


**TECHNICKÁ UNIVERZITA V LIBERCI  
FAKULTA TEXTILNÍ**

**DIPLOMOVÁ PRÁCE**

**LIBEREC 2015**

**IRYNA CHERNOVA**

# TECHNICKÁ UNIVERZITA V LIBERCI FAKULTA TEXTILNÍ



## ANALÝZA VLIVU VYBRANÝCH STRUKTURNÍCH PARAMETRŮ A MECHANICKÝCH VLASTNOSTÍ NA JEJÍ SPLÝVAVOST

*Studijní program:* N3106 – Textilní inženýrství

*Studijní obor:* 3106T017 – Oděvní a textilní technologie

*Autor práce:* Iryna Chernova

*Vedoucí práce:* Ing. Viera Glombíková, Ph.D.

TECHNICKÁ UNIVERZITA V LIBERCI

Fakulta textilní

Akademický rok: 2013/2014

## ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Iryna Chernova**  
Osobní číslo: **T12000571**  
Studijní program: **N3106 Textilní inženýrství**  
Studijní obor: **Oděvní a textilní technologie**  
Název tématu: **Analýza vlivu strukturních parametrů a mechanických vlastností textilie na její splývavost**  
Zadávací katedra: **Katedra oděvnictví**

### Zásady pro vypracování:

1. Rešerše zaměřená na problematiku vlivu strukturních parametrů a mechanických vlastností textilie na její splývavost.
2. Návrh metody predikce splývavosti textilie na základě strukturních parametrů a mechanických vlastností textilie a s využitím parametrů splývavosti měřených pomocí 3D drapescaneru.
3. Zhodnocení oblasti aplikace navrhované metody, kladů a záporů.



Rozsah grafických prací: **dle rozsahu dokumentace**

Rozsah pracovní zprávy: **cca 50 stran**

Forma zpracování diplomové práce: **tištěná**

Seznam odborné literatury:

- Wu, Y.Y. et al. An investigation on the validity of 3D clothing simulation for garment fit evaluation, Proceedings of the IMPoVe 2011, Venice - Italy, pp.463-468,
- Bye, E. and McKinney, Fit analysis using live and 3D scan models, International of Clothing Science and Technology, Vol. 22, 2010, pp.88-100
- Fan, J. et al. Clothing Appearance and Fit: Science and Technology, Woodhead Publishing in Textiles, 2004
- Orzada, B. T., et al. Effect of laundering on fabric drape, bending and shear, International Journal of Clothing Science and Technology, 2009, Vol.21, no.1, , pp.44-55
- Kenkare N., Mayplumlee, T., Evaluation of drape characteristics in fabrics, International Journal of Clothing Science and Technology, 2005, Vol. 17, No.2, pp.109-123
- Platné normy ČSN ISO EN
- Odborné a vědecké časopisy

Vedoucí diplomové práce: **Ing. Viera Glombíková, Ph.D.**


Katedra oděvnictví

Datum zadání diplomové práce: **2. listopadu 2013**

Termín odevzdání diplomové práce: **19. května 2014**

  
Ing. Jana Drašarová, Ph.D.  
děkanka



  
doc. Ing. Antonín Havelka, CSc.  
vedoucí katedry

V Liberci dne 2. listopadu 2013

Technická univerzita v Liberci  
Doc. Ing. Antonín Havelka, CSc.  
Katedra oděvnictví, FT  
Studentská 2  
461 17 Liberec

ŽÁDOST

Žádám o prodloužení termínu odevzdání diplomové (bakalářské) práce do: květen 2015  
Název diplomové (bakalářské) práce: analýza vlivu vybraných  
strukturních a mechanických vlastností  
lutilie na její splyvavost.  
Jméno vedoucího diplomové (bakalářské) práce: Ing. Viera Glombíková, Ph.D.


Jméno, příjmení a adresa žadatele:

Jryna Chernova, Voskovcova 1130/26, Praha 5

Podpis žadatele: 

Datum podání žádosti: 26. 11. 2013

Vyjádření vedoucího práce:

Souhlasím 

Vyjádření vedoucího katedry:

Souhlasím  2. 12. 2013

TECHNICKÁ UNIVERZITA V LIBERCI  
FAKULTA TEXTILNÍ  
Katedra oděvnictví

# PROHLÁŠENÍ

Byla jsem seznámena s tím, že na mou diplomovou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, zejména § 60 – školní dílo.

Beru na vědomí, že Technická univerzita v Liberci (TUL) nezasahuje do mých autorských práv užitím mé diplomové práce pro vnitřní potřebu TUL.

Užiji-li diplomovou práci nebo poskytnu-li licenci k jejímu využití, jsem si vědom povinnosti informovat o této skutečnosti TUL; v tomto případě má TUL právo ode mne požadovat úhradu nákladů, které vynaložila na vytvoření díla, až do jejich skutečné výše.

Diplomovou práci jsem vypracovala samostatně s použitím uvedené literatury a na základě konzultací s vedoucím diplomové práce a konzultantem.

Datum: 14. 5. 2015

Podpis:

# PODĚKOVÁNÍ

Ráda bych poděkovala především vedoucí diplomové práce Ing. Věře Glombíkové, Ph.D. za cenné rady, vstřícnost a čas, který mi věnovala při zpracování této práce. A také za poskytnutí velké databáze vzorků, díky které mohla být realizovaná experimentální část.

Děkuji také doc. Ing. Marošovi Tunákovi, Ph.D. za pomoc při tvorbě experimentální části.

Dále bych ráda poděkovala společnosti Velveta a.s. za poskytnutí dalších materiálů potřebných pro experiment.

V neposlední řadě bych chtěla poděkovat své rodině a blízkým za jejich podporu po celou dobu studia.

# ANOTACE

Tato diplomová práce se zabývá zkoumáním vlivu strukturních a mechanických vlastností na splývavost tkanin. V teoretické části jsou popsány metody měření a hodnocení splývavosti, zejména pomocí obrazové analýzy. Byl zmapován výzkum v oblasti predikce pomocí splývavosti pomocí neuronových sítí.

V první části experimentu proběhlo zjišťování vybraných strukturních a mechanických parametrů tkanin, byla měřena jejich splývavost a dále hodnocena pomocí obrazové analýzy. Byl zjišťován koeficient splývavosti DC (%) a počet vln. Druhá část se zabývá návrhem a testováním predikčních modelů splývavosti vytvořených pomocí neuronových sítí. Splývavost byla hodnocena na základě vybraných strukturních a mechanických vlastností tkanin.

K tomuto účelu bylo využito softwarové prostředí QC Expert a Matlab. Pro obě aplikace byly navrženy tři hlavní modely pro testování. Model sestávající ze všech dostupných vzorků tkanin, model tvořící lehké šatové materiály a model rezných tkanin. Nejlepších výsledků u obou aplikací je dosaženo pro rezné tkaniny s průměrnou absolutní chybou predikce (MAPE) v rozmezí 4,8 – 7,8 %.

## **KLÍČOVÁ SLOVA:**

splývavost, koeficient splývavosti, počet vln, obrazová analýza, neuronové sítě



# ANNOTATION

This thesis is focused on analyzing the effect of chosen structural and mechanical properties of fabrics on their drape. In the theoretical part, methods of measuring and evaluation of drape by means of image processing are described. The research in the field of neural networks as a predictive tool is presented.

The first part of the experiment deals with measuring structural and mechanical properties of samples. Fabric drape is measured by means of image processing method. The drape coefficient and number of nodes were evaluated. In the second part neural network models for prediction of fabric drape are implemented. Prediction of fabric drape is based on their chosen structural and mechanical properties.

These proposed models were created in QC Expert and MATLAB Neural Network Toolbox. Three kinds of model were tested. First model was created from all fabric samples, second model involved light fabrics with good drape and third model consisted of pure cotton fabrics without finishing. The best results of drape prediction for both applications were found for third model. Mean absolute error of drape prediction (MAPE) was in range between 4,8 to 7,8 %.

## **KEY WORDS:**

fabric drape, drape coefficient, number of nodes, image processing, neural networks

## Obsah

Úvod.....	11
1 Splývavost.....	12
1.1 Normy definující měření splývavosti .....	12
1.2 Vybrané metody hodnocení splývavosti .....	13
2 Vybrané faktory ovlivňující splývavost tkanin.....	19
2.1 Strukturní parametry tkaniny.....	19
2.1 Mechanické vlastnosti textilie .....	20
3 Využití inteligentních metod pro predikci splývavosti.....	22
3.1 Neuronové sítě.....	22
3.2 Průzkum v oblasti predikce splývavosti pomocí ANN .....	28
4 Experimentální část.....	34
4.1. Materiály použité na experiment .....	34
4.2. Měření mechanických vlastností pomocí systému KES .....	34
4.3. Měření a hodnocení splývavosti.....	35
4.4. Predikce splývavosti pomocí neuronových sítí .....	43
Závěr .....	65

## Úvod

V oděvním průmyslu je snahou vytvářet kvalitní oděvní výrobky, které budou mít požadované užité vlastnosti, budou zajišťovat komfort při nošení, uspokojí estetické i další požadavky zákazníka. Splývavost je unikátní a jednou z nejdůležitějších estetických vlastností plošných textilií, která ovlivňuje vzhled a kvalitu výrobku. Splývavost je dána druhem oděvního materiálu, jeho složením, použitými přízemi, vazbou, a také finálními úpravami. Zhotovení kvalitního oděvního výrobku si tedy vyžaduje mimo jiné podrobné znalosti oděvních materiálů, jejich struktury a vlastností vyplývajících z dané struktury.

V souvislosti s vývojem virtuálních systémů pro návrh oděvů je snahou předvídat prostorové chování textilie a estetické působení konečného výrobku. Splývavostí a možností její predikce se doposud zabývalo mnoho studií a vědeckých experimentů. Cílem diplomové práce je analyzovat strukturní parametry a mechanické vlastnosti textilie, které nejvíce ovlivňují její splývavost. Predikce splývavosti z mechanických vlastností materiálů bude provedena s využitím neuronových sítí.

V teoretické části je představen pojem splývavost. Pro přehled jsou uvedeny používané metody a principy měření a hodnocení splývavosti. Podrobněji je popsána analýza obrazu a hodnocení splývacích parametrů. Dále jsou uvedeny strukturní a mechanické vlastnosti tkanin, které ovlivňují splývavost. Predikcí splývavosti tkanin z jejich mechanických vlastností se zabývá mnoho vědců. Nejčastěji k tomu využívají různé numerické metody ve spojení s umělými neuronovými sítěmi, které mají v oděvním a textilním průmyslu stále větší využití. Za tímto účelem je dále v rešeršní části zmapován dosavadní výzkum a výsledky dosažené v této oblasti. V experimentální části je provedeno měření splývavosti pomocí obrazové analýzy. Na základě vybraných strukturních a mechanických parametrů jsou navrženy modely neuronových sítí pro predikci splývavosti a v závěru je vyhodnocena úspěšnost navržených modelů.

# 1 Splývavost

Pro pojem splývavost existuje v mnoha literaturách celá řada definic [1,2,3,4]. Po shrnutí se všechny shodují v tom, že splývavost je schopnost deformace textilie vlivem zemské tíže, přičemž se textilie tvaruje do zaoblených záhybů. Splývavost rozhoduje o účelu použití textilie, ovlivňuje estetický vzhled, kvalitu i komfort oděvního výrobku při nošení. Dle normy [5] je splývavost souhrn vlastností jako vláčnost, poddajnost a ohebnost. Vyjadřuje se poměrem mezi plochou zkoušených vzorků a plochou průmětů vzorků k ploše mezikruží. Stupeň splývavosti je pak vyjádřen procentuálně. Vzhledem k vývoji objektivních metod pro hodnocení splývavosti se jí v poslední době věnuje značná pozornost.

## 1.1 Normy definující měření splývavosti

**ČSN 80 0835** Zkoušení splývavosti plošných textilií průmětem. Norma popisuje metodu měření splývavosti a určování koeficientu splývavosti metodou planimetrie. Splývavost textilie se zjišťuje podle zakresleného tvaru promítnutého na plochu přístroje. Rovná – li se plocha průmětu skutečné ploše zkoušeného vzorku, jedná se o absolutně nesplývavý materiál. Pokud se plocha průmětu rovná ploše vnitřního kruhu držící tkaninu, jedná se o absolutně splývavý materiál. Výsledná hodnota splývavosti je vyjádřena procentech. Tato norma vydaná roku 1971 dnes již není platná. [5]

$$x = \frac{S - \overline{S_p}}{S_m} \cdot 10^2 [\%] \quad (1)$$

kde

- S je plocha zkoušeného vzorku
- $\overline{S_p}$  je průměrná plocha průmětu zkoušených vzorků
- $S_m$  je plocha mezikruží (plocha vzorků způsobila ke splývání)

**Interní norma č. 23-202-01/01** Splývavost tkanin. Ohyb přes ostrý roh. Tato vnitřní norma byla vypracovaná v rámci Výzkumného centra Textil LN00B090 a schválena v roce 2003. Týká se hodnocení splývavosti tkanin a některých vybraných pletenin pomocí splývavého úhlu (Drape Angle DA). Měření se provádí ohybem čtvercových vzorků textilií přes ostrý roh (90 °) horizontálního měřicího stolu v důsledku jejich vlastní váhy. Vzorek tkaniny při ohybu vytváří šikmou ostrou a rovnou hranu, následně je měřen její odklon od horizontální roviny. Veličina charakterizující stupeň splývavosti je potom sinus úhlu  $\varphi$ , který vzniká mezi splývavou hranou a horizontální rovinou. [6]

## 1.2 Vybrané metody hodnocení splývavosti

Zákazník i textilní výrobce běžně hodnotí splývavost subjektivně a podle praktických zkušeností. Subjektivní hodnocení postačuje pro obecné použití. Splývavost je velkým fenoménem, proto jí vědci přikládají důležitost a pokouší se ji měřit a hodnotit kvantitativně a objektivně.

Jelikož už byly mými předchůdci několikrát popsány běžné metody měření splývavosti, v následujícím odstavci budou představeny pouze jako přehledná část. Podrobněji budou popsány různé metody zpracování obrazu a hodnocení splývavosti pomocí moderních softwarových zařízení.

Studium objektivních metod hodnocení splývavosti začalo v roce 1930 s Piercem [7], který inicializoval výzkum měření ohybové tuhosti. Měření bylo uskutečněno pomocí vetknutého nosníku (tzv. Cantilever test) a splývavost byla následně určována nepřímou. Toto dvojdimenzionální měření však přináší řadu omezení, protože opomíjí podstatný třetí rozměr. Je třeba brát v úvahu, že tkanina může být ohýbána ve více směrech, oděvy vykazují komplexní 3D tvar. 3D metody měření splývavosti, dále měření mechanických vlastností a hodnocení jejich vzájemných relací umožňují zachytit komplexní informace o splývavosti.

Proto v roce 1950 tým vědců Chu, Cuming, Texeira ve Fabric Research Technology [8] vyvinuli přístroj pro trojdimenzionální měření splývavosti zvaný F. R. L. drapemeter. Tento optický přístroj umožňuje měřit ve třech směrech a kvantitativním způsobem určit anizotropní vlastnosti. Textilie je upnutá mezi dva kruhové disky, pomocí čočky je obrys promítnut na skleněnou desku a výsledná plocha se obkreslí na papír. Z plochy průmětu se vypočítá tzv. koeficient splývavosti  $DC$  v % (2). Čím vyšší je jeho hodnota, tím je tkanina tužší a méně splývá. Cusick později tuto metodu inovoval, systém čočky vyměnil za světelný zdroj a promítnutý stín byl obkreslen na papír.

$$DC = \frac{S - \pi r^2}{\pi R^2 - \pi r^2} \cdot 100 [\%] \quad (2)$$


kde  $S$  je plocha průmětu (stínu) splývající textilie ( $\text{cm}^2$ )

$r^2$  je poloměr kruhového disku

$R^2$  je poloměr původního (nesplývavého) vzorku

Další pokrok v hodnocení splývavosti přišel s vývojem počítačové techniky a virtuálních oděvních systémů. Splývavost měřena tradičně pomocí drapemetru a určením pouze koeficientu splývavosti je pro její kompletní popis nedostačující. Dvě tkaniny se stejným  $DC$  mohou mít rozdílné splývavé tvary. Je potřeba zavést další parametry jako počet, umístění, rozměry a tvar vln, profily splývání. Hodnocení splývavosti z plochy průmětu bylo nahrazeno metodou zpracování obrazu. Tato metoda je obvykle založena na principu Cusickova drapemetru, na který je umístěn digitální fotoaparát nebo kamera pro pořízení snímků. Ty se dále přenesou do počítače a upravují pomocí speciálního softwarového programu (Lucia G, Nis Elements, MATLAB, atd.). Zachycený barevný obraz se převede na šedý a pomocí prahování na binární (černobílý). Dále se měří parametry objektu (plocha, obvod, úhly, atd.).

Digitalizace obrazu přináší efektivní, rychlé a přesnější vyhodnocení splývavosti. Mnoho vědců využilo k popisu splývavých parametrů právě analýzu obrazu a různé softwarové nástroje. [9, 12]



**Obr. 1** Hodnocení splývavosti na základě obrazové analýzy [12]

Už v r. 1998 se Stylios a kol. zabývali 3D virtuálním měřením splývavosti a důležitými atributy splývání jako počet vln, jejich variace a hloubka. Stylios a Zhu navrhli parametr  $S$  jako ukazatel rovnoměrnosti záhybu. Plochý záhyb je v případě, že je  $S$  roven nule. Pokud se  $S$  blíží k 1, dochází ke změně v délce záhybu. [37]

$$S = \sum_{i=1}^n \frac{(p_{\max}(i) - \bar{p}_{\max})^2}{\bar{p}_{\max}^2} \quad (3)$$

kde  $p_{\max}(i)$  je maximální délka  $i$ -tého záhybu  
 $\bar{p}_{\max}$  je průměrná maximální délka záhybu

Robson a Long použili obrazovou analýzu pro zkoumání cirkularity (CIRC) splývavého profilu. Tento parametr popisuje rozsah splývání, jedná se o poměr plochy a obvodu splývavého vzorku. Hodnota je v rozmezí 0 a 1, při hodnotě 1 se jedná o perfektní kruh a hodnota blíží se 0 představuje složitý tvar. [38]

$$\text{CIRC} = 4\pi \frac{A}{p^2} \quad (4)$$


kde A je plocha splývavého profilu

p je obvod splývavého profilu

Behera s kolegy zavedli pomocí analýzy obrazu a software MATLAB nové parametry pro popis splývavosti. Těmi jsou DDR (drape distance ratio) jako alternativní parametr k DC, na rozdíl od něj se s rostoucí flexibilitou zvyšuje. FDI (fold depth index) pro hloubku vln, A je amplituda vytvořené splývavé vlny. [39]

$$\text{DDR} = \frac{r_2 - r_{\text{avg}}}{r_2 - r_1} \times 100 (\%) \quad (5)$$

$$\text{FDI} = \frac{r_{\text{max}} - r_{\text{min}}}{r_2 - r_1} \times 100 (\%) \quad (6)$$



Obr. 2 Splývavý profil [39]

$$A = \frac{r_{\text{max}} - r_{\text{min}}}{2} \quad (7)$$

kde  $r_1$  je poloměr disku

$r_2$  je poloměr původního nespĺývavého vzorku

$r_{\text{min}}, r_{\text{max}}$  je minimální a maximální poloměr splývavého vzorku



Abdin a kol. pro popis splývavých vlastností také použili obrazovou analýzu. Pomocí software MATLAB hodnotili konturu splývání a hodnotili různé parametry splývání, jako DC (%), DDR (Drape Distance Ratio), FDI (Fold Depth Index) a počet vln. Ve své práci dále zkoumají, jak se tyto parametry chovají v závislosti na parametru CF (koeficient zakrytí). Schopnost tkanin splývat se zvětšuje s klesajícím CF, to se projevuje nízkým DC a vysokým DDR. Naopak žádný zjevný trend se neprojevil mezi CF a počtem vln. Hloubka každé vlny (parametr FDI) je snížena s rostoucím CF. [11]

Přístroj pro 3D měření splývavosti Sylvie 3D Drape Tester byl vyvinutý na Budapešťské univerzitě. Jedná se o počítačem řízené skenovací zařízení se čtyřmi kamerami, které pomocí laserů snímá vzorek upnuté splývající textilie. Vytvořený 3D obraz lze v počítači libovolně otáčet. Program automaticky vyhodnotí koeficient splývavosti (*DC*), počet vln (*n*), nový faktor nerovnosti (*DU*), který poskytuje popis geometrické asymetrie a nerovnoměrnosti splývání vzorků. [13]

Unikátní zařízení pro 3D snímání splývavosti představuje 3D drape scanner. Poskytuje skutečný obraz splývavého vzorku textilie a na rozdíl od Cusickova drapometru disponuje sériemi funkcí pro detailnější analýzu splývavého tvaru. Software 3Dscan automaticky vyhodnocuje vybrané parametry splývavosti, což zlepšuje přesnost hodnocení. Mezi tyto parametry patří koeficient splývavosti DC [%], počet vln, jejich plocha a obvod i charakteristika umístění vln (výpočet úhlu a hloubky). Snímání 3D obrazu splývavého vzorku je založeno na jednom z obecných principů 3D laserového skenování. Obraz je vytvářen rotací skenovací hlavy okolo testovaného vzorku. Hlava se skládá ze dvou CCD kamer a zdroje laserového paprsku, paprsek dopadá na povrch snímaného vzorku a pomocí CCD kamer se detekuje jeho stopa. Obraz světelné stopy laseru je použit k tvorbě 3D obrazu splývavé tkaniny pomocí software MATLAB. Oproti klasickému 2D drapometru trvá měření a hodnocení mnohem kratší dobu, asi 1,5 min. Software dále umožňuje zobrazit povrch snímaného vzorku odpovídající skutečné struktuře textilie, tento obraz je pokryt v síťovém modelu představující tzv. mračno bodů.



**Obr. 3 3D drape scanner [17]**



**Obr. 4 Obrázek 2D projekce splývavého vzorku, výpočet DC [17]**

Měření 3D drape scannerem zahrnuje podstatný třetí rozměr splývavosti (v ose z) a umožňuje identifikovat vnitřní vlny. To je důležité zejména pro tkaniny s vysokou splývavostí, kdy testované vzorky vytváří vnitřní splývavé vlny, které se formují pod vnější hranou upínacího kruhového disku. Toto 3D mapování poskytuje skutečný tvar a rozměry testovaného vzorku, umožňuje sledovat hloubku a úhel splývavých vln v libovolném bodě vzorku, zkoumat vnitřní vazby mezi mechanickými vlastnostmi tkaniny a její splývavostí, tj. vztah mezi tuhostí v ohybu a splývavostí a vztah mezi tuhostí ve smyku a splývavostí. [14]

Původním záměrem této práce bylo použít k hodnocení splývavosti přístroj 3D drape scanner, z důvodu technických závad se však realizace neuskutečnila.



**Obr. 5 Hodnocení splývavosti pomocí software 3Dscan [17]**

## 2 Vybrané faktory ovlivňující splývavost tkanin

Tkanina sestává z vazebných bodů, u nichž dochází ke vzniku třecích sil a ty jsou hlavními nositeli mechanických i tvarových vlastností tkaniny. Úroveň splývavosti tkanin je určována mnoha strukturními parametry, a to především dostavou osnovy a útku, druhem nití ve vazbě v obou směrech a plošnou hmotností. Velký vliv má také konečná úprava tkanin. [2]

Glombíková, Halasová, Vítová ve své studii uvádí, že splývavost plošné textilie je ovlivňována vlastnostmi samotné textilie, stejně jako vlastnostmi přízí a vláken, ze kterých je vyrobena. Mezi vlastnosti přízí a vláken patří jemnost, počet zákrutů a materiálové složení. Geometrické vlastnosti zahrnují tloušťku, vazbu, dostavu nebo délku splývající plochy. Důležitými mechanicko - fyzikální vlastnostmi jsou především tuhost v ohybu, třecí vlastnosti a plošná měrná hmotnost. [18]

### 2.1 Strukturní parametry tkaniny

Mezi základní strukturní prvky tkanin patří osnovní a útkové nitě a jejich součinitelé, protože mezi nimi dochází ke vzájemnému působení třecích sil. Dále vazba tkaniny a střída vazby, dostava osnovy a útku, setkání. Je neustále snahou nacházet vztahy mezi strukturou a vlastnostmi textilií. [1]

Mezi strukturní parametry přízí ovlivňující splývavost patří jemnost. S rostoucí jemností roste tuhost v ohybu, a tak klesá splývavost. Nitě jsou hrubší, roste hustota tkaniny, zaplnění, tloušťka a plošná hmotnost.

Dalším vlivným faktorem je zákrut, který zvyšuje třecí sílu mezi vlákny a zabraňuje tak jejich prokluzu. Tkanina se stává tužší na ohyb a je méně splývavá.

Vliv vazby bereme v potaz, pokud ostatní parametry zůstávají konstantní. Plátno je nejhustěji provázané a má nejmenší splývavost. Atlas má splývavost největší a kepr je kompromisem mezi nimi. S vazbou souvisí pojem flotáž, jedná se o neprovazující úsek nitě. U neplátnových vazeb je vyšší počet flotujících nití, tím je se snižuje ohybová tuhost a naopak zvyšuje splývavost tkaniny.

Dostava je počet nití na jednotku délky (dostava osnovy, dostava útku). S rostoucí dostavou roste tuhost tkaniny a klesá splývavost. Plátno má největší dostavu, kterou už nelze dále zvyšovat, nitě jsou nahuštěné a neflotují. Rozestup mezi nitěmi je dán také jejich průměrem.

Co se týká materiálového složení, obecně jsou přírodní vlákna více měkká, poddajná, ohebná a splývavá. Syntetická vlákna jsou tužší. Bavlna např. je oproti lnu poddajnější, více ohebná. [19, 20]

Jing v této souvislosti analyzoval strukturu tkanin a vliv materiálů na tuhost. Zkoumal vztah mezi zákrutem spolu s počtem přízí, tloušťkou tkanin a tuhostí pro třídu lehkých česaných tkanin. Výsledky výzkumu ukazují silný vliv druhu materiálu a struktury příze na tuhost. [21]

Protože tkaniny nejsou osově symetrické, chovají se rozdílně ve směru osnovy a útku, jejich důležitou vlastností je tedy anizotropie. Sidebraite a Mastekaite měřili ohybovou tuhost pro dvanáct různých směrů a dva hlavní směry a na základě korelační analýzy a polárních diagramů zjistili, že obojí jsou dobrými predikátory profilu i koeficientu splývavosti. [9]

Nofitoska a kol. zkoumali vliv struktury a konečných úprav tkanin na jejich ohebnost a splývavost. Nejvlivnějšími parametry se projevila hustota útku a počet nití v útku (dostava). Největší efekt byl dosažen u tkanin s vyšším počtem dvojitých útkových nití. Zvyšující se hustota útku ovlivňuje tuhost jak ve směru útku tak osnovy. V porovnání s tuhostí je vliv na splývavost menší a u různých vzorků se projevuje jinak. Co se týká konečných úprav, není zcela jasná souvislost s tuhostí a splývavostí. Testování u vzorků s olejovou a nepromokavou úpravou se v jednom případě projevilo nižším DC, zatímco v druhém DC vzrostl. [21]

## **2.1 Mechanické vlastnosti textilie**

Řada vědců se shoduje v tom, že na splývavost mají vliv především mechanické vlastnosti. Zároveň se ale rozchází v tvrzení, které parametry jsou ty nejvlivnější. Jak uvádí řada vědců, někteří jsou zmíněni níže, tuhost v ohybu má na splývavost největší

vliv. Je definována jako odolnost plošné textilie vůči ohýbání. Závislost splývavosti na ohybové tuhosti je lineární. S rostoucí tuhostí klesá splývavost. [4]

Cusick [9] ve své práci měřil spolu s koeficientem splývavosti také ohybovou a smykovou tuhost. Později prokázal, že způsobená deformace závisí na smykové tuhosti i ohybové délce. Z tohoto principu vycházela řada dalších vědců, kteří potvrdili vztah mezi splývavostí a mechanickými vlastnostmi, měřenými jak v osnovním tak útkovém směru.

V této souvislosti je potřeba se zmínit o publikaci Mooroky a Niwy, ti vytvořili rovnici poskytující základ pro určení  $DC$  [%] pro predikci splývavosti z mechanických charakteristik naměřených na systému KES. Do vztahu uvedli tuhost v ohybu ve směru osnovy a útku  $B$  [ $\text{g}\cdot\text{cm}^2/\text{cm}$ ] a hmotnost  $W$  [ $\text{mg}/\text{cm}^2$ ]. Niwa a Seto později ukázali, že  $DC$  [%] nezávisí jen na ohybové tuhosti, ale i ohybové a stříhové hysterezi. Hu a Chan uvažovali vztah mezi 16 parametry měřených pomocí KES a hodnotami splývavosti z Cusickova drapometru. Vznikly tyto čtyři rovnice (4,5,6,7), kde  $b_0$  a  $b_i$  představují libovolné konstanty,  $n$  je počet parametrů vztahujících se k  $DC$ ,  $x_i$  je mechanický parametr. Rovnice (4) je jednoduchá regresní rovnice, odvozená rovnice Niwy a Seta (5), rozšířená rovnice s logaritmickou přeměnou mechanických vlastností (6), rovnice (7) je logaritmické vyjádření mechanických vlastností a  $DC$ . [9]

$$DC = b_0 + \sum_{i=1}^n b_i x_i \quad (8)$$

$$DC = b_0 + b_1 \sqrt[3]{\frac{B}{W}} + b_2 \sqrt[3]{\frac{2HB}{W}} + b_3 \sqrt[3]{\frac{G}{W}} + b_4 \sqrt[3]{\frac{2HG}{W}} \quad (9)$$

$$DC = b_0 + \sum_{i=1}^n b_i \ln x_i \quad (10)$$

$$\ln DC = b_0 + \sum_{i=1}^n b_i \ln x_i \quad (11)$$

Tokmak, Berkalp a Gersak [7] ve své studii také prokázali, že největší vliv na splývavost mají ohybové a smykové vlastnosti. Mechanické vlastnosti 21 vzorků tkanin měřili pomocí systému KES i FAST, zkoumali prodloužení, ohybovou a smykovou tuhost. V obou případech se projevila velmi dobrá korelace pro každý parametr. Pomocí vícenásobné regrese bylo zjištěno, mezi primární vliv na splývavost má ohybová smyková tuhost.

Pattanayak a kol. [22] také poukazují na velký vliv mechanických vlastností na splývavost, zejména na ohybovou tuhost, smyk a zaplnění. Všechny tyto vlastnosti mají přímou souvislost se základními vlastnostmi vláken a konstrukcí tkaniny. Vztah mezi mechanickými vlastnostmi a splývavostí je navíc složitý a nelineární. Vyšší tuhost v ohybu brání formování záhybů, tím je tkanina tužší, více plochá, vykazuje vyšší *DC*. Tuhost ve smyku dobře koresponduje s parametry splývavosti. Na vzorek splývající přes hranu působí kombinace sil a všechny možné body jsou tak deformovány.

### **3 Využití inteligentních metod pro predikci splývavosti**

Poslední dobou se vědci snaží predikovat splývavost pomocí numerických metod modelování za pomoci naměřených mechanických vlastností. Jednou z vyspělých a účinných metod jsou neuronové sítě.

#### **3.1 Neuronové sítě**

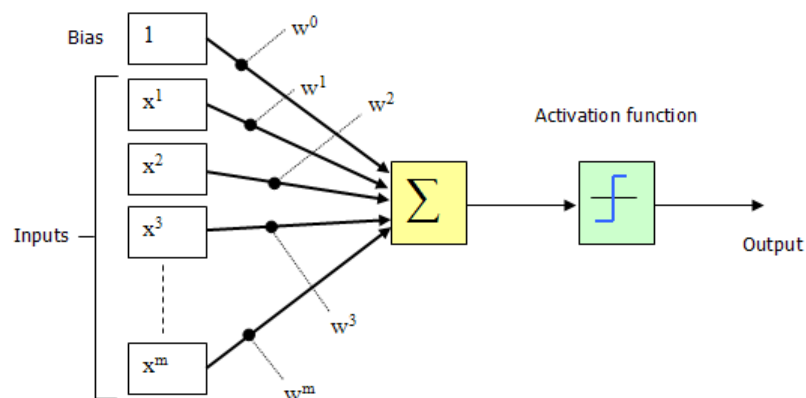
Využití inteligentních metod v textilním a oděvním průmyslu se stále zvyšuje napříč všemi oblastmi. Mezi tyto metody patří neuronové sítě (Artificial Neural Networks), zkráceně ANN nebo jen NN. Umělé neuronové sítě jsou inspirované biologickým nervovým systémem. Jsou konfigurované pro různé aplikace, jako je predikce, rozpoznávání nebo klasifikace dat. Jejich výhoda spočívá v automatickém učení závislostí pouze ze vzorových dat, aniž by bylo zapotřebí přidávat další informace (např. typ závislosti u regrese). Neuronová síť se trénuje na historických datech s cílem odhalit skryté závislosti a využít je k predikování budoucnosti. Je to vlastně jakási černá skříňka, která je schopna se něco naučit z dat. [34]

Jedná se o síťovou strukturu skládající se z mnoha propojených elementů (neuronů). Princip neuronu spočívá v procesu učení, při kterém se celý systém adaptuje podle optimalizačních algoritmů, aby co nejlépe vyřešil danou úlohu. Neurony jsou navzájem propojeny synapsemi, těmi protéká informace, kterou neuron zpracovává. Dělí se na vstupní, pracovní (skryté) a výstupní. Počet neuronů v jednotlivých vrstvách sítě závisí na řešeném problému (počtu vzorů, proměnných, požadované kvalitě předpovědi, atd.). Neuronové sítě se dokážou efektivně naučit rozsáhlé datové soubory a odhalit neznámé vztahy mezi různými proměnnými. Používají se k modelování vztahu mezi vícerozměrnou proměnnou vstupní a výstupní [23].

Každý neuron tvoří vstupy  $x_1$  až  $x_n$  (vektor vstupních proměnných), které jsou násobeny váhami  $w_1$  až  $w_n$  (vektor vah vstupních proměnných). Vážená suma vstupních hodnot představuje vnitřní potenciál neuronu (8).


$$y_{in} = bias + \sum_{i=0}^n x_i \cdot w_i \quad (12)$$

Tato vážená suma je v neuronu následně transformována aktivační funkcí, která vyjadřuje intenzitu odezvy neuronu na daný vstup. Bias představuje nastavitelnou prahovou hodnotu a určuje, kdy je neuron aktivní (jakmile dosáhne hodnoty prahu).



**Obr. 6 Schéma umělého neuronu [32]**


Aktivační funkce by měla být nelineární, protože neuron je nelineární prvek a nelinearita je distribuována v rámci celé sítě. Mezi nejpoužívanější patří logistická funkce, sigmoida, hyperbolický tangens, Gaussova, atd. [23, 26].




**Obr. 7** Přehled přenosových aktivačních funkcí [33]

Váhy určují schopnost a intenzitu vazby, tzv. synapse mezi proměnnou a neuronem. Váhy jako nezávislé prvky sítě jsou nastaveny tak, aby se minimalizoval rozdíl mezi požadovanou a skutečnou odezvou sítě vytvořené vstupním signálem v souladu s daným statistickým kritériem. Neuronová síť tedy používá metodu nejmenších čtverců, aby součet čtverců rozdílů predikované a naměřené hodnoty výstupní proměnné byl nejmenší. Výstupní proměnné se predikují jako vážené lineární kombinace vstupů z poslední skryté vrstvy neuronů. Neuronová síť je zvláštním případem vícenásobné nelineární regrese zvaná neparametrické regrese právě proto, že obsahuje skryté vrstvy [23, 24].





Obr. 8 Schéma neuronové sítě [23]



Obr. 9 Aktivační funkce neuronu [23]

### 3.1.1 Proces učení (trénování sítě)

Pro trénování sítě je potřeba mít dostatek reprezentativních příkladů. Nejprve je nutné vytvořit trénovací množinu (např. naměřené údaje). K různým kombinacím vstupů přiřadíme požadované výstupy. Při tvorbě modelu nejprve zvolíme skupinu prediktorů (nezávisle proměnných) a skupinu závisle proměnných. Následně zvolíme architekturu neuronové sítě, to znamená počet vrstev a neuronů v jednotlivých vrstvách. Následuje optimalizace parametrů sítě, tedy proces učení neuronové sítě, při kterém se optimalizační algoritmus snaží najít vhodné nastavení vah [23].

Úspěšnost NN můžeme posoudit podle poklesu kritéria součtu čtverců, rovnice (13). Střední kvadratická chyba MSE (Mean Square Error) je i součástí učení neuronové sítě, kde se tuto chybu snaží algoritmus zpětné propagace eliminovat, a proto je vhodné ji sledovat. Další používanou chybou pro vyhodnocení celkové predikce je střední absolutní chyba MAE (Mean Absolute Error). [24]

$$MSE = \frac{1}{n} \sum_{i=0}^{n-1} (t_i - o_i)^2 \quad (13)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=0}^n \left| \frac{t_i - o_i}{t_i} \right| \quad (14)$$

kde  $N$  je počet predikovaných hodnot


$t_i$  je měřená hodnota

$o_i$  je predikovaná hodnota

Existuje celá řada typů neuronových sítí. Základní dělení je na jednovrstvé a vícevrstvé sítě s učitelem a bez učitele. Pro klasifikaci, regresi i predikci je nejrozšířenější a nejpoužívanější vícevrstvá síť většinou s aktivační funkcí sigmoida a algoritmem backpropagation. Více vrstev s nelineární přenosovou funkcí dokáže síť naučit nelineární a lineární vztahy mezi vstupními a výstupními proměnnými [24].

### 3.1.1 Backpropagation (BPG)

Nejpoužívanějším učícím algoritmem je algoritmus zpětného šíření chyby, který spočívá v určení chyby na výstupní vrstvě sítě a následně její zpětné šíření do vstupní vrstvy. Dá se říct, že vyhodnocené řešení se porovnává s očekávaným a hodnotí se, o kolik se neuronová síť spletla. Zpětně se na základě toho vypočítá, o kolik se mají změnit váhy neuronů, aby byla tato odchylka minimální. Dělí se na tři hlavní fáze, dopředné šíření vstupního signálu neboli feed forward (vstupy každého neuronu jsou napojeny na výstupy všech neuronů předchozí vrstvy, každý neuron řeší pouze část problému), zpětné šíření chyby a aktualizace váhových hodnot vstupů neuronů. Tyto části se cyklicky opakují, dokud není dosaženo dostatečně malé chyby sítě nebo předem daného mezního počtu iterací [24].



**Obr. 10 Schéma neuronové sítě BPG [34]**

### 3.1.1 Radial Basis Function (RBF)

Třívrstvá síť s radiálně bazickou funkcí, která je určena svým středem a pro argumenty se stejnou vzdáleností od tohoto středu dává stejné funkční hodnoty. Váhy v první vrstvě jsou nastavovány pevně na začátku učení, ve druhé vrstvě podobně jako u vícevrstvé perceptronové sítě nebo přímo regresi. Díky své struktuře a vlastnostem se tato síť na rozdíl od BPG učí mnohem rychleji. RBF neuron se skládá ze vstupů  $x_1$  až  $x_n$  a každému vstupu  $x_i$  je přiřazena váha  $c_{ik}$ . Zahrnuje třífázové učení pro výpočet středu ( $c_{jk}$ ), šířek ( $b_j$ ) a vah ( $w_{jk}$ ). Jako aktivační funkce se nejčastěji využívá Gaussova radiální funkce (rov.), kde  $c$  je střed a  $r$  poloměr. Většinou se projevuje jako rychlejší, ale s méně přesnými výsledky oproti BPG. Navíc RBF síť vyžaduje 10krát více dat než BPG pro dosažení stejných výsledků. [31]

$$h(x) = \exp\left(-\frac{(x - c)^2}{r^2}\right) \quad (15)$$

### 3.2 Průzkum v oblasti predikce splývavosti pomocí ANN

Stylios a Powell [25] zkoumali vztah mezi parametry splývavosti a mechanickými vlastnostmi, a protože je značně nelineární, použili k tomu model neuronové sítě s algoritmem BPG a také klasický lineární regresní model. Sílu predikce obou modelů porovnávali. Jelikož je  $DC$  [%] pro kompletní popis splývavosti nedostačující (tkaniny se stejným  $DC$  mohou mít různý počet vln), provedli objektivní měření podstatných atributů splývavosti, a to počet, hloubku a umístění záhybů. Poté provedli objektivní měření smyku, ohybu a plošné hmotnosti vzorků na systému KES. Bylo zjištěno, že použití přirozeného logaritmu materiálů dělených nejprve podle plošné hmotnosti tkanin vytváří mnohem efektivnější prediktivní model.

Lam a kol. [26] použili ANN pro predikci koeficientu splývavosti a kruhovosti mnoha různých druhů tkanin. Vytvořili vícevrstvou síť se zpětným šířením chyby (BPG) a radiální bazickou funkcí (RBF), ta byla pro trénování rychlejší. Predikce pro kruhovost byla méně přesná než pro  $DC$ .

Glombíková, Kůs a Halasová [27] se také ve své studii, zabývali možností predikce splývavosti tkanin s využitím neuronových sítí. Pro predikci splývavosti použili RBF funkci s využitím systému MATLAB (newrbe), dvouvrstvá dopředná síť s jedním výstupem a vstupní Gaussovou radiální funkcí. Učící algoritmus BPG byl vygenerován pomocí systému MATLAB (newff), dopředná síť s jednou skrytou vrstvou, vstupní aktivační funkcí tan-sigmoid a výstupní přenosovou lineární funkcí. V experimentu bylo testováno 92 tkanin, ty byly rozděleny do dvou souborů, první soubor pro vytvoření prediktivních modelů, který byl dále rozdělen na dvě podskupiny, trénovací (Ia) a kontrolní (Ib). Druhý soubor pro ověření navrženého modelu. Pro měření splývavosti byl použit inovovaný drapemeter, stupeň splývavosti byl vyhodnocen běžnou metodou na základě  $DC$ . Z 16 mechanických vlastností naměřených na systému KES bylo pomocí vícenásobné regresní analýzy a analýzy PCA vybráno 5 hlavních vlivných mechanických parametrů, jmenovitě 2HB (hystereze ohybu), 2HG5 (hystereze smyku při úhlu  $5^\circ$ ),  $T_0$  (tloušťka), MIU (koeficient tření) a  $W$  (plošná hmotnost). Pro trénování neuronových sítí (RBF a BPG) byly následně

vytvořeny tři nové charakteristiky, jako kombinace některých vstupních proměnných a plošné hmotnosti nebo tloušťky. Konkrétně  $2HB$ ,  $W$ ,  $\ln(2HB/W)$  a  $\ln(2HG5/W)$ . Obě skupiny zmíněných parametrů spolu dobře korespondují. Za účelem eliminace multikolinearity dat byla provedena analýza PCA. Multikolinearita je častým problémem analýzy dat s množstvím proměnných, je způsobena vzájemnou závislostí mezi vstupními proměnnými. Tato modifikovaná a původní neupravená data (pro útkový i osnovní směr) sloužila jako vstupní pro trénování neuronové sítě BPG a RBF. Nejlepší výsledky predikce pro RBF model poskytl soubor Ib a II, kde koeficient determinace byl mezi 90 – 94 %, střední relativní chyba predikce okolo 16.5 % a maximální absolutní chyba pod 13.5 %. Pro BPG měl nejlepší výsledky model s 11 neurony ve skryté vrstvě s využitím transformovaných dat pomocí analýzy PCA, kde se projevila střední relativní odchylka i maximální absolutní odchylka v rozsahu 7-12 %. Závislost mezi měřenou a predikovanou splývavostí na základě  $DC$  [%] byla tedy pro BPG i RBF model velmi podobná. Korelační koeficient v rozmezí 0.86 až 0.95. Zvýšení predikční schopnosti se projevilo po transformaci vstupních dat pro trénování ANN pomocí PCA.

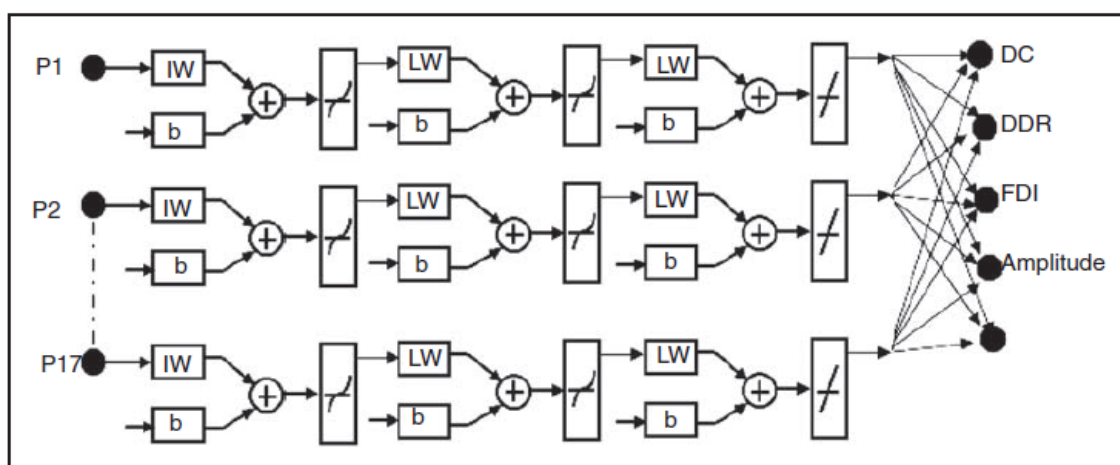
Příspěvek na téma predikce splývavosti tkanin věnovali Militký, Křemenáková a Kůs [28]. Zabývali se výběrem nejvhodnějšího modelu pro predikci splývavosti na základě použití regresních modelů a modelů neuronové sítě s využitím RBF funkce vytvořených pomocí systému MATLAB a nástroje RBF2. Experiment je založen na konvenčním měření splývavosti na základě stanovení  $DC$  [%] s využitím přístroje FRL a obrazové analýzy LUCIA. Měření mechanických vlastností bylo uskutečněno pomocí přístroje KES, byly vybrány 4 potenciální proměnné, a to  $RT$  (tahové elastické zotavení),  $B$  (ohybová tuhost),  $G$  (smyková tuhost),  $W$  (plošná hmotnost). Byla měřena také tloušťka tkanin  $t$  [mm]. Naměřené splývavé a mechanické vlastnosti ze 79 tkanin tvořili soubor I pro trénování sítě. Pro testování schopnosti predikce modelu bylo vybráno dalších 12 tkanin, tvořících soubor II pro ověření kvality modelu. Oba soubory byly analyzovány pomocí vícerozměrných statistických metod. Závislost mezi vybranými proměnnými se projevila zejména mezi tloušťkou a plošnou hmotností, tloušťkou a tahovou silou, tuhostí a plošnou hmotností, tuhostí a smykem. Predikční

schopnost regresního modelu byla charakterizována pomocí predikčního vícenásobného korelačního koeficientu (*PR*). RBF model neuronové sítě byl použit pro predikci *DC* na základě proměnných  $x_1 = B$ ,  $x_2 = G$ ,  $x_3 = RT$ ,  $x_4 = W$ . Algoritmus vybral jako optimum 15 neuronů, včetně optimálních poloměrů, středů a vah. Střední relativní chyba predikce byla 14.65 %. V tomto případě se ukázal jako lepší regresní model s chybou okolo 12.4 %.

Jedda a kol. [29] zkoumali vztah opět mezi *DC* [%] a mechanickými vlastnostmi testovanými tentokrát pomocí systému FAST. Autoři navrhli tři regresní modely pomocí vícenásobné lineární regrese, které byly porovnávány s modelem neuronové sítě, který se ukázal jako mnohem přesnější.

Studie, kterou provedl Pattanayak, Luximon a Khandual [22], se zabývá predikcí splývavého profilu bavlněných tkanin taktéž na základě ANN a vícenásobné regresní metodě. Zkoumali vztah mezi různými parametry splývavosti a mechanickými vlastnostmi ze systému KES. Pro experiment bylo použito 65 vzorků bavlněných tkanin s vazbami různých dostav představující různé zaplnění. Splývavost byla měřena na speciálně vyvinutém přístroji založeném na obrazové analýze. Program zpracuje obraz a poskytuje požadované parametry splývavosti, jako *DC* [%], *DDR* (drape distance ratio), amplitudu, *FDI* (index hloubky převisu), *N* (počet přehybů), které se tvoří během nošení oděvu. Pro vztah mezi zmiňovanými parametry splývavosti a mechanickými vlastnostmi byl vytvořen lineární regresní model na ověřeném předpokladu, že hodnoty těchto parametrů mají normální rozdělení. Pomocí zpětné eliminační metody byla sestrojena jednoduchá predikční rovnice. Bylo zjištěno, že tuhost, smyk a zaplnění má na parametry splývavosti mnohem větší vliv než tahové a tlakové vlastnosti. Z důvodu nelinearity existující mezi vstupy a výstupy byl dále pro predikci splývavosti vytvořen model dopředné neuronové sítě s využitím funkce BPG. Soubory dat byly opět rozděleny na trénovací, validační a nezávislé testovací. Tuto dopřednou síť tvořilo 17 vstupních a 5 výstupních (cílových) prvků, jedná skrytá vrstva s funkcí tan-sigmoid a výstupní přenosová lineární funkce. Původní síť s pěti neurony byla ručně změněna a optimalizována na dvacet neuronů a dvě skryté vrstvy, prokázala se lepší efektivita. Více vrstev umožňuje určení složitých vztahů a rychlejší učení, i když způsobuje více

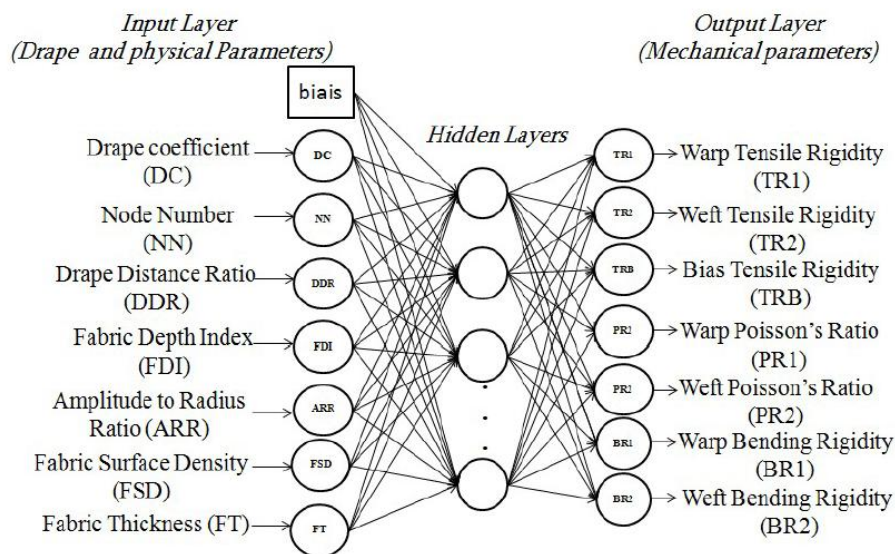
chyb. Deset vzorků z celkového počtu bylo použito pro výpočet procentuální chyby, na základě toho poskytla ANN lepší predikční hodnotu než regresní model. Vypočítala se střední chyba čtverců sítě (MSE) a chybová hodnota se šířila zpět přes síť. Tím docházelo v každé vrstvě k malým změnám vah a biasů. Takto se cyklus opakoval, dokud celková hodnota chyby neklesla pod předem danou prahovou hodnotu. Výsledky jsou oproti statistické metodě přesnější také proto, že berou v úvahu nelinearitu mezi vstupy a výstupy ze statistického modelu. Po shrnutí je model ANN lepší pro hledání složitých nelineárních vztahů a pro přesnější predikci splývavého profilu. Může být velmi užitečným nástrojem pro oděvní průmysl a vývoj vysoce kvalitních textilií.



Obr. 11 Architektura použité neuronové sítě [22]

Za zmínku stojí zajímavý výzkum, který přinesli Hedfi, Ghith a Salah [30]. Využili neuronové sítě pro inverzní přístup, tedy predikci mechanických vlastností z jejich splývavých vlastností. Tuto metodu zvolili z důvodu možnosti úspory nákladů spojených s experimentálním měřením. Využili jednoduchého experimentálního měření splývavosti, tloušťky a hmotnosti na jednotku plochy pro predikci mechanických vlastností. Následně měření splývavosti simulovali na základě drape testu. Virtuální model tkaniny je zde vytvořen pomocí metody konečných prvků a umožňuje měřit znaky splývavosti numericky. Tuto metodu kombinovali s učícím procesem neuronových sítí. K tomu potřebovali databázi obsahující velké množství charakteristik tkanin. Na vstupu jsou fyzikální a splývavé parametry, výstup tvoří mechanické

parametry. Data byla opět rozdělena na soubor trénovací, ověřovací a testovací. Porovnáním simulovaných a naměřených splývavých vlastností se zjišťovala efektivita této metody. Proces se opakoval, dokud rozdíl mezi simulovanou a aktuální splývavostí nebyl dost malý. Nejlepší výsledky poskytl model s optimálním počtem neuronů 35, dvěma skrytými vrstvami a počtem iterací 12. Díky této metodě dokázali predikovat mechanické vlastnosti bez nutnosti měřit je experimentálně.

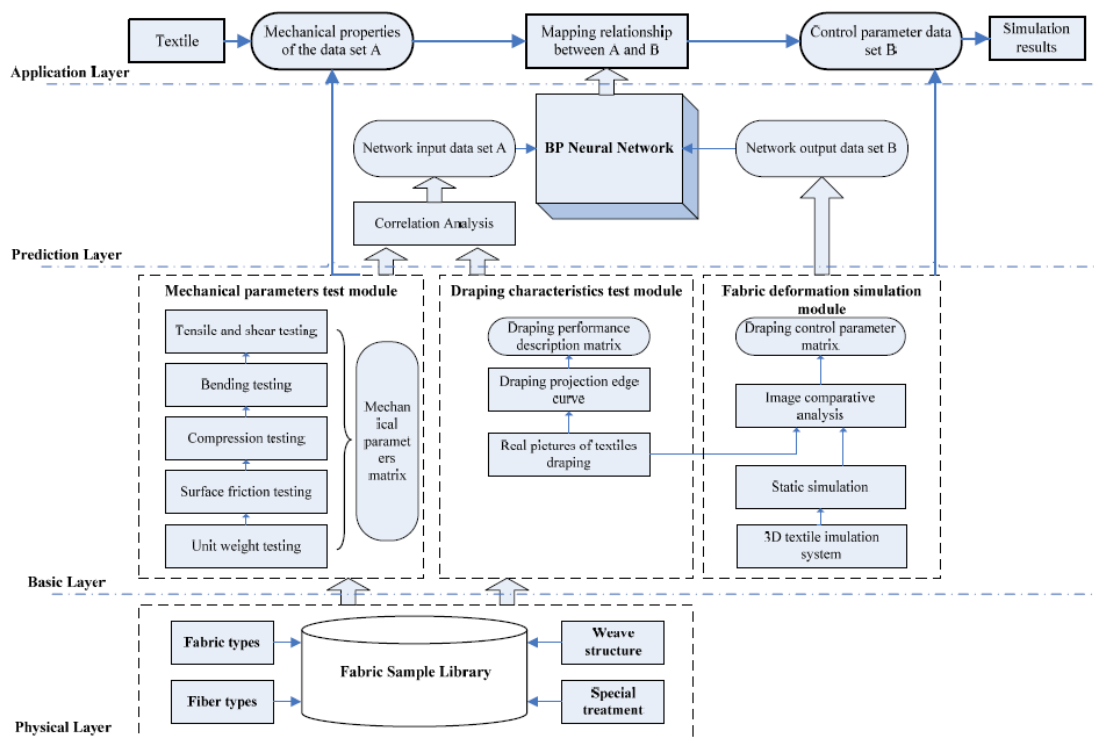


**Obr. 12** Neuronová síť pro inverzní metodu [30]

Jiang, Cui a Hu [31] využili ANN za účelem 3D simulace splývavosti tkanin. Mechanické vlastnosti pro 15 druhů tkanin byly opět měřeny pomocí KES systému. Bylo vybráno sedm parametrů, konkrétně tahová energie (WT), tahové elastické zotavení (RT), ohybová tuhost (B), hysterese ohybu (2HB), tloušťka ( $T_0$ ), koeficient tření (MIU) a plošná hmotnost (W). Tyto parametry představují vstupní proměnné pro neuronovou síť. Byla vytvořena třívrstvá síť, aktivační funkcí byla hyperbolická tangens a výstupní byla klasická lineární. Třináct tkanin představovalo trénovací vzorky a zbylé dvě testovací vzorky. Za účelem eliminace vlivu výsledků učení vzhledem k rozdílným jednotkám vstupních dat byla provedena normalizace.



Jak je vidět na obr. (13), struktura sítě se skládá z fyzické vrstvy, představující knihovnu skutečných vzorků tkanin (čím více, tím lépe). Další vrstvou je základní obsahující modul mechanických parametrů, modul parametrů splývavosti a modul simulace deformace tkaniny. Třetí predikční vrstva na základě BPG mapuje vzájemné vztahy mezi dvěma soubory dat. V poslední aplikační vrstvě se pomocí programu simulují reálné tkaniny. Bylo provedeno 1333 trénovacích kroků, poté byla síť úspěšně zastavena, chyba čtverců sítě uspokojila požadavky systému. Výstup predikční sítě byl uspokojivý. Výsledky ukázaly, že tato metoda je pro 3D simulaci více efektivní a objektivní, protože využívá informací o textilním materiálu a může tak přispět lepším výsledkům simulace ve virtuálním prostředí.



Obr. 13 Vrstvy neuronové sítě [31]

## **4 Experimentální část**

Cílem experimentu je pokusit se predikovat splývavost tkanin pomocí neuronových sítí, a to na základě jejich vybraných strukturních vlastností a mechanických parametrů. V první části je zjišťování vybraných strukturních parametrů a mechanických vlastností u některých vzorků. Měření mechanických vlastností pomocí KES bylo realizováno katedrou oděvnictví. Dále je popsáno měření splývavosti na vzorcích tkanin a hodnocení pomocí obrazové analýzy a vybraného softwarového programu. Ve druhé části experimentu jsou navrženy prediktivní modely splývavosti vytvořené pomocí neuronových sítí, s využitím softwarových programů QC Expert a MATLAB.

### **4.1. Materiály použité na experiment**

Větší část materiálů použitých pro experiment mi byla poskytnuta mou vedoucí diplomové práce Ing. Vierou Glombíkovou, Ph.D. Jedná se o databázi 92 materiálů, od každého materiálu po více vzorcích. Z databáze byly vybrány strukturní a mechanické parametry, které byly později použity jako vstup do neuronové sítě.

Další část vzorků poskytla společnost Velveta a.s. U nich se dodatečně zjišťovala plošná hmotnost [ $\text{g}/\text{m}^2$ ], pomocí digitálních vah dle normy ČSN EN 12127 (80 0849). Ze strukturních parametrů to byla vazba, dostava osnovy a útku. Pomocí soustavy KES byly měřeny mechanické parametry.

Složení všech materiálu je různé (100% CO, 100% PL, 100% VI, směsi), materiály jsou rezné i upravené, v různých vazbách (plátno, kepr, atlas, odvozeniny).

### **4.2. Měření mechanických vlastností pomocí systému KES**

Zde je několik poznámek k využití systému KES (Kawabata Evaluation System), který byl vyvinut k nedestruktivnímu hodnocení mechanických vlastností textilií. Sestává ze čtyř modulů snímajících mechanické vlastnosti lehkých textilií,

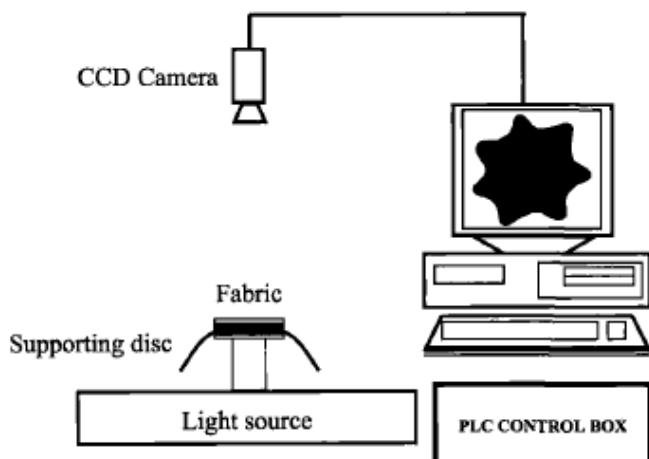
v rozsahu simulující namáhání oděvních textilií při běžném nošení. Celkem měří 16 charakteristik. Modul FB1 je určen pro měření tahu a smyku, lze jím také určovat elastický modul v tahu  $E$  a ve smyku  $G$ , jako základní moduly elastických materiálu, které souvisí mimo jiné i se splývavostí. FB2 měří ohyb a z něho dokáže určit i elastický modul  $E$ . FB3 je modul pro měření stlačení a tedy zjišťuje součinitel stlačitelnosti a mezní tloušťku textilie. Modul FB4 snímá profily povrchu a určuje součinitel tření [36].

Pro tento experiment bylo měření provedeno pouze pro vybrané mechanické vlastnosti, jako tloušťka (stlačitelnost)  $T_0$  [mm], ohybová tuhost  $B$  [ $N \cdot m^2/m$ ], ohybová hystereze  $2HB$  [ $N \cdot m/m$ ], tuhost ve smyku  $G$  [ $N/m \cdot stupeň$ ] a hystereze smyku při smykovém úhlu  $\pm 0,5^\circ$   $2HG$  [ $N/m$ ] a  $\pm 5^\circ$   $2HG$  [ $N/m$ ]. Výběr těchto parametrů pro další použití pro predikci byl dán na základě literární rešerše, neboť podle výzkumů právě tyto parametry nejvíce ovlivňují splývavost.

### **4.3. Měření a hodnocení splývavosti**

Splývavost byla měřena u 9 tkanin. Protože splývavý tvar se pokaždé mění, měření probíhalo na třech vzorcích od každého druhu tkaniny. Celkem bylo tedy získáno 27 splývavých obrazů. Databáze s 92 vzorky zahrnovala i vypočítaný  $DC$  (%). K dispozici jsem měla také splývavé obrazy z předešlého měření. Tudíž zbývalo určit koeficient splývavosti pro nové vzorky a počet vln pro všechny vzorky.

Zkušební vzorky byly před měřením klimatizovány, vyžehleny a ponechány pro relaxaci. Na lícové straně byl vyznačen směr osnovy a útku. Měření splývavosti bylo realizováno pomocí zařízení na katedře oděvnictví, které je založeno na principu Cusickova přístroje. Měření spočívá v upevnění kruhového vzorku textilie (průměr 30 cm) na kruhový disk (průměr 18 cm), pohyblivé zařízení se posune do dolní polohy, následně volné okraje vzorku začnou splývat. Pomocí připojené digitální kamery je vzorek zachycen a dále převeden do počítače, kde probíhá upravování a měření obrazu. K tomuto účelu byl použit program NIS-Elements a MATLAB®. Pro lepší kontrast a viditelné okraje je vzorek podsvícen.



Obr. 14 Zařízení pro měření splývavosti [38]



Obr. 15 Reálný splývavý vzorek  
[zdroj: vlastní]

Pomocí programu Nis Elements se zjišťovaly plochy. Před snímáním vzorků bylo nutné provést kalibraci pomocí milimetrového papíru a označení vzdálenosti v obraze, které odpovídalo skutečné velikosti a poté zvolení správných jednotek (mm). Sejmутý obraz se zmrazil, aby nedošlo k nechtěnému posuvu vzorku a zobrazil se v počítači. Obraz byl transformován na šedý a následně pomocí prahování na binární. Dále se definoval objekt měření, výpočty měřených ploch a základních statistických charakteristik byly uloženy v MS Excel.

Původním záměrem bylo použít k hodnocení DC i počtu vln program Nis Elements. Ve snaze dosáhnout co nejvíce objektivních výsledků jsem se pokusila zjišťovat počet vln pomocí programu Matlab. Než jsem se dopracovala k tomuto kroku, bylo potřeba provést klasické úpravy a transformaci obrazu. Díky navrženému algoritmu, který byl vytvořen ve spolupráci s doc. Ing. Marošem Tunákem, Ph.D., mohly být zároveň automaticky vypočteny plochy vzorků pro výpočet koeficientu splývavosti. V tabulce 1 jsou porovnány výsledky průměrných ploch pro všech 9 vzorků z Nis Elements a Matlabu. Mezi měřenými plochami je zanedbatelný rozdíl, což může být způsobeno kompresí obrazu při ukládání apod. DC (%) proto může být spočten na základě obou

měření ploch. (V experimentu se dále pracuje s DC, který byl vypočten pomocí programu Nis Elements.)

Koeficienty splývavosti k 9 vzorkům byly spočteny dle vzorce:

$$DC = \frac{S - \pi r^2}{\pi R^2 - \pi r^2} \cdot 100 [\%] \quad (16)$$

kde S je průměrná plocha splývající textilie (cm<sup>2</sup>)

r je poloměr kruhového disku (9 cm)

R je poloměr původního vzorku (15 cm)

**Tab. 1 Výsledné plochy splývavých vzorků**


	Průměr [cm <sup>2</sup> ]	Směrodatná odchylka	Min	Max
<b>Nis Elements</b>	480,58	43,38	415,41	534,58
<b>MATLAB</b>	481,88	42,30	417,22	534,06

Aby bylo možné nalézt počet vln, bylo potřeba opět zpracovat nasnímané splývavé obrazy z předchozího měření. Analýza obrazu v programu MATLAB zahrnovala základní kroky jako načtení obrazu, změření délky úseku v pixelech pro následnou kalibraci, převedení obrazu na šedý pomocí příkazu *rgb2gray.m* a pomocí metody thresholding (prahování) na binární obraz (*im2bw*).m. Pro lepší další zpracování a správnou detekci kontury splývavého profilu byly provedeny některé morfologické operace za účelem odstranění nechtěných objektů z obrazu, vyčištění hranic, vyplnění prázdných míst, apod.




**Obr. 16 Úrovně transformace obrazu**

Detekce kontury (obrysu) byla provedena příkazem *edge*, založená na gradientní Cannyho metodě. V porovnání s ostatními poskytuje tato metoda pravdivou přesnou konturu bez šumu.




**Obr. 17 Kontura profilu**



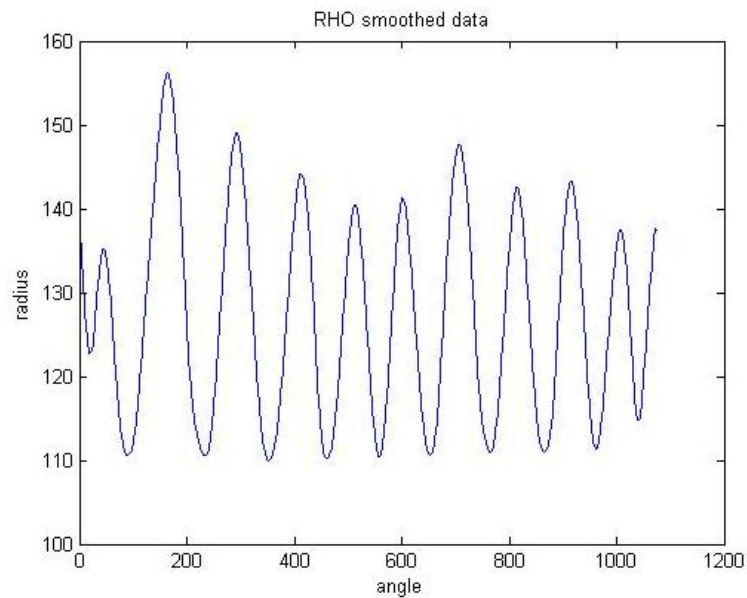
**Obr. 18 Polární graf**

Obrys splývavého vzorku představuje množství jednotlivých diskrétních bodů s danou pozicí souřadnic  $(x_i, y_i)$ . Tyto kartézské souřadnice bylo dále potřeba převést na souřadnice polární, kde je takový bod definován vzdáleností od počátku souřadnic a úhlem ( $^\circ$ ). Díky polárnímu grafu (obr. 17) bylo možné získat konturu splývavého profilu a dále ji hodnotit. Předtím bylo nutným krokem vyhlazení získané křivky pomocí filtru (moving average filter) příkazem *smooth*.

Bylo nutné experimentovat s hodnotou filtru, aby mohlo být dosaženo co nejlepšího vyhlazení křivky a nedošlo k narušení dat. Na obrázku je porovnání před a po vyhlazení.



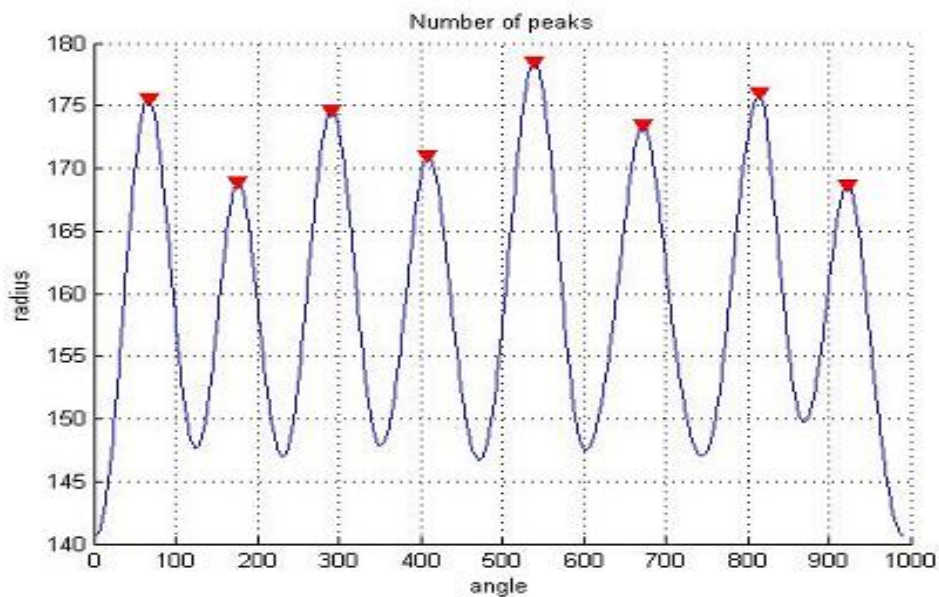
**Obr. 19 Graf - data před filtrací**



**Obr. 20 Graf - data po filtraci**


Nalezení počtu vln bylo provedeno pomocí funkce *findpeaks* (Signal Processing Toolbox), která pracuje na základě lokálních maxim vstupního signálu (dat). U této funkce lze experimentovat s různými hodnotami pro definování minimální výšky vlny, minimální vzdálenosti mezi dvěma sousedními vrcholy nebo nastavení prahové hodnoty.

U některých vzorků bylo díky nastavenému algoritmu pro automatický výpočet snadné nalézt počet vln (peaks), potíže však nastaly u složitějších tvarů a málo splývavých vzorků. Zde se musely individuálně nastavovat jednotlivé parametry vln. U některých vzorků nebylo možné jednoznačně určit přesný počet vln, protože každá hlavní vlna zahrnovala několik dalších menších vln nebo už na první pohled bylo vidět, že se jedná o téměř nesplývavé tkaniny.

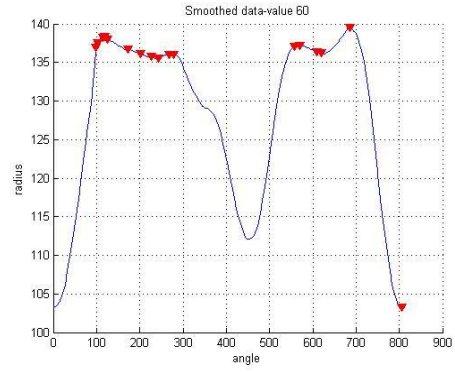


Obr. 21 Graf - počet vln (peaks)






Obr. 22 Profil málo splývavého vzorku



Obr. 23 Chybné nalezení počtu vrcholů

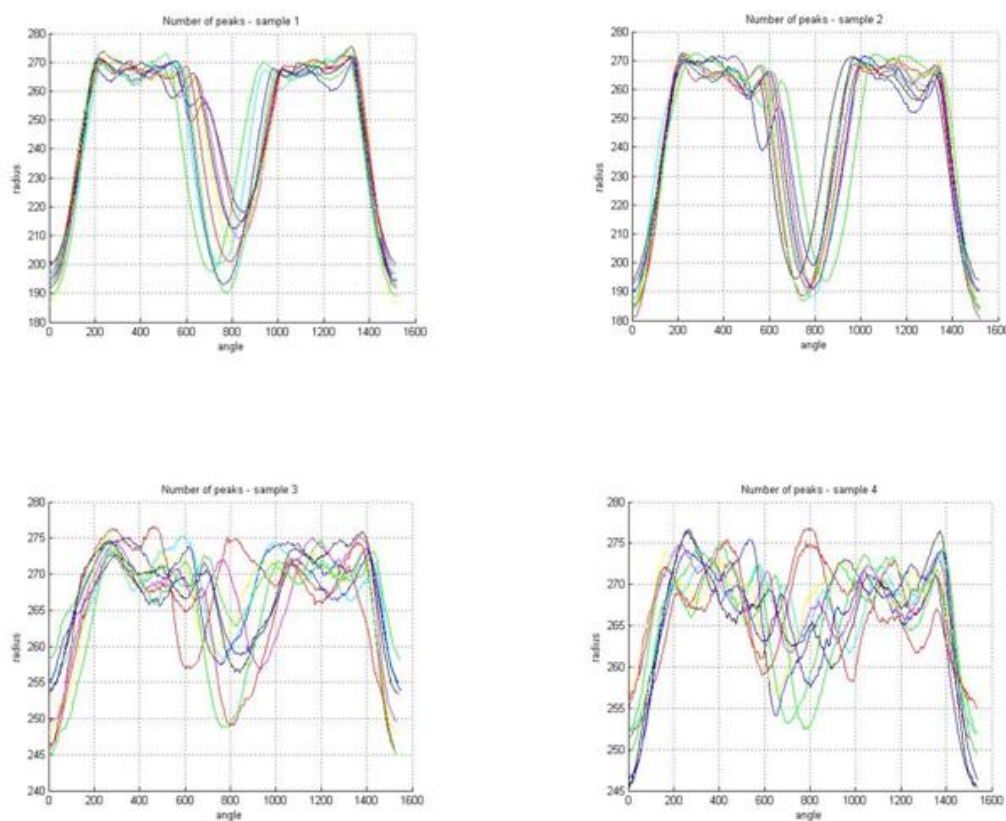
Nalezený počet vln je 0, 5, 6, 7, 8 a 9. U složitých tvarů málo splývavých vzorků, kde nebylo možné určit jasný počet vln, byla definovaná hodnota 0, aby mohly být takové vzorky zařazeny do nějaké kategorie pro budoucí hodnocení predikce. Nulová hodnota byla určena celkem pro 12 vzorků s DC (%) v rozsahu od 70 do 90 % (obr.24).



Obr. 24 Vzorky s nulovým počtem vln

To však neznamená, že ostatní vzorky s hodnotami DC v tomto rozmezí měly vždy nízký počet vln, naopak se zde vyskytl počet vln 6,7,8. To potvrzuje skutečnost, že koeficient splývavosti není vždy jednoznačně podpořen počtem vln. Proto je návrhem pro budoucí šetření zahrnutí dalších parametrů splývavosti, které jsou uvedeny v rešeršní části.

Co se týká chování vln a jejich proměnlivosti u stejných tkanin měřených na 3 vzorcích po sobě, vždy vzniká určité posunutí vln. U některých vzorků více patrné, u jiných méně. Dobře splývavé vzorky mají tendenci vytvářet vlny v podobném, dobře rozlišitelném uspořádání. U málo splývavých vzorků téměř kruhového tvaru nelze jasně posoudit rozložení vln. Na obr. 25 lze vidět rozložení a dominanci vln pro splývavé a téměř nesplývavé vzorky.



**Obr. 25 Rozložení vln - vzorek 1,2,3,4**

Ačkoli se tato metoda hledání vln prokázala úspěšná u dobře splývavých materiálů s koeficientem splývavosti do hodnoty zhruba 50%, pro ostatní vzorky nebyly výsledky uspokojivé. Existují jiné metody pro spolehlivější určení počtu vln např. s použitím nástroje MATLAB Signal Processing Toolbox. Toto hodnocení je ovšem mnohem složitější a v rámci této diplomové práce bohužel na podrobnější zkoumání vln nezbyl dostatek prostoru.

#### **4.4. Predikce splývavosti pomocí neuronových sítí**

Jak již bylo zmíněno, vztah mezi mechanickými vlastnostmi tkanin a splývavostí je silně nelineární. Proto jsou pro experiment zvoleny neuronové sítě, které mají schopnost učit se z příkladů a zachytit nelineární závislosti.

Použití neuronových sítí bylo řešeno dvěma způsoby. Pomocí softwarového programu QC Expert společnosti TriLobyte® a pomocí balíčku MATLAB Neural Network Toolbox nabízející grafické rozhraní a snadnou analýzu natrénovaných dat.

Testování a analýza správnosti navržených modelů pro predikci probíhala při různém nastavení skrytých vrstev a počtu neuronů v jednotlivých vrstvách, po různě zvolené skupiny dat pro trénování, a také při obměňování dalších parametrů sítě.

Postup aplikace ANN:

1. Výběr vhodných prediktorů – nezávisle proměnných, o kterých se domníváme, že mohou mít vliv na zvolené závisle proměnné.
2. Předzpracování (standardizace) dat – transformace vstupních dat na požadované intervaly. Provádí se z důvodu rozdílných jednotek jednotlivých proměnných, to může způsobovat, že se určité znaky jeví jako dominující a mohou tak negativně ovlivnit průběh trénování a vyhodnocování sítě.

$$x'_{i,j} = \frac{x_{ij} - \bar{x}_j}{s_j}$$

Takto standardizovaná data mají nyní střední hodnotu rovnu 0 rozptyl 1.

3. Rozdělení dat do skupin – pro experiment je potřeba mít tři sady dat trénovací, validační a testovací. To umožní posoudit kvalitu predikční schopnosti navržené sítě v průběhu učení na základě tzv. cross-validace. Validace je založena na principu použití k učení neuronové sítě určitou část dat (trénovací), volí se kolem 60-70%. Validací množina slouží ke sledování chyby během procesu trénování, chyba roste jen do určitého počtu iterací, pak se trénování zastaví, nedojde tak k přeučení sítě (overfitting). Testovací množina se použije k testování schopnosti generalizace celého navrženého modelu. Jedná se o nezávislá data, která se dosud v síti vyskytla, ačkoli se nachází uvnitř intervalu trénovacích hodnot, a tak může být posouzena skutečná predikční schopnost celé sítě.
4. Výběr odpovídající architektury sítě – počet skrytých vrstev, počet neuronů v těchto vrstvách. Síť s jednou skrytou vrstvou neuronů se obvykle používají v případech, že předpokládáme lineární nebo slabě nelineární vztahy. Dvouvrstvé sítě modelují silně nelineární vztahy a ve většině případů jsou dostačující. Vícevrstvé sítě jsou složité a bývají přeúčeny, které lze těžko optimalizovat.
5. Vyhodnocení predikce – měření tzv. predikční chybou, která vyjadřuje míru nepřesnosti mezi predikovaným a originálním výstupem.

### **Vstupní data**

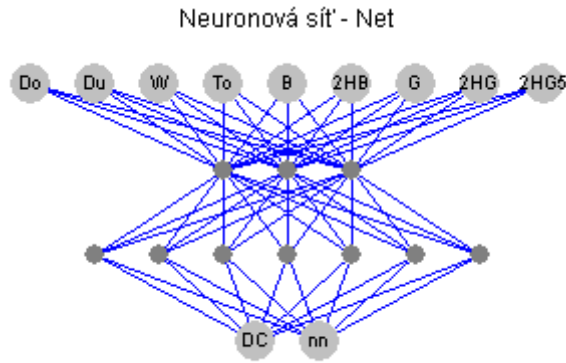
Vstupem do neuronových sítí jsou zmíněné vybrané strukturní parametry a mechanické vlastnosti spolu s plošnou hmotností tkanin. Výběr těchto parametrů byl dán na základě provedených výzkumů mnoha autorů. V tabulce (2) jsou uvedeny základní statistické charakteristiky ke všem vzorkům.

Tab. 2 Vstupní parametry pro neuronovou síť

Symbol	Vlastnost tkaniny	Průměr	Směrodatná odchylka	Min.	Max.
$D_o$	Dostava osnovy	39,69	15,72	16	96
$D_u$	Dostava útku	28,15	12,36	14	66
$W$	Plošná hmotnost	0,15	0,054	0,05	0,31
$T_o$	Tloušťka	0,60	0,25	0,13	1,49
$B$	Ohybová tuhost	0,14	0,13	0,02	0,17
2HB	Ohybová hystereze	0,14	0,20	0,01	1,72
$G$	Smyková tuhost	1,30	1,52	0,18	10,15
2HG	Smyková hystereze $0,5^\circ$	2,72	4,02	0,20	26,64
2HG5	Smyková hystereze $5^\circ$	4,1	4,92	0,27	38,44

#### 4.4.1. QC Expert


Prvním použitým softwarem v této práci je QC Expert od společnosti TriloByte®, který nabízí intuitivní ovládání, pro zadání a výpočty sítě slouží dialogová okna. Po výběru nejvhodnějšího jsou k dispozici výsledky s různými grafy. Výhodou tohoto software je možnost nastavení automatické transformace dat, což umožní normalizovat data do požadovaného rozsahu hodnot. Používá lineární transformaci (min – max) a nelineární transformaci (soft – max). Optimalizační procedura QCExpertu využívá k učení Gauss-Newtonovské algoritmy. [23]



**Obr. 26 Grafické znázornění sítě**

Nejprve byla data rozdělena na trénovací, validační a testovací skupiny. Dále byla zvolena architektura sítě. Zadával se počet skrytých vrstev, počet neuronů, počet iterací, procentuální podíl dat pro učení, kritéria moment a rychlost učení. Zpočátku probíhalo veškeré nastavování na základě metody 'pokus omyl'. Bylo potřeba vyzkoušet mnoho kombinací a vytvořit mnoho různých modelů, aby mohla být vyzkoušena nejlepší stanoviště.

Během trénování sítě se sleduje pokles chybové křivky (obr. 27) pro učící data (modrá křivka) a validační data (zelená křivka). Graf učící procesu znázorňuje pokles součtu čtverců rozdílů predikce a skutečných hodnot závisle proměnné v závislosti na počtu iterací. Po tréninku se zobrazí vypočítaná střední a maximální chyba pro obě tyto skupiny dat.

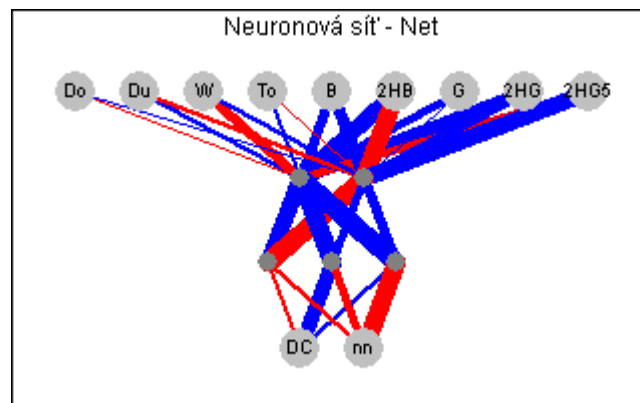


**Obr. 27 Pokles chybové funkce**

Optimalizace začíná s náhodnými hodnotami vah, proto se vyplatí spustit ji vícekrát. Optimalizační algoritmus se snaží najít takové nastavení vah, aby síť předpovídala hodnoty v co nejlepším souladu se zadanými závisle proměnnými. Pokud se nám zdá vypočítaná střední a maximální chyba dostačující, můžeme ještě posoudit predikci známých dat, kterou lze vypočítat v průběhu tohoto učení.

Po zvolení nejvhodnějšího modelu je potřeba posoudit kvalitu predikce celé sítě, tedy i pro neznámá data. K tomu slouží zmíněná testovací data. Co se týká vlivu změn jednotlivých údajů při sestavování sítě, největší vliv měl počet skrytých vrstev a počet neuronů. Změna parametrů jako počet iterací, moment a učící rychlost měla na trénování sítě také velký vliv.

QC Expert zobrazuje pro každý uložený model grafické vyjádření architektury sítě a jejich vah. Tloušťka synapsí znázorňuje absolutní velikost odpovídající váhy a množství informace protékající mezi dvěma neurony. Také se podle ní dá usuzovat významnost nezávisle proměnných na kvalitu predikce jednotlivých závisle proměnných. Červená barva znázorňuje zápornou váhu a modrá barva kladnou váhu. [23]



Obr. 28 Znázornění synapsí

Pro určení nejlepších parametrů sítě bylo vytvořeno mnoho modelů. Pro pozorování schopnosti predikce byly vytvořeny 3 modely. První model zahrnoval všechny vzorky, druhý model sestával pouze z lehkých spíše splývavých materiálů a třetí model tvořily pouze režné tkaniny. V následujících odstavcích je porovnání a diskuze ke všem navrženým modelům.

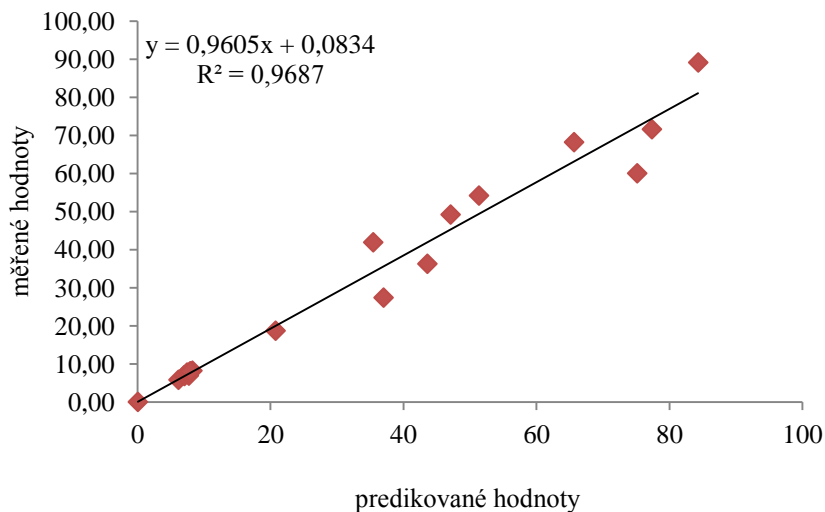
Úspěšnost celkové schopnosti predikce navržených modelů byla hodnocena na základě reziduí mezi skutečnou a predikovanou hodnotou. Byla hodnocena predikční schopnost celková a zvláště pro DC (%) a počet vln. Byl proveden výpočet koeficientu determinace ( $R^2$ ) a průměrné absolutní procentuální chyby (MAPE).

### **Model 1**

Pro model 1 byla použita celá databáze tkanin, tedy v celém rozsahu strukturních a mechanických vlastností i splývavosti. Cílem bylo tedy predikovat splývavost pro všechny možné tkaniny. Data byla rozdělena na dvě skupiny 90% a 10%. Skupina 1 tvoří 91 dat, a je dále rozdělena na podskupinu 1a – trénovací množina (80% ze skupiny 1) a 1b – validační množina (20 % ze skupiny 1). Skupinu 2 (10% z celkových dat) tvoří testovací množina. Je důležité, aby data v testovací množině reprezentovala všechna data z trénovací množiny, data jsou proto v celém rozsahu DC, aby mohla být zahrnuta splývavost všech úrovní.

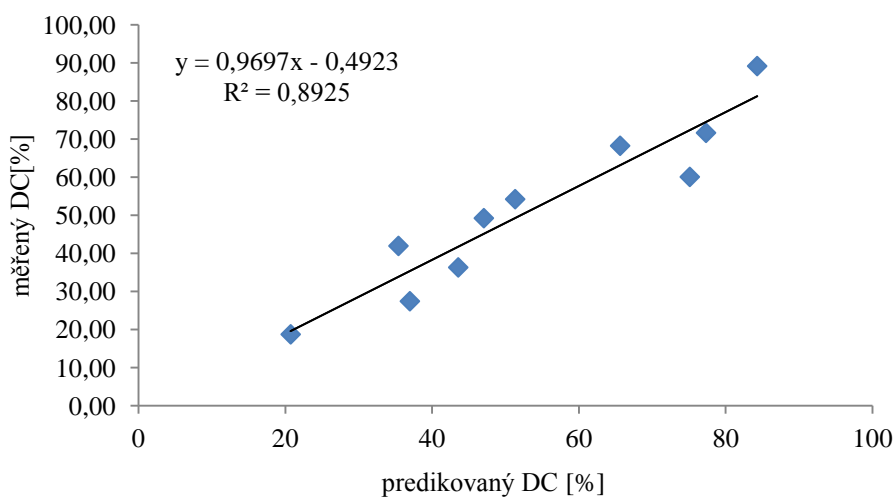
Jedna skrytá vrstva se i při různých kombinacích ostatních parametrů sítě u tohoto modelu projevila jako nedostačující. Síť topologie 9-3-4-2 se ukázala jako nejuspěšnější, tedy počet neuronů v první skryté vrstvě je 3 a ve druhé skryté vrstvě 4. Každému vstupnímu a výstupnímu parametru je tedy přiřazen 1 neuron. Méně uspokojivé výsledky přinášela také síť typu 9-2-3-2 a 9-4-5-2. Počet iterací byl nastaven na 10000, hodnota momentu 0,9 a hodnota pro rychlost učení 0,1. Dosažená střední chyba pro učící data byla 0,0036 a maximální chyba pro tyto data 0,0177. Střední chyba pro validační data 0,0039 a maximální chyba 0,0099.



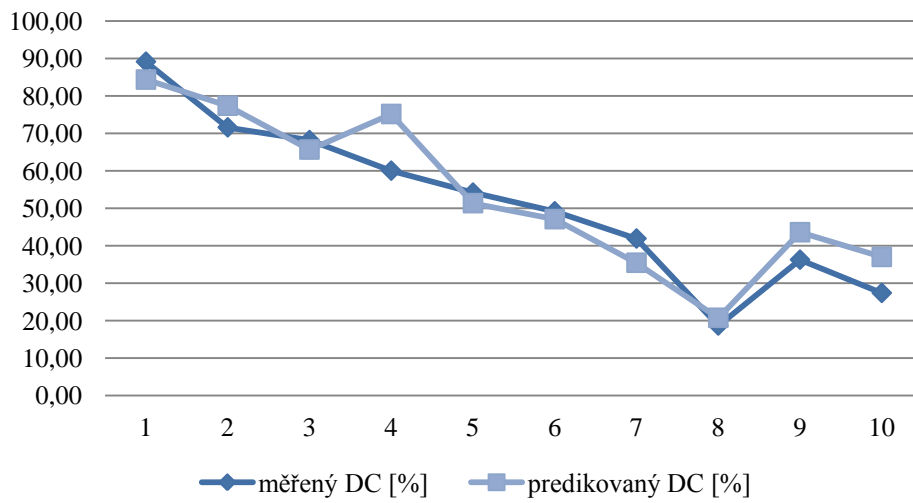


**Obr.29 Graf - koeficient determinace pro Model 1**

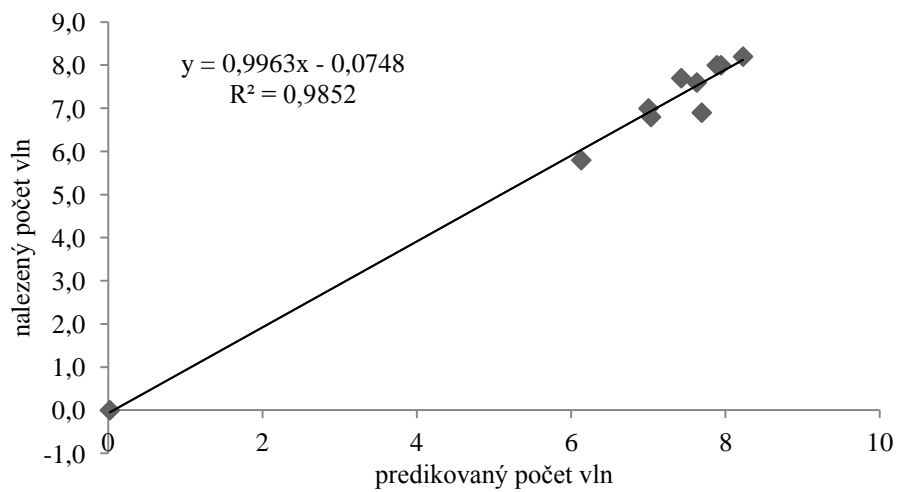
Koeficient determinace vyjádřený v procentech dosáhl v tomto případě 97 %. Průměrná absolutní chyba predikce MAPE je přibližně 0,0804. Výsledky pro predikovaný DC jsou znázorněné na obr. 30.



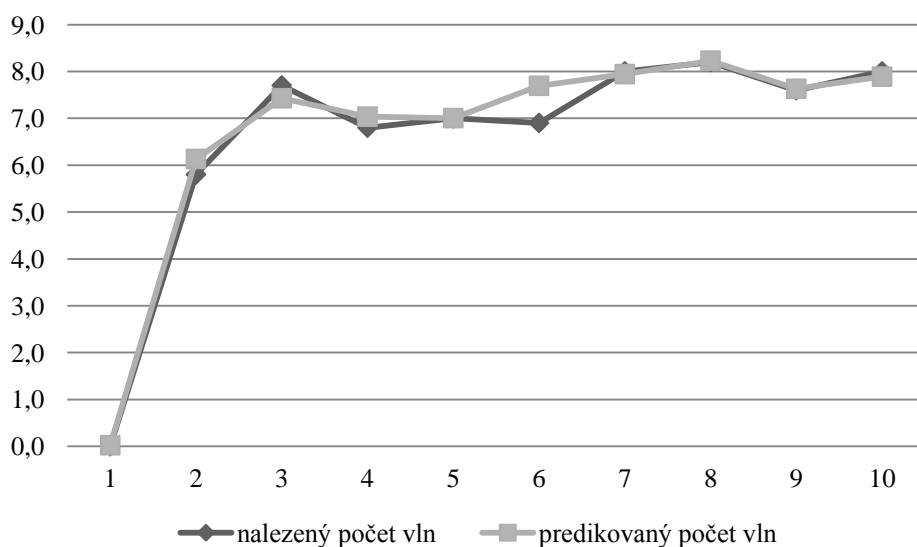
**Obr. 30 Model 1 – koeficient determinace pro DC**



**Obr. 31 Model 1 - predikovaný a měřený DC**



**Obr. 32 Model 1 – koeficient determinace pro počet vln**

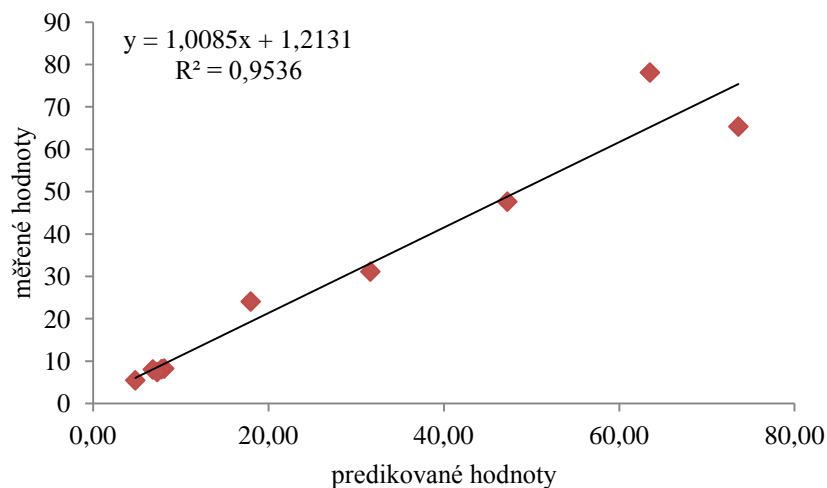


**Obr. 33 Model 2 - predikovaný a měřený počet vln**

## Model 2


Pro tento model byly vybrány lehké až střední tkaniny o plošné hmotnosti v rozmezí 100 až 240 g/m<sup>2</sup> a tloušťkou do 0,7 mm. Jedná se o splývavé materiály s koeficientem splývavosti do 50 %. Svými vlastnostmi jsou vhodné pro použití jako dámské letní šatovky. Soubor tvoří celkem 51 tkanin. Z toho je 5 tkanin zvoleno pro nezávislý test predikce sítě. Zbýlých 46 vzorků je rozděleno na trénovací skupinu (80% dat) a validační skupinu (20% dat).

Model s nejlepšími výsledky je typu 9-2-3-2. Tedy 2 neurony v první skryté vrstvě a 3 neurony ve druhé skryté vrstvě. Počet iterací pro ukončení optimalizace je 3000. Moment je snížen na hodnotu 0,5 a rychlost učení zvýšena na 0,2. Během tréninku byla dosažena pro učící data střední chyba 0,0123 a maximální chyba 0,0743. Pro validační data je střední chyba 0,0245 a maximální chyba 0,0456. Regresní rabat je v porovnání s předešlým modelem nižší.




**Obr. 34 Model 2 - koeficient determinace**


Myšlenkou při výběru tohoto modelu bylo, že výběr menší skupiny dat s podobnými charakteristikami materiálů a splývavostí v užším rozsahu, by mohl zlepšit predikci sítě. I přes opakované trénování a různé kombinace parametrů sítě však nebylo dosaženo lepších výsledků predikce než u Modelu 1. MAPE je po zaokrouhlení 0,1066.




**Obr. 35 Model 2 – koeficient determinace pro DC**



**Obr. 36 Model 2 - predikovaný a měřený DC**



**Obr. 36 Model 2 – koeficient determinace pro počet vln**



**Obr. 37 Model 2 - predikovaný a nalezený počet vln**


Na druhou stranu mohla být predikce zhoršena z důvodu menšího počtu celkových dat. Proto byl navržen Model 3 ještě v užším rozsahu tkanin, aby tuto domněnku potvrdil nebo vyvrátil.

### **Model 3**

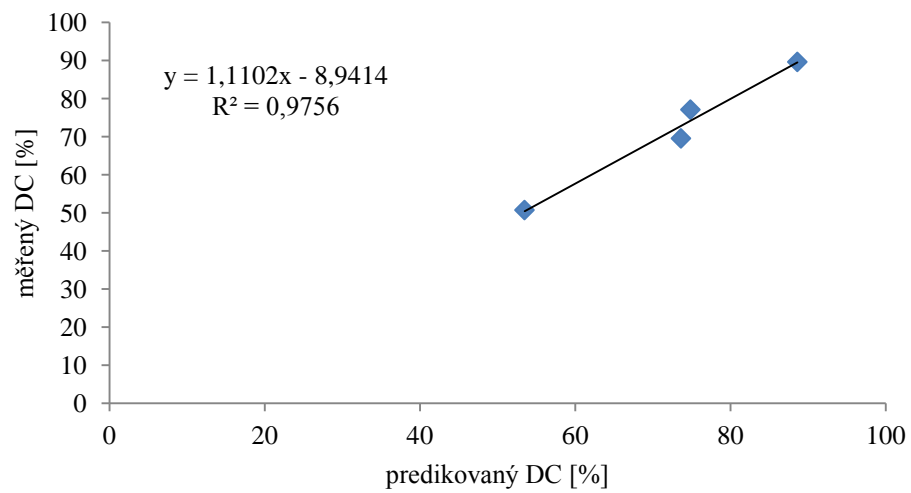
Pro tento model byly vybrány pouze režné tkaniny ze 100 % bavlny bez dalších úprav. Soubor celkem tvoří 23 dat. Z toho 19 dat je rozděleno na trénovací a validační soubor v poměru opět 80% a 20 %, 4 tkaniny jsou použity pro závěrečné testování.

Zde přinesla nejlepší výsledky síť s jednou skrytou vrstvou typologie 9-7-2, tedy 7 skrytých neuronů. Počet iterací stanoven na 3000, moment má hodnotu 0,8 a rychlost učení 0,2. Pro učicí soubor byla dosažena střední chyba 0,0001 a maximální chyba 0,0123. MAPE představuje 0,0775. To je zlepšení oproti předchozím modelům.


Koeficient determinace dosáhl hodnoty 1. Střední kvadratická chyba predikce je 0,12 a střední absolutní chyba predikce 0,213. Je tedy vyvrácena domněnka, že menší soubor dat negativně ovlivňuje výsledky predikce, pokud jsou data výhodně zvolena.




**Obr. 38 Model 3 - koeficient determinace**



**Obr. 39 Model 3 - koeficient determinace pro DC**




**Obr. 40 Model 3 - predikovaný a měřený DC**



**Obr. 41 Model 3 - koeficient determinace pro počet vln**





**Obr. 42 Model 3 - predikovaný a nalezený počet vln**


Ačkoli bylo realizováno mnoho modelů neuronových sítí hledající optimální nastavení parametrů pro predikci a došlo i k určitému zlepšení, i tak ještě může být průměrná absolutní chyba predikce snížena. V procentuálním vyjádření je chyba MAPE nejnižší pro Model 3 představující rezné tkaniny, a to 7,75 %. Při dalším testování v QC Expertu by bylo vhodné ještě podrobnější zkoumání vlivných parametrů sítě na predikci a odzkoušení desítky jiných modelů.

#### 4.4.2. MATLAB Neural Network Toolbox

Jako druhý nástroj pro vytvoření, naučení a simulaci neuronových sítí je v práci použit MATLAB, který má implementované algoritmy pro jejich řešení. Neural Network Toolbox (*nntool*) nabízí přístupné uživatelské rozhraní pro nastavení sítě a parametrů trénování. Nejprve se importují vstupní data (*input*), výstupní data (*target*) a vzorová data (pro pozdější výpočet predikce). Při sestavování sítě se volí typ sítě, trénovací funkce, přenosová funkce, počet skrytých vrstev a počet neuronů.

Byla zvolena síť backpropagation se zpětným šířením chyby. Pro trénink sítě byl vybrán Levenberg-Marquardtův algoritmus (*trainlm*). Jedná se o jeden z nejpoužívanějších a nejrychlejších backpropagation algoritmů, ve kterém je možné

nastavit více než 10 parametrů (max. počet iterací, max. počet chyb při validaci, cílový výkon sítě (*goal*), učící konstantu, momentum, atd.). Struktura sítě byla nastavena jako dvouvrstvá, obsahující jednu skrytou a jednu výstupní vrstvu. Jako přenosová funkce byla zvolena funkce hyperbolický tangens (*tansig*). Na výstupu sítě je použita klasická lineární funkce (*purelin*). Konečné nastavení neuronové sítě bylo získáno postupnými úpravami topologie sítě, nastavováním tréninkových prvků, volbou vhodných přenosových funkcí, a především hledáním vhodného počtu neuronů.



Obr. 43 Znázornění možné topologie neuronové sítě


Množina dat je v MATLABu rozdělena náhodným výběrem (*dividerand*) na 3 skupiny. K natrénování sítě připadá 70 % dat. Validáčnící data představují 15 % a kontrolují generalizaci sítě, v případě, že se model nevylepší, umožní trénink zastavit. Dalších 15 % dat tvoří testovací soubor k nezávislému testování sítě. Proto jsem pro návrh modelu použila 90% dat a pro 10% dat byla vypočtena predikce.

Testování se ukončí na základě validation stop, díky které se kontroluje přetrénování sítě. Jedná se o ukončení tréninku vyhodnocené počtem po sobě jdoucích epoch (iterací) se zhoršujícím se výkonem sítě pro validační množinu. Defaultně je nastaveno 6 epoch, bylo experimentováno s počtem v rozmezí 6-30.

V průběhu je vypočtena hodnota chyby (Mean Square Error) hodnotící neshodu mezi výstupem ze sítě a požadovaným výstupem. Graf ukazuje pokles chybové křivky pro všechny skupiny dat. Také se pozoruje, zda nedošlo k přetrénování sítě. Pokud chyba u trénovací, validační i testovací sady postupně klesá a dále už se nijak výrazně nezvyšuje, k přetrénování sítě nedošlo.

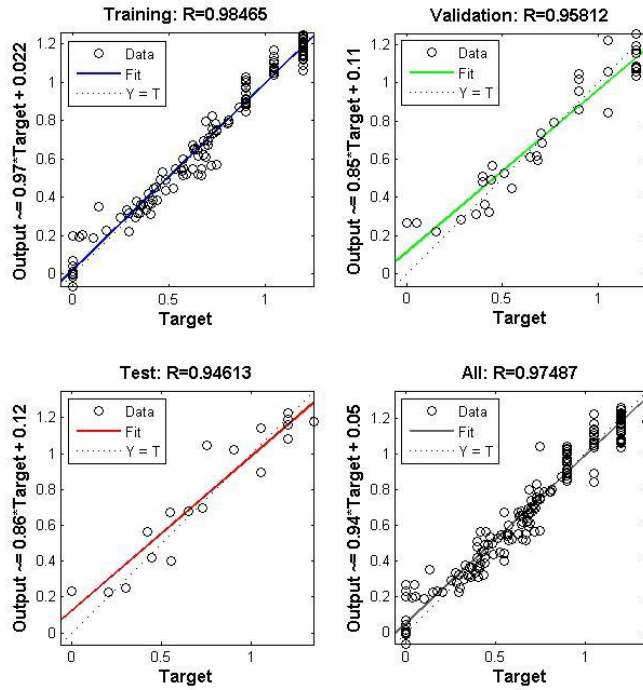
## Model 1

Tento soubor tvoří stejné tkaniny jako v případě testování v QCExpertu. Chyba sítě se měnila v závislosti na počtu neuronů ve skryté vrstvě. Uspokojivé výsledky sítě byly s počtem neuronů 20 a 50 a nejlepší vybraný model tvořilo 35 neuronů.




Obr. 44 Model 1 - pokles chyby

Graf na obr. 44 znázorňuje snížení chybové funkce na 4 iteraci. Na obr. lze vidět podíl závislé proměnné vysvětlený regresním modelem. Po testování a výběru nejvhodnějších sítí se přešlo k samotné predikci neznámých hodnot, které síť dosud neviděla. Graf na obr. 45 znázorňuje výsledky predikci vybraných hodnot. Vypočítaná chyba MAPE je 0,0775.




Obr. 45 Model 1 - regrese



Obr. 46 Model 3 - porovnání predikovaných a měřených hodnot

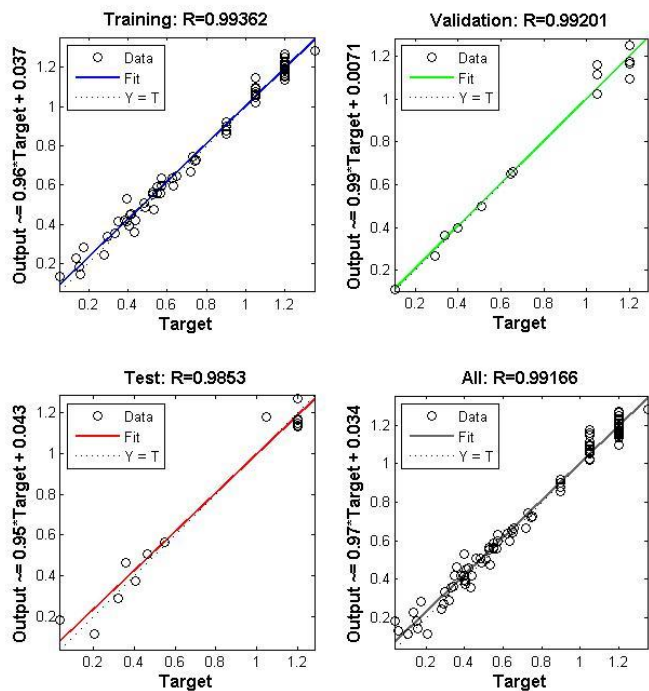
## Model 2

Pro tento model byl optimální počet neuronů 10. Dobré výsledky přinášely také sítě se 7 a 13 neurony. Počet iterací 7 a průběh chybové funkce je znázorněn na obr. 47.




Obr. 47 Model 2 - pokles chyby

Korelační koeficient pro všechny množiny dosahuje 0,99. Následně byla opět provedena predikce pro nová data. Výsledná chyba MAPE je 0,0715.




Obr. 48 Model 2 - regrese



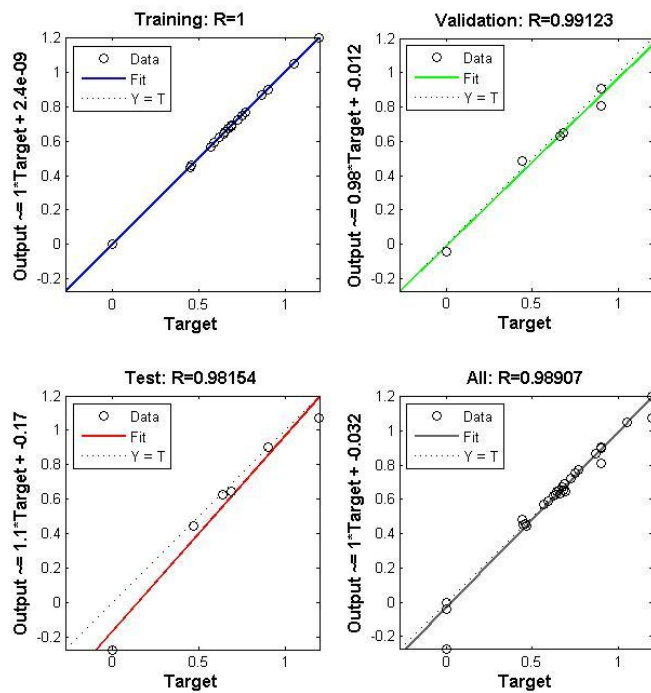
Obr. 49 Model 2 - porovnání predikovaných naměřených hodnot

### Model 3

Model rezných tkanin byl testován pro 5, 7 a 10 neuronů. Nejlepších výsledků bylo dosaženo s 5 neurony ve skryté vrstvě.




Obr. 50 Model 3 - pokles chyby



Obr. 51 Model 3 - regrese

Vypočítaná chyba predikce MAPE je 0,048. Tedy ze všech testovaných souborů nejnižší.



**Obr. 52 Model 3 - porovnání predikovaných a měřených hodnot**

Ze všech uvedených ukázek vyplývá, že největší vliv na průběh chybové křivky a korelační koeficient má počet neuronů. V tab. 3 je znázorněn jeho vliv na tyto ukazatele kvality predikčních modelů pro všechny tři soubory tkanin. U prvního souboru zahrnujícího všechna data to bylo 35 neuronů, u druhého souboru vybraných lehkých splývacích tkanin 10 neuronů a na závěr u třetího souboru režných tkanin pouze 5 neuronů. Tudíž zde platí, že se zvyšujícím se počtem dat je také potřeba více neuronů. Pro stanovení počtu skrytých vrstev a počtu neuronů neexistuje žádný zaručený postup, proto se i v této práci vycházelo z pokusů. I když byla optimalizace u každého modelu vždy spuštěna několikrát (30 krát), mohlo se jednat také o náhodu, že zrovna algoritmus sítě vybral nejlepší postavení vah. Z toho důvodu by bylo v dalším pátrání vhodné vygenerovat nebo navrhnout algoritmus s konfigurací vedoucí k lepší predikci. Pomocí software MATLAB byla dosažena chyba MAPE v rozsahu 4,8 % až 7,75%. Oproti předchozímu testování v QC Expert se sice jedná určité zlepšení, ale stále se jedná o vyšší chybu.



**Tab. 3 Vliv počtu na neuronů na úspěšnost trénování**

	počet neuronů	MSE	R			
			training	validation	test	all
<b>Model 1</b>						
1a	<b>20</b>	<b>0,008</b>	<b>0,974</b>	<b>0,936</b>	<b>0,845</b>	<b>0,945</b>
1b	35	0,012	0,985	0,958	0,946	0,975
1c	<b>50</b>	<b>0,02</b>	<b>0,994</b>	<b>0,955</b>	<b>0,909</b>	<b>0,974</b>
<b>Model2</b>						
2a	<b>7</b>	<b>0,01</b>	<b>0,992</b>	<b>0,981</b>	<b>0,981</b>	<b>0,987</b>
2b	10	0,002	0,994	0,992	0,985	0,992
2c	<b>13</b>	<b>0,055</b>	<b>0,943</b>	<b>0,926</b>	<b>0,833</b>	<b>0,921</b>
<b>Model3</b>						
3a	5	0,002	1	0,991	0,982	0,989
3b	<b>7</b>	<b>0,014</b>	<b>0,983</b>	<b>0,942</b>	<b>0,934</b>	<b>0,969</b>
3c	<b>10</b>	<b>0,019</b>	<b>0,936</b>	<b>0,94</b>	<b>0,935</b>	<b>0,937</b>

## Závěr

Cílem diplomové práce bylo analyzovat vliv strukturních parametrů a mechanických vlastností, které mají největší vliv na splývavost tkanin. Poté se pokusit na základě těchto vybraných parametrů splývavost predikovat pomocí vhodných nástrojů.

V teoretické části byla popsána splývavost, metody jejího měření a nástroje používané pro hodnocení. Protože byla v této práci použita obrazová analýza, je jí věnováno dostatek prostoru. Dále byl proveden průzkum v oblasti hodnocení splývacích parametrů právě pomocí obrazové analýzy, dále v oblasti zkoumání parametrů ovlivňujících splývavost, a také v oblasti predikce pomocí neuronových sítí.

V experimentální části byly na vybraných vzorcích tkanin zjišťovány strukturní parametry (dostava osnovy a útku, vazba), mechanické vlastnosti a plošná hmotnost. Dále byla na kruhových vzorcích naměřena splývavost pomocí zařízení založeném na

principu Cusickova přístroje spolu s digitální kamerou pro zachycení splývavých profilů, za účelem dalšího zpracování v počítačovém softwaru Nis Elements a MATLAB. Zde byly vypočítány plochy pro získání koeficientu splývavosti DC (%) a dále byl zjišťován počet vln. Ukázalo se, že největší problém je s určením počtu vln pro málo splývavé vzorky složitých tvarů. Proto je toto zkoumání zčásti stále subjektivní.

V další části byly navrženy a testovány predikční modely na principech a teorii neuronových sítí. Neuronové sítě jsou v této oblasti velmi populární a výzkumy ukazují dosažení velmi dobrých výsledků. Cílem bylo predikovat splývavé parametry jako DC (%) a počet vln. Pro návrh a implementaci neuronových sítí byl použit Softwarový program QC Expert a MATLAB Neural Network Toolbox. V této práci je porovnáváno několik těchto prediktivních modelů a několik přístupů při nastavování sítě.

Byly sestaveny tři hlavní modely. První model zahrnoval data všech vzorků tkanin, druhý model tvořily pouze lehké šatové tkaniny se splývavostí do 50 % a třetí model sestával pouze z rezných bavlněných tkanin. Tyto modely byly mezi sebou porovnávány a hodnoceny. Koeficient determinace byl vypočítán za účelem posouzení lineární vazby mezi predikovaným a měřeným souborem hodnot. Pro každý model byla vypočtena průměrná absolutní chyba predikce MAPE.

Chyba a úspěšnost při tréninku se měnila při obojím testování především se změnou počtu skrytých vrstev a počtu neuronů. Pro MATLAB byla zvolena síť backpropagation a přenosová funkce hyperbolický tangens, která už po pár testování projevovala lepší naučenost. Pomocí softwaru QC Expert bylo dosaženo nejnižší chyby predikce MAPE pro soubor rezných tkanin, v procentuálním vyjádření 7,75%. U Modelu1 testovaného pro všechny tkaniny byla chyba 8,04% a pro Model2 vyšla nejvyšší chyba 10,66%. Celkově bylo nejnižší chyby dosaženo v toolboxu MATLAB, opět pro rezné tkaniny, a to 4,8%. U Modelu1 byla chyba 7,75 % a pro Model2 7,15%. Tentokrát byla tedy nejvyšší soubor všech dat. Výsledky predikce dosahují stále dost vysoké chyby a mohou být dále zlepšovány, naskýtá se prostor pro použití např. analýzy hlavních komponent (PCA) nebo další úpravy vstupních dat.

Díky této práci jsem získala základní znalosti v oblasti predikce pomocí neuronových sítí. Je však nutno konstatovat, že se jedná o experimentálně náročnou práci a úspěšnost výsledků je značně závislá na zkušenostech.

## Literatura

- [1] HLOCH, S., SODOMKA, L., VALÍČEK, J., RADVANSKÁ, A.: *Struktura, vlastnosti, diagnostika a technologie textilií*. 1. vyd. Prešov: Vydavatelství Michala Vaška, 2006. ISBN 80-8073-668-5
- [2] STANĚK, J.: *Nauka o textilních materiálech: díl I, část 4, Vlastnosti délkových a plošných textilií*. Liberec: VŠST 1988
- [3] HES, L., SLUKA, P.: *Úvod do komfortu textilií*. 1. vyd. Technická univerzita v Liberci, 2005. ISBN 80-7083-926-0
- [4] KOVAČIČ, V.: *Textilní zkušebnictví 2*. 1. vyd. Technická univerzita v Liberci, 2004. ISBN 80-7083-825-6
- [5] ČSN 80 0835. *Zkoušení splývavosti plošných textilií průmětem*. 1971
- [6] INTERNÍ NORMA 23-202-01/01. *Splývavost tkanin. Ohyb přes ostrý roh*. Liberec, 2003.
- [7] TOKMAK, O., BERKALP., O. B., GERSAK, J.: *Investigation of the Mechanics and Performance of Woven Fabrics Using Objective Evaluation Techniques. Part I: The Relationship Between FAST, KES-F and Cusick's Drape-Meter Parameters*. FIBRES & TEXTILES in Eastern Europe 2010, Vol. 18, No. 2(79) pp. 55-59.
- [8] LOJEN, D. Ž., JEVŠNIK, S.: *Some Aspects of Fabric Drape*. FIBRES & TEXTILES in Eastern Europe October/December 2007, Vol. 15, No. 4 (63).
- [9] KENKARE, N., MAY-PLUMLEE, T.: *Evaluation of drape characteristics in fabrics*. International Journal of Clothing Science and Technology Vol. 17 No. 2, 2005 pp. 109-123.
- [10] LO, W. M., J. L. HU, L. K. LI. *Modeling a Fabric Drape Profile*. Textile Research Journal. 2002, 72(5), s. 454-463.
- [11] Abdin Y, Taha I, El-Sabbagh A, Ebeid S.. Description of draping behavior of woven fabrics over single curvatures by image processing and simulation techniques. Elsevier. 2013; 45:792-799.

- [12] *Obrazová analýza*. [elektronická skripta]. [cit. 2014-02-26]. Dostupné na Internetu: <http://www.kod.tul.cz/predmety/STE/cviceni/OBRAZOV%C3%81%20ANAL%C3%9DZA1.pdf>.
- [13] AL-GAADI, B., GOKTEPE, F., HALÁSZ, M.: *A new method in fabric drape measurement and analysis of the drape formativ process*. Textile Research Journal 2012, 82(5) 502-512.
- [14] GLOMBÍKOVÁ, V.: *THE 3D DRAPE SCANNER*. Strutex, 15th International Conference. TU Liberec, December 2008.
- [15] GLOMBÍKOVÁ, V., HALASOVÁ, A., PROVAZNÍKOVÁ, S.: *CONTRIBUTION TO DRAPE EVALUATION BY MEANS OF 3D DRAPE SCANNER AND FFT*. Strutex, 14th International Conference. TU Liberec, November 2007.
- [16] *3D laserové skenování – teorie*. [elektronická skripta]. [cit. 2014-03-04]. Dostupné na Internetu: <http://lfgm.fsv.cvut.cz/data/vvt/s1/laserteorie3d.pdf>.
- [17] *Zpracovatelské a užité vlastnosti oděvních materiálů. Splývavost*. [elektronická skripta]. [cit. 2014-05-12]. Dostupné na Internetu: [http://www.kod.tul.cz/predmety/OM/prednasky/OM\\_prednaska5\\_2013.pdf](http://www.kod.tul.cz/predmety/OM/prednasky/OM_prednaska5_2013.pdf).
- [18] GLOMBÍKOVÁ, V., HALASOVÁ, A., VÍTOVÁ, J.: *Vplyv tuhosti a délky previsu na splývavost'*. Strutex, 8. národní konference. TU v Liberci, 2001.
- [19] *Vysocefunkční textilie. Využití struktury a vlastností tkanin a pletenin pro zajištění specifických funkcí textilního materiálu*. [elektronická skripta]. [cit. 2014-05-12]. Dostupné na Internetu: [http://www.ft.tul.cz/depart/kde/studium/predmetyPRILOHY/5\\_PT0.pdf](http://www.ft.tul.cz/depart/kde/studium/predmetyPRILOHY/5_PT0.pdf).
- [20] KOLČAVOVÁ SIRKOVÁ, B.: *Konstrukce a vlastnosti tkanin*. [elektronická skripta]. [cit. 2014-05-22]. Dostupné na Internetu: <http://www.ktt.tul.cz/>.

- [21] NOFITOSKA, M., DEMBOSKI, G., CARVALHO, M.A.F.: *Effect of fabric structure variation on garment aesthetic properties*. TEKSTÍL ve KONFEKSIYON 2012.
- [22] PATTANAYAK, A.K., LUXIMON, A., KHANDUAL, A.: *Prediction of drape profile of cotton woven fabrics using artificial neural network and multiple regression method*. Textile Research Journal, 2010. 81 (6) 559-566
- [23] TriloByte Statistical Academy. Studijní materiály. *Neuronová síť*. [cit. 2014-06-07]. Dostupné na Internetu: <http://www.trilobyte.cz/Informace/Studijni-materialy.html>.
- [24] VOLNÁ, E. *Neuronové sítě I*. Ostrava, 2008. Studijní materiály pro distanční kurz. Ostravská univerzita v Ostravě.
- [25] STYLIOS, G. K. N., POWELL, J.: *Engineering the drapeability of textile fabrics*. International Journal of Clothing Science and Technology, 15 (3/4), 211-217, 2003.
- [26] LAM, A., RAHEJA, A., GOVINDRAJ, M.: *Neural network models for fabric drape prediction*, 2004 IEEE International Joint Conference on Neural Networks, Australia, IEEE, 25-29 July 2004. 2925-2929.
- [27] GLOMBÍKOVÁ, V., KŮS, Z., HALASOVÁ, A.: *Usage of artificial neural network for prediction of fabric drape*. Strutex, 12th International Conference. TU Liberec, November 2005.
- [28] MILITKÝ, J., KŘEMENÁKOVÁ, D., KŮS, Z.: *Selected topics of textile and material science. Textile fabrics. Fabric drape prediction*. Technical University of Liberec. Liberec, Plzeň 2011. ISBN 978-80-261-0062-1.
- [29] JEDDA, H., GHITH, A., SAKLI, F.: *Prediction of fabric drape using the FAST system*. Journal of the Textile Institute 98 (3), 219-225, 2007.
- [30] HEDFI, H., GHITH, A., SALAH, H.B.H.: *Intelligent Evaluation of Fabrics' Elastic Properties from Simulated Drape Test*. IJCTA, July-August 2011. Vol 2 (4), 741-749.

- [31] JIANG, Y., CUI, M., HU, J.: *Computer Generation of 3D Textile Draping Simulation*. Elsevier, AASRI Conference on Modeling, Identification and Control, 2012. 661-666.
- [32] CODE PROJECT. *Neural Network for Beginners*. [cit. 2014-06-12 ] Dostupné na Internetu: <http://www.codeproject.com/Articles/16419/AI-Neural-Network-for-beginners-Part-of>).
- [33] *Neural network*. [cit. 2014-10-27 ] Dostupné na Internetu: [https://www.byclb.com/TR/Tutorials/neural\\_networks/ch7\\_1.htm](https://www.byclb.com/TR/Tutorials/neural_networks/ch7_1.htm).
- [34] OBITKO, M.: *Prediction using neural networks*. [online]. [cit. 2014-11-15] Dostupné na Internetu: <http://obitko.com/tutorials/neural-network-prediction/>.
- [35] Laboratoř zpracování řeči a analýzy signálu. Výuka ČVUT. [cit. 2014-11-19] Dostupné na Internetu: <http://noel.feld.cvut.cz/vyu/scs/prezentace2003/ZISC/rbf/rbf12.htm>.
- [36] SODOMKA, L.: *Několik poznámek k využití KES soustavy*. Česká společnost pro nedestruktivní zkoušení materiálů 37. mezinárodní konference DEFEKTOSKOPIE 2007, Praha. 7. – 9. 11. 2007.
- [37] Stylios GK, Wan TR. The Concept of Virtual Measurement 3D Fabric Drapeability, CTRJ. 1999; 11(1): 10-18.
- [38] Robson D, Long CC. Drape analysis using imaging techniques. CTRJ. 2000; 18(1): 1-8.
- [39] Behera BK, Mishra R. Objective measurement of fabric appearance using digital image processing. J TEXT I. 2006; 97(2): 147-53.

# **PŘÍLOHY**



**Tab. 1 Přehled vybraných rezných tkanin pro trénování neuronové sítě (navržený Model 2)**

Složení	Vazba	Dostava osnovy	Dostava útku	Plošná hmotnost	Tloušťka	DC	počet vln
100% CO - rezná	kepr 7/1	28	28	0,121	0,933	68,47	6
100% CO - rezná	atlas 7/1	28	28	0,119	0,950	65,32	6
100% CO - rezná	plátno	28	26,5	0,123	0,740	89,57	0
100% CO - rezná	plátno	28	24	0,116	0,693	89,08	0
100% CO - rezná	plátno	28	20	0,105	0,657	74,06	5
100% CO - rezná	plátno	28	14	0,095	0,673	71,56	6
100% CO - rezná	plátno	22	18	0,134	0,617	77,05	5
100% CO - rezná	plátno	22	22	0,146	0,570	81,08	7
100% CO - rezná	plátno	22	14	0,118	0,603	72,51	7
100% CO - rezná	plátno	26	18	0,085	0,513	68,16	8
100% CO - rezná	plátno	26	22	0,094	0,587	72,22	8
100% CO - rezná	plátno	26	26	0,102	0,570	74,21	8
100% CO - rezná	kepr 2/3	66	66	0,147	0,546	73,85	0
100% CO - rezná	kepr 2/4	66	66	0,146	0,566	73,47	0
100% CO - rezná	kepr 1/6	66	66	0,145	0,624	69,50	0
100% CO - rezná	kepr 2/5	66	66	0,144	0,566	70,83	0
100% CO - rezná	atlas 1/5	66	66	0,145	0,574	70,06	0
100% CO - rezná	atlas 1/6(2)	66	66	0,144	0,600	63,50	5
100% CO - rezná	atlas 5/1	21,2	21,2	0,141	0,930	50,69	6
100% CO - rezná	kepr 1/5	21,2	21,2	0,143	1,010	53,85	6
100% CO - rezná	ryps 3/3	21,2	21,2	0,143	0,920	54,60	6
100% CO - rezná	panama 3/3	21,2	21,2	0,140	0,903	52,93	6
100% CO - rezná	atlas 2/4	21,2	21,2	0,144	0,917	52,47	6

Tab.2 Přehled vybraných tkanin pro Model 2 neuronové sítě (dámské letní šatovky)

Složení	Vazba	Dostava osnovy	Dostava útku	Plošná hmotnost	Tloušťka	DC	počet vln	Složení	Vazba	Dostava osnovy	Dostava útku	Plošná hmotnost	Tloušťka	DC	počet vln
PL/CO 65/35	plátno	45	36	0,11	0,32	50,35	6,8	PL/VI	žakar	41,5	22,5	0,16	0,53	39,84	7,6
100% CO	plátno	56	28	0,12	0,39	78,78	5,4	10 % VI	plátno	45	31,5	0,08	0,16	52,16	6,5
100 % VI	plátno	16	14	0,08	0,36	17,97	8,1	VI/AC	plátno	60,5	23,5	0,12	0,28	43,50	7,1
PL/CO	plátno	45	29	0,10	0,42	58,39	6,7	100% PL	atlas	48	20,5	0,18	0,66	63,05	7,6
PL/CO 65/35	kepr 2/1	32	19	0,27	0,60	70,54	6,8	100 % PL	atlas	64	36,5	0,10	0,24	60,36	7,9
PL/CO 65/35	kepr 2/1	50	25	0,20	0,52	60,00	6,8	PA/VI	plátno	44,5	34	0,11	0,44	25,42	8,5
PL/CO 65/35	plátno	46	20,5	0,20	0,57	61,70	7,7	100 % VI	atlas	78,5	31	0,14	0,27	56,12	5,9
CO/PL	kepr	54	28	0,11	0,40	76,72	6,4	100 % PL	žakar	61	26	0,16	0,41	70,28	7,2
100% PL	atlas	58	44	0,16	0,48	54,15	7,0	100 % PL	kepr	48	23	0,19	0,44	63,75	8,2
100 % PL	atlas	53	42	0,18	0,33	69,11	5,7	směs	atlas	52	30	0,12	0,61	44,96	8,3
PL/CO 65/35	kepr 3/1	34	20	0,22	0,63	63,84	7,4	směs	plátno	29	20	0,13	0,51	16,88	7,5
100 % PL	plátno	44	30	0,06	0,17	49,17	6,9	směs	plátno	43	33	0,05	0,13	48,56	7,7
VI/LI	plátno	30	19	0,18	0,55	41,89	8,0	směs	plátno	32	23	0,09	0,27	27,37	8,0
100% CO	atlas 4/1	53	31	0,14	0,62	70,95	6,5	100 % CO	plátno	44	26	0,10	0,48	61,92	8,3
100% VI	plátno	40	22	0,12	0,41	22,84	8,0	100 % PL	plátno	24	21	0,11	0,59	49,76	7,6
100% VI	plátno	42	24	0,12	0,39	27,04	7,3	100 % CO	plátno	43	29	0,10	0,48	61,82	8,0
100% VI	plátno	32,5	18,5	0,12	0,48	18,68	8,2	100 % CO	plátno	46	26	0,10	0,44	59,71	7,0
100% CO	plátno	25,5	19	0,13	0,62	77,49	6,4	100 % PL	kepr 2/1	36	28	0,11	0,53	48,41	7,6
100%CO	atlas	52	41	0,10	0,49	48,33	7,5	100 % PL	atlas	28	21	0,23	0,61	44,24	7,3
PL/VI	atlas	96	23	0,10	0,31	51,52	8,1	55 PL/45 VI	plátno	27	26	0,15	0,49	39,28	8,0
100 % PL	kepr	33,5	32	0,13	0,44	47,24	6,8	100 % PL	plátno	26	23	0,18	0,55	49,11	8,3
PL/VI	atlas	64	27,5	0,16	0,60	29,09	8,5	100% VI	plátno	16	14	0,08	0,36	17,97	8,1
100 % PL	plátno	22,5	17,5	0,15	0,44	68,43	7,2	směs	plátno	48	28	0,11	0,36	31,61	7,8
VI/AC	kepr	45	31	0,08	0,16	42,91	7,6	100% PL	kepr	33,5	32	0,13	0,44	47,24	6,8
100 % VI	kepr	59	33	0,12	0,20	56,30	6,6	100 % CO	atlas 1/6(2)	66	66	0,14	0,60	63,50	4,8
PL/VI	atlas	59	27	0,16	0,44	38,23	8,1	100 % VI	plátno	36	18	0,24	0,59	73,59	7,3