy do modelu vstupuje velké množství vstupních proměnných, které mezi sebou vykazují složité nelineární vazby, které lze jen velmi těžko postihnout matematicky. Z tohoto důvodu se jeví jako výhodné použití umělých neuronových sítí, které jsou vhodné pro aproximaci vztahů mezi různými procesními daty, zejména pak mezi daty nestrukturovanými s vysokým stupněm nelinearity. Správný odhad chemického složení strusek má zásadní význam pro optimalizaci jejich výsledného složení, které ovlivňuje teplotu likvidu tavení strusek, bazicitu a následně sulfidickou kapacitu strusek a tím i odsiřovací schopnosti rafinačních strusek. Při správné predikci můžeme dosáhnout především snížení spotřeby struskotvorných přísad, zejména vápna, čímž se snižuje ekonomická zátěž na výrobu oceli.

Při vytváření umělých neuronových sítí se disertační práce zaměřuje na následující chemické složky strusky - CaO, Al<sub>2</sub>O<sub>3</sub>, SiO<sub>2</sub> a MgO. Tyto chemické složky jsou hlavními nositeli chemického složení a určují, jaké vlastnosti bude mít struska (zda se dá použít k dalšímu zpracování a jak kvalitní bude vyrobená ocel).

Z dostupných dat bylo vytvořeno šest různých variant umělých neuronových sítí. Tyto umělé neuronové sítě vznikaly z různých kombinací vstupních a výstupních dat. V první, druhé a páté variantě měl predikční model jednu umělou neuronovou síť. U těchto variant se predikovaly všechny výstupy najednou. Každá varianta měla jiná data

pro učení umělé neuronové sítě. Ve třetí variantě se predikční model skládal ze dvou umělých neuronových sítí. Byly predikovány zvláště chemické složky CaO, Al<sub>2</sub>O<sub>3</sub>, SiO<sub>2</sub> a MgO a zvláště chemické složky FeO, bazicita, Fe<sub>2</sub>O<sub>3</sub>, MnO, P<sub>2</sub>O<sub>5</sub>, Cr<sub>2</sub>O<sub>3</sub> a S. U čtvrté varianty byl vytvořen predikční model z desíti umělých neuronových sítí. Každý chemický prvek výstupu měl svou vlastní umělou neuronovou síť. Šestá varianta učila umělou neuronovou síť z dominantních složek a legur a výstup obsahoval jen dominantní chemické složky.

U každé varianty je znázorněna struktura vstupů a výstupů umělé neuronové sítě a jsou charakterizována vstupní data. Výsledky jsou prezentovány u všech variant v grafech pro chemické složky CaO, Al<sub>2</sub>O<sub>3</sub>, SiO<sub>2</sub>, které se používají k vykreslování ternárního diagramu. V těchto grafech jsou porovnávány predikované hodnoty chemických složek strusky s hodnotami, které byly získány z chemických analýz. V tabulkách jsou pak uvedeny relativní predikční chyby, průměrné relativní střední odchylky a průměrné rozdíly predikované a reálné výstupní hodnoty dominantních složek. Grafy a tabulky jsou doplněny sloupcovými grafy, které prezentují histogramy reziduí. V závěru každé varianty je tato zhodnocena dle výchozího předpokladu a jsou uvedeny závěry z verze, podle kterých byl pak upřesňován postup dalších prací.

Tento rozsáhlý experimentální materiál byl podkladem pro splnění hlavního cíle disertační práce – vytvoření uživatelského programu, který predikuje chemické složení rafinačních strusek pomocí neuronových sítí.

Celkem bylo vytvořeno v programu STATISTICA 5300 umělých neuronových sítí. Z toho bylo kontrolováno 375 a testováno 88 a v práci je prezentováno 10 umělých neuronových sítí. Z výsledků byly vytvořeny dva predikční modely. První se skládá z jedné umělé neuronové sítě, druhý se skládá ze třech umělých neuronových sítí, kde dvě umělé neuronové sítě predikují každá dvě dominantní složky, a jedna síť predikuje zbylé chemické složky. Oba modely byly implementovány do uživatelského prostředí.

Přínosem disertační práce je také metodika vytváření modelu s mnoha četnými výstupy z více umělých neuronových sítí najednou. Takto koncipovaný model dosahuje daleko lepších výsledků než model složený z jedné umělé neuronové sítě. Dále bylo zjištěno, že ze stále stejných dat se není možno dostat nad určitou hranici kvality naučení umělé neuronové sítě, i když se různě kombinují vstupní a výstupní data pro

učení. Zlepšení predikčních schopností umělého neuronového modelu lze dosáhnout výrazným navýšením a zkvalitněním dat pro učení.

Praktickým přínosem práce je vytvoření uživatelského programu pro predikci chemického složení rafinační strusky. Tento program ukazuje, jaký vliv budou mít legující složky na chemické složení rafinačních strusek. Program dále vykresluje ternární diagram, který znázorňuje teplotu likvidu, která má zásadní vliv na rychlost tvorby strusky a její tekutost. Program také vypočítává hmotnost strusky a hmotnost jednotlivých složek strusky.

Důležitou skutečností je také to, že strukturu vytvořeného uživatelského programu lze použít i k řešení jiných predikčních aplikací v technologických procesech, které zahrnují modely s umělými neuronovými sítěmi.

Uvedené výsledky v disertační práci a dosavadní zkušenosti s aplikacemi umělých neuronových sítí v oblasti sekundární metalurgie ukazují, že jejich použití v této oblasti je perspektivní.

## 7 Použitá literatura

- [1] MELECKÝ, J.; DOBROVSKÝ, L.; DUDEK, R. Posouzení syntetických strusek a jejich provozní využití ve společnosti Mittal Steel Ostrava a.s. In *Sborník z konference Iron and steelmaking*, Malenovice, XV. mezinárodní vědecká konference, 2005. 140 – 144s. ISBN 80-248-0947-8.
- [2] JANČÍKOVÁ, Z. *Umělé neuronové sítě v materiálovém inženýrství*. Monografie, GEP ARTS Ostrava, 2006. 83 s. ISBN 80-248-1174-X.
- [3] VONDRÁK, I. *Umělá inteligence a neuronové sítě*. 1.vyd. Ostrava: VŠB – TU Ostrava, 1994. 140 s.
- [4] ZELINKA, I. *Umělá inteligence I: Neuronové sítě a genetické algoritmy*. 1.vyd. Brno: VUT – Brno 1998, Nakladatelství VUTIUM. 126 s. ISBN 80-214-1163-5.
- [5] BÍLA, J. *Umělá inteligence I: Neuronové sítě v aplikacích*. 1.vyd. Praha: Vydavatelství ČVUT, 1995. 115 s. ISBN 80-01-01275-1.
- [6] NOVÁK, M. *Neuronové sítě a neuropočítače*. 1.vyd. Praha: Senzo, a. s., vydavatelství VÝBĚR, 1992. 192 s. ISBN 80-901245-0-X.
- [7] NOVÁK, M.; KOLEKTIV. *Umělé neuronové sítě. Teorie a aplikace*. 1.vyd. Praha: C. H. Beck, 1998. 328 s. ISBN 80-7179-132-6.
- [8] DRÁBEK, O.; SEIDL, P.; TAUFER I. Umělé neuronové sítě - základy a teorie (3). *CHEMagazin*, 2006, roč. 16, č. 1, s. 12-14.
- [9] VOLNÁ, E. *Neuronové sítě I*. 1.vyd. Ostrava: Přírodovědecká fakulta, Ostravská Univerzita, 2002. 85s. ISBN: 80-7042-762-0.
- [10] RACLAVSKÝ, V. *Metalurgie oceli*. 1.vyd. Ostrava: VŠB – TU Ostrava, 1987. 220 s.
- [11] KALOUSEK, J.; DOBROVSKÝ, L. *Teorie hutních pochodů*. 1.vyd. Ostrava: VŠB – TU Ostrava, 1987. 180 s.
- [12] ADOLF, Z. *Mimopecní rafinace oceli*. 1.vyd. Ostrava: VŠB – TU Ostrava, 1988. 133 s.
- [13] PARMA, V. *Ocelářství I*. 3.vyd. Ostrava: VŠB – TU Ostrava, 1988. 276 s.
- [14] PARMA, V. *Ocelářství II*. 2.vyd. Ostrava: VŠB – TU Ostrava, 1984. 186 s.
- [15] PARMA, V. *Ocelářství III*. 2.vyd. Ostrava: VŠB – TU Ostrava, 1985. 192 s.
- [16] VROŽINA M.; DAVID J.; GARZINOVÁ R. *Studijní Opora část 2. Řízení technologických procesů v metalurgii*. Ostrava: VŠB- TUO, 2008, Dostupné z

- <<https://www.fmmi.vsb.cz/shared/uploadedfiles/fmmi/638-Vrozina-Rizeni-technologickych-procesu-v-metalurgii.pdf>>.
- [17] MIKOLAJEK, J. *Strojní zařízení kontinuálních procesů v metalurgii 1*. 1.vyd. Ostrava: VŠB – TU Ostrava, 1992. 257 s.
- [18] BÖHM, Z. *Výroba oceli v tandemových pecích*. 1.vyd. Praha: SNTL nakladatelství technické literatury, 1984. 229 s.
- [19] BROŽ, L.; KOLEKTIV. *Hutnictví železa*. 1.vyd. Praha: SNTL, 1988. 460 s.
- [20] NUTIL, J.; ČECH, V. *Měření v hutním průmyslu*. 1.vyd. Praha: SNTL, 1982. 316 s.
- [21] ZENHULA, K. *Snímače neelektrických veličin*. 2.vyd. Praha: SNTL, 1983. 371 s.
- [22] MATOUŠEK, D. *C++ Builder vývojové prostředí 1. díl*. 3.vyd. Praha: Technická literatura BEN, 2002. 687 s. ISBN 80-7300-064-4.
- [23] MATOUŠEK, D. *C++ Builder vývojové prostředí 2. díl*. 2.vyd. Praha: Technická literatura BEN, 2003. 575 s. ISBN 80-7300-117-9.
- [24] MATOUŠEK, D. *C++ Builder vývojové prostředí 3. díl*. 1.vyd. Praha: Technická literatura BEN, 2003. 615 s. ISBN 80-7300-063-6.
- [25] PRATA, S. *Mistrovství v C++*. 2.vyd. Brno: CP Books a.s. 2004. 1006s. ISBN 80-251-0098-7.
- [26] WRÓBLEWSKI, P. *Algoritmy, datové struktury a programovací techniky*. Brno CP Books a.s. 2004. ISBN 80-251-0343-9.
- [27] KERNINGHAM, B. W.; RITCHE, D. C. *Programming Language*, 2nd Edition. Hall: Pearson Education, Inc. 1988. 351 s. ISBN 0131103628.
- [28] VIRIUS, M. *Pasti a propasti jazyka C++*. 2.vyd. Brno: CP Books a.s. 2003. 375 s. ISBN 80-251-0509-1
- [29] KADAVÝ, D. *CorelDRAW. Uživatelská příručka*. 1.vyd. Brno: CP Books a.s. 2005. 375 s. ISBN 80-251-0559-8
- [30] *Statistica. Uživatelská příručka*, Praha: Czech edition by StatSoft CR s.r.o. 2004. ISBN 80-238-9116-2.
- [31] *Materiály firmy StatSoft Inc.* c2006 [cit. 12. 3. 2007]. Dostupné z <<http://www.statsoft.cz>>.
- [32] ŠČUREK, R.; ŠVEC, P. *Ochrana letiště před protiprávními činy*, monografie, 1.vyd. Ostrava: Sdružení požárního a bezpečnostního inženýrství, 2009. 135 s. ISBN 978-80-7385-071-5. Kapitola 11, Bezpečnostní informační systém letiště, s. 102-110.

## 8 Seznam publikací doktoranda

- [1] JANČÍKOVÁ, Z.; HEGER, M.; ŠVEC, P.; ŠPIČKA, I. Predikce vybraných parametrů ocelí při tepelném zpracování s využitím prvků umělé inteligence. In *International Conference Principia Cybernetica*, Zlín, 2006. s. 18. ISBN 80-7318-460-5.
- [2] JANČÍKOVÁ, Z.; ŠVEC, P.; ŠPIČKA, I.; HEGER, M. Využití prvků umělé inteligence pro predikci vad kovárenských ingotů, In *International Conference Principia Cybernetica*, ČVUT Praha, 2007. ISBN 978-80-01-03804-8
- [3] JANČÍKOVÁ, Z.; ŠVEC, P. Investigation of Causes of the Forge Ingots Impaired Formability Produced from Vacuum Steel with Artificial Intelligence Elements Exploitation. *Acta Metallurgica Slovaca*, 5/2007, roč. 13, TU Košice, Slovenská republika, 2007. s. 344-348. ISSN-1335-1532.
- [4] JANČÍKOVÁ, Z.; ŠVEC, P. Výzkum příčin zhoršené tvařitelnosti kovárenských ingotů vyrobených z vakuované oceli s využitím prvků umělé inteligence, In *Iron and Steelmaking*, XVII. International Scientific Conference, Štrbské Pleso, Slovenská republika, 2007.
- [5] ŠVEC J.; ŠVEC P. Bodové a nebodové zdroje fyzikálních prací. In *Sborník vědeckých prací VŠB- TUO, Řada bezpečnostního inženýrství*. Ostrava: Vysoká škola báňská – TUO 2007, s. 81-87. ISSN 1801-1764.
- [6] ŠVEC J.; ŠVEC P. Fyzikální veličiny popisující vliv fyzikálních polí na člověka. In *Sborník vědeckých prací VŠB - TUO, Řada bezpečnostního inženýrství*. Ostrava: Vysoká škola báňská – TUO 2008, s. 101-106. ISSN 1801-1764.
- [7] JANČÍKOVÁ, Z.; ŠVEC, P. Application of Artificial Intelligence Methods for Prediction of Chemical Composition of Refining Slag, In *9<sup>th</sup> International Carpatian Control Conference 2008*, Sinaia, Rumunsko, 2008, s. 275-278, ISBN 978-973-746-897-0.
- [8] JANČÍKOVÁ, Z.; MELECKÝ, J.; ŠVEC, P. Aplikace metod umělé inteligence při predikci chemického složení rafinačních strusek, In *International Conference Metal 2008*, Hradec nad Moravicí, 2008, s. 98, ISBN 978-80-254-1987-8.
- [9] JANČÍKOVÁ, Z.; ŠVEC, P. *Prediction of Chemical Composition of Refining Slag With Exploitation of Artificial Neural Networks*, In *Cybernetic Letters, Principia Cybernetica 2008* [cit. 2008-12-31]. Brno: EXPERTIA, o.p.s. ISSN 1802-3525. < <http://www.cybletter.com/index.php?s=2008-II>>
- [10] ZIMNÝ, O.; FRISCHER, R.; BOGAR, M.; ŠVEC, P. The Improvement of Quality of Steelworks Products Using Artificial Neural Network. In *Proceedings International Students' Day of Metallurgy 2009*. Vyd 1. Ostrava: VŠB – TU Ostrava, 2009. ISBN 978-80-248-2006-4.



- [11] ŠVEC, P.; FRISCHER, R.; ZIMNÝ, O.; BOGAR, M. Modern Diagnostic of Technological Device. In *Proceedings International Students' Day of Metallurgy 2009*. vyd. Ostrava: VŠB – TU Ostrava, 2009. ISBN 978-80-248-2006-4.
- [12] FRISCHER, R.; ŠPIČKA, I.; ŠVEC, P. Diskrétní číslicové regulátory a jejich možnosti., In *Sborník Principia Cybernetica*. Košice: Technická univerzita Košice 2009, SR, ISBN 978-80-01-03804-8.
- [13] FRISCHER, R.; ŠPIČKA, I.; ŠVEC, P. Discreet Digital Controlers and Their. In *Transfer Inovácií 2009* [cit. 2009-10-1]. Košice: Ústav technológií a manažmentu, Strojnícka fakulta – Technická univerzita Košice 2009. ISSN 1337-7094. <<http://www.sjf.tuke.sk/transferinovacii/pages/archiv/transfer/14-2009/pdf/074-078.pdf>>
- [14] ŠVEC J.; ŠVEC P. Objemové zmeny látok, In *Sborník vědeckých prací VŠB - TUO, Řada bezpečnostního inženýrství, č. 4*. Ostrava: Vysoká škola báňská – TUO 2009, s. 95 – 103. ISSN 1801-1764.
- [15] ŠČUREK, R.; ŠVEC, P. *Ochrana letiště před protiprávními činy*, monografie vyd.1. Ostrava: Sdružení požárního a bezpečnostního inženýrství, 2009. 135 s. ISBN 978-80-7385-071-5. Kapitola 11, Bezpečnostní informační systém letiště, s. 102-110.