

# **Aplikace perceptronových neuronových sítí pro hodnocení jakosti povrchů získaných progresivní technologií**

Bc. Josef Kocháň

---

Diplomová práce  
2022



Univerzita Tomáše Bati ve Zlíně  
Fakulta technologická

---

Univerzita Tomáše Bati ve Zlíně

Fakulta technologická

Ústav výrobního inženýrství

Akademický rok: 2021/2022

# ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení:	Bc. Josef Kocháň
Osobní číslo:	T20779
Studijní program:	N3909 Procesní inženýrství
Studijní obor:	Řízení jakosti
Forma studia:	Prezenční
Téma práce:	Aplikace perceptorových neuronových sítí pro hodnocení jakosti povrchů získaných progresivní technologií

## Zásady pro vypracování

1. Vypracování rešerše na zadané téma
2. Proměření vzorků danou technikou měření
3. Sestavení perceptorové neuronové sítě včetně jejího naučení

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

Seznam doporučené literatury:

MELOUN, Milan a Jiří MILITKÝ. *Kompendium statistického zpracování dat*. Praha: Karolinum, 2012. ISBN 978-80-246-2196-8.

WHITEHOUSE, D. J. *Handbook of surface and nanometrology*. 2nd ed. Boca Raton: CRC Press, c2011. ISBN 978-1-4200-8201-2.

AGGARWAL, Charu C. *Neural networks and deep learning: a textbook*. Cham: Springer, [2018].

Vedoucí diplomové práce: **prof. Dr. Ing. Vladimír Pata**  
Ústav výrobního inženýrství

Datum zadání diplomové práce: **3. ledna 2022**

Termín odevzdání diplomové práce: **13. května 2022**

**prof. Ing. Roman Čermák, Ph.D. v.r.**  
děkan

L.S.

**prof. Ing. Berenika Hausnerová, Ph.D. v.r.**  
ředitel ústavu

Ve Zlíně dne 18. února 2022

## **PROHLÁŠENÍ AUTORA DIPLOMOVÉ PRÁCE**

Beru na vědomí, že:

- diplomová práce bude uložena v elektronické podobě v univerzitním informačním systému a dostupná k nahlédnutí;
- na moji diplomovou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3;
- podle § 60 odst. 1 autorského zákona má Univerzita Tomáše Bati ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- podle § 60 odst. 2 a 3 autorského zákona mohu užít své dílo – diplomovou práci nebo poskytnout licenci k jejímu využití jen s předchozím písemným souhlasem Univerzity Tomáše Bati ve Zlíně, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše);
- pokud bylo k vypracování diplomové práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tj. k nekomerčnímu využití), nelze výsledky diplomové práce využít ke komerčním účelům;
- pokud je výstupem diplomové práce jakýkoliv softwarový produkt, považují se za součást práce rovněž i zdrojové kódy, popř. soubory, ze kterých se projekt skládá. Neodevzdání této součásti může být důvodem k neobhájení práce.

### **Prohlašuji,**

- že jsem diplomové práci pracoval samostatně a použitou literaturu jsem citoval. V případě publikace výsledků budu uveden jako spoluautor.
- že odevzdaná verze diplomové práce a verze elektronická nahraná do IS/STAG jsou obsahově totožné.

Ve Zlíně dne:

Jméno a příjmení studenta:

.....  
podpis studenta

## **ABSTRAKT**

Cílem této diplomové práce je sestavit a naučit neuronovou síť predikovat výsledky heterogenního povrchu, který vznikl za pomoci technologie obrábění vodním paprskem s příměsí abraziva a následný důkaz, že statistické vyhodnocení, za využití nástrojů regresní analýzy není zcela správné. Zkoumané vzorky se od sebe odlišují jakostí povrchu, díky změnám řezných podmínek, přesněji řečeno změnám řezné rychlosti.

Klíčová slova: neuronová síť, regresní analýza, statistické hodnocení povrchu

## **ABSTRACT**

The goal of this diploma thesis is to compile and learn the neural network to predict the results of the heterogenous surface which was created by the water jet machining technology with abrasive admixture and following evidence that statistical evaluation, using the tools of regression analysis is not completely correct. The investigated samples differs by the surface quality thanks to the changes in cutting conditions. Specifically the changes speed of cutting.

Keywords: Neural network, regression analysis, statistical evaluation of the surface

Tímto bych chtěl poděkovat panu prof. Dr. Ing. Vladimíru Patovi za skvělé vedení mé diplomové práce, za cenné rady během tvorby mé diplomové práce a v neposlední řadě za přístup, který měl k celé naší studijní skupině během dvou let magisterského studia.

Největší poděkování však náleží mé rodině za podporu mého studia vysoké školy. Velký dík také patří mým kamarádům a spolužákům, díky kterým člověk neztrácel naději i v chmurných dobách.

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

# OBSAH

<b>ÚVOD</b> .....	<b>9</b>
<b>I TEORETICKÁ ČÁST</b> .....	<b>10</b>
<b>1 NEKONVENČNÍ METODY OBRÁBĚNÍ</b> .....	<b>11</b>
1.1 PRINCIP VODNÍHO PAPRSKU .....	11
1.2 TYPY VODNÍHO PAPRSKU .....	13
1.2.1 Čistý vodní paprsek .....	14
1.2.2 Abrazivní vodní paprsek .....	17
1.2.3 Abrazivní suspenzivní paprsek .....	19
1.2.4 Kryogenní vodní paprsek .....	21
<b>2 HETEROGENITA POVRCHU</b> .....	<b>22</b>
2.1 PŘÍČINA VZNIKU HETEROGENNÍHO POVRCHU .....	22
2.2 ZKOUMANÉ OBLASTI HETEROGENNÍHO POVRCHU .....	23
<b>3 STATISTICKÉ PARAMETRY JAKOSTI POVRCHU</b> .....	<b>24</b>
3.1 STRUKTURA POVRCHU .....	24
3.1.1 Tvar .....	25
3.1.2 Vlnitost .....	25
3.1.3 Drsnost .....	25
3.2 PARAMETRY STRUKTURY POVRCHU .....	26
3.2.1 Výškové parametry .....	26
3.2.2 Délkové parametry .....	28
<b>4 STATISTICKÉ HODNOCENÍ POVRCHU</b> .....	<b>29</b>
4.1 EDA.....	29
4.1.1 Diagram časové řady .....	29
4.1.2 Box-plot diagram .....	30
4.1.3 Histogram .....	30
4.2 LINEÁRNÍ REGRESE.....	31
<b>5 NEURONOVÉ SÍTĚ</b> .....	<b>32</b>
5.1 NEURON .....	32
5.2 PERCEPTRON .....	34
5.3 ZPŮSOBY VYUŽITÍ .....	35
<b>II PRAKTICKÁ ČÁST</b> .....	<b>36</b>
<b>6 CÍLE DIPLOMOVÉ PRÁCE</b> .....	<b>37</b>
<b>7 VÝROBA A PŘÍPRAVA VZORKŮ</b> .....	<b>38</b>
7.1 VLASTNOSTI ZVOLENÉHO MATERIÁLU A ŘEZNÉ PARAMETRY .....	38
7.2 ÚPRAVA VZORKŮ PŘED MĚŘENÍM.....	38
<b>8 PROCES MĚŘENÍ A ZVOLENÉ MĚŘÍCÍ PARAMETRY</b> .....	<b>39</b>

8.1	POUŽITÝ MĚŘÍCÍ PŘÍSTROJ TALYSURF CLI 500 .....	39
8.2	KALIBRACE PŘÍSTROJE A NÁSLEDNÁ VOLBA PARAMETRŮ SNÍMÁNÍ .....	40
<b>9</b>	<b>STATISTICKÉ VYHODNOCENÍ VZORKŮ .....</b>	<b>41</b>
9.1	ZPRACOVÁNÍ VÝSLEDKŮ MĚŘENÉHO VZORKU Q1 .....	41
9.1.1	Ověření oblasti heterogenity .....	41
9.1.2	Užití regresních analýz.....	43
9.1.3	Aplikace regresní analýzy na nerozdělené data .....	46
9.1.4	Závěr analýzy vzorku Q1 .....	47
9.2	ZPRACOVÁNÍ VÝSLEDKŮ MĚŘENÉHO VZORKU Q2 .....	48
9.2.1	Ověření oblasti heterogenity .....	48
9.2.2	Ověření Testu normality .....	50
9.2.3	Aplikace metodiky EDA .....	51
9.2.4	Závěr analýzy vzorku Q2 .....	53
9.3	ZPRACOVÁNÍ VÝSLEDKŮ MĚŘENÉHO VZORKU Q3 .....	54
9.3.1	Ověření heterogenity .....	54
9.3.2	Ověření testu normality .....	55
9.3.3	Aplikace metodiky EDA .....	56
9.3.4	Výsledky po odlogaritmování .....	58
9.3.5	Závěr analýzy vzorku Q3 .....	59
9.4	ZPRACOVÁNÍ VÝSLEDKŮ MĚŘENÉHO VZORKU Q4 .....	60
9.4.1	Ověření oblasti heterogenity .....	60
9.4.2	Ověření testu normality .....	61
9.4.3	Délkové parametry .....	62
9.4.4	Testy odlehlých hodnot .....	64
9.4.5	Hodnoty po odlogaritmování .....	66
9.4.6	Závěry analýzy vzorku Q4 .....	67
<b>10</b>	<b>SHRnutí VÝSLEDKŮ STATISTICKÉHO HODNOCENÍ .....</b>	<b>68</b>
10.1	VÝSLEDKY VZORKU Q1 .....	68
10.2	VÝSLEDKY VZORKU Q2 .....	68
10.3	VÝSLEDKY VZORKU Q3 .....	68
10.4	ZP VÝSLEDKY VZORKU Q4 .....	68
<b>11</b>	<b>NEURONOVÁ SÍŤ .....</b>	<b>69</b>
11.1	POSTUP VYHOTOVENÍ NEURONOVÉ SÍŤE .....	70
11.2	PREDIKCE VÝSLEDKŮ NEURONOVÉ SÍŤE .....	75
<b>12</b>	<b>SHRnutí VÝSLEDKŮ NEURONOVÉ SÍŤE CHYBA! ZÁLOŽKA NENÍ DEFINOVÁNA.</b>	
	<b>ZÁVĚR .....</b>	<b>77</b>
	<b>SEZNAM POUŽITÉ LITERATURY .....</b>	<b>78</b>
	<b>SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK .....</b>	<b>81</b>
	<b>SEZNAM OBRÁZKŮ .....</b>	<b>82</b>
	<b>SEZNAM TABULEK .....</b>	<b>85</b>



## ÚVOD

Statistické hodnocení povrchu má v praxi obrovské využití. Problém ale nastává tehdy, když se povrch prokáže jako heterogenní. V takovém případě vyhodnocení povrchu, užitím regresních analýz, bohužel selhává. Naštěstí se ale v poslední době objevuje možnost využít neuronových sítí. Tyto sítě se zcela běžně využívají v lékařství, programování a jiných odvětvích. Tato síť se je schopná, na základě vložených dat, naučit predikovat výsledky těchto specifických povrchů a nahradit tak regresní analýzu, která bohužel v těchto případech selhává. Třeba se časem dočkáme mnohem většího zastoupení této technologie v oboru strojírenství.

Obsahem této práce je postupná cesta k vytvoření této sítě, na základě naměřených dat, která byla získána pomocí přístroje Talysurf CLI 500. K vytvoření došlo díky programu QC.Expert, který je pro tuto aplikaci vhodný.

## **I. TEORETICKÁ ČÁST**

## 1 NEKONVENČNÍ METODY OBRÁBĚNÍ

Stále se rozšiřující databáze materiálů s vylepšenými mechanickými a tepelnými vlastnostmi, je pro tradiční postupy obrábění obtížné. Důvodem může být skutečnost, že nástroje používané v případě tradičních obráběcích procesů jsou vždy tvrdší než obrobek. Například objem opotřebovaného materiálu broušení kotouče byl velmi vysoký v porovnání s objemem odebraného kovu, a proto broušení bylo omezeno na obrábění polykrystalického diamantového profilu nástrojů. Hlavním omezením pro obrábění keramiky a kompozitů, jsou vysoké náklady spojené s jejich obráběním.

S rostoucí poptávkou na trhu se stále častěji objevují mikro obráběné materiály s nízkou tuhostí a složité tvary s vysokou kvalitou povrchu jsou rovněž obtížné. obrábět tradičními obráběcími postupy. Proto, aby bylo možné splnit požadavky rostoucí poptávce trhu po takových materiálech a součástech, je třeba vyvinout nové způsoby obrábění. Proto byly vyvinuty nové postupy.

Nové výrobní postupy hrají velmi důležitou roli pro průmyslová odvětví, jako jsou např výroba letadel, automobilů, zápusťek a nástrojů. Tyto procesy se označují jako netradiční obráběcí procesy a lze je rozdělit do kategorií na základě jejich počtu úkonů potřebných k odstranění materiálu ze vzorku obrobku. [1]

### 1.1 Princip vodního paprsku

Typický schematický náčrt vzniku vodního paprsku je znázorněn na obr. 1. Hlavní součásti jsou systém vysokotlakého vodního čerpadla, vysokotlaký generátorový systém, CNC jednotka, řezná hlava a zachycovač. Vysokotlaké čerpadlo se používá k dodávání tlaku do vysokotlaké vodní pumpy za pomoci čerpadla nepřetržitě. Zahrnuje dva různé zásobníky, tím jsou nádrž na řeznou vodu a nádrž na chladicí vodu. Obecně platí, že část sedliny o velikosti větší než 1 mm je třeba odstranit z nádrže vody, protože dochází k opotřebení kritické části čerpadla, což vede k jeho poškození. Chladicí voda se používá ke snížení teploty olejového čerpadla. Vysokotlaký generátorový systém je vybaven zesilovačem a akumulátorem pro generování vysokého tlaku a skladování vysokého tlaku vody. Hydraulický systém poskytuje kapalinu. Koncový spínač, umístěný na každém konci dráhy pístu, signalizuje elektronické ovládací prvky, aby posunuly směrový regulační

ventil tím mohly změnit směr pístu. Sestava zesilovače s pístnicí na každé straně pístu, vytváří tlak v obou směrech.


Během vstupního zdvihu pístu vstupuje filtrovaná voda do vysokotlakého výstupu. Přes sestavu zpětného ventilu, po zdvihu pístu je voda stlačena a vystupuje z válce ve formě vysokotlaké voda. Tlak vody je přibližně 200-400 MPa a prochází otvorem, jehož průměr je přibližně 1,5 m. Akumulátor uchovává vysokotlakou vodu, aby se v dalším stupni snížila tlaková ztráta. Rychlost výstupního proudu vody se blíží 200-300 m/s. Vývoj v oblasti počítačů a softwaru pro řízení a další vylepšení přinesly řadu změn, umožnily řezat tvary velmi blízké čistému rozměru a povrchové úpravě.[2]

Dnešní technologie je nyní schopna pracovat s osmi koordinovanými osami. Přesný stůl X-Y je tuhý rám, který leží na nádrži, která odchytává odpadní vodu. Pohyb řezné trysky je řízen jednotkou CNC, což vede k vysoké rozměrové přesnosti obrábění. Řezací hlava přeměňuje tlakovou vodu na řezný nástroj. Řezná hlava je vybavena fokusační trubicí, clonou, tryskou a tryskami, směšovací komorou, jak je znázorněno na obr. 5. Pro ústí lze použít safír, rubín a diamant. Vysokotlaká trubka nese z akumulátoru do řezací hlavy přes trubku. Výkonnost fokusační trubice závisí na geometrii vstupní zóny a vnitřním průměru fokusační trubice.[2]

Čím menší je vnitřní průměr, tím koncentrovanější je celková koncentrace energie. Minimální průměr souvisí s abrazivními částicemi a s velikostí částic. Pro spolehlivou funkci by měl být průměr fokusační trubice pětikrát nebo vícekrát větší než průměr částic. Nové materiály mají životnost trubice již od 4 do 100 h. Vysokotlaká voda prochází clonou, která přeměňuje tlakovou energii vody do kinetické energie vodní částice v důsledku konvergentního tvaru otvoru. Vysokorychlostní vodní paprsek pak prochází směšovacím zařízením neboli komorou, která je přímo spojena s otvorem. Voda ztrácí svou tlakovou energii při průchodu směšovací komorou.[2]

V důsledku vakuování se abrazivo dostává do směšovací komory a mísí se s vodou. V míchací komoře se vysoká energie částic vody přenáší na abrazivo, pak směs vody a abraziva prochází tryskou s přívodem vody a působí jako pila čímž řeže materiál. Systém

dodávání brusiva zahrnuje zásobník abraziva a pneumaticky ovládaný ventil, který přivádí abrazivo do zásobníku.[2]




Obrázek 1 – princip fungování vodního paprsku [3]

## 1.2 Typy vodního paprsku

Princip vodního a abrazivního vodního paprsku jsou podobné a hlavní rozdíl spočívá v zavedení abrazivních částic při obrábění abrazivním vodním paprskem. V obyčejném obrábění vodním paprskem nebo jednoduše obrábění vodním paprskem se do stroje přivádí filtrovaná voda. Nízkotlaké posilovací čerpadlo přivádí vodu do zesilovače pod tlakem přibližně 100 barů z vody, která přichází z obecného vodovodu. Paprsek vody je z trysky vyvržen skrz otvor, který je pak při dotyku s obrobkem prořízne materiál. [4]

Princip činnosti procesu obrábění abrazivním vodním paprskem je rovněž podobný popsánému obrábění vodním paprskem, jediným rozdílem je přidání abraziva materiálu, který se přidává do vody pod vysokým tlakem. Abrazivní materiály, jako je granát, oxid

křemičitý a oxid hlinitý, se zavádějí do trysky. Kvalita řezu závisí na řadě parametrů, mezi které patří průměr trysky, rychlost posuvu proudu, tlak proudu, hmotnostní průtok a velikostní rozložení abrazivních částic, viskozita kapaliny, typ kapaliny, vzdálenost mezi jednotlivými částmi, typ materiálu obrobku a tloušťka obrobku. [4]



Obrázek 2 - Typy vodních paprsků [5]

### 1.2.1 Čistý vodní paprsek


Klíčovým prvkem je vodní paprsek, který dopadá na obrobek vysokou rychlostí. K úběru materiálu dochází erozí v důsledku vysokého výkonu proudu. Vodu žene hydraulické čerpadlo poháněné elektromotorem. Hlavní funkce hydraulického čerpadla je pohon zesilovače. Zesilovač je pístové čerpadlo. Hydraulické čerpadlo dodává olej pod vysokým tlakem, který poskytuje hnací sílu pro zesilovač. Větší flexibilitu nabízí čerpadlo pro řezání vodním paprskem. [1]

Funkcí zesilovače je převod tlaku pracovní kapaliny z nízkého na vysoký tlak. Přepočít je až 3800 barů z extrémně nízkého tlaku 4 barů. Zesilovač je poháněn kapalinou z hydraulického čerpadla, které dodává olej do středové části zesilovače. Směr pohybu pístu je obráceně pomocí směrových regulačních ventilů ovládaných koncovým spínačem na obou koncích dráhy pístu. Uspořádání pístů na obou stranách pístu sestavy zesilovače. Jeden strana je spojena se vstupním zdvihem přijímajícím vodu, zatímco druhý konec je výstupní, který vyvolává vysoký tlak. [1]

O případné kolísání tlaku vody se stará akumulátor a tím je zajištěna nepřetržitá dodávka vysokotlaké vody. Stlačitelnost vody při změně směru pohybu pístu hraje rozhodující roli při udržování rovnoměrného tlaku vody a rychlosti proudu vody. Tlaková voda se k řezací hlavě přivádí pomocí vysokotlakých trubek. Speciálně navržené ručně ovládané nebo elektronicky ovládané ventily ovládají řezání. [1]

Tryska pro řezání proudem zajišťuje souvislý proud. Ultra vysoký tlak má potenciál obrábět měkké materiály s nízkou hustotou, které se konvenčními metodami obrábějí obtížně. Konstrukční materiál trysky je obvykle syntetický safír. Životnost trysky je přibližně 200 h. K poškození trysky dochází především částicemi nečistot a minerálními usazeninami vznikajícími v důsledku tvrdosti erozivní vody. Vícestupňová filtrace se používá hlavně k odstranění nežádoucích pevných částic větších než 1,5 mm, což napomáhá prodloužení životnosti trysky. Pružnost řezací hlavy umožňuje integraci s různými systémy řízení pohybu od dvouosými stoly až po víceosé. [1]

Zbytky z obrábění vodním paprskem se shromažďují v zásobníku na zásobníku známém jako záchytný koš. Snížení rychlosti proudu vede ke zvýšení hlučnosti, který je snižován záchytným košem. [1]



Obrázek 3 – schéma stoje používající čistý vodní paprsek [6]

Obrábění vodním paprskem je jednou z nejuniverzálnějších technologií obrábění, jejíž výhody využívá řada výrobních odvětví.

Výhody obrábění vodním paprskem jsou uvedeny níže:

- Obrábění vodním paprskem je bez tepla, a je proto vhodné pro materiály, při jejichž obrábění dochází k tvorbě nadměrného tepla, které následně vede ke změně vlastností obráběného materiálu.
- Na rozdíl od jiných konvenčních procesů obrábění nevznikají prachové částice, které jsou při vdechování škodlivé.
- Při obrábění vodním paprskem dochází k velmi malému plýtvání materiálem, protože šířka záběru při obrábění vodním paprskem je velmi malá.
- Prototypy lze vyrábět efektivně. Při obrábění vodním paprskem se díly nařezou přesně podle rozměrů, jakmile obsluha naprogramuje řezání na stroji.
- Obrábění vodním paprskem eliminuje použití dalších procesů obrábění, jako je např. dokončovací práce, protože tento proces nezanechává otřepy ani drsné hrany.
- Použitý nástroj není třeba brousit, protože se během obrábění neopotřebovává.
- Proces má schopnost řezat ve více směrech.
- Tento proces nabízí nižší dobu realizace a náklady díky jednoduchosti upínání a eliminaci komplikovaných nástrojů.
- Vodní paprsek může pronikat do velkých tlouštěk. [1]

Proces obrábění vodním paprskem má určitá omezení, která jsou popsána níže:


- Počet materiálů, které lze ekonomicky obrábět, je nízký. Přestože lze řezat tvrdé materiály, jako je nástrojová ocel, ale hodinové sazby jsou vysoké. Z tohoto důvodu se proces stává nákladnou záležitostí.
- Vysoké náklady na údržbu z něj nedělají vhodnou volbu pro hromadnou výrobu.
- Vodní paprsek sice dokáže proniknout do silných materiálů, ale je obtížné udržet rozměrovou přesnost. [1]



### 1.2.2 Abrazivní vodní paprsek

Řezání pomocí vodního paprsku s abrazivem a se ukázalo jako velmi vhodná, ba dokonce lepší metodou než ostatní tradiční metody řezání. Řezání abrazivním vodním paprskem (AWJ) se široce používá zejména při řezání tvrdších nebo málo obrobitelných materiálů, jako jsou slitiny Ti, keramika, kompozity s kovovou maticí, beton. atd. Stroj AWJ obvykle používá jako primární čerpadlo multireciproční čerpadlo. Upravená voda je čerpána na velmi vysoké tlaky v rozsahu 4 000-6 000 barů (400-600 MPa). [7]

Abrazivo (např. granát) se přivádí do čerpadla ze sousední násypky a směřuje do směšovací komory uvnitř zařízení řezací hlavy. Abrazivo se urychluje a opouští trysku spolu s vodou otvorem o malém průměru. Voda vystupující z otvoru vysokou rychlostí (i více než 1 000 m/s) se používá pro aplikace při řezání/obrábění materiálů včetně kalené oceli, keramiky, kevlarových polymerů vyztužených vlákny a mimo jiné i Ti, a to erozním procesem. [7]



Obrázek 4 - Typy vodních paprsků [8]

Technologie AWJ nabízí ve srovnání s konvenčními a jinými nekonvenčními technikami následující výhody:

- Vysoká univerzálnost obrábění: Abrazivním vodním paprskem lze řezat téměř všechny druhy materiálů a křehké materiály, včetně mnoha obtížně obrobitelných materiálů, jako jsou např. Ti slitiny, vysoce pevná pokročilá keramika, vysokopevnostní ocel, kovová matrice a další kevlarové kompozity.
- Zanedbatelné tepelné zkreslení: Teplo vznikající při procesu AWJ je okamžitě odváděno vodou. V důsledku toho nedochází téměř k žádnému zvýšení teploty v prostoru obrobku, což vede k minimálním změnám vlastností materiálu, mikrostruktury a strukturální integrity. Tato vlastnost je užitečná zejména pro obrábění tepelně citlivých materiálů, jako jsou kovy, super slitiny a pokročilé materiály. keramika.
- Malá řezná síla a rychlé nastavení: Řezné síly jsou velmi malé, a proto je možné pravděpodobnost poškození povrchu řezaného materiálu je minimální. Ploché vzorky lze přímo nastavit položením na stůl, aniž by bylo nutné je opracovávat. bez nutnosti složitého upínání nebo výměny nástrojů.
- Možnost generování kontur: AWJ jsou výjimečně dobré při 2D obrábění. Je však možné řezat i složité 3D tvary nebo úkosy libovolných úhlů a provádět 3D profilování.
- Šetrnost k životnímu prostředí: AWJ neprodukuje žádný škodlivý prach ani částice, které by mohly v případě vdechnutí ohrozit zdraví, a je považován za jeden z nejšetrnějších procesů obrábění k životnímu prostředí.
- Dostupnost surovin: Jako základní pracovní kapalina se používá voda. Nejčastěji používanými brusnými materiály jsou granát nebo oxid křemičitý, které se snadno dostupné za nízkou cenu. [7]


Obrábění AWJ však trpí také následujícími nevýhodami:

- Celkově je systém ve srovnání s konvenčními technikami drahý.
- Problémy se zachycováním vlhkosti;
- Hlučnost a nebezpečnost;
- Recyklace brusiva. [7]

### 1.2.3 Abrazivní suspenzivní paprsek

Podle současného stavu techniky existují dvě různé hlavy na řezání vodním proudem s příměsí abraziva, které jsou znázorněny na obrázku 5. Pro generování abrazivního vodního paprsku se používá vysokotlaký vodní paprsek. (300-600 MPa) se protlačí otvorem vodního čerpadla. Tím je voda urychlována na rychlost s konstantním objemovým průtokem. Ve směšovací komoře se vzduch a abrazivní částice urychlovány proudem vody díky Venturiho trubici, za účasti Venturiho efektu. Ve spojení se směšovací komorou se ve fokusační trysce soustřeďuje do laminárního proudu. [9]

Po výstupu z trysky se abrazivní vodní paprsek chová jako volný proud a rozpíná se, dokud nedopadne na povrch obrobku. Na rozdíl od metody vstřikování jsou v suspenzi voda a abrazivní částice předem smíchány ve směsi a následně se rozptýlí dynamikou proudění vody pod vysokým tlakem. Po dispergaci obou fází se suspenze protlačena přes fokusační trysku. Po opuštění trysky se abrazivo chová podobně jako vstřikovací vodní paprsek. Hlavní rozdíl mezi oběma typy trysek spočívá v tom, že proud suspenze expanduje pomaleji v důsledku nedostatku vzduchu v proudu. [9]



Obrázek 5 – suspenzivní vodní paprsek [10]

AWJM je v porovnání s ostatními obráběcími stroji poměrně náročný proces, ale i přes to přináší řadu výhod:

- Jedná se o proces prováděný za studena, a proto nedochází k tepelnému poškození obráběného materiálu nebo jeho povrchu
- AWJM neprodukuje žádné nebezpečné plyny, a proto je šetrný k životnímu prostředí.
- Je schopen vyrábět všechny druhy tvarů pouze s jedním nástrojem.
- Proces AWJM je ve srovnání s jinými procesy relativně levnější.
- Díky malé šířce záběru při obrábění vodním paprskem dochází k velmi malému plýtvání materiálem.
- Proces je snadno ovladatelný, protože obsluha musí pouze naprogramovat rozměry do stroje a díl bude vyroben přesně podle požadavků. [1]


Nevýhody:

- Tímto procesem nelze řezat velmi tlusté díly, protože proud se vychýlí a řeže šikmo.
- Na povrchu lze také vytvořit vlnovitý vzor.
- Při obrábění velmi tlustých dílů může také dojít ke zúžení, a tím ke vzniku k rozměrové nepřesnosti.
- Tímto procesem jsme schopni řezat pouze omezený počet materiálů. [1]

### 1.2.4 Kryogenní vodní paprsek

Technologie ledového paprsku známá také jako ledový abrazivní vodní paprsek (IAWJ) je v současné době vyvíjený prototyp technologie. V IAWJ se místo ledu používají částice ledu vyrobené z vody. Cílem je zvýšit účinnost čistého vodního paprsku (WJ) při zachování jeho výhod. Technologie má velký potenciál využití v potravinářském a zdravotnickém průmyslu i v dalších oblastech, kde je třeba zajistit čistotu procesu, s ideálně nulovým vznikem odpadu, což je priorita číslo jedna. [11]

Pro použití ledu jako abraziva, je třeba brát do úvahy použití extrémně nízkých teplot, při kterých se jeho mechanické vlastnosti, jako je tvrdost, stávají využitelnými pro obrábění. Jsou studovány dva přístupy k získání ledových částic ve vodě a sice generování ledových částic v řezné hlavě a při generování ledových částic mimo obráběcí řezné hlavice, které se přidávají do proudu podobně jako v případě technologii vstřikování AWJ. Hlavním úkolem je zajistit velmi studené, a tedy tvrdé částice ledu v řezné zóně, kde je možné použít tyto částice jako abrazivo. Proto je nezbytné sledovat a kontrolovat teploty vyskytující se v systému. Pozitivní vliv ledu na účinnost řezání byl zpozorován, ale nemohl být dostatečně prozkoumán z důvodu nedostatku stabilních částic, které se vyskytují v současném prototypu. [11]



Obrázek 6 – schéma kryogenního vodního paprsku [12]

## 2 HETEROGENITA POVRCHU

Heterogenní povrch může vzniknout několika způsoby. Nejrozšířenějším z nich je využití nekonvenčních technologií. Mezi zástupce této technologie, které lze běžně spatřit ve výrobní praxi, patří obrábění lasem či u zmiňovaný vodní paprsek. [15]

### 2.1 Příčina vzniku heterogenního povrchu


Při obrábění vodním paprskem se malé částice liší velikostí a tvarem a oddělují se od obrobku (mikročástice), v důsledku destruktivní koncentrace napětí v materiálu. Výsledkem tohoto procesu je vytvoření povrchu s charakteristickými lomy (Obr.7). Vizuální vzhled a textura řezaného povrchu se může značně lišit v závislosti na parametrech procesu a použitých materiálu. Řezání vodním paprskem vytváří vlastnosti řezaného povrchu a přesnosti, které jsou rozděleny do pěti úrovní kvality (Obr. 7). Ty jsou definovány drsností, úhlovou odchylkou a počátečními a koncovými vadami. [13]

Rozsah přítlaku, rychlost posuvu a řezné médium (brusný materiál se svými mechanickými vlastnostmi) mají vliv zásadní vliv na úroveň kvality. Proto je v praxi stanovení kvality řezaného povrchu velmi důležité. Pokročilý bezkontaktní optický stín nebo kontaktní profilometr by mohly být použity k posouzení stavu opracovaných povrchů abrazivním vodním paprskem. V průmyslové praxi je potřeba jednoduchý a nepříliš nákladný systém pro vyhodnocení kvality řezaného povrchu. Jeden ze způsobů by mohlo být využití fraktální analýzy, popřípadě kontaktní měření za pomoci laseru, či bezkontaktní měření za pomoci interferometru. [13]



Obrázek 7 – Kvalita povrchu při rozdílných řezných podmínkách [14]

## 2.2 Zkoumané oblasti heterogenního povrchu



Obrázek 8– Struktura profilových čar v jednotlivých částech heterogenního povrchu [15]


V oblasti řezu můžeme najít 3 jasně viditelné části řezu. Tyto části se nazývají primární, sekundární, terciální. Jsou způsobeny rozdílným působením řezného paprsku na obráběnou plochu. V primární části lze pozorovat velmi vysokou kvalitu a přesnost daného řezu. Je to zapříčiněno nulovou až minimální ztrátou energie mezi výstupem z trysky a řezem v dané oblasti. Sekundární oblast, které se taky říká oblast přechodová, je charakteristická svým poklesem kvality obráběného povrchu. Daný paprsek při průchodu primární částí ztrácí část své energie a to se projevuje na již zmíněné kvalitě povrchu přechodové oblasti. Zhoršená kvalita ale není na celé ploše, nýbrž pouze na některých částech. V poslední části neboli terciální, nemá paprsek dostatečnou energii, oproti předešlým částem a to se i projevuje na výsledném povrchu. Vznik terciální části však není pravidlem. Zcela běžně se v materiálu může vyskytnout pouze primární a sekundární část. To záleží na dané technologii a řezných podmínkách. V případě že má paprsek dostatek energie, vyskytne se ve výsledném řezu pouze část primární a sekundární.[15,16]

### 3 STATISTICKÉ PARAMETRY JAKOSTI POVRCHU

První zmínky o kladení důrazu na dodržování předem definovaných mír, se datuje již od dob starého Egypta. Může se sice zdát, že je to na míle vzdálené od dnešní doby, ale není tomu tak. V dnešní době je ale na tuto část vědy kladen mnohem větší důraz. Počínaje nakupováním surovin, které se buď váží na váze, nebo výroba převodové skříně s důrazem na výrobní kvalitu a kvalitu materiálů. Nové vědecké poznatky posouvají tuto vědu stále dál díky čemuž je kladen tlak na různá odvětví (chemické, strojírenství, potravinářství, ...). [17]

#### 3.1 Struktura povrchu

Jedná se o nasnímanou obrobenou plochu, na které při aplikaci obrábění vznikly nerovnosti. Tyto nerovnosti se z nasnímaného 3D formátu převedou na 2D formát a to tak. Tato operace se provede proložením roviny kolmé na obrobenou a nasnímanou plochu (viz obrázek 9). Výsledný profil vzniklý na dané rovině se nazývá profil povrchu. Z něj se pak nadále dají získat základní parametry jako tvar, vlnitost nebo drsnost. [18]



Obrázek 9 – schéma profilu povrchu [19]



### 3.1.1 Tvar

Při odfiltrování drsnosti a vlnitosti lze získat tzv. obecný tvar povrchu. Za určitých podmínek by se tento parametr profilu povrchu neboli skutečný tvar výrobku, měl shodovat s výrobním výkresem. [18]



Obrázek 10 – schéma profilu povrchu [18]

### 3.1.2 Vlnitost


Můžeme ji definovat jako nerovnost daného povrchu, která se při výrobním procesu vyskytuje a je nežádoucí. Její vznik je zapříčiněn otřesy a chvěním při výrobě, či špatně zvoleným technologickým postupem. Lze ji ovšem minimalizovat za předpokladu správného určení technologického postupu, řádného opevnění obrobku při obrábění či minimalizace chvění. [18]



Obrázek 11 – schéma vlnitosti povrchu [18]

### 3.1.3 Drsnost

Drsnost povrchu lze definovat jako křivku povrchu, která vznikla působením vlivů technologických procesů. Jedná se především o pohyb nástroje a obrobku vůči sobě. Výslednou drsnost lze ovlivnit například posuvem obráběné součásti, použité technologii opracování, zvoleným materiálem a dalšími technologickými vlivy. [18]



Obrázek 12 – schéma drsnosti povrchu [18]

### 3.2 Parametry struktury povrchu

Jedná se o parametry, které určuje norma ČSN EN ISO 4287. Tato norma dělí dané parametry do několika skupin:


- Výškové parametry
- Délkové parametry
- Tvarové parametry

Značení daných parametrů, které můžeme registrovat na daných výkresech, probíhá formou velkého a malého písmene. První písmeno je vždy označení daného profilu, ze kterého byl parametr zjištěn. Jedná se o anglický název daného parametru.

- P-parametr – výpočet ze základního profilu
- R-parametr – výpočet z profilu drsnosti
- W-parametr – výpočet z profilu vlnitosti [19]


#### 3.2.1 Výškové parametry

- Nejvyšší výška výstupku profilu – jedná se o nejvyšší výšku píku materiálu na vyhodnocované délce [19]




Obrázek 13 – Nejvyšší výška výstupku profilu [19]

- Největší hloubka prohlubně profilu – jedná se o nejdelší hloubku prohlubně materiálu na vyhodnocované délce [19]



Obrázek 14 – Nejvyšší hloubka prohlubně [19]


- Nejvyšší výška profilu – jedná se o součet délky nejvyššího píku a nejdelší prohlubně na vyhodnocované délce [19]



Obrázek 15 – Nejvyšší výška profilu [19]

### 3.2.2 Délkové parametry


- Materiálový poměr – jedná se o aritmetický průměr šířek prvků na vyhodnocované délce. Daný poměr se udává v procentech [19]



Obrázek 16 – Materiálový poměr profilu [20]

$$Rmr = \frac{B1+B2+B4+B5+...+Bn}{L} * 100\% \quad (1)$$

- Průměrná šířka prvků profilu – jedná se o aritmetický průměr šířek prvků na vyhodnocované délce. [19]



Obrázek 17 – Průměrná šířka profilu [19]

## 4 STATISTICKÉ HODNOCENÍ POVRCHU

### 4.1 EDA


Název metodiky vychází z anglického názvu Exploratori Data Analysis. Do češtiny se to dá přeložit jako průzkumová analýza dat. Jedná se o metodu, při které je možno zjistit, jaké nežádoucí vlivy působí na náš soubor dat. [21]

Mezi její zástupce patří:

- Diagram časové řady
- Box-plot diagram
- Histogram

#### 4.1.1 Diagram časové řady

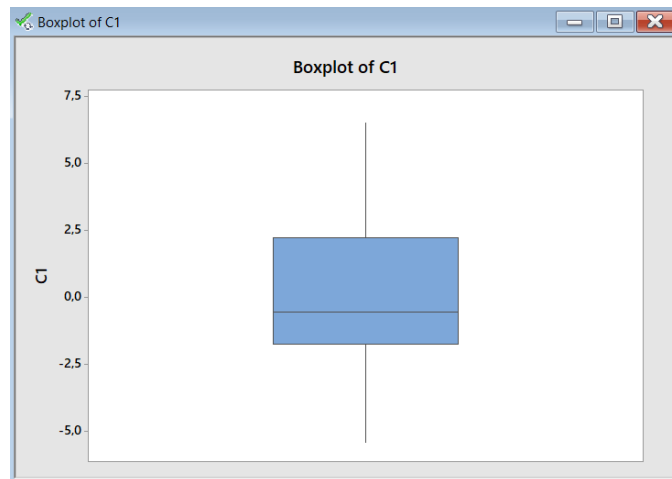
Jedná se o vynesení bodů do grafu za pomoci souřadnic X a Y. tyto body mohou ale také nemusí být propojeny spojnici trendu. Na ose X bývá vyneseno číslo měření, poloha měřeného bodu, ... na ose Y je vynesena číselní hodnota bodu. [22]



Obrázek 18 – diagram časové řady

### 4.1.2 Box-plot diagram


Box-plotový diagram neboli v češtině krabicový diagram. Slouží nám pro odhalení podezřelých hodnot, které je potřeba dále vyšetřit a zjistit, zda se jedná o chyby náhodné (žádoucí), nebo o outlayery. Graf je rozdělen pomocí kvantilů a kvartilů. [23]



Obrázek 19 – box-plotový diagram

### 4.1.3 Histogram

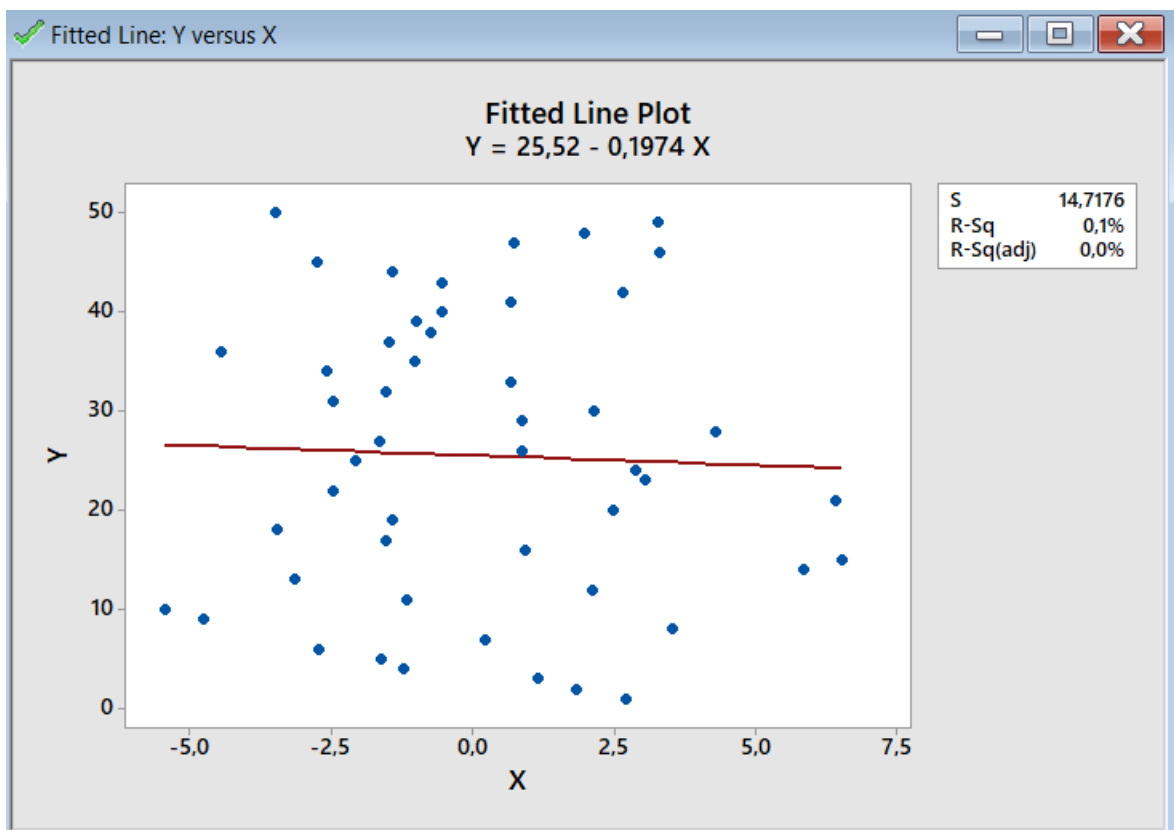
Rozděluje vyšetřovaný soubor do intervalů četnosti a vykresluje je do grafů. Ideální tvar histogramu je zvonovitého tvaru. To je ovšem pouze v ideálním případě. V praxi se setkáváme spíše s tvary šikmé, bimodální, plošné či hřebenové distribuce. [24]



Obrázek 20 – Histogram

## 4.2 Lineární regrese

Jedná se o hojně využívaný typ základní regrese, která má využití například u popisu heterogenních povrchů. Skládá se ze vstupních parametrů X a Y, kde Y je závislá proměnná na parametru X. Smyslem této analýzy je, aby výsledná regresní přímka co nejlépe vystihovala růst nebo pokles vyšetřovaných dat. [25]



Obrázek 21 – graf lineární regrese

## 5 NEURONOVÉ SÍTĚ

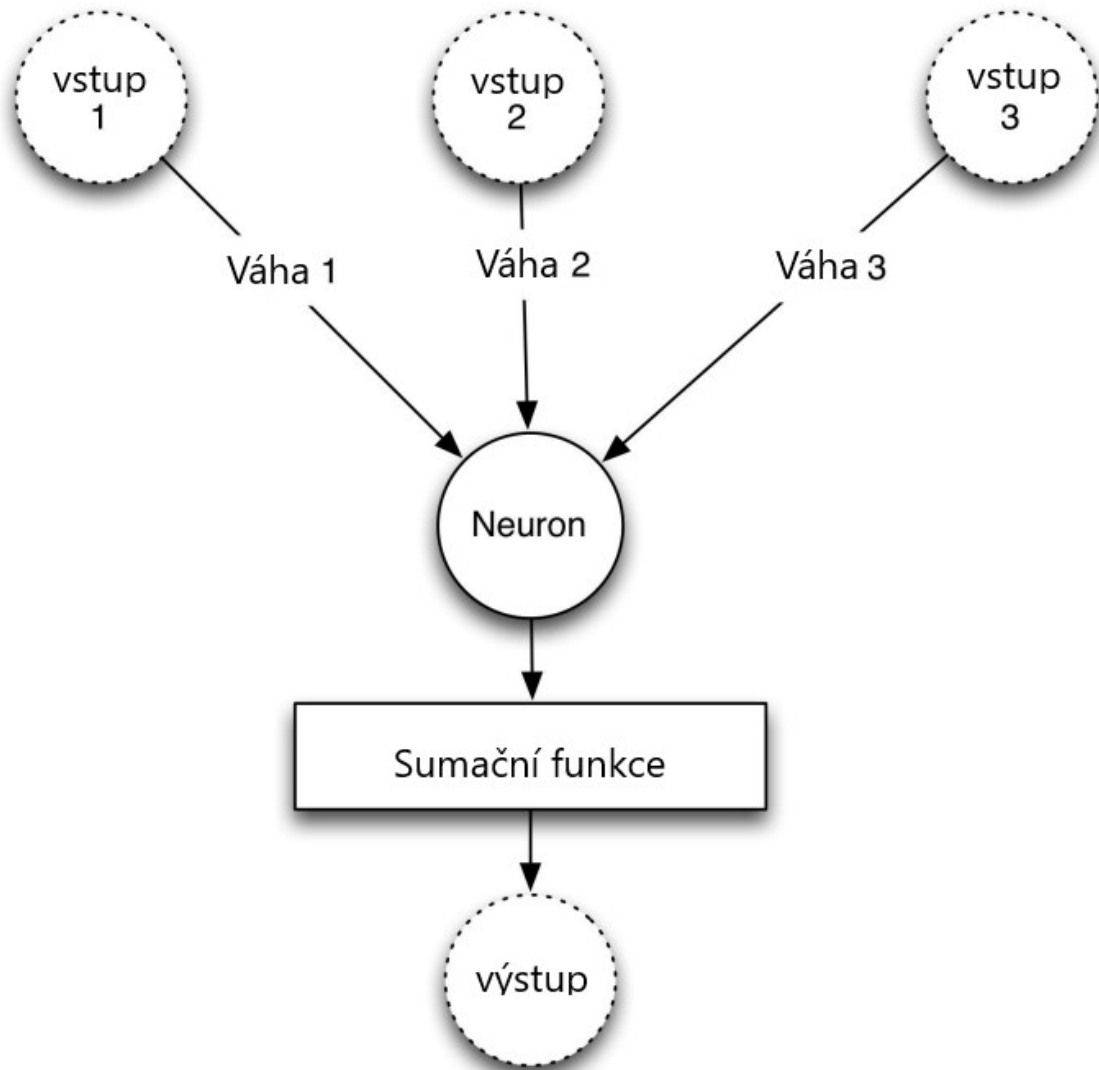
Velkou vizí neuronových sítí je vytvořit umělou inteligenci, jejichž architektura simuluje výpočty v lidském nervovém systému. To samozřejmě není jednoduchý úkol, protože výpočetní výkon nejrychlejšího počítače současnosti je nepatrným zlomkem výpočetního výkonu lidského nervového systému (mozku). Neuronové sítě byly vyvinuty brzy po nástupu počítačů v padesátých a šedesátých letech minulého století. Rosenblattův perceptronový algoritmus byl považován za základní stavební kámen neuronové techniky, který vyvolal počáteční nadšení z vyhlídek umělé inteligence. Po počáteční euforii však přišlo období zklamání, kdy údaje a výpočetně náročná povaha neuronových sítí, byla považována za překážku jejich použitelnosti. [26]

Nakonec na přelomu století vedla větší dostupnost dat a rostoucí výpočetní výkon k větším úspěchům neuronových sítí a tato oblast byla znovuzrozena pod novým označením "hluboké učení". Ačkoli jsme ještě daleko od dne kdy by se umělá inteligence (AI) přiblížila lidskému výkonu, existují specifické oblasti jako je rozpoznávání obrazu, samořídící automobily a hraní her, kde se umělá inteligence vyrovnala lidskému výkonu nebo jej překonala. Je také těžké předpovědět, co by umělá inteligence mohla být schopna v budoucnu dokázat. [26]

### 5.1 Neuron

Většina struktur neuronových sítí využívá určitý typ neuronu. Programátoři neustále zavádějí mnoho různých druhů neuronů a neuronových sítí. V důsledku toho není možné obsáhnout všechny jejich architektury. Mezi implementacemi neuronových sítí však existují některé společné rysy. Algoritmus, který se nazývá neuronová síť, se obvykle skládá z jednotlivých propojených jednotek i přes to, se tyto jednotky mohou, ale nemusí nazývat neurony. Ve skutečnosti se název pro jednotku zpracování neuronové v různých literárních zdrojích liší. Může to být např. nazývat uzal, neuron nebo jednotka. [27]






Obrázek 22 – Schéma modelu neuronu [27]

Umělý neuron násobí každý z těchto vstupů váhou. Poté tyto hodnoty sečte a tento součet předá sumační funkci. Umělý neuron přijímá vstupy z jednoho nebo více zdrojů, které mohou být jiné. Tento vstup je obvykle binární. Binární vstup je často kódován jako true (1) a false (0). Každá vstup je vynásoben příslušnou vahou a součin tohoto násobení je vložen do sumační (aktivační) funkce, která je znázorněna obecným vztahem (2), kde  $X$  je hodnota vstupu a  $W$  je váha. Výsledkem tohoto procesu je jediný výstup z neuronu. [27]

$$sum = W * X = \sum_{i=1}^m w_j x_j \quad (2)$$

## 5.2 Perceptron

Perceptrony, byly představeny Frankem Rosenblattem v roce 1957. Funkcí perceptronu je klasifikace různých vzorů. V nejběžnějším případě se dá perceptron představit jako struktura s jednou vrstvou neuronů, které jsou propojeny se vstupy systému. Tato spojení mají váhové koeficienty, které lze během procesu trénování měnit. Cílem je nalézt takovou sadu vah  $w_0, w_1, \dots, w_n$ , aby signál na výstupu perceptronu byl 1, pokud vstupní vektor patří do třídy 1, a 0, pokud vektor patří do třídy 0. Váhy se upravují v souladu s pravidlem (nebo zákonem) učení perceptronu. Perceptron byl jedním z prvních paradigmat neuronových sítí a stále se používá příležitostně. Jejich jednoduchá struktura zařazení a rychlá konvergence při trénování způsobily, že se Rosenblatovy perceptrony pro výzkumníky staly atraktivní. Rosenblatt zdůrazňoval, že perceptrony nebyly vyvinuty k řešení žádné praktické úlohy rozpoznávání vzorů nebo umělé inteligence. Jednalo se spíše o model lidského mozku než o aplikaci technické zařízení. Rosenblattův perceptron je často považován za jednovrstvý. [28]



Obrázek 23 – Schéma neuronové sítě (perceptronu) [15]

### 5.3 Způsoby využití

V posledních deseti letech se zvýšil zájem zejména o metodiku pravděpodobnostních neuronových sítí (PNN). Toto tvrzení lze stvrdit nahlédnutím do jejího použití ve velkém množství vědeckých článků z poslední doby. Metodika PNN se často používá zejména v klasifikačních úlohách a byla úspěšně aplikována při řešení problémů souvisejících se zvyšováním bezpečnosti elektronické pošty, zcela jistě v rámci systémů detekce narušení. Tato koncepce usnadnění klasifikační úlohy se uplatnila také v medicíně, zejména při zjišťování odolnosti vůči antibiotikům, dále při diagnostice hepatitidy a při získávání řešení dalších medicínských problémů. [29]

Vzhledem k současnému dynamickému vývoji v oblasti explorační analýzy dat lze pozorovat rozšiřující se zájem o intervalovou analýzu. Základní aplikací intervalové analýzy je přitom zajištění vhodné kvality přesnosti numerických výpočtů. Navíc lze jednoduchým způsobem rozšířit použití intervalové analýzy na vícerozměrný případ. V důsledku toho je algoritmus velmi snadno interpretovatelný. Kromě toho se snižuje složitost výpočtu vzhledem k jiným podobným metodám používaným pro modelování neurčitosti. [29]

## **II. PRAKTICKÁ ČÁST**

## 6 CÍLE DIPLOMOVÉ PRÁCE

Cílem diplomové práce bylo stanovení heterogenity povrchu za pomoci vhodné regresní analýzy. Tato analýza byla aplikována na data získané s předem připravených vzorků, které byly obrobena za pomoci nekonvenčního obrábění, přesněji řečeno za pomoci vodního paprsku s abrazivem. K tomuto úkonu byl použit program Minitab. Dalším cílem je aplikace neuronových sítí na tento povrch a nalezení sítě tak, aby byla schopna s co nejlepší přesností daný heterogenní povrch. K tomuto účelu byl využit statistický program QCexpert zpřístupněný našemu oboru.

## 7 VÝROBA A PŘÍPRAVA VZORKŮ

### 7.1 Vlastnosti zvoleného materiálu a řezné parametry


Materiál, z něhož jsou vyrobeny zkoumané vzorky, je hojně využívaným materiálem pro letecký (trup letadel, kritické letadlové struktury, ...) a dopravní průmysl. Dále se také používá pro výrobu vědeckých nástrojů, ortopedických pomůcek a šroubovaných produktů. Má velice dobrou obrobitelnost a slabší chemickou odolnost, není vhodným materiálem pro svařování. Pevnost v tahu je 420 MPa a mez kluzu 270 MPa. Námi zkoumané vzorky dostaly označení Q1-Q4. jednalo se o vzorky obrobené za pomoci technologie řezání vodním paprskem. Řezné podmínky byly následující: Q1 40 mm/min, Q2 50 mm/min, Q3 60 mm/min a Q4 70 mm/min. Tlak kapaliny byl konstantní 200 MPa.



Obrázek 24 – vzorky s označením Q1-Q4

### 7.2 Úprava vzorků před měřením

Před samotným měřením, bylo nutné dané vzorky upravit. Bylo to z důvodu snadného upevnění měřeného vzorku do námi zvoleného přístroje. Jednalo se o rovinný řez napříč vzorkem (Obrázek 25).



Obrázek 25 – úprava vzorku

## 8 PROCES MĚŘENÍ A ZVOLENÉ MĚŘÍCÍ PARAMETRY

### 8.1 Použitý měřicí přístroj Talysurf CLI 500


Pro naměření hodnot a získání výsledků bylo použito měřicího přístroje, dostupného v laboratořích našeho ústavu, Talysurf CLI 500. Jeho výrobcem je firma Taylor Hobson, která k předním výrobcům měřicí techniky. Daný přístroj byl vybaven konfokální hlavou (Chromatic Length Aberration – CLA), která funguje na bázi snímání a vyhodnocování odražených paprsků dle jejich vlnových délek. Přenesení dat bylo provedeno za pomoci firemního programu Talymap, dodávaného jako součást daného přístroje. Tento program zabezpečuje všechny kontrolní, řídicí a vyhodnocovací procesy celého přístroje. [30]



Obrázek 26 – měřicí přístroj Talysurf CLI 500

## 8.2 Kalibrace přístroje a následná volba parametrů snímání

Na přístrojovou desku určenou ke uložení zkoumaného vzorku byla umístěna oddělená část námi zkoumaného materiálu. Následně byla za pomoci programu Talymap načteny kalibrační soubory. Následně se provedla automatická kalibrace systému. Poté bylo nastaveno příčné snímání daného vzorku vzhledem k rovině řezu a následné vyhodnocení.



Obrázek 27 – uložení vzorku

Jako další krok následovala volba parametrů snímání. Počátek souřadnicového systému, jenž definoval plochu, na které byl proveden sběr dat, byl vzhledem k uložení vzorku vybrán, jako levý horní okraj. Ohraničení tohoto souřadnicového systému bylo na ose X 7,2 mm a na ose Y 4,2. Vzdálenost mezi jednotlivými body měřený byla 25  $\mu\text{m}$ , jak u osy X, tak i u osy Y. počet bodů měření byl 169. Definovaná rychlost měření byla stanovena na 500  $\mu\text{m/s}$  v jednom směru s rychlostí návratu snímače 200  $\mu\text{m/s}$ . celková doba měření byla stanovena na 2h 35min.



## 9 STATISTICKÉ VYHODNOCENÍ VZORKŮ

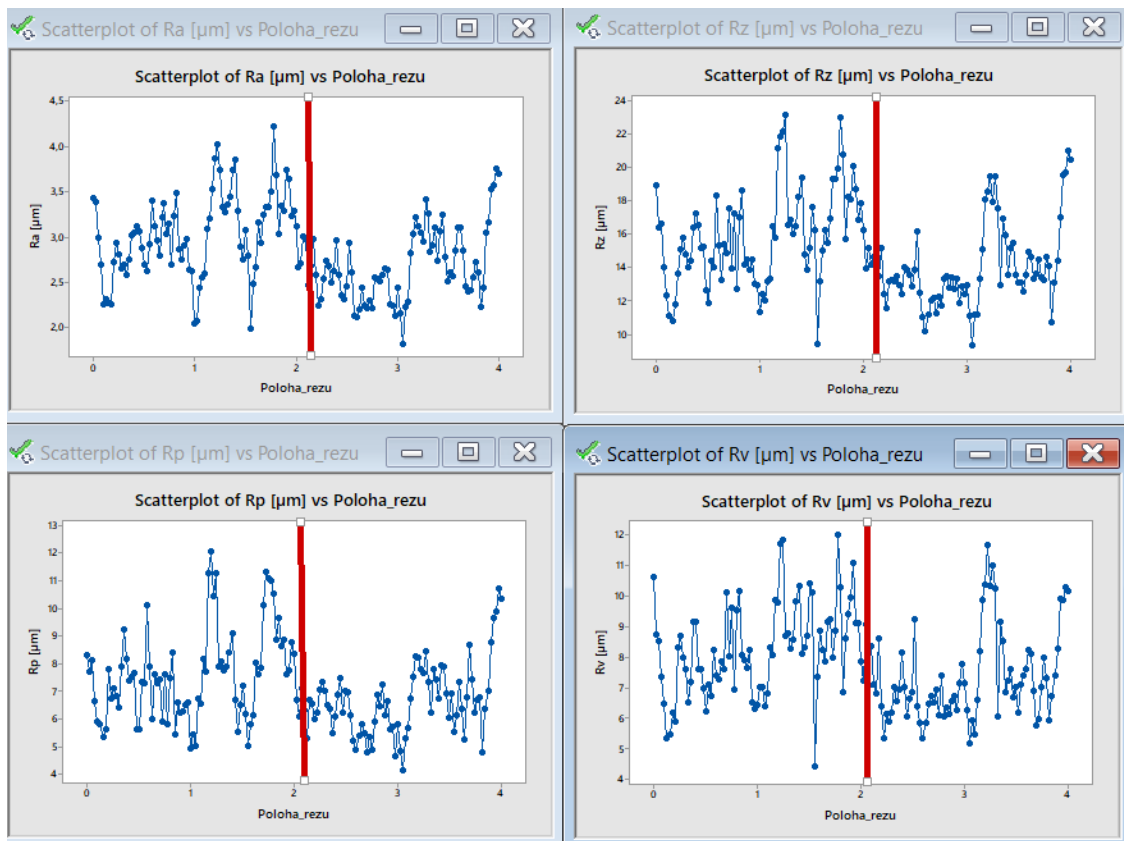
Díky programu Talymap byly získány parametry drsnosti povrchu, dle normy ISO 4287. K vypracování byl použit statistický program minitab. K dispozici byla široká škála parametrů, a proto následoval výběr několika z nich. Jednalo se o tyto:

- Ra – Průměrná aritmetická úchylka posuzovaného profilu
- Rz – Největší výška profilu
- Rp – Nejvyšší výška výstupku měřeného profilu
- Rv – Největší hloubkou prohlubně měřeného profilu

### 9.1 Zpracování výsledků měřeného vzorku Q1

#### 9.1.1 Ověření oblasti heterogenity

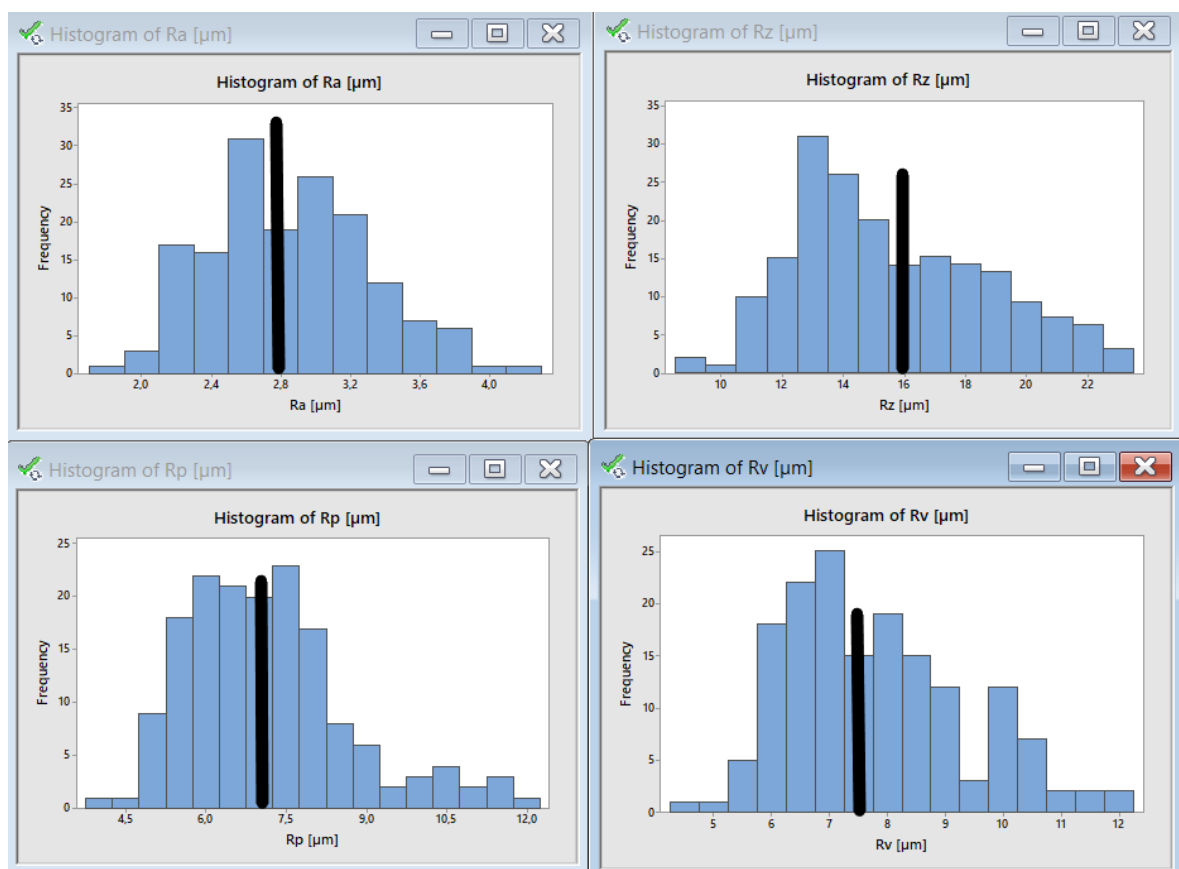
Jako první byl zhotoven graf Scatterplot, kde osa X představuje polohu měřeného bodu a na ose Y byla vynesena jeho hodnota R. V tomto grafu, je-li povrch heterogenní, lze tuto strukturu povrchu velice rychle zpozorovat.



Obrázek 28 – závislost parametrů Ra, Rz, Rv, Rp vzorku Q1 na poloze

Po vyhotovení grafů byla zpozorována možná heterogenita. Předpokládaná změna povrchu je přisuzována budu, který má hodnotu své Y souřadnice rovnu 2,1.

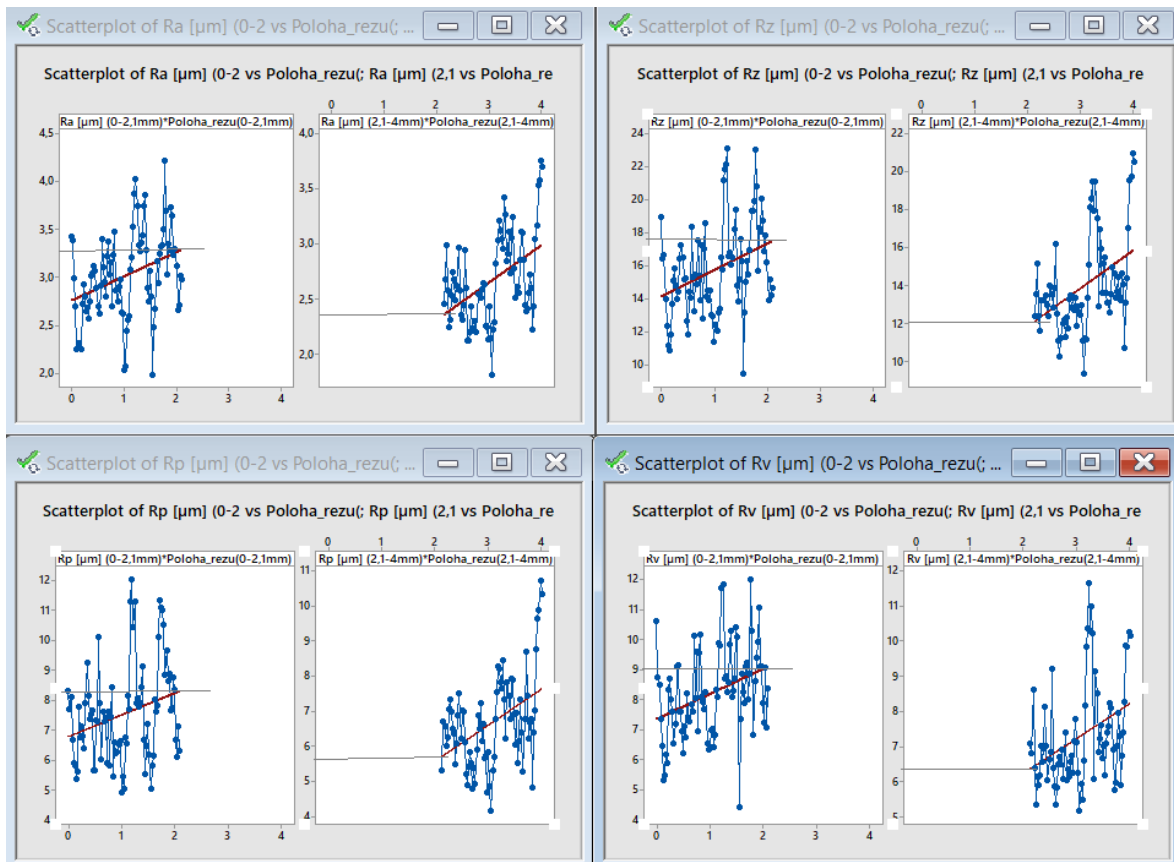
Jako další krok byl zvolen použití grafu s názvem histogram. Na tomto grafu lze provést další posouzení, zda se jedná o heterogenní povrch či nikoli. V případě heterogenity povrchu bude mít přítomný histogram znaky předpokládaného povrchu. Po zhotovení bylo zaznamenán předpoklad heterogenity, jelikož daný graf nese náznaky 2 různých souborů povrchu. Tento předpoklad byl zaznamenán černou čarou v obr. 29.



Obrázek 29 – histogramy parametrů Ra, Rz, Rv, Rp

Byl vyřčen pouze předpoklad, který je nutný podložit statistickou metodou. Jako další krok bylo vyhotovení dalšího Scatterplotu. Tentokrát bylo vyhotovení trochu odlišně, než je tomu na Obr.28. Došlo k rozdělení dat v předpokládaném bodu přechodu mezi dvěma různými oblastmi povrchu a následné proložení těchto bodů regresní přímkou.


### 9.1.2 Užití regresních analýz



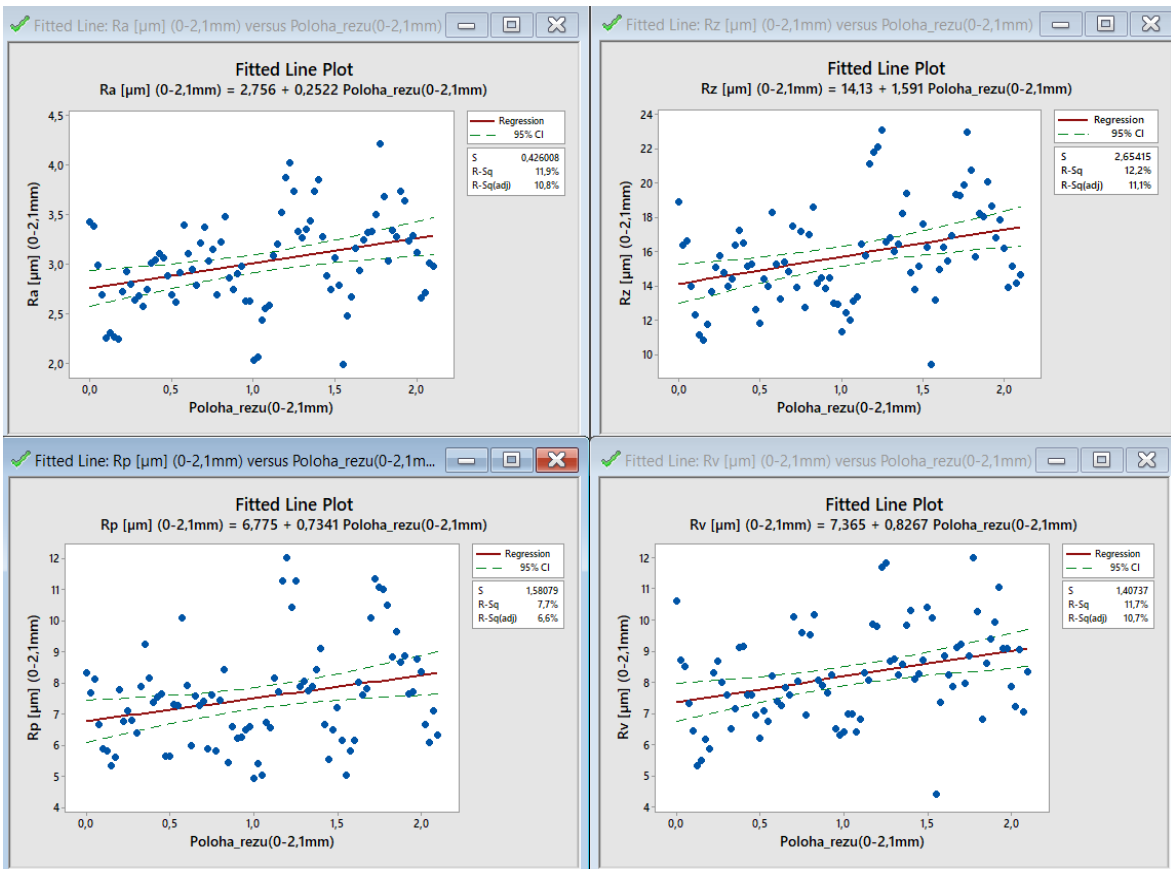
Obrázek 30 – scatterplot rozdělených parametrů Ra, Rz, Rv, Rp proložených lineární regresí

Na grafech (Obr.30) bylo sledováno dvou skutečností. To první bylo, že v rozdělených datech se opravdu vyskytuje lineární regrese. Druhá je, že koncový bod lineární regrese v intervalu (0-2,1) a počáteční bod lineární regrese v intervalu (2,1-4) se spolu neshodují a tím nastala kolize mezi těmito přímkami. Tato skutečnost nastala díky umělému rozdělení datového souboru.

V dalším kroku bylo vyhotoveno čtyř grafů lineárních regresních analýz. Bylo tomu tak pro parametry Ra, Rz, Rv, Rp omezených polohou bodu pro (0-2,1). Bylo tomu tak pro detailnější zjištění rozptýlů bodů a následné hodnotě parametru R-Sq.



Obrázek 31 – lineární regresní analýza Rz v intervalu (0–2,1mm)



Obrázek 32 – lineární regresní analýza Ra, Rz, Rv, Rp v intervalu (0–2,1mm)

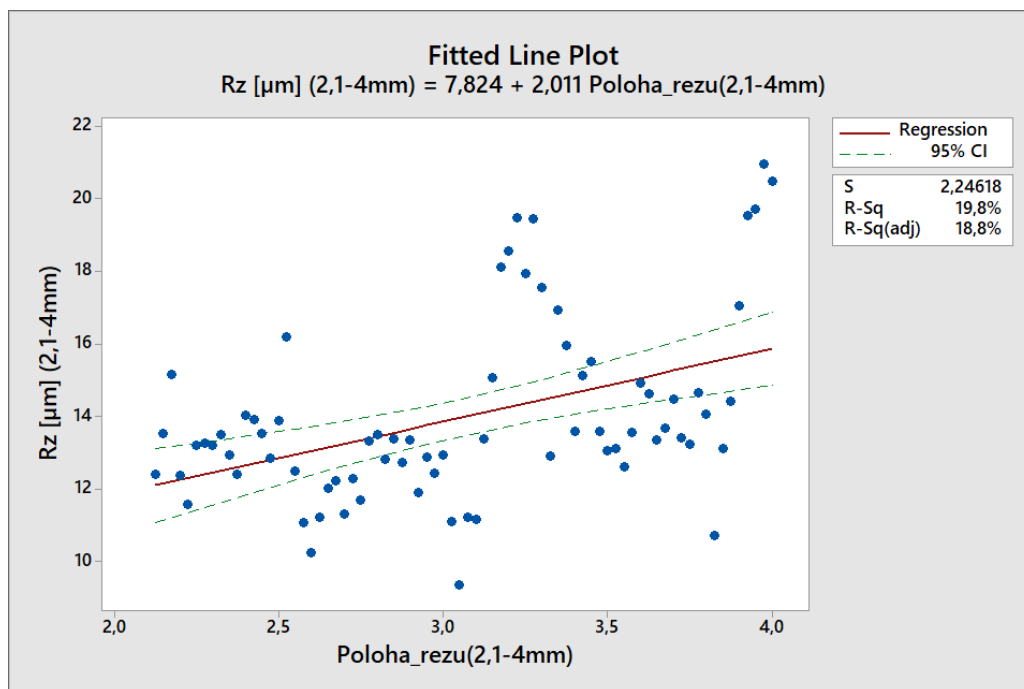
Po důkladném prozkoumání všech grafů lze potvrdit skutečnost, že je v souboru dat s intervalem měření (0-2,1) opravdu přítomná lineární regrese. Dalším faktem je, že daný soubor obsahuje obrovský rozptyl dat. Model byl tedy shledán významným s obrovskými rozptyly dat u všech parametrů.

V dalším roku byla provedena kontrola významnosti modelů v programu QC.Expert, která použil Fisher-Snedecorův test významnosti modelu a dospěl k těmto závěrům:

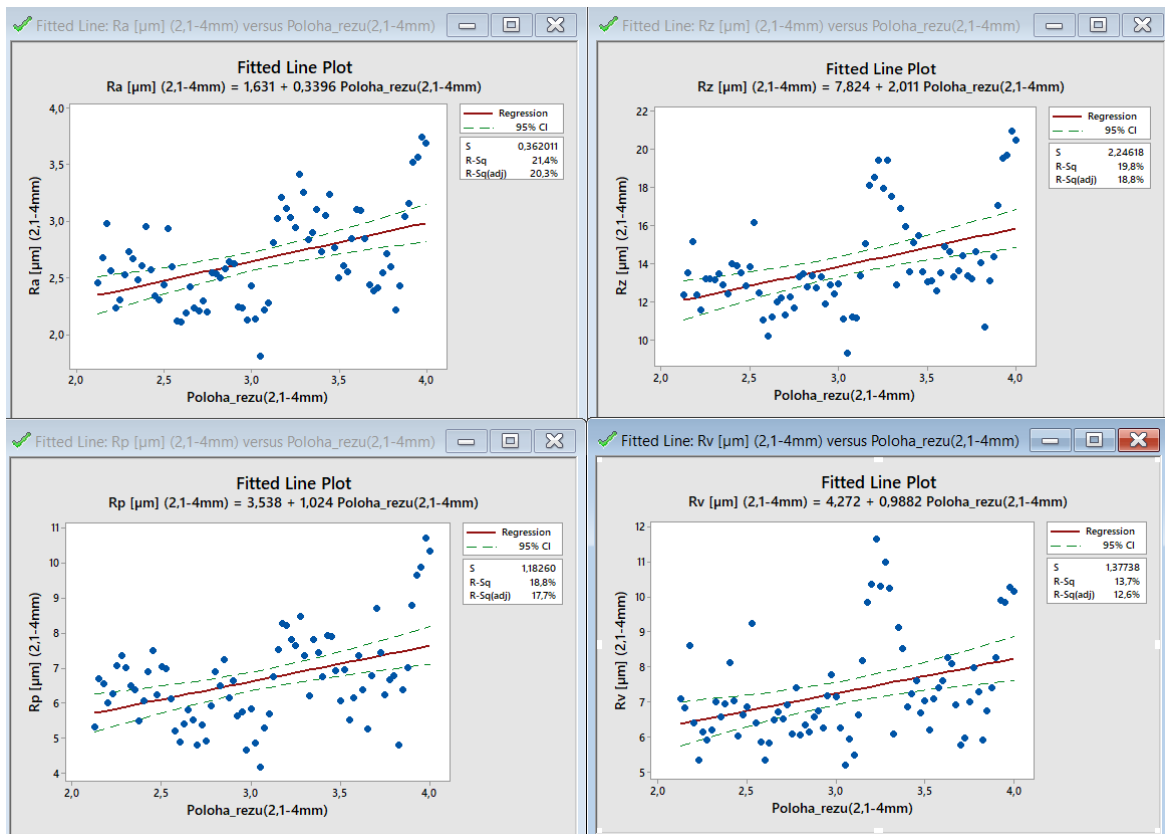
Tabulka 1 – výsledky Fisher-Snedecorův test významnosti

	Ra (0-2,1)	Rz Ra (0-2,1)	Rp Ra (0-2,1)	Rv Ra (0-2,1)
Hodnota kritéria F	11,2077	11,4910	6,8978	11,0350
Kvantil F	3,9559	3,9559	3,9559	3,9559
Pravděpodobnost	0,0012	0,0010	0,0102	0,0013
Závěr	Model je významný	Model je významný	Model je významný	Model je významný

Jako další krok bylo vyhotovení modelů lineárních regresí s daty o intervalu polohy měření (2,1-4), pro parametry Ra, Rz, Rv, Rp.

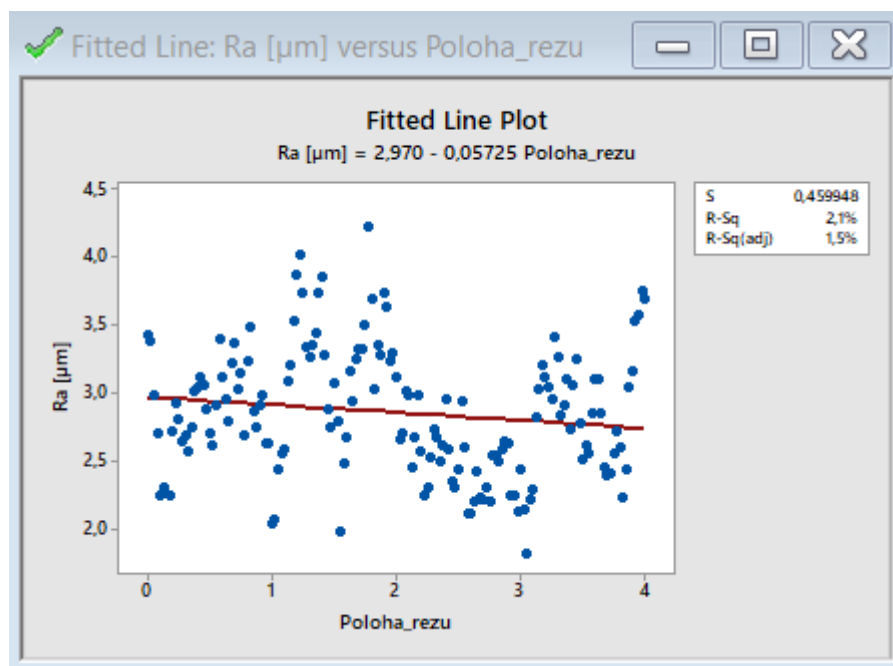


Obrázek 33 – lineární regresní analýza Rz v intervalu (2,1 - 4 mm)




Obrázek 34 – lineární regresní analýza Ra, Rz, Rv, Rp v intervalu (0-2,1mm)

### 9.1.3 Aplikace regresní analýzy na nerozdělené data



Obrázek 35 -aplikace lineární regrese na data



Obrázek 36 – aplikace kubické regrese na data

#### 9.1.4 Závěr analýzy vzorku Q1

Po sestavení grafů lineárních analýz, pro parametry Ra, Rz, Rv, Rp v intervalu měření (2,1-4), bylo shledáno několik skutečností. Zkoumané soubory dat mají znaky lineární regrese. Jako další bylo zpozorováno obrovských rozptylů dat na daných intervalech. Lze konstatovat, že dané lineární regrese se v dat jsou významné, ovšem s obrovským rozptylem zkoumaných dat. Toto tvrzení potvrdila i analýza v programu QC.Expert (tab.2). po aplikaci regresních analýz se ukázala tato metoda jako nevhodná k popisu heterogenního povrchu, což je ve shodě s dostupnou literaturou.

Tabulka 2 – výsledky Fisher-Snedecorův test významnosti

	Ra (2,1-4)	Rz (2,1-4)	Rp (2,1-4)	Rv (2,1-4)
Hodnota kritéria F	20,11315	18,3176	17,1237	11,7665
Kvantil F	3,97022	3,9702	3,9702	3,9702
Pravděpodobnost	1,6209	$5,526210^{-5}$	$9,1646 \times 10^{-5}$	$9,8949 \times 10^{-4}$
Závěr modelu	významný	významný	významný	významný

## 9.2 Zpracování výsledků měřeného vzorku Q2

### 9.2.1 Ověření oblasti heterogenity

Jako první byl zhotoven graf scatterplot. Na Ose X byly vyneseny hodnoty polohy vzdálenosti bodu od počátku měření. Osa y obsahovala číselnou hodnotu daného parametru Ra, Rz, Rv, Rp.




Obrázek 37 – závislost parametrů Ra, Rz, Rv, Rp vzorku Q2 na poloze

Po prozkoumání výsledků z datových souborů byly zpozorovány znaky možné homogenity. Píky vzniklé na grafu by tudíž byly podezřelé hodnoty a následovalo by hodnocení dle metodiky EDA.

Naměřená data byly porovnány s fotkami, které vznikly využitím mikroskopu dostupném na naší fakultě. Tyto snímky můžeme pozorovat na Obr.36.

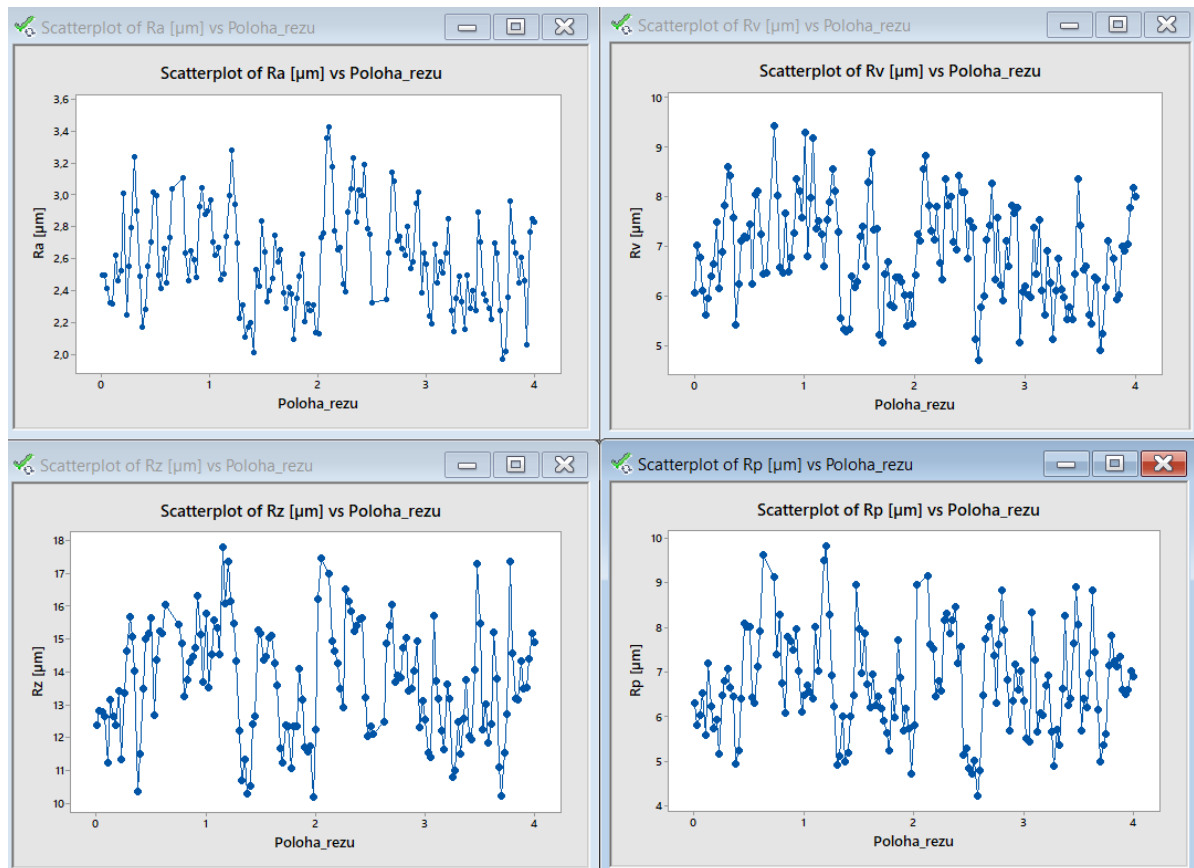




Obrázek 38 – měřená plocha pod mikroskopem

Po porovnání nasnímané plochy a Obr.36 byl vyřčen závěr, že se v tomto případě jedná o zcela jasný homogenní povrch. Myšlenka přítomnosti podezřelých hodnot na grafech s Obr.35 se prokázala jako pravděpodobná. Bylo tomu tak díky prohlubním vzniklých na obrobené a nasnímané ploše. Tyto hodnoty byly ze souboru vyjmuty a k povrchu se přistoupilo jako k homogennímu.

Po odstranění byly znova vygenerovány grafy scatterplot.

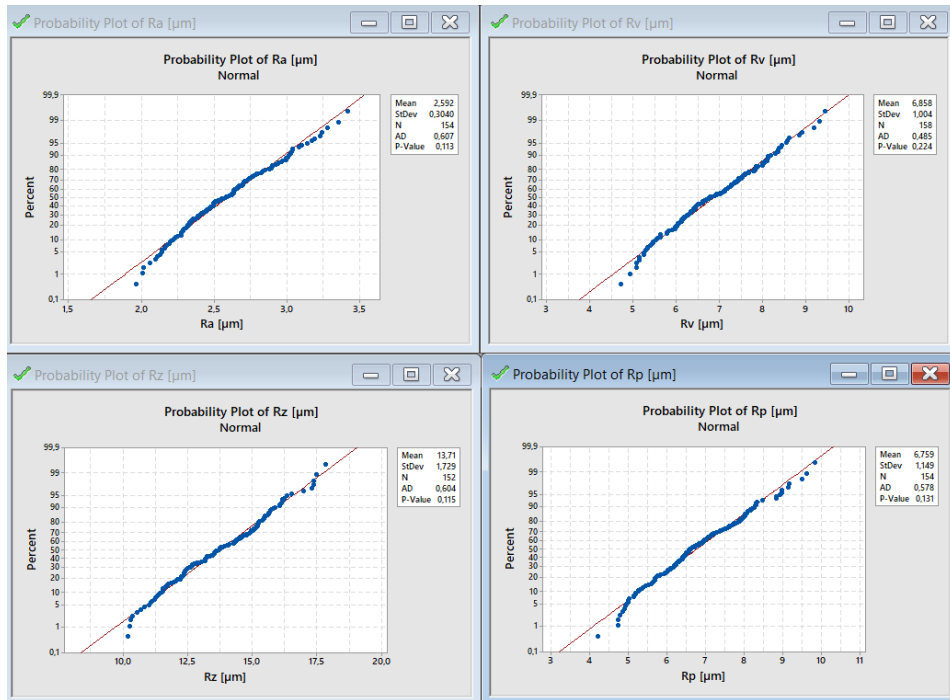


Obrázek 39 – závislost parametrů Ra, Rz, Rv, Rp vzorku Q2 na poloze

Po odstranění bylo definitivně rozhodnuto že jde s největší pravděpodobností o druh homogenního povrchu. Proto byl nadále za pomoci hypotéz vytvořen graf na kontrolu normality, kterou musí obsahovat každý homogenní povrch. Následně bylo vyhotovena Analýza v programu QC. Expert. Z té vyplynulo že daný povrch nenese známky heterogenity a regresní analýza je nevýznamná

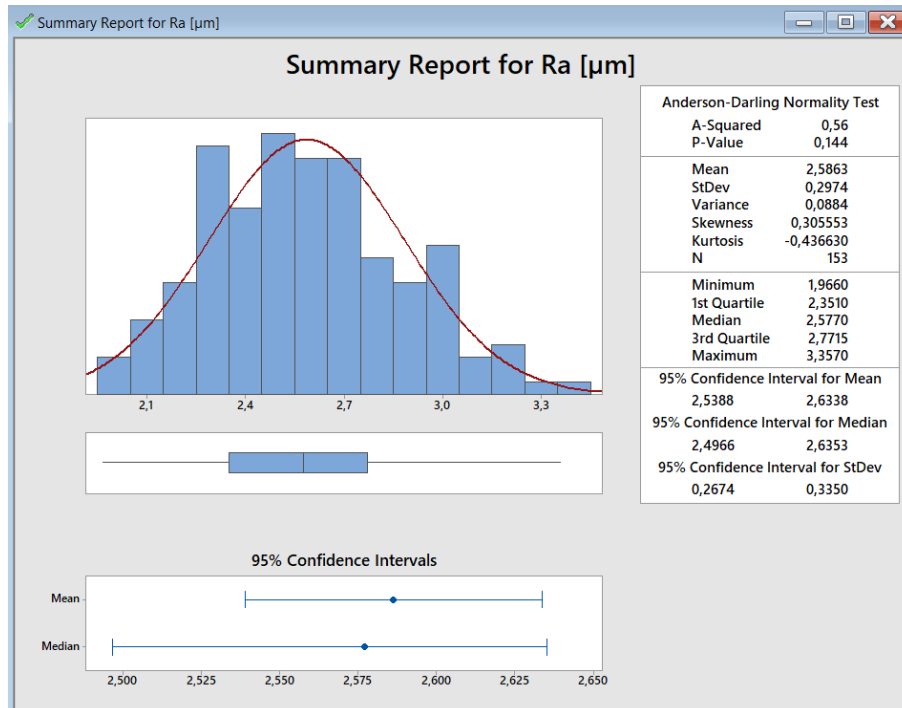
### 9.2.2 Ověření Testu normality

Byl sestrojen test normalit (Obr.38). V testu byla položena  $H_0$ : data pochází z normálního rozdělení,  $H_a$ : data pochází s jiného než normálního rozdělení,  $1-\alpha=95\%$ . výsledný parametr P nám ve všech případech vyšel p větší než  $\alpha$ , tedy nebyla zamítnuta hypotéza, že data mají normální rozdělení.

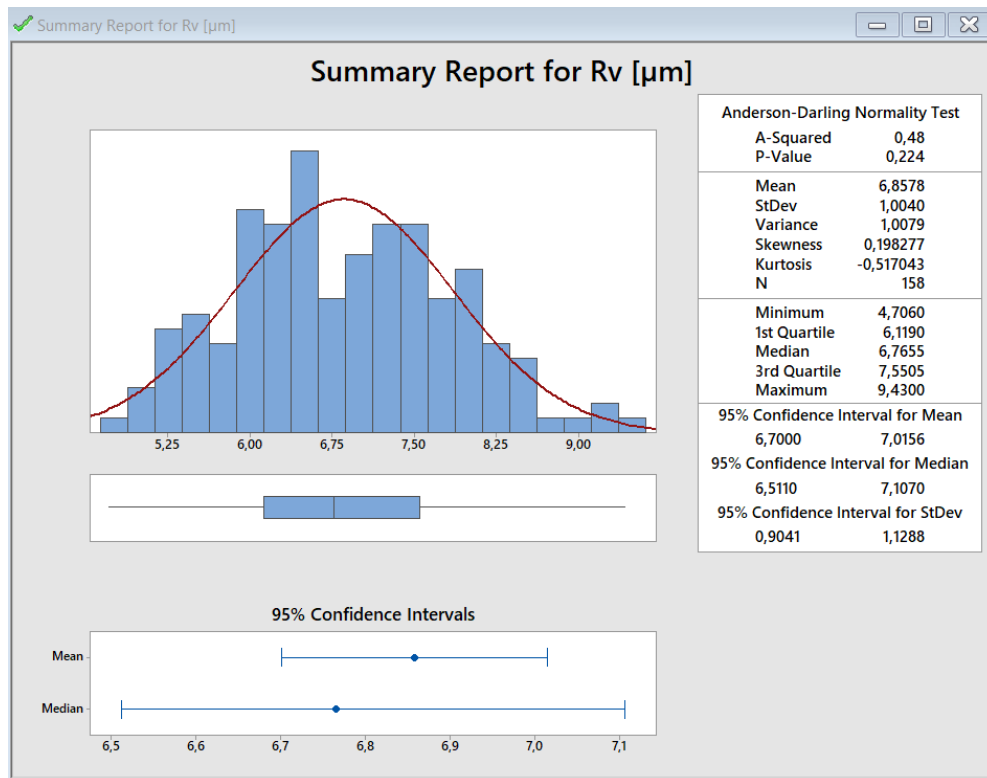


Obrázek 40 – test normalit parametrů Ra, Rz, Rv, Rp vzorku Q2

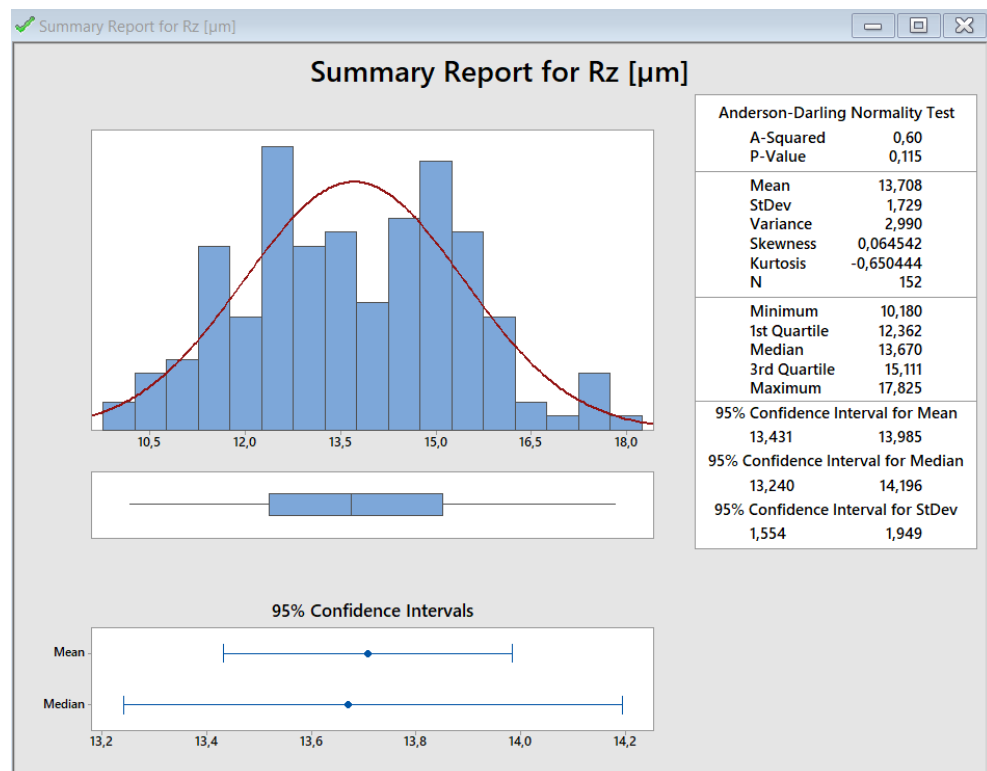
### 9.2.3 Aplikace metodiky EDA



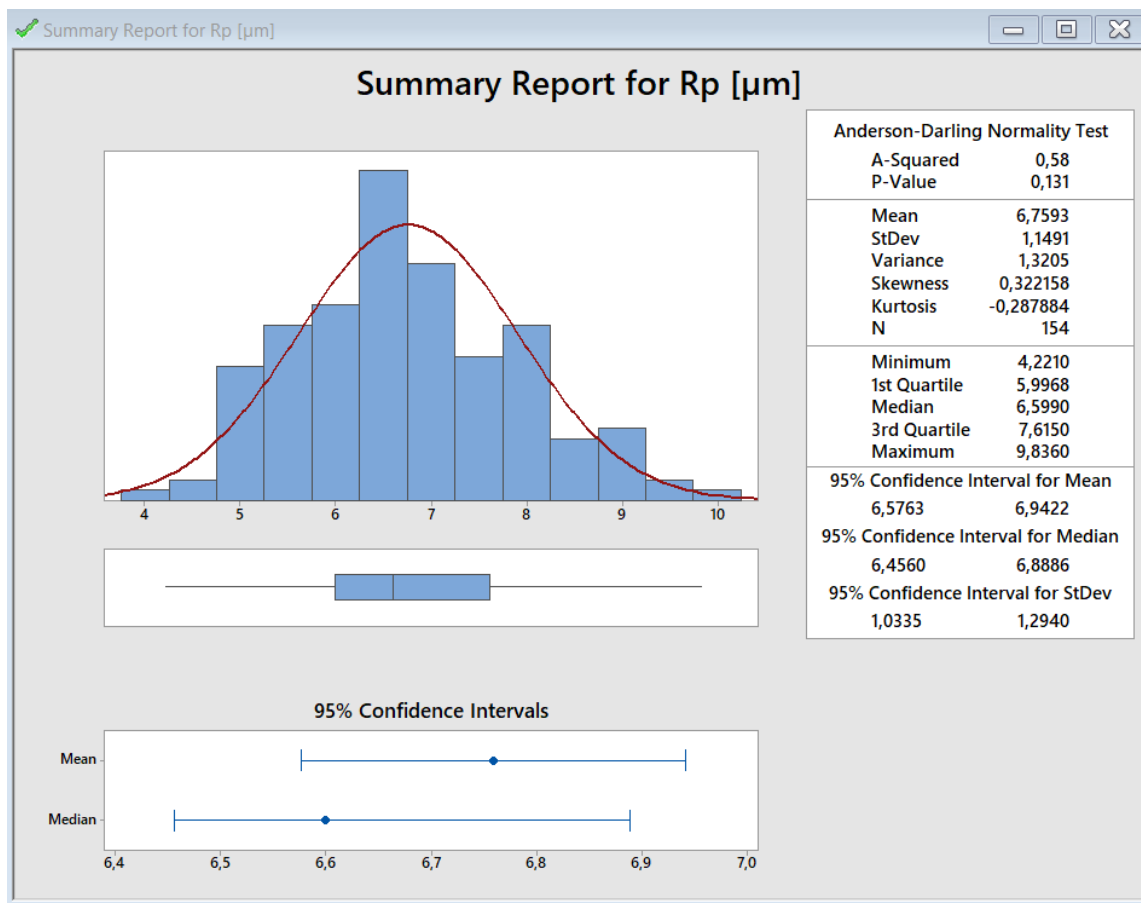
Obrázek 41 – souhrnná zpráva pro parametr Ra vzorku Q2



Obrázek 42 – souhrnná zpráva pro parametr Rv vzorku Q2



Obrázek 43 – souhrnná zpráva pro parametr Rz vzorku Q2



Obrázek 44– souhrnná zpráva pro parametr Rp vzorku Q2

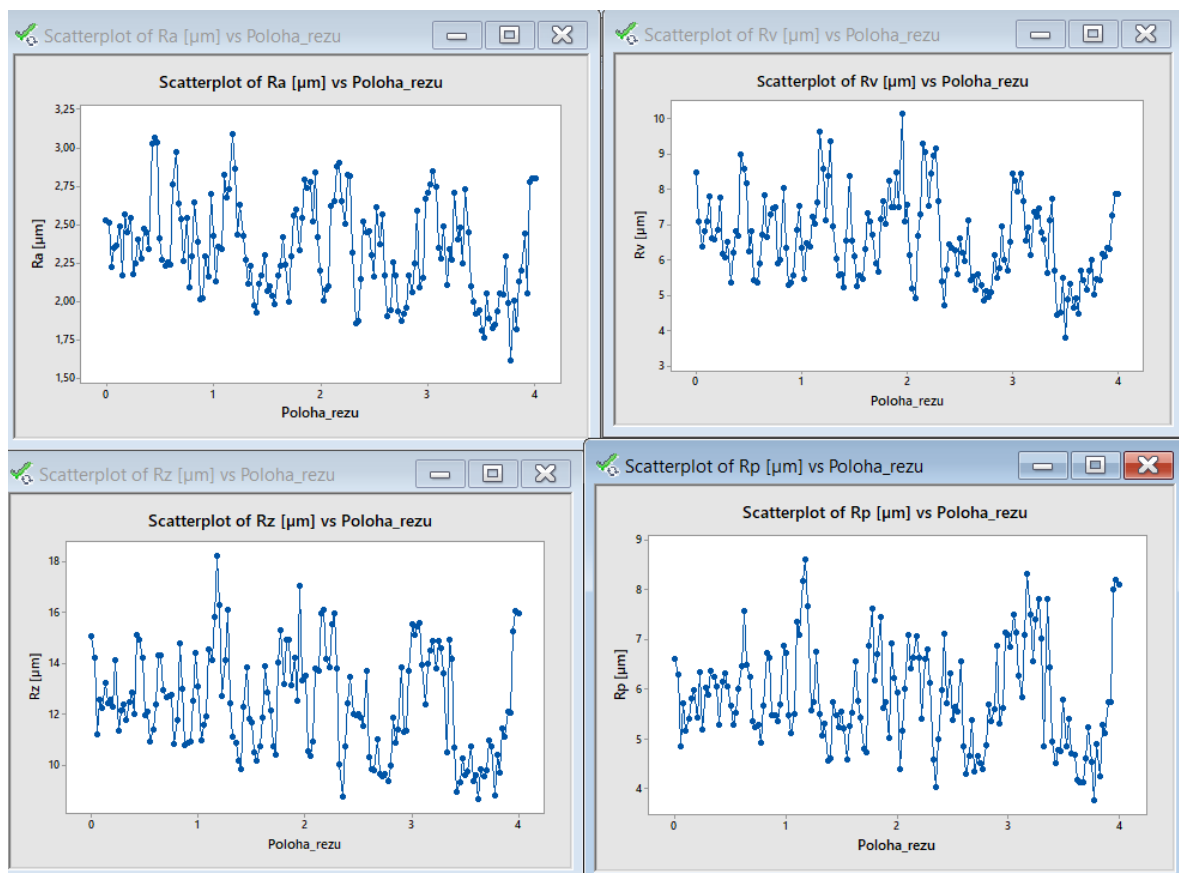
#### 9.2.4 Závěr analýzy vzorku Q2

Byla provedena datová analýza, díky které lze zcela bezpochyby vyřknout závěr, že data pochází s normálního rozdělení a jde tedy o homogenní povrch. Toto tvrzení bylo řečeno poté, co nám z Anderson-Darlingova testu vyšel parametr  $p$  pokaždé větší než hodnota parametr  $\alpha$ , s možností omylu 5 %. Byla zhotovena hodnota pro minimum, první kvartil, medián, třetí kvartil a maximum. I přes větší variační rozpětí na konfidenční interval vyšel jak pro medián, tak pro průměr.

### 9.3 Zpracování výsledků měřeného vzorku Q3

#### 9.3.1 Ověření heterogenity

Jako první byl zhotoven graf scatterplot. Na Ose X byly vyneseny hodnoty polohy vzdálenosti bodu od počátku měření. Osa y obsahovala číselnou hodnotu daného parametru Ra, Rz, Rv, Rp.



Obrázek 45 – závislost parametrů Ra, Rz, Rv, Rp vzorku Q3 na poloze

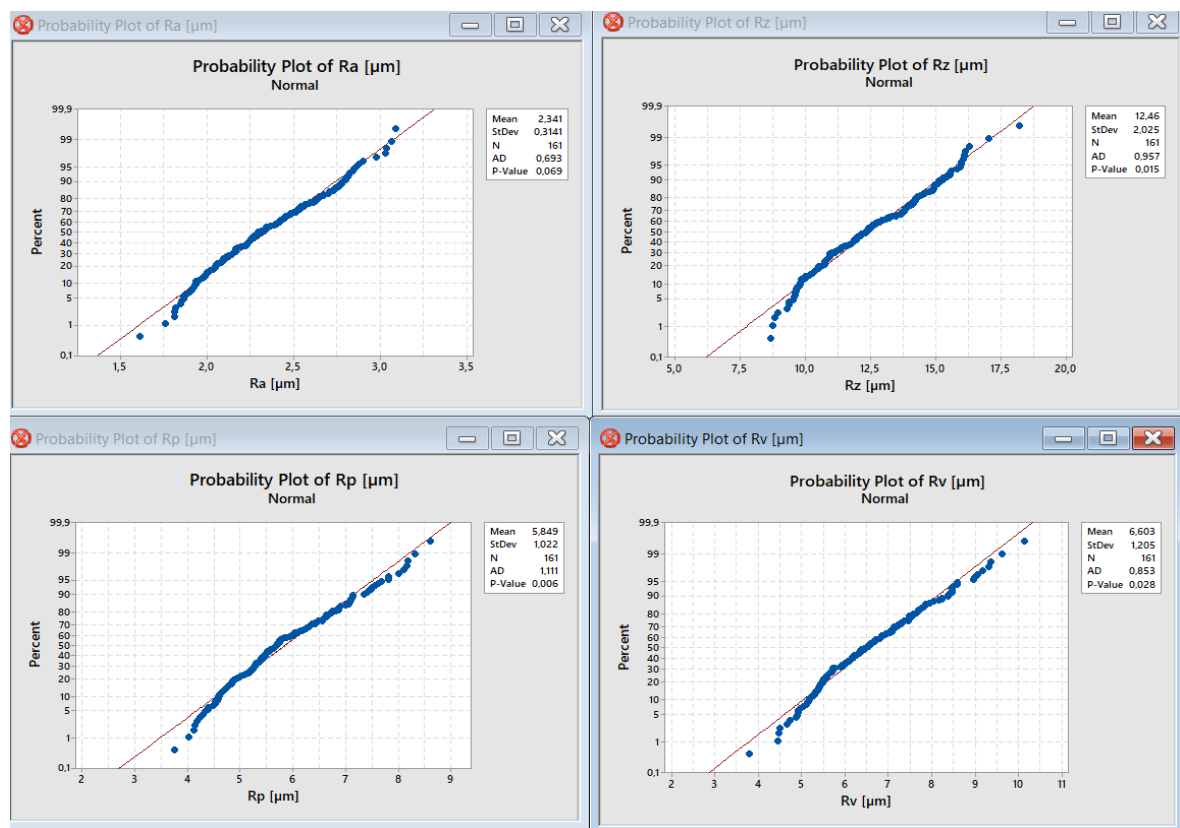
Po prozkoumání dat, byl vznesen předpoklad o homogenitě povrchu. Následné zkoumání v programu QC.Expert vyvrátilo přítomnost heterogenity, na základě nevýznamnosti regresní analýzy.

V dalším kroku byl sestaven graf normálního rozdělení, na základě předpokladů homogenního povrchu. Tento předpoklad homogenity byl také podložen výslednou podobou povrchu, který byl vyfocen a prozkoumán pod mikroskopem dostupným v laboratořích.



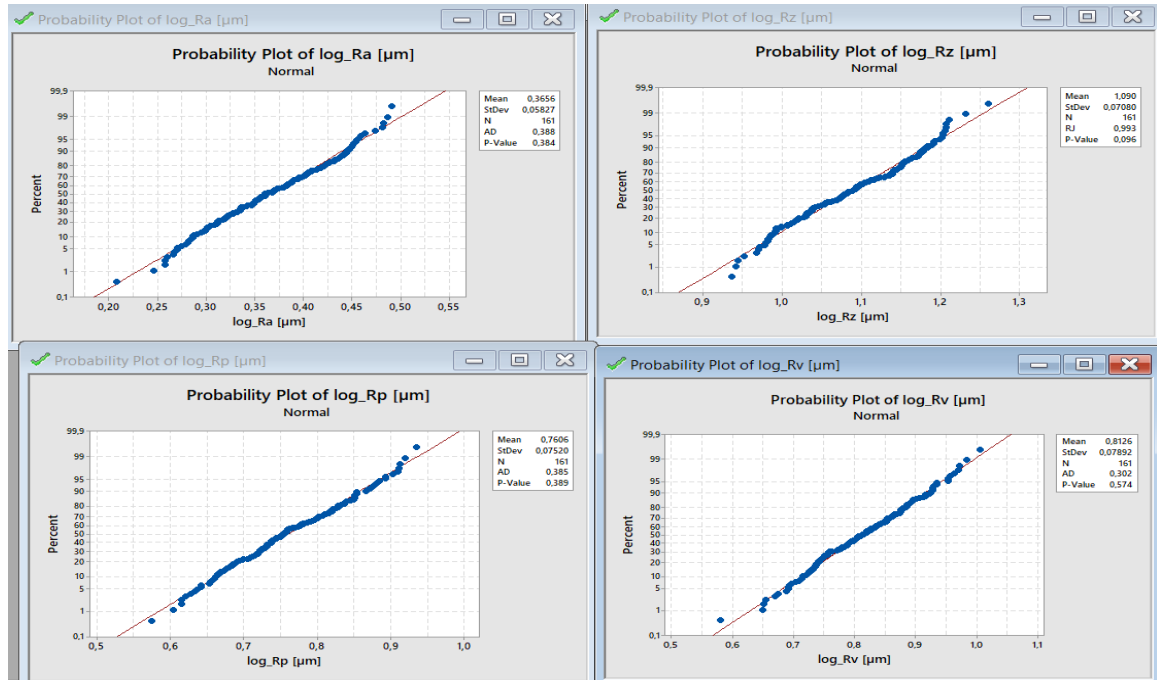
Obrázek 46 – měřená plocha pod mikroskopem

### 9.3.2 Ověření testu normality



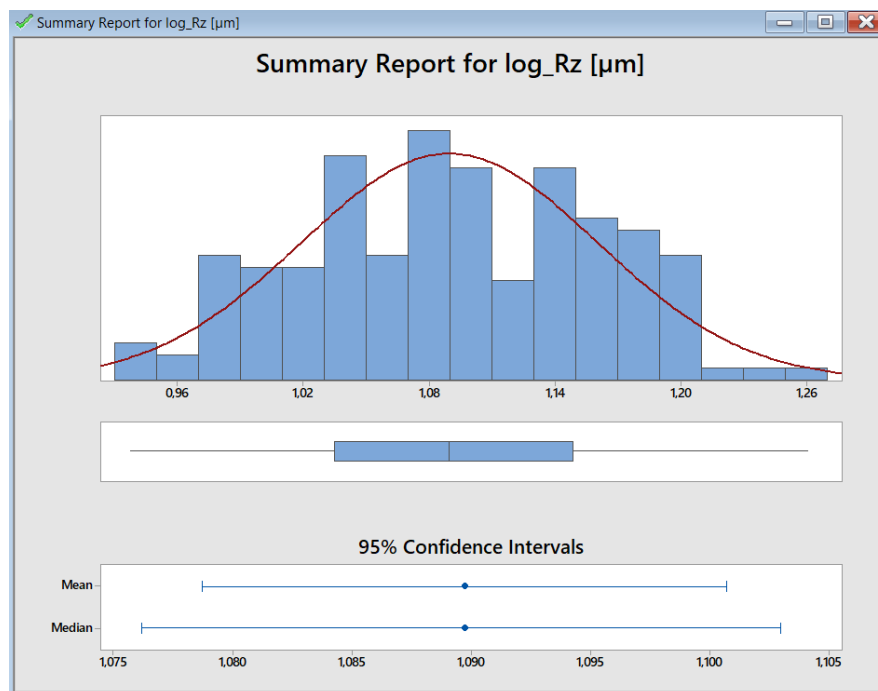
Obrázek 47– test normalit parametrů Ra, Rz, Rv, Rp vzorku Q2

Byl zhotoven test normalit. Z výsledků vyplývajících z grafů (Obr.46) bylo zjištěno, že daná data nepocházejí z normálního rozdělení. Po zjištění této skutečnosti, bylo navrženo zlogaritmování daných dat a následné opakování testu normality.



Obrázek 48 – test normalit parametrů Ra, Rz, Rv, Rp vzorku Q2 po zlogaritmování

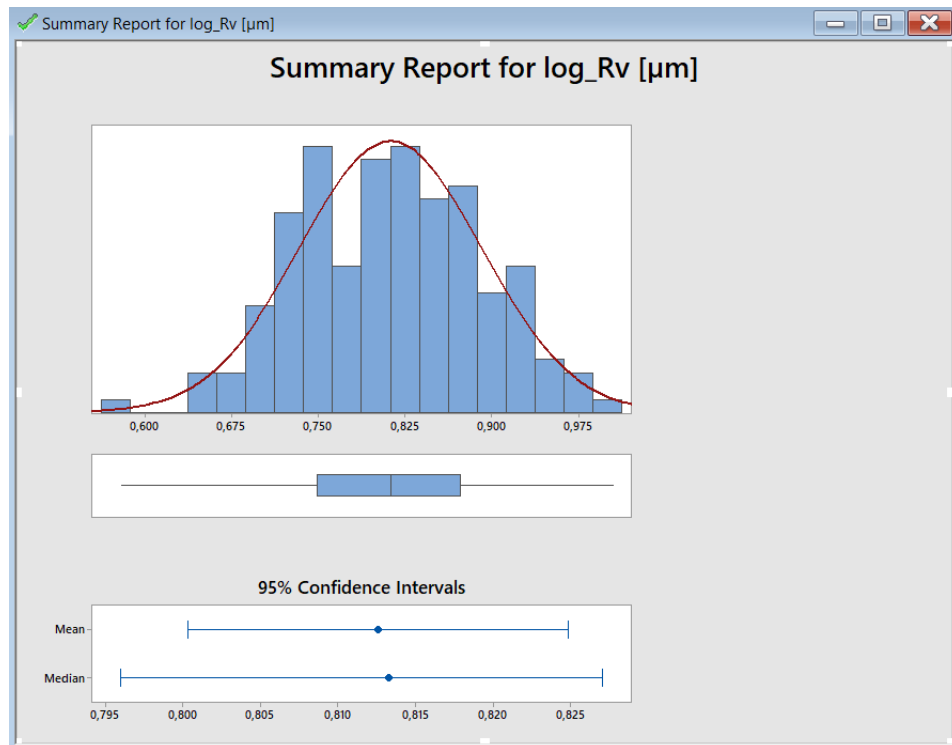
### 9.3.3 Aplikace metodiky EDA



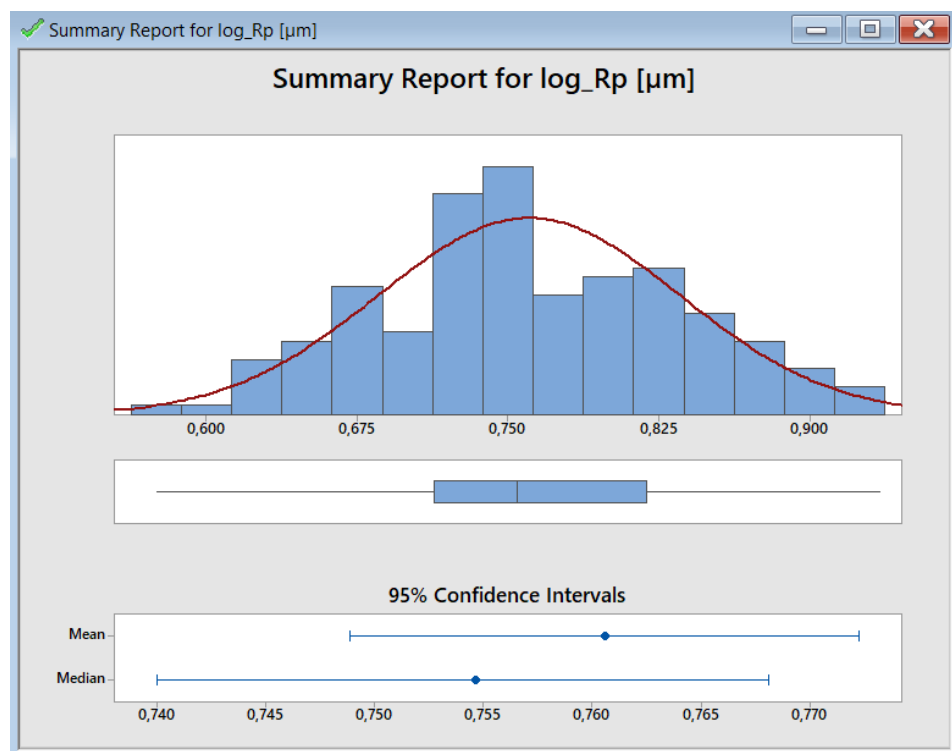
Obrázek 49 – Souhrnná zpráva parametru Rz vzorku Q2 po zlogaritmování



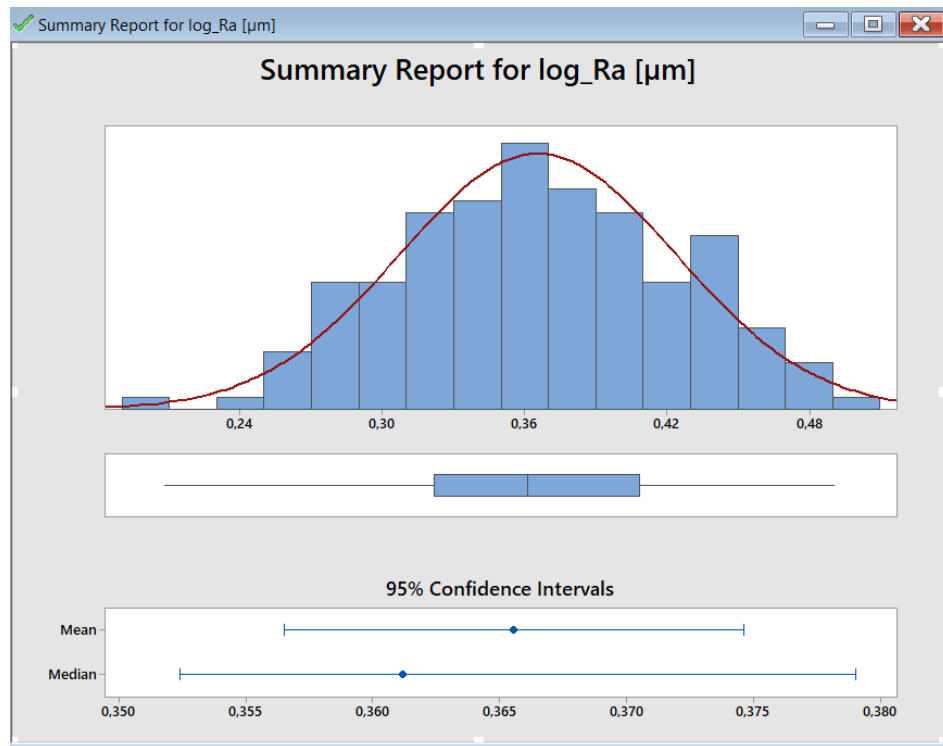
Pro vyhotovení normálního rozdělení byl použito Rayner-Joiner test normálního rozdělení. Stalo se tomu tak pouze u parametru Rz. Bylo tomu z důvodu chybějících hodnot v histogramu (Obr. 47). Využití daného testu je v tomto případě ve shodě s literaturou.



Obrázek 50 – Souhrnná zpráva parametru  $R_v$  vzorku Q2 po zlogaritmování



Obrázek 51 – Souhrnná zpráva parametru  $R_p$  vzorku Q2 po zlogaritmování



Obrázek 52 – Souhrnná zpráva parametru Ra vzorku Q2 po zlogaritmování

### 9.3.4 Výsledky po odlogaritmování

Tabulka 3 – hodnoty histogramů všech parametrů pro vzorek Q3

	Ra	Rv	Rp	Rz
AD/Rj (Rz)	1,47403	1,35256	1,46961	2,69932
P-Value	1,46815	1,77535	2,43513	1,04603
Mean	1,44132	2,25376	2,13952	2,97338
StDev	1,06000	1,08212	1,07810	1,07337
Variance	1,00341	1,00625	1,00567	1,00501
Skewness	0,98077	0,99691	1,08389	0,95932
Kurtosis	0,54152	0,71511	0,59596	0,92241
N	161	161	161	161

Tabulka 4 – hodnoty box-plotových grafů všech parametrů pro vzorek Q3

	Ra	Rv	Rp	Rz
Minimum	1,23109	1,78627	1,77766	2,55359
1st Quartile	1,37947	2,11588	2,04008	2,81511
Median	1,43499	2,25536	2,12687	2,97368
3rd Quartile	1,50442	2,39506	2,26775	3,15441
Maximum	1,63317	2,73346	2,54683	3,52789

Tabulka 5 – hodnoty konfidenčních intervalů všech parametrů pro vzorek Q3

95 % Confidence Interval for	Ra		Rv		Rp		Rz	
Mean	1,42831	1,45445	2,22625	2,28163	2,11463	2,16472	2,94085	3,00627
Median	1,42245	1,46088	2,21666	2,28656	2,09587	2,15571	2,93351	3,01319
StDev	1,05392	1,06763	1,07372	1,09267	1,07013	1,08811	1,06588	1,08275

### 9.3.5 Závěr analýzy vzorku Q3

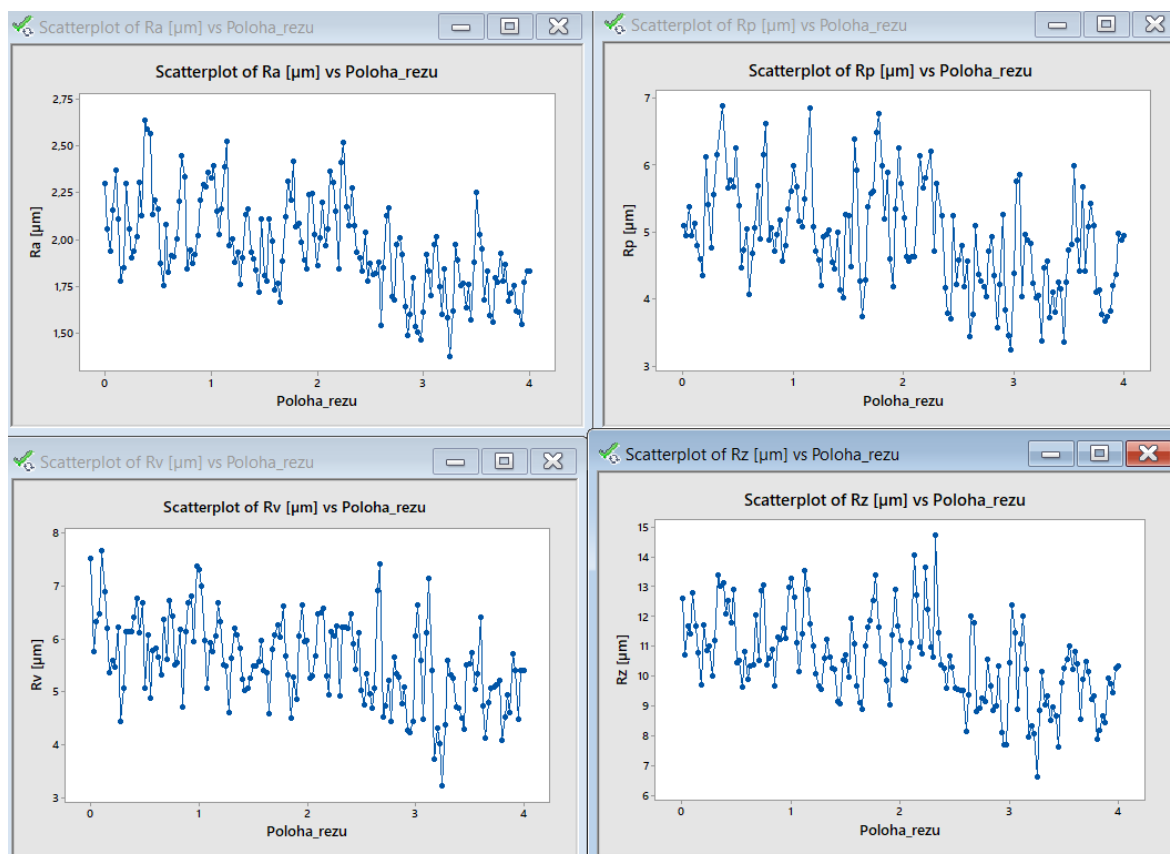
Výsledné hodnoty všech grafů (Obr.47 – Obr.50) byly hodnotami po zlogaritmování. Výsledky tak byly získány pomocí odlogaritmováním a zapsány (tabulky 3-5).

Z Box-plotových diagramů nebyly v žádném ze souborů dat parametrů Ra, Rz, Rv, Rp vzorku Q3 zjištěny jakékoli podezřelé hodnoty. U Parametru Ra, Rv, Rp bylo použito Anderson-Drlingova testu normálního rozdělení. U parametru Rz bylo použito již zmíněného Rayner-Joinerova testu. Byla zjištěna přítomná šikmost dat, proto byl nutné dané hodnoty logaritmovat. Po zlogaritmování byla zjištěna přítomná normalita datového souboru. Byla zhotovena hodnota pro minimum, první kvartil, medián, třetí kvartil a maximum.

## 9.4 Zpracování výsledků měřeného vzorku Q4


### 9.4.1 Ověření oblasti heterogenity

Jako první byl zhotoven graf scatterplot. Na Ose X byly vyneseny hodnoty polohy vzdálenosti bodu od počátku měření. Osa y obsahovala číselnou hodnotu daného parametru Ra, Rz, Rv, Rp.



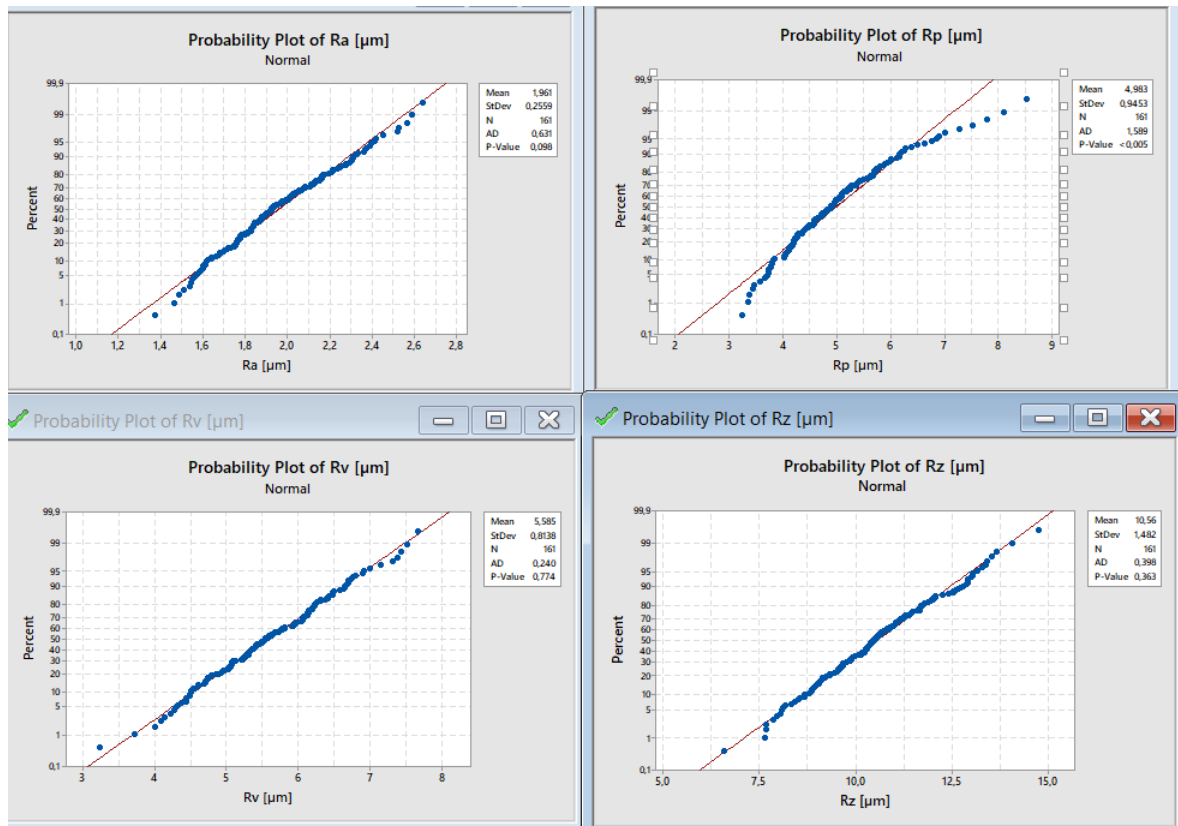
Obrázek 53– závislost parametrů Ra, Rz, Rv, Rp vzorku Q4 na poloze

Po vykreslení grafů scatterplot bylo vyřčena domněnka, že se jedná o data s normálním rozdělením, tudíž se bude jednat o homogenní povrch. Toto domněnka byla podložena fotografií (Obr.52) na které je jasně vidět celistvost povrchu. Na daném snímku se nevyskytují žádné náznaky přechodů mezi dvěma povrchy. Aby se tyto domněnky potvrdily, bylo vyhotoveno grafů normálního rozdělení (Obr. 53).




Obrázek 54 – měřená plocha pod mikroskopem

### 9.4.2 Ověření testu normality



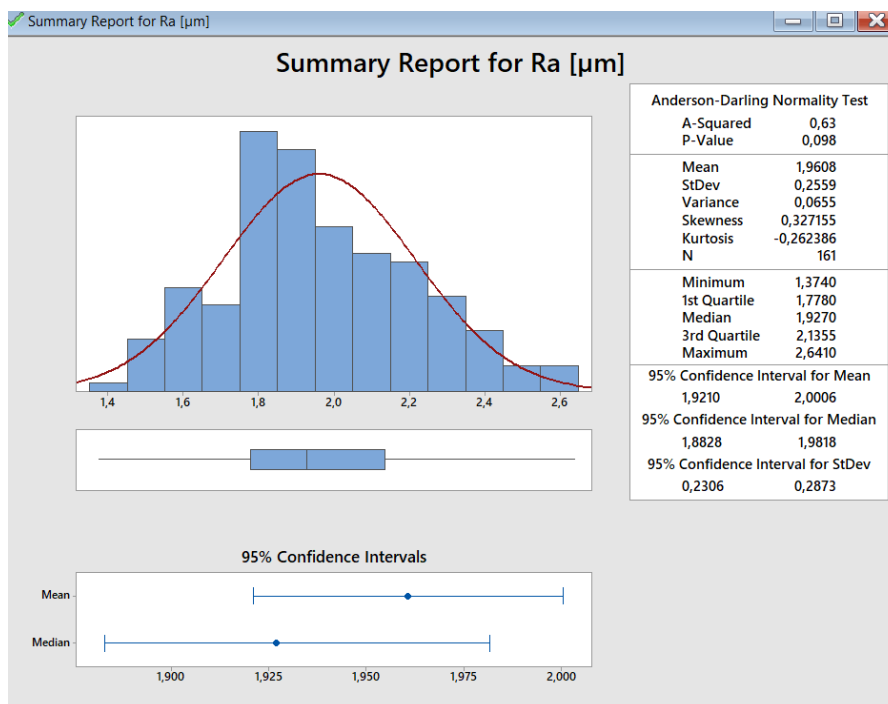
Obrázek 55– test normalit parametrů Ra, Rz, Rv, Rp vzorku Q4

Při pohledu na výsledky grafů (Obr.53) lze tvrdit, že data, kromě parametru Rp, opravdu pocházejí s normálového rozdělení a lze na ně aplikovat metodiku EDA. U parametru Rp byla shledána možná šikmost dat a následoval krok logaritmováním.

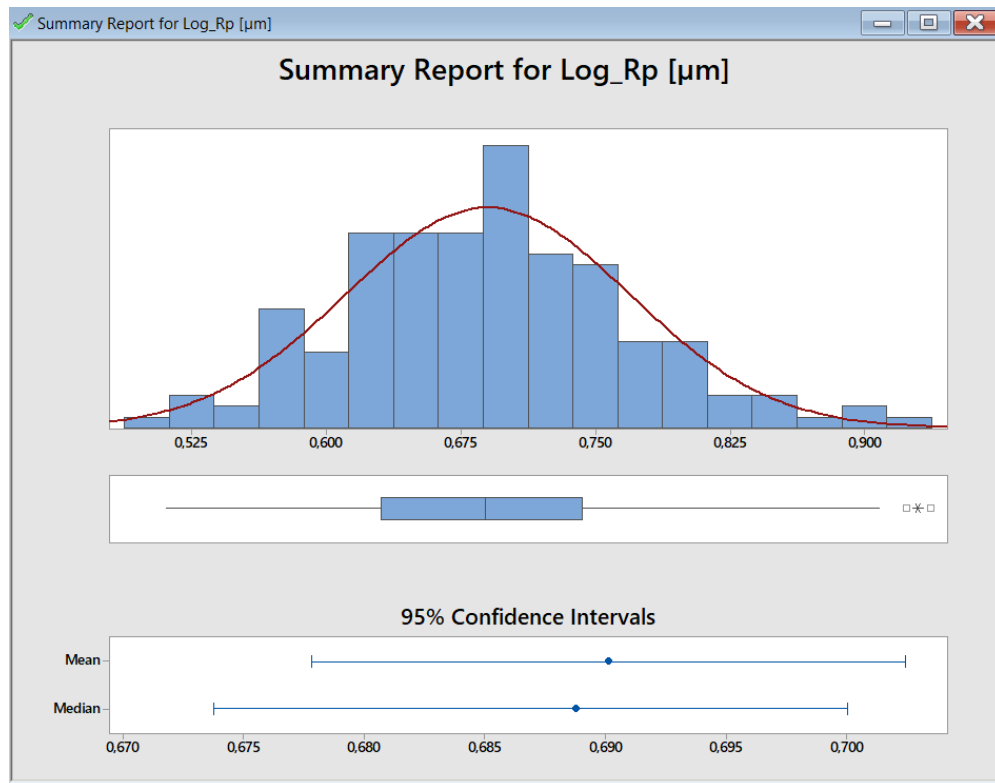


Obrázek 56– test normálního rozdělení logaritmovaných dat parametru Rp vzorku Q4

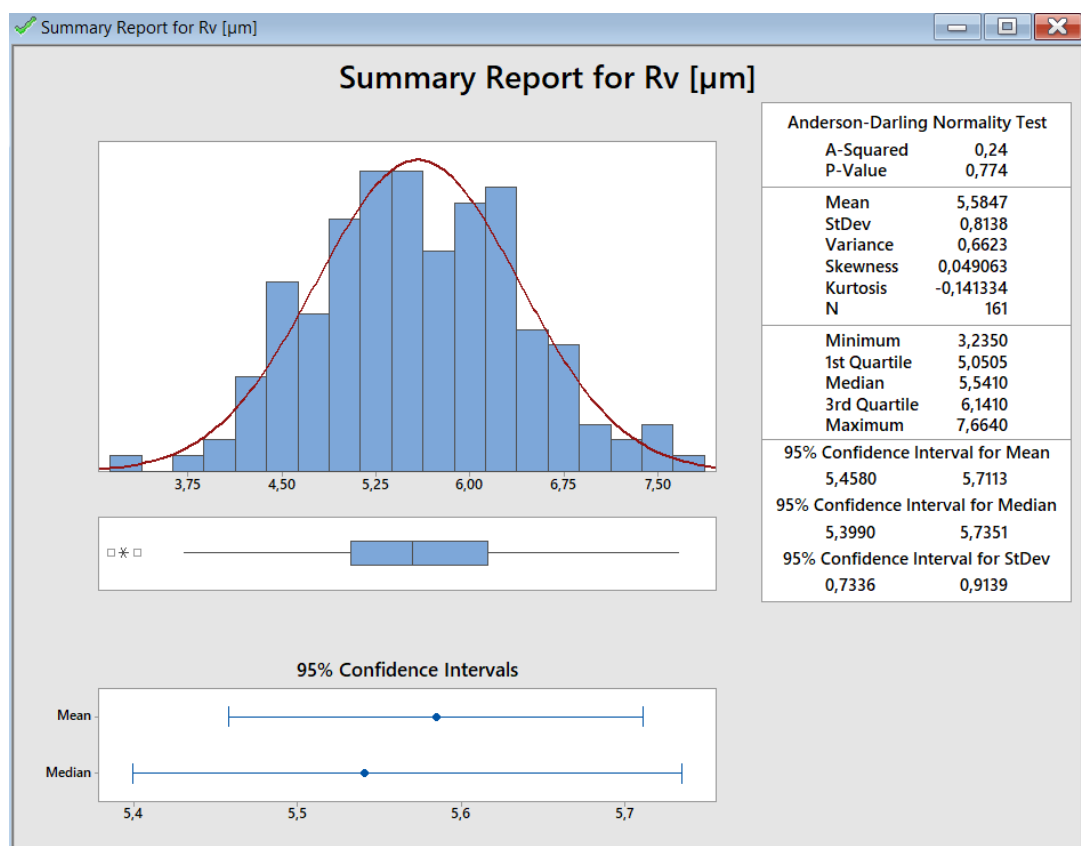
### 9.4.3 Délkové parametry



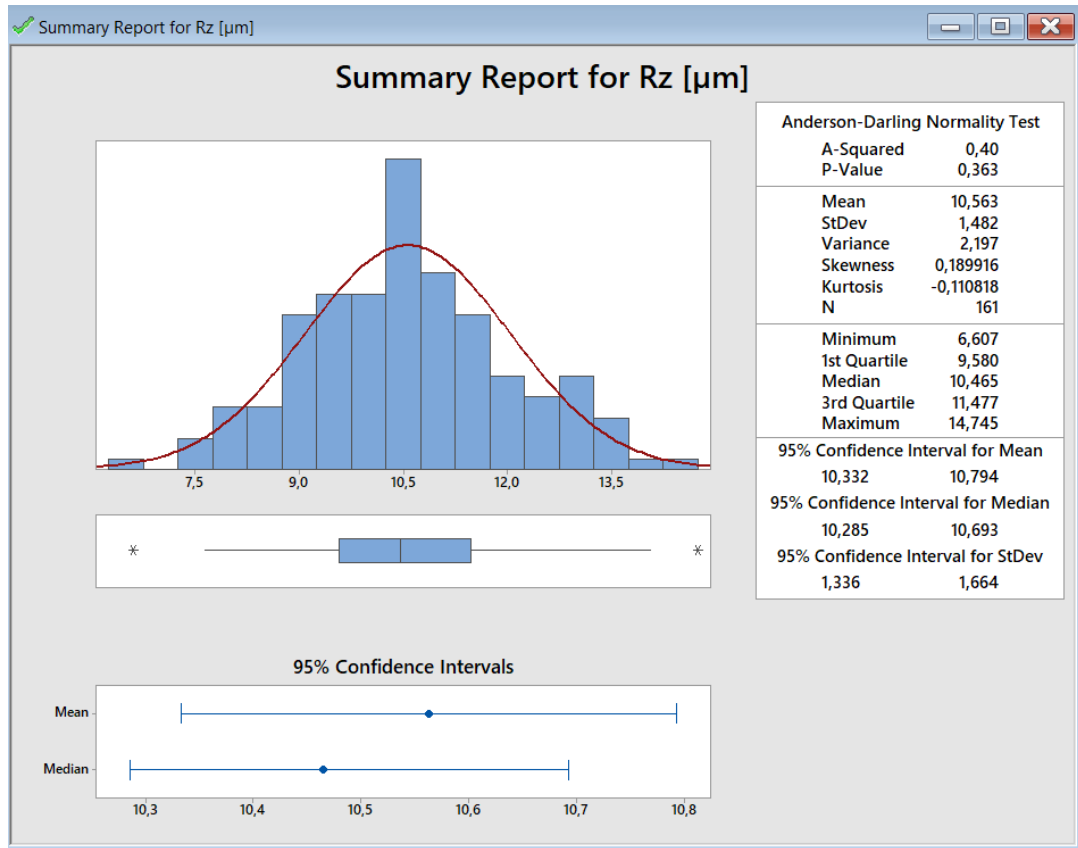
Obrázek 57 – Souhrnná zpráva parametru Ra vzorku Q4



Obrázek 58 - Souhrnná zpráva parametru Rp vzorku Q4




Obrázek 59 – Souhrnná zpráva parametru Rv vzorku Q4




Obrázek 60 – Souhrnná zpráva parametru Rz vzorku Q4

### 9.4.4 Testy odlehlých hodnot




Obrázek 61 – test outlayerů parametru Rz vzorku Q4





Obrázek 62– test outlayerů parametru Rv vzorku Q4



Obrázek 63– test outlayerů parametru Rp vzorku Q4

#### 9.4.5 Hodnoty po odlogaritmování

Tabulka 6 - hodnoty histogramu parametru Rp pro vzorek Q4

	Rp
AD/Rj (Rz)	1,40495
P-Value	1,64543
Mean	1,99397
StDev	1,08238
Variance	1,00629
Skewness	1,40907
Kurtosis	1,24114
N	161

Tabulka 7 - hodnoty box-plotového grafu parametru Rp pro vzorek Q4

	Rp
Minimum	1,66709
1st Quartile	1,87879
Median	1,99128
3rd Quartile	2,10139
Maximum	2,53512

Tabulka 8 - hodnoty konfidenčních intervalů parametru Rp pro vzorek Q4

95 % Confidence Interval for	Rp	
	Mean	1,96956
Median	1,96160	2,01387
StDev	1,07397	1,09297

#### 9.4.6 Závěry analýzy vzorku Q4

Byly vykresleny histogramové a box-plotové grafy. Při pohledu na grafy histogramů nebyly zjištěny žádné podezřelé hodnoty. Lze tak usuzovat z pravidelnosti a zvonových tvarů daných grafů. Box-plotové diagramy u parametru Rz, Rp a Rv zobrazily výskyt podezřelých hodnot u parametru Rz a jedné u parametru Rv a Rp. Po provedení testu na outlayery byl vyřčen závěr, že se u všech případů jedná o chyby náhodné, a tak byly v datových souborech jejich hodnoty zachovány. Byla zhotovena hodnota pro minimum, první kvartil, medián, třetí kvartil a maximum. V tabulkách jsou uvedeny hodnoty všech grafů parametru Rp po provedení odlogaritmování.

## 10 SHRUTÍ VÝSLEDKŮ STATISTICKÉHO HODNOCENÍ

### 10.1 Výsledky vzorku Q1

U vzorku Q1 bylo za pomoci statistické analýzy dokázáno, že daný povrch obsahuje znaky heterogenního povrchu. Bylo tomu tak na základě lineární regresní analýzy. Na základě výskytu množství děr na obrobené ploše, byla ze souboru odstraněna část dat naměřená v těchto úlocích. Data obsažená v tomto souboru vykazují veliký rozptyl dat. Výsledný povrch byl prokázán jako heterogenní. Na základě výsledku analýz lze potvrdit fakt, že regresní analýza není vhodným nástrojem k popisu dat vzniklých na základě heterogenního povrchu.

### 10.2 Výsledky vzorku Q2

Vzorek Q2 obsahoval viditelné znaky homogenního povrchu. Tento předpoklad se potvrdil na základě provedení testu normality u všech parametrů. Následně byla provedena statická analýza EDA, která se dala aplikovat na základě testu normality. Byla dokázána homogenita výsledného povrchu.

### 10.3 Výsledky vzorku Q3

U vzorku Q3 byl proveden test normálního rozdělení u všech parametrů. Výsledek testu však ukázal opak. Po prozkoumání snímku na povrchu pod mikroskopem bylo shledáno závěru, že daný povrch vykazuje znaky homogenity. Byl vyřčen předpoklad, že soubor parametrů může obsahovat šikmost na základě výskytu homogenity pod mikroskopem a výskytu jiného než normálního rozdělení. Výsledky testů normality po zlogaritmování dat prokázali, že se jedná o soubor dat s normální rozdělení, které byly sešikmené.

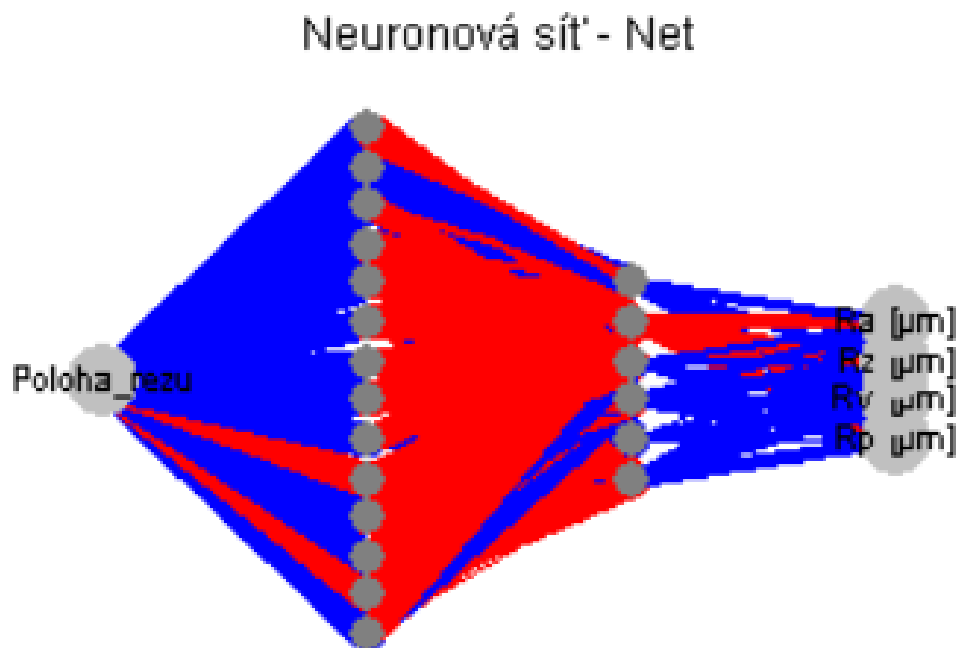
### 10.4 Zp Výsledky vzorku Q4

U Vzorku Q4 byla proveden test normality všech parametrů. U parametru Rz bylo shledáno jiné než normální rozdělení. Ostatní parametry se ukázaly jako Data pocházející z normálního rozdělení. Na to základě toho bylo provedeno zlogaritmování dat parametru Rz. Ukázalo se, že daný parametr byl ovlivněn šikmostí dat. Následné provedení EDY tento fakt potvrdilo.

## 11 NEURONOVÁ SÍŤ

T této části práce bude popsán postup vzniku neuronové sítě. Následně pak porovnání dat predikovaných touto sítí s daty, která byla změřena a vyhodnocována v předešlé části práce. Bude se jednat o data vzorku Q1, a to z důvodu přítomnosti heterogenního povrchu. Ostatní vzorky Q2, Q3, Q4 z této predikce byly vynechány. Je to z důvodu přítomnosti homogenního povrchu. Tvorba této sítě na strukturu homogenního povrchu, by bylo pouze generování náhodných výsledků normálového rozdělení, což by bylo zbytečné.

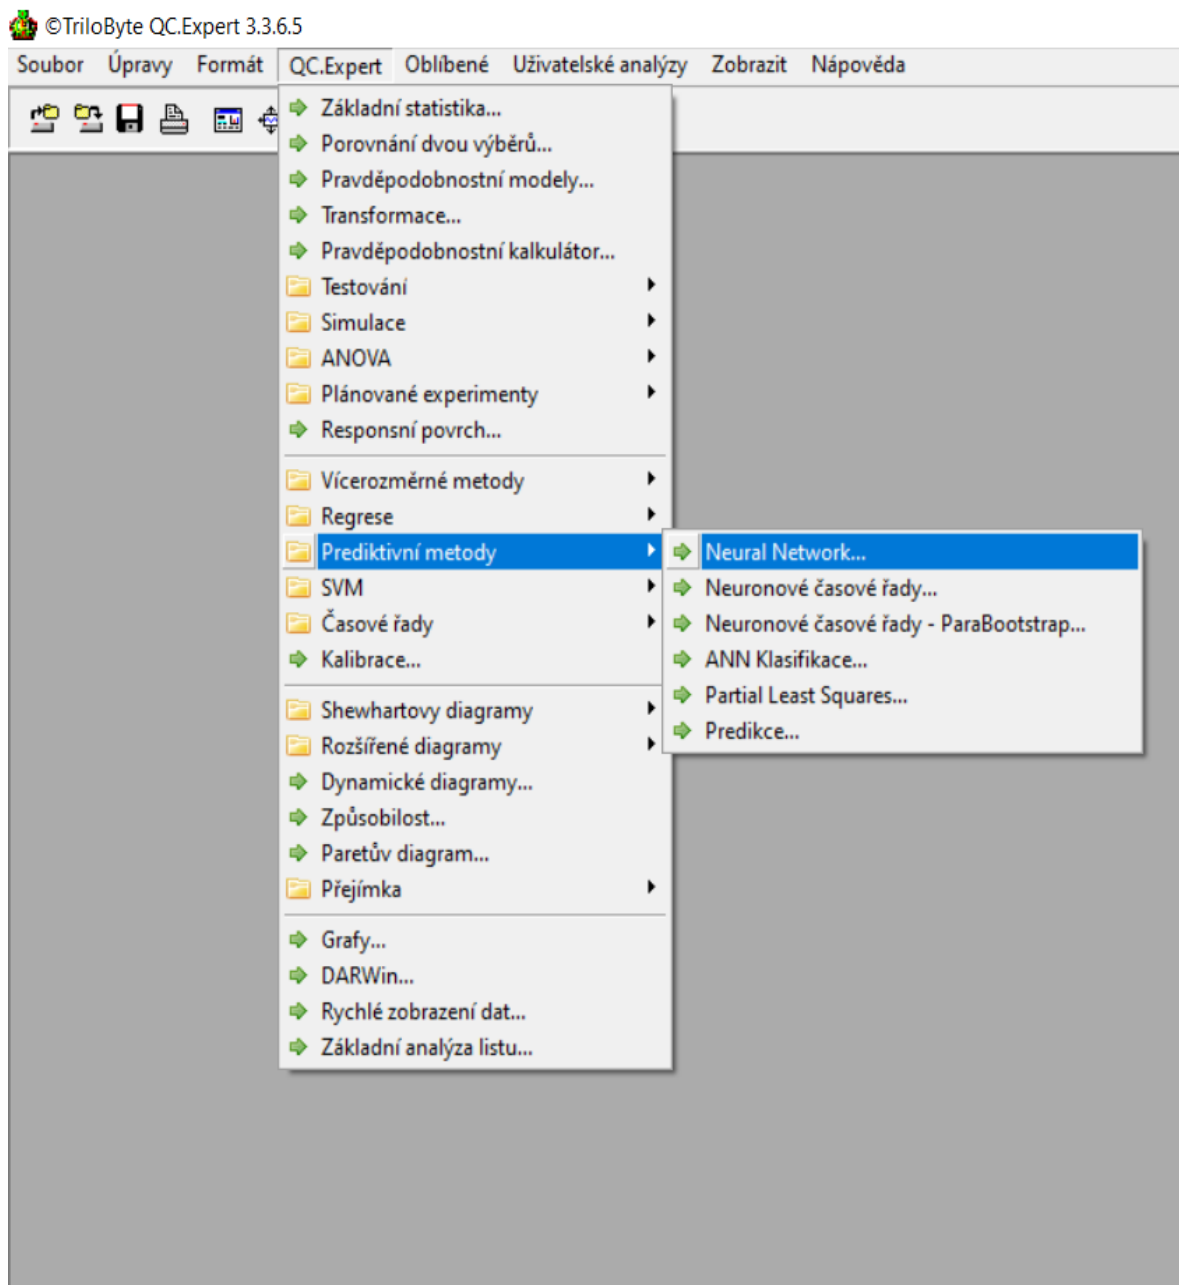
Síť byla navržena programem QC.Expert, který disponuje touto funkcí. Vstupním parametrem byla Poloha\_řezu. Tento parametr se vyskytuje jako osa X v grafech statistického hodnocení. Zvolená struktura navrhované sítě byla navržena jako síť o dvou skrytých vrstvách. Po několika zhotovených sítí, byl nejvhodnější počet neuronů zvolen jako 14:6. Výsledná struktura se dá tedy popsat jako 1/14/6/4, která je graficky znázorněna na obrázku 62.



Obrázek 64 - struktura navržené sítě

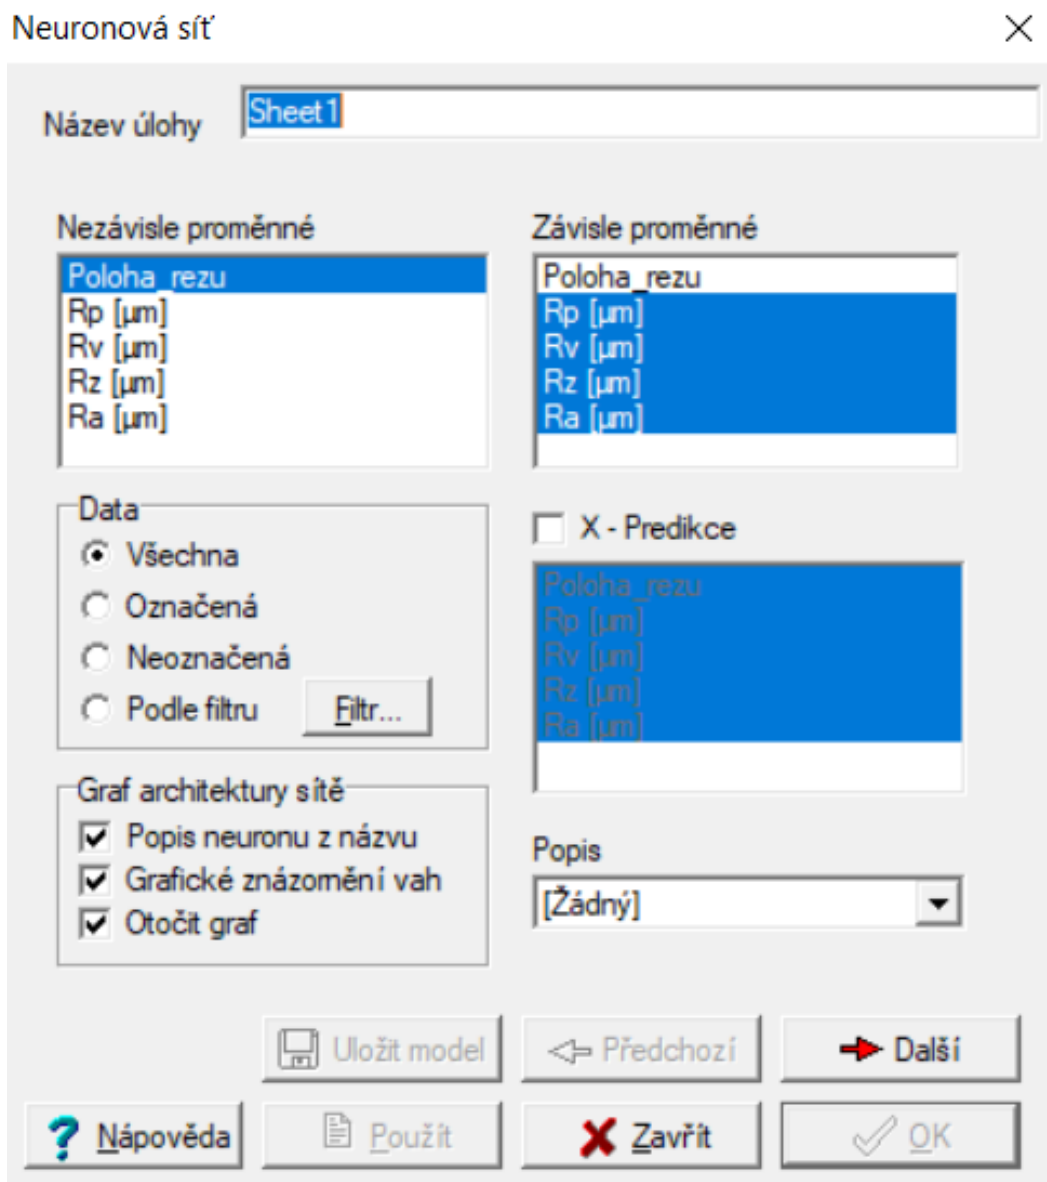
## 11.1 Postup vytvoření neuronové sítě

Pro vytvoření dané sítě bylo použito parametru Ra, Rz, Rp, Rv a Poloha\_řezu. Po vložení bylo vybráno pole QC.Expert => Prediktivní metody => Neural Network.



Obrázek 65 - Zvolená prediktivní metoda

V nově vytvořené okně bylo potřeba zvolit závislé a nezávislé proměnné a navolit graf architektury sítě. V našem případě byla nezávisle proměnné poloha řezu a závisle proměnná parametry Ra, Rp, Rv a Rz. V poli graf architektury sítě byly zaškrtnuty parametry: Popis neuronu z názvu, Grafické znázornění vah a Otočit graf. celé toto výběrové okno je zaznamenáno na obrázku 64.



Obrázek 66 - volba parametrů sítě

V dalším okně, které se nám zobrazí po odkliknutí okénka „Další“, bylo vybráno pro počet skrytých vrstev počet 2. Pro počet interakcí bylo zvoleno 10000. Do polí pro počet neuronů, bylo vybráno pro první vrstvu 14 a druhou 6 neuronů. Dalším a posledním změněným polem bylo „Dat pro učení“. systémově je zde zadáno automaticky 100 % a pro naše účely bylo toto číslo pozměněno na 70 %.

**Neuronová síť** [X]

Název úlohy: Sheet1

Počet skrytých vrstev: 2

Počet iterací: 10000

Exponent: 2

Stmlost sigmoidy: 1.00

Dat pro učení (%): 70

Použít pro učení neoznačená data

Hladina významnosti: 0.05

Moment: 0.9

Rychlost učení: 0.1

Ukončit při chybě <: 0.05

Vrstva	Neuronů
1	14
2	6

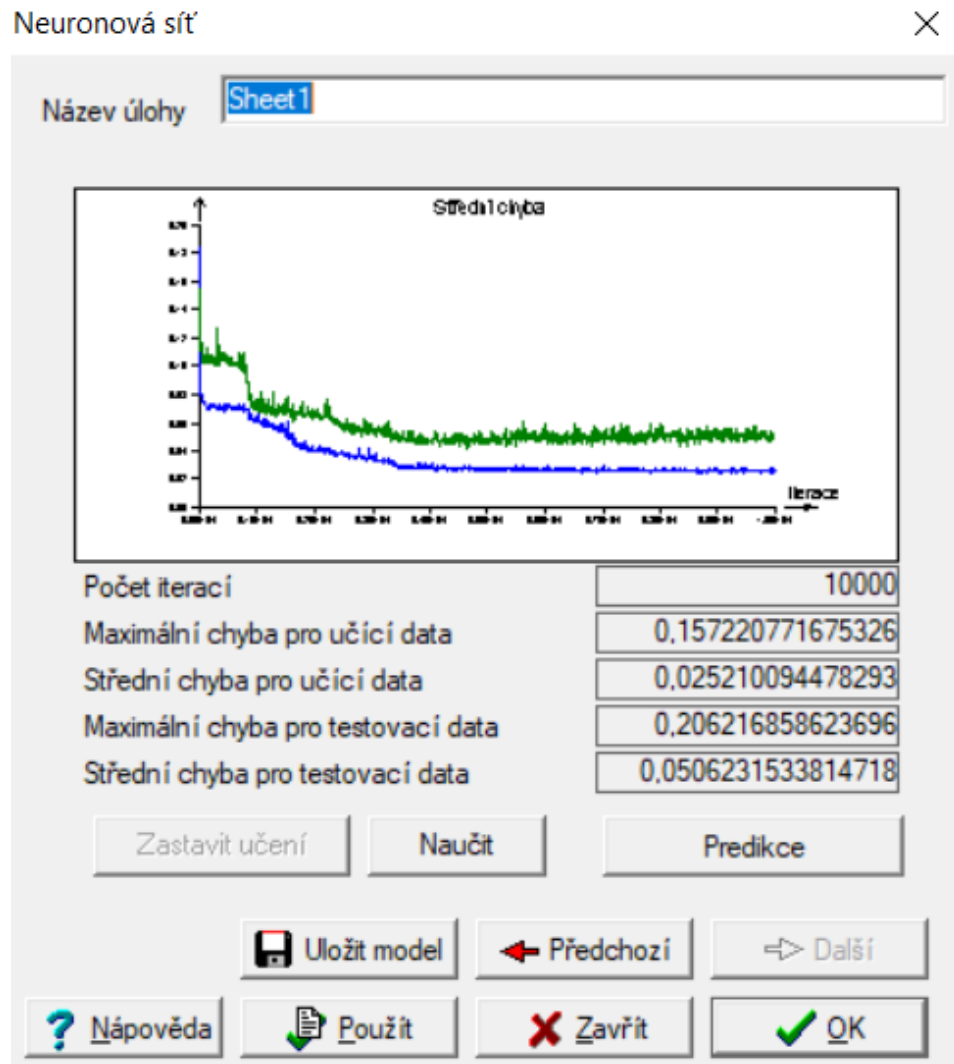
Transformace      Terminační kritéria

Uložit model      ← Předchozí      → Další

? Nápověda      Použít      X Zavřít      OK

Obrázek 67 – volba počtu neuronů






Obrázek 68 – učení neuronové sítě

V dalším okně byla naučena daná neuronová síť. Zde můžeme zpozorovat námi zvolený počet interakcí, které byly zadány v předešlém kroku. Pro maximální efektivitu dané sítě byly stěžejními parametry:

- Maximální chyba pro učicí data
- Střední chyba pro učicí data
- Maximální chyba pro učicí data
- Střední chyba pro testovací data

Pro nalezení optimální sítě bylo nutné, aby tyto parametry měly co nejmenší hodnotu. Dalším důležitým předmětem pozorování byl pokles dvou vzniklých křivek v bílém poli, které představovalo průběh učení neuronové sítě a pokles hodnoty chyb během učení. Kdyby dané křivky tento pokles nezaznamenaly jednalo by se o síť, která neměla vhodnou strukturu k tomu, aby se byla schopna naučit predikovat průběhy dat daného heterogenního povrchu.



Obrázek 69 – ukázka průběhu učení neuronové sítě

Tabulka 9 – výsledky parametrů neuronové sítě

Počet iterací	10000
Maximální chyba pro učící data	0,157221
Střední chyba pro učící data	0,02521
Maximální chyba pro testovací data	0,206217
Střední chyba pro testovací data	0,050623

Program QC.Expert udělil neuronům následující parametr váhy:

Vrstva / Neuron	1. Váha	2. Váha	3. Váha	4. Váha	5. Váha	6. Váha	7. Váha	8. Váha	9. Váha	10. Váha	11. Váha	12. Váha	13. Váha	14. Váha	Sloupec1
2/1	9,764985														-8,821635
2/2	-29,2899														-13,369726
2/3	8,649834														-7,4916344
2/4	10,5198														-9,0566913
2/5	-27,8965														-5,3720261
2/6	10,46022														-9,5262507
2/7	21,73177														-13,548853
2/8	6,620068														-2,6202027
2/9	7,578956														-6,7840681
2/10	9,343576														-8,2108441
2/11	11,04269														-10,100523
2/12	9,958766														-8,7533989
2/13	30,38279														-0,7242521
2/14	8,949109														-7,6208794
3/1	-0,28244	-15,1383	-1,66874	-0,88249	0,075249	-0,70761	-1,41781	-3,74871	-1,91194	-0,819067	-0,155966	-1,154805	-8,500197	-1,535771	5,4487141
3/2	-3,5798	-0,70212	-3,2521	-4,69477	-9,54354	-3,88991	-5,48895	1,036042	-2,43541	-3,600351	-4,167612	-3,904221	10,349236	-3,500263	-4,711558
3/3	5,66389	-0,82514	4,206381	6,046625	-18,7831	6,350703	-6,08353	1,213303	3,029439	5,127827	6,8493192	5,7207659	-31,61346	4,3043667	6,2460356
3/4	-0,75531	17,10975	0,056619	-0,34025	-11,4068	-1,03885	-1,88251	-1,26344	0,181319	-0,375987	-1,252751	-0,550679	8,1130143	0,1842465	-3,6879352
3/5	-7,31665	-18,181	-8,26968	-9,26421	-3,93985	-8,19994	-16,9454	-7,25757	-8,52969	-8,267155	-8,755305	-8,458999	9,0637003	-8,708868	4,0287709
3/6	-1,42345	-1,51672	-2,22644	-1,52243	-2,35314	-1,79574	-4,56033	-2,80305	-2,91504	-2,097885	-0,984833	-1,180977	7,327746	-2,213534	-3,7280281
4/1	3,391499	0,031278	2,64053	1,12335	-3,89514	3,332438									-1,5446187
4/2	2,993773	1,699013	1,971503	0,917624	-2,57236	0,501441									-0,988188
4/3	3,529256	0,983942	2,611676	1,158712	-3,52682	2,00129									-1,4202322
4/4	3,400272	0,145202	2,395841	1,397717	-3,25984	2,365989									-1,5186473

Obrázek 70 – hodnota vah neuronů

## 11.2 Predikce výsledků neuronové sítě

Po dokončení návrhu neuronové sítě bylo možné provést predikci výsledků. Do pole „Poloha\_rezu“ byla zadána vzdálenost, která nám přiřadila hodnoty výsledných parametru Ra, Rp, Rv a Rz (Obrázek 71).

Neuronová síť - predikce

Nezávisle proměnné		Závisle proměnné	
Proměnná	Hodnota	Proměnná	Hodnota
Poloha_rezu	35	Rp [μm]	10.1752848686
		Rv [μm]	10.0197783006
		Rz [μm]	20.0785649007
		Ra [μm]	3.55858227083

Spočítat při posunu

Obrázek 71 – predikce výsledných parametrů

Tyto parametry byly pak následně porovnány s parametry vygenerovanými měřícím přístrojem a byla spočítána jejich výslední odchylka (Tabulka 10)

Tabulka 10 – výsledné porovnání hodnot

Poloha_řezu/ parametr profilu	poloha [μm]	Rp_sítě [μm]	Rp_data [μm]	Rv_sítě [μm]	Rv_data [μm]	Rz_sítě [μm]	Rz_data [μm]	Ra_sítě [μm]	Ra_data [μm]
35	0,85	10,175	5,449	10,019	8,07	20,078	14,149	3,559	2,86
70	1,725	8,382	11,329	6,288	7,987	16,411	19,316	4,326	3,331
100	2,475	10,175	6,23	10,019	6,624	20,079	12,854	3,558	2,308
130	3,225	6,327	7,81	12,49	11,656	18,052	19,467	2,988	3,04
160	3,975	10,425	10,713	10,363	10,255	20,916	20,968	4,101	3,748
průměrný rozdíl [μm]		2,6778		1,597		3,5052		0,6698	

### 11.3 Závěrečné hodnocení neuronové sítě

Na základě neměřených parametrů byla vyhotovena a naučena neuronová síť, která díky své schopnosti predikovat výsledky, vyhodnotila parametry povrchu. Následné byly parametry sepsány a porovnány s hodnotami měření vyhodnocené přístrojem Talysurf CLI 500. Výsledná hodnota parametru sítě se významně nelišila od hodnot parametru naměřených.

## ZÁVĚR

Bylo provedeno měření vzorků s označením Q1, Q2, Q3, Q4. Tyto hodnoty byly následně vyhodnoceny, za pomoci regresních analýz, v programu minitab 17.

Vzorek Q1 vykazoval známky heterogenního povrchu, což bylo i následně statisticky dokázáno. U vzorků Q2, Q3, Q4 se vyhodnocení, využitím regresních analýz, ukázalo jako neproveditelné. Bylo tomu tak z důvodu přítomné heterogenity povrchu. U vzorků Q3 Q4 byla navíc zjištěna přítomnost šikmosti měřeného povrchu. Tento problém byl řešen logaritmováním daných dat, což vyřešilo daný problém. Dokázaná přítomnost homogenity byla způsobena s největší pravděpodobností tím, že při obrábění daného materiálu, došlo ke špatnému zvolení řezných podmínek (tlaku vody, který činil 200 MPa) na daný materiál. Tyto řezné podmínky se běžně využívají u kovů, ale námi zkoumaný materiál byl dural. Při výrobě nejspíše chyběla specifikace drsnosti povrchu na daný vzorek.

Výsledkem statistického hodnocení je nicméně prokázáno, nevhodnost regresních analýz při řešení heterogenity. Toto tvrzení je totožné s výsledky v odborné literatuře.

Výsledná neuronová síť vykazuje vhodnost aplikace na heterogenní povrchy. Tato statistická funkce je zcela bez pochyby budoucností tohoto odvětví. V našem případě byla použita na parametry vzniklé obráběním. Zcela bez pochyby, by šla využít i jako prostředek k možné volbě druhu materiálu, následnému zvolení řezných či brusných podmínek a následné určení výsledků drsnosti obrobene plochy. Zcela bez pochyby by byla schopna optimalizovat procesy řízení kvality, tak řízení procesů.

**SEZNAM POUŽITÉ LITERATURY**

- [1] Kaushik Kumar, Divya Zindani, J. Paulo Davim. *Advanced Machining and Manufacturing Processes*. Springer International Publishing AG, part of Springer Nature 2018. ISBN 978-3-319-76075-9
- [2] S. Saravanan, V. Vijayan, S.T. Jaya Suthahar, A.V. Balan, S. Sankar, M. Ravichandran. *A review on recent progresses in machining methods based on abrasive water jet Machining* [online]. 2020 [cit. 2022-04-1]. Dostupné z: <https://doi.org/10.1016/j.matpr.2019.05.373>.
- [3] Princip řezání vodním paprskem [online]. Dostupné z: <http://www.rezani-cnc.cz/princip-rezani-vodnim-paprskem.html>
- [4] Rasheedat Modupe Mahamood, Esther Titilayo Akinlabi. *Advanced Noncontact Cutting and Joining Technologies Micro – and Nano-manufacturing*. Springer International Publishing AG 2018. ISBN 978-3-319-75118-4
- [5] MARCEL KOLB. *Waterjet cutting: material processing with a high-pressure waterjet*. München: Moderne industrie, 2006. ISBN 39-378-8954-X.
- [6] EL-HOFY, Hassan. *Advanced machining processes: nontraditional and hybrid machining processes*. New York: McGraw-Hill Professional, 2005. ISBN 9780071453349.
- [7] J. Paulo Davim. *Nontraditional Machining Processes*. Pringer-Verlag London 2013. ISBN 978-1-4471-5179-1
- [8] ] HLOCH, S.et. al., Abrasive type influence on surface roughness at abrasive waterjet cutting. *Machines, technologies, materials: International virtual journal for science, technics and innovations for the industry*. 2008, no. 10-11, ISSN 1313-0226.
- [9] M. Putz, M. Dix, F. Morczinek, M. Dittrich. *Suspension Technology for Abrasive Waterjet (AWJ) Cutting of Ceramics* [online]. 2018 [cit. 2022-04-02]. Dostupné z: <https://doi.org/10.1016/j.procir.2018.09.037>
- [10] SHIMIZU Seiji. *Tribology in Water Jet Processes. New Tribological Ways* [online]. China: Intech, 2011, s. 14 [cit. 2016-11-27]. ISBN 978-953-307-206-7. Dostupné z: <http://www.intechopen.com/books/new-tribological-ways/tribology-in-water-jet-processes>

- [11] Marko Jerman, Henri Orbančić, Andrej Lebar, Izidor Sabotin, Pavel Drešar, Joško Valentinčić. *ICE JET TECHNOLOGY*. MM Science Journal, June 2018 [online]. [cit. 2022-04-11]. Dostupné z: 10.17973/MMSJ.2018\_06\_201772
- [12] Marko Jerman, Henri Orbančić, Andrej Lebar, Izidor Sabotin, Pavel Drešar, Joško Valentinčić. *Measuring the Water Temperature Changes in Ice Abrasive Water Jet Prototype*. Published by Elsevier Ltd. 2016 [online]. [cit. 2022-04-12]. dostupné z: <https://www.sciencedirect.com/science/article/pii/S1877705816311596>
- [13] Andrzej Perec, Frank Pude, Josef Stirnimann, Konrad Wegener. *FEASIBILITY STUDY ON THE USE OF FRACTAL ANALYSIS FOR EVALUATING THE SURFACE QUALITY GENERATED BY WATERJET*. UNIV OSIJEK, TECH FACTRG IVANE BRLIC-MAZURANIC 2, SLAVONSKI BROD HR-35000, CROATI [online]. [cit. 2022-04-13]. ISSN: 1330-3651
- [14] ELNA Servis Počerady, s.r.o. *PRINCIP ŘEZÁNÍ VODNÍM PAPERSEM*. [online]. [cit. 2022-04-13]. Dostupné z: <http://elnaservis.cz/rezani-vodnim-paprskem.html>
- [15] PATA, Vladimír. *Moderní způsoby hodnocení drsnosti strojírenských povrchů na bázi matematické statistiky*. Univerzita Tomáše Bati ve Zlíně, [2019]. 62 s. ISBN 978-80-7454-829-1
- [16] *Structural Changes in Metals during Laser Cutting*. Scientific.net [online]. Dostupné z: <https://www.scientific.net/MSF.919.25>
- [17] Preben Howarth, Fiona Redgrave. *Metrology – in short” 3rd edition*. Schultz Grafisk, DK 2620 Albertslund, 2008. ISBN 978-87-988154-5-7
- [18] WHITEHOUSE, David. *Surfaces and their Measurement*. Hermes Penton Science. [2002] 425 s. ISBN 1 9039 9601 5
- [19] 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
- [20] *Hybridní parametr Rmr* [online]. [cit. 2022-04-09]. dostupné z: <https://www.taylor-hobson.fr/resource-center/faq/what-are-hybrid-parameters>
- [21] *Towards Data science: EDA* [online], 2018. [cit. 2021-03-10]. Dostupné z: <https://towardsdatascience.com/exploratory-data-analysis-8fc1cb20fd15>

- [22] *Learnche* [online], 2021 [cit. 2021-03-10]. Dostupné z: <https://learnche.org/pid/data-visualization/time-series-plots>
- [23] *Box ploty* [online], 2017 [cit. 2021-03-12]. Dostupné z: <http://kvalita-jednoduse.cz/box-plot/>
- [24] *Asq* [online], 2021 [cit. 2021-03-10]. Dostupné z: <https://asq.org/quality-resources/histogram>
- [25] MELOUN, Milan a Jiří MILITKÝ. *Statistická analýza experimentálních dat*. Vyd. 2., upr. a rozš. Praha: Academia, 2004. ISBN 80-200-1254-0
- [26] Charu C. Aggarwal. *Neural Networks and Deep Learning*. Springer International Publishing AG, part of Springer Nature 2018. ISBN 978-3-319-94463-0
- [27] Jeff Heaton. *Artificial Intelligence for Humans, Volume 3. Neural Networks and Deep Learning*. Heaton Research, Inc. December, 2015. ISBN: 978-1505714340
- [28] Ernst Kussul, Tatiana Baidyk, Donald C. Wunsch. *Neural Networks and Micromechanics*. Springer-Verlag Berlin Heidelberg 2010. ISBN: 978-3-642-02535-8
- [29] Kowalski P.A., Kulczycki P. Interval probabilistic neural network. *Neural Comput & Applic* **28**, 817–834 (2017). <https://doi.org/10.1007/s00521-015-2109-3>
- [30] TAYLOR-HOBSON. *Talysurf CLI 500 Operator's Handbook*. 2005, 176 s



**SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK**

Rz	největší výška profilu
Rt	celková výška profilu
Rc	průměrná výška prvků profilu
Ra	průměrná aritmetická úchylka posuzovaného profilu
Rq	průměrná kvadratická úchylka posuzovaného profilu
ISO	International Organization for Standardization – Mezinárodní organizace pro normalizaci
MPa	Megapascal
3 D	Trojrozměrný prostor
2 D	Dvourozměrný prosto
μm	mikrometr
EDA	explorativní datová analýza
Rmr	materiálový poměr
mm/s	milimetr za sekundu
Z	Výška největšího výstupku profilu
Zp	Výška nejvyššího výstupku profilu v rozsahu základní délky
Zt	Výška prvku profilu v rozsahu základní délky
Zv	Hloubka nejnižší prohlubně profilu v rozsahu základní délky

## SEZNAM OBRÁZKŮ

Obrázek 1 – princip fungování vodního paprsku [3].....	13
Obrázek 2 - Typy vodních paprsků [5].....	14
Obrázek 3 – schéma stoje používající čistý vodní paprsek [6].....	15
Obrázek 4 - Typy vodních paprsků [8].....	17
Obrázek 5 – suspenzní vodní paprsek [10].....	19
Obrázek 6 – schéma kryogenního vodního paprsku [12] .....	21
Obrázek 7 – Kvalita povrchu při rozdílných řezných podmínkách [14] .....	22
Obrázek 8– Struktura profilových čar v jednotlivých částech heterogenního povrchu [15] .....	23
Obrázek 9 – schéma profilu povrchu [19] .....	24
Obrázek 10 – schéma profilu povrchu [18] .....	25
Obrázek 11 – schéma vlnitosti povrchu [18].....	25
Obrázek 12 – schéma vlnitosti povrchu [18].....	25
Obrázek 13 – Nejvyšší výška výstupku profilu [19] .....	26
Obrázek 14 – Nejvyšší hloubka prohlubně [19] .....	27
Obrázek 15 – Nejvyšší výška profilu [19].....	27
Obrázek 16 – Materiálový poměr profilu [20].....	28
Obrázek 17 – Průměrná šířka profilu [19].....	28
Obrázek 18 – diagram časové řady .....	29
Obrázek 19 – box-plotový diagram .....	30
Obrázek 20 – Histogram .....	30
Obrázek 21 – graf lineární regrese.....	31
Obrázek 22 – Schéma modelu neuronu [27] .....	33
Obrázek 23 – Schéma neuronové sítě (perceptronu) [15] .....	34
Obrázek 24 – vzorky s označením Q1-Q4.....	38
Obrázek 25 – úprava vzorku.....	38
Obrázek 26 – měřicí přístroj Talysurf CLI 500 .....	39
Obrázek 27 – uložení vzorku.....	40
Obrázek 28 – závislost parametrů Ra, Rz, Rv, Rp vzorku Q1 na poloze .....	41
Obrázek 29 – histogramy parametrů Ra, Rz, Rv, Rp .....	42
Obrázek 30 – scatterplot rozdělených parametrů Ra, Rz, Rv, Rp proložených lineární regresi.....	43
Obrázek 31 – lineární regresní analýza Rz v intervalu (0–2,1mm).....	44
Obrázek 32 – lineární regresní analýza Ra, Rz, Rv, Rp v intervalu (0-2,1mm).....	44

Obrázek 33 – lineární regresní analýza Rz v intervalu (2,1 - 4 mm).....	45
Obrázek 34 – lineární regresní analýza Ra, Rz, Rv, Rp v intervalu (0-2,1mm).....	46
Obrázek 35 -aplikace lineární regrese na data .....	46
Obrázek 36 – aplikace kubické regrese na data .....	47
Obrázek 37 – závislost parametrů Ra, Rz, Rv, Rp vzorku Q2 na poloze .....	48
Obrázek 38 – měřená plocha pod mikroskopem .....	49
Obrázek 39 – závislost parametrů Ra, Rz, Rv, Rp vzorku Q2 na poloze .....	50
Obrázek 40 – test normalit parametrů Ra, Rz, Rv, Rp vzorku Q2 .....	51
Obrázek 41 – souhrnná zpráva pro parametr Ra vzorku Q2.....	51
Obrázek 42 – souhrnná zpráva pro parametr Rv vzorku Q2 .....	52
Obrázek 43 – souhrnná zpráva pro parametr Rz vzorku Q2.....	52
Obrázek 44– souhrnná zpráva pro parametr Rp vzorku Q2 .....	53
Obrázek 45 – závislost parametrů Ra, Rz, Rv, Rp vzorku Q3 na poloze .....	54
Obrázek 46 – měřená plocha pod mikroskopem .....	55
Obrázek 47– test normalit parametrů Ra, Rz, Rv, Rp vzorku Q2 .....	55
Obrázek 48 – test normalit parametrů Ra, Rz, Rv, Rp vzorku Q2 po zlogaritmování .....	56
Obrázek 49 – Souhrnná zpráva parametru Rz vzorku Q2 po zlogaritmování .....	56
Obrázek 50 – Souhrnná zpráva parametru Rv vzorku Q2 po zlogaritmování.....	57
Obrázek 51 – Souhrnná zpráva parametru Rp vzorku Q2 po zlogaritmování.....	57
Obrázek 52 – Souhrnná zpráva parametru Ra vzorku Q2 po zlogaritmování .....	58
Obrázek 53– závislost parametrů Ra, Rz, Rv, Rp vzorku Q4 na poloze .....	60
Obrázek 54 – měřená plocha pod mikroskopem .....	61
Obrázek 55– test normalit parametrů Ra, Rz, Rv, Rp vzorku Q4 .....	61
Obrázek 56– test normálního rozdělení logaritmovaných dat parametru Rp vzorku Q4 ....	62
Obrázek 57 – Souhrnná zpráva parametru Ra vzorku Q4 .....	62
Obrázek 58 - Souhrnná zpráva parametru Rp vzorku Q4.....	63
Obrázek 59 – Souhrnná zpráva parametru Rv vzorku Q4 .....	63
Obrázek 60 – Souhrnná zpráva parametru Rz vzorku Q4 .....	64
Obrázek 61 – test outlayerů parametru Rz vzorku Q4.....	64
Obrázek 62– test outlayerů parametru Rv vzorku Q4 .....	65
Obrázek 63– test outlayerů parametru Rp vzorku Q4 .....	65
Obrázek 64 - struktura navržené sítě .....	69
Obrázek 65 - Zvolená prediktivní metoda .....	70
Obrázek 66 - volba parametrů sítě .....	71
Obrázek 67 – volba počtu neuronů .....	72

---

Obrázek 68 – učení neuronové sítě.....	73
Obrázek 69 – ukázka průběhu učení neuronové sítě .....	74
Obrázek 70 – hodnota vah neuronů .....	75
Obrázek 71 – predikce výsledných parametrů.....	75

**SEZNAM TABULEK**

Tabulka 1 – výsledky Fisher-Snedecorův test významnosti.....	45
Tabulka 2 – výsledky Fisher-Snedecorův test významnosti.....	47
Tabulka 3 – hodnoty histogramů všech parametrů pro vzorek Q3.....	58
Tabulka 4 – hodnoty box-plotových grafů všech parametrů pro vzorek Q3.....	59
Tabulka 5 – hodnoty konfidenčních intervalů všech parametrů pro vzorek Q3.....	59
Tabulka 6 - hodnoty histogramu parametru Rp pro vzorek Q4.....	66
Tabulka 7 - hodnoty box-plotového grafu parametru Rp pro vzorek Q4.....	66
Tabulka 8 - hodnoty konfidenčních intervalů parametru Rp pro vzorek Q4.....	67
Tabulka 9 – výsledky parametrů neuronové sítě.....	74
Tabulka 10 – výsledné porovnání hodnot.....	76

