

**ZÁPADOČESKÁ UNIVERZITA V PLZNI
FAKULTA ELEKTROTECHNICKÁ**

KATEDRA TECHNOLOGIÍ A MĚŘENÍ

DIPLOMOVÁ PRÁCE

**Využití umělých neuronových sítí pro analýzu výsledků
materiálových zkoušek**

ZÁPADOČESKÁ UNIVERZITA V PLZNI
Fakulta elektrotechnická
Akademický rok: 2015/2016

ZADÁNÍ DIPLOMOVÉ PRÁCE
(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Jiří VOPAT**
Osobní číslo: **E14N0127P**
Studijní program: **N2612 Elektrotechnika a informatika**
Studijní obor: **Komerční elektrotechnika**
Název tématu: **Využití umělých neuronových sítí pro analýzu výsledků materiálových zkoušek**
Zadávající katedra: **Katedra technologií a měření**

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

1. Proveďte teoretický rozbor druhů a možností použití neuronových sítí pro statistickou analýzu
2. Proveďte základní statistickou analýzu souboru dat dodaných výsledků materiálových zkoušek
3. Analyzujte možnosti 2 zvolených statistických SW v oblasti neuronových sítí
4. Ve zvolených statistických SW použijte všechny dostupné druhy neuronových sítí pro analýzu výsledných dat
5. Porovnejte možnosti a výsledky provedených analýz a vyvoďte závěry

Rozsah grafických prací: podle doporučení vedoucího

Rozsah kvalifikační práce: 40 - 60 stran

Forma zpracování diplomové práce: tištěná/elektronická

Seznam odborné literatury:

1. Novák, M.: Umělé neuronové sítě - Teorie a aplikace, Praha, Nakladatelství C. H. Beck Praha, 1998
2. Meloun, M.; Militký, J.: Statistické zpracování experimentálních dat, East Publishing, 1998
3. Fridrich, V.: Statistika 1, ZČU, 2002
4. manuály k SW

Vedoucí diplomové práce: Ing. Lukáš Kupka, Ph.D.
Katedra technologií a měření

Datum zadání diplomové práce: 15. října 2015
Termín odevzdání diplomové práce: 16. května 2016


Doc. Ing. Jiří Hammerbauer, Ph.D.
děkan




Doc. Ing. Vlastimil Skočil, CSc.
vedoucí katedry

V Plzni dne 15. října 2015

Abstrakt

Práce se zabývá srovnáním programu STATISTICA a QC Expert v oblasti použití neuronových sítí pro statistickou analýzu. Srovnávání jednotlivých metod je provedeno na výsledcích mechanických zkoušek vícevrstvých kompozitů. V úvodní kapitole jsou popsány základní elementární prvky používané v neuronových sítích. Dále se práce zabývá rozdělením neuronových sítí a základním popisem jejich typických představitelů. V praktické části se věnuje jednotlivým analýzám, které je možné provádět ve zmiňovaných programech. Výsledky jednotlivých analýz (předpovědi) jsou vždy zobrazeny v tabulce spolu s příloženými grafy. V závěru je uvedené srovnání využitých programů a v nich použitých analýz.

Klíčová slova

umělá neuronová síť, regrese, klasifikace, shluková analýza, residuum, předpověď

Abstract

The master thesis is focused on a comparison of the program STATISTICA and the program QC Expert. It compares these two programs in the area of using artificial neural networks for the statistical analysis. The comparison of methods is performed on values, which were gained from the mechanical test of multilayer composites. Elementary units used in neural networks are described at the beginning of the thesis. Next part is about a division of neural networks into groups and there is also a basic description of typical types of neural networks. The practical part is about analyses, which are used in statistical software. Results of analyses are displayed in tables and graphs. At the end there is comparison of programs and analyses, which were used in them.

Key words

artificial neural network, regression, classification, cluster analysis, residuum, prediction

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně, s použitím odborné literatury a pramenů uvedených v seznamu, který je součástí této diplomové práce.

Dále prohlašuji, že veškerý software, použitý při řešení této diplomové práce, je legální.

.....
podpis

V Plzni dne 16.5.2016

Jiří Vopat

Poděkování

Tímto bych chtěl poděkovat vedoucímu diplomové práce Ing. Lukáši Kupkovi, Ph.D. za ochotu, vstřícný přístup, odborné rady trpělivost a za čas, který mi věnoval při konzultacích.

Obsah

OBSAH	8
ÚVOD	9
SEZNAM SYMBOLŮ A ZKRATEK	10
1 TEORIE NEURONOVÝCH SÍTÍ	11
1.1 SOUVISLOST BIOLOGICKÉHO NEURONU S PERCEPTRONEM.....	11
1.2 POPIS MODELU UMĚLÉHO NEURONU.....	11
1.3 SYNAPTICKÉ OPERACE.....	12
1.4 SOMATICKÉ OPERACE.....	12
2 NEURONOVÉ SÍTĚ	14
2.1 STRUKTURY NEURONOVÝCH SÍTÍ.....	14
2.2 DRUHY NEURONOVÝCH SÍTÍ.....	15
2.3 VÍCEVRSTVÁ NEURONOVÁ SÍŤ.....	16
2.3.1 Vybavování v MLP.....	16
2.3.2 Učení u MLP sítě.....	16
2.4 RBF SÍŤ.....	17
2.5 KOHONENOVA SÍŤ.....	18
2.5.1 Vybavování v Kohonenově síti.....	19
2.5.2 Učení v Kohonenově síti.....	19
2.6 HOPFIELDOVA SÍŤ.....	20
3 ÚPRAVA DAT PŘED STATISTICKOU ANALÝZOU	21
4 ZÁKLADNÍ STATISTICKÁ ANALÝZA	23
5 STATISTICKÁ ANALÝZA DAT S VYUŽITÍM NEURONOVÝCH SÍTÍ V PROGRAMU STATISTICA	26
5.1 REGRESE.....	26
5.2 KLASIFIKACE.....	35
5.3 SHLUKOVÁ ANALÝZA.....	37
6 STATISTICKÁ ANALÝZA DAT S VYUŽITÍM NEURONOVÝCH SÍTÍ V PROGRAMU QC EXPERT	45
6.1 REGRESE.....	45
6.2 KLASIFIKACE.....	52
7 POROVNÁNÍ PROGRAMŮ	54
7.1 REGRESE.....	54
7.2 KLASIFIKACE.....	59
ZÁVĚR	60
SEZNAM LITERATURY A INFORMAČNÍCH ZDROJŮ	62
PŘÍLOHY	63
PŘÍLOHA A – DATA PODROBOVANÁ ANALÝZÁM.....	63
PŘÍLOHA B - SHLUKOVACÍ STROMY.....	68

Úvod

Existuje celá řada problémů, s jejichž řešením by měly počítače problém (např. rozpoznávání řeči). Pro lidský mozek by však bylo řešení těchto problémů triviální. Neuronová síť představuje zjednodušený matematický model nervových systémů živých organismů. Neuronová síť má stejně jako živý organismus schopnost učit se z předcházejících zkušeností. Není vždy nutná znalost algoritmu. K nalezení řešení postačuje mít dostatek dat a síť sama nastaví své parametry tak, aby našla v této množině dat platné souvislosti. Tento proces umožňuje síti zapamatovat si vzorové příklady a zobecnit platné zákonitosti. Toto zevšeobecnění umožňuje neuronové síti nalézt řešení pro zcela neznámé hodnoty dat.

Neuronové sítě jsou neocenitelným pomocníkem při analýze dat v širokém spektru oblastí. Používají se například k predikci časových řad v ekonomii, kde předpovídají vývoj směnného kurzu a změnu ceny akcií. Uplatnění naleznou v lékařské diagnostice, kde se mohou používat k vyhodnocování lékařských snímků (odhad velikosti nádorového onemocnění). S užitím neuronových sítí lze analyzovat text a určit zda se jedná o písmena či číslice.

Předkládaná práce je zaměřena na použití neuronových sítí při vyhodnocování výsledků materiálových zkoušek. Analýza statistického souboru byla provedena ve 2 programech (STATISTICA, QC Expert) s následným porovnáním výsledků.

Seznam symbolů a zkratk

x_i	vstupní informace
\vec{x}	vektor vstupních informací
n	počet spojů
w_i	synaptická váha
\vec{w}	vektor synaptických vah
b	práh
\oplus	operátor konfluence
z_i	konfluence
u	agregace
ζ	potenciál neuronu
S	přenosová funkce
y	hodnota výstupu
λ	parametr strmosti
F_{\max} [N].....	maximální síla
R_{mo} [MPa].....	pevnost v ohybu
E [MPa].....	Youngův modul vyjádřený z normy
E [N/mm ²].....	Youngův modul vyjádřený ze směrnice mezi 2 body
MLP.....	Multiple Layer Perceptron (vícevrstvá neuronová síť)
RBF.....	Radial Basic Functions (síť s radiální bází)
ANN.....	Automated Neural Network (automatizované neuronové síť)

1 Teorie neuronových sítí

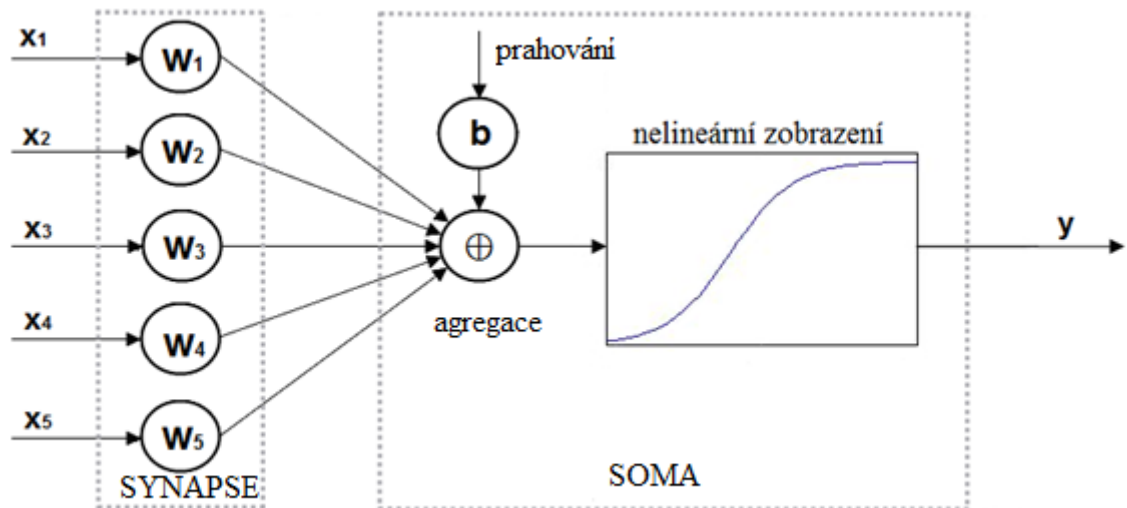
Umělé neuronové sítě jsou sestavy umělých neuronů, které jsou navzájem mezi sebou propojeny spoji. Tyto spoje jsou ohodnoceny váhami. Adaptace těchto vah umožňuje schopnost učení sítě. Neuronové sítě navíc nacházejí souvislosti v trénovacích datech, které jsou reprezentovány prostřednictvím vah. Mají také schopnost generalizace (zevšeobecnování) získaných poznatků, tj. schopnost reagovat na neznámá data, na kterých nebyla síť učena. [4]

1.1 Souvislost biologického neuronu s perceptronem

Na samém začátku je nutné zmínit se o biologickém neuronu, který je předobrazem umělého neuronu (tzv. perceptronu). Lidský neuron se skládá ze 4 částí: z těla (soma), vstupů dendritů, výstupu axonu a synapse. Synapse je rozhraní, kde se stýkají dendrity s axony sousedních neuronů. Dendrity a axon jsou určeny k vedení vzruchů ven z buňky resp. do buňky. V základních matematických modelech neuronu se předpokládá, že tato vedení vzruchů jsou zcela dokonalá. Zbylé dvě části modelu provádějí synaptické a somatické operace. [1]

1.2 Popis modelu umělého neuronu

Do neuronu vstupuje n spojů (axonů), které představují výstupy jiných neuronů. Po každém z těchto vstupů přichází informace x_i ve formě reálného čísla. Každý z těchto spojů je ohodnocen reálným číslem (synaptickou) váhou w_i , která udává důležitost spoje. Synapse umožňuje provést operaci konfluence vstupů do neuronu a předcházejících zkušeností v podobě zmíněných vah. Soma přijme signály ze synapse a provádí operaci agregace, tj. váženou sumaci vstupních signálů. Když je hodnota této agregace vyšší než určitý práh b , neuron se aktivuje. Na výstupu se potom objeví signál, který je nelineární funkcí této vážené sumy. V těle neuronu se uplatňují 3 matematické operace: agregace, prahování a nelineární zobrazení. Matematický model neuronu je uveden na *Obr. 1.1*. [1, 2, 3]



Obr. 1.1 Matematický model neuronu

1.3 Synaptické operace

Vektor synaptických vah umožňuje uložit zkušenosti do neuronu, se schopností adaptovat se na nové zkušenosti získané pomocí učení. Konfluence kombinuje vstupní vektor \vec{x} s vektorem synaptických vah \vec{w} a přiřazuje každé složce vstupního vektoru určitou váhu, která odpovídá uložené zkušenosti. [1] Lze ji popsat tímto vztahem:

$$z_i = x_i \oplus w_i, i=1, 2, \dots, n \quad (1.2)$$

kde \oplus je operátor konfluence. Pro základní model přechází tento operátor na lineární případ, takže tento vztah lze přepsat na tvar:

$$z_i = x_i w_i, i=1, 2, \dots, n \quad (1.3)$$

1.4 Somatické operace

Agregace provádí sloučení vstupních signálů vektoru z_i , v jednoduchém modelu lze vyjádřit pomocí sumace:

$$u = \sum_{i=1}^n z_i \quad (1.4)$$

Vážený součet udává tzv. potenciál neuronu. ξ :

$$\xi = \sum_{i=1}^n x_i w_i - b = \sum_{i=0}^n w_i x_i \quad (1.5)$$

Na tento potenciál reaguje neuron výstupní odezvou $y = S(\xi)$, kde S je nelineární, též přenosová nebo také aktivační funkce a b je prahová hodnota. Když je hodnota u nižší než práh b , výstupní signál bude odpovídat pasivnímu stavu neuronu. Při překročení prahu roste výstupní signál monotónně až do saturované hodnoty. Hodnota výstupu y je určena oborem hodnot funkce S jak pro pasivní tak pro saturovaný stav neuronu. Jednou z nejčastěji používaných funkcí je tzv. sigmoida. Tato funkce lze vyjádřit pomocí vztahu:


$$y(\xi) = S(\xi) = 1/(1 + e^{-\lambda\xi}) \quad (1.6)$$

kde λ je parametr strmosti. Velikost strmosti ovlivňuje sklon střední části funkce, kterou lze považovat za lineární a má velký vliv na proces učení neuronové sítě. Sigmoidální funkce (*Obr. 1.8*) je využívána pro svou spojitost, je tedy diferencovatelná v celém oboru reálných čísel. Používají se dva typy aktivačních funkcí. Modely s nespojitými přenosovými funkcemi bývají také označovány jako modely první generace. Mezi ně patří například Heavisideova funkce (funkce pro jednotkový skok) – *Obr. 1.9*. Modely druhé generace používají spojitě aktivační funkce. Nejčastěji se používá sigmoida, uplatnění nalezne též hyperbolický tangens nebo Gaussova křivka. [1,3]


Všechny operace probíhající v modelu lze zapsat pomocí tabulky:

Tab. 1.7 Vlastnosti základního modelu [1]

SYNAPTICKÉ OPERACE	konfluence	$z_i = x_i w_i$
SOMATICKÉ OPERACE	agregace	$u = \sum_{i=1}^n z_i$
	prahování	$\xi = u - b$
	nelin. zobrazení	$y = 1/(1 + \exp(-\lambda\xi))$



Obr. 1.8 Sigmoidální funkce




Obr. 1.9 Heavisideova funkce

2 Neuronové sítě

2.1 Struktury neuronových sítí

Neurony jsou sdružovány do vrstev a vytvářejí vícevrstvou perceptronovou síť (MLP). Perceptrony sousedících vrstev jsou navzájem propojeny tak, že výstup z jednoho neuronu určité vrstvy se distribuuje do vstupu perceptronů následující vrstvy. První vrstva se označuje jako vstupní vrstva. Poslední vrstva je vrstvou výstupní. Mezi těmito vrstvami se nacházejí skryté vrstvy. Počet vrstev a počet neuronů v těchto vrstvách závisí na druhu úlohy. [1,6]



Obr. 2.1 Třívrstvá perceptronová síť s dopředným šířením signálu se 4 vstupy a 2 výstupy

Ve vyjádření počtu vrstev panuje značná rozporuplnost. V některých publikacích se mezi vrstvy nepočítá vrstva vstupní, v některých dokonce ani vrstva výstupní. Na perceptronovou síť uvedenou na Obr. 2.1 lze tedy nahlížet také jako na dvouvrstvou síť. Tyto sítě se používají pro klasifikaci vstupů do tříd (výrobků, poskytování úvěrů), pro predikci (regresi) dat na základě dostatečně velké historie dat (např. teplota, poptávka na trhu, apod.) [1, 3, 8]

2.2 Druhy neuronových sítí


Neuronové sítě je možné rozdělit podle struktury do 2 skupin:

- **sítě s dopředným šířením signálu** (feedforward network)

Signál postupuje pouze ze vstupní vrstvy do výstupní vrstvy. Takováto síť je uvedena na *Obr. 2.1*. Dopředné sítě je možné dále dělit na dvě skupiny podle funkce, která je jimi realizována. Je to funkce lineární a nelineární.

- **sítě se zpětnou vazbou** (rekurentní síť, feedback network)

V těchto sítích se signál může šířit na rozdíl od dopředných sítí také z výstupu zpátky na vstup. Tato struktura umožňuje výpočty založené na iteracích, čehož se využívá například v optimalizačních úlohách. [2,6]



Obr. 2.2 Neuronová síť se zpětnou vazbou – Hopfieldova síť [4]

Nelineární neuronové sítě s dopředným šířením lze dělit podle procesu učení. Učení může probíhat buď s učitelem (supervised learning) anebo bez učitele (unsupervised learning). Při prvním způsobu je zapotřebí tzv. trénovací množina. Jedná se o dvojici složenou ze vstupu a očekávaného výstupu. Neuronové sítě se předkládají dvojice z trénovací množiny, a to několikrát a navíc v náhodném pořadí. Pro každý předložený vstup vygeneruje neuronová síť hodnotu skutečného výstupu. Tato hodnota je porovnána s požadovaným výstupem. Pokud se požadovaný výstup od toho skutečného liší. Trénovací algoritmus upraví hodnotu vah a prahů, tak aby byl tento rozdíl minimální. [2,6]

Při učení bez učitele se sítě předkládají pouze vstupy, požadovaný výstup (informace učitele) chybí. Síť se sama snaží nalézt souvislosti ve vstupních datech a nastavuje hodnoty svých vah a prahů, tak aby na podobné vstupy bylo zareagováno podobnými výstupy.[6]

2.3 Vícevrstvá neuronová síť

Vícevrstvá neuronová síť MLP (Multiple Layer Perceptron) byla popsána v podkapitole 2.1. Tato síť je nejpoužívanější neuronovou sítí vůbec. Používá se pro regresní a klasifikační úlohy. V této práci bude primární neuronovou sítí používanou ve zvolených programech.

2.3.1 Vybavování v MLP

Při vybavování se přiloží vzor na vstupy sítě a dochází k jeho transformaci přes váhy neuronů jednotlivých vrstev k výstupům sítě. Postupně jsou vypočítávány potenciály od první po poslední vrstvu podle vztahu (1.5). Na jejich základě jsou vypočítány hodnoty výstupů pro další vrstvu. V následující vrstvě se provádí výpočet podle vztahu:

$$y = f(\xi) \quad (2.3)$$

kde f je nejčastěji sigmoidální funkce nebo jakákoliv jiná diferencovatelná funkce. Výstupy z poslední vrstvy jsou přímo výstupními hodnotami sítě. [4]

2.3.2 Učení u MLP sítě

Při učení je snahou nastavit váhy tak, aby odchylka mezi skutečným a předpovídaným výstupem byla minimální vzhledem k předkládaným trénovacím hodnotám. Tato odchylka je definována předpisem:

$$E = \sum_k E_k \quad (2.4)$$

kde index k zajišťuje průchod přes všechny trénovací vzory a E_k je chyba daná vztahem:

$$E_k = \frac{1}{2} \sum_j (y_j - d_{kj}) \quad (2.5)$$

kde j umožňuje procházení jednotlivých neuronů výstupní vrstvy a d_{kj} je j -tý prvek žádaného výstupu k -tého trénovacího vzoru. [4]

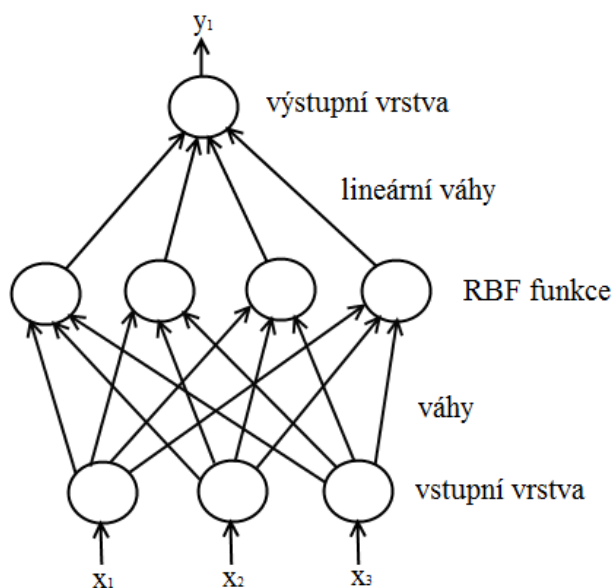
2.4 RBF síť

RBF síť (Radial Basic Function) je 2 vrstvá síť bez zpětné vazby, nepočítá-li se s vrstvou vstupní. Tato síť má rychlejší průběh učení a využívá se hlavně pro složitější úlohy s rozsáhlým učicím souborem. Ve druhé vrstvě se nacházejí neurony s lineární aktivační funkcí. V první vrstvě jsou všechny váhy rovné 1 s radiálními neurony, tzn. že každý neuron této vrstvy je zastoupen tzv. radiální funkcí $f(r_i)$. Je to funkce vzdálenosti r_i mezi vstupním vektorem vstupních informací \vec{x} a centroidem \vec{c}_i i -tého neuronu. [2, 8] Pro výstup i -tého neuronu z 1. vrstvy platí:

$$y_i = f(r_i) \quad (2.6)$$

obvykle se jedná o Eukleidovskou vzdálenost:

$$r_i = \sqrt{(\vec{x} - \vec{c}_i)^T (\vec{x} - \vec{c}_i)} \quad (2.7)$$



Obr. 2.8 RBF síť


Tato síť se používá k aproximaci více rozměrných nelineárních funkcí. Uplatnění by mohla nalézt ve složitých klasifikačních a regresních úlohách. Tato síť však není schopná konkurovat vícevrstvé neuronové síti v jednodušších úlohách. Ve svých vrstvách používá totiž podstatně více neuronů než MLP.

2.5 Kohonenova síť

Kohonenova síť, též označovaná jako samoorganizující se mapa (SOM), nepotřebuje k učení učitele. Během učení nastavuje své váhy a prahy tak, aby na podobné vstupní hodnoty reagovala podobnými výstupy, a tak dochází ke shlukování a třídění vstupních dat. Kohenovy sítě se používají:


- ke zpracování řeči, obrazu
- k úpravě zvuku
- k detekci osob podle fotografií
- při přepisu ručně psaného textu na tištěný

Jedná se o jednovrstvou síť s dopředným šířením. Tato jediná vrstva se označuje jako kompetiční vrstva. Vstupy sítě jsou propojeny se všemi neurony, tzn. že každý neuron má přístup k informacím ze všech vstupů [2, 4,7].



Obr. 2.9 Struktura Kohonenovy sítě [4]

Neurony v první vrstvě mají mezi sebou postranní vazby, které jsou uspořádány nejčastěji do čtvercové mřížky (Obr. 2.10). Na váhy příslušných neuronů lze nazírat jako na souřadnice udávající umístění neuronu v prostoru. Tato síť se sama snaží objevit souvislosti ve vstupních datech na základě některé společné vlastnosti nebo výrazné odlišnosti. [2, 4, 7]



Obr. 2.10 Uspořádání Kohonenovy sítě se 2 vstupy a čtvercovou mřížkou tvořenou 9 neurony [4]

2.5.1 Vybavování v Kohonenově síti

Pro vybavování je zapotřebí vypočítat vzdálenosti d_j , které jsou mezi předloženým vzorem a vahami všech neuronů umístěných v kompetiční vrstvě. Využívá se k tomu vzorec:

$$d_j = \sum_{i=1}^m (x_i - w_{ij})^2 \quad (2.11)$$

kde koeficient j umožňuje procházet všechny neurony, kterých je m , v kompetiční vrstvě. x_i jsou prvky předkládaného vzoru a w_{ij} jsou váhy neuronů. Vybere se právě ten neuron, jehož vzdálenost od předloženého vzoru je minimální. Tento neuron se také někdy označuje jako vítězný. Výstup tohoto neuronu je aktivní, výstupy u zbylých neuronů jsou neaktivní. [4]

2.5.2 Učení v Kohonenově síti

Algoritmus Kohonenovy sítě provádí vektorovou kvantizaci: snaží rozmístit neurony v kompetiční vrstvě tak, aby rozdělení neuronů aproximovalo k pravděpodobnostnímu rozdělení trénovacích vzorů. Při učení se porovnávají vstupní vzory s hodnotami uloženými v každém neuronu. V případě nalezení neuronu, jenž je nejbližší trénovacímu vzoru, upraví síť váhy tohoto nalezeného neuronu včetně vah neuronů, které se vyskytují v okolí tohoto neuronu. Před učením jsou váhy neuronů nastaveny náhodně, rozmístění

neuronů v první vrstvě je také náhodné. Vlivem učení se rozmístění neuronů přibližuje rozdělení trénovacích vzorů. [4]

2.6 Hopfieldova síť

Hopfieldova síť (Obr. 2.2) má stejný počet neuronů n jako je vstupů, resp. výstupů sítě, protože každý z těchto neuronů je zároveň vstupní i výstupní. Všechny tyto neurony mají jeden externí vstup a výstup. Každý výstup neuronu je spojen s každým vstupem neuronu (kromě sebe samotného), tak že se vytvoří uzavřená smyčka. Tyto spoje jsou ohodnoceny váhami w_{ij} , kde $i = 1, 2, \dots, n$; a $j = 1, 2, \dots, n$. Pro tyto váhy, které jsou stejné v obou směrech, platí: $w_{ij} = w_{ji}$. Proto že nelze přivést vstup neuronů na jejich vlastní výstup platí také: $w_{ii} = 0$. Takovýmto uspořádáním vznikne diagonálně symetrická váhová matice s nulami na hlavní diagonále. Tato síť je zpětnovazební. Vyžaduje aktualizaci stavů pomocí iterací. Hopfieldova síť se používá jako asociativní paměť, jejíž kapacita je omezená. Umožňuje vybavování informace na základě její částečné znalosti. Používá se též jako klasifikátor např. při rozpoznávání obrazu OCR (Optical Character Recognition), k rozpoznávání státních poznávacích značek, apod. Uplatnění nalezne též při řešení optimalizačních úloh (rozvrhování výroby, hledání nejkratší cesty). [1, 2, 3, 4, 8]


Pro popis učení Hopfieldovi sítě musí být zavedena Energetická funkce:

$$E = -\frac{1}{2} \sum_i \sum_j w_{ij} x_i x_j \quad (2.12)$$

Hodnota energetické funkce je velká pro velké chyby a malá pro malé chyby. Změnou hodnot vah lze ovlivnit velikost této funkce. Při procesu učení se provádí minimalizace energetické funkce, čím menší chyba tím snáze si síť vzor zapamatuje[4].

3 Úprava dat před statistickou analýzou

Před samotnou analýzou bylo zapotřebí odstranit extrémní a odlehlé hodnoty. První tři hodnoty byly pokusné. U dalších dvou hodnot bylo patrné, že se jedná o extrémy, a proto bylo možné je odebrat. Zbylé odlehlé hodnoty vyskytující se v datovém souboru, které nešly nalézt zběžným pohledem, bylo možné odhalit pomocí shlukovacího stromu v programu STATISTICA. Po odstranění hodnot, které byly nejvíce odlehlé (viz. Příloha Tab. A5), byla data rozdělena na trénovací a zkušební. V příloze je také zobrazen celý shlukovací strom, jehož osu nebylo možné zobrazit v čitelném měřítku (Obr. B1). A proto byly tyto vyškrtnuté hodnoty zvětšeny v Obr. 3.1. Data byla rozdělena do 10 skupin podle kombinace hustoty výztuže a počtu vrstev výztuže. Tato kombinace bude v této práci označována jako *úroveň výztuže*. Hodnoty z každé z těchto skupin byly sestaveny v rámci svého bloku podle velikosti pevnosti v ohybu R_{m0} od nejmenší po největší. Z každého tohoto bloku byly vybrány dvě čísla. Jedno zepředu druhé zezadu z přibližně stejné pozice. Mezi zkušební hodnoty byly zařazeny také mediány vypočtené z každého bloku. Tyto hodnoty se nepodílely na trénování sítě. Byly pouze použity pro ověření schopnosti sítě predikovat neznámé hodnoty. Část trénovacích dat byla použita pro testování sítě, část pro validaci sítě. Testovací data slouží k zastavení procesu trénování, aby nedošlo k přetrénování sítě. Validační data slouží k ověření kvality modelu. [11] Poměr mezi trénovacími, testovacími a validačními daty byl určen volbou v příslušném programu. Program pak už sám automaticky volil hodnoty.



Obr. 3.1 Odlehlé hodnoty (zvětšeno)

V obdržených datech figurovala veličina F_{\max} . Tato síla závisela na geometrických rozměrech vzorku. Ty byly u každého vzorku jiné, a proto nebylo vhodné tento parametr používat při daných analýzách. Zbylé veličiny: pevnost v ohybu R_{mo} , činitel pružnosti též označovaný jako Youngův modul E , který je zastoupen v obdržených datech dvakrát. Jedná se o tutéž veličinu vyjádřenou různými způsoby. Youngovi moduly popisují stejnou veličinu: jeden podle normy, druhý podle směrnice mezi dvěma body, takže je nevhodné predikovat Youngův modul zjištěný jedním způsobem z Youngova modulu zjištěného druhým způsobem (regrese). Činitelé pružnosti mají mezi sebou vysoký koeficient korelace, což se dalo očekávat, protože tyto veličiny jsou z hlediska materiálového pohledu na sobě velmi závislé.

Correlations (shluky_vše_ořezáno)	
Marked correlations are significant at $p < ,05000$	
N=270 (Casewise deletion of missing data)	
Variable	E[N/mm2] E[MPa]
Rmo[MPa]	0,87 0,93
E[N/mm2]	1,00 0,96

Obr. 3.2 Koeficienty korelace

Činitel pružnosti E vyjádřený v MPa je definován v normě ČSN EN 60672_2. Jedná se o namáhání, které je zapotřebí k tomu, aby v materiálu vyvolalo jednotkovou jednoosou deformaci v tahu nebo v tlaku.

Při měření se používá metoda, při které se z užívaného rozsahu zvolí spodní hranice síly, jež je větší nebo rovna 10 % maximální hodnoty síly. Zvolí se horní hranice síly, která je menší nebo rovna 90 % maxima používané síly. Dopočtou se posuny ze změny síly mezi těmito dvěma úrovněmi. Jednotlivé posuny lišící se o více než 5 % od průměrné hodnoty všech měření se vypustí. Ze zbylých hodnot se dopočte průměr. [10]

Pro tříbodový ohyb se postupuje dle metody popsané výše za použití vzorce:

$$E = \frac{F * l^3 * 10^{-3}}{4 * f * b * h^3} \quad (3.3)$$

kde: F [N] je rozdíl mezi horní a spodní hranicí síly zvolené při výpočtu průhybu
 l [mm] je vzdálenost mezi středy podpěrných válečků
 f [mm] je průměrná hodnota průhybu měřená uprostřed zkušebního kusu odpovídající síle F

b [mm] je šířka zkušebního kusu

h [mm] je tloušťka zkušebního kusu

$$MPa = N/mm^2 \quad (3.4)$$

Platnost tohoto vztahu a absence veličiny F_{max} umožňuje data po ořezání analyzovat rovnou bez standardizace.

4 Základní statistická analýza

Statistická analýza byla provedena pro každou skupinu vzorků v programu Microsoft Excel. K tomuto účelu byl využit nástroj popisná statistika.

Tab. 4.1 Tabulky základních statistických analýz pro materiály s úrovní výztuže:

a) bez výztuže, b) nízka 1;

a)

bez výztuže					
R _{mo}	[Mpa]	E	[N/mm2]	E	[MPa]
Stř. hodnota	3 042,18	Stř. hodnota	12 736 845,85	Stř. hodnota	16 757 957,38
Chyba stř. hodnoty	41,86	Chyba stř. hodnoty	193 528,31	Chyba stř. hodnoty	213 961,64
Medián	3 049,00	Medián	12 739 389,00	Medián	16 739 894,50
Směr. odchylka	213,47	Směr. odchylka	986 804,60	Směr. odchylka	1 090 994,57
Rozptyl výběru	45 569,05	Rozptyl výběru	9,74E+11	Rozptyl výběru	1,19E+12
Špičatost	-0,09	Špičatost	-0,63	Špičatost	-0,78
Šikmost	-0,27	Šikmost	-0,07	Šikmost	-0,05
Rozdíl max-min	889	Rozdíl max-min	3 630 945	Rozdíl max-min	4 168 866
Minimum	2 540	Minimum	10 817 720	Minimum	14 527 922
Maximum	3 429	Maximum	14 448 665	Maximum	18 696 788
Součet	79 097	Součet	331 157 992	Součet	435 706 892
Počet	26	Počet	26	Počet	26
Největší (1)	3 429	Největší (1)	14 448 665	Největší (1)	18 696 788
Nejmenší (1)	2 540	Nejmenší (1)	10 817 720	Nejmenší (1)	14 527 922

b)

nízka 1					
R _{mo}	[Mpa]	E	[N/mm2]	E	[MPa]
Stř. hodnota	2986,531	Stř. hodnota	11 059 869,96	Stř. hodnota	15 078 985,30
Chyba stř. hodnoty	43,27133	Chyba stř. hodnoty	190 473,73	Chyba stř. hodnoty	188 227,67
Medián	3024,25	Medián	11 189 336,00	Medián	15 206 869,00
Směr. odchylka	224,8444	Směr. odchylka	989 730,52	Směr. odchylka	978 059,64
Rozptyl výběru	50555,01	Rozptyl výběru	9,80E+11	Rozptyl výběru	9,57E+11
Špičatost	0,064603	Špičatost	-0,95	Špičatost	-0,42
Šikmost	-0,43633	Šikmost	0,26	Šikmost	-0,39
Rozdíl max-min	982,98	Rozdíl max-min	3 472 565	Rozdíl max-min	3 969 793
Minimum	2441,06	Minimum	9 492 998	Minimum	12 763 491
Maximum	3424,04	Maximum	12 965 563	Maximum	16 733 284
Součet	80636,33	Součet	298 616 489	Součet	407 132 603
Počet	27	Počet	27	Počet	27
Největší (1)	3424,04	Největší (1)	12 965 563	Největší (1)	16 733 284
Nejmenší (1)	2441,06	Nejmenší (1)	9 492 998	Nejmenší (1)	12 763 491

c) nízká 2, d) nízká 3, e) střední 1, f) střední 2;

c)

nízká 2					
R _{mo}	[Mpa]	E	[N/mm ²]	E	[MPa]
Stř. hodnota	1 809,31	Stř. hodnota	6 682 853,72	Stř. hodnota	5 724 820,61
Chyba stř. hodnoty	37,58	Chyba stř. hodnoty	132 982,13	Chyba stř. hodnoty	80 121,35
Medián	1 834,88	Medián	6 669 323,50	Medián	5 798 808,00
Směr. odchylka	195,28	Směr. odchylka	690 995,42	Směr. odchylka	416 322,75
Rozptyl výběru	38 134,78	Rozptyl výběru	4,77E+11	Rozptyl výběru	1,73E+11
Špičatost	4,24	Špičatost	-0,75	Špičatost	1,41
Šikmost	-1,88	Šikmost	0,15	Šikmost	-1,28
Rozdíl max-min	841	Rozdíl max-min	2 625 160	Rozdíl max-min	1 704 560
Minimum	1 172	Minimum	5 589 379	Minimum	4 591 615
Maximum	2 013	Maximum	8 214 539	Maximum	6 296 175
Součet	48 851	Součet	180 437 051	Součet	154 570 157
Počet	27	Počet	27	Počet	27
Největší (1)	2 013	Největší (1)	8 214 539	Největší (1)	6 296 175
Nejmenší (1)	1 172	Nejmenší (1)	5 589 379	Nejmenší (1)	4 591 615

d)

nízká 3					
R _{mo}	[Mpa]	E	[N/mm ²]	E	[MPa]
Stř. hodnota	2 040,61	Stř. hodnota	6 920 651,41	Stř. hodnota	6 089 291,66
Chyba stř. hodnoty	19,99	Chyba stř. hodnoty	116 432,07	Chyba stř. hodnoty	61 529,18
Medián	2 056,65	Medián	6 940 316,50	Medián	6 082 039,75
Směr. odchylka	105,75	Směr. odchylka	616 100,60	Směr. odchylka	325 581,83
Rozptyl výběru	11 183,35	Rozptyl výběru	3,80E+11	Rozptyl výběru	1,06E+11
Špičatost	1,81	Špičatost	1,35	Špičatost	-0,84
Šikmost	0,82	Šikmost	-0,19	Šikmost	-0,28
Rozdíl max-min	482	Rozdíl max-min	3 097 822	Rozdíl max-min	1 140 925
Minimum	1 886	Minimum	5 383 332	Minimum	5 520 110
Maximum	2 368	Maximum	8 481 153	Maximum	6 661 035
Součet	57 137	Součet	193 778 240	Součet	170 500 167
Počet	28	Počet	28	Počet	28
Největší (1)	2 368	Největší (1)	8 481 153	Největší (1)	6 661 035
Nejmenší (1)	1 886	Nejmenší (1)	5 383 332	Nejmenší (1)	5 520 110

e)

střední 1					
R _{mo}	[Mpa]	E	[N/mm ²]	E	[MPa]
Stř. hodnota	2 176,06	Stř. hodnota	7 453 293,25	Stř. hodnota	8 191 862,81
Chyba stř. hodnoty	33,62	Chyba stř. hodnoty	117 801,87	Chyba stř. hodnoty	123 977,18
Medián	2 225,52	Medián	7 415 773,25	Medián	8 206 812,75
Směr. odchylka	171,41	Směr. odchylka	600 674,02	Směr. odchylka	632 162,05
Rozptyl výběru	29 381,40	Rozptyl výběru	3,61E+11	Rozptyl výběru	4,00E+11
Špičatost	-1,05	Špičatost	1,77	Špičatost	1,60
Šikmost	-0,29	Šikmost	0,83	Šikmost	0,88
Rozdíl max-min	602	Rozdíl max-min	2 860 676	Rozdíl max-min	2 957 443
Minimum	1 884	Minimum	6 315 015	Minimum	7 023 169
Maximum	2 486	Maximum	9 175 691	Maximum	9 980 612
Součet	56 578	Součet	193 785 625	Součet	212 988 433
Počet	26	Počet	26	Počet	26
Největší (1)	2 486	Největší (1)	9 175 691	Největší (1)	9 980 612
Nejmenší (1)	1 884	Nejmenší (1)	6 315 015	Nejmenší (1)	7 023 169

f)

střední 2					
R _{mo}	[Mpa]	E	[N/mm ²]	E	[MPa]
Stř. hodnota	1 989,33	Stř. hodnota	7 164 084,24	Stř. hodnota	7 719 687,11
Chyba stř. hodnoty	32,52	Chyba stř. hodnoty	110 174,98	Chyba stř. hodnoty	104 807,04
Medián	2 012,69	Medián	7 222 372,50	Medián	7 608 179,50
Směr. odchylka	168,97	Směr. odchylka	572 485,99	Směr. odchylka	544 593,37
Rozptyl výběru	28 550,32	Rozptyl výběru	3,28E+11	Rozptyl výběru	2,97E+11
Špičatost	0,75	Špičatost	-0,84	Špičatost	-1,10
Šikmost	-0,66	Šikmost	-0,23	Šikmost	0,07
Rozdíl max-min	743	Rozdíl max-min	2 157 047	Rozdíl max-min	1 882 007
Minimum	1 576	Minimum	5 952 733	Minimum	6 779 134
Maximum	2 318	Maximum	8 109 780	Maximum	8 661 140
Součet	53 712	Součet	193 430 275	Součet	208 431 552
Počet	27	Počet	27	Počet	27
Největší (1)	2 318	Největší (1)	8 109 780	Největší (1)	8 661 140
Nejmenší (1)	1 576	Nejmenší (1)	5 952 733	Nejmenší (1)	6 779 134

g) střední 3, h) vysoká 1, i) vysoká 2, j) vysoká 3

g)

střední 3					
R _{mo}	[Mpa]	E	[N/mm2]	E	[MPa]
Stř. hodnota	1 952,10	Stř. hodnota	7 273 379,98	Stř. hodnota	7 730 187,65
Chyba stř. hodnoty	26,08	Chyba stř. hodnoty	109 057,54	Chyba stř. hodnoty	96 383,64
Medián	1 942,97	Medián	7 073 823,50	Medián	7 640 536,00
Směr. odchylka	135,53	Směr. odchylka	566 679,61	Směr. odchylka	500 824,11
Rozptyl výběru	18 367,71	Rozptyl výběru	3,21E+11	Rozptyl výběru	2,51E+11
Špičatost	0,43	Špičatost	-0,25	Špičatost	-0,65
Šikmost	0,25	Šikmost	0,74	Šikmost	0,04
Rozdíl max-min	611	Rozdíl max-min	2 179 477	Rozdíl max-min	1 937 786
Minimum	1 660	Minimum	6 446 749	Minimum	6 709 359
Maximum	2 271	Maximum	8 626 225	Maximum	8 647 144
Součet	52 707	Součet	196 381 260	Součet	208 715 067
Počet	27	Počet	27	Počet	27
Největší (1)	2 271	Největší (1)	8 626 225	Největší (1)	8 647 144
Nejmenší (1)	1 660	Nejmenší (1)	6 446 749	Nejmenší (1)	6 709 359

h)

vysoká 1					
R _{mo}	[Mpa]	E	[N/mm2]	E	[MPa]
Stř. hodnota	2 026,88	Stř. hodnota	7 917 805,98	Stř. hodnota	8 408 014,36
Chyba stř. hodnoty	26,10	Chyba stř. hodnoty	107 215,89	Chyba stř. hodnoty	85 984,02
Medián	2 006,73	Medián	7 783 321,75	Medián	8 424 612,00
Směr. odchylka	138,12	Směr. odchylka	567 333,19	Směr. odchylka	454 984,66
Rozptyl výběru	19 077,38	Rozptyl výběru	3,22E+11	Rozptyl výběru	2,07E+11
Špičatost	1,14	Špičatost	0,19	Špičatost	1,04
Šikmost	0,94	Šikmost	0,47	Šikmost	-0,30
Rozdíl max-min	593	Rozdíl max-min	2 278 634	Rozdíl max-min	2 232 873
Minimum	1 813	Minimum	6 849 104	Minimum	7 176 406
Maximum	2 406	Maximum	9 127 738	Maximum	9 409 279
Součet	56 753	Součet	221 698 568	Součet	235 424 402
Počet	28	Počet	28	Počet	28
Největší (1)	2 406	Největší (1)	9 127 738	Největší (1)	9 409 279
Nejmenší (1)	1 813	Nejmenší (1)	6 849 104	Nejmenší (1)	7 176 406

i)

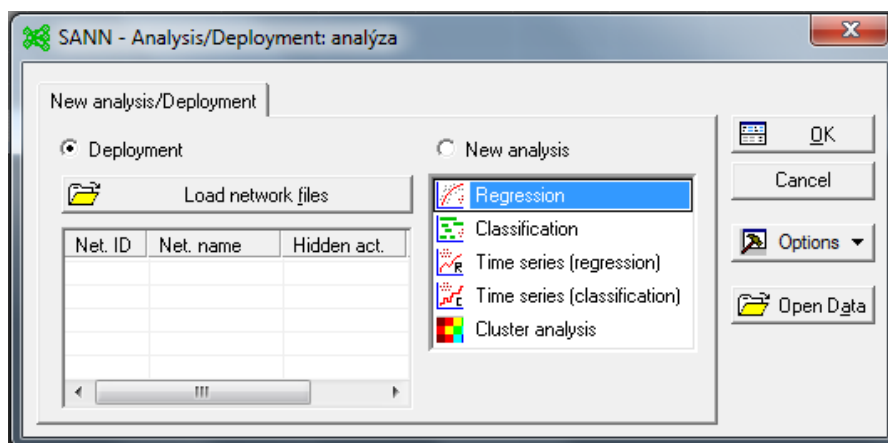
vysoká 2					
R _{mo}	[Mpa]	E	[N/mm2]	E	[MPa]
Stř. hodnota	2 067,78	Stř. hodnota	7 941 408,98	Stř. hodnota	8 309 141,11
Chyba stř. hodnoty	29,85	Chyba stř. hodnoty	106 290,31	Chyba stř. hodnoty	80 012,10
Medián	2 090,66	Medián	8 034 752,00	Medián	8 282 645,00
Směr. odchylka	157,94	Směr. odchylka	562 435,48	Směr. odchylka	423 384,25
Rozptyl výběru	24 944,51	Rozptyl výběru	3,16E+11	Rozptyl výběru	1,79E+11
Špičatost	17,45	Špičatost	-0,20	Špičatost	1,68
Šikmost	-3,68	Šikmost	0,00	Šikmost	-0,77
Rozdíl max-min	968	Rozdíl max-min	2 213 731	Rozdíl max-min	1 977 183
Minimum	1 343	Minimum	6 901 019	Minimum	7 036 452
Maximum	2 311	Maximum	9 114 750	Maximum	9 013 635
Součet	57 898	Součet	222 359 452	Součet	232 655 951
Počet	28	Počet	28	Počet	28
Největší (1)	2 311	Největší (1)	9 114 750	Největší (1)	9 013 635
Nejmenší (1)	1 343	Nejmenší (1)	6 901 019	Nejmenší (1)	7 036 452

j)

vysoká 3					
R _{mo}	[Mpa]	E	[N/mm2]	E	[MPa]
Stř. hodnota	2 004,93	Stř. hodnota	7 701 161,38	Stř. hodnota	8 133 818,90
Chyba stř. hodnoty	24,00	Chyba stř. hodnoty	125 102,42	Chyba stř. hodnoty	117 392,35
Medián	2 000,72	Medián	7 758 620,25	Medián	8 212 794,50
Směr. odchylka	122,37	Směr. odchylka	637 899,70	Směr. odchylka	598 585,89
Rozptyl výběru	14 974,54	Rozptyl výběru	4,07E+11	Rozptyl výběru	358 305 073 620
Špičatost	0,88	Špičatost	1,36	Špičatost	0,72
Šikmost	0,28	Šikmost	-0,25	Šikmost	-0,74
Rozdíl max-min	550	Rozdíl max-min	3 131 685	Rozdíl max-min	2 518 845
Minimum	1 783	Minimum	6 043 994	Minimum	6 690 630
Maximum	2 334	Maximum	9 175 679	Maximum	9 209 474
Součet	52 128	Součet	200 230 196	Součet	211 479 292
Počet	26	Počet	26	Počet	26
Největší (1)	2 334	Největší (1)	9 175 679	Největší (1)	9 209 474
Nejmenší (1)	1 783	Nejmenší (1)	6 043 994	Nejmenší (1)	6 690 630

5 Statistická analýza dat s využitím neuronových sítí v programu STATISTICA

Program STATISTICA disponuje modulem ANN (Automated Neural Networks), který umožňuje analyzovat data pomocí neuronových sítí. V tomto modulu lze provádět několik analýz (Obr. 5.1), např. regresi, klasifikaci a shlukovou analýzu. Regresi a klasifikaci lze navíc provádět také pro časové řady. Datový soubor použitý v této práci nepatří mezi časové řady, a proto nemůže být podroben analýzám jich se týkajících. Tento program umožňuje vytvářet sítě pouze s jednou skrytou vrstvou. Po spuštění modulu ANN v programu STATISTICA se otevře okno pro výběr analýzy. V tomto okně je nutné zvolit novou analýzu pro natrénování neuronových sítí. Po nalezení nejvhodnějších sítí je možné je uložit. Síť pak lze nahrát a aplikovat na zvolená data rovnou.

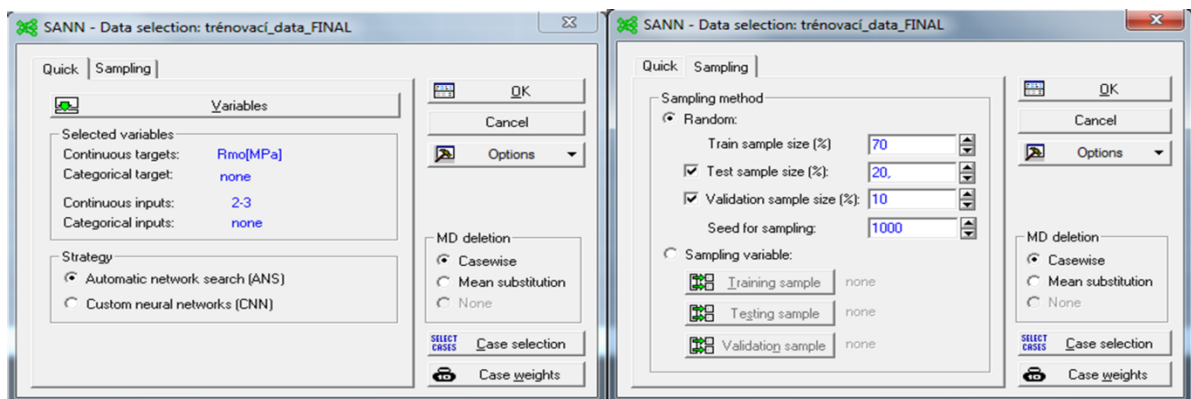


Obr. .5.1 Výběr analýzy v modulu ANN

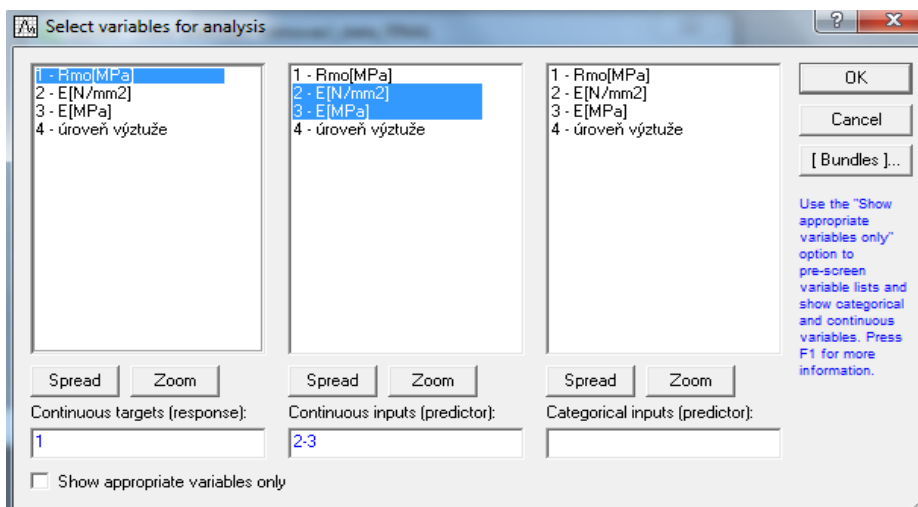
5.1 Regrese

Regresní analýza se používá pro předpověď jedné nebo více proměnných na základě znalosti souvislostí mezi jednotlivými veličinami. Tyto vztahy lze těžko popsat matematickým vztahem, ale tento vztah lze objevit pomocí neuronových sítí na základě dostatečného počtu naměřených hodnot. Čím více hodnot bude naměřeno (použito k trénování sítě), tím bude rozdíl (residuum) mezi předpovídanou hodnotou a skutečnou hodnotou menší. Byly provedeny dva způsoby regrese. Při jednom se z Youngových modulů snažila síť předpovědět pevnost ohybu. Ve druhém se z pevnosti ohybu síť snažila určit oba Youngovi moduly.

V samotném začátku je důležité zvolit v prvním okně regresní analýzu. Poté se otevře okno, ve kterém je možné nastavit proměnné v záložce rychle. Pod záložkou vzorkování se skrývá možnost rozhodnout, kolik hodnot bude použito k trénování sítí a kolik jich bude určeno k testování popřípadě validaci těchto sítí. V této práci byla trénovací data rozdělena ještě mezi testovací a validační v poměru 70:20:10 (Obr. 5.2 vzorkování).

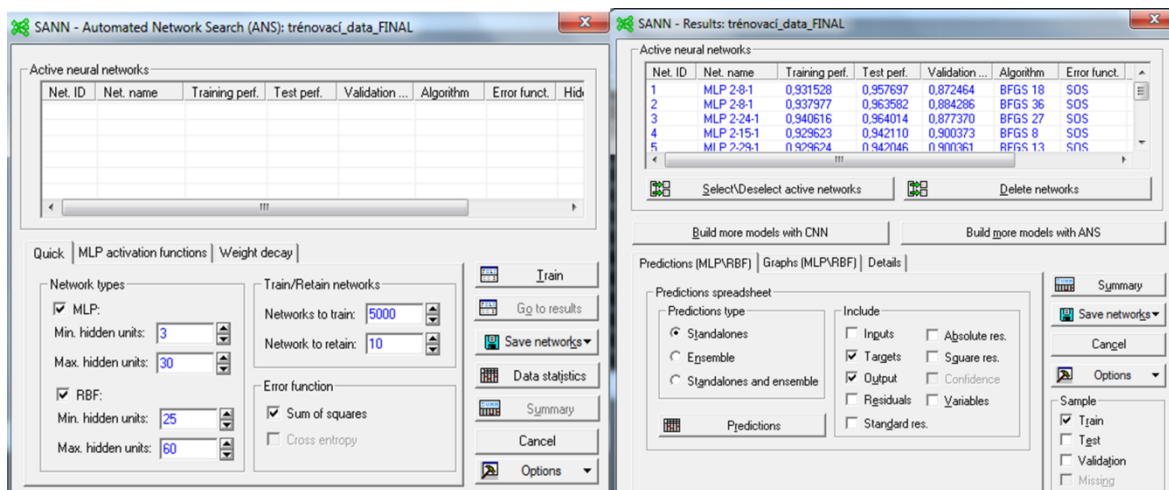


Obr. 5.2 Výběr mezi záložkami



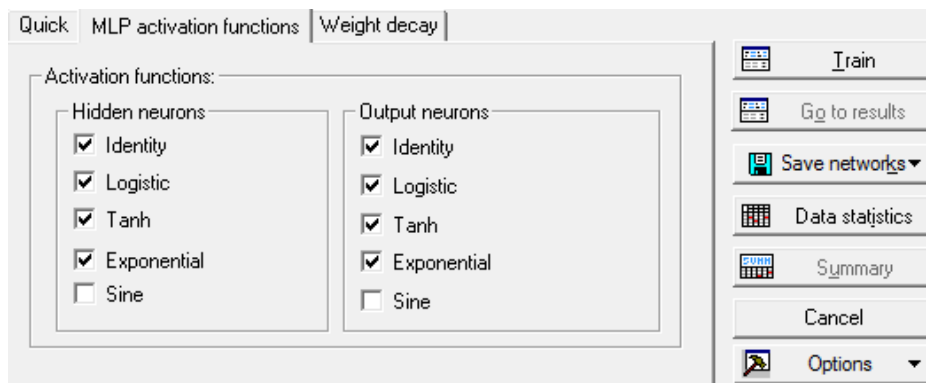
Obr. 5.3 Volba proměnných

V následujícím okně se rozhoduje o tom, jaký druh sítě má být natrénován (MLP, RBF), kolik neuronů bude ve skryté vrstvě, jaký počet sítí se má natrénovat a kolik nejlepších sítí se vybere.



Obr. 5.4 Nastavení parametrů sítě a natrénování

Po natrénování sítí je možné nejlepší sítě uložit buď v *c* kódu nebo v PMML skriptu. Uložené sítě je pak možné nahrát a vyzkoušet na zkušebních datech. Při všech analýzách použitých v této práci byly využity všechny nabízené aktivační funkce kromě funkce sinus (Obr. 5.5).



Obr. 5.5 aktivační funkce vrstev neuronů

Tab. 5.6 Predikce R_{mo}

Case name	Rmo [MPa] Target	Rmo [MPa] - Output 1. MLP 2-3-1	Rmo [MPa] - Output 2. MLP 2-10-1	Rmo [MPa] - Output 3. MLP 2-3-1	Rmo [MPa] - Output 4. MLP 2-9-1	Rmo [MPa] - Output 5. MLP 2-7-1
0_0_18	2872,110	2903,850	2879,413	2919,281	2902,966	2932,812
0_0_25	3208,610	3064,447	3047,678	3090,088	3010,426	3041,483
N_1_12	2829,040	2799,246	2767,825	2825,317	2810,172	2839,461
N_1_25	3176,630	3047,968	3025,862	3048,727	3025,361	3059,957
N_2_5	1747,200	1894,727	1911,770	1985,869	1890,209	1916,347
N_2_12	1957,130	1884,567	1869,577	1944,833	1854,774	1857,864
N_3_19	1940,170	1858,201	1795,334	1720,163	1800,500	1800,517
N_3_21	2111,060	1890,189	1885,545	1969,197	1867,274	1872,193
S_1_6	2005,510	1996,375	2004,254	1960,462	1989,720	1988,946
S_1_15	2314,110	2041,755	2004,540	2033,266	1991,763	2000,512
S_2_3	1907,850	2004,195	2013,038	1964,547	1999,702	1998,762
S_2_11	2103,480	2084,887	2091,405	2083,904	2099,896	2093,242
S_3_13	1861,820	2069,246	2073,447	2056,692	2065,379	2070,404
S_3_20	2027,610	1991,406	1988,015	1970,651	1971,860	1972,633
V_1_19	1931,390	2081,232	2075,333	2096,385	2118,981	2072,944
V_1_21	2105,960	2097,123	2102,034	2106,058	2114,051	2106,776
V_2_9	2022,810	2024,532	2032,278	1986,567	2020,713	2020,998
V_2_27	2141,570	2066,776	2075,165	2050,816	2075,467	2072,602
V_3_7	2103,360	2120,561	2118,559	2148,886	2112,174	2126,175
V_3_10	1942,060	2034,588	2043,192	1999,132	2033,890	2033,749
0_0_med	3048,995	3055,771	3033,607	3057,388	3027,631	3064,119
N_1_med	3024,250	2985,999	2965,342	2999,094	2984,767	3013,037
N_2_med	1834,880	1879,884	1887,417	1937,241	1864,524	1879,411
N_3_med	2056,645	1899,267	1912,578	1990,943	1890,255	1901,221
S_1_med	2225,520	2067,454	2071,257	2053,827	2062,499	2067,786
S_2_med	2012,690	2010,951	2018,878	1971,505	2005,812	2005,498
S_3_med	1942,970	2014,977	2018,619	1979,663	2004,283	2005,765
V_1_med	2006,725	2084,316	2090,366	2082,168	2089,786	2091,266
V_2_med	2090,660	2065,351	2074,018	2048,752	2079,650	2071,587
V_3_med	2000,720	2062,915	2071,387	2044,056	2069,663	2067,864

Při regresi byly předpovězeny hodnoty pomocí 5 nejlepších sítí, které byly nalezeny při trénování 5000 neuronových sítí. Pro zjištění nejlépe predikující sítě je vhodné uvést ještě tabulku residuí, která bude uvedena dále. Residua mohou nabývat kladných i záporných hodnot a proto je krajně nevhodné počítat průměr těchto hodnot nebo je sčítat. Lepším způsobem porovnání těchto sítí je sečíst kvadrát residuí. Tím bude vyloučen vliv záporných hodnot. Nejmenší suma kvadrátů residuí určí tu neuronovou síť, jejíž predikční schopnost je nejlepší. Pro lepší představu byla tato hodnota ještě odmocněna. Nejlepší sítě byly vybrány právě na základě této hodnoty.


Tab. 5.7 Residua předpovědi R_{mo}

Case name	Rmo [MPa] Target	Rmo [MPa] - Residuals 1. MLP 2-3-1	Rmo [MPa] - Residuals 2. MLP 2-10-1	Rmo[MPa] - Residuals 3. MLP 2-3-1	Rmo [MPa] - Residuals 4. MLP 2-9-1	Rmo [MPa] - Residuals 5. MLP 2-7-1
0_0_18	2872,110	31,740	7,303	47,171	30,856	60,702
0_0_25	3208,610	-144,163	-160,932	-118,522	-198,184	-167,127
N_1_12	2829,040	-29,794	-61,215	-3,723	-18,868	10,421
N_1_25	3176,630	-128,662	-150,768	-127,903	-151,269	-116,673
N_2_5	1747,200	147,527	164,570	238,669	143,009	169,147
N_2_12	1957,130	-72,563	-87,553	-12,297	-102,356	-99,266
N_3_19	1940,170	-81,969	-144,836	-220,007	-139,670	-139,653
N_3_21	2111,060	-220,871	-225,515	-141,863	-243,786	-238,867
S_1_6	2005,510	-9,135	-1,256	-45,048	-15,790	-16,564
S_1_15	2314,110	-272,355	-309,570	-280,844	-322,347	-313,598
S_2_3	1907,850	96,345	105,188	56,697	91,852	90,912
S_2_11	2103,480	-18,593	-12,075	-19,576	-3,584	-10,238
S_3_13	1861,820	207,426	211,627	194,872	203,559	208,584
S_3_20	2027,610	-36,204	-39,595	-56,959	-55,750	-54,977
V_1_19	1931,390	149,842	143,943	164,995	187,591	141,554
V_1_21	2105,960	-8,837	-3,926	0,098	8,091	0,816
V_2_9	2022,810	1,722	9,468	-36,243	-2,097	-1,812
V_2_27	2141,570	-74,794	-66,405	-90,754	-66,103	-68,968
V_3_7	2103,360	17,201	15,199	45,526	8,814	22,815
V_3_10	1942,060	92,528	101,132	57,072	91,830	91,689
0_0_med	3048,995	6,776	-15,388	8,393	-21,364	15,124
N_1_med	3024,250	-38,251	-58,908	-25,156	-39,483	-11,213
N_2_med	1834,880	45,004	52,537	102,361	29,644	44,531
N_3_med	2056,645	-157,378	-144,067	-65,702	-166,390	-155,424
S_1_med	2225,520	-158,066	-154,263	-171,693	-163,021	-157,734
S_2_med	2012,690	-1,739	6,188	-41,185	-6,878	-7,192
S_3_med	1942,970	72,007	75,649	36,693	61,313	62,795
V_1_med	2006,725	77,591	83,641	75,443	83,061	84,541
V_2_med	2090,660	-25,309	-16,642	-41,908	-11,010	-19,073
V_3_med	2000,720	62,195	70,667	43,336	68,943	67,144
odmocnina ze sumy kvadrátů residuí		596,640	645,874	619,238	671,834	644,200

Nejlepší predikční schopnost má hned první neuronová síť MLP 2-3-1. Tato síť má stejně jako třetí neuronová síť 3 neurony ve skryté vrstvě. Tyto dvě sítě se od sebe liší aktivační funkcí ve výstupní vrstvě. Nejlépe natrénovaná síť nemá nejlepší predikční schopnost pro zkušební data. Nejlépe natrénovanou sítí byla třetí síť MLP 2-3-1, jejíž suma kvadrátů residuí byla nejmenší. Tato porovnání trénovacích dat jsou kvůli jejich obrovskému rozsahu přiložena pouze na CD.

Net. ID	Net. Name	Hidden act.	Output act.
1	MLP 2-3-1	Tanh	Exponential
2	MLP 2-10-1	Tanh	Exponential
3	MLP 2-3-1	Tanh	Logistic
4	MLP 2-9-1	Tanh	Exponential
5	MLP 2-7-1	Tanh	Identity

Tab. 5.8 seznam nejlepších sítí



Obr. 5.9. Graf residuí R_{mo}

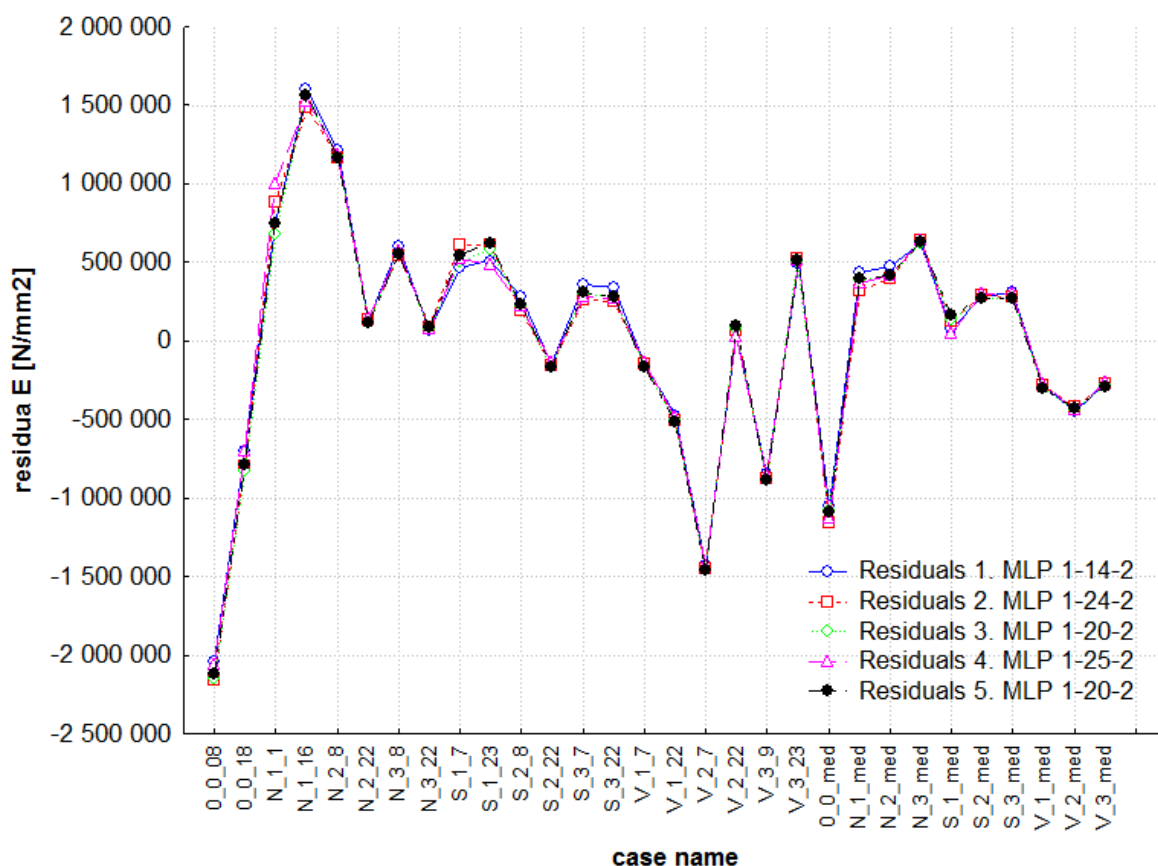
Zobrazené neuronové sítě mají velmi podobnou predikční schopnost pro materiály s úrovní výztuže *střední* a *vysoká*. Pro materiály *bez výztuže* a s *nízkou* úrovní výztuže se vyskytují mezi sítěmi jen malé odchylky. Výjimkami jsou obě sítě MLP 2-3-1, které se od ostatních liší v materiálu N_2_12. Nejvyšší výchylka byla u vzorku S_1_15, kterou takto předpověděly všechny uvedené sítě.

Z hlediska materiálové povahy bylo možné trénovat neuronové sítě pro určení modulů pružnosti z pevnosti v ohybu. Moduly pružnosti popisují stejnou veličinu různými způsoby. Neuronová síť by tedy měla být schopna predikovat z jedné hodnoty obě zbylé. Pro tento účel byly vytvořeny trénovací data, obdobným způsobem popsáním v kapitole 3. Hodnoty se sestavily podle velikosti Youngových modulů a to byl jediný rozdíl oproti způsobu popsáním v kapitole 3, jinak byl postup stejný. Získaly se tak odlišná trénovací (Tab. A2) a zkušební data (Tab. A4).

Tab. 5.10 Residua předpovědi E [N/mm²]

case name	E [N/mm ²] Target	E [N/mm ²] - Residuals 1. MLP 1-14-2	E [N/mm ²] - Residuals 2. MLP 1-24-2	E [N/mm ²] - Residuals 3. MLP 1-20-2	E [N/mm ²] - Residuals 4. MLP 1-25-2	E [N/mm ²] - Residuals 5. MLP 1-20-2
0_0_08	13 405 149,0	-2 043 100,58	-2 158 767,64	-2 152 800,60	-2 058 164,55	-2 119 354,83
0_0_18	12 000 349,0	-701 502,17	-799 990,62	-826 807,99	-698 366,21	-784 487,95
N_1_1	11 702 951,0	747 369,08	883 694,24	678 310,79	1 004 688,01	745 673,28
N_1_16	10 069 736,0	1 599 738,60	1 487 255,89	1 561 269,61	1 523 168,18	1 560 629,64
N_2_8	6 079 397,0	1 216 068,82	1 164 177,90	1 170 903,08	1 189 053,07	1 167 617,08
N_2_22	7 375 691,0	131 205,30	136 156,35	119 164,92	143 995,12	117 465,64
N_3_8	6 655 659,0	602 763,72	542 867,85	554 293,23	568 493,50	551 493,11
N_3_22	7 518 293,0	64 455,55	91 167,11	78 839,70	78 455,72	82 711,59
S_1_7	7 753 367,5	468 350,14	609 289,28	508 952,43	522 067,52	547 412,70
S_1_23	6 997 718,0	508 888,57	608 050,59	578 236,58	486 961,28	622 973,28
S_2_8	6 817 005,5	281 602,36	197 061,99	226 337,08	219 969,62	227 374,38
S_2_22	7 604 952,0	-145 972,22	-154 978,84	-168 139,49	-140 813,55	-171 092,72
S_3_7	6 643 039,5	354 990,86	264 397,22	301 842,49	280 898,56	306 601,27
S_3_22	6 739 660,5	336 995,95	250 469,30	281 759,13	272 280,95	283 524,91
V_1_7	7 648 083,5	-151 662,76	-149 774,66	-166 114,51	-140 358,59	-168 159,38
V_1_22	7 846 486,5	-472 903,16	-505 607,63	-508 907,34	-484 196,28	-512 612,22
V_2_7	8 841 511,0	-1 426 332,28	-1 447 768,51	-1 456 154,03	-1 429 367,14	-1 459 681,45
V_2_22	7 523 286,0	38 006,46	69 016,19	79 481,46	25 687,87	92 450,89
V_3_9	8 260 966,5	-851 260,54	-874 213,36	-881 952,23	-855 363,99	-885 521,60
V_3_23	7 081 812,0	496 728,72	522 222,78	508 325,00	512 015,37	511 457,77
0_0_med	12 739 389,0	-1 048 938,55	-1 158 810,57	-1 082 656,04	-1 128 033,41	-1 085 267,99
N_1_med	11 189 336,0	436 918,60	319 783,59	388 555,76	366 315,40	392 154,66
N_2_med	6 669 324,0	474 996,81	395 729,11	420 428,68	420 368,68	420 100,09
N_3_med	6 940 317,0	621 293,93	642 027,79	625 115,46	638 331,60	626 374,64
S_1_med	7 415 773,0	74 875,38	122 421,11	136 642,37	46 044,06	160 355,15
S_2_med	7 222 373,0	284 493,06	289 435,27	272 445,53	297 278,78	270 745,18
S_3_med	7 073 824,0	306 824,54	275 989,35	271 802,76	296 951,26	268 106,10
V_1_med	7 783 322,0	-285 662,45	-283 412,13	-299 835,70	-274 175,98	-301 842,11
V_2_med	8 034 752,0	-450 210,25	-422 954,83	-434 349,80	-437 032,45	-430 072,14
V_3_med	7 758 620,0	-270 592,02	-271 156,68	-286 887,24	-260 564,47	-289 176,95
odmocnina ze sumy kvadrátů residuí		4 020 075,09	4 104 123,94	4 077 461,67	4 042 687,94	4 078 839,13

Nejlepší predikční schopnost měla síť MLP 1-14-2. V rámci jednoho vzorku sítě předpověděly zhruba stejné hodnoty a residua se od sebe tolik neodlišují. Z pohledu na celou tabulku jsou rozdíly mezi residui značné. Nejhůře předpověděnou hodnotou byl materiál s označením 0_0_08. Nejlepší sítí by podle trénovacích dat měla být MLP 1-24-2, která má ze všech vypočtených sítí nejhorší predikční schopnost pro zkušební data.




Obr. 5.11 Graf residuí E [N/mm²]

Nejhorší predikční schopnost měly sítě na samotném začátku u materiálu *bez výztuže*. U materiálu s úrovní *nizká* 1 dosáhly dalšího extrému. Pro další úrovně výztuže nedosahovala predikce úrovně materiálu takových výchylek a dosahovala přívětivějších hodnot. Výchylky residuí se pak zase zvýšily u materiálu úrovně *vysoká*. U mediánů nastal extrém pouze u materiálu *bez výztuže*, zbylé výchylky jsou srovnatelné se střední částí grafu. Mezi natrénovanými sítěmi nepanují v grafu takové rozdíly. Tyto malé rozdíly jsou však umocněny velkým rozsahem na vertikální ose.

Tab. 5.12 Residua pro předpověď E [MPa]

case name	E [MPa] Target	E [MPa] - Residuals 1. MLP 1-14-2	E [MPa] - Residuals 2. MLP 1-24-2	E [MPa] - Residuals 3. MLP 1-20-2	E [MPa] - Residuals 4. MLP 1-25-2	E [MPa] - Residuals 5. MLP 1-20-2
0_0_08	17 516 858,0	-2 295 292,42	-2 438 961,28	-2 361 638,17	-2 389 187,95	-2 370 086,78
0_0_18	15 458 511,0	-405 954,41	-581 124,73	-477 165,75	-531 875,33	-478 661,16
N_1_1	16 733 284,0	393 907,03	115 946,29	531 892,32	503 448,10	651 014,59
N_1_16	15 206 869,0	649 343,44	674 458,78	611 792,71	638 558,86	606 027,85
N_2_8	5 798 808,0	1 351 229,30	1 423 759,03	1 385 458,63	1 339 688,31	1 394 431,84
N_2_22	6 210 926,5	1 392 184,81	1 457 079,92	1 367 044,33	1 397 455,04	1 391 993,27
N_3_8	5 520 110,0	1 558 284,46	1 628 070,57	1 602 469,67	1 545 303,93	1 608 455,75
N_3_22	6 493 203,5	1 348 410,49	1 373 408,92	1 306 795,34	1 356 831,00	1 332 104,12
S_1_7	8 766 481,0	643 616,71	526 998,87	611 570,27	578 281,36	604 199,07
S_1_23	7 960 618,5	227 270,67	208 053,63	331 587,28	186 620,12	312 225,72
S_2_8	6 968 733,5	-186 436,75	-132 605,50	-101 437,44	-198 272,54	-108 014,64
S_2_22	8 086 895,0	-597 071,80	-524 582,13	-608 684,91	-596 320,16	-586 867,12
S_3_7	7 230 476,5	-626 316,80	-582 967,31	-517 210,39	-630 861,58	-531 337,53
S_3_22	7 565 866,0	-822 915,83	-771 445,37	-732 563,87	-833 603,34	-740 812,95
V_1_7	8 199 272,5	-621 927,49	-554 834,79	-644 149,81	-617 622,31	-619 820,94
V_1_22	8 307 219,5	-1 000 787,29	-925 032,73	-988 142,06	-1 007 480,21	-972 874,61
V_2_7	8 800 381,0	-1 406 740,76	-1 331 384,50	-1 405 860,95	-1 410 013,52	-1 387 319,36
V_2_22	8 178 362,5	-204 101,07	-233 115,42	-212 492,22	-211 612,54	-204 126,35
V_3_9	8 098 923,5	-716 956,20	-641 436,17	-714 520,45	-720 705,66	-696 403,16
V_3_23	7 699 035,5	121 469,95	151 956,92	79 887,93	130 384,84	105 840,26
0_0_med	16 739 895,0	-844 650,11	-807 480,73	-878 811,03	-850 117,92	-883 508,75
N_1_med	15 206 869,0	567 770,22	567 960,13	523 861,14	546 183,94	516 172,41
N_2_med	5 798 808,0	1 066 352,36	1 125 093,83	1 140 019,74	1 052 910,25	1 136 968,16
N_3_med	6 082 040,0	1 674 109,44	1 718 440,19	1 635 093,74	1 683 235,68	1 661 881,46
S_1_med	8 206 813,0	-201 950,74	-241 571,27	-147 895,49	-225 047,73	-158 838,82
S_2_med	7 608 180,0	-5 144,09	59 757,90	-30 276,20	123,39	-5 328,98
S_3_med	7 640 536,0	-319 519,55	-243 705,55	-308 861,69	-325 666,99	-293 031,49
V_1_med	8 424 612,0	-844 255,04	-777 403,70	-866 824,20	-839 834,40	-842 419,60
V_2_med	8 282 645,0	-430 319,41	-408 321,33	-471 736,38	-422 256,22	-446 848,75
V_3_med	8 212 795,0	-655 631,86	-587 023,33	-675 494,60	-652 115,66	-651 693,56
odmocnina ze sumy kvadrátů residuí		5 131 375,91	5 181 297,07	5 166 550,98	5 184 618,16	5 183 713,66

Nejllepší predikční schopnost měla síť MLP 1-14-2. Tato síť byla také nejlépe natrénovaná sítí. Residua dosahují v některých případech přívětivých hodnot. Vyskytuje se však několik residuí, jejichž hodnota se blíží, v jednom případě dokonce překračuje 15 % z originální hodnoty. Pro medián N_2_med to bylo více než 28 %. Nejhůře předpověděnou hodnotou byl materiál s označením 0_0_08, který měl nejvyšší residuum.



Obr. 5.13 Graf residuí E [MPa]

V předpovídaných datech se objevují obrovské výchylky. Největší výchylky bylo dosaženo na samém začátku. Velké výchylky také nastaly u materiálů s nízkou úrovní stupně 2 a 3. Obdobná výchylka se objevila i u N_3_med. Nejlépe predikovanými materiály byly: S_1_23, S_2_8, V_2_22 a V_3_23. Z mediánů byly nejlépe předpověděny ty, které měly střední úroveň výztuže.

5.2 Klasifikace

Tento nástroj umožňuje natrénování neuronové sítě na trénovacích hodnotách s následnou možností klasifikovat úplně neznámé hodnoty. Čím více dat bude pro trénování sítě k dispozici, tím bude pravděpodobnější správné určení příslušného materiálu (úroveň výztuže).

V prvním okně se vybere klasifikace, pak je postup obdobný jako u regresní analýzy. Ve volbě proměnných se vyberou všechny tři veličiny (vstupy), ze kterých se budou předpovídat úrovně výztuže (výstupy). Těchto výstupů (úrovně výztuže) bylo deset. V záložce vzorkování bylo nastaveno rozdělení trénovacích dat na 80:20. Validací data byla v této analýze opomenuta kvůli malému počtu trénovacích hodnot a velkému počtu výstupů.

Tab. 5.14 Klasifikace zkušebních hodnot

case name	úroveň výztuže Target	úroveň výztuže - Output 1. MLP 3-9-10	úroveň výztuže - Output 2. MLP 3-3-10	úroveň výztuže - Output 3. MLP 3-22-10	úroveň výztuže - Output 4. MLP 3-6-10	úroveň výztuže - Output 5. MLP 3-17-10
0_0_18	bez výztuže	bez výztuže	nízká 1	nízká 1	bez výztuže	nízká 1
0_0_25	bez výztuže	bez výztuže	bez výztuže	bez výztuže	bez výztuže	bez výztuže
N_1_12	nízká 1	nízká 1	nízká 1	nízká 1	nízká 1	nízká 1
N_1_25	nízká 1	nízká 1	nízká 1	bez výztuže	bez výztuže	bez výztuže
N_2_5	nízká 2	nízká 2	nízká 2	nízká 2	nízká 2	nízká 2
N_2_12	nízká 2	nízká 2	nízká 3	nízká 2	nízká 2	nízká 2
N_3_19	nízká 3	nízká 2	nízká 3	nízká 2	nízká 2	nízká 2
N_3_21	nízká 3	nízká 3	nízká 3	nízká 3	nízká 3	nízká 3
S_1_6	střední 1	střední 2	střední 2	střední 3	střední 2	střední 2
S_1_15	střední 1	střední 1	střední 1	střední 1	střední 1	střední 1
S_2_3	střední 2	střední 3	střední 3	střední 3	střední 3	střední 3
S_2_11	střední 2	vyšoká 2	vyšoká 2	vyšoká 2	vyšoká 2	vyšoká 2
S_3_13	střední 3	vyšoká 1	vyšoká 1	vyšoká 1	vyšoká 1	vyšoká 1
S_3_20	střední 3	střední 2	střední 2	střední 2	střední 2	střední 2
V_1_19	vyšoká 1	vyšoká 2	vyšoká 1	vyšoká 1	vyšoká 2	vyšoká 3
V_1_21	vyšoká 1	vyšoká 2	vyšoká 2	vyšoká 2	vyšoká 2	vyšoká 2
V_2_9	vyšoká 2	střední 2	vyšoká 3	střední 3	střední 2	střední 2
V_2_27	vyšoká 2	vyšoká 2	vyšoká 2	vyšoká 2	vyšoká 2	vyšoká 2
V_3_7	vyšoká 3	vyšoká 1	vyšoká 1	vyšoká 1	vyšoká 1	střední 1
V_3_10	vyšoká 3	střední 3	vyšoká 3	vyšoká 3	střední 3	střední 3
0_0_med	bez výztuže	bez výztuže	bez výztuže	bez výztuže	bez výztuže	bez výztuže
N_1_med	nízká 1	nízká 1	nízká 1	nízká 1	nízká 1	nízká 1
N_2_med	nízká 2	nízká 2	nízká 2	nízká 2	nízká 2	nízká 2
N_3_med	nízká 3	nízká 3	nízká 3	nízká 3	nízká 3	nízká 3
S_1_med	střední 1	střední 1	střední 1	střední 1	střední 1	střední 1
S_2_med	střední 2	střední 2	střední 3	střední 3	střední 2	střední 2
S_3_med	střední 3	střední 2	střední 3	střední 3	střední 2	střední 3
V_1_med	vyšoká 1	vyšoká 1	vyšoká 3	vyšoká 1	vyšoká 1	vyšoká 1
V_2_med	vyšoká 2	vyšoká 2	vyšoká 2	vyšoká 2	vyšoká 2	vyšoká 2
V_3_med	vyšoká 3	vyšoká 3	vyšoká 3	vyšoká 3	vyšoká 3	vyšoká 3

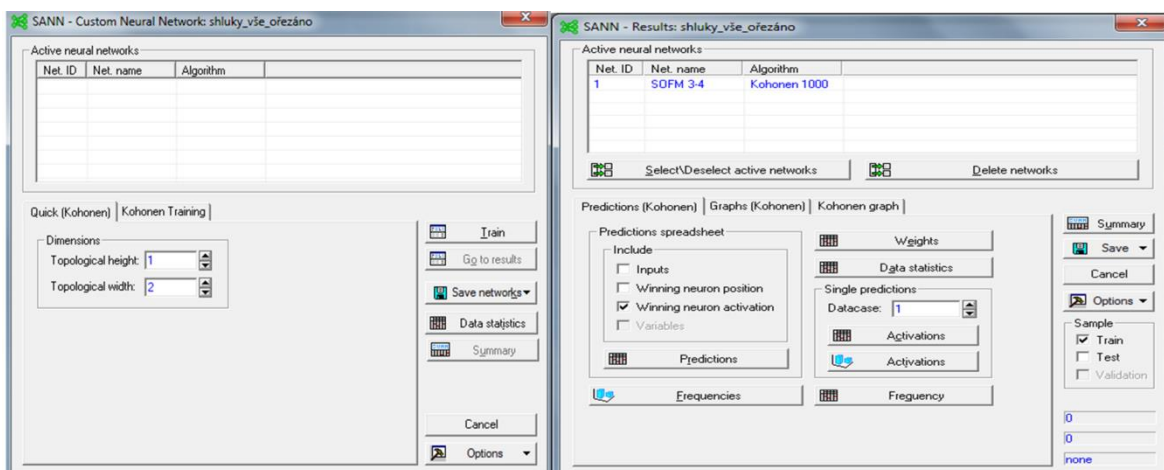
K nejlepším sítím patří sítě: MLP 3-9-10, MLP 3-3-10 a MLP 3-22-10. Tyto sítě klasifikovaly správně 18 ze 30 materiálů. K chybné klasifikaci došlo záměnou za jiný materiál v rámci shluků (viz. podkap. 5.3). Materiál *bez výztuže* mohl být zaměněn pouze s materiálem, jehož úroveň výztuže byla *nízká 1*. Materiál s úrovní výztuže *nízká 2* byl zaměněn v některých případech pouze s materiálem úrovně *nízká 3*. Nejvíce chybných klasifikací proběhlo u materiálů s úrovní výztuže *střední* a *vyšoká*. Tyto materiály byly často zaměněny mezi sebou. Docházelo však také ke špatnému přiřazení stupně úrovně, i když samotná úroveň byla určena správně. Výsledný přehled o úspěšném klasifikování materiálu zvolenými sítěmi je v Tab. 5.15.

Tab. 5.15 Statistické shrnutí klasifikační analýzy

		úroveň výztuže-bez výztuže	úroveň výztuže- nízká 1	úroveň výztuže- nízká 2	úroveň výztuže- nízká 3	úroveň výztuže- střední 1	úroveň výztuže- střední 2	úroveň výztuže- střední 3	úroveň výztuže- vysoká 1	úroveň výztuže- vysoká 2	úroveň výztuže- vysoká 3
MLP 3-9-10	Total	3,0000	3,0000	3,0000	3,0000	3,00000	3,0000	3,0000	3,00000	3,00000	3,00000
	Correct	3,0000	3,0000	3,0000	2,0000	2,00000	1,0000	0,0000	1,00000	2,00000	1,00000
	Incorrect	0,0000	0,0000	0,0000	1,0000	1,00000	2,0000	3,0000	2,00000	1,00000	2,00000
	Correct (%)	100,0000	100,0000	100,0000	66,0000	66,00000	33,0000	0,0000	33,00000	66,00000	33,00000
	Incorrect (%)	0,0000	0,0000	0,0000	33,0000	33,00000	66,0000	100,0000	66,00000	33,00000	66,00000
MLP 3-3-10	Total	3,0000	3,0000	3,0000	3,0000	3,00000	3,0000	3,0000	3,00000	3,00000	3,00000
	Correct	2,0000	3,0000	2,0000	3,0000	2,00000	0,0000	1,0000	1,00000	2,00000	2,00000
	Incorrect	1,0000	0,0000	1,0000	0,0000	1,00000	3,0000	2,0000	2,00000	1,00000	1,00000
	Correct (%)	66,0000	100,0000	66,0000	100,0000	66,00000	0,0000	33,0000	33,00000	66,00000	66,00000
	Incorrect (%)	33,0000	0,0000	33,0000	0,0000	33,00000	100,0000	66,0000	66,00000	33,00000	33,00000
MLP 3-22-10	Total	3,0000	3,0000	3,0000	3,0000	3,00000	3,0000	3,0000	3,00000	3,00000	3,00000
	Correct	2,0000	2,0000	3,0000	2,0000	2,00000	0,0000	1,0000	2,00000	2,00000	2,00000
	Incorrect	1,0000	1,0000	0,0000	1,0000	1,00000	3,0000	2,0000	1,00000	1,00000	1,00000
	Correct (%)	66,0000	66,0000	100,0000	66,0000	66,00000	0,0000	33,0000	66,00000	66,00000	66,00000
	Incorrect (%)	33,0000	33,0000	0,0000	33,0000	33,00000	100,0000	66,0000	33,00000	33,00000	33,00000
MLP 3-6-10	Total	3,0000	3,0000	3,0000	3,0000	3,00000	3,0000	3,0000	3,00000	3,00000	3,00000
	Correct	3,0000	2,0000	3,0000	2,0000	2,00000	1,0000	0,0000	1,00000	2,00000	1,00000
	Incorrect	0,0000	1,0000	0,0000	1,0000	1,00000	2,0000	3,0000	2,00000	1,00000	2,00000
	Correct (%)	100,0000	66,0000	100,0000	66,0000	66,00000	33,0000	0,0000	33,00000	66,00000	33,00000
	Incorrect (%)	0,0000	33,0000	0,0000	33,0000	33,00000	66,0000	100,0000	66,00000	33,00000	66,00000
MLP 3-17-10	Total	3,0000	3,0000	3,0000	3,0000	3,00000	3,0000	3,0000	3,00000	3,00000	3,00000
	Correct	2,0000	2,0000	3,0000	2,0000	2,00000	1,0000	1,0000	1,00000	2,00000	1,00000
	Incorrect	1,0000	1,0000	0,0000	1,0000	1,00000	2,0000	2,0000	2,00000	1,00000	2,00000
	Correct (%)	66,0000	66,0000	100,0000	66,0000	66,00000	33,0000	33,0000	33,00000	66,00000	33,00000
	Incorrect (%)	33,0000	33,0000	0,0000	33,0000	33,00000	66,0000	66,0000	66,00000	33,00000	66,00000

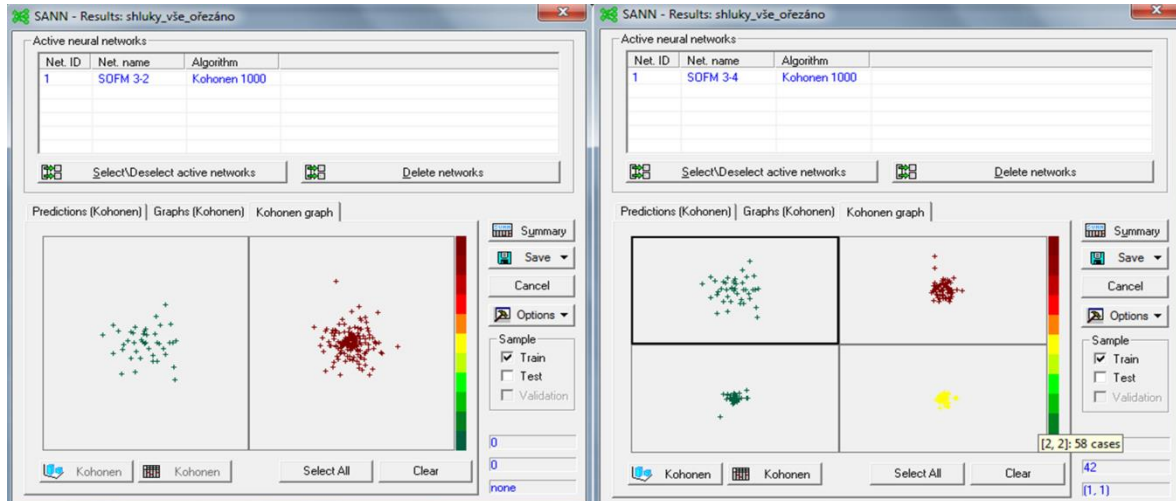
5.3 Shluková analýza

Posledním nástrojem ANN použitým v této práci co se programu STATISTICA týče je shluková analýza. Výsledky této analýzy je vhodné porovnat s výsledky získanými pomocí shlukovacího stromu, který byl zmíněn v kapitole týkající se úpravy dat. U shlukové analýzy se používá Kohonenova síť. Po spuštění shlukové analýzy je třeba nastavit topologické parametry této sítě (výšku a šířku) - (Obr. 5.16). Volbou těchto parametrů se určí, do kolika shluků se bude síť snažit rozdělit trénované veličiny.



Obr. 5.16 Výběr parametrů a trénování sítě

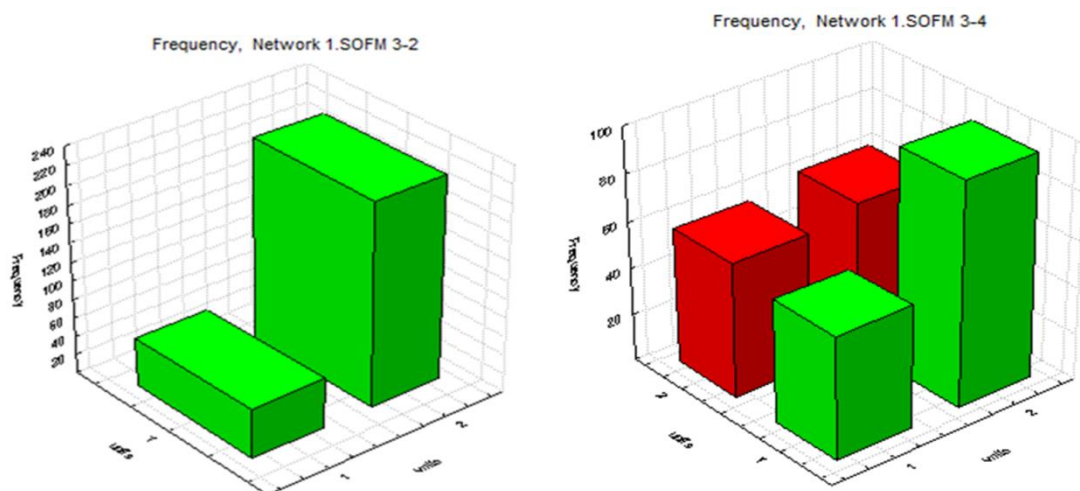
V této práci byly trénovány dvě neuronové sítě pro klasifikaci. Jedna s rozměry 1 a 2, kde první z uvedených čísel je topologická výška. Tato síť rozdělila data do 2 shluků. Druhá měla rozměry 2 na 2 a rozdělila data do 4 shluků.



Obr. 5.17 a) Kohonenova síť (1,2)

b) Kohonenova síť (2,2)

Jak bylo zmíněno Kohonenova síť má 1 vrstvu neuronů. Počet vstupů je určen množstvím veličin mezi nimiž byly hledány souvislosti. Pro tento případ jsou to 3. Počet neuronů v kompetiční vrstvě závisí na volbě topologických parametrů této sítě např. 4. Což lze vyvodit i z označení sítě SOFM 3-4 (Obr. 5.18).



Obr. 5.18 Četnost hodnot ve shlucích

Tab. 5.19 Výsledky shlukovacích metod

a) shlukovací strom

0 0 3	0 0 18	N 1 5	N 1 20	N 2 9	N 2 24	N 3 11	N 3 26	S 1 15	S 2 2	S 2 18	S 3 5	S 3 21	V 1 8	V 1 23	V 2 10	V 2 25	V 3 14
0 0 04	0 0 19	N 1 6	N 1 21	N 2 10	N 2 25	N 3 12	N 3 27	S 1 16	S 2 3	S 2 19	S 3 6	S 3 22	V 1 9	V 1 24	V 2 11	V 2 26	V 3 15
0 0 05	0 0 20	N 1 7	N 1 22	N 2 11	N 2 26	N 3 13	N 3 28	S 1 17	S 2 5	S 2 20	S 3 7	S 3 23	V 1 10	V 1 25	V 2 12	V 2 27	V 3 16
0 0 06	0 0 21	N 1 8	N 1 23	N 2 12	N 2 27	N 3 14	S 1 1	S 1 18	S 2 6	S 2 21	S 3 8	S 3 24	V 1 11	V 1 26	V 2 13	V 2 28	V 3 17
0 0 07	0 0 22	N 1 9	N 1 24	N 2 13	N 2 28	N 3 15	S 1 2	S 1 19	S 2 7	S 2 22	S 3 9	S 3 25	V 1 12	V 1 27	V 2 14	V 3 1	V 3 18
0 0 08	0 0 23	N 1 10	N 1 25	N 2 14	N 3 1	N 3 16	S 1 3	S 1 20	S 2 8	S 2 23	S 3 10	S 3 26	V 1 13	V 1 28	V 2 15	V 3 2	V 3 19
0 0 09	0 0 24	N 1 11	N 1 26	N 2 15	N 3 2	N 3 17	S 1 4	S 1 21	S 2 9	S 2 24	S 3 11	S 3 27	V 1 14	V 2 1	V 2 16	V 3 4	V 3 20
0 0 10	0 0 25	N 1 12	N 1 28	N 2 16	N 3 3	N 3 18	S 1 5	S 1 22	S 2 10	S 2 25	S 3 12	S 3 28	V 1 15	V 2 2	V 2 17	V 3 6	V 3 21
0 0 11	0 0 26	N 1 13	N 2 2	N 2 17	N 3 4	N 3 19	S 1 6	S 1 23	S 2 11	S 2 26	S 3 13	V 1 1	V 1 16	V 2 3	V 2 18	V 3 7	V 3 22
0 0 12	0 0 27	N 1 14	N 2 3	N 2 18	N 3 5	N 3 20	S 1 7	S 1 24	S 2 12	S 2 27	S 3 14	V 1 2	V 1 17	V 2 4	V 2 19	V 3 8	V 3 23
0 0 13	0 0 28	N 1 15	N 2 4	N 2 19	N 3 6	N 3 21	S 1 8	S 1 25	S 2 13	S 2 28	S 3 15	V 1 3	V 1 18	V 2 5	V 2 20	V 3 9	V 3 24
0 0 14	N 1 1	N 1 16	N 2 5	N 2 20	N 3 7	N 3 22	S 1 9	S 1 26	S 2 14	S 3 1	S 3 16	V 1 4	V 1 19	V 2 6	V 2 21	V 3 10	V 3 25
0 0 15	N 1 2	N 1 17	N 2 6	N 2 21	N 3 8	N 3 23	S 1 10	S 1 27	S 2 15	S 3 2	S 3 17	V 1 5	V 1 20	V 2 7	V 2 22	V 3 11	V 3 26
0 0 16	N 1 3	N 1 18	N 2 7	N 2 22	N 3 9	N 3 24	S 1 13	S 1 28	S 2 16	S 3 3	S 3 18	V 1 6	V 1 21	V 2 8	V 2 23	V 3 12	V 3 27
0 0 17	N 1 4	N 1 19	N 2 8	N 2 23	N 3 10	N 3 25	S 1 14	S 2 1	S 2 17	S 3 4	S 3 20	V 1 7	V 1 22	V 2 9	V 2 24	V 3 13	V 3 28


b) shlukovací analýza Kohonen (2,1)

0 0 3	0 0 18	N 1 5	N 1 20	N 2 9	N 2 24	N 3 11	N 3 26	S 1 15	S 2 2	S 2 18	S 3 5	S 3 21	V 1 8	V 1 23	V 2 10	V 2 25	V 3 14
0 0 04	0 0 19	N 1 6	N 1 21	N 2 10	N 2 25	N 3 12	N 3 27	S 1 16	S 2 3	S 2 19	S 3 6	S 3 22	V 1 9	V 1 24	V 2 11	V 2 26	V 3 15
0 0 05	0 0 20	N 1 7	N 1 22	N 2 11	N 2 26	N 3 13	N 3 28	S 1 17	S 2 5	S 2 20	S 3 7	S 3 23	V 1 10	V 1 25	V 2 12	V 2 27	V 3 16
0 0 06	0 0 21	N 1 8	N 1 23	N 2 12	N 2 27	N 3 14	S 1 1	S 1 18	S 2 6	S 2 21	S 3 8	S 3 24	V 1 11	V 1 26	V 2 13	V 2 28	V 3 17
0 0 07	0 0 22	N 1 9	N 1 24	N 2 13	N 2 28	N 3 15	S 1 2	S 1 19	S 2 7	S 2 22	S 3 9	S 3 25	V 1 12	V 1 27	V 2 14	V 3 1	V 3 18
0 0 08	0 0 23	N 1 10	N 1 25	N 2 14	N 3 1	N 3 16	S 1 3	S 1 20	S 2 8	S 2 23	S 3 10	S 3 26	V 1 13	V 1 28	V 2 15	V 3 2	V 3 19
0 0 09	0 0 24	N 1 11	N 1 26	N 2 15	N 3 2	N 3 17	S 1 4	S 1 21	S 2 9	S 2 24	S 3 11	S 3 27	V 1 14	V 2 1	V 2 16	V 3 4	V 3 20
0 0 10	0 0 25	N 1 12	N 1 28	N 2 16	N 3 3	N 3 18	S 1 5	S 1 22	S 2 10	S 2 25	S 3 12	S 3 28	V 1 15	V 2 2	V 2 17	V 3 6	V 3 21
0 0 11	0 0 26	N 1 13	N 2 2	N 2 17	N 3 4	N 3 19	S 1 6	S 1 23	S 2 11	S 2 26	S 3 13	V 1 1	V 1 16	V 2 3	V 2 18	V 3 7	V 3 22
0 0 12	0 0 27	N 1 14	N 2 3	N 2 18	N 3 5	N 3 20	S 1 7	S 1 24	S 2 12	S 2 27	S 3 14	V 1 2	V 1 17	V 2 4	V 2 19	V 3 8	V 3 23
0 0 13	0 0 28	N 1 15	N 2 4	N 2 19	N 3 6	N 3 21	S 1 8	S 1 25	S 2 13	S 2 28	S 3 15	V 1 3	V 1 18	V 2 5	V 2 20	V 3 9	V 3 24
0 0 14	N 1 1	N 1 16	N 2 5	N 2 20	N 3 7	N 3 22	S 1 9	S 1 26	S 2 14	S 3 1	S 3 16	V 1 4	V 1 19	V 2 6	V 2 21	V 3 10	V 3 25
0 0 15	N 1 2	N 1 17	N 2 6	N 2 21	N 3 8	N 3 23	S 1 10	S 1 27	S 2 15	S 3 2	S 3 17	V 1 5	V 1 20	V 2 7	V 2 22	V 3 11	V 3 26
0 0 16	N 1 3	N 1 18	N 2 7	N 2 22	N 3 9	N 3 24	S 1 13	S 1 28	S 2 16	S 3 3	S 3 18	V 1 6	V 1 21	V 2 8	V 2 23	V 3 12	V 3 27
0 0 17	N 1 4	N 1 19	N 2 8	N 2 23	N 3 10	N 3 25	S 1 14	S 2 1	S 2 17	S 3 4	S 3 20	V 1 7	V 1 22	V 2 9	V 2 24	V 3 13	V 3 28


c) shlukovací analýza Kohonen (2,2)

0 0 3	0 0 18	N 1 5	N 1 20	N 2 9	N 2 24	N 3 12	S 1 6	S 2 16	S 3 21	N 3 14	S 1 23	S 3 15	V 2 22	S 2 11	V 1 7	V 2 4	V 3 1
0 0 04	0 0 19	N 1 6	N 1 21	N 2 10	N 2 25	N 3 13	S 1 16	S 2 21	S 3 22	S 1 1	S 1 25	S 3 27	V 2 23	S 2 22	V 1 8	V 2 5	V 3 2
0 0 05	0 0 20	N 1 7	N 1 22	N 2 11	N 2 26	N 3 15	S 1 20	S 2 24	S 3 23	S 1 2	S 1 26	V 1 1	V 2 24	S 2 23	V 1 13	V 2 6	V 3 4
0 0 06	0 0 21	N 1 8	N 1 23	N 2 12	N 2 27	N 3 16	S 1 22	S 2 26	S 3 24	S 1 3	S 1 27	V 1 9	V 2 26	S 2 27	V 1 14	V 2 7	V 3 6
0 0 07	0 0 22	N 1 9	N 1 24	N 2 13	N 2 28	N 3 17	S 1 24	S 3 3	S 3 25	S 1 4	S 2 2	V 1 10	V 2 27	S 2 28	V 1 15	V 2 8	V 3 8
0 0 08	0 0 23	N 1 10	N 1 25	N 2 14	N 3 1	N 3 18	S 1 28	S 3 4	V 1 6	S 1 5	S 2 13	V 1 11	V 3 7	S 3 2	V 1 16	V 2 10	V 3 9
0 0 09	0 0 24	N 1 11	N 1 26	N 2 15	N 3 2	N 3 19	S 2 1	S 3 5	V 1 20	S 1 7	S 2 14	V 1 12	V 3 16	S 3 11	V 1 17	V 2 12	V 3 10
0 0 10	0 0 25	N 1 12	N 1 28	N 2 16	N 3 3	N 3 20	S 2 3	S 3 6	V 1 27	S 1 8	S 2 17	V 1 25	V 3 22	S 3 12	V 1 18	V 2 14	V 3 14
0 0 11	0 0 26	N 1 13	N 2 2	N 2 17	N 3 4	N 3 21	S 2 5	S 3 7	V 2 28	S 1 9	S 2 18	V 1 28	V 3 23	S 3 13	V 1 19	V 2 15	V 3 17
0 0 12	0 0 27	N 1 14	N 2 3	N 2 18	N 3 5	N 3 22	S 2 6	S 3 8	V 3 11	S 1 10	S 2 19	V 2 2	V 3 25	S 3 26	V 1 21	V 2 17	V 3 18
0 0 13	0 0 28	N 1 15	N 2 4	N 2 19	N 3 6	N 3 23	S 2 7	S 3 9	V 3 12	S 1 13	S 2 20	V 2 3	V 3 26	S 3 28	V 1 22	V 2 18	V 3 19
0 0 14	N 1 1	N 1 16	N 2 5	N 2 20	N 3 7	N 3 24	S 2 8	S 3 16	V 3 13	S 1 17	S 2 25	V 2 9	N 3 28	V 1 2	V 1 23	V 2 19	V 3 21
0 0 15	N 1 2	N 1 17	N 2 6	N 2 21	N 3 8	N 3 25	S 2 9	S 3 17	V 3 15	S 1 18	S 3 1	V 2 11	S 1 14	V 1 3	V 1 24	V 2 20	V 3 24
0 0 16	N 1 3	N 1 18	N 2 7	N 2 22	N 3 9	N 3 26	S 2 12	S 3 18	V 3 20	S 1 19	S 3 10	V 2 13	S 1 15	V 1 4	V 1 26	V 2 21	V 3 27
0 0 17	N 1 4	N 1 19	N 2 8	N 2 23	N 3 11	N 3 27	S 2 15	S 3 20	N 3 5	S 1 21	S 3 14	V 2 16	S 2 10	V 1 5	V 2 1	V 2 25	V 3 28

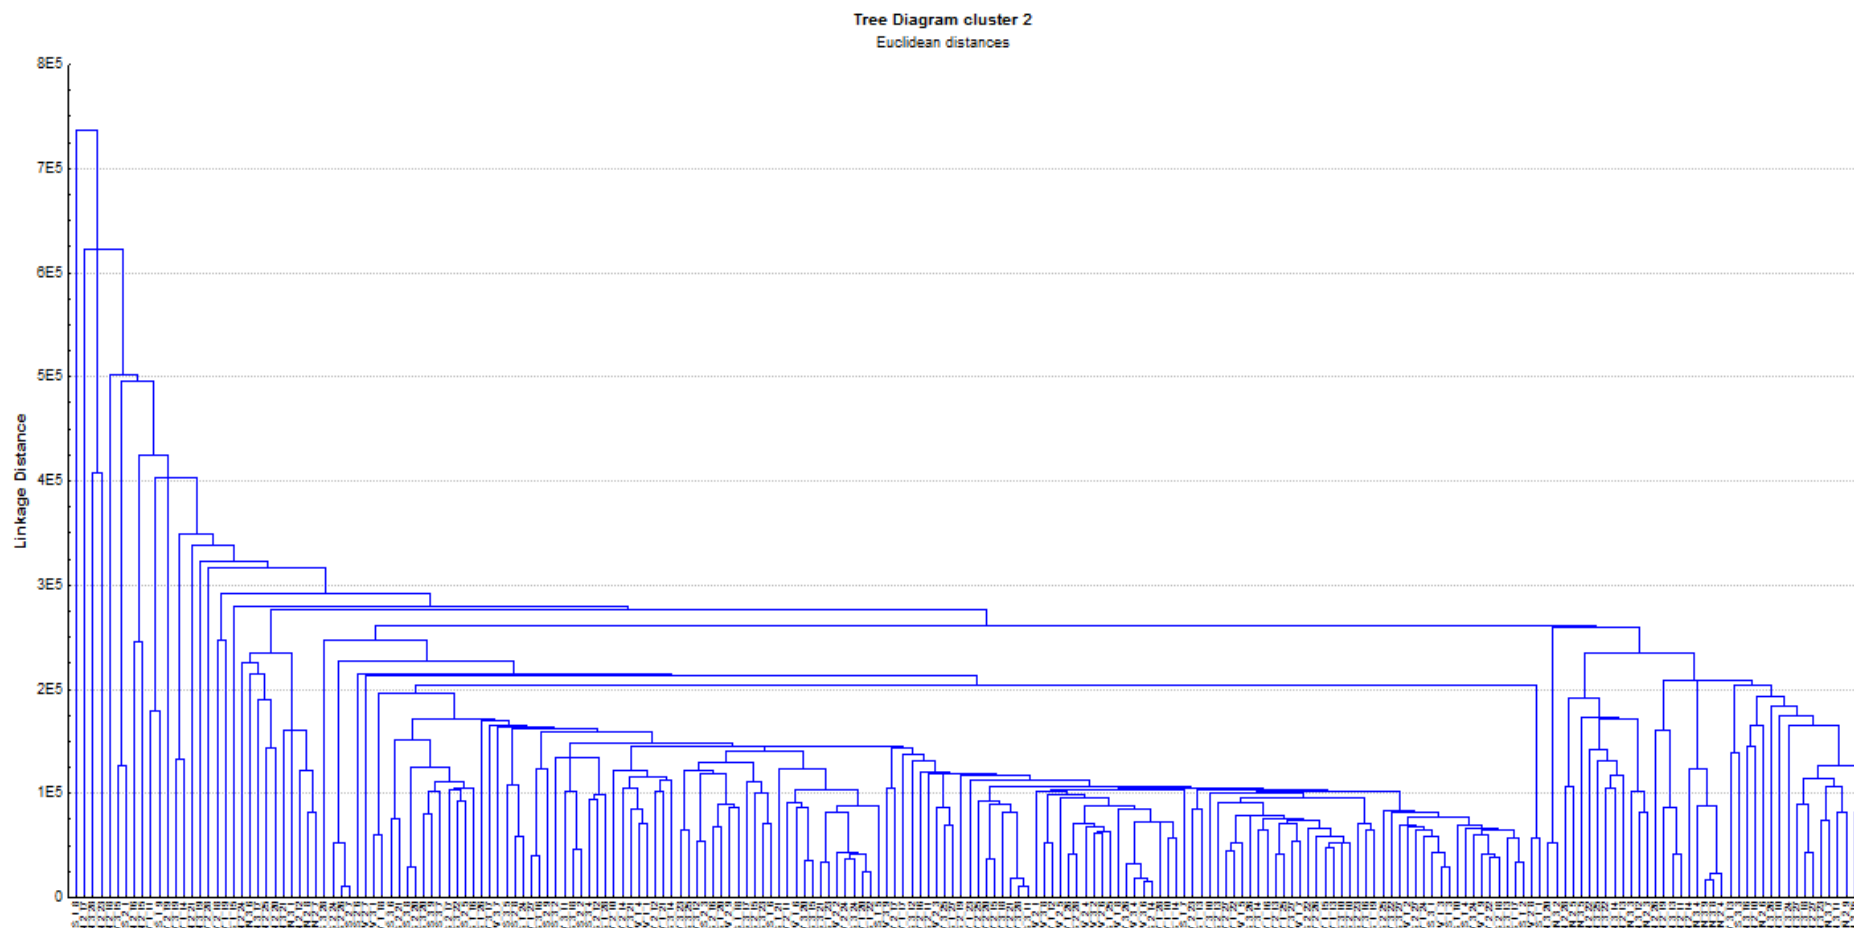
Obr. 5.20 Rozdělení trénovacích a zkušebních hodnot do shluků shlukovacím stromem




Obr. 5.21 Shlukovací strom pro shluk 1



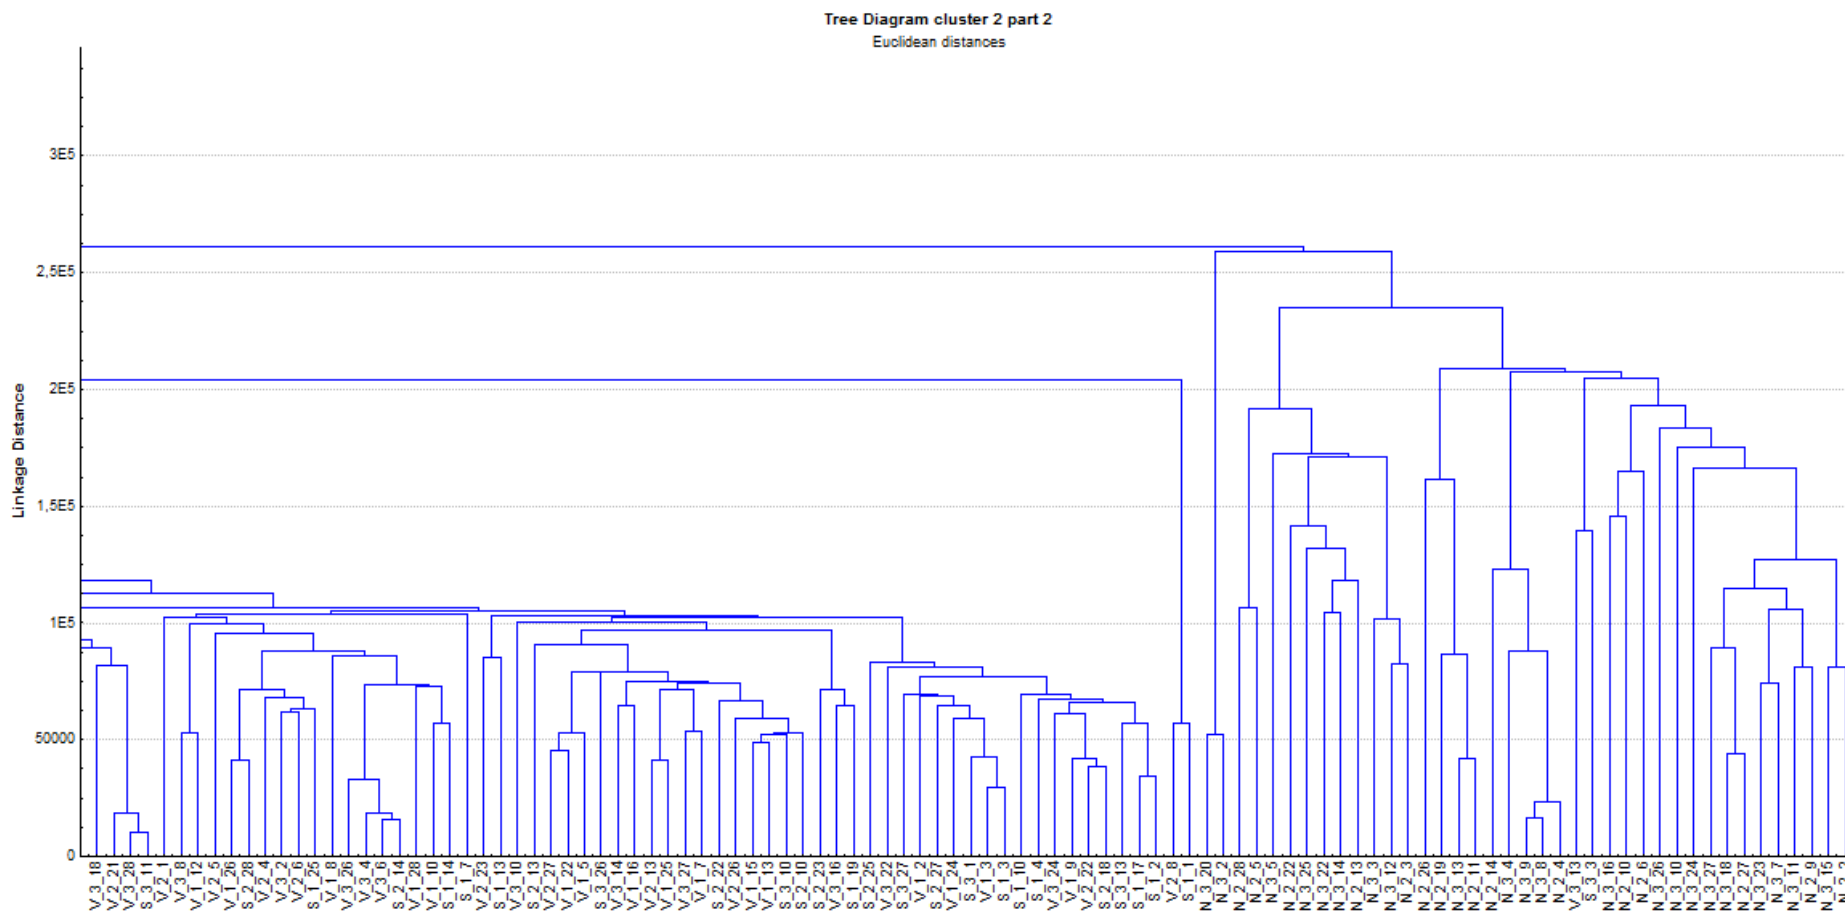
Obr. 5.22 Shlukovací strom pro shluk 2



Obr. 5.23 a) Shluk 2 část 1



Obr. 5.23 b) Shluk 2 část 2



Shlukovací strom rozdělil data do 2 shluků (Obr. 5.20). V prvním shluku (Obr. 5.21) byly materiály *bez výztuže* a materiály s úrovní výztuže *nizká 1*. Do druhého shluku byly zařazeny ostatní zbylé materiály (Obr. 5.22). Pro špatné rozlišení osy byl obrázek rozdělen na dvě části (Obr. 5.23 a, b). Rozdělení do shluků prodtřednictvím shlukovacího stromu je naprosto shodné s rozdělením shlukovací analýzy, při níž byla použita Kohonenova síť (1,2).

Shluková analýza byla provedena ještě pro Kohonenovu síť (2,2). Tato neuronová síť rozdělila data do 4 shluků. První shluk obsahoval stejná data jako první shluk, který byl určen shlukovacím stromem a Kohonenem (1,2). Při porovnání zbylých tří shluků s druhým shlukem, který byl sestaven shlukovacím stromem se rozdělení ani v nejmenším neshodují. Je to způsobené rozdílnými metodami pro vytváření shluků. Shlukovací strom sestavuje shluky podle Eukleidovských vzdáleností. Při shlukové analýze se data rozdělují do shluků podle určitého algoritmu.


Shluky získané výše zmíněnými způsoby byly vyneseny do tabulek (Tab. 5.19 a, b, c).

6 Statistická analýza dat s využitím neuronových sítí v programu QC Expert

Tento program nabízí celkem 2 statistické analýzy s použitím neuronových sítí. Je to klasifikační analýza a regresní analýza. Na rozdíl od programu STATISTICA tento program umožňuje vytvářet více než jednu skrytou vrstvu neuronů. Neumožňuje však natrénovat větší počet sítí najednou, ale pouze jednu v daný okamžik. Každá natrénovaná síť je originálem, tzn. že při opakovaném trénování neuronové sítě stejných parametrů se s velkou pravděpodobností nedojde ke stejným výsledkům jako u sítě předcházející. Tento program navíc používá pouze jediný druh aktivační funkce a to sigmoidu . [12]

6.1 Regrese

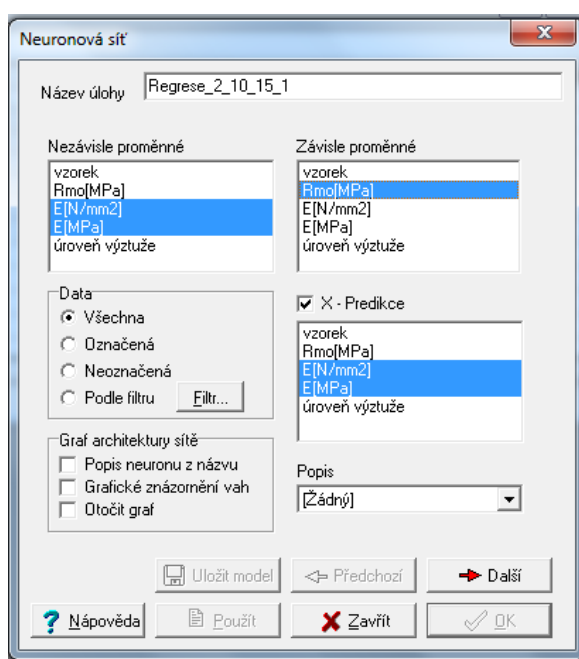
Po spuštění programu QC Expert a vložení trénovacích dat je možné spustit modul neuronová síť, který se ukrývá pod položkou prediktivní metody (Obr. 6.1).



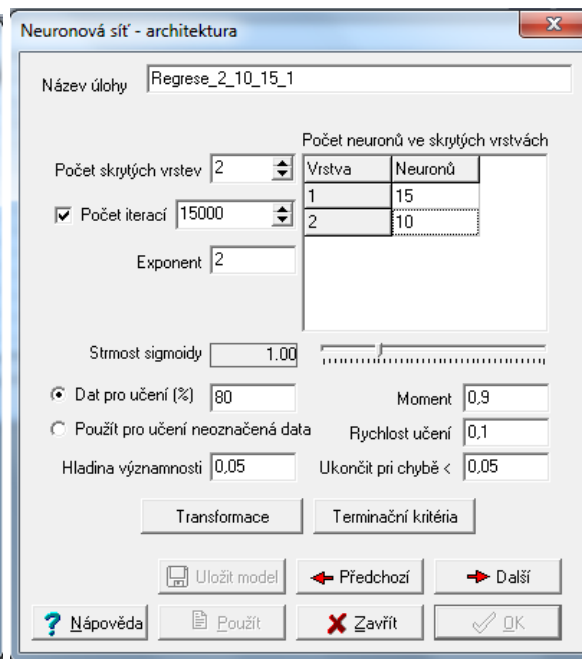
Obr. 6.1 Výběr modulu neuronová síť

V následujícím kroku se otevře okno, v němž je možné nastavit závisle a nezávisle proměnné. Zaškrtnutím možnosti predikce a výběrem nezávisle proměnných se vypočtou predikované hodnoty pro závisle proměnné. Regrese byla provedena v tomto programu také dvakrát. Nejprve byla jako závisle proměnná zvolena síla v ohybu a Youngovi moduly jako nezávisle proměnné. Pak se proměnné prohodily, jak tomu bylo také v programu STATISTICA.

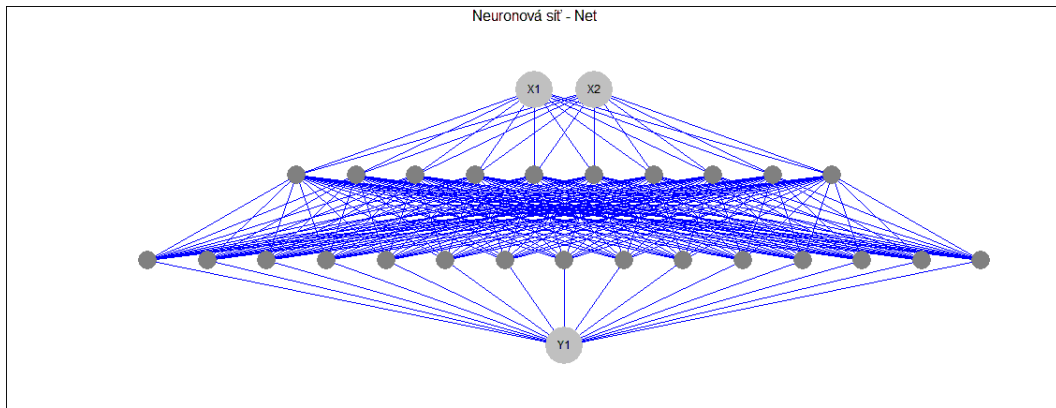
V dalším okně je možné nastavit počet skrytých vrstev a množství neuronů obsažených v jednotlivých vrstvách. V tomto okně se také volí počet iterací, kterých má být při výpočtu provedeno. Dále je možné nastavit strmost sigmoidy, která zůstala na implicitní hodnotě. Pak je také třeba určit kolik procent dat má být použito pro učení (trénování) sítě. Zbylá data se použijí jako testovací hodnoty. Tyto hodnoty si program volí automaticky.



Obr. 6.2 Výběr proměnných

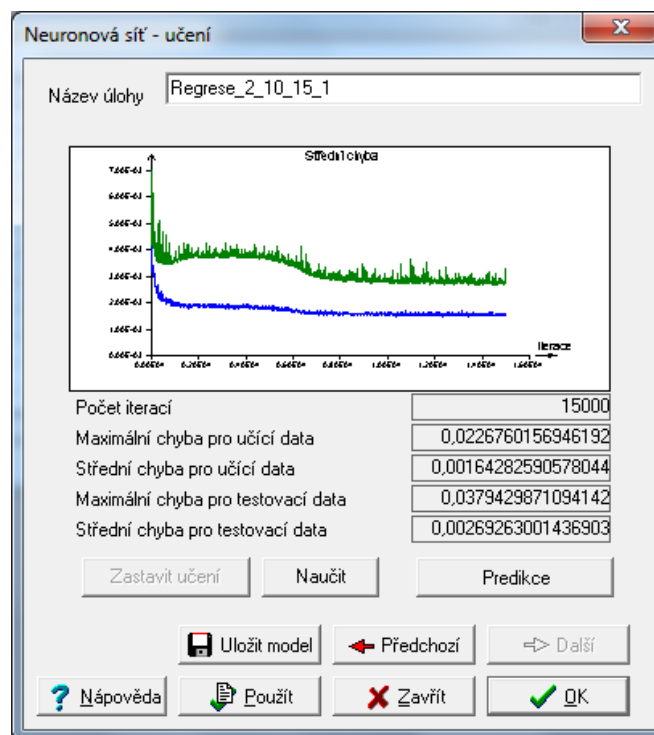


Obr. 6.3 Nastavení parametrů neuronové sítě



Obr. 6.4 Neuronová síť MLP 2-10-15-1 se dvěma skrytými vrstvami

Při trénování se zobrazuje střední chyba učicích a testovacích dat pro jednotlivé iterace, které jsou zároveň vynášeny do grafu (Obr 6.5). Síť je poté možno uložit včetně grafu trénování. U každé natrénované sítě se zobrazí obrázek její struktury (Obr. 6.4)



Obr. 6.5 Proces trénování neuronové sítě

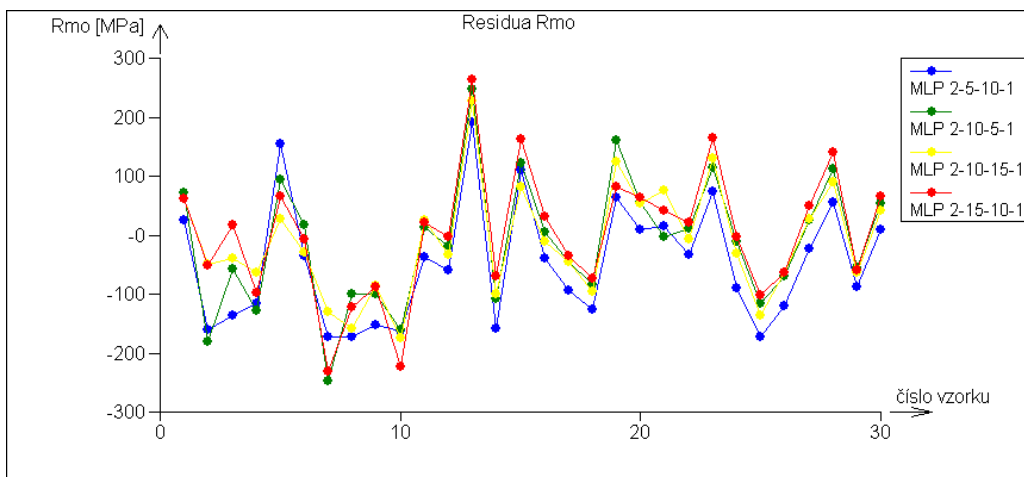
Z trénovacího grafu je patrné, že při výpočtu střední hodnoty došlo k výskytu lokálního extrému, který je znakem přetrénování sítě. Toto přetrénování bylo následně odstraněno, což je patrné z poklesu křivky pro střední chybu testovacích dat

V modulu predikce je možné načíst si uloženou síť a po nahrání zkušebních dat vyzkoušet predikci sítě.

Tab. 6.6 Predikce R_{mo}

číslo	vzorek	Rmo [MPa] orig.	Rmo [MPa] MLP 2-5-10-1 Residua	Rmo [MPa] MLP 2-10-5-1 Residua	Rmo [MPa] MLP 2-10-15-1 Residua	Rmo [MPa] MLP 2-15-10-1 Residua
1	O_0_18	2872,11	25,199	72,453	61,391	62,368
2	O_0_25	3208,61	-159,739	-180,153	-50,327	-52,157
3	N_1_12	2829,04	-137,184	-57,367	-39,007	16,829
4	N_1_25	3176,63	-116,107	-128,252	-63,679	-98,773
5	N_2_5	1747,2	154,824	93,189	26,275	65,535
6	N_2_12	1957,13	-35,438	17,865	-30,301	-6,084
7	N_3_19	1940,17	-172,407	-248,007	-129,596	-231,536
8	N_3_21	2111,06	-172,936	-100,944	-159,042	-122,491
9	S_1_6	2005,51	-151,681	-99,364	-86,573	-88,071
10	S_1_15	2314,11	-161,943	-161,536	-173,853	-223,218
11	S_2_3	1907,85	-37,151	13,910	24,472	21,102
12	S_2_11	2103,48	-58,820	-19,007	-33,070	-3,428
13	S_3_13	1861,82	191,096	247,908	227,745	263,412
14	S_3_20	2027,61	-157,893	-107,282	-100,345	-69,717
15	V_1_19	1931,39	110,735	122,613	82,265	163,008
16	V_1_21	2105,96	-40,115	4,142	-11,148	31,930
17	V_2_9	2022,81	-93,131	-45,140	-44,720	-35,229
18	V_2_27	2141,57	-126,082	-83,977	-95,922	-72,845
19	V_3_7	2103,36	64,057	160,959	124,258	81,917
20	V_3_10	1942,06	9,451	55,432	52,735	63,160
21	O_0_med	3048,995	15,568	-2,429	76,156	42,207
22	N_1_med	3024,25	-32,891	10,773	-7,241	20,574
23	N_2_med	1834,88	73,763	113,672	130,480	163,966
24	N_3_med	2056,645	-89,065	-10,546	-31,661	-2,753
25	S_1_med	2225,52	-173,611	-117,147	-137,094	-102,913
26	S_2_med	2012,69	-120,746	-70,562	-64,000	-62,903
27	S_3_med	1942,97	-23,901	25,958	26,892	49,200
28	V_1_med	2006,725	54,803	111,308	90,904	139,660
29	V_2_med	2090,66	-87,937	-56,448	-64,102	-60,065
30	V_3_med	2000,72	9,467	52,987	41,403	65,121
odmocnina ze sumy kvadrátů residuí			610,147	593,017	504,797	583,213

Nejlépe predikující sítí je MLP 2-10-15-1. Tato sítí byla také nejlépe natrénovanou sítí. Největší residuum bylo zjištěno pro vzorek S_3_13, což platí pro všechny uvedené sítě. Velká residua byla také u vzorků: N_3_19, N_3_21, S_1_15 a S_1_med.



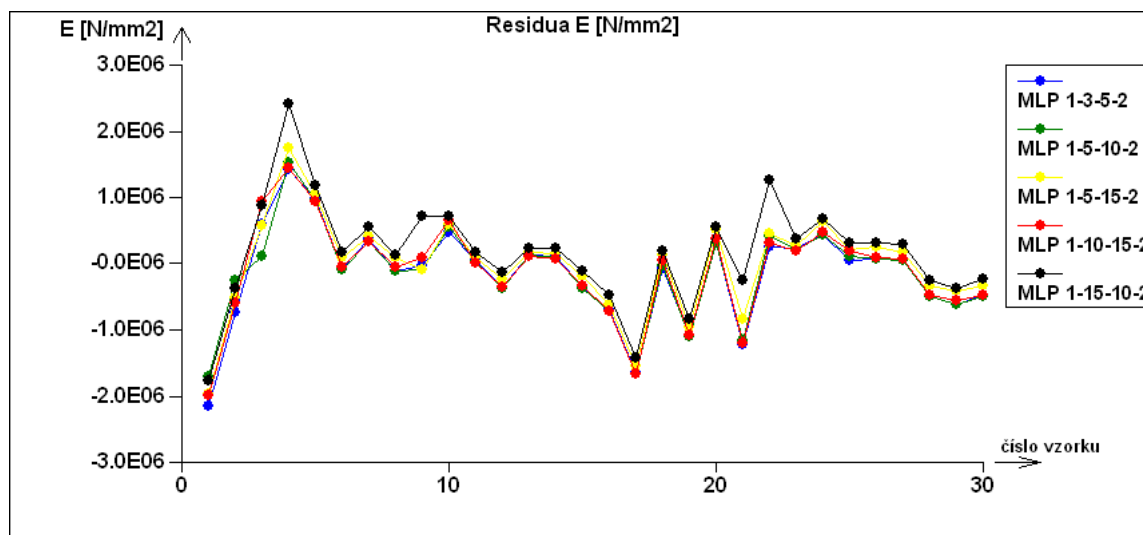
Obr. 6.7 Graf residuí R_{mo}

Mezi jednotlivými sítěmi panují znatelné výchyly v residuích. Největší rozdíly mezi residuí jednotlivých sítí jsou pro materiály *bez výztuže* a *nizká 1*. Nejvíce odlišný průběh residuí má křivka MLP 2-5-10-1.

Tab. 6.8 Predikce E [N/mm²]

číslo	vzorek	E [N/mm ²] orig.	E [N/mm ²] MLP 1-3-5-2 Residua	E [N/mm ²] MLP 1-5-10-2 Residua	E [N/mm ²] MLP 1-5-15-2 Residua	E [N/mm ²] MLP 1-10-15-2 Residua	E [N/mm ²] MLP 1-15-10-2 Residua
1	0_0_18	13 405 149,0	-2 150 364,73	-1 715 674,15	-1 962 605,74	-1 987 856,34	-1 765 072,41
2	0_0_25	12 000 349,0	-739 867,90	-261 121,99	-518 527,72	-587 353,61	-369 348,86
3	N_1_12	11 702 951,0	600 975,71	120 322,45	584 119,76	948 753,29	882 125,56
4	N_1_25	10 069 736,0	1 428 917,95	1 523 030,93	1 743 218,81	1 453 287,19	2 412 148,04
5	N_2_5	6 079 397,0	979 183,00	955 440,75	1 045 943,36	945 050,27	1 178 087,55
6	N_2_12	7 375 691,0	-75 712,30	-84 641,82	89 454,60	-53 735,80	168 041,51
7	N_3_19	6 655 659,0	363 731,91	338 987,10	421 005,25	324 810,41	550 227,58
8	N_3_21	7 518 293,0	-109 922,46	-105 413,36	94 341,53	-47 446,77	134 561,50
9	S_1_6	7 753 367,5	-35 219,43	-99 639,22	-83 539,60	100 064,32	715 597,17
10	S_1_15	6 997 718,0	484 537,13	562 695,41	591 946,04	655 516,47	723 232,31
11	S_2_3	6 817 005,5	47 288,53	25 585,41	87 162,74	5 801,50	178 393,73
12	S_2_11	7 604 952,0	-362 436,21	-375 869,95	-224 819,75	-357 161,04	-123 681,17
13	S_3_13	6 643 039,5	137 214,03	123 206,08	179 603,65	106 333,30	239 259,06
14	S_3_20	6 739 660,5	105 340,85	84 978,46	145 123,65	65 519,66	229 492,88
15	V_1_19	7 648 083,5	-360 894,34	-370 886,98	-201 828,02	-342 802,22	-117 935,47
16	V_1_21	7 846 486,5	-702 083,66	-721 923,09	-607 198,06	-720 878,60	-480 349,46
17	V_2_9	8 841 511,0	-1 649 870,46	-1 666 826,95	-1 535 553,14	-1 657 824,14	-1 418 632,68
18	V_2_27	7 523 286,0	-63 496,33	-33 510,37	124 810,84	45 179,90	183 729,01
19	V_3_7	8 260 966,5	-1 075 598,85	-1 092 961,45	-964 001,95	-1 085 077,01	-845 486,30
20	V_3_10	7 081 812,0	317 783,94	320 533,55	520 680,14	375 974,02	562 452,24
21	0_0_med	12 739 389,0	-1 216 593,63	-1 154 469,48	-836 883,91	-1 202 889,12	-248 521,56
22	N_1_med	11 189 336,0	261 435,15	417 496,35	453 237,88	309 055,83	1 257 245,17
23	N_2_med	6 669 324,0	236 785,47	212 976,55	278 343,79	193 240,40	383 194,53
24	N_3_med	6 940 317,0	431 487,96	429 915,16	626 962,72	477 912,67	676 647,64
25	S_1_med	7 415 773,0	51 795,96	108 771,07	211 558,91	198 331,39	305 099,99
26	S_2_med	7 222 373,0	77 568,53	68 635,86	242 717,83	99 533,59	321 320,30
27	S_3_med	7 073 824,0	78 530,96	59 146,75	176 508,29	61 453,93	302 028,37
28	V_1_med	7 783 322,0	-494 628,63	-504 498,41	-334 841,18	-476 084,97	-251 566,98
29	V_2_med	8 034 752,0	-621 994,28	-616 498,95	-417 280,77	-557 224,35	-377 593,87
30	V_3_med	7 758 620,0	-481 570,26	-492 377,58	-327 379,97	-466 486,55	-239 369,49
odmocnina ze sumy kvadrátů residuí			4 044 636,30	3 775 260,65	3 891 737,06	4 027 125,61	4 347 139,06

Nejlépe predikující sítí byla MLP 1-5-10-2, která svou predikční schopností výrazněji předčila většinu zkoušených sítí. Nejhorše predikovaným vzorkem byl materiál 0_0_18. Mezi špatně predikované vzorky také patřily: N_1_25, V_2_9, V_3_7 a 0_0_med. Nejlépe natrénovanou sítí byla MLP 1-5-15-2, jejíž predikční schopnost je srovnatelná s MLP 1-5-10-2. Nejhorše predikující sítí byla neuronová sít' MLP 1-15-10-2.



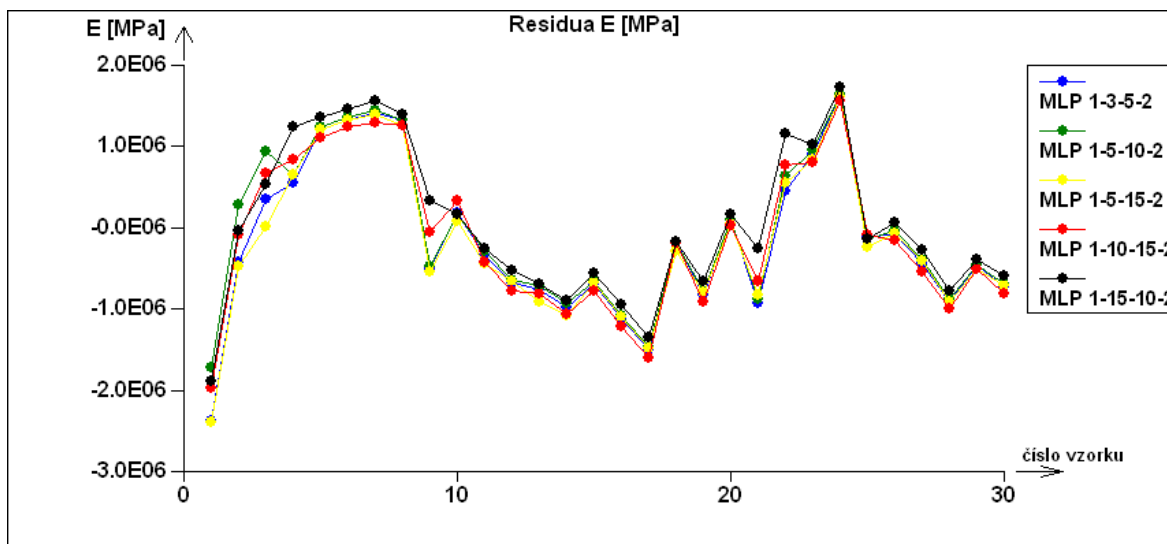
Obr. 6.9 Graf residuí E [N/mm2]

Nejvíce odlišný průběh má MLP 1-15-10-2. Průběhy ostatních sítí jsou až na malé rozdíly srovnatelné. K nejmenším výchylkám došlo u všech stupňů *střední* úrovně výztuže a u prvního stupně *vysoké* úrovně výztuže. Většina mediánů dosáhla také nízkých výchylek.

Tab. 6.10 Predikce E [MPa]

číslo	vzorek	E [Mpa] orig.	E [Mpa] MLP 1-3-5-2 Residua	E [Mpa] MLP 1-5-10-2 Residua	E [Mpa] MLP 1-5-15-2 Residua	E [Mpa] MLP 1-10-15-2 Residua	E [Mpa] MLP 1-15-10-2 Residua
1	0_0_18	17 516 858,0	-2 381 394,40	-1 726 584,53	-2 395 420,21	-1 978 848,37	-1 884 540,57
2	0_0_25	15 458 511,0	-429 902,26	286 087,32	-481 386,91	-94 039,13	-41 374,85
3	N_1_12	16 733 284,0	349 393,74	944 302,18	12 443,40	676 503,38	527 292,60
4	N_1_25	15 206 869,0	552 112,64	649 275,36	656 590,62	841 690,79	1 236 886,19
5	N_2_5	5 798 808,0	1 213 921,96	1 247 288,98	1 208 120,71	1 102 106,53	1 365 152,64
6	N_2_12	6 210 926,5	1 325 222,90	1 353 793,49	1 332 158,81	1 248 223,85	1 461 572,43
7	N_3_19	5 520 110,0	1 413 173,23	1 446 723,48	1 392 696,51	1 301 129,96	1 554 781,33
8	N_3_21	6 493 203,5	1 322 726,33	1 326 856,49	1 267 254,62	1 266 935,65	1 386 380,66
9	S_1_6	8 766 481,0	-507 118,32	-476 578,10	-541 487,88	-60 085,33	327 916,77
10	S_1_15	7 960 618,5	183 566,61	173 102,57	75 747,78	328 252,22	171 130,22
11	S_2_3	6 968 733,5	-340 320,65	-296 408,40	-438 994,27	-428 150,98	-250 340,54
12	S_2_11	8 086 895,0	-682 674,55	-649 735,77	-663 386,16	-770 625,45	-527 971,63
13	S_3_13	7 230 476,5	-761 801,46	-702 661,18	-912 040,30	-818 123,99	-699 223,25
14	S_3_20	7 565 866,0	-974 437,14	-927 729,78	-1 084 506,92	-1 056 200,58	-891 169,65
15	V_1_19	8 199 272,5	-693 092,54	-663 192,02	-682 353,91	-772 528,20	-551 658,21
16	V_1_21	8 307 219,5	-1 116 239,33	-1 082 115,72	-1 100 043,79	-1 220 544,31	-953 400,76
17	V_2_9	8 800 381,0	-1 508 249,32	-1 474 064,47	-1 487 187,56	-1 605 353,91	-1 346 052,98
18	V_2_27	8 178 362,5	-169 564,78	-193 039,91	-282 734,56	-191 411,96	-176 012,00
19	V_3_7	8 098 923,5	-820 371,01	-786 144,82	-799 616,31	-918 521,32	-657 758,88
20	V_3_10	7 699 035,5	91 348,61	98 668,08	43 339,63	33 455,02	163 417,33
21	0_0_med	16 739 895,0	-933 158,28	-879 545,32	-826 821,41	-660 168,85	-264 128,09
22	N_1_med	15 206 869,0	454 699,18	641 738,55	552 081,85	777 639,65	1 163 800,02
23	N_2_med	5 798 808,0	910 438,02	949 588,14	835 399,58	811 838,77	1 015 256,34
24	N_3_med	6 082 040,0	1 632 179,52	1 647 866,22	1 604 612,49	1 568 604,76	1 727 345,19
25	S_1_med	8 206 813,0	-116 755,35	-146 117,97	-240 817,81	-82 781,99	-145 581,42
26	S_2_med	7 608 180,0	-72 118,27	-43 543,46	-65 170,38	-149 124,38	64 246,92
27	S_3_med	7 640 536,0	-432 697,68	-398 515,43	-415 285,09	-535 911,41	-269 578,93
28	V_1_med	8 424 612,0	-914 927,54	-885 171,43	-904 603,19	-994 075,94	-774 059,99
29	V_2_med	8 282 645,0	-453 576,49	-451 157,13	-512 981,98	-508 211,78	-394 370,38
30	V_3_med	8 212 795,0	-730 105,72	-699 310,35	-716 797,77	-811 480,57	-585 062,57
odmocnina ze sumy kvadrátů residuí			5 169 672,47	4 964 799,46	5 178 821,15	5 075 579,88	5 060 715,26

Nejlepší predikční schopnost měla MLP 1-5-10-2. Tato síť je také nejlépe natrénovanou sítí. Nejhorší predikci měla MLP 1-3-5-2. Největší residuální hodnota byla pro vzorek 0_0_18. Velká residua byla vypočtena pro vzorky *nizké* úrovně 2. a 3. stupně. Velkých residuí dosáhly také vzorky: V_1_21, V_2_9 a N_3_med.



Obr. 6.11 Graf residuí E [MPa]

Největší rozdíly mezi křivkami jsou v první části grafu: ve vzorcích *bez výztuže* a *nízké* úrovně výztuže. Ve zbylých částech grafu jsou průběhy srovnatelné. Výchytky residuí dosahovaly vždy určitého stupně a jen některé z nich se přiblížily nižším hodnotám. Nízkých hodnot residuí dosáhly pouze vzorky: 0_0_25, S_1_15, V_3_10.

6.2 Klasifikace

U klasifikace se postupuje analyticky jako u regrese. S tím rozdílem, že se vybere modul ANN klasifikace. Jako závisle proměnná se vybere úroveň výztuže a jako nezávislé proměnné síla v ohybu a Youngovi moduly. Po natrénování a uložení sítě se načtou zkušební data a provede se klasifikační analýza. Výsledkem je pravděpodobnostní tabulka, v níž byly tučně zvýrazněny dvě hlavní diagonály, ve kterých by se měly vyskytovat správná řešení. Když se skutečná hodnota shodovala s předpovídanou hodnotou, byla označena zeleně. V případě neshody byla předpovídaná hodnota s nejvyšší pravděpodobností označena červeně. Pravděpodobnostní tabulka byla doplněna o sloupec s předpovídanou úrovní výztuže a o sloupec se skutečnou úrovní výztuže.

Obr. 6.12 Klasifikace zkušebních hodnot

	bez výztuže	nízká 1	nízká 2	nízká 3	střední 1	střední 2	střední 3	vysoká 1	vysoká 2	vysoká 3	predikovaná úroveň	skutečná úroveň
O_0_18	0,99890671	0,008392	8,72E-14	2,56E-16	2,67E-08	7,06E-13	3,49E-18	8,00E-09	2,26E-18	0,000529	bez výztuže	bez výztuže
O_0_25	0,99938678	0,008446	1,38E-15	1,90E-14	1,14E-09	3,04E-16	1,39E-18	1,32E-06	4,52E-17	0,003662	bez výztuže	bez výztuže
N_1_12	3,19E-09	0,999997	4,56E-11	9,08E-20	1,99E-07	2,15E-10	3,01E-06	0,006069	3,22E-17	3,04E-12	nízká 1	nízká 1
N_1_25	0,99938631	0,00845	1,38E-15	1,90E-14	1,14E-09	3,04E-16	1,39E-18	1,32E-06	4,52E-17	0,003659	bez výztuže	nízká 1
N_2_5	1,29E-12	3,80E-11	0,997441	0,00311	6,50E-12	5,55E-09	9,41E-14	5,57E-11	4,99E-18	1,29E-17	nízká 2	nízká 2
N_2_12	4,21E-15	1,39E-12	0,999782	0,00264405	2,25E-13	1,02E-15	0,002504	2,74E-15	3,63E-15	3,65E-05	nízká 2	nízká 2
N_3_19	1,55E-08	8,93E-13	0,000386	0,99774131	1,51E-05	0,000725	5,01E-18	1,93E-15	2,10E-14	1,24E-06	nízká 3	nízká 3
N_3_21	5,39E-09	6,21E-18	7,68E-07	0,9999999	3,17E-13	4,47E-16	1,49E-17	4,53E-14	1,55E-17	5,09E-13	nízká 3	nízká 3
S_1_6	1,99E-20	3,26E-15	6,34E-05	2,13E-15	3,59E-06	7,20E-09	0,061085	2,90E-16	1,22E-16	3,15E-16	střední 3	střední 1
S_1_15	5,36E-11	2,44E-13	5,35E-18	2,65E-12	0,999858	5,32E-08	3,06E-08	7,41E-11	1,71E-10	5,42E-13	střední 1	střední 1
S_2_3	5,37E-17	2,15E-13	0,001113	1,31E-17	1,82E-13	5,63E-13	0,792924	1,55E-08	1,78E-17	7,92E-15	střední 3	střední 2
S_2_11	3,37E-15	0,001551	4,34E-13	1,55E-15	1,37E-08	1,01E-11	4,48E-10	1,83E-05	0,9999998	3,01E-19	vysoká 2	střední 2
S_3_13	1,98E-11	0,001517	0,00233	3,88E-18	7,08E-18	4,92E-08	0,000243	1,50E-14	2,69E-30	2,68E-10	nízká 2	střední 3
S_3_20	2,00E-20	3,24E-15	6,30E-05	2,14E-15	3,54E-06	7,20E-09	0,061566	2,89E-16	1,23E-16	3,20E-16	střední 3	střední 3
V_1_19	2,66E-12	3,04E-16	2,53E-17	1,26E-10	5,12E-13	9,86E-21	3,28E-11	0,999754	0,999841	1,66E-06	vysoká 1	vysoká 1
V_1_21	2,55E-15	0,002887	4,48E-13	1,50E-15	1,30E-08	1,12E-11	4,41E-10	1,37E-05	0,9999999	2,13E-19	vysoká 2	vysoká 1
V_2_9	4,62E-20	1,40E-15	2,27E-12	2,84E-16	0,15582	5,26E-11	0,000307	3,70E-06	1,84E-06	0,000102	střední 1	vysoká 2
V_2_27	8,47E-12	1,41E-16	7,76E-09	2,02E-19	6,03E-13	1,03E-06	6,21E-12	0,391812	0,206552	1,12E-08	vysoká 1	vysoká 2
V_3_7	1,45E-19	1,82E-12	7,85E-12	5,68E-17	0,913732	2,02E-11	0,000206	7,99E-05	3,29E-06	2,33E-09	střední 3	vysoká 3
V_3_10	2,70E-16	7,68E-12	0,004247	1,13E-17	5,44E-14	3,59E-12	0,776806	8,02E-10	1,25E-19	8,11E-14	střední 3	vysoká 3
O_0_med	0,99938678	0,008446	1,38E-15	1,90E-14	1,14E-09	3,04E-16	1,39E-18	1,32E-06	4,52E-17	0,003662	bez výztuže	bez výztuže
N_1_med	0,00023776	0,984279	3,74E-15	2,04E-15	0,001536	1,18E-09	2,78E-14	2,71E-06	1,15E-25	4,27E-13	nízká 1	nízká 1
N_2_med	2,79E-15	5,63E-13	0,998638	0,00057902	3,01E-13	3,82E-15	0,004501	1,97E-15	4,61E-15	1,09E-05	nízká 2	nízká 2
N_3_med	7,17E-08	2,07E-18	1,36E-09	0,999999999	3,25E-09	2,01E-13	6,74E-15	1,97E-15	2,90E-19	3,55E-17	nízká 3	nízká 3
S_1_med	5,95E-11	2,30E-13	6,04E-18	2,36E-12	0,999842	5,97E-08	2,82E-08	7,19E-11	1,80E-10	6,02E-13	střední 1	střední 1
S_2_med	1,96E-20	2,83E-15	5,45E-05	1,93E-15	3,47E-06	4,81E-09	0,077398	3,51E-16	1,34E-16	5,11E-16	střední 3	střední 2
S_3_med	1,99E-20	3,28E-15	6,36E-05	2,12E-15	3,61E-06	7,18E-09	0,060909	2,91E-16	1,22E-16	3,14E-16	střední 3	střední 3
V_1_med	1,24E-13	1,21E-14	1,34E-10	5,86E-17	2,93E-08	2,30E-17	0,000117	0,003904	0,000655	0,76327	vysoká 3	vysoká 1
V_2_med	8,21E-18	2,28E-11	2,22E-12	3,47E-15	1,06E-12	1,27E-11	3,63E-11	6,45E-07	0,99974	2,22E-07	vysoká 2	vysoká 2
V_3_med	6,70E-17	1,72E-12	1,18E-09	3,04E-18	1,00E-07	3,62E-13	0,002067	0,873587	1,26E-08	1,56E-05	vysoká 1	vysoká 3

Nejlépe klasifikující neuronovou sítí byla MLP 3-25-15-10. Tato síť klasifikovala správně 17 ze 30 materiálů. K chybné klasifikaci došlo záměnou za jiný materiál v rámci shluků (viz. podkap. 5.3). Materiál *bez výztuže* byl zaměněn pouze s materiálem, jehož úroveň výztuže byla *nízká 1*. Tato síť naprosto selhala v klasifikaci materiálů s úrovní výztuže *střední 2* a *vysoká 3*. Zcela správně byl klasifikován pouze materiál s úrovní výztuže *nízká 3*. K malým nepřesnostem došlo u úrovní *bez výztuže*, *nízká 1* a *2*. Nejčastěji predikovanou úrovní byla *střední 3*. Nejvíce chybných klasifikací proběhlo u materiálů s úrovní výztuže *střední* a *vysoká*. Tyto materiály byly často zaměněny mezi sebou. V některých případech došlo ke špatnému přiřazení stupně úrovně, i když samotná úroveň byla určena správně.

7 Porovnání programů

Program STATISTICA umožňuje natrénování velkého množství sítí s tím, že program sám zvolí síť s nejlepšími vlastnostmi. Proces trénování je časově a paměťově náročný. Program umožňuje natrénovat pouze sítě s jednou skrytou vrstvou. Po vyzkoušení natrénovaných sítí je možné zobrazit výsledky v tabulce, jež nevyžaduje velkých úprav a může být použita rovnou. Zobrazit lze i další tabulky jako např. pravděpodobnostní tabulku, tabulku vah, apod. Tento program nabízí široké spektrum 2D a 3D grafů. Grafy mají širokou škálu možností nastavit nejrůznější parametry, ať už jedná o textovou nebo vizuální stránku grafu.

V programu QC Expert se trénuje vždy jen jedna síť. Tento proces není tak časově ani paměťově náročný. Nalezení vhodné sítě závisí na počtu natrénovaných sítí a pak už záleží jen na uživateli, kterou z nich zvolí jako nejlepší. Proces trénování sítě se zobrazuje v grafu pro střední chybu. Zobrazení výsledků je shrnuto v jediném dokumentu, který se musí upravit do tabulky. Grafy nabízené v tomto programu jsou pouze základní. Nenabízí takovou možnost nastavení, jako to bylo u předchozího programu. Dokonce není možné změnit měřítko os. Program umožňuje trénování vícevrstevných sítí. Počet vrstev je volitelný.


7.1 Regrese

Pro srovnání regresní analýzy z obou programů byla vybrána vždy nejlépe predikující síť. Sítě byly porovnány jak v tabulce, tak v grafu residuí. Grafy byly vyneseny v programu STATISTICA.

Tab. 7.1 Porovnání nejlepších sítí pro předpověď R_{mo}

Case name	Rmo [MPa] Target	Rmo [MPa] - Residuals1. MLP 2-3-1	Rmo [MPa] MLP 2-10-15-1 Residua
O_0_18	2872,110	31,740	61,391
O_0_25	3208,610	-144,163	-50,327
N_1_12	2829,040	-29,794	-39,007
N_1_25	3176,630	-128,662	-63,679
N_2_5	1747,200	147,527	26,275
N_2_12	1957,130	-72,563	-30,301
N_3_19	1940,170	-81,969	-129,596
N_3_21	2111,060	-220,871	-159,042
S_1_6	2005,510	-9,135	-86,573
S_1_15	2314,110	-272,355	-173,853
S_2_3	1907,850	96,345	24,472
S_2_11	2103,480	-18,593	-33,070
S_3_13	1861,820	207,426	227,745
S_3_20	2027,610	-36,204	-100,345
V_1_19	1931,390	149,842	82,265
V_1_21	2105,960	-8,837	-11,148
V_2_9	2022,810	1,722	-44,720
V_2_27	2141,570	-74,794	-95,922
V_3_7	2103,360	17,201	124,258
V_3_10	1942,060	92,528	52,735
O_0_med	3048,995	6,776	76,156
N_1_med	3024,250	-38,251	-7,241
N_2_med	1834,880	45,004	130,480
N_3_med	2056,645	-157,378	-31,661
S_1_med	2225,520	-158,066	-137,094
S_2_med	2012,690	-1,739	-64,000
S_3_med	1942,970	72,007	26,892
V_1_med	2006,725	77,591	90,904
V_2_med	2090,660	-25,309	-64,102
V_3_med	2000,720	62,195	41,403
odmocnina ze sumy kvadrátů residuí		596,640	504,797

Nejlépe natrénovaná síť nemá nejlepší predikční schopnost pro zkušební data. Tento jev platí pro oba programy. Lepší predikční schopnost má neuronová síť MLP 2-3-1, která v 16 ze 30 případů predikovala lépe než MLP 2-10-15-1. Je to mírný nepoměr a lze tedy tvrdit, že tyto sítě mají srovnatelnou predikční schopnost. Největší residuální hodnota se vyskytuje u této dvouvrstvé sítě. Nejmenší pak u sítě MLP 2-3-1. Největší rozdíl mezi residuí byl u vzorku N_2_5 a u mediánu N_3_med. Rozdíl mezi odmocninami ze sumy kvadrátů residuí (dále už jen kritérium výběru sítě) je malý. Toto kritérium nebylo vždy rozhodujícím faktorem pro určení sítě s lepší predikční schopností.



Obr. 7.2 Porovnání nejlepších sítí pro předpověď R_{mo}

Mezi křivkami jsou mírné rozdíly a to včetně predikovaných mediánů. U některých vzorků jsou rozdíly v residuích zanedbatelné, např. N_1_12, S_2_11, S_3_13, V_1_21, V_2_27 a V_1_med. Obě sítě jsou ve schopnosti predikce srovnatelné. Pro materiály *bez výztuže* a úroveň *nizká* a *střední* dosahuje neuronová síť MLP-2-3-1 vyšších výchylek residuí než neuronová síť MLP 2-10-15-1. Vyskytují se samozřejmě výjimky: 0_0_18, N_2_19, S_1_6, S_3_20. Pro *vysokou* úroveň výztuže má lepší predikční schopnost MLP 2_3_1. V predikovaných mediánech jsou nejznatelnější rozdíly mezi sítěmi. Největší rozdíl mezi předpovídanými hodnotami v tomto úseku je u mediánu N_2_med a N_3_med.


Tab. 7.3 Předpovědi Youngových modulů

case name	E [N/mm ²] Target	E [N/mm ²] - Residuals 1. MLP 1-14-2	E [N/mm ²] MLP 1-5-10-2 Residua
0_0_08	13 405 149,0	-2 043 100,58	-1 715 674,15
0_0_18	12 000 349,0	-701 502,17	-261 121,99
N_1_1	11 702 951,0	747 369,08	120 322,45
N_1_16	10 069 736,0	1 599 738,60	1 523 030,93
N_2_8	6 079 397,0	1 216 068,82	955 440,75
N_2_22	7 375 691,0	131 205,30	-84 641,82
N_3_8	6 655 659,0	602 763,72	338 987,10
N_3_22	7 518 293,0	64 455,55	-105 413,36
S_1_7	7 753 367,5	468 350,14	-99 639,22
S_1_23	6 997 718,0	508 888,57	562 695,41
S_2_8	6 817 005,5	281 602,36	25 585,41
S_2_22	7 604 952,0	-145 972,22	-375 869,95
S_3_7	6 643 039,5	354 990,86	123 206,08
S_3_22	6 739 660,5	336 995,95	84 978,46
V_1_7	7 648 083,5	-151 662,76	-370 886,98
V_1_22	7 846 486,5	-472 903,16	-721 923,09
V_2_7	8 841 511,0	-1 426 332,28	-1 666 826,95
V_2_22	7 523 286,0	38 006,46	-33 510,37
V_3_9	8 260 966,5	-851 260,54	-1 092 961,45
V_3_23	7 081 812,0	496 728,72	320 533,55
0_0_med	12 739 389,0	-1 048 938,55	-1 154 469,48
N_1_med	11 189 336,0	436 918,60	417 496,35
N_2_med	6 669 324,0	474 996,81	212 976,55
N_3_med	6 940 317,0	621 293,93	429 915,16
S_1_med	7 415 773,0	74 875,38	108 771,07
S_2_med	7 222 373,0	284 493,06	68 635,86
S_3_med	7 073 824,0	306 824,54	59 146,75
V_1_med	7 783 322,0	-285 662,45	-504 498,41
V_2_med	8 034 752,0	-450 210,25	-616 498,95
V_3_med	7 758 620,0	-270 592,02	-492 377,58
odmocnina ze sumy kvadrátů residuí		4 020 075,09	3 775 260,65

case name	E [MPa] Target	E [MPa] - Residuals 1. MLP 1-14-2	E [MPa] MLP 1-5-10-2 Residua
0_0_08	17 516 858,0	-2 295 292,42	-1 726 584,53
0_0_18	15 458 511,0	-405 954,41	286 087,32
N_1_1	16 733 284,0	393 907,03	944 302,18
N_1_16	15 206 869,0	649 343,44	649 275,36
N_2_8	5 798 808,0	1 351 229,30	1 247 288,98
N_2_22	6 210 926,5	1 392 184,81	1 353 793,49
N_3_8	5 520 110,0	1 558 284,46	1 446 723,48
N_3_22	6 493 203,5	1 348 410,49	1 326 856,49
S_1_7	8 766 481,0	643 616,71	-476 578,10
S_1_23	7 960 618,5	227 270,67	173 102,57
S_2_8	6 968 733,5	-186 436,75	-296 408,40
S_2_22	8 086 895,0	-597 071,80	-649 735,77
S_3_7	7 230 476,5	-626 316,80	-702 661,18
S_3_22	7 565 866,0	-822 915,83	-927 729,78
V_1_7	8 199 272,5	-621 927,49	-663 192,02
V_1_22	8 307 219,5	-1 000 787,29	-1 082 115,72
V_2_7	8 800 381,0	-1 406 740,76	-1 474 064,47
V_2_22	8 178 362,5	-204 101,07	-193 039,91
V_3_9	8 098 923,5	-716 956,20	-786 144,82
V_3_23	7 699 035,5	121 469,95	98 668,08
0_0_med	16 739 895,0	-844 650,11	-879 545,32
N_1_med	15 206 869,0	567 770,22	641 738,55
N_2_med	5 798 808,0	1 066 352,36	949 588,14
N_3_med	6 082 040,0	1 674 109,44	1 647 866,22
S_1_med	8 206 813,0	-201 950,74	-146 117,97
S_2_med	7 608 180,0	-5 144,09	-43 543,47
S_3_med	7 640 536,0	-319 519,55	-398 515,43
V_1_med	8 424 612,0	-844 255,04	-885 171,43
V_2_med	8 282 645,0	-430 319,41	-451 157,13
V_3_med	8 212 795,0	-655 631,86	-699 310,35
odmocnina ze sumy kvadrátů residuí		5 131 375,91	4 964 799,46


Lepší predikční schopnost modulu E [N/mm²] má neuronová síť z programu QC Expert: MLP 1-5-10-2. Tato síť predikovala lépe 18 hodnot. Rozdíl mezi kritérii výběru sítě je nezanedbatelný a prokazuje lepší predikční schopnost této sítě. Při srovnávání jednotlivých vzorků byl největší rozdíl v residuích u materiálu S_1_7. Největší residuum bylo u prvního vzorku. Vysoká residua byla vypočtena ještě pro: N_1_16, N_2_8, V_2_7 a 0_0_med.

Schopnost predikovat modul E [MPa] byla u obou sítí srovnatelná. Rozdíl mezi residui u jednotlivých vzorků byl většinou minimální. Rozdíl mezi kritérii výběru sítě nebyl tak značný jako u modulu E [N/mm²]. Nejhuře predikovaným vzorkem byl opět vzorek 0_0_8. U vzorků: V_1_22, V_2_7, N_2_med a N_3_med byly velké výchylky v residuích. Velká residua byla také u vzorků *nizké* úrovně výztuže se stupněm 2 a 3.



Obr. 7.4 Porovnání nejlepších sítí pro předpověď E [N/mm²]

Křivky mají podobný průběh s minimálním výskytem větších rozdílů mezi residui v rámci stejného vzorku. Největší rozdíly jsou ve vzorku N_1_1 a S_1_7. Průběh křivek je téměř totožný pro prvky úrovně vysoká stupně 2 a 3 a mediány 0_0_med a N_1_med. Neuronová síť MLP 1-5-10-2 má ve většině případů lepší predikční schopnosti než MLP 1-14-2.



Obr. 7.5 Porovnání nejlepších sítí pro předpověď E [MPa]

Největší rozdíly mezi křivkami jsou pro vzorky *bez výztuže* a s úrovní výztuže *nízká* 1, další rozdíl je v hodnotě S_1_7. Pro zbylé hodnoty mají křivky podobný průběh. Křivky jsou téměř totožné pro vzorky s *vysokou* úrovní výztuže všech stupňů a pro hodnoty všech mediánů.

7.2 Klasifikace

Lepší schopnost klasifikace měly neuronové sítě z programu STATISTICA, které správně určily 18 hodnot. Neuronová síť z programu QC Expert klasifikovala správně 17 úrovní výztuže. Pro klasifikaci materiálů *bez výztuže* a s úrovní výztuže *nízká* byly nejlepší neuronové sítě MLP 3-25-15-10 a MLP 3-9-10. Pro vzorky s úrovní výztuže *střední* a *vysoká* klasifikovaly nejlépe sítě MLP 3-3-10 a MLP 3-22-10. Tyto sítě se pro tyto hodnoty lišily jen v klasifikaci vzorků: S_1_6, V_2_9. V této části bylo nejlepšími sítěmi z programu STATISTICA klasifikováno 8 vzorků chybně. Neuronová síť MLP 3-25-15-10 klasifikovala chybně dokonce 9 vzorků. Mediány byly lépe klasifikovány sítěmi ze STATISTICY. Klasifikace mediánů prostřednictvím sítí z programu QC Expert dosáhla 3 chyb. To je nejvíce ze všech sítí trénovaných k tomuto účelu.

Závěr

Cílem diplomové práce bylo porovnat vybrané softwary v oblasti statistické analýzy s využitím neuronových sítí. Pro tento účel jsem obdržel data materiálových zkoušek, která byla získána při mechanických zkouškách kompozitních materiálů s různou úrovní výztuže: *bez výztuže, nízká 1, nízká 2, nízká 3, střední 1, střední 2, střední 3, vysoká 1, vysoká 2, vysoká 3*.

Při analýze dat využitím shlukovacího stromu v programu STATISTICA jsem zjistil, že hodnoty je nutné před samotnou analýzou upravit. Po vyřazení pokusných, extrémních a nejvíce odlehlých hodnot jsem data rozdělil na trénovací a zkušební. Trénovací data byla určena k natrénování neuronové sítě a k nalezení algoritmu. Tato data se ještě částečně dělila na testovací a na validační. Zkušební data nebyla použita k trénování neuronových sítí a sloužila k vyzkoušení predikční schopnosti sítě a k posouzení správné funkce modelu.

Program STATISTICA nabízí celkem tři analýzy, ve kterých je možné využít pro výpočty neuronové sítě. Jsou to: regresní analýza, klasifikační analýza a shluková analýza. QC Expert nabízí stejné typy analýz jako STATISTICA kromě shlukové analýzy.

První metodou v programu STATISTICA byla regresní analýza. Při této analýze se ze vstupů (nezávisle proměnných) předpovídají výstupy. V tomto programu jsem prováděl 2 regresní analýzy. Při první z nich se předpovídala pevnost v ohybu R_{mo} z Youngových modulů. U druhé se předpovídaly oba Youngovi moduly z pevnosti v ohybu. Pro předpovězení Youngových modulů se musely přerozdělit hodnoty podle jiného kritéria než tomu bylo u první regrese. Obě uspořádání hodnot byla použita také při regresních analýzách v programu QC Expert. Nejlépe predikující neuronovou sítí pro předpověď R_{mo} byla ta s nejmenším počtem neuronů ve skryté vrstvě MLP 2-3-1. Predikované výsledky od ostatních sítí jsou srovnatelné s výsledky této nejlepší sítě. Predikční schopnost tohoto modelu byla ve většině případů velmi dobrá.

Druhá regresní analýza prováděná v tomto programu, která predikovala oba činitele pružnosti E z jednoho vstupu, jímž byla pevnost v ohybu R_{mo} . Obě veličiny byly nejlépe predikovány stejnou sítí MLP 1-14-2. Rozdíly mezi residui dosahovaly v některých případech procentuálně vyšších výkyvů než tomu bylo u první regrese. Nejhůře predikovanými vzorky byly: *0_0_8* a *V_2_7*.

Pevnost v ohybu nejlépe predikovala v programu QC Expert dvouvrstvá síť MLP 2-10-15-1. Predikční schopnost této sítě je srovnatelná s MLP 2-3-1. Rozdíl v kritériu výběru sítě byl malý.

Pro druhou regresi byla nejlépe predikující sítí MLP 1-5-10-2. Predikční schopnost této sítě je pro Youngův modul v N/mm² podstatně lepší než u jednovrstvé sítě. Toto platí u většiny vzorků. Pro Youngův modul v MPa byla predikce této sítě srovnatelná s predikční schopností jednovrstvé sítě. Nejhorší predikovaný vzorek byl 0_0_8, stejně jako u jednovrstvé sítě MLP-1-14-2.

Při klasifikační analýze jsou zkušební vzorky na něž nebyla síť trénována rozřazeny programem do tříd. Následně jsou předpovězené třídy porovnány se skutečnými třídami. Lepší klasifikační schopnosti měly jednovrstvé sítě natrénované v programu STATISTICA. Dvouvrstvá síť z programu QC Expert klasifikovala špatně jeden vzorek navíc oproti zmiňovaným jednovrstvým sítím.

Shlukovací analýza byla provedena dvěma sítěmi. První z nich rozdělila hodnoty do 2 shluků stejně, jak tomu bylo u shlukovacího stromu. Druhá rozdělila data do 4 shluků. Data v prvním shluku byla shodná u všech tří metod. Data rozdělená do zbylých 3 shluků se shodovala s daty, která byla ve druhém shluku shlukovacího stromu. Uspořádání hodnot v těchto shlucích však bylo rozdílné. To bylo způsobeno rozdílnými metodami, které se používají v daných analýzách k rozřazování hodnot do shluků.

Přínosem této práce je úspora času při měření a možnost měřit pouze některé veličiny. Zbylé veličiny budou předpovídaný pomocí neuronových sítí. Při používání neuronových sítí by se nemuselo odečítat tolik hodnot nebo by se nepotřebovalo tolik měřících přístrojů.

V regresní analýze dosáhly nejlepších výsledků sítě, které předpovídaly pevnost v ohybu z Youngových modulů. Nejlepší z těchto sítí by se mohly využít při měření rovnou bez velkých úprav. Síť natrénované pro predikci Youngových modulů z pevnosti v ohybu dosáhly obstojných výsledků, ale některé vzorky byly předpovězeny s velkou procentuální odchylkou. Největší procentuální odchylka byla pro vzorek V_2_7. Tyto sítě by mohly být natrénovány na vyšším počtu dat než jsem měl k dispozici, aby se zlepšila jejich predikční schopnost.

Nejlepší neuronové sítě pro klasifikaci by mohly být použity při klasifikování materiálů *bez výztuže* a pro všechny stupně vzorků *nízké* úrovně. Tyto sítě nejsou vhodné pro klasifikaci vzorků s úrovní výztuže *střední* a *vysoká*. Pro přesnější klasifikování vzorků *střední* a *vysoké* úrovně by musely sítě být natrénovány na větším počtu hodnot.

Seznam literatury a informačních zdrojů

- [1] NOVÁK, Mirko. *Umělé neuronové sítě teorie a aplikace*. 1. vyd. Praha: C.H.Beck, 1998, 382 s. ISBN 80-7179-132-6.
- [2] RADOVÁ, Vlasta. Přednášky z předmětu Neuronové Sítě (NEU), 2016, dostupné z: <http://www.kky.zcu.cz/cs/courses/neu>
- [3] MAŘÍK, Vladimír, ŠTĚPÁNKOVÁ, Olga, LAŽANSKÝ, Jiří a kolektiv. *Umělá inteligence (1)*. 1. vyd. Praha: Academia, 1993, Kapitola 9, s. 217-241, ISBN 80-200-0496-3.
- [4] MAŘÍK, Vladimír, ŠTĚPÁNKOVÁ, Olga, LAŽANSKÝ, Jiří a kolektiv. *Umělá inteligence (4)*. 1. vyd. Praha: Academia, 2003, ISBN 80-200-1044-0.
- [5] MAŘÍK, Vladimír, ŠTĚPÁNKOVÁ, Olga, LAŽANSKÝ, Jiří a kolektiv. *Umělá inteligence (6)*. 1. vyd. Praha: Academia, 2013, Kapitola 12, s. 382-423 ISBN 978-80-200-2276-9.
- [6] MOLNÁR, Karol. Úvod do problematiky neuronových sítí. [online], [cit. 2015-22-10], <http://www.elektrorevue.cz/clanky/00013/index.html>
- [7] VOJÁČEK, Antonín. Samoučící se neuronová síť – SOM. [online], [cit. 2015-19-11], http://www.kiv.zcu.cz/studies/predmety/uir/NS/Samouc_NN2.pdf, 14.5. 2006
- [8] https://is.mendelu.cz/eknihovna/opory/zobraz_cast.pl?cast=21471. [online], [cit 2015-30-11]
- [9] VONDRÁK, Ivo. Neuronové sítě. VŠB-TU Ostrava. Duben, 1994. Elektronický text. Dostupný z: http://vondrak.cs.vsb.cz/download/Neuronove_site.pdf.
- [10] ČSN EN 60672-2 Keramické a skleněné izolační materiály: část 2 zkušební metody
- [11] Úvod do neuronových sítí, Statsoft, dostupné z: http://www.statsoft.cz/file1/PDF/newsletter/2013_02_05_StatSoft_Neuronove_site_linky.pdf
- [12] QC Expert - help

Přílohy

Příloha A – Data podrobovaná analýzám

Tab. A1 trénovací data pro predikování R_{m0} , použité též pro klasifikaci

Číslo vzorku	R _{m0} [Mpa]	E [N/mm ²]	E [MPa]	úroveň výztuže
0_0_3	2961,36	11 611 453,0	15 626 027,0	bez výztuže
0_0_04	3130,57	12 759 994,0	17 747 774,0	bez výztuže
0_0_05	2861,88	10 817 720,0	14 527 922,0	bez výztuže
0_0_06	2934,45	11 721 406,0	15 750 186,0	bez výztuže
0_0_07	2871,62	12 672 715,0	17 233 072,0	bez výztuže
0_0_08	2911,54	13 405 149,0	17 516 858,0	bez výztuže
0_0_09	2540,04	12 954 599,0	15 187 344,0	bez výztuže
0_0_10	2795,73	14 058 180,0	15 996 384,0	bez výztuže
0_0_11	2979,18	12 718 784,0	17 670 652,0	bez výztuže
0_0_12	3311,12	13 709 113,0	18 301 464,0	bez výztuže
0_0_13	3280,92	13 380 922,0	17 446 048,0	bez výztuže
0_0_14	3376,92	13 961 331,0	18 298 884,0	bez výztuže
0_0_15	3136,96	12 614 020,0	16 614 229,0	bez výztuže
0_0_16	3180,37	11 826 715,0	15 747 808,0	bez výztuže
0_0_17	3014,14	13 254 807,0	16 786 456,0	bez výztuže
0_0_19	3182,35	12 357 363,0	16 199 436,0	bez výztuže
0_0_20	2866,47	11 174 179,0	16 227 828,0	bez výztuže
0_0_21	3256,62	12 202 741,0	17 097 620,0	bez výztuže
0_0_22	3100,99	12 374 061,0	16 983 272,0	bez výztuže
0_0_23	3083,85	13 292 526,0	16 693 333,0	bez výztuže
0_0_24	3429,38	11 292 827,0	16 328 039,0	bez výztuže
0_0_26	3137,35	12 762 448,0	17 606 900,0	bez výztuže
0_0_27	2685,65	13 343 257,0	15 690 423,0	bez výztuže
0_0_28	2986,52	14 448 665,0	18 696 788,0	bez výztuže
N_1_1	3424,04	11 702 951,0	16 733 284,0	nízká 1
N_1_2	3145,08	9 894 630,0	14 358 102,0	nízká 1
N_1_3	2918,91	10 052 910,0	13 963 593,0	nízká 1
N_1_4	2981,16	9 492 998,0	14 787 747,0	nízká 1
N_1_5	3024,25	10 078 830,0	14 085 575,0	nízká 1
N_1_6	2747,35	9 883 670,0	13 633 215,0	nízká 1
N_1_7	2842,02	10 467 185,0	13 993 573,0	nízká 1
N_1_8	3243,62	11 408 184,0	15 905 892,0	nízká 1
N_1_9	2857,87	11 368 209,0	14 847 449,0	nízká 1
N_1_10	2704,01	9 969 931,0	12 763 491,0	nízká 1
N_1_11	2603,39	12 820 370,0	15 520 052,0	nízká 1
N_1_13	2738,57	12 035 205,0	15 779 910,0	nízká 1
N_1_14	2803,26	11 917 174,0	14 737 242,0	nízká 1
N_1_15	3267,4	10 631 760,0	15 486 044,0	nízká 1
N_1_16	3040,92	10 069 736,0	15 206 869,0	nízká 1
N_1_17	3066,1	11 682 360,0	15 459 653,0	nízká 1
N_1_18	3211,73	10 548 252,0	15 700 944,0	nízká 1
N_1_19	3200,77	10 566 839,0	16 064 045,0	nízká 1
N_1_20	3124	11 346 616,0	16 014 182,0	nízká 1
N_1_21	3179,48	11 393 217,0	16 195 383,0	nízká 1
N_1_22	3046,81	11 571 054,0	16 031 167,0	nízká 1
N_1_23	3062,05	12 965 563,0	15 603 202,0	nízká 1
N_1_24	2961,65	9 841 385,0	13 960 728,0	nízká 1
N_1_26	2995,16	10 892 777,0	14 993 936,0	nízká 1
N_1_28	2441,06	12 344 218,0	14 445 147,0	nízká 1
N_2_2	1955,95	6 824 636,5	5 911 149,5	nízká 2
N_2_3	1974,45	7 384 019,0	6 025 783,0	nízká 2
N_2_4	1769,64	6 669 323,5	5 553 573,5	nízká 2
N_2_6	1854,31	6 547 805,5	5 735 021,0	nízká 2
N_2_7	1980,63	6 064 938,0	5 879 793,5	nízká 2
N_2_8	1902,76	6 079 397,0	5 798 808,0	nízká 2
N_2_9	1926,06	7 024 518,0	6 057 973,0	nízká 2
N_2_10	1969,02	6 635 021,0	5 874 807,5	nízká 2
N_2_11	1836,7	7 053 062,5	5 667 491,5	nízká 2

Číslo vzorku	R _{m0} [Mpa]	E [N/mm ²]	E [MPa]	úroveň výztuže
N_2_13	1984,59	7 488 730,5	6 296 174,5	nízká 2
N_2_14	1690,96	6 820 729,5	5 548 486,5	nízká 2
N_2_15	1750,23	6 198 867,5	5 231 560,5	nízká 2
N_2_16	1692,45	6 166 859,5	4 987 446,0	nízká 2
N_2_17	1327,24	6 648 226,5	4 591 615,0	nízká 2
N_2_18	1171,82	5 692 132,0	4 819 546,5	nízká 2
N_2_19	2008,38	7 097 366,5	5 777 500,0	nízká 2
N_2_20	1834,88	5 810 896,0	5 789 647,5	nízká 2
N_2_21	1617,02	5 782 219,5	5 312 835,5	nízká 2
N_2_22	2012,71	7 375 691,0	6 210 926,5	nízká 2
N_2_23	1818,44	8 214 538,5	6 146 023,0	nízká 2
N_2_24	1810,33	5 589 378,5	5 827 916,5	nízká 2
N_2_25	1907,74	5 796 316,0	5 932 421,0	nízká 2
N_2_26	1730,74	7 258 015,5	5 764 111,5	nízká 2
N_2_27	1820,32	6 991 862,0	6 168 228,5	nízká 2
N_2_28	1799,69	7 554 945,5	5 895 223,5	nízká 2
N_3_1	1918,07	6 287 152,5	5 897 354,5	nízká 3
N_3_2	2098,78	7 176 514,0	6 394 680,0	nízká 3
N_3_3	2071,27	7 532 186,5	6 130 715,5	nízká 3
N_3_4	1916,19	6 723 145,5	5 623 466,5	nízká 3
N_3_5	2367,57	7 478 808,5	6 661 034,5	nízká 3
N_3_6	1921,28	5 935 426,5	5 613 979,0	nízká 3
N_3_7	2055,14	7 102 964,5	5 986 580,5	nízká 3
N_3_8	1885,91	6 655 659,0	5 520 110,0	nízká 3
N_3_9	1925,65	6 653 269,0	5 536 511,0	nízká 3
N_3_10	2131,5	6 771 275,5	6 340 976,5	nízká 3
N_3_11	2030,48	6 944 572,0	6 043 879,5	nízká 3
N_3_12	2083,19	7 458 721,0	6 060 730,5	nízká 3
N_3_13	2088,55	7 044 592,0	5 708 818,5	nízká 3
N_3_14	2151,91	7 455 708,0	6 409 407,0	nízká 3
N_3_15	1987,05	6 904 992,5	5 923 287,5	nízká 3
N_3_16	2058,15	6 642 499,5	6 020 212,5	nízká 3
N_3_17	2022,6	5 877 616,0	6 103 349,0	nízká 3
N_3_18	2073,88	6 992 739,5	6 212 190,0	nízká 3
N_3_20	2130,21	7 174 200,0	6 446 698,5	nízká 3
N_3_22	2086,42	7 518 293,0	6 493 203,5	nízká 3
N_3_23	1904,88	7 149 768,0	6 043 865,5	nízká 3
N_3_24	1925,74	6 815 884,0	6 148 645,5	nízká 3
N_3_25	1991,62	7 618 053,5	6 321 285,0	nízká 3
N_3_26	2147,41	6 696 928,5	6 508 661,0	nízká 3
N_3_27	2119,7	6 936 061,0	6 281 135,0	nízká 3
N_3_28	1992,64	8 481 153,0	6 453 767,5	nízká 3
S_1_1	2370,69	8 143 971,5	8 996 573,0	střední 1
S_1_2	2113,4	7 423 325,5	8 292 423,0	střední 1
S_1_3	2194,88	7 577 019,5	8 412 599,0	střední 1
S_1_4	2188,35	7 408 221,0	8 178 893,5	střední 1
S_1_5	2278,8	6 808 264,5	7 935 331,0	střední 1
S_1_7	2377,91	7 753 367,5	8 766 481,0	střední 1
S_1_8	2485,65	9 175 691,0	9 980 612,0	střední 1
S_1_9	2369,26	8 535 450,0	9 379 150,0	střední 1
S_1_10	2166,54	7 492 601,0	8 346 010,0	střední 1
S_1_13	1955,05	7 978 242,0	8 259 073,0	střední 1
S_1_14	2259,21	7 835 574,5	8 564 278,0	střední 1
S_1_16	1971,84	6 620 152,5	7 411 120,0	střední 1
S_1_17	2260,82	7 457 209,0	8 286 062,5	střední 1
S_1_18	2256,16	7 388 610,5	7 742 814,0	střední 1
S_1_19	2060,5	7 529 277,5	7 906 167,0	střední 1
S_1_20	1974,71	7 235 018,5	7 705 662,5	střední 1

Číslo vzorku	R _{m0} [Mpa]	E [N/mm ²]	E [MPa]	úroveň výztuže
S_1_21	2282,2	7 243 670,5	7 894 800,0	střední 1
S_1_22	1928,92	6 935 988,5	7 842 049,0	střední 1
S_1_23	2295,24	6 997 718,0	7 960 618,5	střední 1
S_1_24	1883,52	6 796 877,5	7 023 169,0	střední 1
S_1_25	2289,83	7 958 453,0	8 522 356,0	střední 1
S_1_26	2316,05	7 336 505,5	8 539 971,0	střední 1
S_1_27	2089,49	7 168 086,5	8 234 732,0	střední 1
S_1_28	1889,02	7 538 929,5	7 563 229,5	střední 1
S_2_1	1811,68	5 952 733,0	6 779 133,5	střední 2
S_2_2	2117,21	7 346 586,5	7 374 390,5	střední 2
S_2_5	1963,53	6 674 869,5	7 500 396,5	střední 2
S_2_6	2086,55	6 474 366,5	7 576 626,0	střední 2
S_2_7	1963,81	6 427 764,0	7 004 067,5	střední 2
S_2_8	1814,46	6 817 005,5	6 968 733,5	střední 2
S_2_9	1618,31	6 992 945,0	7 191 648,0	střední 2
S_2_10	1938,81	7 736 843,0	7 969 626,0	střední 2
S_2_12	1809,15	7 451 671,5	7 608 179,5	střední 2
S_2_13	2237,82	7 787 318,0	8 375 782,0	střední 2
S_2_14	2119,88	7 853 040,5	8 481 920,0	střední 2
S_2_15	1575,55	7 103 170,5	7 342 506,0	střední 2
S_2_16	1940,39	7 190 542,5	7 757 197,0	střední 2
S_2_17	2129,53	6 837 099,5	7 602 467,5	střední 2
S_2_18	2318,09	7 485 495,0	8 172 287,5	střední 2
S_2_19	2083,16	7 310 505,0	8 112 612,0	střední 2
S_2_20	2147,01	6 787 189,5	7 744 397,0	střední 2
S_2_21	2012,69	6 484 389,0	7 343 002,0	střední 2
S_2_22	1983,73	7 604 952,0	8 086 895,0	střední 2
S_2_23	2044,14	7 651 544,0	7 924 344,0	střední 2
S_2_24	2036,25	6 471 771,5	7 050 706,0	střední 2
S_2_25	2093,3	7 606 294,5	8 299 055,5	střední 2
S_2_26	1828,01	6 436 294,5	7 011 948,0	střední 2
S_2_27	1974,5	7 543 165,0	8 467 670,0	střední 2
S_2_28	2053,07	8 070 566,5	8 661 140,0	střední 2
S_3_1	2191,8	7 565 138,5	8 371 354,0	střední 3
S_3_2	1943,36	7 673 438,5	7 572 440,5	střední 3
S_3_3	1660,31	6 736 158,5	6 709 358,5	střední 3
S_3_4	1841,8	7 384 986,0	7 542 570,5	střední 3
S_3_5	1992,98	6 906 657,5	6 907 716,0	střední 3
S_3_6	1945,64	6 446 748,5	7 276 885,5	střední 3
S_3_7	1768,93	6 643 039,5	7 230 476,5	střední 3
S_3_8	1834,46	6 808 970,0	7 725 010,5	střední 3
S_3_9	2043,36	6 687 498,5	7 322 326,5	střední 3
S_3_10	2077,54	7 706 537,0	8 012 934,5	střední 3
S_3_11	1991,75	8 157 544,5	8 279 436,5	střední 3
S_3_12	1935,79	8 007 322,0	7 990 221,0	střední 3
S_3_14	2271,03	8 302 735,0	8 562 873,0	střední 3
S_3_15	2122,03	7 066 908,0	7 882 724,0	střední 3
S_3_16	1942,97	6 870 854,0	7 211 011,5	střední 3
S_3_17	1762,01	6 992 751,0	7 350 356,0	střední 3
S_3_18	1938,5	7 333 830,0	7 418 479,5	střední 3
S_3_21	1996,02	6 966 959,0	7 974 040,5	střední 3
S_3_22	1804,61	6 739 660,5	7 565 866,0	střední 3
S_3_23	1874,9	7 073 823,5	7 480 296,5	střední 3
S_3_24	1930,75	6 882 454,0	7 887 331,0	střední 3
S_3_25	1899,19	7 109 818,0	7 640 536,0	střední 3
S_3_26	1938,63	7 813 153,5	8 188 009,5	střední 3
S_3_27	2134,55	7 668 236,5	8 375 268,0	střední 3
S_3_28	1974,49	8 626 225,0	8 647 144,0	střední 3
V_1_1	2324	8 434 809,0	8 884 657,0	vyšoká 1
V_1_2	2003,28	7 526 546,5	8 534 355,0	vyšoká 1
V_1_3	2022,07	7 602 839,0	8 397 770,0	vyšoká 1
V_1_4	2033,97	8 443 844,0	8 813 812,0	vyšoká 1
V_1_5	1911,97	7 896 994,0	8 322 135,5	vyšoká 1
V_1_6	1918,34	7 129 315,5	7 942 066,0	vyšoká 1
V_1_7	2005,94	7 648 083,5	8 199 272,5	vyšoká 1
V_1_8	1935,08	7 637 139,0	8 576 287,0	vyšoká 1
V_1_9	2041,29	7 498 094,5	8 132 089,0	vyšoká 1

Číslo vzorku	R _{m0} [Mpa]	E [N/mm ²]	E [MPa]	úroveň výztuže
V_1_10	2100,98	7 779 864,5	8 577 236,0	vyšoká 1
V_1_11	2405,62	8 711 456,0	9 409 279,0	vyšoká 1
V_1_12	2204,76	7 843 230,5	8 714 726,0	vyšoká 1
V_1_13	1856,31	7 717 599,0	8 063 906,0	vyšoká 1
V_1_14	2096,77	9 121 606,0	9 088 790,0	vyšoká 1
V_1_15	1942,13	7 670 541,0	8 075 709,5	vyšoká 1
V_1_16	1956,96	7 786 779,0	7 913 521,0	vyšoká 1
V_1_17	1824,48	8 402 625,0	8 330 630,5	vyšoká 1
V_1_18	1975,17	8 751 675,0	9 007 864,0	vyšoká 1
V_1_20	1926,3	6 956 717,5	7 855 963,5	vyšoká 1
V_1_22	1939,52	7 846 486,5	8 307 219,5	vyšoká 1
V_1_23	2007,51	7 958 387,0	7 867 845,0	vyšoká 1
V_1_24	2033,85	7 628 349,0	8 451 454,0	vyšoká 1
V_1_25	2150,18	7 753 026,5	8 238 936,0	vyšoká 1
V_1_26	2134,09	8 047 019,0	8 627 496,0	vyšoká 1
V_1_27	1812,53	6 849 104,0	7 176 406,0	vyšoká 1
V_1_28	2152,05	7 715 907,5	8 542 388,0	vyšoká 1
V_2_1	1992,84	8 018 224,0	8 822 691,0	vyšoká 2
V_2_2	2078,13	6 901 019,0	7 926 714,0	vyšoká 2
V_2_3	2065,82	7 226 145,0	8 299 865,0	vyšoká 2
V_2_4	2080,73	7 950 727,0	8 647 714,0	vyšoká 2
V_2_5	2020,86	8 093 764,0	8 753 676,0	vyšoká 2
V_2_6	2063,86	7 935 820,0	8 581 351,0	vyšoká 2
V_2_7	1960,28	8 841 511,0	8 800 381,0	vyšoká 2
V_2_8	2088,71	8 089 878,5	9 013 635,0	vyšoká 2
V_2_10	2018,46	8 415 959,0	8 517 022,0	vyšoká 2
V_2_11	2101,01	7 163 773,0	8 025 880,0	vyšoká 2
V_2_12	2127,33	8 271 006,5	8 715 967,0	vyšoká 2
V_2_13	2154,62	7 716 180,5	8 220 007,0	vyšoká 2
V_2_14	2102,01	8 511 535,0	8 956 650,0	vyšoká 2
V_2_15	2071,57	8 093 496,0	8 370 376,0	vyšoká 2
V_2_16	2116,53	7 628 719,5	7 772 762,0	vyšoká 2
V_2_17	2120,25	8 282 161,0	8 201 200,5	vyšoká 2
V_2_18	2160,01	9 114 750,0	8 494 288,0	vyšoká 2
V_2_19	1998,41	8 903 543,0	8 151 278,5	vyšoká 2
V_2_20	2117,1	8 059 635,5	8 383 928,0	vyšoká 2
V_2_21	2092,61	8 145 559,5	8 265 425,0	vyšoká 2
V_2_22	2166,18	7 523 286,0	8 178 362,5	vyšoká 2
V_2_23	2161,99	8 051 280,0	8 215 741,5	vyšoká 2
V_2_24	2143,07	6 919 663,0	7 880 247,5	vyšoká 2
V_2_25	2076,86	8 274 106,0	8 379 576,5	vyšoká 2
V_2_26	2310,99	7 768 928,0	8 019 130,5	vyšoká 2
V_2_28	1343,1	7 318 524,0	7 036 452,0	vyšoká 2
V_3_1	1971	8 707 458,0	8 965 769,0	vyšoká 3
V_3_2	2074,42	7 997 224,5	8 576 395,0	vyšoká 3
V_3_4	1958,35	7 877 770,5	8 487 712,0	vyšoká 3
V_3_6	2019,32	7 860 749,5	8 495 513,0	vyšoká 3
V_3_8	2055,22	7 852 056,5	8 662 303,0	vyšoká 3
V_3_9	1957,48	8 260 966,5	8 098 923,5	vyšoká 3
V_3_11	1811,04	7 438 027,5	7 330 120,0	vyšoká 3
V_3_12	1937,69	7 220 381,0	7 587 291,5	vyšoká 3
V_3_13	1813,43	6 624 309,0	6 792 851,5	vyšoká 3
V_3_14	1877,22	7 849 382,0	7 897 087,5	vyšoká 3
V_3_15	1783,43	6 043 994,0	6 690 629,5	vyšoká 3
V_3_16	2117,82	7 590 949,5	7 887 075,5	vyšoká 3
V_3_17	2087,55	8 106 493,0	7 795 647,0	vyšoká 3
V_3_18	1984,34	8 182 561,5	8 365 977,5	vyšoká 3
V_3_19	2127,68	9 175 679,0	9 209 474,0	vyšoká 3
V_3_20	1840,14	7 090 452,0	7 855 558,0	vyšoká 3
V_3_21	2119,09	8 379 201,0	8 758 426,0	vyšoká 3
V_3_22	2333,54	7 469 494,0	8 433 390,0	vyšoká 3
V_3_23	2078,47	7 081 812,0	7 699 035,5	vyšoká 3
V_3_24	1999,87	7 550 982,0	8 232 717,5	vyšoká 3
V_3_25	2013,27	7 223 414,0	8 192 871,5	vyšoká 3
V_3_26	2125,69	7 861 899,0	8 450 231,0	vyšoká 3
V_3_27	1995,23	7 667 858,5	8 149 668,5	vyšoká 3
V_3_28	2001,57	8 165 889,0	8 285 804,0	vyšoká 3

Tab. A2 Trénovací data pro Youngovi modely

Číslo vzorku	Rmo [Mpa]	E [N/mm2]	E [MPa]	úroveň výztuže
0_0_3	2961,36	11 611 453,0	15 626 027,0	bez výztuže
0_0_04	3130,57	12 759 994,0	17 747 774,0	bez výztuže
0_0_05	2861,88	10 817 720,0	14 527 922,0	bez výztuže
0_0_06	2934,45	11 721 406,0	15 750 186,0	bez výztuže
0_0_07	2871,62	12 672 715,0	17 233 072,0	bez výztuže
0_0_09	2540,04	12 954 599,0	15 187 344,0	bez výztuže
0_0_10	2795,73	14 058 180,0	15 996 384,0	bez výztuže
0_0_11	2979,18	12 718 784,0	17 670 652,0	bez výztuže
0_0_12	3311,12	13 709 113,0	18 301 464,0	bez výztuže
0_0_13	3280,92	13 380 922,0	17 446 048,0	bez výztuže
0_0_14	3376,92	13 961 331,0	18 298 884,0	bez výztuže
0_0_15	3136,96	12 614 020,0	16 614 229,0	bez výztuže
0_0_16	3180,37	11 826 715,0	15 747 808,0	bez výztuže
0_0_17	3014,14	13 254 807,0	16 786 456,0	bez výztuže
0_0_19	3182,35	12 357 363,0	16 199 436,0	bez výztuže
0_0_20	2866,47	11 174 179,0	16 227 828,0	bez výztuže
0_0_21	3256,62	12 202 741,0	17 097 620,0	bez výztuže
0_0_22	3100,99	12 374 061,0	16 983 272,0	bez výztuže
0_0_23	3083,85	13 292 526,0	16 693 333,0	bez výztuže
0_0_24	3429,38	11 292 827,0	16 328 039,0	bez výztuže
0_0_25	3208,61	14 442 668,0	18 273 634,0	bez výztuže
0_0_26	3137,35	12 762 448,0	17 606 900,0	bez výztuže
0_0_27	2685,65	13 343 257,0	15 690 423,0	bez výztuže
0_0_28	2986,52	14 448 665,0	18 696 788,0	bez výztuže
N_1_2	3145,08	9 894 630,0	14 358 102,0	nízká 1
N_1_3	2918,91	10 052 910,0	13 963 593,0	nízká 1
N_1_4	2981,16	9 492 998,0	14 787 747,0	nízká 1
N_1_5	3024,25	10 078 830,0	14 085 575,0	nízká 1
N_1_6	2747,35	9 883 670,0	13 633 215,0	nízká 1
N_1_7	2842,02	10 467 185,0	13 993 573,0	nízká 1
N_1_8	3243,62	11 408 184,0	15 905 892,0	nízká 1
N_1_9	2857,87	11 368 209,0	14 847 449,0	nízká 1
N_1_10	2704,01	9 969 931,0	12 763 491,0	nízká 1
N_1_11	2603,39	12 820 370,0	15 520 052,0	nízká 1
N_1_12	2829,04	11 189 336,0	14 373 828,0	nízká 1
N_1_13	2738,57	12 035 205,0	15 779 910,0	nízká 1
N_1_14	2803,26	11 917 174,0	14 737 242,0	nízká 1
N_1_15	3267,4	10 631 760,0	15 486 044,0	nízká 1
N_1_17	3066,1	11 682 360,0	15 459 653,0	nízká 1
N_1_18	3211,73	10 548 252,0	15 700 944,0	nízká 1
N_1_19	3200,77	10 566 839,0	16 064 045,0	nízká 1
N_1_20	3124	11 346 616,0	16 014 182,0	nízká 1
N_1_21	3179,48	11 393 217,0	16 195 383,0	nízká 1
N_1_22	3046,81	11 571 054,0	16 031 167,0	nízká 1
N_1_23	3062,05	12 965 563,0	15 603 202,0	nízká 1
N_1_24	2961,65	9 841 385,0	13 960 728,0	nízká 1
N_1_25	3176,63	12 481 129,0	16 488 350,0	nízká 1
N_1_26	2995,16	10 892 777,0	14 993 936,0	nízká 1
N_1_28	2441,06	12 344 218,0	14 445 147,0	nízká 1
N_2_2	1955,95	6 824 636,5	5 911 149,5	nízká 2
N_2_3	1974,45	7 384 019,0	6 025 783,0	nízká 2
N_2_4	1769,64	6 669 323,5	5 553 573,5	nízká 2
N_2_5	1747,2	7 521 916,5	5 794 167,5	nízká 2
N_2_6	1854,31	6 547 805,5	5 735 021,0	nízká 2
N_2_7	1980,63	6 064 938,0	5 879 793,5	nízká 2
N_2_9	1926,06	7 024 518,0	6 057 973,0	nízká 2
N_2_10	1969,02	6 635 021,0	5 874 807,5	nízká 2
N_2_11	1836,7	7 053 062,5	5 667 491,5	nízká 2
N_2_12	1957,13	6 145 638,5	5 971 926,0	nízká 2
N_2_13	1984,59	7 488 730,5	6 296 174,5	nízká 2
N_2_14	1690,96	6 820 729,5	5 548 486,5	nízká 2
N_2_15	1750,23	6 198 867,5	5 231 560,5	nízká 2
N_2_16	1692,45	6 166 859,5	4 987 446,0	nízká 2

Číslo vzorku	Rmo [Mpa]	E [N/mm2]	E [MPa]	úroveň výztuže
N_2_17	1327,24	6 648 226,5	4 591 615,0	nízká 2
N_2_18	1171,82	5 692 132,0	4 819 546,5	nízká 2
N_2_19	2008,38	7 097 366,5	5 777 500,0	nízká 2
N_2_20	1834,88	5 810 896,0	5 789 647,5	nízká 2
N_2_21	1617,02	5 782 219,5	5 312 835,5	nízká 2
N_2_23	1818,44	8 214 538,5	6 146 023,0	nízká 2
N_2_24	1810,33	5 589 378,5	5 827 916,5	nízká 2
N_2_25	1907,74	5 796 316,0	5 932 421,0	nízká 2
N_2_26	1730,74	7 258 015,5	5 764 111,5	nízká 2
N_2_27	1820,32	6 991 862,0	6 168 228,5	nízká 2
N_2_28	1799,69	7 554 945,5	5 895 223,5	nízká 2
N_3_1	1918,07	6 287 152,5	5 897 354,5	nízká 3
N_3_2	2098,78	7 176 514,0	6 394 680,0	nízká 3
N_3_3	2071,27	7 532 186,5	6 130 715,5	nízká 3
N_3_4	1916,19	6 723 145,5	5 623 466,5	nízká 3
N_3_5	2367,57	7 478 808,5	6 661 034,5	nízká 3
N_3_6	1921,28	5 935 426,5	5 613 979,0	nízká 3
N_3_7	2055,14	7 102 964,5	5 986 580,5	nízká 3
N_3_9	1925,65	6 653 269,0	5 536 511,0	nízká 3
N_3_10	2131,5	6 771 275,5	6 340 976,5	nízká 3
N_3_11	2030,48	6 944 572,0	6 043 879,5	nízká 3
N_3_12	2083,19	7 458 721,0	6 060 730,5	nízká 3
N_3_13	2088,55	7 044 592,0	5 708 818,5	nízká 3
N_3_14	2151,91	7 455 708,0	6 409 407,0	nízká 3
N_3_15	1987,05	6 904 992,5	5 923 287,5	nízká 3
N_3_16	2058,15	6 642 499,5	6 020 212,5	nízká 3
N_3_17	2022,6	5 877 616,0	6 103 349,0	nízká 3
N_3_18	2073,88	6 992 739,5	6 212 190,0	nízká 3
N_3_19	1940,17	5 383 331,5	5 578 650,5	nízká 3
N_3_20	2130,21	7 174 200,0	6 446 698,5	nízká 3
N_3_21	2111,06	6 366 725,0	6 036 972,0	nízká 3
N_3_23	1904,88	7 149 768,0	6 043 865,5	nízká 3
N_3_24	1925,74	6 815 884,0	6 148 645,5	nízká 3
N_3_25	1991,62	7 618 053,5	6 321 285,0	nízká 3
N_3_26	2147,41	6 696 928,5	6 508 661,0	nízká 3
N_3_27	2119,7	6 936 061,0	6 281 135,0	nízká 3
N_3_28	1992,64	8 481 153,0	6 453 767,5	nízká 3
S_1_1	2370,69	8 143 971,5	8 996 573,0	střední 1
S_1_2	2113,4	7 423 325,5	8 292 423,0	střední 1
S_1_3	2194,88	7 577 019,5	8 412 599,0	střední 1
S_1_4	2188,35	7 408 221,0	8 178 893,5	střední 1
S_1_5	2278,8	6 808 264,5	7 935 331,0	střední 1
S_1_6	2005,51	7 132 384,5	7 438 722,5	střední 1
S_1_8	2485,65	9 175 691,0	9 980 612,0	střední 1
S_1_9	2369,26	8 535 450,0	9 379 150,0	střední 1
S_1_10	2166,54	7 492 601,0	8 346 010,0	střední 1
S_1_13	1955,05	7 978 242,0	8 259 073,0	střední 1
S_1_14	2259,21	7 835 574,5	8 564 278,0	střední 1
S_1_15	2314,11	6 315 015,0	7 805 536,0	střední 1
S_1_16	1971,84	6 620 152,5	7 411 120,0	střední 1
S_1_17	2260,82	7 457 209,0	8 286 062,5	střední 1
S_1_18	2256,16	7 388 610,5	7 742 814,0	střední 1
S_1_19	2060,5	7 529 277,5	7 906 167,0	střední 1
S_1_20	1974,71	7 235 018,5	7 705 662,5	střední 1
S_1_21	2282,2	7 243 670,5	7 894 800,0	střední 1
S_1_22	1928,92	6 935 988,5	7 842 049,0	střední 1
S_1_24	1883,52	6 796 877,5	7 023 169,0	střední 1
S_1_25	2289,83	7 958 453,0	8 522 356,0	střední 1
S_1_26	2316,05	7 336 505,5	8 539 971,0	střední 1
S_1_27	2089,49	7 168 086,5	8 234 732,0	střední 1
S_1_28	1889,02	7 538 929,5	7 563 229,5	střední 1
S_2_1	1811,68	5 952 733,0	6 779 133,5	střední 2
S_2_2	2117,21	7 346 586,5	7 374 390,5	střední 2

Číslo vzorku	R _{m0} [Mpa]	E [N/mm ²]	E [MPa]	úroveň výztuže
S_2_3	1907,85	7 222 372,5	7 532 665,5	střední 2
S_2_5	1963,53	6 674 869,5	7 500 396,5	střední 2
S_2_6	2086,55	6 474 366,5	7 576 626,0	střední 2
S_2_7	1963,81	6 427 764,0	7 004 067,5	střední 2
S_2_9	1618,31	6 992 945,0	7 191 648,0	střední 2
S_2_10	1938,81	7 736 843,0	7 969 626,0	střední 2
S_2_11	2103,48	8 109 780,0	8 492 156,0	střední 2
S_2_12	1809,15	7 451 671,5	7 608 179,5	střední 2
S_2_13	2237,82	7 787 318,0	8 375 782,0	střední 2
S_2_14	2119,88	7 853 040,5	8 481 920,0	střední 2
S_2_15	1575,55	7 103 170,5	7 342 506,0	střední 2
S_2_16	1940,39	7 190 542,5	7 757 197,0	střední 2
S_2_17	2129,53	6 837 099,5	7 602 467,5	střední 2
S_2_18	2318,09	7 485 495,0	8 172 287,5	střední 2
S_2_19	2083,16	7 310 505,0	8 112 612,0	střední 2
S_2_20	2147,01	6 787 189,5	7 744 397,0	střední 2
S_2_21	2012,69	6 484 389,0	7 343 002,0	střední 2
S_2_23	2044,14	7 651 544,0	7 924 344,0	střední 2
S_2_24	2036,25	6 471 771,5	7 050 706,0	střední 2
S_2_25	2093,3	7 606 294,5	8 299 055,5	střední 2
S_2_26	1828,01	6 436 294,5	7 011 948,0	střední 2
S_2_27	1974,5	7 543 165,0	8 467 670,0	střední 2
S_2_28	2053,07	8 070 566,5	8 661 140,0	střední 2
S_3_1	2191,8	7 565 138,5	8 371 354,0	střední 3
S_3_2	1943,36	7 673 438,5	7 572 440,5	střední 3
S_3_3	1660,31	6 736 158,5	6 709 358,5	střední 3
S_3_4	1841,8	7 384 986,0	7 542 570,5	střední 3
S_3_5	1992,98	6 906 657,5	6 907 716,0	střední 3
S_3_6	1945,64	6 446 748,5	7 276 885,5	střední 3
S_3_8	1834,46	6 808 970,0	7 725 010,5	střední 3
S_3_9	2043,36	6 687 498,5	7 322 326,5	střední 3
S_3_10	2077,54	7 706 537,0	8 012 934,5	střední 3
S_3_11	1991,75	8 157 544,5	8 279 436,5	střední 3
S_3_12	1935,79	8 007 322,0	7 990 221,0	střední 3
S_3_13	1861,82	7 452 698,0	8 229 170,5	střední 3
S_3_14	2271,03	8 302 735,0	8 562 873,0	střední 3
S_3_15	2122,03	7 066 908,0	7 882 724,0	střední 3
S_3_16	1942,97	6 870 854,0	7 211 011,5	střední 3
S_3_17	1762,01	6 992 751,0	7 350 356,0	střední 3
S_3_18	1938,5	7 333 830,0	7 418 479,5	střední 3
S_3_20	2027,61	6 757 114,5	7 361 230,0	střední 3
S_3_21	1996,02	6 966 959,0	7 974 040,5	střední 3
S_3_23	1874,9	7 073 823,5	7 480 296,5	střední 3
S_3_24	1930,75	6 882 454,0	7 887 331,0	střední 3
S_3_25	1899,19	7 109 818,0	7 640 536,0	střední 3
S_3_26	1938,63	7 813 153,5	8 188 009,5	střední 3
S_3_27	2134,55	7 668 236,5	8 375 268,0	střední 3
S_3_28	1974,49	8 626 225,0	8 647 144,0	střední 3
V_1_1	2324	8 434 809,0	8 884 657,0	vyšoká 1
V_1_2	2003,28	7 526 546,5	8 534 355,0	vyšoká 1
V_1_3	2022,07	7 602 839,0	8 397 770,0	vyšoká 1
V_1_4	2033,97	8 443 844,0	8 813 812,0	vyšoká 1
V_1_5	1911,97	7 896 994,0	8 322 135,5	vyšoká 1
V_1_6	1918,34	7 129 315,5	7 942 066,0	vyšoká 1
V_1_8	1935,08	7 637 139,0	8 576 287,0	vyšoká 1
V_1_9	2041,29	7 498 094,5	8 132 089,0	vyšoká 1
V_1_10	2100,98	7 779 864,5	8 577 236,0	vyšoká 1
V_1_11	2405,62	8 711 456,0	9 409 279,0	vyšoká 1
V_1_12	2204,76	7 843 230,5	8 714 726,0	vyšoká 1
V_1_13	1856,31	7 717 599,0	8 063 906,0	vyšoká 1
V_1_14	2096,77	9 121 606,0	9 088 790,0	vyšoká 1
V_1_15	1942,13	7 670 541	8 075 709,5	vyšoká 1

Číslo vzorku	R _{m0} [Mpa]	E [N/mm ²]	E [MPa]	úroveň výztuže
V_1_16	1956,96	7 786 779	7 913 521	vyšoká 1
V_1_17	1824,48	8 402 625,0	8 330 630,5	vyšoká 1
V_1_18	1975,17	8 751 675,0	9 007 864,0	vyšoká 1
V_1_19	1931,39	9 127 738,0	8 740 413,0	vyšoká 1
V_1_20	1926,3	6 956 717,5	7 855 963,5	vyšoká 1
V_1_21	2105,96	8 212 791,5	8 632 175,0	vyšoká 1
V_1_23	2007,51	7 958 387,0	7 867 845,0	vyšoká 1
V_1_24	2033,85	7 628 349,0	8 451 454,0	vyšoká 1
V_1_25	2150,18	7 753 026,5	8 238 936,0	vyšoká 1
V_1_26	2134,09	8 047 019,0	8 627 496,0	vyšoká 1
V_1_27	1812,53	6 849 104,0	7 176 406,0	vyšoká 1
V_1_28	2152,05	7 715 907,5	8 542 388,0	vyšoká 1
V_2_1	1992,84	8 018 224,0	8 822 691,0	vyšoká 2
V_2_2	2078,13	6 901 019,0	7 926 714,0	vyšoká 2
V_2_3	2065,82	7 226 145,0	8 299 865,0	vyšoká 2
V_2_4	2080,73	7 950 727,0	8 647 714,0	vyšoká 2
V_2_5	2020,86	8 093 764,0	8 753 676,0	vyšoká 2
V_2_6	2063,86	7 935 820,0	8 581 351,0	vyšoká 2
V_2_8	2088,71	8 089 878,5	9 013 635,0	vyšoká 2
V_2_9	2022,81	7 304 489,0	7 762 169,5	vyšoká 2
V_2_10	2018,46	8 415 959,0	8 517 022,0	vyšoká 2
V_2_11	2101,01	7 163 773,0	8 025 880,0	vyšoká 2
V_2_12	2127,33	8 271 006,5	8 715 967,0	vyšoká 2
V_2_13	2154,62	7 716 180,5	8 220 007,0	vyšoká 2
V_2_14	2102,01	8 511 535,0	8 956 650,0	vyšoká 2
V_2_15	2071,57	8 093 496,0	8 370 376,0	vyšoká 2
V_2_16	2116,53	7 628 719,5	7 772 762,0	vyšoká 2
V_2_17	2120,25	8 282 161,0	8 201 200,5	vyšoká 2
V_2_18	2160,01	9 114 750,0	8 494 288,0	vyšoká 2
V_2_19	1998,41	8 903 543,0	8 151 278,5	vyšoká 2
V_2_20	2117,1	8 059 635,5	8 383 928,0	vyšoká 2
V_2_21	2092,61	8 145 559,5	8 265 425,0	vyšoká 2
V_2_23	2161,99	8 051 280,0	8 215 741,5	vyšoká 2
V_2_24	2143,07	6 919 663,0	7 880 247,5	vyšoká 2
V_2_25	2076,86	8 274 106,0	8 379 576,5	vyšoká 2
V_2_26	2310,99	7 768 928,0	8 019 130,5	vyšoká 2
V_2_27	2141,57	7 835 768,5	8 263 460,0	vyšoká 2
V_2_28	1343,1	7 318 524,0	7 036 452,0	vyšoká 2
V_3_1	1971	8 707 458,0	8 965 769,0	vyšoká 3
V_3_2	2074,42	7 997 224,5	8 576 395,0	vyšoká 3
V_3_4	1958,35	7 877 770,5	8 487 712,0	vyšoká 3
V_3_6	2019,32	7 860 749,5	8 495 513,0	vyšoká 3
V_3_7	2103,36	7 519 197,0	8 697 890,0	vyšoká 3
V_3_8	2055,22	7 852 056,5	8 662 303,0	vyšoká 3
V_3_10	1942,06	7 431 995,5	7 880 930,0	vyšoká 3
V_3_11	1811,04	7 438 027,5	7 330 120,0	vyšoká 3
V_3_12	1937,69	7 220 381,0	7 587 291,5	vyšoká 3
V_3_13	1813,43	6 624 309,0	6 792 851,5	vyšoká 3
V_3_14	1877,22	7 849 382,0	7 897 087,5	vyšoká 3
V_3_15	1783,43	6 043 994,0	6 690 629,5	vyšoká 3
V_3_16	2117,82	7 590 949,5	7 887 075,5	vyšoká 3
V_3_17	2087,55	8 106 493,0	7 795 647,0	vyšoká 3
V_3_18	1984,34	8 182 561,5	8 365 977,5	vyšoká 3
V_3_19	2127,68	9 175 679,0	9 209 474,0	vyšoká 3
V_3_20	1840,14	7 090 452,0	7 855 558,0	vyšoká 3
V_3_21	2119,09	8 379 201,0	8 758 426,0	vyšoká 3
V_3_22	2333,54	7 469 494,0	8 433 390,0	vyšoká 3
V_3_24	1999,87	7 550 982,0	8 232 717,5	vyšoká 3
V_3_25	2013,27	7 223 414,0	8 192 871,5	vyšoká 3
V_3_26	2125,69	7 861 899,0	8 450 231,0	vyšoká 3
V_3_27	1995,23	7 667 858,5	8 149 668,5	vyšoká 3
V_3_28	2001,57	8 165 889,0	8 285 804,0	vyšoká 3

Tab. A3 zkušební data pro Rmo

Číslo vzorku	Rmo [Mpa]	E [N/mm2]	E [MPa]	úroveň výztuže
0_0_18	2872,11	12 000 349,0	15 458 511,0	bez výztuže
0_0_25	3208,61	14 442 668,0	18 273 634,0	bez výztuže
N_1_12	2829,04	11 189 336,0	14 373 828,0	nízká 1
N_1_25	3176,63	12 481 129,0	16 488 350,0	nízká 1
N_2_5	1747,2	7 521 916,5	5 794 167,5	nízká 2
N_2_12	1957,13	6 145 638,5	5 971 926,0	nízká 2
N_3_19	1940,17	5 383 331,5	5 578 650,5	nízká 3
N_3_21	2111,06	6 366 725,0	6 036 972,0	nízká 3
S_1_6	2005,51	7 132 384,5	7 438 722,5	střední 1
S_1_15	2314,11	6 315 015,0	7 805 536,0	střední 1
S_2_3	1907,85	7 222 372,5	7 532 665,5	střední 2
S_2_11	2103,48	8 109 780,0	8 492 156,0	střední 2
S_3_13	1861,82	7 452 698,0	8 229 170,5	střední 3
S_3_20	2027,61	6 757 114,5	7 361 230,0	střední 3
V_1_19	1931,39	9 127 738,0	8 740 413,0	vyšoká 1
V_1_21	2105,96	8 212 791,5	8 632 175,0	vyšoká 1
V_2_9	2022,81	7 304 489,0	7 762 169,5	vyšoká 2
V_2_27	2141,57	7 835 768,5	8 263 460,0	vyšoká 2
V_3_7	2103,36	7 519 197,0	8 697 890,0	vyšoká 3
V_3_10	1942,06	7 431 995,5	7 880 930,0	vyšoká 3
0_0_med	3048,995	12 739 389,0	16 739 895,0	bez výztuže
N_1_med	3024,25	11 189 336,0	15 206 869,0	nízká 1
N_2_med	1834,88	6 669 324,0	5 798 808,0	nízká 2
N_3_med	2056,645	6 940 317,0	6 082 040,0	nízká 3
S_1_med	2225,52	7 415 773,0	8 206 813,0	střední 1
S_2_med	2012,69	7 222 373,0	7 608 180,0	střední 2
S_3_med	1942,97	7 073 824,0	7 640 536,0	střední 3
V_1_med	2006,725	7 783 322,0	8 424 612,0	vyšoká 1
V_2_med	2090,66	8 034 752,0	8 282 645,0	vyšoká 2
V_3_med	2000,72	7 758 620,0	8 212 795,0	vyšoká 3

Tab. A4 zkušební data pro Youngovi modely


Číslo vzorku	Rmo [Mpa]	E [N/mm2]	E [MPa]	úroveň výztuže
0_0_08	2911,54	13 405 149,0	17 516 858,0	bez výztuže
0_0_18	2872,11	12 000 349,0	15 458 511,0	bez výztuže
N_1_1	3424,04	11 702 951,0	16 733 284,0	nízká 1
N_1_16	3040,92	10 069 736,0	15 206 869,0	nízká 1
N_2_8	1902,76	6 079 397,0	5 798 808,0	nízká 2
N_2_22	2012,71	7 375 691,0	6 210 926,5	nízká 2
N_3_8	1885,91	6 655 659,0	5 520 110,0	nízká 3
N_3_22	2086,42	7 518 293,0	6 493 203,5	nízká 3
S_1_7	2377,91	7 753 367,5	8 766 481,0	střední 1
S_1_23	2295,24	6 997 718,0	7 960 618,5	střední 1
S_2_8	1814,46	6 817 005,5	6 968 733,5	střední 2
S_2_22	1983,73	7 604 952,0	8 086 895,0	střední 2
S_3_7	1768,93	6 643 039,5	7 230 476,5	střední 3
S_3_22	1804,61	6 739 660,5	7 565 866,0	střední 3
V_1_7	2005,94	7 648 083,5	8 199 272,5	vyšoká 1
V_1_22	1939,52	7 846 486,5	8 307 219,5	vyšoká 1
V_2_7	1960,28	8 841 511,0	8 800 381,0	vyšoká 2
V_2_22	2166,18	7 523 286,0	8 178 362,5	vyšoká 2
V_3_9	1957,48	8 260 966,5	8 098 923,5	vyšoká 3
V_3_23	2078,47	7 081 812,0	7 699 035,5	vyšoká 3
0_0_med	3048,995	12 739 389,0	16 739 895,0	bez výztuže
N_1_med	3024,25	11 189 336,0	15 206 869,0	nízká 1
N_2_med	1834,88	6 669 324,0	5 798 808,0	nízká 2
N_3_med	2056,645	6 940 317,0	6 082 040,0	nízká 3
S_1_med	2225,52	7 415 773,0	8 206 813,0	střední 1
S_2_med	2012,69	7 222 373,0	7 608 180,0	střední 2
S_3_med	1942,97	7 073 824,0	7 640 536,0	střední 3
V_1_med	2006,725	7 783 322,0	8 424 612,0	vyšoká 1
V_2_med	2090,66	8 034 752,0	8 282 645,0	vyšoká 2
V_3_med	2000,72	7 758 620,0	8 212 795,0	vyšoká 3

Tab. A5 Seznam odstraněných hodnot

číslo vzorku	Rmo [Mpa]	E [N/mm2]	E [N/MPa]	hustota výztuže	důvod vyřazení
pok1	2280,22	-----	-----	-----	pokusná hodnota
pok2	2276,92	0,0	11 262 492,0	-----	pokusná hodnota
pok3	2075,92	10 633 303,0	10 891 584,0	-----	pokusná hodnota
0_0_1	6,44	1 377,4	1 644,2	bez výztuže	extrémní hodnota
0_0_2	7,21	1 275,9	1 727,0	bez výztuže	extrémní hodnota
N_1_27	2344,59	10 210 253,0	11 704 902,0	nízká 1	odlehá hodnota
N_2_1	2025,95	6 289 445,0	3 618 883,5	nízká 2	odlehá hodnota
S_1_11	753,55	2 322 967,3	1 470 572,6	střední 1	odlehá hodnota
S_1_12	920,02	4 609 888,5	3 005 830,0	střední 1	odlehá hodnota
S_2_4	2781,12	11 869 822,0	11 850 630,0	střední 2	odlehá hodnota
S_3_19	2981,81	10 465 630,0	11 203 679,0	střední 3	odlehá hodnota
V_3_3	1099,85	4 539 798,0	4 557 351,0	vyšoká 3	odlehá hodnota
V_3_5	1221,25	4 427 392,5	4 950 386,5	vyšoká 3	odlehá hodnota

Příloha B - Shlukovací stromy

Obr. B1 odebrané hodnoty



Obr. B2 Shlukovací strom ořezané hodnoty

