

**Statistické hodnocení podmínek  
opakovatelnosti při hodnocení jakosti povrchů  
dle ISO standardů**

Ing. Šárka Košková



---

---

Univerzita Tomáše Bati ve Zlíně

Fakulta technologická

Ústav výrobního inženýrství

akademický rok: 2018/2019

## ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Ing. Šárka Košková**  
Osobní číslo: **T17905**  
Studijní program: **N3909 Procesní inženýrství**  
Studijní obor: **Řízení jakosti**  
Forma studia: **kombinovaná**

Téma práce: **Statistické hodnocení podmínek opakovatelnosti při hodnocení jakosti povrchů dle ISO standardů**

Zásady pro vypracování:

- 1. Zpracování rešerše pro hodnocení jakosti povrchů na bázi drsnosti a vlnitosti dle standardů ISO a jejich vzájemné porovnání**
- 2. Proměření zadaných vzorků z hlediska standardů ISO bezkontaktním způsobem**
- 3. Aplikace diskriminační analýzy na vybrané parametry proměřených dle standardů ISO**

Rozsah diplomové práce: cca 60 stran  
Rozsah příloh: dle pokynů VDP  
Forma zpracování diplomové práce: tištěná/elektronická


Seznam odborné literatury:

1. MELOUN, Milan a Jiří MILITKÝ. Statistická analýza experimentálních dat. Vyd. 2. uprav. rozš. Praha: ACADEMIA, 2004, 953 s. ISBN 80-200-1254-0
2. MELOUN, Milan. Kompedium statistického zpracování dat: metody a řešené úlohy. Vyd. 2., přeprac. a rozš. Praha: Academia, 2006, 982 s. ISBN 80-200-1396-2
3. MELOUN, Milan. Statistické zpracování experimentálních dat. 2. vyd. Praha: Ars magna, 1998, 839 s. ISBN 80-721-9003-2
4. BUMBÁLEK, Bohumil, Vladimír ODVODY a Bohuslav OŠŤÁDAL. Drsnost povrchu. 1. vyd. Praha: SNTL, 1989, 338 s

Vedoucí diplomové práce: doc. Dr. Ing. Vladimír Pata  
Ústav výrobního inženýrství  
Datum zadání diplomové práce: 2. ledna 2019  
Termín odevzdání diplomové práce: 17. května 2019

Ve Zlíně dne 7. února 2019

  
doc. Ing. Roman Čermák, Ph.D.  
děkan



  
prof. Ing. Berenika Hausnerová, Ph.D.  
ředitel ústavu

Příjmení a jméno: Ing. Šárka Košková

Obor: Řízení jakosti

## PROHLÁŠENÍ

Prohlašuji, že

- beru na vědomí, že odevzdáním diplomové/bakalářské práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb. o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších právních předpisů, bez ohledu na výsledek obhajoby <sup>1)</sup>;
- beru na vědomí, že diplomová/bakalářská práce bude uložena v elektronické podobě v univerzitním informačním systému dostupná k nahlédnutí, že jeden výtisk diplomové/bakalářské práce bude uložen na příslušném ústavu Fakulty technologické UTB ve Zlíně a jeden výtisk bude uložen u vedoucího práce;
- byl/a jsem seznámen/a s tím, že na moji diplomovou/bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3 <sup>2)</sup>;
- beru na vědomí, že podle § 60 <sup>3)</sup> odst. 1 autorského zákona má UTB ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- beru na vědomí, že podle § 60 <sup>3)</sup> odst. 2 a 3 mohu užít své dílo – diplomovou/bakalářskou práci nebo poskytnout licenci k jejímu využití jen s předchozím písemným souhlasem Univerzity Tomáše Bati ve Zlíně, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše);
- beru na vědomí, že pokud bylo k vypracování diplomové/bakalářské práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tedy pouze k nekomerčnímu využití), nelze výsledky diplomové/bakalářské práce využít ke komerčním účelům;
- beru na vědomí, že pokud je výstupem diplomové/bakalářské práce jakýkoliv softwarový produkt, považují se za součást práce rovněž i zdrojové kódy, popř. soubory, ze kterých se projekt skládá. Neodevzdání této součásti může být důvodem k neobhájení práce.

Ve Zlíně 18. dubna 2019



.....

<sup>1)</sup> zákon č. 111/1998 Sb. o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších právních předpisů, § 47 Zveřejňování závěrečných prací:

(1) Vysoká škola nevydělečně zveřejňuje disertační, diplomové, bakalářské a rigorózní práce, u kterých proběhla obhajoba, včetně posudků oponentů a výsledku obhajoby prostřednictvím databáze kvalifikačních prací, kterou spravuje. Způsob zveřejnění stanoví vnitřní předpis vysoké školy.

(2) Disertační, diplomové, bakalářské a rigorózní práce odevzdané uchazečem k obhajobě musí být též nejméně pět pracovních dnů před konáním obhajoby zveřejněny k nahlížení veřejnosti v místě určeném vnitřním předpisem vysoké školy nebo není-li tak určeno, v místě pracoviště vysoké školy, kde se má konat obhajoba práce. Každý si může ze zveřejněné práce pořizovat na své náklady výpisy, opisy nebo rozmnoženiny.

(3) Platí, že odevzdáním práce autor souhlasí se zveřejněním své práce podle tohoto zákona, bez ohledu na výsledek obhajoby.

<sup>2)</sup> zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, § 35 odst. 3:

---

(3) Do práva autorského také nezasahuje škola nebo školské či vzdělávací zařízení, užije-li nikoli za účelem přímého nebo nepřímého hospodářského nebo obchodního prospěchu k výuce nebo k vlastní potřebě dílo vytvořené žákem nebo studentem ke splnění školních nebo studijních povinností vyplývajících z jeho právního vztahu ke škole nebo školskému či vzdělávacího zařízení (školní dílo).

<sup>3)</sup> zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, § 60 Školní dílo:

(1) Škola nebo školské či vzdělávací zařízení mají za obvyklých podmínek právo na uzavření licenční smlouvy o užití školního díla (§ 35 odst. 3). Odpirá-li autor takového díla udělit svolení bez vážného důvodu, mohou se tyto osoby domáhat nahrazení chybějícího projevu jeho vůle u soudu. Ustanovení § 35 odst. 3 zůstává nedotčeno.

(2) Není-li sjednáno jinak, může autor školního díla své dílo užít či poskytnout jinému licenci, není-li to v rozporu s oprávněnými zájmy školy nebo školského či vzdělávacího zařízení.

(3) Škola nebo školské či vzdělávací zařízení jsou oprávněny požadovat, aby jim autor školního díla z výdělku jím dosaženého v souvislosti s užitím díla či poskytnutím licence podle odstavce 2 přiměřeně přispěl na úhradu nákladů, které na vytvoření díla vynaložily, a to podle okolností až do jejich skutečné výše; přitom se přihlédne k výši výdělku dosaženého školou nebo školským či vzdělávacím zařízením z užití školního díla podle odstavce 1.

## **ABSTRAKT**

Tato diplomová práce se zabývá zkoumáním způsobů vyhodnocení jakosti povrchu řezné plochy vzorků z různých materiálů po obrábění laserem CO<sub>2</sub> a vláknovým laserem. Jakost povrchu vyjádřená parametry drsnosti Rz a Ra je zkoumána v závislosti na materiálu vzorku a použité technologie obrábění. Za tímto účelem jsou v teoretické části nejprve shrnuty pojmy a definice dané příslušnými normami ISO, v dalších kapitolách jsou stručně představeny statistické metody pro vyhodnocování naměřených dat. Poslední část teoretické části se věnuje problematice použití neuronových sítí pro vyhodnocování naměřených dat. V praktické části byla statisticky vyhodnocena naměřená data ze šesti vzorků. Na základě závěrů této analýzy byly posouzeny možnosti neuronových sítí při určení materiálu daného vzorku pomocí známých parametrů drsnosti.

### **Klíčová slova:**

Jakost povrchu; parametry drsnosti Ra, Rz, Rmr; statistická analýza naměřených dat; perceptron.

## **ABSTRACT**

This diploma thesis deals with methods of evaluation of surface quality of the cut surface of the given samples made from different materials. These samples are cut with either CO<sub>2</sub> laser or fibre laser. Quality surface is given by the roughness parameters Rz, Ra and Rmr, which are analysed in dependence on the material of the sample and the technology used. For this purpose, theoretical part starts with terms and definitions, given by relevant ISO standards. Next chapters describe brief introduction into methods of statistical analysis. Last part is devoted to using neuron networks for data analysis. In practical part data of six samples were statistically analysed. Based on this analysis possibilities of using neuron networks for determination of the material were judged.

### **Keywords:**

Surface quality; roughness parameters Ra, Rz, Rmr; statistical measured data analysis; perceptron.



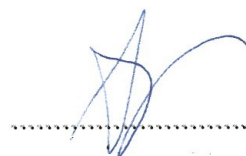


---

Na tomto místě bych ráda poděkovala především mému vedoucímu diplomové práce panu doc Ing. Vladimíru Patovi za cenné připomínky, rady a podněty, a především za podporu při vlastním vyhodnocování dat. Dále bych chtěla poděkovat paní Ing. Mileně Kubišové za rady týkajících se formálního zpracování práce. V neposlední řadě mé poděkování patří panu Ing. Richardu Janu Voigtsovi za jazykovou korekturu a grafickou úpravu práce.

Prohlašuji, že odevzdaná verze bakalářské/diplomové práce a verze elektronická nahraná do IS/STAG jsou totožné.

Ve Zlíně 18.dubna 2019



## OBSAH

<b>ÚVOD</b> .....	<b>10</b>
<b>I. TEORETICKÁ ČÁST</b> .....	<b>11</b>
<b>1 NORMY ISO</b> .....	<b>12</b>
1.1 JAKOST POVRCHU .....	12
1.2 ZÁKLADNÍ TERMÍNY PODLE NORMY ČSN EN ISO 4287 [5] .....	15
1.2.1 Profil povrchu .....	15
1.2.2 Profil drsnosti .....	15
1.2.3 Základní délka.....	15
1.2.4 Vyhodnocovaná délka .....	16
1.2.5 Střední čára profilu drsnosti.....	16
1.3 DEFINICE PARAMETRŮ DRSNOSTI.....	16
1.4 ZÁKLADNÍ TERMÍNY PODLE NORMY ČSN EN ISO 4288 [6] .....	17
1.5 FILTRACE PRŮBĚHU NAMĚŘENÝCH HODNOT .....	17
1.5.1 Historie filtrů .....	18
1.5.2 Filtry – definice a typy .....	18
1.5.3 Cut-off – mezní vlnová délka.....	19
<b>2 STATISTICKÉ NÁSTROJE PRO VYHODNOCOVÁNÍ DAT</b> .....	<b>20</b>
2.1 TESTY HYPOTÉZ .....	20
2.1.1 Testy významnosti.....	21
2.2 KLASIFIKACE DAT .....	23
2.2.1 Shluková analýza dat [15][2] .....	23
2.2.2 Metody shlukování.....	25
<b>3 NEURONOVÉ SÍTĚ [9]</b> .....	<b>29</b>
3.1 MATEMATICKÝ MODEL NEURONU .....	29
3.2 UČENÍ NEURONOVÉ SÍTĚ .....	33
3.3 PERCEPTRON .....	33
3.3.1 Princip učení perceptronu.....	34
<b>4 OBRÁBĚNÍ VLÁKNOVÝM LASEREM A LASEREM CO<sub>2</sub></b> .....	<b>36</b>
4.1 OBRÁBĚNÍ LASEREM CO <sub>2</sub> .....	36
4.2 OBRÁBĚNÍ VLÁKNOVÝM LASEREM.....	37
<b>5 MATERIÁLY VZORKŮ</b> .....	<b>38</b>

5.1	NEREZOVÁ OCEL 17 240 A JEJÍ ZÁKLADNÍ VLASTNOSTI .....	38
5.2	KONSTRUKČNÍ OCEL 11 375 A JEJÍ ZÁKLADNÍ VLASTNOSTI .....	38
5.3	UŠLECHTILÁ OCEL HARDOX 450 A JEJÍ ZÁKLADNÍ VLASTNOSTI.....	39
<b>6</b>	<b>MĚŘICÍ PŘÍSTROJ TAYLOR HOBSON TALYSURF CLI 500 .....</b>	<b>40</b>
<b>II.</b>	<b>PRAKTICKÁ ČÁST.....</b>	<b>43</b>
<b>7</b>	<b>ÚVOD PRAKTICKÉ ČÁSTI .....</b>	<b>44</b>
7.1	ČASOVÉ DIAGRAMY.....	44
7.2	VLIV MATERIÁLŮ NA PARAMETRY RZ A RA .....	46
7.3	POROVNÁNÍ VLIVU POUŽITÉ TECHNOLOGIE NA PARAMETRY RZ A RA VZORKU.....	53
7.3.1	Vyhodnocení parametrů Rz a Ra .....	59
7.4	SHLUKOVÁ ANALÝZA .....	59
7.4.1	Shrnutí shlukové analýzy dat.....	62
7.5	NEURONOVÁ SÍŤ .....	66
7.5.1	Shrnutí výsledků analýzy vzorků materiálů pomocí neuronové sítě.....	74
<b>ZÁVĚR .....</b>	<b>.....</b>	<b>75</b>
<b>SEZNAM POUŽITÉ LITERATURY .....</b>	<b>.....</b>	<b>76</b>
<b>SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK .....</b>	<b>.....</b>	<b>79</b>
<b>SEZNAM OBRÁZKŮ.....</b>	<b>.....</b>	<b>80</b>
<b>SEZNAM TABULEK.....</b>	<b>.....</b>	<b>82</b>
<b>SEZNAM PŘÍLOH .....</b>	<b>.....ERROR! BOOKMARK NOT DEFINED.</b>	

## ÚVOD

Jakost povrchu materiálu určuje a vyjadřuje jednak vlastnost obrobku, výrobku, jednak jeho kvalitu. Už výrobky ze dřeva a kamene vyžadovaly pro další užití dosažení jisté úrovně kvality povrchu. Nároky na ni byly vystupňovány s rozvojem metalurgie, zejména při výrobě řezných nástrojů denního užití – nožů, mečů, srpů, kos a náradí. Avšak při výrobě těchto předmětů stále ještě stačilo hodnocení povrchu pohledem či hmatem. Metody obrábění se také vyvíjely, od vyloženě primitivních, až po dodnes známé klasické soustružení, řezání pilou, obrážení, a spolu s nimi i způsoby klasifikace určování kvality povrchu. Drsnost se začala předepisovat na výkresech a byla dána normami, které se staly dokumenty schvalujícími pravidla reprodukovatelnosti výrobků. „Měření“ drsnosti povrchu pohledem a hmatem už sice dávno přestávalo stačit, nebylo však možno ji exaktně a dostatečně přesně změřit. S příchodem nových technologií, a moderních měřicích přístrojů, jako například laserů, začalo být možno drsnost povrchu přesně měřit a určit její parametry. Tyto technické možnosti se promítly do procesu standardizace.

Normami předepsané způsoby hodnocení jakosti povrchu a opakovatelnost výrobního postupu vedla k myšlence, zda je možné na základě znalosti způsobu obrábění a za podmínek opakovatelnosti změřených parametrů drsnosti určit druh obráběného materiálu. Předmětem této práce bylo ověření této myšlenky.

## I. TEORETICKÁ ČÁST

## 1 NORMY ISO

Potřeba standardizace dílů, výrobků a postupů v průmyslové výrobě je téměř stejně stará jako průmyslová výroba sama. Avšak s nárůstem globalizace roste význam vzájemné nahraditelnosti a zastupitelnosti v rámci dodavatelsko-odběratelského řetězce. Se vzájemnou zastupitelností dodavatelů úzce souvisí nezávislé porovnávání klíčových parametrů výrobků, neboť jak je všeobecné známo, když dva dělají totéž, nemusí to být totéž. Nastavit pravidla pro posuzování různých výrobků či výrobních postupů je hlavní myšlenka Mezinárodní organizace pro normalizaci, která byla založena 23. února 1947 v Ženevě. Hlavní náplní činnosti této organizace je tvorba mezinárodních norem ISO. Samotný název těchto norem pochází z řeckého slova isos (shodný bez ohledu na jazykové rozdíly) a vyjadřuje celou filosofii organizace. Standardizací při posuzování jakosti povrchu se zabývají hlavně normy ISO 4287 [5], ISO 4288 [6], ISO 25178 [7] a ISO 16610-21 [8].


Parametry pro určování struktury povrchu profilovou metodou jsou dány normami ISO 4287 a ISO 25178. Norma ISO 4288 standardizuje postupy pro posuzování struktury povrchu. Norma ISO 16610-21 stanovuje termíny týkající se filtrace.

### 1.1 Jakost povrchu

Při obrábění vznikají působením nástroje nerovnosti. Jakost daného povrchu a s tím související jeho drsnost přímo závisí na metodě výroby. Aby byly povrchy porovnatelné z hlediska jakosti, normy ISO 4287, ISO 4288, ISO 25178 a další definují řadu parametrů, kterými lze kvantifikovat povrch daného vzorku. V této práci se pracuje pouze s parametry týkající se drsnosti povrchu, tzv. R-parametry.


Tyto parametry jsou výsledkem proměření daného vzorku drsnoměrem. Uvažujme řez materiálem kolmý k obráběné ploše. Při dostatečném zvětšení lze pozorovat několik typů struktury povrchu. Při analýze těchto typů rozlišujeme nepřesnosti nazývané tvar, vlnitost a drsnost.

Následující obr. 1 ukazuje rozlišení vlnitosti a drsnosti dle vlnových délek dle ISO 4287.



Obr. 1 Přenosová charakteristika profilu drsnosti a vlnitosti [5]

Následující obr. 2 ukazuje řez vzorkem se všemi složkami – drsností, vlnitostí a tvarem [23].



Obr. 2 Řez povrchem zobrazující všechny složky povrchové nepřesnosti

Z obr. 2 je patrné, že největší nerovnosti povrchu jsou dané tvarem povrchu. Jsou způsobeny například nedostatečnou tuhostí obráběcího stroje, nepřesným seřizováním vodících ploch apod. Po odfiltrování složek drsnosti a vlnitosti se získá profil s vlnovou délkou větší než  $\lambda_c$ . Viz následující obr. 3.



Obr. 3 Profil tvaru povrchu

Vlnitost (obr. 4) je v podstatě makronerovnost a je způsobena převážně vlivem stroje například nevyvážením brousícího kotouče. Profil této nerovnosti je určen vlnovou délkou mezi  $\lambda_c$  a  $\lambda_f$  dle ISO 4287.



Obr. 4 Profil vlnitosti povrchu

Mikronerovnosti označované jako drsnost (obr. 5) jsou nepřesnosti ve vlnovém pásmu  $\lambda_s$  až  $\lambda_c$ . Jsou většinou způsobeny relativním pohybem nástroje a obrobku. Poněkud obecně lze říci, že profil drsnosti je nesen profilem vlnitosti.



Obr. 5 Profil drsnosti povrchu




## 1.2 Základní termíny podle normy ČSN EN ISO 4287 [5]

Norma ISO 4287 definuje některé základní parametry, kterými jsou profil povrchu, profil drsnosti, základní délka, vyhodnocovaná délka, střední čára, střední čára profilu drsnosti a parametry drsnosti.

### 1.2.1 Profil povrchu

Profil povrchu je profil vzniklý jako průsečnice skutečného povrchu a dané roviny, viz obr. 6.



Obr. 6 Profil povrchu

### 1.2.2 Profil drsnosti

Profil drsnosti je profilem vzniklým ze základního profilu potlačením dlouhovlnných složek, použitím profilu  $\lambda_c$ .

### 1.2.3 Základní délka

Základní délka se pro definici drsnosti označuje jako  $l_r$  a měří se ve směru osy X. Je rovna charakteristické vlnové délce profilového filtru  $\lambda_c$ .

### 1.2.4 Vyhodnocovaná délka

Vyhodnocovaná délka  $l_n$  je délkou ve směru osy X, použitá pro posouzení vyhodnocovaného povrchu.


### 1.2.5 Střední čára profilu drsnosti

Střední čára profilu drsnosti je čára odpovídající dlouhovlnné složce profilu potlačené filtrem profilu  $\lambda_c$ .

## 1.3 Definice parametrů drsnosti

Vycházíme ze základní délky profilu, na které definujeme parametry  $R_z$ ,  $R_a$  a  $R_{mr}$  dle ISO 4287.

- Parametr  $R_z$  je definován jako součet výšky  $Z_p$  nejvyššího výstupku profilu a hloubky  $Z_v$  nejnižší prohlubně v rozsahu základní délky.




Obr. 7 Zobrazení výšky profilu drsnosti

- Parametr  $R_a$  se nazývá výškový a je definován jako průměrná aritmetická úchylka posuzovaného profilu, je to tedy aritmetický průměr absolutních hodnot pořadnic  $Z(x)$  v rozsahu základní délky  $R_a = \frac{1}{l} \int_0^l |Z(x)| dx$ . Je střední hodnotou vzdáleností zkoumaného povrchu od střední čáry daného profilu. Pro hodnocení drsnosti povrchu nemusí být  $R_a$  vždy efektivní, jelikož jde pouze o statistickou hodnotu. Dva různé povrchy se stejnou hodnotou  $R_a$  totiž mohou mít rozdílné požadavky na chování součásti ohledně funkčnosti či její životnosti. Podle definice se při stanovení parametru  $R_a$  totiž nerozlišuje mezi výstupky a prohlubněmi. Pro hodnocení drsnosti povrchu se navzdory tomu tento parametr

používá nejvíce. Změřit parametr Ra je poměrně snadné a při opakovaném měření vykazují hodnoty značnou přesnost.

- Parametr Rmr je materiálový poměr profilu. Jde o poměr délky materiálu elementu profilu  $MI(c)$  na dané úrovni  $c$  k vyhodnocované délce:

$$Rmr(c) = \frac{MI(c)}{ln}$$



Obr. 8 Parametry pro stanovení Rmr (c) na dané úrovni c

#### 1.4 Základní termíny podle normy ČSN EN ISO 4288 [6]

Norma ISO 4288 definuje pravidla pro odhadování parametrů na základě naměřených dat, pro porovnávání měřených hodnot s tolerančními mezemi, pro hodnocení parametrů a pravidla a postupy pro kontrolu dotykovými přístroji. Především jde o pravidlo 16 %, které specifikuje přijatelnost povrchu. Dále platí pravidlo maxima, které stanovuje způsob zadání maximální hodnoty daného parametru s ohledem na nejistotu měření. Součástí této normy je i stanovení počtu základních délek, na kterých byl požadovaný parametr vyhodnocován, na standardní hodnotu 5 a případný přepočet, pokud je počet základních délek jiný. S počtem základních délek souvisí i vztah mezi vyhodnocovanou délkou a spolehlivostí rozhodnutí, zda kontrolovaný povrch vyhovuje zadané specifikaci. Norma ISO 4288 také stanovuje postup určení délky „cut-off“ pro měření parametrů profilu drsnosti.

#### 1.5 Filtrace průběhu naměřených hodnot

Během analýzy povrchu je v několika bodech vyžadována filtrace, například pro rozlišení vlnitosti, tvaru a drsnosti v případě, že data pocházejí z optického měřicího přístroje. Až po rozlišení výše zmíněných složek je teprve možné spočítat parametry podle požadovaných specifikací.

### 1.5.1 Historie filtrů

První filtry byly vytvořeny pomocí rezistorů a kapacitorů a byly používány téměř 30 let u všech dotykových profilometrů. V 80. letech byl jejich princip implementován pomocí počítačového algoritmu. Dalším důležitým mezníkem ve vývoji bylo zavedení filtrů RC2 v 90. letech, avšak v této době již byly vyvíjeny dnes nejpoužívanější Gaussovy filtry [16][12][22]. Tyto filtry byly zavedeny jako standard normou ISO 11562 v roce 1996 pro hodnocení profilů a v roce 2011 byla přijata norma ISO 16610-21 jako oficiální standard definující Gaussův filtr pro otevřené a uzavřené povrchy. Gaussovy filtry jsou úspěšně používány pro různé aplikace v průmyslu a výzkumu již více než 20 let a většina přístrojů měřících strukturu povrchu je mají zavedený jako z výroby nastavený (default), jelikož poskytují nejstabilnější výsledky s minimálním fázovým zkreslením.

### 1.5.2 Filtry – definice a typy

Během analýzy povrchu je v několika bodech vyžadována filtrace, například pro rozlišení vlnitosti, tvaru a drsnosti v případě, že data pocházejí z optického měřicího přístroje. Po rozlišení výše zmíněných složek je možné teprve spočítat parametry podle požadovaných specifikací. Principy filtrace jsou specifikovány v normě ISO 25178 [7]:

- S-Filtr odstraňuje krátkovlnné komponenty;
- L-Filtr dlouhovlnné komponenty;
- F-operátor odstraňuje nepřesnosti způsobené tvarem.
- 

Výstup měření drsnosti povrchu materiálu obsahuje složky o různých vlnových délkách. Aby bylo možno provést analýzu konkrétního faktoru (v našem případě jde o parametry drsnosti), je třeba z naměřeného průběhu odfiltrovat dlouhovlnné složky vlnitosti. Jak již bylo uvedeno, vlnitost a drsnost se liší především vlnovou délkou.

Typy a způsoby filtrace průběhu naměřených hodnot jsou dány normou ISO 16610 [8], která definuje různé filtry, například:

#### 1. Lineární filtry:

- Gaussovy filtry definované normou ISO 16610-21
- Spline filtry definované normou ISO 16610-22

#### 2. Silné (robustní) filtry:

- Gaussovy regresní filtry definované normou ISO 16610-31
- Spline filtry definované normou ISO 16610-32

V této práci byla použita Gaussova lineární filtrace [16][12][22].

### 1.5.3 Cut-off – mezní vlnová délka

Dále norma ISO 16610 definuje pojem cut-off [8]. Jde o vlnovou délku sinusového profilu pro účinnost profilového filtru, což podle normy znamená propuštění 50 % amplitud. Tato vlnová délka (cut-off) se musí před začátkem měření nastavit jako volitelný parametr přístroje. Mezní vlnová délka je funkcí profilometru a je transformací profilu povrchu na odpovídající elektrický signál v rozsahu základní délky. Vyplyvá to z porovnání významu mezní vlnové délky se základní délkou analyzovaného profilu.

Pro každou konkrétní úlohu je třeba zvolit adekvátní vlnové délky a vhodný filtr, který zajistí převod veličin drsnosti z analyzovaného povrchu.

Jako další možné filtry, které byly dány v úvahu, byly filtry s lineární útlumovou charakteristikou v délce vlny spíše než ve frekvenci. To je přirozené rozšíření pro filtry použité v metrologii povrchu, protože povrchy mají prostorový, nikoliv časový charakter.

## 2 STATISTICKÉ NÁSTROJE PRO VYHODNOCOVÁNÍ DAT

V teoretické rovině se jakost povrchu hodnotí pomocí parametrů daných normami ISO a závěry vyplývají ze statistických testů a analýz. Tyto testy jsou běžné statistické testy hypotéz, které jsou založeny na předpokladu, že data z nasnímaného povrchu vykazují normální rozdělení a lze zanedbat jejich šikmost. Dále se neuvažuje vliv systematických chyb. Proto se nejprve provádí základní explorativní analýza dat, kdy se zjišťuje typ rozdělení, případné odchylky, šikmost, špičatost. Ohledně parametrů daného souboru dat se hodnotí především aritmetický průměr a rozptyl. K tomuto hodnocení používáme různé diagramy a grafy.

- **Histogram** – je diagram, kde výška daného sloupce vyjadřuje hustotu pravděpodobnosti výskytu dané hodnoty zkoumané veličiny. Sloupce se často prokládají jádrovým odhadem pravděpodobnosti, který názorně zobrazuje křivku rozdělení.
- **Diagram boxplot** – identifikuje polohu mediánu a odlehlé hodnoty.
- **Time-series diagram** – časový diagram zobrazuje naměřená data v pořadí, ve kterém byla zaznamenána. Z tohoto diagramu lze snadno posoudit vývoj hodnot.

### 2.1 Testy hypotéz

Statistické hypotézy jsou obecně vzato tvrzení o dané populaci, které se pomocí různých statistických metod potvrzují nebo zamítají. Tyto metody se souhrnně nazývají testy významnosti. Jejich společným rysem je, že pokaždé se rozhoduje mezi dvěma navzájem se vylučujícími tvrzeními – hypotézami. Ta hypotéza, kterou je třeba testovat se nazývá nulová hypotéza a označuje se jako  $H_0$ . Proti ní se staví alternativní hypotéza  $H_A$ , která vyjadřuje negaci nulové hypotézy. Volba formulace těchto hypotéz je velmi závislá na kontextu daného statistického případu. Avšak podobně jako u soudních procesů je otázka presumpce neviny, ve statistice je nulová hypotéza považována za pravdivou tak dlouho, dokud se na základě statistických dat neprokáže opak – neboli platnost alternativní hypotézy. Protože datový soubor, na jehož základě se testy provádějí je vždy konečný, je třeba nulovou hypotézu formulovat tak, aby na základě výsledku testu byla zamítnuta. V opačném případě by mohla nastat mezní situace, že pro daný soubor o  $N$  hodnotách je nulová hypotéza přijata, avšak pro  $N+1$  měření již podmínky testu nejsou splněny.

Dále každá formulace hypotézy je zatížena potenciálně možnou chybou při přijímání či zamítání nulové hypotézy. Proto je vždy zvolena jistá hladina významnosti  $\alpha$ , která určuje pravděpodobnost chyby I. druhu. Chyba I. druhu znamená, že se nulová hypotéza zamítne ve prospěch alternativní hypotézy i přes její platnost. Podobně definovaná je chyba II. druhu, která nastává, pokud se přijme nulová hypotéza přes platnost alternativní hypotézy. Pravděpodobnost, že nastane chyba II. druhu se označuje  $\beta$  a nazývá se síla testu.

		Rozhodnutí na základě testu	
		$H_0$ je přijata	$H_0$ je zamítnuta
Skutečnost	Platí $H_0$	Test byl vyhodnocen správně se spolehlivostí testu – $1-\alpha$	Chyba I. druhu hladina významnosti $\alpha$
	Platí $H_A$	Chyba II. druhu $\beta$	Chyba II. druhu $1-\beta$ síla testu

Tab. 1 Chyby prvního a druhého druhu [23]

Optimálně by obě tyto chyby měly být co nejmenší, což bohužel není možné. Se snižováním hodnoty  $\alpha$  se zvyšuje hodnota  $\beta$ . Proto se  $\alpha$  obvykle volí jako 0,050 nebo 0,010. To znamená, že připouštíme s pravděpodobností 0,050 respektive 0,010 chybné zamítnutí nulové hypotézy.

### 2.1.1 Testy významnosti

Testy významnosti jsou kritéria, na jejichž základě se rozhoduje, zda je možné zamítnout nulovou hypotézu. V následující části jsou zmíněny testy, které byly použity v praktické části. Tyto testy jsou implementovány ve statistickém programu MiniTab.

#### 2.1.1.1 F-test shody rozptylů

F-test je statistickým testem, který umožňuje určit, že statistika  $F = \frac{S_x^2}{S_y^2}$  se řídí

Snedecorovým rozdělením. Toto rozdělení je odvozeno od normálního rozdělení a patří k nástrojům, umožňujícím úplnou statistickou analýzu dat. [24]

V tomto testu jako nulovou hypotézu položíme tvrzení, že dané dva výběry s předpokládaným normálním rozdělením mají shodné rozptyly. Tento test je velmi citlivý na nesplnění podmínky normality dat, avšak pro námi zvolenou hodnotu chyby I. druhu  $\alpha = 0,050$  je tento test dostatečně robustní, aby poskytl použitelné výsledky.

### Princip F-testu

Nechť výběry  $X_1 \dots X_n$  a  $Y_1 \dots Y_n$  jsou nezávislé výběry ze dvou populací, z nichž každá má normální rozdělení. Je třeba testovat, zda tyto výběry mají shodné rozptyly  $s_x^2$  a  $s_y^2$ , kde

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$s_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2$$

- Testovací kritérium F-testu je definováno jako  $F = \frac{s_x^2}{s_y^2}$
- Nulová hypotéza tohoto testu je postavena  $H_0: \sigma_x^2 = \sigma_y^2$
- Proti tomu alternativní hypotéza je  $H_A: \sigma_x^2 \neq \sigma_y^2$

#### 2.1.1.2 t-test

Studentův t-test střední hodnoty testuje, zda se střední hodnoty testovaných výběrů liší statisticky významně či nikoliv. Opět předpokládá, že testovaná data mají normální rozdělení. U tohoto testu výběr testovacího kritéria závisí, zda dané výběry mají shodné rozptyly či ne. Proto se t-test provádí až po F-testu.

Pro shodné rozptyly má testovací kritérium tvar [2]

$$T_1 = \frac{|\bar{x} - \bar{y}|}{\sqrt{(n_1-1)s_x^2 + (n_2-1)s_y^2}} \sqrt{\frac{n_1 n_2 (n_1 + n_2 - 2)}{(n_1 + n_2)}}, \text{ kde}$$

- $\bar{x}$  je aritmetický průměr prvního výběru o  $n_1$  prvcích s rozptylem  $s_x^2$
- $\bar{y}$  je aritmetický průměr prvního výběru o  $n_2$  prvcích s rozptylem  $s_y^2$

Pokud rozptyly testovaných výběrů nejsou shodné, používá se kritérium

$$T_2 = \frac{|\bar{x} - \bar{y}|}{\sqrt{\frac{s_x^2}{n_1} + \frac{s_y^2}{n_2}}}$$

Jako nulová hypotéza je u tohoto testu položeno  $H_0: \mu_1 = \mu_2$ .



Proti tomu je postavena alternativní hypotéza  $H_A: \mu_1 \neq \mu_2$ .

### 2.1.1.3 Analýza variance – ANOVA

Analysis of Variance [10] – tento způsob analýzy je vhodný, pokud je třeba analyzovat více než dva výběry. Je více metod, které jsou označeny jako ANOVA, ale v této práci byla použita jednofaktorová metoda ANOVA. Bylo předpokládáno normální rozdělení dat a shodné rozptyly. Pokud tyto předpoklady nejsou splněny, metoda ANOVA nedává hodnověrné výsledky, a je třeba použít jiné metody testování, například Kruskal-Wallisův test.

Pro jednofaktorovou analýzu ANOVA je položena nulová hypotéza

$$H_0: \mu_1 = \mu_2 = \mu_3 \dots$$

Jako alternativní hypotéza je použita

$$H_A: \mu_1 \neq \mu_2 \neq \mu_3 \dots$$

Protože pomocí metody ANOVA se testuje shodnost středních hodnot daných výběrů, je třeba před vlastním použitím této metody otestovat shodnost rozptylů například F-testem.

## 2.2 Klasifikace dat

Při posuzování naměřených dat z množiny vzorků je třeba tato data rozdělit na několik podmnožin dle určitých kritérií. Tímto se určí skupiny, které vykazují jistou podobnost. Třídění dat do skupin je součástí disciplíny „statistické učení“, kde se na základě množiny takzvaných trénovacích dat stanovuje predikční model, který umožňuje předpovědět s určitou pravděpodobností výstupní hodnotu. V následující kapitole této práce je popsáno použití neuronových sítí právě pro určení výsledné hodnoty na základě vstupních naměřených dat. V literatuře jsou popsány různé metody klasifikace dat. V této práci je použita metoda shlukové analýzy.

### 2.2.1 Shluková analýza dat [15][2]

Shlukování patří mezi techniky vícerozměrné analýzy dat. Základní myšlenkou a principem metody shlukování je rozdělení na měřených dat do skupin (shluků) tak, aby položky z jednoho shluku měly „podobnější“ vlastnosti než ostatní. Tímto způsobem lze dobře identifikovat vychýlené hodnoty.

V teorii shlukové analýzy jsou popisovány dva základní přístupy ke klasifikaci objektů, a to hierarchické a nehierarchické metody. Mezi nehierarchické metody patří dle Lukasové optimalizační metody a metody analýzy módů. Hierarchické metody můžeme dále rozdělit na aglomerativní a divizní. Zkoumané znaky, dle kterých se vytvářejí shluky by měly být v ideálním případě nezávislé. Pro alespoň přibližné posouzení závislosti pozorovaných znaků lze použít koeficient korelace:

$$r_{ij} = \frac{\frac{1}{n} \sum_{m=1}^n z_{mi} z_{mj} - \bar{z}_i \bar{z}_j}{s_i s_j} = \frac{k_{ij}}{s_i s_j}, \text{ kde}$$

- $k_{ij}$  – kovariance znaků  $z_i$  a  $z_j$
- $s_i$  a  $s_j$  – směrodatné odchylky znaků  $z_i$  a  $z_j$

Jelikož podobnost znaků je hlavním kritériem pro vytváření shluků, je třeba tuto podobnost nějakým způsobem kvantifikovat. K tomu se využívají různé metriky, například euklidovská statistická nebo Minkovského. Software, který byl v této práci použit, pracuje s Euklidovskou metrikou, proto se tato práce ostatními metrikami nezabývá. Euklidovská metrika  $\rho$  bodu A ( $a_1 \dots a_p$ ) a bodu B ( $b_1 \dots b_p$ ) je definována jako:

$$\rho(A, B) = \left[ \sum_{i=1}^p (a_i - b_i)^2 \right]^{1/2}$$

kde funkce  $\rho(A, B)$  je definovaná na  $E_p \times E_p$  a musí splňovat čtyři podmínky:

1.  $\rho(A, B) = 0 \Leftrightarrow A = B$
2.  $\rho(A, B) \geq 0$
3.  $\rho(A, B) = \rho(B, A)$
4.  $\rho(A, C) \leq \rho(A, B) + \rho(B, C)$

Tyto podmínky vycházejí z geometrického modelu dat, kde míra podobnosti je vyjádřena vzdáleností jednotlivých objektů v Euklidovském prostoru.


### 2.2.2 Metody shlukování

V literatuře je popsáno několik hierarchických aglomerativních metod, pomocí nichž se vytvářejí shluky. Na začátku procesu se předpokládá  $N$  shluků, z nichž každý obsahuje právě jeden objekt. Dále je dána symetrická  $N \times N$  matice vzdáleností (reprezentujících podobnost prvků)  $D = \{d_{ik}\}$ .

Práce byla zpracovávána pomocí programu MiniTab. Tento program nabízí několik metod pro vytváření shluků:


#### 2.2.2.1 *Single linkage* – metoda nejbližšího souseda:

V matici  $D$  se vyhledávají dva prvky, které mají nejmenší vzdálenosti, a z těchto prvků se vytvoří nový prvek – shluk. Matice vzdáleností se následně přepočítá a celý postup se opakuje.



Obr. 9 Metoda nejbližšího souseda


Tato metoda má nevýhodu, že nebere v úvahu vzájemnou vzdálenost objektů dvou shluků jako celku, ale pouze nejmenší vzdálenost dvou extrémních prvků daných shluků. Tím dochází ke zkreslení výsledku, jak je znázorněno na obr. 10 znázorňující vztah vzdálenosti mezi objekty.



Obr. 10 Metoda nejbližšího souseda – vztah vzdálenosti mezi objekty [2]

#### 2.2.2.2 Complete linkage – metoda nejvzdálenějšího souseda:

V této metodě jde v principu o stejný postup jako u metody předchozí, avšak místo vyhledávání shluků s nejmenší vzájemnou vzdáleností vyhledáváme prvky matice  $D$ , které mají vzdálenost největší. Tím je zajištěno, že v jednom kroku všechny prvky náležející jednomu shluku mají vzdálenost menší nebo rovnou určité maximální vzdálenosti. Vzhledem k podobnosti způsobu vytváření shluků, má tato metoda i podobnou nevýhodu.



Obr. 11 Metoda nejvzdálenějšího souseda

### 2.2.2.3 Average linkage – metoda průměrné vzdálenosti

Zde se vzdálenost dvou shluků vyjadřuje aritmetickým průměrem vzdáleností všech dvojic prvků, u kterých každý prvek patří jinému shluku.

### 2.2.2.4 Centroid linkage – metoda těžiště


Při použití této metody se vzdálenost dvou shluků hodnotí na základě vzdálenosti jejich těžišť. Přičemž souřadnice těžiště se určí z průměrných hodnot souřadnic objektů uvnitř daného shluku. Tato metoda je ovlivněna odlehlými hodnotami méně než ostatní výše zmíněné metody.

### 2.2.2.5 Median linkage – mediánová metoda

Tato metoda je jistým vylepšením metody těžiště. Místo vzdáleností těžišť dvou shluků se posuzují vzdálenosti jejich mediánů

### 2.2.2.6 Wardova metoda

Hlavní myšlenkou této metody je minimalizovat ztrátu informací při spojování dvou shluků do jednoho. Pro daný shluk je vyjádřen součet směrodatných odchylek každého prvku shluku od aritmetického průměru v daném shluku.



Obr. 12 Wardova metoda

V každém kroku této metody se spočítá přírůstek součtu čtverců odchylek vzniklý sloučením daných dvou shluků. V prvním kroku je v každém shluku jeden objekt, a tudíž je vnitroshluková variabilita rovna nule. Poté je vybrána ta dvojice shluků, kde je přírůstek nejmenší, a tyto dva shluky se sloučí do nového shluku.

Dle [2] je vnitroshluková variabilita určena vzorcem:

$$VSS = \sum_{j=1}^m \sum_{i=1}^k (x_{ij} - \bar{x}_j)^2$$

Kde:

- $m$  je počet znaků objektu
- $K$  je počet objektů v jednom shluku
- $\bar{x}_j$  je aritmetický průměr
- $\bar{x}_j = \frac{1}{K} \sum_{i=1}^k x_{ij}$

Po přidání dalších shluků s  $k_1$  objekty se původní matice  $k \times m$  změní na matici  $(k+k_1) \times m$ . Potom se při výpočtu VSS musí vzít v úvahu nový počet objektů. Ačkoliv tato metoda poskytuje dobré výsledky, její nevýhodou je vytvářet relativně malé shluky.

### 3 NEURONOVÉ SÍTĚ [9]

Od začátku rozvoje počítačových technologií byla zkoumána technologie architektury počítače, klasická von Neumannovská architektura vykazovala jeden nedostatek. Při regulaci jevů, které byly postaveny na empirických zkušenostech obsluhujícího pracovníka byly výpočty prováděné na klasickém počítači příliš pomalé, a tudíž nepoužitelné. Na tyto hranice von Neumannovské architektury naráželo například rozpoznávání písma, kdy není možné postihnout analyticky všechny typy písmen a jejich odchylky. Proto na základě inspirace lidským mozkiem a potažmo funkcí nervové soustavy byly pokusy jak matematicky a posléze technických prostředků vyjádřit biologický princip funkce centrální nervové soustavy, především schopnost empiricky se učit na základě příkladů pomocí zobecňování. Za počátek vývoje neuronových sítí můžeme považovat představení jednoduchého matematického neuronu v roce 1943 pány Warrenem McCullockem a Walterem Pittsem. Zdokonalení tohoto modelu pomocí vah, přiřazených k jednotlivým vstupům Donaldem Hebbem v roce 1949 bylo dalším významným milníkem ve vývoji neuronových sítí. Konečně v roce 1957 byla představena první jednoduchá neuronová síť – perceptron Frankem Rosenblattem. Od té doby se neuronové sítě neustále vyvíjejí, a především se zdokonalují implementace tzv. rozhodovacího softwaru.


Neuronové sítě se dnes používají všude, kde je požadavek na schopnost systému učit se z příkladů a zobecňovat zkušenosti z předchozích událostí. Dalším důvodem pro využití neuronů při vyhodnocování naměřených dat je možnost řešit nelineární úlohy, například regresi.

#### 3.1 Matematický model neuronu

Neuron je principiálně jednotka, která provádí zobrazení euklidovského prostoru na reálná čísla  $\{\mathbb{R}\}^n \rightarrow \mathbb{R}$ . To znamená, že převádí  $n$  vstupů, kterým jsou přiřazeny váhy, na jednu hodnotu výstupní funkce. Výstup neuronu je hodnota funkce  $f(\xi)$ , kde

$\xi = \sum_{i=1}^n x_i \cdot w_i - \theta$  je vnitřní potenciál neuronu. Tato funkce se vyčíslí právě když součet součinů hodnota vstupu  $x_i \times w_i$  překročí předem zadanou hodnotu  $\theta$  nazývanou práh.

Obrázek 13 znázorňuje princip neuronu. [25]



Obr. 13 Princip neuronu

Přenosová funkce může být několika typů. Buď skoková, kdy se hodnota výstupu skokově změní při překročení prahové hodnoty, nebo analogová, kdy výstupní hodnota je generována spojitou přenosovou funkcí. Skoková funkce se používá jen u výstupní vrstvy, kdy je požadován binární výstup. U ostatních vrstev se používají analogové funkce.

### Příklady přenosových funkcí

Výstupní hodnota  $y$  je pro přenosovou funkci obecně vyjádřena vztahem:

$$y = f\left(\sum_{i=1}^n x_i \cdot w_i - \theta\right), \text{ kde}$$


- $x_i$  je hodnota  $i$ -tého vstupu
- $w_i$  je váha příslušná  $i$ -tému vstupu
- $\theta$  je prahová hodnota
- $n$  je počet vstupů
- $f$  je přenosová funkce



Jako přenosová funkce se používá lineární funkční závislost, hyperbolický tangens ( $f(x) = \operatorname{tgh}(x)$ ) nebo sigmoida:

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

kde  $\lambda$  je parametr strmosti.



Obr. 14 Sigmoida [26]

Samotný neuron je schopen provádět pouze nejzákladnější operace, a proto jsou vytvářeny struktury neuronů, které zajišťují i velmi složité rozhodovací operace. Pro tyto struktury se vžilo označení neuronové sítě. Neuronová síť je orientovaný graf s ohodnocenými hranami, kde rozeznáváme uzly vstupní, výstupní a skryté, a kde hrany reprezentují tok signálu. Hrany jsou ohodnoceny parametrem zpracování signálu, který se nazývá váhou. V jednotlivých uzlech jsou umístěny samostatné neurony. Uzly, jejich rozmístění a vzájemné vazby tvoří důležitý aspekt architektury dané sítě. Vstupní uzly většinou pouze distribuují příchozí data k všem neuronům první skryté vrstvy. Dále se síť může skládat z několika skrytých vrstev, které jsou navrženy tak, aby síť jako celek vykonávala požadované operace. Výstupní vrstva funguje převážně jako výstupní rozhraní sítě.


V polovině 80. let bylo dokázáno [27], že libovolnou spojitou funkci

$$f: [0,1]^n \rightarrow \mathbb{R}^m, f(x) = y$$


je možné s požadovanou přesností aproximovat pomocí třívrstvé sítě. Parametr  $n$  udává počet vstupních neuronů a parametr  $m$  udává počet výstupních neuronů. Prostřední, skrytá vrstva, pak obsahuje  $2n+1$  neuronů.

**Pomocí jednoho lineárního neuronu lze implementovat:**


Konjunkci (uzel AND), disjunkci (uzel OR) a negaci (uzel NOT):



Obr. 15 Konjunkce (uzel AND)



Obr. 16 Disjunkce (uzel OR)



Obr. 17 Negace (uzel NOT)

U výše uvedených příkladů číslo v kroužku udává prahovou hodnotu a hodnoty přiřazené vstupům jsou jejich váhy.

Pomocí těchto základních prvků lze vytvořit jakoukoli logickou funkci.

### 3.2 Učení neuronové sítě


Schopnost samoregulace na základě předchozích zkušeností je jeden z hlavních přínosů neuronových sítí. Tato schopnost vzniká při procesu učení, kdy nejprve provádíme požadované operace na tzv. trénovací množině dat. To znamená, že pro dané vstupy jsou požadované výstupy známe a síť na základě vyhodnocení chybové funkce, což je většinou střední kvadratická odchylka, upraví váhy spojů mezi jednotlivými neurony. Aby bylo možné najít minimální hodnotu chybové funkce, musí mít všechny přenosové funkce spojitou první derivaci. Pak je i chybová funkce derivovatelná a [28] hodnota změny váhy daného vstupu je

$$\Delta w_i = -\eta \frac{\delta E}{\delta w_i}, \text{ kde}$$

$E$  je chybová funkce vyjádřená druhou mocninou rozdílu mezi skutečnou výstupní hodnotou a očekávanou. Parametr nazývaný  $\eta$  je rychlost učení a udává délku kroku iterace. Tento způsob učení se nazývá učení s učitelem.

### 3.3 Perceptron

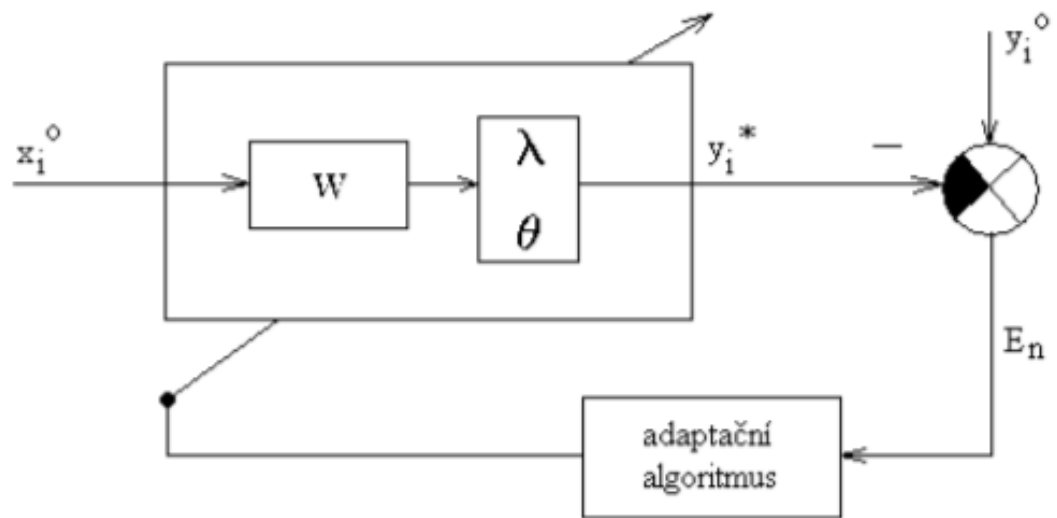
Původní využití perceptronu bylo rozpoznávat znaky pomocí pole optických snímačů. Tím byla modelována biologická percepce a vznikl název perceptron. V současné době se tento název všeobecně ujal a používá se v oblasti umělé inteligence pro označení vrstevnaté dopředné neuronové sítě. To je síť, kde se signály šíří jednosměrně, od vstupu k výstupu. U perceptronové sítě má každý neuron počet vstupů rovný počtu neuronů v předchozí vrstvě a počet jeho výstupů je rovný počtu neuronů v následné vrstvě. V jedné vrstvě se mezi neurony nevyskytují žádné vazby. Jak bylo zmíněno výše, třívrstevná síť umí provádět libovolnou logickou funkci a díky této vlastnosti je to jedna z nejčastějších topologií.



Obr. 18 Perceptron s jednou skrytou vrstvou

### 3.3.1 Princip učení perceptronu

Pro perceptronové sítě se používá učení s učitelem podle zobecněné gradientní metody. Pro tuto metodu je v literatuře používaný název metoda zpětného šíření chyby neboli error backpropagation, protože se při aproximaci jednotlivých vah postupuje od výstupu zpět ke vstupům. Po počáteční inicializaci vah sítě se postupně vypočítají chyby pro neurony výstupní vrstvy, poté je možné vyčíslit chyby neuronů ve skryté vrstvě. Upraví se všechny váhy jednotlivých spojů mezi neurony a postup se opakuje, dokud není splněno kritérium pro zastavení učení. Tímto kritériem může být například dosažení ustálené hodnoty chybové funkce v jejím minimu nebo dosažení hodnoty chybové funkce, která je menší než jistá předem zadaná hodnota. Schematicky je tento postup zobrazen na obr. 19.




Obr. 19 Princip učení perceptronu

## 4 OBRÁBĚNÍ VLÁKNOVÝM LASEREM A LASEREM CO<sub>2</sub>

### 4.1 Obrábění laserem CO<sub>2</sub>


Pro vybuzení paprsku slouží jako aktivní plyn CO<sub>2</sub> a do rezonátoru přiváděné další plyny N<sub>2</sub> a He slouží k chlazení a depopulaci energetických hladin s nízkou úrovní. Dusík a kyslík se přivádějí do řezné hlavy pro podporu řezání, chlazení a odvod roztaveného materiálu z místa řezu.



Obr. 20 Princíp laseru CO<sub>2</sub> [29]

## 4.2 Obrábění vláknovým laserem

Ve vláknovém laseru vytváří aktivní prostředí pro vznik laserového paprsku křemíkové vlákno dopované Ytterbiem. Laserový paprsek je veden optickým vláknem. Pro podporu řezání, chlazení a odvod roztaveného materiálu se přivádějí do řezné hlavy dusík a kyslík.



Obr. 21 Princip vláknového laseru [30]

## 5 MATERIÁLY VZORKŮ

Pro měření byly použity tři typy materiálů [31], a sice konstrukční ocel 11375 (vzorek 235), ořezávací ušlechtilá ocel HARDOX 450 (vzorek HARDOX) a nerezová ocel 17240 (vzorek 1\_430). V této práci byly měřené vzorky označeny následovně:

Označení	Vzorek
F_1_430	ocel 17240 obráběná vláknovým laserem
CO <sub>2</sub> _1_430	oceli 17240 obráběny laserem CO <sub>2</sub>
F_235	oceli 11375 obráběny vláknovým laserem
CO <sub>2</sub> _235	oceli 11375 obráběny laserem CO <sub>2</sub>
F_HARDOX	oceli HARDOX obráběny vláknovým laserem
CO <sub>2</sub> _HARDOX	oceli HARDOX obráběny laserem CO <sub>2</sub>

Tab. 2 Označení měřených vzorků

### 5.1 Nerezová ocel 17 240 a její základní vlastnosti

V případě austenitické oceli ČSN 17 240 (DIN 1.4301) jde o nemagnetický, nekalitelný, materiál, za studena náchylný ke zpevnování, které se způsobuje mechanickým namáháním při jeho opracování, jako je tažení nebo třískové obrábění. Tato ocel vykazuje výbornou odolnost proti korozi ve vodě a v ovzduší bez koncentrace chloridů či anorganických kyselin a solí. Tuto odolnost lze zvýšit leštěním. Má velmi dobré mechanické vlastnosti i při nízkých teplotách. Naopak lze ji použít v provozních teplotách až do výše 350°C. Výše uvedené vlastnosti tento materiál předurčují pro využití v potravinářském, farmaceutickém a kosmetickém průmyslu a také v architektuře při opláštění budov.

### 5.2 Konstrukční ocel 11 375 a její základní vlastnosti

V případě oceli ČSN 11 375 (EN S 235 JRC + N) jde o neušlechtilý materiál s obvyklou jakostí, který je vhodný ke svařování. Běžně se používá na konstrukci a opláštění strojů. Z této oceli se vyrábějí duté svařované profily, součásti vyráběné z plechů či kované součásti. Lze je použít jako tlakové nádoby do teplot 300 °C, spojky a podvozky vagonu apod.




### 5.3 Ušlechtilá ocel Hardox 450 a její základní vlastnosti

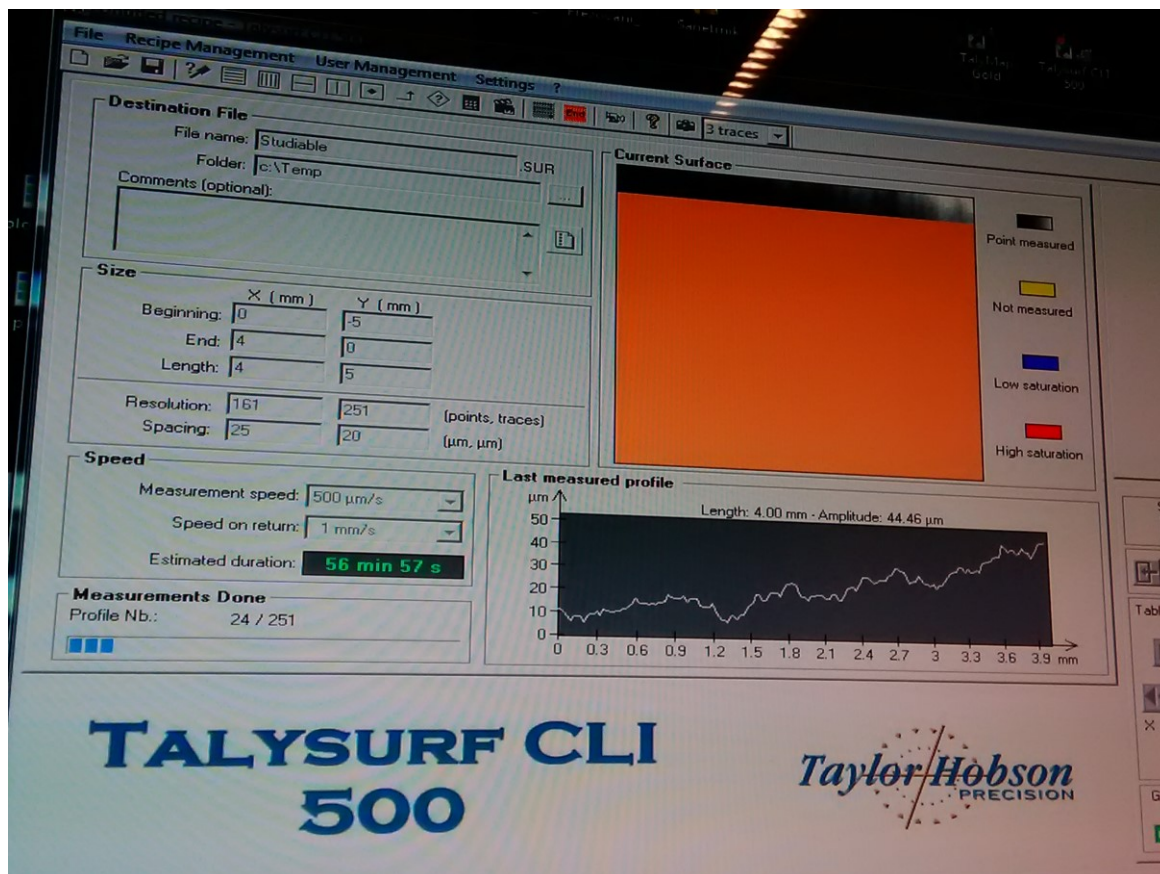
Kalené ocelové plechy z tohoto materiálu vykazují nízký obsah uhlíku a legujících prvků kvůli splnění požadavků na vysokou pevnost a tvrdost se současným zajištěním technologičnosti. Vysokopevnostní a otěruvzdorné oceli mají základní rozdíl při poslední fázi výroby v popouštěcí teplotě. Otěruvzdorné oceli se totiž po kalení nepopouštějí, případně se popouštějí jen do cca 200 °C, což jsou mnohem nižší teploty než u ocelí vysokopevnostních.

## 6 MĚŘICÍ PŘÍSTROJ TAYLOR HOBSON TALYSURF CLI 500

Vzorky byly změřeny drsnoměrem Taylor Hobson Talysurf CLI 500 [17]. Jde o drsnoměr pro bezdotykové měření drsnosti povrchu s univerzálním určením pro všechny materiály a povrchy. Zaznamenává data, která snímá bezdotykovou sondou s konfokální hlavou CLS. Přestože je určen zejména pro 3D měření, dokáže bez potíží změřit i 2D údaje. Firemní program Talymap Gold, který je v základní výbavě, sestaví z bezdotykově získaných dat strukturu měřeného povrchu. Z těchto dat následně vyhodnocuje a znázorňuje graf buď ve 2D nebo 3D souřadném systému a výšky profilu barevně rozliší.



Obr. 22 Měřicí přístroj Talysurf CLI500 – konfigurace při měření



Obr. 23 Měřicí přístroj Talysurf CLI 500 – parametry nastavení

## **II. PRAKTICKÁ ČÁST**


## 7 ÚVOD PRAKTICKÉ ČÁSTI

Cílem této práce bylo navrhnout postup, jak na základě změřených parametrů drsnosti Rz a Ra určit materiál vzorku a způsob, jakým byl vzorek obráběním vyroben.


Data použitá v této práci byla získána proměřením 6 vzorků, z nichž vždy dva byly ze stejného materiálu, přičemž každý z dvojice byl obráběn jinou technologií, a sice laserem CO<sub>2</sub> a vláknovým laserem.

### 7.1 Časové diagramy


Naměřená data byla nejprve zkontrolována pomocí časových diagramů, jestli neobsahují hrubé chyby.



Obr. 24 Časový diagram průběhu parametru Rz pro analyzované vzorky



Obr. 25 Časový diagram průběhu parametru Ra pro analyzované vzorky



Obr. 26 Časový diagram průběhu parametru Rmr pro analyzované vzorky

Z výše uvedených průběhů vyplývá, že data v zásadě odpovídají předpokladům. To znamená, že neobsahují zjevné hrubé chyby měření a jsou ovlivněna pouze náhodnými chybami.

## 7.2 Vliv materiálů na parametry Rz a Ra

V této části měření byl zjišťován vliv materiálu na parametry drsnosti při stejné technologii obrábění. Bylo posuzováno 6 vzorků (po dvou z 1-430, 235 a HARDOX. Z každého materiálu byly dva vzorky, z nichž jeden byl obráběn vláknovým laserem a druhý laserem CO<sub>2</sub>.

Pro test rozptylů tří vzorků, které byly obráběny stejným laserem, byla stanovena pro parametr Rz nulová hypotéza:

- $H_0: \sigma_{Rz F1-430}^2 = \sigma_{Rz F-235}^2 = \sigma_{Rz F-HARDOX}^2$  pro vláknový laser, respektive
- $H_0: \sigma_{Rz CO2\_1-430}^2 = \sigma_{Rz CO2-235}^2 = \sigma_{Rz CO2-HARDOX}^2$ , pro CO<sub>2</sub> laser

a alternativní hypotéza:

- $H_A: \sigma_{Rz F1-430}^2 \neq \sigma_{Rz F-235}^2 \neq \sigma_{Rz F-HARDOX}^2$  pro vláknový laser, respektive
- $H_A: \sigma_{Rz CO2\_1-430}^2 \neq \sigma_{Rz CO2-235}^2 \neq \sigma_{Rz CO2-HARDOX}^2$ , pro CO<sub>2</sub> laser

Stejným způsobem byla stanovena pro parametr Ra nulová hypotéza:

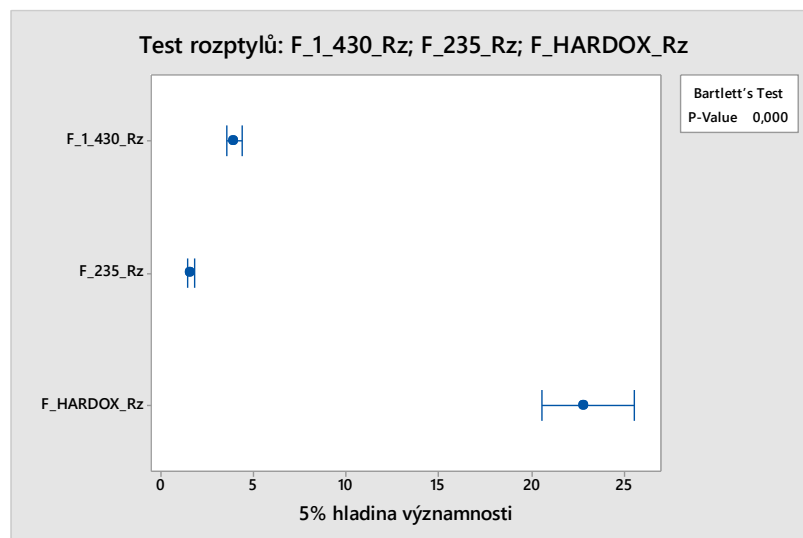
- $H_0: \sigma_{Ra F1-430}^2 = \sigma_{Ra F-235}^2 = \sigma_{Ra F-HARDOX}^2$ , pro vláknový laser, respektive
- $H_0: \sigma_{Ra CO2\_1-430}^2 = \sigma_{Ra CO2-235}^2 = \sigma_{Ra CO2-HARDOX}^2$ , pro CO<sub>2</sub> laser

a alternativní hypotéza:


- $H_A: \sigma_{Ra F1-430}^2 \neq \sigma_{Ra F-235}^2 \neq \sigma_{Ra F-HARDOX}^2$  pro vláknový laser. Respektive
- $H_A: \sigma_{Ra CO2\_1-430}^2 \neq \sigma_{Ra CO2-235}^2 \neq \sigma_{Ra CO2-HARDOX}^2$ , pro CO<sub>2</sub> laser

U obou parametrů byla u všech vzorků zvolena hladina významnosti  $\alpha = 0,050$ .






Obr. 27 Test rozptylů F\_1\_430\_Rz; F\_235\_Rz; F\_HARDOX\_Rz

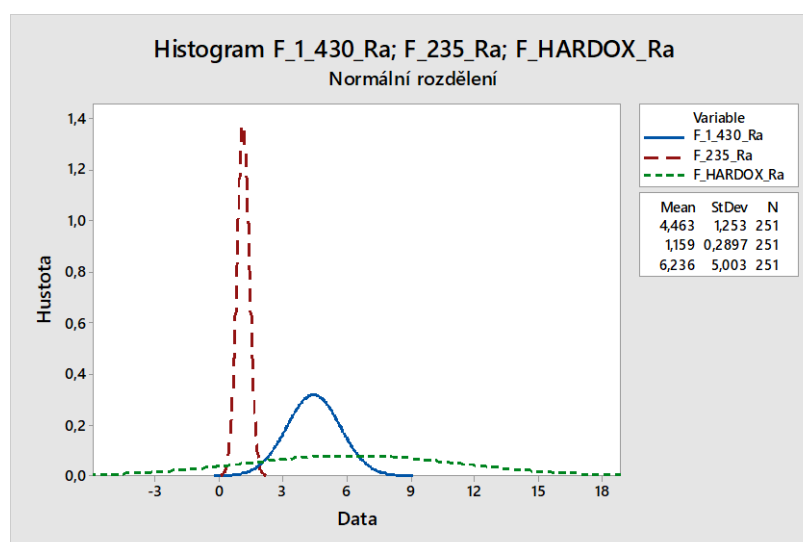


Obr. 28 Test rozptylů F\_1\_430\_Rz; F\_235\_Rz; F\_HARDOX\_Ra

Hodnota  $p$  byla u obou způsobů obrábění zjištěna  $p = 0,000 < \alpha = 0,050$ , z čehož vyplývá, že hypotéza  $H_0$  je zamítnuta, tudíž rozdíl mezi rozptyly hodnot parametrů  $R_z$  a  $R_a$  u daných materiálů při jednom typu technologie obrábění jsou statisticky významně odlišné. Výsledky testů rozptylu byly potvrzeny histogramy, viz následující dva obrázky – obr. 29 a obr. 30. Histogram F\_1\_430\_Rz; F\_235\_Rz; F\_HARDOX\_Rz; normální rozdělení, a obr. Histogram F\_1\_430\_Ra; F\_235\_Ra; F\_HARDOX\_Ra; normální rozdělení.



Obr. 29 Histogram F\_1\_430\_Rz; F\_235\_Rz; F\_HARDOX\_Rz



Obr. 30 Histogram F\_1\_430\_Ra; F\_235\_Ra; F\_HARDOX\_Ra

Druhým krokem analýzy byla analýza one-way (jednocestná) ANOVA (Analysis of Variation), kde byla stanovena nulová hypotéza:

- $H_0: \mu_{Rz F1-430} = \mu_{Rz F-235} = \mu_{Rz F-HARDOX}$  pro vláknový laser, respektive
- $H_0: \mu_{Rz CO2_1-430} = \mu_{Rz CO2-235} = \mu_{Rz CO2-HARDOX}$  pro laser  $CO_2$

a alternativní hypotéza:

- $H_A: \mu_{Rz F1-430} \neq \mu_{Rz F1-235} \neq \mu_{Rz F-HARDOX}$  pro vláknový laser, respektive
- $H_A: \mu_{Rz CO2_1-430} \neq \mu_{Rz CO2-235} \neq \mu_{Rz CO2-HARDOX}$ , pro laser  $CO_2$

Stejným způsobem byly stanoveny nulová hypotéza pro parametr Ra.

- $H_0: \mu_{Ra\ F1-430} = \mu_{Ra\ F1-235} = \mu_{Ra\ F-HARDOX}$  pro vláknový laser, respektive
- $H_0: \mu_{Ra\ CO2_1-430} = \mu_{Ra\ CO2-235} = \mu_{Ra\ CO2-HARDOX}$ , pro laser CO<sub>2</sub>

a alternativní hypotéza:

- $H_A: \mu_{Ra\ F1-430} \neq \mu_{Ra\ F1-235} \neq \mu_{Ra\ F-HARDOX}$  pro vláknový laser, respektive
- $H_A: \mu_{Ra\ CO2_1-430} \neq \mu_{Ra\ CO2-235} \neq \mu_{Ra\ CO2-HARDOX}$ , pro laser CO<sub>2</sub>

U obou parametrů byla u všech vzorků zvolena hladina významnosti  $\alpha = 0,050$ .

Příslušné intervalové diagramy graficky potvrzují výsledky testu.

### **Výpis testu one-way ANOVA: F\_1\_430\_Rz; F\_235\_Rz; F\_HARDOX\_Rz:**

Method

Null hypothesis All means are equal

Alternative hypothesis At least one mean is different

Significance level  $\alpha = 0,05$

Equal variances were not assumed for the analysis.

Factor Information

Factor Levels Values

Factor 3 F\_1\_430\_Rz; F\_235\_Rz; F\_HARDOX\_Rz

Welch's Test

DF

Source Num DF Den F-Value P-Value

Factor 2 383,666 1591,26 0,000

Model Summary

R-sq R-sq(adj) R-sq(pred)

36,67% 36,50% 36,16%

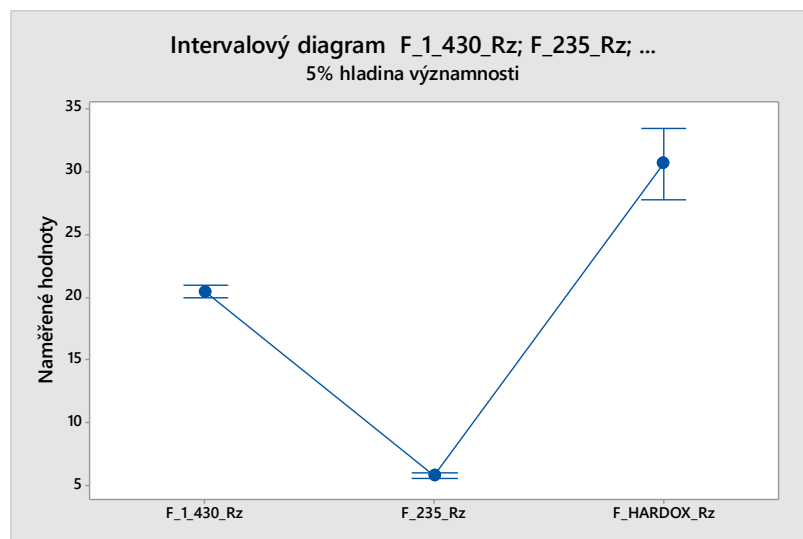
Means

Factor N Mean StDev 95% CI

F\_1\_430\_Rz 251 20,466 3,944 (19,976; 20,956)

F\_235\_Rz 251 5,813 1,660 (5,607; 6,020)

F\_HARDOX\_Rz 251 30,63 22,83 (27,79; 33,47)



Obr. 31 Intervalový diagram F\_1\_430\_Rz; F\_235\_Rz;  
při 5% hladině významnosti

### Výpis testu one-way ANOVA: F\_1\_430\_Ra; F\_235\_Ra; F\_HARDOX\_Ra:

Method

Null hypothesis All means are equal

Alternative hypothesis At least one mean is different

Significance level  $\alpha = 0,05$

Equal variances were not assumed for the analysis.

Factor Information

Factor Levels Values

Factor 3 F\_1\_430\_Ra; F\_235\_Ra; F\_HARDOX\_Ra

Welch's Test

DF

Source Num DF Den F-Value P-Value

Factor 2 351,258 947,04 0,000


Model Summary

R-sq R-sq(adj) R-sq(pred)

33,32% 33,14% 32,78%

Means

Factor	N	Mean	StDev	95% CI
F_1_430_Ra	251	4,4633	1,2531	(4,3076; 4,6191)
F_235_Ra	251	1,1589	0,2897	(1,1229; 1,1950)
F_HARDOX_Ra	251	6,236	5,003	(5,614; 6,858)



Obr. 32 Intervalový diagram F\_1\_430\_Rz; F\_235\_Ra;  
při 5% hladině významnosti

Výsledky analýzy naměřených hodnot pro vzorky obráběné laserem CO<sub>2</sub> jsou uvedeny v příloze P I.

U obou parametrů, Rz i Ra, byly hodnoty p pro test středních hodnot ANOVA  $p = 0,000 < \alpha = 0,050$ , z čehož vyplývá zamítnutí nulové hypotézy  $H_0$ . Závěrem lze říci, že ve zkoumaném příkladu má materiál statisticky významný vliv na průměrné hodnoty parametrů Rz a Ra.

### Shrnutí výsledků testů zkoumající vliv materiálu na parametry Rz, Ra

	<b>H<sub>0</sub></b>	<b>H<sub>A</sub></b>	<b>p-value</b>
<b>Rz</b>	$\sigma_{Rz F1-430}^2 = \sigma_{Rz F-235}^2 =$ $\sigma_{Rz F-HARDOX}^2$	$\sigma_{Rz F1-430}^2 \neq \sigma_{Rz F-235}^2 \neq$ $\sigma_{Rz F-HARDOX}^2$	0,000
	$\mu_{Rz F1-430} = \mu_{Rz F1-235} =$ $\mu_{Rz F-HARDOX}$	$\mu_{Rz F1-430} \neq \mu_{Rz F1-235} \neq$ $\mu_{Rz F-HARDOX}$	0,000
	$\sigma_{Rz CO2\_1-430}^2 = \sigma_{Rz CO2-235}^2 =$ $\sigma_{Rz CO2-HARDOX}^2$	$\sigma_{Rz CO2\_1-430}^2 \neq \sigma_{Rz CO2-235}^2 \neq$ $\sigma_{Rz CO2-HARDOX}^2$	0,000
	$\mu_{Rz CO2\_1-430} = \mu_{Rz CO2-235} =$ $\mu_{Rz CO2-HARDOX}$	$\mu_{Rz CO2\_1-430} \neq \mu_{Rz CO2-235} \neq$ $\mu_{Rz CO2-HARDOX}$	0,000
<b>Ra</b>	$\sigma_{Ra F1-430}^2 = \sigma_{Ra F-235}^2 =$ $\sigma_{Ra F-HARDOX}^2$	$\sigma_{Ra F1-430}^2 \neq \sigma_{Ra F-235}^2 \neq$ $\sigma_{Ra F-HARDOX}^2$	0,000
	$\mu_{Ra F1-430} = \mu_{Ra F1-235} =$ $\mu_{Ra F-HARDOX}$	$\mu_{Ra F1-430} \neq \mu_{Ra F1-235} \neq$ $\mu_{Ra F-HARDOX}$	0,000
	$\sigma_{Ra CO2\_1-430}^2 = \sigma_{Ra CO2-235}^2 =$ $\sigma_{Ra CO2-HARDOX}^2$	$\sigma_{Ra CO2\_1-430}^2 \neq \sigma_{Ra CO2-235}^2 \neq$ $\sigma_{Ra CO2-HARDOX}^2$	0,000
	$\mu_{Ra CO2\_1-430} = \mu_{Ra CO2-235} =$ $\mu_{Ra CO2-HARDOX}$	$\mu_{Ra CO2\_1-430} \neq \mu_{Ra CO2-235} \neq$ $\mu_{Ra CO2-HARDOX}$	0,000

Tab. 3 Výsledky testů vlivu materiálu daných vzorků na parametry Rz a Ra

Z výše uvedené tabulky vyplývá, že u všech testů byla zamítnuta nulová hypotéza, protože hodnota p byla vždy menší než  $\alpha$ . Tudíž lze zobecnit, že typ materiálu statisticky významně ovlivňuje parametry drsnosti Rz a Ra.

### 7.3 Porovnání vlivu použité technologie na parametry Rz a Ra vzorku

V této části měření byly porovnávány parametry Rz a Ra pro dvojici vzorků ze stejného materiálu, z nichž jeden vzorek byl obráběn vláknovým laserem a druhý laserem CO<sub>2</sub>.

Nejprve byla data vyhodnocena pomocí F-testu, kde byla stanovena pro parametr Rz nulová hypotéza:

- $H_0: \sigma_{Rz F1-430}^2 = \sigma_{Rz CO2 1-430}^2$  pro materiál 1-430, respektive
- $H_0: \sigma_{Rz F235}^2 = \sigma_{Rz CO2_235}^2$  pro materiál 235, respektive
- $H_0: \sigma_{Rz F\_HARDOX}^2 = \sigma_{Rz CO2 HARDOX}^2$  pro materiál HARDOX

a alternativní hypotéza:

- $H_A: \sigma_{Rz F1-430}^2 \neq \sigma_{Rz CO2 1-430}^2$  pro materiál 1-430, respektive
- $H_A: \sigma_{Rz F235}^2 \neq \sigma_{Rz CO2_235}^2$  pro materiál 235, respektive
- $H_A: \sigma_{Rz F\_HARDOX}^2 \neq \sigma_{Rz CO2 HARDOX}^2$  pro materiál HARDOX


Stejným způsobem byla stanovena pro parametr Ra nulová hypotéza:

- $H_0: \sigma_{Ra F1-430}^2 = \sigma_{Ra CO2 1-430}^2$  pro materiál 1-430, respektive
- $H_0: \sigma_{Ra F235}^2 = \sigma_{Ra CO2_235}^2$  pro materiál 235, respektive
- $H_0: \sigma_{Ra F\_HARDOX}^2 = \sigma_{Ra CO2 HARDOX}^2$  pro materiál HARDOX

a alternativní hypotéza:


- $H_A: \sigma_{Ra F1-430}^2 \neq \sigma_{Ra CO2 1-430}^2$  pro materiál 1-430, respektive
- $H_A: \sigma_{Ra F_235}^2 \neq \sigma_{Ra CO2_235}^2$  pro materiál 235, respektive
- $H_A: \sigma_{Ra F\_HARDOX}^2 \neq \sigma_{Ra CO2 HARDOX}^2$  pro materiál HARDOX

U obou parametrů byla u všech vzorků zvolena hladina významnosti  $\alpha = 0,050$ .



Obr. 33 Test a hladina významnosti pro dva rozptyly:

F\_1\_430; CO<sub>2</sub>\_1\_430 pro parametr Rz

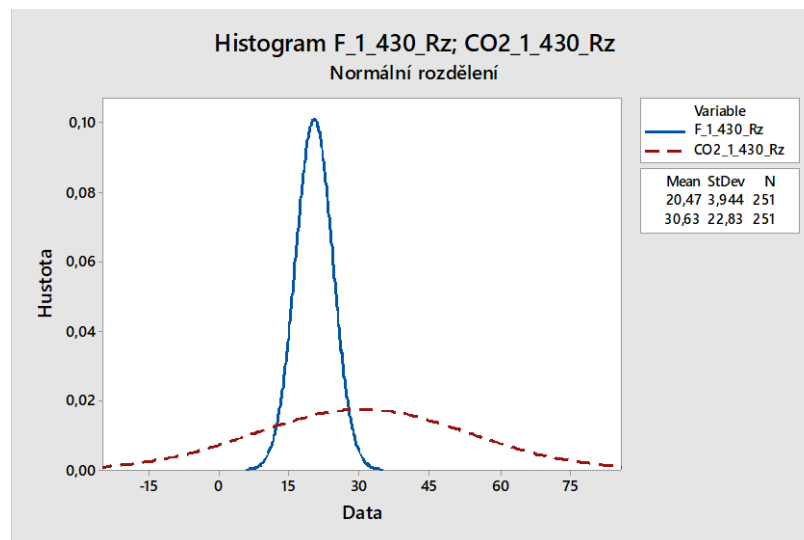


Obr. 34 Test a hladina významnosti pro dva rozptyly:


F\_1\_430; CO<sub>2</sub>\_1\_430 pro parametr Ra



Hodnota  $p$  byla zjištěna  $p = 0,000$ ,  $< \alpha = 0,050$ , z čehož vyplývá, že hypotéza  $H_0$  je zamítnuta, tudíž rozdíl v rozptylech mezi vzorky z téhož materiálu, které jsou obráběny různými typy laserů (vláknovým laserem a laserem  $CO_2$ ) je pro parametry Rz a Ra statisticky významný. Výsledky testů rozptylu byly potvrzeny histogramy, viz následující dva histogramy.



Obr. 35 Histogram F\_1\_430 Rz; CO<sub>2</sub>\_1\_430\_Rz



Obr. 36 Histogram F\_1\_430 Ra; CO<sub>2</sub>\_1\_430\_Ra

Dalším krokem analýzy byl T-test pro dvojici vzorků ze stejného materiálu, kde byla stanovena nulová hypotéza:

- $H_0: \mu_{Rz F_{1-430}} = \mu_{Rz CO2_{1-430}}$  pro materiál 1-430, respektive
- $H_0: \mu_{Rz F_{235}} = \mu_{Rz CO2_{235}}$  pro materiál 235, respektive
- $H_0: \mu_{Rz F_{HARDOX}} = \mu_{Rz CO2_{HARDOX}}$  pro materiál HARDOX

a alternativní hypotéza:

- $H_A: \mu_{Rz F_{1-430}} \neq \mu_{Rz CO2_{1-430}}$  pro materiál 1-430, respektive
- $H_A: \mu_{Rz F_{235}} \neq \mu_{Rz CO2_{235}}$  pro materiál 235, respektive
- $H_A: \mu_{Rz F_{HARDOX}} \neq \mu_{Rz CO2_{HARDOX}}$  pro materiál HARDOX

Stejným způsobem byly stanoveny nulová a alternativní hypotéza pro parametr Ra:

- $H_0: \mu_{Ra F_{1-430}} = \mu_{Ra CO2_{1-430}}$  pro materiál 1-430, respektive
- $H_0: \mu_{Ra F_{235}} = \mu_{Ra CO2_{235}}$  pro materiál 235, respektive
- $H_0: \mu_{Ra F_{HARDOX}} = \mu_{Ra CO2_{HARDOX}}$  pro materiál HARDOX

a alternativní hypotéza:

- $H_A: \mu_{Ra F_{1-430}} \neq \mu_{Ra CO2_{1-430}}$  pro materiál 1-430, respektive
- $H_A: \mu_{Ra F_{235}} \neq \mu_{Ra CO2_{235}}$  pro materiál 235, respektive
- $H_A: \mu_{Ra F_{HARDOX}} \neq \mu_{Ra CO2_{HARDOX}}$  pro materiál HARDOX
- 

U obou parametrů byla u všech vzorků zvolena hladina významnosti  $\alpha = 0,050$ .

### Výpis testu Two-Sample T-Test and CI: F\_1\_430\_Rz; CO2\_1\_430\_Rz:

Two-sample T for F\_1\_430\_Rz vs CO2\_1\_430\_Rz

	N	Mean	StDev	SE Mean
F_1_430_Rz	251	20,47	3,94	0,25
CO2_1_430_Rz	251	30,6	22,8	1,4

Difference =  $\mu$  (F\_1\_430\_Rz) -  $\mu$  (CO2\_1\_430\_Rz)

Estimate for difference: -10,16

95% CI for difference: (-13,04; -7,28)

T-Test of difference = 0 (vs  $\neq$ ): T-Value = -6,95 P-Value = 0,000 DF = 264

### Výpis testu Two-Sample T-Test and CI: F\_1\_430\_Ra; CO2\_1\_430\_Ra:

Two-sample T for F\_1\_430\_Ra vs CO2\_1\_430\_Ra

	N	Mean	StDev	SE Mean
F_1_430_Ra	251	4,46	1,25	0,079
CO2_1_430_Ra	251	6,24	5,00	0,32

Difference =  $\mu$  (F\_1\_430\_Ra) -  $\mu$  (CO2\_1\_430\_Ra)

Estimate for difference: -1,772

95% CI for difference: (-2,413; -1,132)

T-Test of difference = 0 (vs  $\neq$ ): T-Value = -5,44 P-Value = 0,000 DF = 281

Výsledky pro zbylé dva materiály jsou uvedeny v příloze P II.

Hodnota p byla zjištěna  $p = 0,000$ ,  $< \alpha = 0,050$ , z čehož vyplývá, že hypotéza  $H_0$  je zamítnuta, tudíž rozdíl středních hodnot mezi vzorky z téhož materiálu které jsou obráběny různými typy laserů (vláknovým laserem a laserem  $CO_2$ ) je pro parametry Rz a Ra statisticky významně odlišný.

### Shrnutí výsledků testů vlivu použité technologie na hodnoty parametrů Rz a Ra

	<b>H<sub>0</sub></b>	<b>H<sub>A</sub></b>	<b>p-value</b>
<b>Rz</b>	$\sigma_{Ra\ F1-430}^2 = \sigma_{Ra\ CO2\ 1-430}^2$	$\sigma_{Rz\ F1-430}^2 \neq \sigma_{Rz\ CO2\ 1-430}^2$	0,000
	$\mu_{Rz\ F_1-430} = \mu_{Rz\ CO2_1-430}$	$\mu_{Rz\ F_1-430} \neq \mu_{Rz\ CO2_1-430}$	0,000
	$\sigma_{Rz\ F235}^2 = \sigma_{Rz\ CO2_235}^2$	$\sigma_{Rz\ F235}^2 \neq \sigma_{Rz\ CO2_235}^2$	0,000
	$\mu_{Rz\ F_235} = \mu_{Rz\ CO2_235}$	$\mu_{Rz\ F_235} \neq \mu_{Rz\ CO2_235}$	0,000
	$\sigma_{Rz\ F\_HARDOX}^2 =$ $\sigma_{Rz\ CO2\ HARDOX}^2$	$\sigma_{Rz\ F\_HARDOX}^2 \neq$ $\sigma_{Rz\ CO2\ HARDOX}^2$	0,000
	$\mu_{Rz\ F\_HARDOX} =$ $\mu_{Rz\ CO2\_HARDOX}$	$\mu_{Rz\ F\_HARDOX} \neq$ $\mu_{Rz\ CO2\_HARDOX}$	0,000
<b>Ra</b>	$\sigma_{Ra\ F1-430}^2 = \sigma_{Ra\ CO2\ 1-430}^2$	$\sigma_{Ra\ F1-430}^2 \neq \sigma_{Ra\ CO2\ 1-430}^2$	0,000
	$\mu_{Ra\ F_1-430} = \mu_{Ra\ CO2_1-430}$	$\mu_{Ra\ F_1-430} \neq \mu_{Ra\ CO2_1-430}$	0,000
	$\sigma_{Ra\ F235}^2 = \sigma_{Ra\ CO2_235}^2$	$\sigma_{Ra\ F_235}^2 \neq \sigma_{Ra\ CO2_235}^2$	0,000
	$\mu_{Ra\ F_235} = \mu_{Ra\ CO2_235}$	$\mu_{Ra\ F_235} \neq \mu_{Ra\ CO2_235}$	0,000
	$\sigma_{Ra\ F\_HARDOX}^2 =$ $\sigma_{Ra\ CO2\ HARDOX}^2$	$\sigma_{Ra\ F\_HARDOX}^2 \neq$ $\sigma_{Ra\ CO2\ HARDOX}^2$	0,000
	$\mu_{Ra\ F\_HARDOX} =$ $\mu_{Ra\ CO2\_HARDOX}$	$\mu_{Ra\ F\_HARDOX} \neq$ $\mu_{Ra\ CO2\_HARDOX}$	0,000

Tab. 4 Výsledná tabulka – výsledky testů vlivů použité technologie obrábění

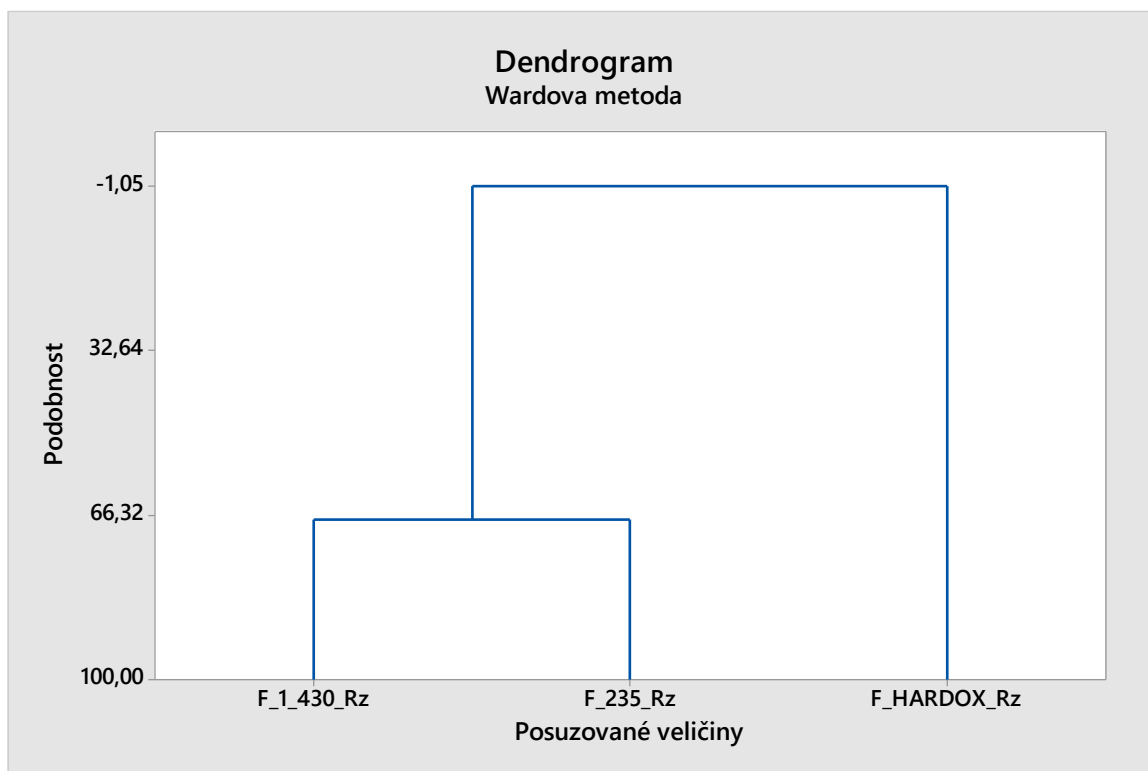
Z tabulky je zřejmé, že u obou parametrů, Rz i Ra, byly hodnoty  $p = 0,000 < \alpha = 0,050$ , z čehož vyplývá zamítnutí nulové hypotézy  $H_0$ . Z toho plyne, že použitá technologie má statisticky významný vliv na průměrné hodnoty parametrů Rz a Ra.

### 7.3.1 Vyhodnocení parametrů Rz a Ra

Nulovou hypotézu lze zamítnout na základě výše uvedených tabulek 4 kvůli skutečnosti, že  $\alpha$  je vždy větší než hodnota  $p$ . Tudiž vzorky z různých materiálů nebo obráběné různými technologiemi se z hlediska parametrů drsnosti Rz a Ra statisticky významně liší. Toto zjištění implikuje další úvahu, zda lze tuto odlišnost využít pro určení materiálu vzorku na základě známých parametrů Rz a Ra.

### 7.4 Shluková analýza

Tento krok datové analýzy měl za cíl zjistit, zda data vykazují nějakou podobnost a pokud ano, tuto podobnost blíže popsat. Jelikož je zkoumána možnost určit použitý materiál pomocí naměřených parametrů drsnosti, porovnávají se pouze vzorky obráběné stejnou technologií. Pro vlastní analýzu byla použita Wardova metoda.



Obr. 37 Shluková analýza vzorků obráběných vláknovým laserem – parametr Rz

## Výpis shlukové analýzy (Cluster Analysis of Variables):


**F\_1\_430\_Rz; F\_235\_Rz; F\_HARDOX\_Rz**

Correlation Coefficient Distance, Ward Linkage

Amalgamation Steps

		Number					
		of obs.					
	Number of	Similarity	Distance	Clusters	New	in	new
Step	clusters	level	level	joined	cluster	cluster	
1	2	67,2571	0,65486	1 2	1	2	
2	1	-1,0455	2,02091	1 3	1	3	

Porovnáním parametrů Rz u vzorků obráběných vláknovým laserem bylo zjištěno, že vzorky F\_1\_430 a F\_235 jsou podobné s vysokou úrovní podobnosti, kdežto vzorek F\_HARDOX vykazuje odlišnost.



Obr. 38 Shluková analýza vzorků obráběných vláknovým laserem – parametr Ra



#### 7.4.1 Shrnutí shlukové analýzy dat

Následující dvě tabulky ukazují úrovně podobnosti vzorků obráběných vláknovým laserem a laserem CO<sub>2</sub>:

<b>Vláknový laser</b>		
<b>Shluk</b>	F_1_430 + F_235	F_HARDOX
<b>Rz</b>	67,2571	-1,0475
<b>Ra</b>	71,4731	-9,3357


Tab. 5 Úrovně podobnosti vzorků obráběných vláknovým laserem

<b>Laser CO<sub>2</sub></b>		
<b>Shluk</b>	F_1_430	CO2_235 +
<b>Rz</b>	59,7677	88,7200
<b>Ra</b>	52,3875	91,5500

Tab. 6 Úrovně podobnosti vzorků obráběných laserem CO<sub>2</sub>

Z tabulek vyplývá, že v případě obrábění vláknovým laserem, vzorky F1\_430 a F\_235 vykazují větší podobnost a vzorek F\_HARDOX se liší. Při použití CO<sub>2</sub> laseru se naopak lišil vzorek CO2\_1\_430 od vzorků CO2\_235 a CO2\_HARDOX, a to jak u parametru Rz, tak u parametru Ra. Proto byly ještě všechny vzorky porovnány dohromady.





Obr. 39 Porovnání podobnosti všech vzorků na základě parametru Rz

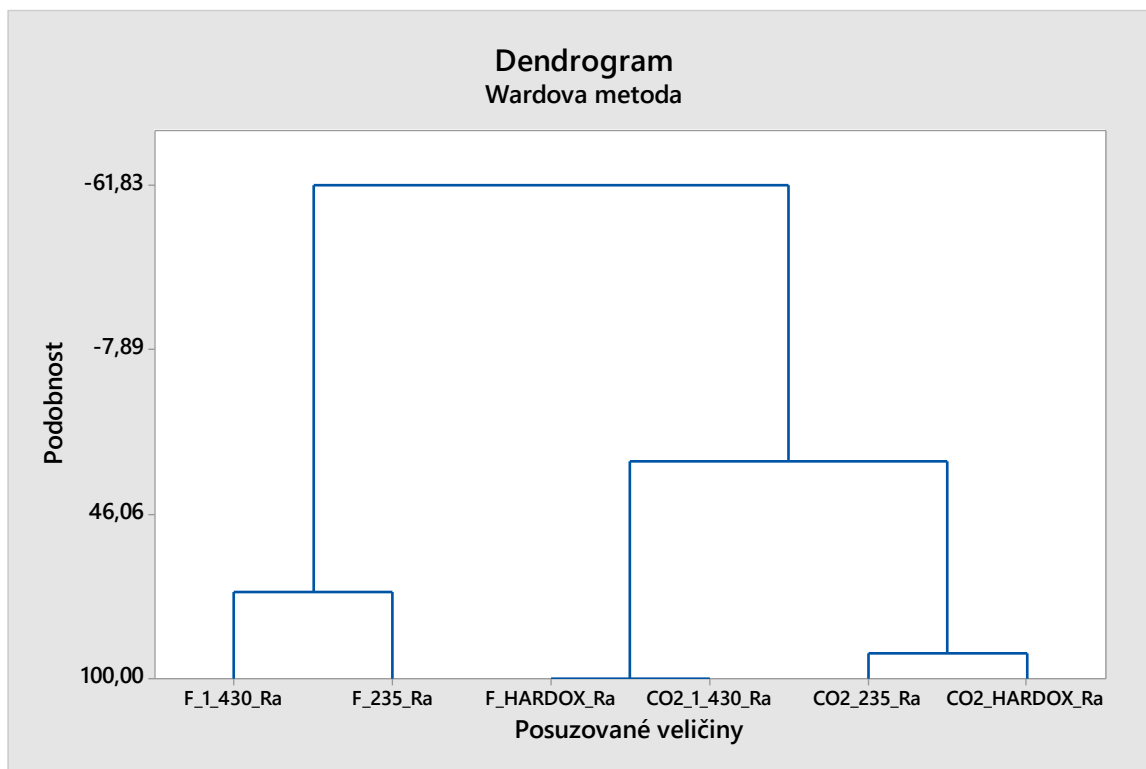
### Výpis shlukové analýzy (Cluster Analysis of Variables):

**F\_1\_430\_Rz; F\_235\_Rz; F\_HARDOX\_Rz; CO2\_1\_430\_Rz; ...**

Correlation Coefficient Distance, Ward Linkage

Amalgamation Steps

Step	clusters	level	level	joined	Number of obs.		
					cluster	cluster	cluster
1	5	100,000	0,00000	3	4	3	2
2	4	88,720	0,22560	5	6	5	2
3	3	67,257	0,65486	1	2	1	2
4	2	39,652	1,20697	3	5	3	4
5	1	-57,218	3,14437	1	3	1	6



Obr. 40 Porovnání podobnosti všech vzorků na základě parametru Ra

### Výpis shlukové analýzy (Cluster Analysis of Variables):

**F\_1\_430\_Ra; F\_235\_Ra; F\_HARDOX\_Ra; CO2\_1\_430\_Ra; ...**

Correlation Coefficient Distance, Ward Linkage

Amalgamation Steps

	Number		of obs.		Number of Similarity		Distance		Clusters		New in new	
Step	clusters	level	level	joined	cluster	cluster						
1	5	100,000	0,00000	3	4	3	2					
2	4	91,550	0,16900	5	6	5	2					
3	3	71,473	0,57054	1	2	1	2					
4	2	28,581	1,42837	3	5	3	4					
5	1	-61,829	3,23658	1	3	1	6					

Tento krok analýzy potvrdil podobnost výše zmiňovaných dvojic vzorků a navíc ukázal, že odlišné vzorky (F\_HARDOX a CO2\_1\_430) tvoří shluk s podobností 100, a to pro oba

uvažované parametry. Pokud by tedy určení materiál vzorku vycházelo pouze ze statistického vyhodnocení parametrů Rz a Ra, hrozila by tudíž záměna u dvojice vzorků F1\_430 a F\_235, a u dvojice vzorků CO2\_235 a CO2\_HARDOX.

## 7.5 Neuronová síť


Předchozí testy ukázaly, že vždy dva materiály mají parametry drsnosti podobné natolik, že nelze pouze na základě naměřených hodnot  $R_z$  a  $R_a$  určit materiál s dostatečnou spolehlivostí. Proto při dalším rozhodování byl uvažován i parametr  $R_{mr}$ . Pro vlastní určení materiálu vzorku byla navržena neuronová síť ve formě perceptronu s jednou skrytou vrstvou.

Pro sestavení vlastní sítě byl použit program Statistica 13. Nejprve byl odhadnut počet neuronů ve skryté vrstvě podle vzorce

$$\frac{2 \cdot (n_1 + n_2)}{2}, \text{ kde}$$

- $n_1$  je počet neuronů ve vstupní vrstvě
- $n_2$  je počet neuronů ve výstupní vrstvě

Po dosazení do výše uvedeného vztahu vyšel počet neuronů roven 6. Na základě tohoto teoretického odhadu by síť vypadala podle obrázku 41.



Obr. 41 Perceptron s šesti neurony ve skryté vrstvě

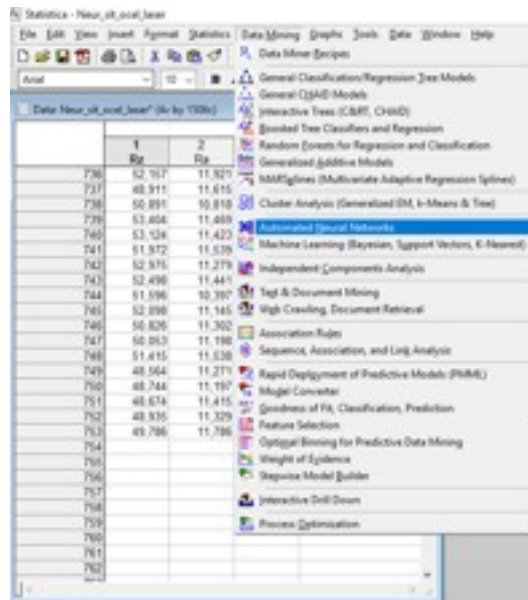
Pro každý typ použité obráběcí technologie byla sestavena neuronová síť, která byla trénovaná na trénovací množině dat. Tato množina obsahovala 753 uspořádaných trojic

[Rz; Ra; Rmr], což byly naměřené hodnoty těchto parametrů drsnosti na všech vzorcích obráběných stejným způsobem, viz obr 42.

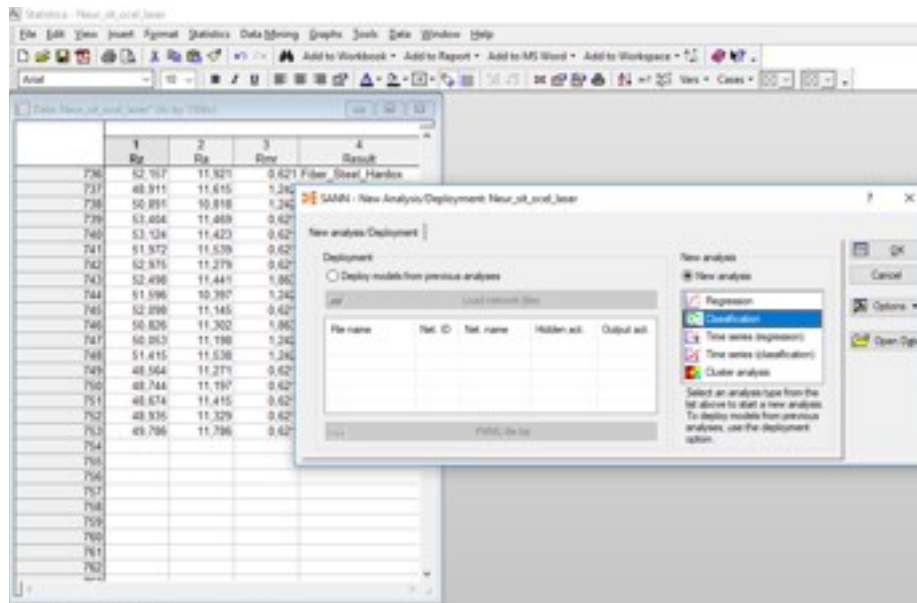
	1	2	3	4
	Rz	Ra	Rmr	Result
1	20,748	5,222	0,621	Fiber_Steel_430
2	21,622	5,295	0,621	Fiber_Steel_430
3	21,543	5,308	1,963	Fiber_Steel_430
4	21,721	4,969	1,963	Fiber_Steel_430
5	21,864	4,989	0,621	Fiber_Steel_430
6	22,526	5,212	1,242	Fiber_Steel_430
7	22,415	5,218	1,242	Fiber_Steel_430
8	21,864	5,642	2,484	Fiber_Steel_430
9	23,413	5,956	0,751	Fiber_Steel_430
10	20,502	4,902	0,621	Fiber_Steel_430
11	23,993	5,369	1,242	Fiber_Steel_430
12	21,787	5,215	1,242	Fiber_Steel_430
13	20,931	5,056	1,242	Fiber_Steel_430
14	22,271	5,454	0,621	Fiber_Steel_430
15	21,738	5,677	1,242	Fiber_Steel_430
16	19,402	5,377	1,242	Fiber_Steel_430
17	20,638	5,618	1,963	Fiber_Steel_430
18	20,732	5,265	1,242	Fiber_Steel_430
19	20,363	4,797	0,621	Fiber_Steel_430
20	18,608	4,637	1,963	Fiber_Steel_430
21	20,316	4,744	1,242	Fiber_Steel_430
22	20,96	4,791	2,484	Fiber_Steel_430
23	19,641	4,48	3,126	Fiber_Steel_430
24	20,355	4,905	1,963	Fiber_Steel_430
25	19,217	5,08	2,484	Fiber_Steel_430
26	21,871	5,236	1,963	Fiber_Steel_430
27	22,275	5,613	0,621	Fiber_Steel_430
736	52,767	11,921	0,621	Fiber_Steel_Hardox
737	48,911	11,615	1,242	Fiber_Steel_Hardox
738	50,891	10,818	1,242	Fiber_Steel_Hardox
739	53,404	11,469	0,621	Fiber_Steel_Hardox
740	53,124	11,423	0,621	Fiber_Steel_Hardox
741	51,972	11,539	0,621	Fiber_Steel_Hardox
742	52,975	11,279	0,621	Fiber_Steel_Hardox
743	52,498	11,441	1,963	Fiber_Steel_Hardox
744	51,596	10,397	1,242	Fiber_Steel_Hardox
745	52,298	11,145	0,621	Fiber_Steel_Hardox
746	50,826	11,302	1,963	Fiber_Steel_Hardox
747	50,263	11,198	1,242	Fiber_Steel_Hardox
748	51,415	11,538	1,242	Fiber_Steel_Hardox
749	48,564	11,271	0,621	Fiber_Steel_Hardox
750	48,744	11,197	0,621	Fiber_Steel_Hardox
751	48,674	11,415	0,621	Fiber_Steel_Hardox
752	48,935	11,329	0,621	Fiber_Steel_Hardox
753	49,796	11,796	0,621	Fiber_Steel_Hardox
754				
755				
756				
757				
758				
759				
760				
761				
762				

Obr. 42 Trénovací množina dat

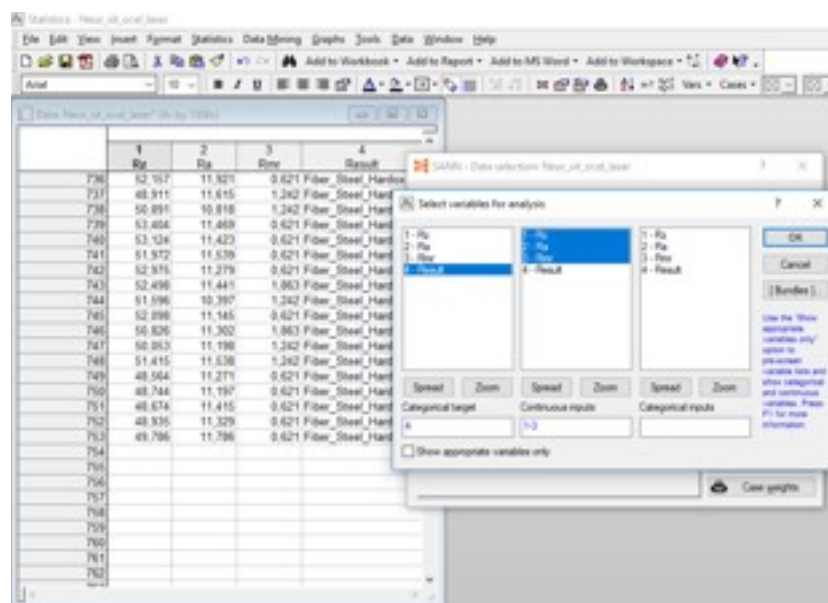
Pro zadané hodnoty byla v programu Statistica 13 vygenerována neuronová síť a provedena klasifikační analýza ve třech krocích pro parametry Rz, Ra Rmr, viz obr. 43.



Obr. 43 Klasifikační analýza pro zadané parametry Rz, Ra Rmr – krok č. 1



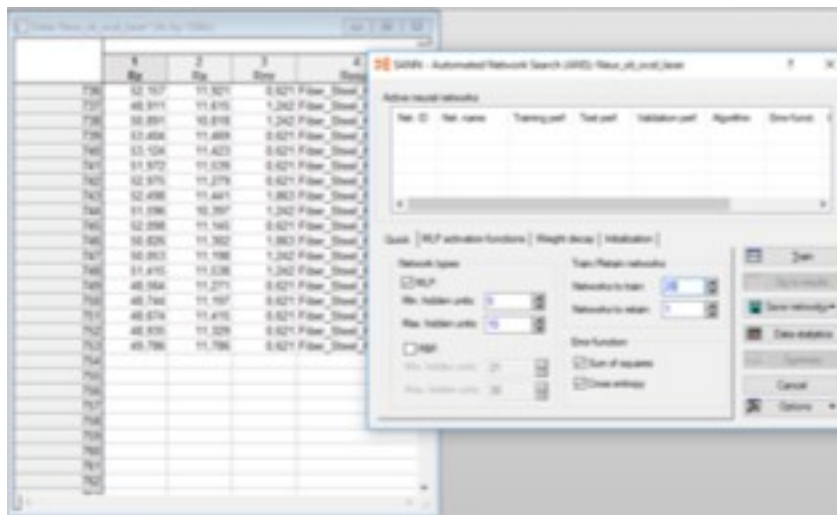
Obr. 44 Klasifikační analýza pro zadané parametry Rz, Ra Rmr – krok č. 2



Obr. 45 Klasifikační analýza pro zadané parametry Rz, Ra Rmr – krok č. 3

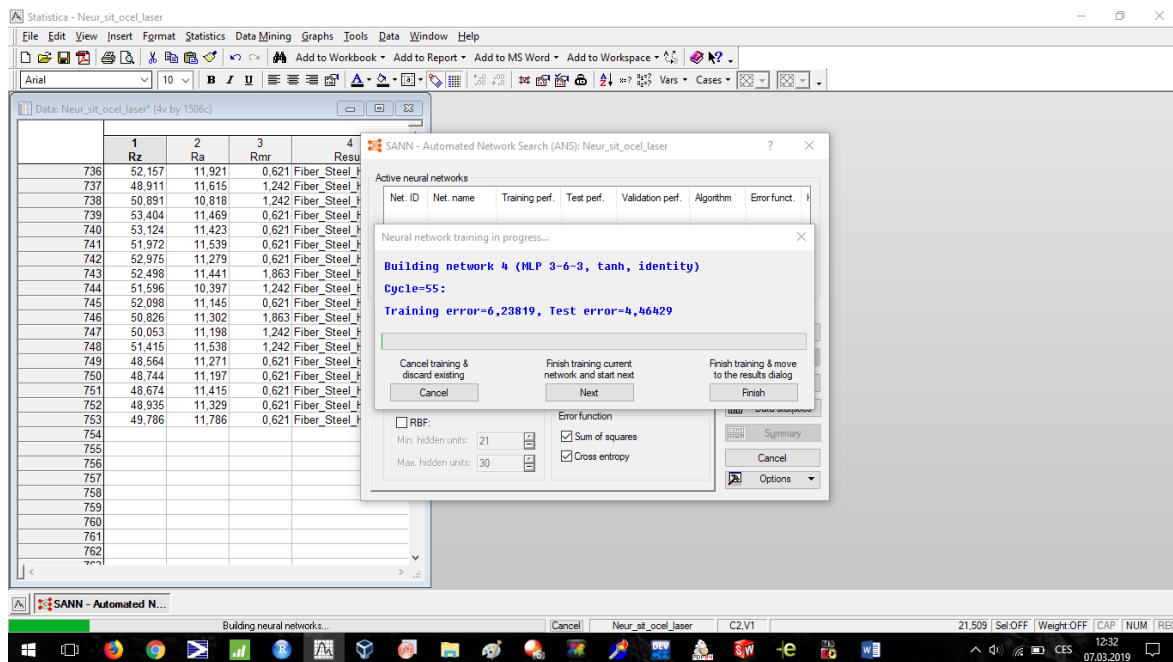
Dále byly s ohledem na odhad struktury sítě nastaveny parametry pro výpočet. Dle uvedeného heuristického pravidla byl zvolen minimální počet neuronů skryté vrstvy 5 a maximální počet těchto neuronů 10. S těmito parametry bylo nalezeno 20 neuronových sítí. Tento počet byl zvolen kvůli časové náročnosti procedury. Z vygenerovaných 20 sítí byla

nalezena jedna, která poskytuje „nejlepší“ výsledky. To znamená, že kvadratická chyba bude minimální a strmost učení nejvyšší.

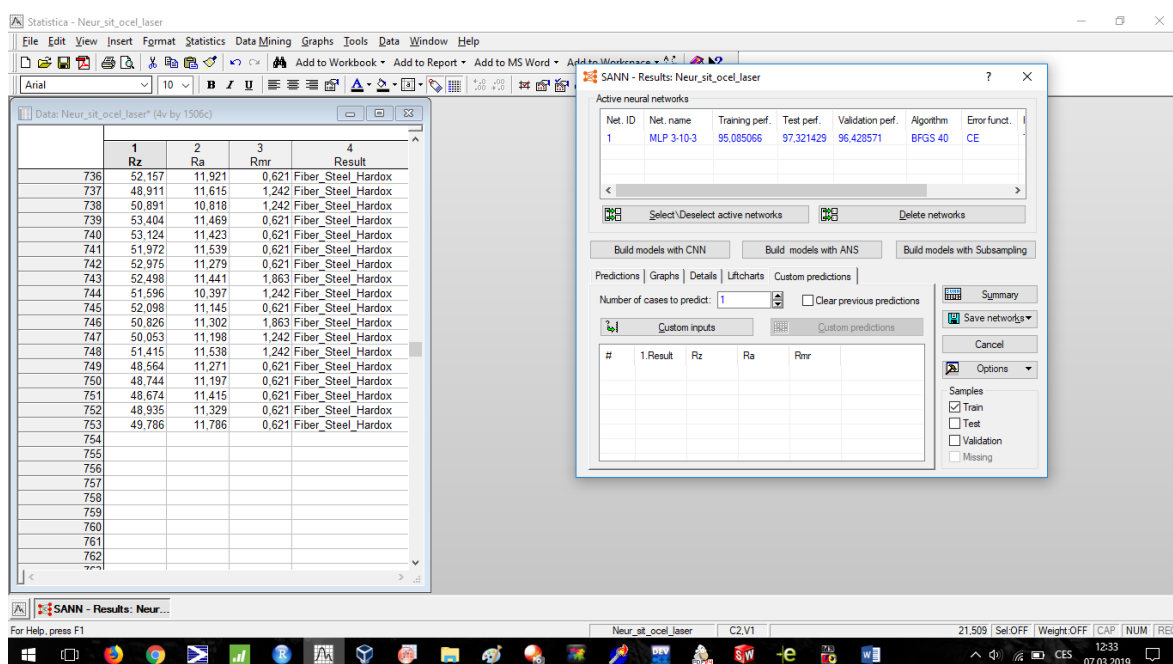


Obr. 46 Zadání parametrů sítě

Následující obrázky dokumentují výsledky učení sítě. Na obrázku 47 je původně navržená síť se šesti neurony ve skryté vrstvě, kterou program Statistica 13 odmítl, jelikož dávala horší výsledky než tímto programem navržená síť na obr. 48. Pro vzorky obráběné vláknovým laserem byla vygenerována síť s deseti neurony ve skryté vrstvě, která vykazuje pravděpodobnost chybného výsledku cca 2,3 %. Pro CO<sub>2</sub> laser byla jako nejvhodnější určena síť s pěti neurony ve skryté vrstvě viz příloha P IV.



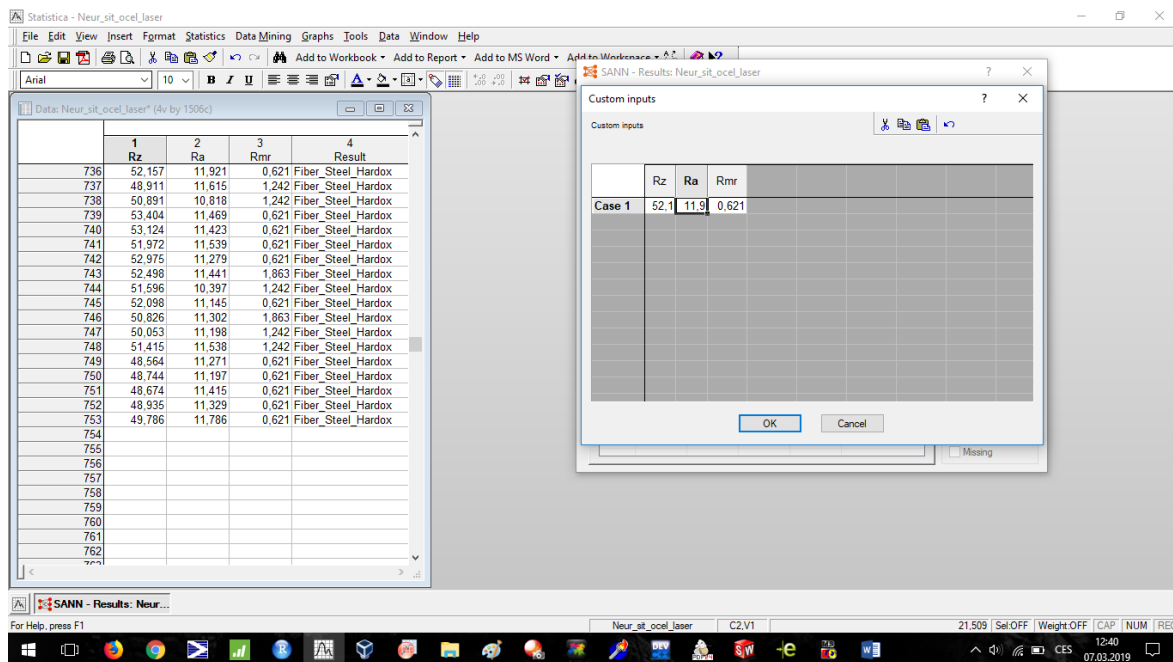
Obr. 47 Odmítnutí navrhované sítě s šesti neurony ve skryté vrstvě



Obr. 48 Programem vygenerovaná síť s deseti neurony ve skryté vrstvě

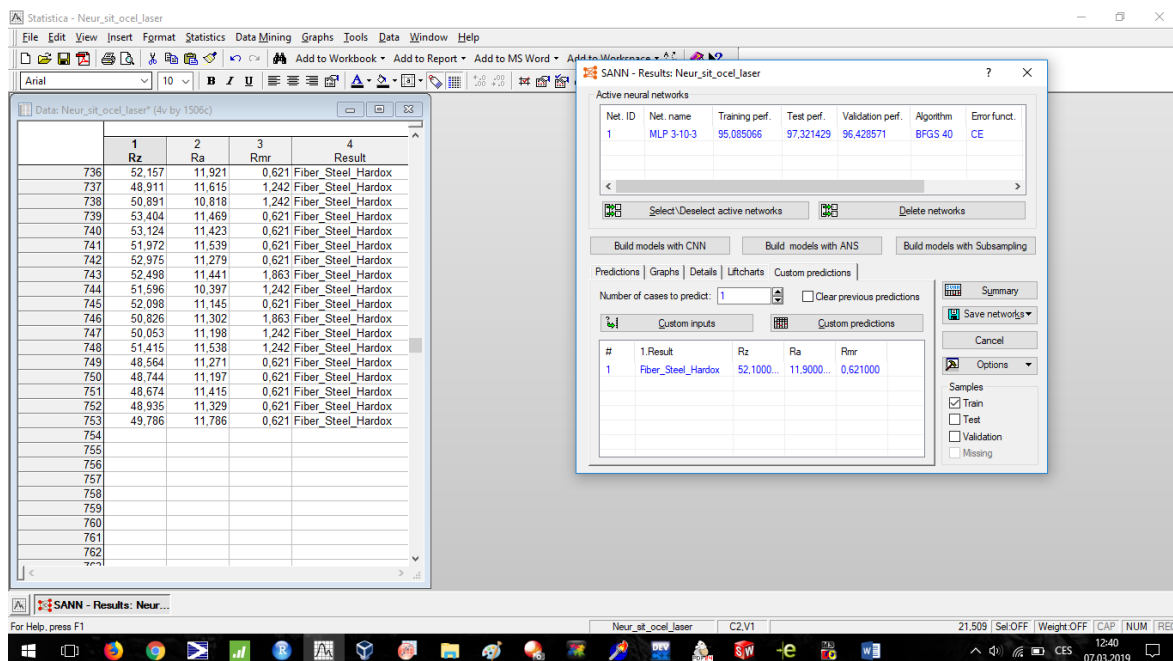
Hodnoty parametrů byly zadány ručně tak, aby bylo možné otestovat rozhodovací schopnosti sítě. Síť poté vyhodnotila, jaký materiál byl použit. Na obrázku 49 je vidět ruční zadání vstupních parametrů drsnosti Rz, Ra a Rmr.





Obr. 49 Zadávání vstupních parametrů Rz, Ra a Rmr

Na obrázku 50 pak je vidět správné vyhodnocení posuzovaného materiálu.

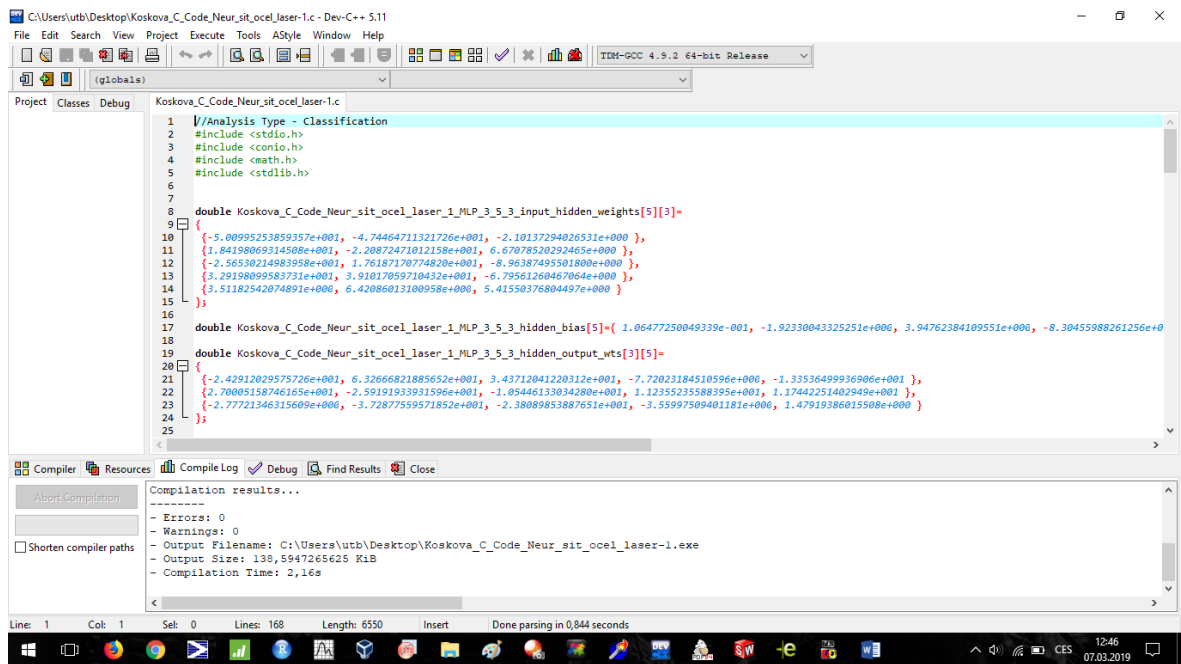


Obr. 50 Vyhodnocení posuzovaného materiálu

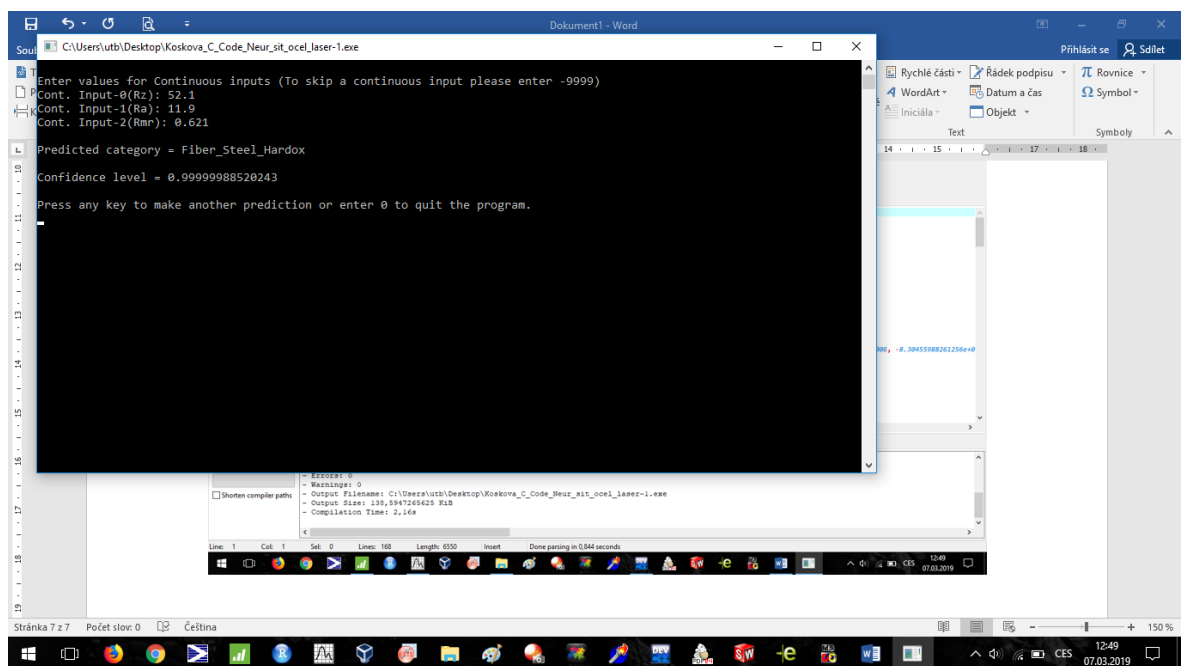
Aby bylo možné tuto síť používat bez programu Statistica 13, pomocí vah byl vygenerován zdrojový kód v jazyce C++ a síť byly dále testovány díky volně přístupnému vývojovému prostředí Dev C++. Zdrojové kódy pro obě obráběcí technologie a zadané váhy jsou uvedeny v přílohách P V, P VI a P VII.



Obr. 51 Použité programovací prostředí C++



Obr. 52 Vygenerovaný zdrojový kód



Obr. 53 Ukázka funkce neuronové sítě v prostředí C++

Pomocí konzole bylo otestováno 20 trojic vstupních parametrů ze vzorků obráběných vláknovým laserem, 20 trojic vstupních parametrů ze vzorků obráběných laserem CO<sub>2</sub>, a

nakonec výstup v podobě rozpoznaného materiálu a pravděpodobnosti správného určení materiálu. Veškeré údaje byly zpracovány do tabulky 7.

Vláknový laser					CO2 laser				
Rz	Ra	Rmr	Rozpoznaný	%	Rz	Ra	Rmr	Rozpoznaný	%
20,30	4,80	0,60	F_1_430	0,99850	13,40	2,60	0,62	CO2_1_430	0,6122
18,50	4,60	1,80	F_1_430	0,99980	11,30	2,50	1,80	CO2_1_430	0,8978
20,32	4,70	1,20	F_1_430	0,99850	11,90	2,52	1,86	CO2_1_430	0,7229
20,98	4,78	2,40	F_1_430	0,99820	11,70	2,54	1,24	CO2_1_430	0,5873
19,40	4,48	3,10	F_1_430	0,99820	12,40	2,40	1,20	CO2_1_430	0,8348
20,40	4,90	1,80	F_1_430	0,99900	11,60	2,10	0,60	CO2_1_430	0,8873
19,20	5,00	2,40	F_1_430	0,99930	10,70	2,12	0,62	CO2_1_430	0,6611
21,80	5,20	1,80	F_1_430	0,99910	11,40	2,62	1,80	CO2_1_430	0,4669
22,27	5,60	0,60	F_1_430	0,99940	11,20	2,43	0,62	CO2_1_430	0,5175
21,20	5,20	1,20	F_1_430	0,99920	11,60	2,30	0,62	CO2_1_430	0,7579
7,50	1,40	3,70	F_235	0,99998	8,70	1,40	1,80	CO2_235	0,4242
6,80	1,30	3,70	F_235	0,99998	5,00	1,20	13,60	CO2_235	0,9849
6,70	1,26	1,20	F_235	0,99940	7,30	1,44	4,30	CO2_235	0,9134
6,60	1,41	1,24	F_235	0,99270	6,20	1,10	3,70	CO2_235	0,9307
6,20	1,25	0,60	F_235	0,99880	7,50	1,40	3,10	CO2_235	0,8222
7,20	1,31	1,86	F_235	0,99970	6,70	1,30	3,00	CO2_235	0,9085
5,90	1,20	8,07	F_235	1,00000	6,00	1,10	3,70	CO2_235	0,9419
6,00	1,42	3,10	F_235	0,95950	6,60	1,20	0,60	CO2_235	0,9165
7,20	1,49	1,20	F_235	0,98950	7,10	1,18	2,50	CO2_235	0,8538
6,95	1,41	0,60	F_235	0,99640	6,30	1,22	8,00	CO2_235	0,9607
13,30	2,60	0,62	F_HARDOX	0,88750	16,60	3,70	1,80	CO2_HARDOX	0,6329
11,20	2,50	1,86	F_HARDOX	0,99999	14,10	3,50	1,20	CO2_HARDOX	0,9273
11,90	2,52	1,80	F_HARDOX	0,99940	15,10	3,60	1,80	CO2_HARDOX	0,9074
11,80	2,54	1,24	F_HARDOX	0,99900	15,00	3,70	0,62	CO2_HARDOX	0,9745
12,40	2,41	1,24	F_HARDOX	0,86100	14,44	3,60	1,10	CO2_HARDOX	0,9728
11,40	2,10	0,62	F_HARDOX	0,87560	14,80	3,50	1,80	CO2_HARDOX	0,7229
10,80	2,12	0,62	F_HARDOX	0,99880	14,60	3,55	1,24	CO2_HARDOX	0,8973
11,50	2,62	1,80	F_HARDOX	0,99970	14,20	3,70	0,60	CO2_HARDOX	0,9937
11,29	2,40	0,60	F_HARDOX	0,99880	15,00	3,50	4,30	CO2_HARDOX	0,8853
11,64	2,30	0,62	F_HARDOX	0,99870	13,30	3,40	3,70	CO2_HARDOX	0,9415

Tab. 7 Výsledky testování 20 vzorků

### 7.5.1 Shrnutí výsledků analýzy vzorků materiálů pomocí neuronové sítě

Obě sítě rozpoznaly materiál správně, i když síť hodnotící vzorky obráběné laserem CO<sub>2</sub> vykazovala nižší pravděpodobnost správnosti rozhodnutí.

## ZÁVĚR

Tato diplomová práce se zabývá problematikou závislosti parametrů drsnosti, použitého materiálu vzorku a technologie obrábění.

Nejprve byla vypracována literární rešerše, kde jsou zmíněny příslušné normy ISO definující zkoumané parametry, a dále jsou zde popsány možné metody vyhodnocení a třídění naměřených dat. Pozornost byla věnována převážně těm metodám, které byly poté použity v praktické části. Zvláštní kapitola byla věnována problematice neuronových sítí a jako poslední bod teoretické části byly charakterizovány obráběcí technologie použité při pořízení vzorků, materiály, z nichž byly vzorky vyhotoveny a použitý drsnoměr.

Hlavní myšlenka praktické části byla, jak využít naměřené hodnoty parametrů drsnosti pro určení materiálu vzorku. Nejprve byla pomocí drsnoměru Talysurf CLI500 pořízeny pro každý vzorek množiny hodnot parametrů Rz, Ra a Rmr. Naměřená data byla nejprve analyzována programem MiniTab. V několika krocích bylo ověřeno, zda data obsahují odlehle hodnoty, či zda nejsou ovlivněna hrubými chybami při měření. Poté byly množiny hodnot parametrů Rz a Ra příslušné k daným vzorkům analyzovány z hlediska statisticky významného ovlivnění použitým materiálem nebo technologií. Ve všech případech byl vliv materiálu i použité technologie obrábění shledán statisticky významným. V dalším kroku byla data tříděna podle kritérií podobnosti pomocí shlukové analýzy. Jelikož vždy dvě množiny dat vykazovaly vysokou podobnost, ukázalo se, pouze parametry Rz a Ra v kombinaci s klasickými postupy statistické analýzy nejsou dostatečné pro určení materiálu vzorku. Proto byla programem Statistica 13 pro každý typ laseru vygenerována neuronová síť typu perceptron s jednou skrytou vrstvou, která vyhodnocovala naměřené hodnoty výše zmíněných parametrů spolu s hodnotami parametru Rmr, který byl použit jako dodatečné kritérium při určování vzorku. Tyto sítě pak byly otestovány na zkušební množině dat a ve všech případech byl materiál příslušnou sítí správně rozpoznán. Všeobecně síť pro vzorky obráběné vláknovým laserem vykazovala vyšší spolehlivost než síť pro vzorky obráběné laserem CO<sub>2</sub>. Nejvyšší spolehlivost byla zaznamenána pro materiál F1\_430 a nejnižší pro materiál CO2\_1\_430.

## SEZNAM POUŽITÉ LITERATURY

- [1] MELOUN, Milan a Jiří MILITKÝ. Statistická analýza experimentálních dat. Vyd. 2. uprav. Rozš. Praha: ACADEMIA, 2004, 953 s. ISBN 80-200-1254-0
- [2] MELOUN, Milan. Kompendium statistického zpracování dat: metody a řešené úlohy. Vyd. 2., přeprac. a rozš. Praha: Academia, 2006, 982 s. ISBN 80-200-1396-2
- [3] MELOUN, Milan. Statistické zpracování experimentálních dat. 2. vyd. Praha: Ars magna, 1998, 839 s. ISBN 80-721-9003-2
- [4] BUMBÁLEK, Bohumil, Vladimír ODVODY a Bohuslav OŠŤÁDAL. Drsnost povrchu. 1. vyd. Praha: SNTL, 1989, 338 s
- [5] ČSN EN ISO 4287: 1999. Geometrické požadavky na výrobky (GPS) – Struktura povrchu: Profilová metoda – termíny, definice a parametry struktury povrchu. Praha. Český normalizační institut, 1999
- [6] ČSN EN ISO 4288: 1999. Geometrické požadavky na výrobky (GPS) – Struktura povrchu: Profilová metoda – pravidla a postupy pro posuzování struktury povrchu. Praha. Český normalizační institut, 1999
- [7] ČSN EN ISO 25178-2: 2012. Geometrické specifikace povrchu (GPS) – Textura povrchu: Plocha – část 2: Termíny, definice a parametry textury povrchu. Praha. Český normalizační institut, 2012
- [8] ČSN ISO 16610-21: 2012. Geometrické specifikace produktu (GPS) – Filtrace – část 21: Lineární profilové filtry: Gaussovy filtry. Praha. Český normalizační institut, 2012
- [9] VOLNÁ Eva, Neuronové sítě 1. Vyd. 2. Ostrava: Ostravská univerzita v Ostravě, 2008, 86s. Dostupné z: [www1.osu.cz/~volna/Neuronove\\_site\\_skripta.pdf](http://www1.osu.cz/~volna/Neuronove_site_skripta.pdf)
- [10] LITSCHMANNOVÁ Martina, Úvod do statistiky. Ostrava: VŠB – TU Ostrava, Fakulta elektrotechniky a informatiky, 2011. Dostupné z: [mi21.vsb.cz/sites/mi21.vsb.cz/files/unit/uvod\\_do\\_statistiky.pdf](http://mi21.vsb.cz/sites/mi21.vsb.cz/files/unit/uvod_do_statistiky.pdf)
- [11] NOVOVIČOVÁ Jana, Pravděpodobnost a matematická statistika. Praha: ČVUT, Fakulta dopravní, 2006. Dostupné z: [physics.ujep.cz/~jskvor/KVM/Statistika/NovovicovaPravdStatistika2006.pdf](http://physics.ujep.cz/~jskvor/KVM/Statistika/NovovicovaPravdStatistika2006.pdf)

- [12] LEACH Richard, Fundamental Principles of Engineering Nanometrology (2<sup>nd</sup> edition), 2014. Dostupné z: <https://www.sciencedirect.com/topics/engineering/gaussian-filter>
- [13] DOMOKES Eszergár-Kiss, BÁLINT Caesar, Definition of User Groups Applying Ward's Method. Dostupné z: [www.sciencedirect.com](http://www.sciencedirect.com)
- [14] WARD Joe H. Jr., Hierarchical Grouping to Optimize an Objective Function, Journal of the American Statistical Association, Vol. 58, No. 301, 1963. Dostupné z: <https://pdfs.semanticscholar.org/0430/b241bdd0b67d37e1143370f8d24fc46d83e9.pdf>
- [15] LUKASOVÁ Alena, ŠARMANOVÁ Jana, Metody shlukové analýzy. Praha: SNTL, 1985, 210 s.
- [16] WHITEHOUSE D. J., Handbook of Surface and Nanometrology (2<sup>nd</sup> edition). Boca Raton: CRC Press 2011. ISBN 978-1-4200-8201-2.
- [17] TALYSURF CLI 500. Dostupné z: <https://www.taylor-hobson.com>
- [18] F-test. Dostupné z: <https://www.en.wikipedia.org/wiki/F-test>
- [19] PATA Vladimír, KUBIŠOVÁ Milena, Statistické metody hodnocení jakosti strojírenských povrchů. Vyd. 1. Zlín: Univerzita Tomáše Bati ve Zlíně, Fakulta technologická, 2018, 423 s. ISBN 978-80-7454-740-9
- [20] TYKAL Miroslav, Metrologie povrchu. Dostupné z: [gps.fme.vutbr.cz/STAH\\_INFo/2606\\_Tykal\\_GPS.pdf](https://gps.fme.vutbr.cz/STAH_INFo/2606_Tykal_GPS.pdf)
- [21] BHUSHAN Bharat, Surface Roughness Analysis and Measurement Techniques. Dostupné z: [home.ufam.edu.br/berti/nanomaterials/8403\\_PDF\\_CH02.pdf](http://home.ufam.edu.br/berti/nanomaterials/8403_PDF_CH02.pdf)
- [22] ŠTEFAN Vojtěch, Filtrace dat při měření drsnosti povrchu. Plzeň: Západočeská univerzita v Plzni, 2014. Vedoucí práce: Ing. Zdeněk Pospěch Ph. D. Dostupné z: <https://dspace5.zcu.cz/handle/11025/15066>
- [23] Přednášky doc. Dr. Ing. Vladimír Pata.
- [24] ROGALEWICZ Vladimír, Pravděpodobnost a statistika pro inženýry. Vyd. 2, Praha: ČVUT v Praze, 1998, 176 s, ISBN 978-80-01-03785-0
- [25] [http://www.statsoft.cz/file1/PDF/newsletter/2013\\_02\\_05\\_StatSoft\\_Neuronove\\_site\\_linky.pdf](http://www.statsoft.cz/file1/PDF/newsletter/2013_02_05_StatSoft_Neuronove_site_linky.pdf)

- [26] JIŘINA Marcel a kol., Neuronové sítě. Dostupné z:  
[https://cw.fel.cvut.cz/old/\\_media/courses/a6m33dvz/dvz2017-05-nnet.pdf](https://cw.fel.cvut.cz/old/_media/courses/a6m33dvz/dvz2017-05-nnet.pdf)
- [27] [https://sorry.vse.cz/~berka/docs/izi456/kap\\_5.4.pdf](https://sorry.vse.cz/~berka/docs/izi456/kap_5.4.pdf)
- [28] [iss.unas.cz/NEURON-site-vyuka2.doc](http://iss.unas.cz/NEURON-site-vyuka2.doc)
- [29] Přednášky Nekonvenční technologie, Ing. Adam Škrobák, Ph. D.
- [30] <http://www.lt.cz/e-learning/laser/princip-vlakového-fiber-laseru>
- [31] ZAORAL Radek, Porovnání výsledků laserového obrábění na laseru CO<sub>2</sub> a vláknovém laseru. Zlín, 2016. Dostupné z: <http://digilib.k.utb.cz/handle/10563/37896>



## SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

$\alpha$	Hladina významnosti
$\beta$	Síla testu
$H_0$	Nulová hypotéza
$H_A$	Alternativní hypotéza
$l_r$	Základní délka
$l_n$	Vyhodnocovaná délka
$\lambda_c$	Hraniční vlnová délka mezi profilem drsnosti a vlnitosti
$\lambda_f$	Hraniční vlnová délka mezi profilem vlnitosti a profilem tvaru
$\lambda_s$	Nejkratší vlnová délka profilu drsnosti
$\mu$	Střední hodnota
$R_a$	Střední aritmetická drsnost
$R_{mr}$	Materiálový poměr profilu
$R_z$	Největší výška profilu
$s^2$	Míra rozptylu
$\sigma$	Rozptyl
$Z_p$	Výška nejvyššího výstupku profilu
$Z_v$	Hloubka nejnižší prohlubně

## SEZNAM OBRÁZKŮ

Obr. 1 Přenosová charakteristika profilu drsnosti a vlnitosti [5].....	13
Obr. 2 Řez povrchem zobrazující všechny složky povrchové nepřesnosti.....	13
Obr. 3 Profil tvaru povrchu.....	13
Obr. 4 Profil vlnitosti povrchu.....	14
Obr. 5 Profil drsnosti povrchu.....	14
Obr. 6 Profil povrchu.....	15
Obr. 7 Zobrazení výšky profilu drsnosti.....	16
Obr. 8 Parametry pro stanovení Rmr (c) na dané úrovni c.....	17
Obr. 9 Metoda nejbližšího souseda.....	25
Obr. 10 Metoda nejbližšího souseda – vztah vzdálenosti mezi objekty [2].....	26
Obr. 11 Metoda nejvzdálenějšího souseda.....	26
Obr. 12 Wardova metoda.....	27
Obr. 13 Princip neuronu.....	30
Obr. 14 Sigmoida [26].....	31
Obr. 15 Konjunkce (uzel AND).....	32
Obr. 16 Disjunkce (uzel OR).....	32
Obr. 17 Negace (uzel NOT).....	32
Obr. 18 Perceptron s jednou skrytou vrstvou.....	34
Obr. 19 Princip učení perceptronu.....	35
Obr. 20 Princip laseru CO <sub>2</sub> [29].....	36
Obr. 21 Princip vláknového laseru [30].....	37
Obr. 22 Měřicí přístroj Talysurf CLI500 – konfigurace při měření.....	41
Obr. 23 Měřicí přístroj Talysurf CLI 500 – parametry nastavení.....	42
Obr. 24 Časový diagram průběhu parametru Rz pro analyzované vzorky.....	44
Obr. 25 Časový diagram průběhu parametru Ra pro analyzované vzorky.....	45
Obr. 26 Časový diagram průběhu parametru Rmr pro analyzované vzorky.....	45
Obr. 27 Test rozptylů F_1_430_Rz; F_235_Rz; F_HARDOX_Rz.....	47
Obr. 28 Test rozptylů F_1_430_Ra; F_235_Ra; F_HARDOX_Ra.....	47
Obr. 29 Histogram F_1_430_Rz; F_235_Rz; F_HARDOX_Rz.....	48
Obr. 30 Histogram F_1_430_Ra; F_235_Ra; F_HARDOX_Ra.....	48
Obr. 31 Intervalový diagram F_1_430_Rz; F_235_Rz;.....	50
Obr. 32 Intervalový diagram F_1_430_Rz; F_235_Ra;.....	51

Obr. 33 Test a hladina významnosti pro dva rozptyly: .....	54
Obr. 34 Test a hladina významnosti pro dva rozptyly: .....	54
Obr. 35 Histogram $F_{1\_430}$ Rz; $CO_2_{1\_430}$ Rz .....	55
Obr. 36 Histogram $F_{1\_430}$ Ra; $CO_2_{1\_430}$ Ra .....	55
Obr. 37 Shluková analýza vzorků obráběných vláknovým laserem – parametr Rz ...	59
Obr. 38 Shluková analýza vzorků obráběných vláknovým laserem – parametr Ra ...	60
Obr. 39 Porovnání podobnosti všech vzorků na základě parametru Rz .....	63
Obr. 40 Porovnání podobnosti všech vzorků na základě parametru Ra .....	64
Obr. 41 Perceptron s šesti neurony ve skryté vrstvě .....	66
Obr. 42 Trénovací množina dat .....	67
Obr. 43 Klasifikační analýza pro zadané parametry Rz, Ra Rmr – krok č. 1 .....	67
Obr. 44 Klasifikační analýza pro zadané parametry Rz, Ra Rmr – krok č. 2 .....	68
Obr. 45 Klasifikační analýza pro zadané parametry Rz, Ra Rmr – krok č. 3 .....	68
Obr. 46 Zadání parametrů sítě .....	69
Obr. 47 Odmítnutí navrhované sítě s šesti neurony ve skryté vrstvě .....	70
Obr. 48 Programem vygenerovaná síť s deseti neurony ve skryté vrstvě .....	70
Obr. 49 Zadávání vstupních parametrů Rz, Ra a Rmr .....	71
Obr. 50 Vyhodnocení posuzovaného materiálu .....	71
Obr. 51 Použité programovací prostředí C++ .....	72
Obr. 52 Vygenerovaný zdrojový kód .....	73
Obr. 53 Ukázka funkce neuronové sítě v prostředí C++ .....	73

## SEZNAM TABULEK

Tab. 1 Chyby prvního a druhého druhu [23] .....	21
Tab. 2 Označení měřených vzorků .....	38
Tab. 3 Výsledky testů vlivu materiálu daných vzorků na parametry Rz a Ra.....	52
Tab. 4 Výsledná tabulka – výsledky testů vlivů použité technologie obrábění.....	58
Tab. 5 Úrovně podobnosti vzorků obráběných vláknovým laserem .....	62
Tab. 6 Úrovně podobnosti vzorků obráběných laserem CO <sub>2</sub> .....	62
Tab. 7 Výsledky testování 20 vzorků .....	74