

Hodnocení jakosti heterogenních povrchů

Bc. Marian Skucius

Diplomová práce
2021

 Univerzita Tomáše Bati ve Zlíně
Fakulta technologická

Univerzita Tomáše Bati ve Zlíně

Fakulta technologická

Ústav výrobního inženýrství

Akademický rok: 2020/2021

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení:	Bc. Marian Skucius
Osobní číslo:	T19546
Studijní program:	N3909 Procesní inženýrství
Studijní obor:	Řízení jakosti
Forma studia:	Prezenční
Téma práce:	Hodnocení jakosti heterogenních povrchů

Zásady pro vypracování

Vypracovat rešerši na téma jakost povrchů, se zaměřením na povrchy heterogenní.

Připravit a proměřit zadané vzorky

Navrhnout a ověřit vhodné statistické metody pro globální hodnocení heterogenit

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

Seznam doporučené literatury:

PATA, Vladimír a Milena KUBIŠOVÁ. *Statistické metody hodnocení jakosti strojírenských povrchů*. Ve Zlíně: Univerzita Tomáše Bati, Fakulta technologická, 2018. ISBN 978-80-7454-740-9.

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.

SMITH, Graham T. *Machine tool metrology: an industrial handbook*. [Switzerland]: Springer, [2016]. ISBN 978-3-319-25107-3.

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

Datum zadání diplomové práce: **5. ledna 2021**

Termín odevzdání diplomové práce: **14. května 2021**

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

Diplomová práce se zabývá návrhem a sestavením neuronové sítě pro predikování výsledků parametrů drsnosti u heterogenních povrchů. Současně dokazuje, že jiné statistické metody, především regresní analýzy, v tomto směru selhávají a jejich výsledky nelze spolehlivě použít. K získání potřebných dat pro sestavení neuronové sítě posloužily vzorky vyrobené za použití řezání vodním paprskem. Tento povrch je charakteristický pro svou heterogenitu. Práce popisuje tyto vzorky, parametry jejich vzniku, laboratorní měření, kompletní sestavení neuronové sítě a následné srovnání výsledků s regresními funkcemi.

Klíčová slova: heterogenní povrch, drsnost povrchu, abrazivní vodní paprsek, regresní analýzy, neuronové sítě

ABSTRACT

This diploma thesis deals with the design and assembly of a neural network for predicting the results of roughness parameters in heterogeneous surfaces. At the same time, it proves that other statistical methods, especially regression analyzes, fail in this direction and their results cannot be used reliably. Samples made using water jet cutting were used to obtain the data needed to assemble the neural network. This surface is characterized by its heterogeneity. The work describes these samples, parameters of their origin, laboratory measurements, complete construction of the neural network and comparison of results with regression functions.

Keywords: heterogeneous surface, surface roughness, abrasive water jet, regression analysis, neural networks

Poděkování

Tímto děkuji mému vedoucímu diplomové práce prof. Dr. Ing. Vladimíru Patovi za jeho čas, velkou ochotu, cenné rady a především velkou pomoc, kterou mi poskytl pro správné zpracování a zdárné dokončení této diplomové práce. Především mu děkuji za to, že si na mě udělal vždy čas i přesto, že tato diplomová práce vznikala během epidemie nemoci Covid-19 a všechny potřebné konzultace byly vedeny pouze formou online.

Největší poděkování však patří mým rodičům, kteří mě po celou dobu mého navazujícího studia podporovali a zajišťovali mi dobré prostředí pro klidné studium.

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

OBSAH

ÚVOD	9
I TEORETICKÁ ČÁST	10
1 JAKOST POVRCHU A JEHO HODNOCENÍ	11
1.1 NORMY ISO	11
1.2 STRUKTURA POVRCHU	11
1.2.1 Tvar	12
1.2.2 Vlnitost.....	12
1.2.3 Drsnost	13
1.3 PARAMETRY STRUKTURY POVRCHU	13
1.3.1 Střední čára.....	15
1.3.2 Výškové parametry	15
1.3.3 Délkové parametry	18
2 NEKONVENČNÍ TECHNOLOGIE ODBĚRU MATERIÁLU	21
2.1 OBRÁBĚNÍ VODNÍM PAPERSEM.....	22
2.1.1 Princip vodního paprsku	22
2.1.2 Typy vodního paprsku.....	23
2.1.3 Čistý vodní paprsek.....	24
2.1.4 Abrazivní vodní paprsek	24
2.1.5 Abrazivní suspenzní paprsek.....	26
2.1.6 Kvalita řezu	27
3 HETEROGENNÍ POVRCH	28
4 STATISTICKÉ NÁSTROJE NA HODNOCENÍ DAT	30
4.1 REGRESNÍ ANALÝZA.....	30
4.1.1 Lineární regrese.....	30
4.1.2 Nelineární regrese	32
5 NEURONOVÉ SÍTĚ	34
5.1 PRINCIP SÍTĚ.....	34
5.2 MODEL NEURONU.....	35
5.3 PERCEPTRON	36
5.4 PŘEUČENÍ NEURONOVÉ SÍTĚ	37
II PRAKTICKÁ ČÁST	38
6 STANOVENÍ CÍLŮ DIPLOMOVÉ PRÁCE	39
7 PŘÍPRAVA VZORKŮ A JEJICH VLASTNOSTI	40
7.1 ÚPRAVA VZORKŮ PŘED MĚŘENÍM.....	41

8	PARAMETRY A PRŮBĚH MĚŘENÍ	42
8.1	MĚŘICÍ PŘÍSTROJ POUŽITÝ K MĚŘENÍ.....	42
8.2	PARAMETRY MĚŘENÍ.....	43
8.3	ZPRACOVÁNÍ A EXPORT NAMĚŘENÝCH DAT	45
8.3.1	3D scan.....	45
8.3.2	Odstranění tvaru a zobrazení 3D plochy.....	46
8.3.3	Rozklad 3D povrchu na vlnitost a drsnost	48
8.3.4	Export naměřených hodnot	49
9	ANALÝZA NAMĚŘENÝCH DAT	51
9.1	OVĚŘENÍ HETEROGENITY POVRCHU	51
9.1.1	Teorie tří oblastí heterogenního povrchu	52
9.2	APLIKACE REGRESNÍCH ANALÝZ	55
9.2.1	Lineární regrese.....	55
9.2.2	Nelineární regrese kvadratická.....	55
9.2.3	Nelineární regrese kubická.....	56
9.2.4	Shrnutí výsledků regresních analýz	56
10	NEURONOVÉ SÍTĚ	57
10.1	SESTAVENÍ NEURONOVÉ SÍTĚ	58
10.2	PREDIKCE NEURONOVÉ SÍTĚ	63
10.3	POROVNÁNÍ VÝSLEDKŮ NEURONOVÉ SÍTĚ S REÁLNÝMI HODNOTAMI	65
10.4	POROVNÁNÍ VÝSLEDKŮ NEURONOVÉ SÍTĚ S REGRESNÍ ANALÝZOU.....	69
10.5	ZHODNOCENÍ VŠECH VÝSLEDKŮ.....	71
	ZÁVĚR	72
	SEZNAM POUŽITÉ LITERATURY	73
	SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK	76
	SEZNAM OBRÁZKŮ	78
	SEZNAM TABULEK	80
	SEZNAM PŘÍLOH	81

ÚVOD

V době čím dál výkonnějších počítačů nastává otázka, zda za několik let bude vůbec ještě někdo pracovat rukama a nebude místo něj práci vykonávat stroj. Tato myšlenka je velmi obecná a lze ji aplikovat do mnoha odvětví. V našem případě ji můžeme aplikovat částečně i do oboru metrologie. Představme si například, že před zahájením sériové výroby určitého dílu nebude nutné metrologicky ověřovat povrch vzniklý řeznými operacemi nebo dělat několik vzorků k určení optimálního nastavení stroje k dosažení kvalitní a efektivní výroby. Pro naplnění této myšlenky stačí rozvíjet možnosti neuronových sítí, které dokáží na základě dodaných vstupních parametrů predikovat výsledné požadované vlastnosti. Nicméně žádný učený z nebe nespadl a proto, stejně jako lidé, i neuronové sítě potřebují ke své správné funkci dostatek učících dat.

V této diplomové práci bude popsána kompletní cesta k dosažení takové funkční neuronové sítě pro predikci hodnot heterogenního povrchu. Její výsledky budou dále porovnávány s reálnými hodnotami a s výsledky běžně používaných statistických nástrojů.

I. TEORETICKÁ ČÁST

1 JAKOST POVRCHU A JEHO HODNOCENÍ

Postupem času se rozvoj vědy a techniky zasloužil o kladení stále větších požadavků na výslednou kvalitu strojních součástí. Důležitost tohoto vývoje má za cíl snižovat hmotnost, prodlužovat životnost a zvyšovat spolehlivost vyráběných komponentů. Zvětšování mezinárodních korporací tak nutí všechny zapojené subjekty dbát zřetel nejen na vlastní státní normy. Za tímto účelem byla založena Mezinárodní organizace pro normalizaci, která se zasloužila o vytvoření mezinárodních technických norem s názvem ISO. [1]

1.1 Normy ISO

Norma ČSN EN ISO 4287 stanoví termíny, definice a parametry pro určování struktury povrchu (drsnost, vlnitost, základní profil) profilovou metodou. Jedná se o normu geometrických požadavků na výrobky (GPS). [2]

Norma ČSN EN ISO 4288 stanoví termíny pro porovnání měřených hodnot s tolerančními mezemi stanovenými pro parametry struktury povrchu v normách ISO 4287, ISO 12085, ISO 13565-2 a ISO 13565-3. Současně specifikuje standartní pravidla pro výběr mezních vlnových délek cut-off λ_c pro parametry profilu drsnosti podle ISO 8287, měřených pomocí dotkových (hrotových) přístrojů podle ISO 3274. Jedná se o normu geometrických požadavků na výrobky (GPS). [3]

Norma ČSN EN ISO 25178-2 stanoví termíny, definice a parametry pro stanovení povrchové textury pomocí plošných metod. Jedná se o normu geometrických požadavků na výrobky (GPS). [4]


1.2 Struktura povrchu

Struktura povrchu, taktéž drsnost povrchu, je soubor geometrických nerovností, které vypovídají o kvalitě povrchu daného produktu a určují jeho vzhled.

Strukturu povrchu lze rozložit na následující základní složky:

- tvar
- vlnitost

- drsnost



Obr. 1 – Řez povrchem obsahující všechny složky struktury povrchu [5]

1.2.1 Tvar

Jedná se o obecný tvar povrchu, který lze získat odfiltrováním drsnosti a vlnitosti. Tím lze získat skutečný tvar výrobku, který by se za správných okolností měl shodovat s technickým výkresem. [5]



Obr. 2 – Tvar povrchu po odfiltrování drsnosti a vlnitosti [5]

1.2.2 Vlnitost


Vlnitost lze nazvat jako makronerovnost povrchu. Tato složka struktury povrchu vzniká především negativními vlivy působícími při výrobě jako například chvění a vibracemi stroje. Tyto problémy jsou často důsledkem subtilní konstrukce zařízení, nedůkladné kalibrace nebo poškozením stroje nebo nástroje. Může se tedy jednat o špatné vyvážení brusného kotouče nebo ohnutí osy frézovacího nástroje. [5]



Obr. 3 – Vlnitost povrchu [5]

1.2.3 Drsnost

Drsnost lze nazvat jako mikronerovnost povrchu. Tato složka struktury povrchu vzniká především vzájemným pohybem nástroje a obrobku. Výsledná drsnost závisí především na použité technologii, rychlosti obrábění, materiálem obrobku, vitalitou nástroje a dalšími parametry. Jednotlivé technologie se zásadně liší ve způsobu odběru (vytrhávání) třísky a tedy i ve výsledcích nejlepší dosažitelné drsnosti povrchu. [5]



Obr. 4 – Drsnost povrchu [5]

1.3 Parametry struktury povrchu

Z důležitosti struktury povrchu pro jeho funkci je patrná nutnost měření a hodnocení jeho charakteristik. K získání komplexních informací o povrchu jsou stále ověřovány další způsoby hodnocení struktury povrchu. Ty umožňují přiřazení jednotlivých měřených parametrů k vlastnostem povrchu a podmínkám jeho vzniku. [6]

Přestože jsou postupy měření a hodnocení povrchu dlouhodobě předmětem norem, stále se postupem času vyvíjejí, zpřesňují a doplňují o nové postupy. Výsledkem těchto kroků je zajistit pokud možno nejvíce objektivní hodnocení profilu povrchu ve vztahu k jeho funkci. Přitom se nejedná pouze o zjištění stavu zkoumaného povrchu, ale také o predikci případných změn v průběhu provozu daného výrobku. Hodnocení povrchu přináší jen základní měřené parametry, které však nabízejí pouze dílčí pohled na určité vlastnosti povrchu. [7]

S vývojem jednotlivých výrobních technologií, které jsou schopny zhotovit povrch s nižší drsností povrchu než například před 50 lety, se současně vyvíjelo i hodnocení struktury povrchu. Nové pojetí geometrické specifikace výrobků, jimiž jsou normy ISO "Geometrické požadavky na výrobky" (GPS), byl vytvořen systém posuzování a 2D hodnocení struktury povrchu. Tento systém je ošetřen sadou norem. [8]

Parametry profilu nerovností se dělí do následujících skupin:

- **Amplitudové** (výškové) parametry - určují pouze velikosti vrcholů nebo prohlubní, respektive obojí, bez ohledu na rozteč (např. Ra);
- **Frekvenční** parametry (v podélném směru) – určují se pouze při roztečích nepravidelností podél plochy (příklad: Rsm - průměrná šířka prvků profilu);
- **Hybridní** parametry - jsou určeny kombinací amplitudy a rozteče (příklad: střední vlnová délka). [5]

Parametry profilu stanovuje norma ČSN EN ISO 4287. Dle kvantifikované charakteristiky hodnocení nerovností povrchu podle této normy dělíme parametry profilu povrchu na:

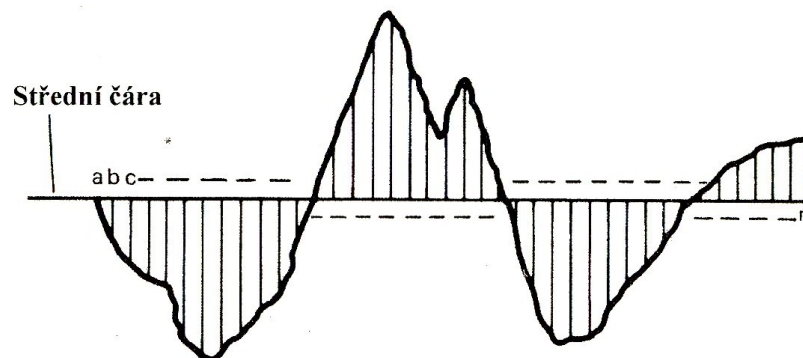

- výškové parametry (výstupky a prohlubně),
- délkové parametry,
- tvarové parametry.

Norma ČSN EN ISO 4287 definuje tyto geometrické parametry:

- **P** - parametr - parametr vypočítaný ze základního profilu
- **R** - parametr - parametr vypočítaný z profilu drsnosti
- **W** - parametr - parametr vypočítaný z profilu vlnitosti [2]

1.3.1 Střední čára

Tato přímka protínající středy vrcholů a prohlubní je určena tak, že součet vše ploch nad touto čarou (vrcholů) je roven součtu všech ploch pod touto čarou (prohlubní). K přesnějšímu určení střední čáry lze využít výpočet pomocí metody nejmenších čtverců. [5, 23] Jedná se o přímku, od které se určují všechny parametry určující strukturu povrchu popsané dále v této kapitole.




Obr. 5 – definice střední čáry profilu [5]

1.3.2 Výškové parametry

Největší výška výstupku profilu R_p - vyjadřuje výšku Z_p nejvyššího výstupku profilu v rozsahu základní délky.

Největší hloubka prohlubně profilu R_v – udává hloubku Z_v nejnižší prohlubně profilu v rozsahu základní délky.

Největší výška profilu R_z – jedná se o součet výšky Z_p (nejvyššího výstupku profilu) a hloubky Z_v (nejnižší prohlubně profilu) v rozsahu základní délky l_r . Hodnota R_z je udávána v mikrometrech (μm). [2]




Obr. 6 – Definice parametru Rz [5]

Celková výška profilu R_t – jedná se součet výšky Z_p (nejvyšší výstupku profilu) a hloubky Z_v (nejnižší prohlubně profilu) v rozsahu vyhodnocované délky l_n . [2]

Průměrná výška prvků profilu R_c – jde o průměrnou hodnotu výšek Z_t prvků profilu v rozsahu základní délky. [2]


$$R_c = \frac{1}{m} \sum_{i=1}^m Z_{t_i} \quad (\mu\text{m}) \quad (1)$$



Obr. 7 – průměrná výška prvků profilu [2]

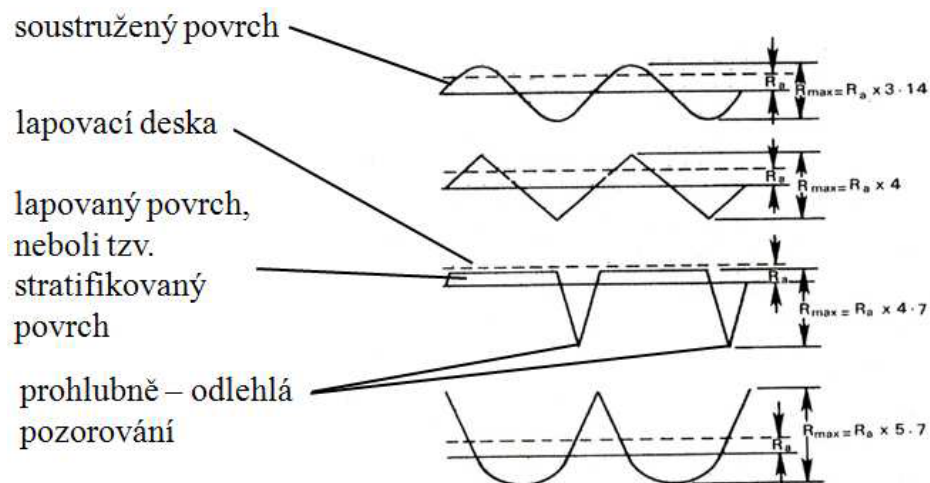
Průměrná aritmetická úchylka posuzovaného profilu R_a – jde o aritmetický průměr absolutních hodnot pořadnic $Z(x)$ v rozsahu základní délky. V praxi se jedná o nejdůležitější a nejvíce užívaný parametr drsnosti povrchu ve směru výšky. [9]

$$R_a = \frac{1}{l_r} \cdot \int_0^{l_r} |Z(x)| dx \quad (\mu m) \quad (2)$$



Obr. 8 – aritmetická úchylka profilu R_a [5]

Problémy spojené s měřením hodnoty R_a jsou, že tvar struktury povrchu a jeho opakovatelnost. Parametr R_a tedy nedává 100% informace o tvaru nepravidelností povrchu. Problematiku jasně ukazuje obrázek 9. [5]



Obr. 9 – různé hodnoty R_a v závislosti na zvolené technologii obrábění [5]

Průměrná kvadratická úchylka posuzovaného profilu Rq - popisuje kvadratický průměr pořadnic $Z(x)$ v rozsahu vyhodnocené délky lr . [9]

$$Rq = \sqrt{\frac{1}{l} \int_0^l |Z^2(x)| dx} \quad (3)$$

Šikmost posuzovaného profilu Rsk – jde o podíl průměrné hodnoty třetích mocnin pořadnic $Z(x)$ a třetí mocniny hodnoty Rq rozsahu vyhodnocené délky lr . [9]


$$Rsk = \frac{1}{Rq^3} \left| \frac{1}{lr} \int_0^{lr} |Z^3(x)| dx \right| \quad (4)$$

Špičatost posuzovaného profilu Rku – jedná se o podíl poměrné hodnoty čtvrtých mocnin pořadnic $Z(x)$ a čtvrté mocniny hodnoty Rq rozsahu základní délky lr . [9]

$$Rku = \frac{1}{Rq^4} \left| \frac{1}{lr} \int_0^{lr} |Z^4(x)| dx \right| \quad (5)$$

1.3.3 Délkové parametry


Průměrná šířka prvků profilu Rsm – jde o aritmetický průměr šířek Xs prvků profilu v rozsahu základní délky lr . Hodnota šířky Xs zahrnuje vždy dva sousední profilové extrémy, tedy vrchol a údolí. Tato šířka se určuje ke střední čáře profilu, která byla popsána dříve. Parametr Rsm je zvláště užitečný při určování posuvu u konkrétní operace obrábění. [9, 22]



Obr. 10 – průměrná šířka Rsm [5]


Materiálový poměr Rmr – jedná se o poměr délky nosné plochy v jakékoli hloubce profilu k celkové délce profilu vyjádřený v procentech. Lze tedy říct, že poměr 0% náleží nejvyšší špičce vrcholu v konkrétním řezu, naopak nejhlubší údolí by představovalo 100%. Jde o velmi důležitý parametr v praxi a užívá se především u dvou dílů se vzájemnou dotykovou plochou. [5, 22]

$$Rmr = \frac{a+b+c+d+e}{L} \times 100\% \quad (6)$$



Obr. 11 – materiálový poměr délek vůči celkové délce profilu [5]

Abbot-Firestonova křivka – křivka materiálového poměru představuje profil povrchu jako funkci úrovně grafu. Tuto křivku lze sestavit vynesáním hodnot materiálových poměrů v hloubce celého zkoumaného profilu. Stejně jako u parametru Rmr zde tedy pracujeme se součtem nosných ploch v konkrétní hloubce profilu. Tato výsledná křivka poskytuje možnost charakterizace různých tvarů profilů. [22, 5]



Obr. 12 – princip vzniku Abbot-Firestonovy křivky [22]

Finální struktura povrchu konečného výrobku a všechny výše popsané parametry k jeho hodnocení se rapidně mění v závislosti na použité technologii obrábění. Konvenční technologie jako například soustružení, frézování nebo broušení jsou charakteristické relativně stejně jakostním povrchem na celé ploše výrobku. Takový povrch má při provedení několika měření na různých místech jeho plochy téměř totožné výsledky parametrů Ra, Rz, Rmr a Rsm. Nicméně při použití nekonvenčních (moderních) technologií dostáváme povrch, který se svou strukturou dle zkoumaného místa na jeho ploše velmi výrazně liší. Ale než začneme hovořit o struktuře takového povrchu, je nejprve nutné si řádně popsat takové nekonvenční technologie a až poté jaké povrchy při jejich použití vznikají.

2 NEKONVENČNÍ TECHNOLOGIE ODBĚRU MATERIÁLU

Název nekonvenční způsoby odběru materiálu anebo také nekonvenční způsoby obrábění se používá pro širokou škálu mechanických, elektrických, tepelných a chemických procesů při odběru materiálu, které byly vyvinuty převážně po roce 1940.

Stručnou definici nekonvenčních (netradičních) technologií je těžké stanovit kvůli velmi rozdílným procesům, které do této kategorie patří. V odborné literatuře panuje shoda v tom, že do této skupiny patří procesy, které byly do průmyslu zavedeny za posledních 80 let. Jedná se o metody, které používají běžné formy energie novým způsobem anebo používají energii, které k obrábění nikdy dříve použita nebyla.

Dříve byly tyto nové způsoby obrábění určeny pro zvláštní použití a nebyly příliš šířeny. V současnosti je tomu však zcela jinak. Velká část nových metod byla vyvinuta pro řešení speciálních úloh v leteckém a kosmickém průmyslu v letech 1950 až 1960. Dnes většina z nich nachází široké uplatnění v různorodých odvětvích průmyslu.

Velmi technicky složité vynálezy posledního století jako jsou letadla, automobily, kosmické rakety a vesmírné stanice dali vytvořit širokou škálu nových těžkoobrobitelných materiálů, jejichž opracování představuje poměrně těžko řešitelný problém. Jako příklad je možno uvést kompozitní materiály s kovovou maticí, monolitické a kompozitní keramické materiály, vysoko trvanlivé polymery a jiné. Problémy vznikající při obrábění těchto materiálů vyplývají především z jejich vysoké tvrdosti a křehkosti, žáruvzdornosti, nevhodných tepelných vlastností, chemické reaktivity s řezným nástrojem nebo nehomogenní mikrostruktury. V těchto případech se ukazují výhody nekonvenčních technologií. [11]

Mezi nejrozšířenější nekonvenční metody lze zařadit:

- Obrábění laserovým paprskem
- Řezání plazmou
- Řezání vodním paprskem

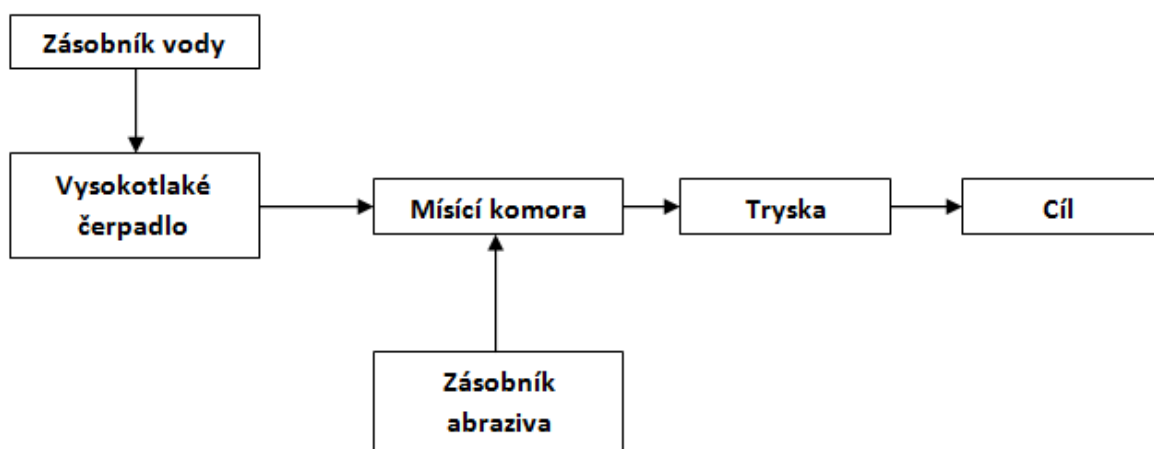
V této diplomové práci budou posuzovány drsnosti povrchů vzniklých pomocí obrábění vodním paprskem za různých podmínek. Proto bude z celé škály nekonvenčních technologií vybrána právě tato pro její bližší prozkoumání.

2.1 Obrábění vodním paprskem

Technologie obrábění vysokoenergetickým kapalinovým paprskem (VKP) je známa i pod anglickým názvem Abrasive Jet Machining (AJM) nebo také Abrasive Flow Machining (AFM). Využívá se zde abrazivních a erozivních účinků vysokoenergetického kapalinového (vodního) paprsku pro obrábění materiálů. Technologie byla vyvinuta převážně pro opracování nekovových materiálů při stavbě raketoplánů v USA. Díky přednostem této metody našla své uplatnění v leteckém a zbytku kosmického průmyslu a později v celé řadě dalších průmyslových oborů. [11,12]

2.1.1 Princip vodního paprsku

Princip vzniku řezného vodního paprsku je poměrně jednoduchý. Voda z nádrže je za pomoci vysokotlakých čerpadel přesunuta do dopravního systému. Tato čerpadla jsou schopná předat vodě tlak až 6000 bar, avšak tato hodnota se různí výrobcem daného čerpadla a především jeho použitím. Voda z dopravního systému dále putuje do komory, kde se již jako vodní paprsek mísí s abrazivem (tvrdé brusné částice). Tato vysokotlaká směs je dále tlačena skrz trysku (často označovanou jako dýza), která udává průměr výstupního paprsku a z níž tento paprsek dopadá na obráběný materiál. Tyto kroky se můžou nepatrně lišit v závislosti na typu vodního paprsku, které budou popsány dále. Celý proces zjednodušeně ilustruje následující obrázek. [13]



Obr. 13 – schéma principu vzniku vodního paprsku [13]


2.1.2 Typy vodního paprsku

Vodní paprsek lze podle jeho charakteru rozdělit na:

- kontinuální – nepřerušovaný
- diskontinuální – přerušovaný (vyvinut z důvodu větší efektivity úběru materiálu)

Dále je možné paprsek dělit na čistý vodní paprsek nebo abrazivní vodní paprsek, který kromě vody obsahuje navíc částice tvrdého materiálu, které zvyšují (až 1000x) řezný výkon. Takto obohacený vodní paprsek se ještě podle způsobu míšení rozděluje na abrazivní vodní paprsek (abrazive injector waterjet) a abrazivní suspenzivní vodní paprsek (abrazive suspension waterjet). Přestože se jedná o relativně podobné technologie, jsou jejich vlastnosti poměrně velmi odlišné a liší se především použitím a jejich výkonností.

Čistý vodní paprsek narušuje povrch obrobku pouze jen erozí samotné vysokotlaké vody. Nicméně u abrazivní paprsek narušuje materiál abrazivem, kde voda slouží pouze jako urychlovací médium a jen částečně jako nástroj k erozi. Na následujícím obrázku můžeme vidět schématické rozdělení typů vodního paprsku. [14]



Obr. 14 – přehled typů vodních paprsků [14]


2.1.3 Čistý vodní paprsek

Čistý vodní paprsek jako nástroj pro řezání materiálu vzniká průchodem vysokotlaké vody přes safírovou, rubínovou nebo diamantovou trysku. V tomto případě jde o odběr materiálu erozivním účinkem. Vzhledem k nízkým rezným výkonům je tento způsob využíván především pro měkké materiály. Může se tedy jednat o textilie, dřevěné překližky, umělé hmoty, kovové fólie, papírové výrobky, pěny, těsnicí materiály nebo potraviny. K nejčastěji zpracovávaným výrobkům patří hedvábný papír, vybavení interiérů automobilů či jednorázové pleny. Paradoxem je, že při řezání plen nebo papíru touto metodou vznikne na jejich povrchu menší vlhkost, než při dotyku prstu nebo dýchnutí člověkem.

Použití čistého vodního paprsku přináší hned několik výhod, které jsou rozhodující pro zájemce o tuto technologii. Protože paprsek neobsahuje žádná abraziva, lze tak dosáhnout velmi malých průměrů trysky (0,1016 - 0,254 mm). Díky tomu lze vyprodukovat malé množství odpadu a umožnit výrobu velmi složitých tvarů s jemnou konturou, ostrými úhly, malými poloměry a to vše s velkou přesností. Při řezání čistou vodou nevzniká žádné teplo, díky čemuž není materiál v místě řezu tepelně namáhán, což je oproti řezání laserem nebo plazmou velká výhoda. Řezná síla je poměrně nízká, což vylučuje nutnost obrobek pevně upínat složitými přípravky. I přes svůj malý rezný výkon tato technologie zvládne řezat měkké a lehké materiály do velké hloubky (izolace ze sklených vláken do tloušťky až 610 mm). Bezesporu největší výhodou oproti řezání s abrazivním materiálem je především životnost trysky, která je díky použitým materiálům poměrně drahou spotřební položkou při užívání této technologie. [13, 14, 16]

2.1.4 Abrazivní vodní paprsek

Jedná se o typ abrazivního paprsku, který pracuje s proudem vody, jenž je urychlen přes první tzv. vodní trysku. Paprsek vody se poté dostane do směšovací komory. V ní je vytváří podtlak, který způsobí strhávání abraziva dodávaného hadicí ze zásobníku. Množství abraziva ve vodním paprsku je úměrné poklesu jeho tlaku před směšovací komorou. Následně je tato směs tlačena do zaostřovací trysky, ze které je cílena na řezaný výrobek. Celý proces je znázorněn a popsán na obrázku číslo 15. [12, 14]




Obr. 15 – princip vzniku abrazivního vodního paprsku [14]

Problémy a nevýhody této metody:

- Výstupní tryska je namáhána rychlé a silné erozi vzniklého vodního paprsku. Pro zvýšení životnosti je využito vložky z karbidu wolframu.
- Přestože je abrazivní materiál strháván proudem vody zcela samovolně, tak je často potřeba dodávat externí zdroj energie pro toto mísení. Problém nastává při poklesu tlaku, kdy je abrazivní materiál mísen a tedy tak dochází i ke snížení výstupního tlaku na konci zaostřovací trysky. Důsledkem je poté snížení celkového řezného výkonu.
- Jako problematický se jeví také suchý podávací otvor abraziva. Dávkování je řízeno především sacím tlakem ve směšovací komoře a je také závislé na velikosti otvoru. Optimální dávkování je téměř nemožné kontrolovat při použití pouze jednoho otvoru. Jako možné, ale nepraktické se nabízí střídavě užívat různé velikosti otvorů do chvíle než je nastavení optimální poměr abraziva a vody. Dávkování se dále mění v závislosti na opotřebení vstupního otvoru vlivem eroze.
- Při užití suchého abraziva dochází ke strhávání vzduchu, což má za následek vážný problém. Díky stlačitelnosti vzduchu dochází po opuštění trysky k jeho opětovnému roztažení, což má za následek narušení paprsku do kapek a výrazné snížení řezného výkonu.
- Opačným problémem předchozího stavu je, když se voda ze směšovací komory dostane do potrubí ze zásobníku abraziva. Dochází tak zanášení nebo úplnému ucpání přívodu abrazivní složky. [11, 14]

2.1.5 Abrazivní suspenzní paprsek

Tato metoda v podstatě upravuje tu předchozí, aby se zabránilo vniknutí vzduchu do směšovací komory. Přibližně 10% stlačené vody je přidaným potrubím odvedeno do zásobníku abraziva, který slouží současně jako směšovací komora. V tomto provedení se musí jednat již o vysokotlakou nádobu, která vydrží působící tlaky. Díky tomu je směs vody a abraziva dopravena do trysky, aniž by do ní vstupoval vzduch. Tato konstrukce však přináší komplikaci ve formě dávkování abraziva. Není žádný způsob jak zaručit, že přívod ze zásobníku bude dodávat stále stejnou koncentraci abrazivního materiálu. Díky tomu, že je směs abraziva a vody urychlována společně pod tlakem, je účinnost této metody vyšší než u strhávání suchého abraziva. Tak je možné použít při obrábění menší tlak a menší dávku abraziva. Tyhle vlastnosti zajišťují vyšší životnost trysek a menší finanční náklady na provoz zařízení. [12, 14]



Obr. 16 - princip vzniku abrazivního suspenzního paprsku [14]

2.1.6 Kvalita řezu

Topografie povrchu při použití technologie řezání vodním paprskem je málo prozkoumanou oblastí. Stejně jako jiné vysokoenergetické paprsky zanechává i tato technologie viditelné rýhy na obrobené ploše výrobků. To výrazně ovlivňuje rozměrové přesnosti a kvality dokončeného povrchu. Faktory ovlivňující kvalitu výsledného řezu jsou především množství abraziva, tlak vodního paprsku, tvar řezu a tloušťka obrobku. Pro vodní paprsek je charakterizující, že povrch vzniklý při použití této technologie lze označit za heterogenní z důvodu, že na jeho povrchu není podél dráhy řezu konstantní struktura a drsnost. Na následujícím obrázku lze spatřit různé úrovně heterogenity řezů lišící se v pěti stupních, kdy na vzorku Q1 je vidět značná heterogenita a na vzorku Q5 téměř homogenní povrch. [17,18]



Obr. 17 – stupně kvality řezu vodním paprskem [18]

Výsledná struktura a charakter heterogenních povrchů za použití technologie řezání vodním abrazivním paprskem je předmětem zkoumání této diplomové práce. Proto o tomto tématu bude pojednávat následující kapitola, ve které bude tato struktura detailněji popsána.


3 HETEROGENNÍ POVRCH

Lze konstatovat, že typické heterogenní povrchy z hlediska své drsnosti vznikají především za použití nekonvenčních technologií. V našem případě se budeme zabývat povrchy, jež vznikly řezáním vodním paprskem s příměsí abraziva. Mnoho autorů odborné literatury se shoduje, že téma topografie povrchů po obrábění vodním paprskem je poměrně málo prozkoumanou oblastí. Současně autoři uvádějí, že při použití vysokoenergetické paprskové metody zůstávají na obrobku viditelné stopy, které jednotně nazývají rýhováním. Tyto rýhy dle jejich slov značně ovlivňují rozměrovou přesnost a hlavně kvalitu hotového povrchu výsledného výrobku. [19]


Velké zastoupení autorů odborné literatury uvádí, že po řezání vodním paprskem se výsledná plocha z topologického hlediska skládá z dvou odlišných oblastí. Jedná se o oblast hladkou a oblast drsnou (také nazývanou jako rýhovanou [19]). Tyto oblasti se dále nazývají jako primární a sekundární. [19]

Podle teorie o řezání vodním paprskem lze konstatovat, že s hloubkou průniku do řezaného materiálu ztrácí paprsek svou kinetickou energii a dochází k jeho vychýlení, což zapříčiní vzniku dvou typických zón, které mají odlišnou drsnost povrchu, a která se mezi nimi postupně mění. Hladká oblast vzniká vlivem řezného opotřebení. Druhá méně kvalitní drsná oblast vzniká vlivem deformačního opotřebení. [19]

Při provedení detailnějšího průzkumu a analýzy dat heterogenního povrchu lze vyvodit, že je možné rozdělení tohoto povrchu ještě více zpřesnit. Kromě rozdělení na primární sekundární oblast lze toto členění rozšířit ještě o jednu. Vzniknou tak oblasti primární, sekundární a terciální. Po tomto kroku první dvě oblasti spadají do zóny hladké a oblast terciální lze určit jako rýhovanou. Tuto teorii podporují obrázky pod tímto odstavcem, na kterých lze spatřit nezanedbatelné rozdíly mezi jednotlivými oblastmi. [19]



Obr. 18 – členění obrobku na jednotlivé zóny [19]



Obr. 19 – struktura profilových čar v oblastech heterogenního povrchu [19]

Strukturu povrchu a její průběh měnící se k lepší nebo horší kvalitě lze často popsat především změnami parametrů při výrobním procesu (opotřebení nástroje, změny rychlosti obrábění). Tyto změny jsou obvykle popsatelné určitým matematickým vztahem s lineárním nebo nelineárním průběhem dané funkce. Jedním takovým nástrojem jsou regresní analýzy, které se k těmto účelům často používají. Jejich uplatnění je velmi široké, ale stejně jako vše mají svá jistá omezení. Tato omezení souvisí právě s heterogenním povrchem a proto je nutné si tento statistický nástroj lépe popsat v následující části práce.

4 STATISTICKÉ NÁSTROJE NA HODNOCENÍ DAT

4.1 Regresní analýza

Regresní analýza je využívána pro zkoumání závislostí dvou či více číselných proměnných. Jedná se o souhrn statistických postupů a metod pro odhad hodnot nebo středních hodnot zkoumané proměnné. Pro tato zkoumání se nejčastěji užívá výběrového souboru naměřených dat. [27, 28]

Lineární regresní analýza se nejčastěji používá v těchto případech:

1. Popis empirických dat
2. Určování parametrů
3. Predikce
4. Řízení
5. Výběru důležitých proměnných [25]

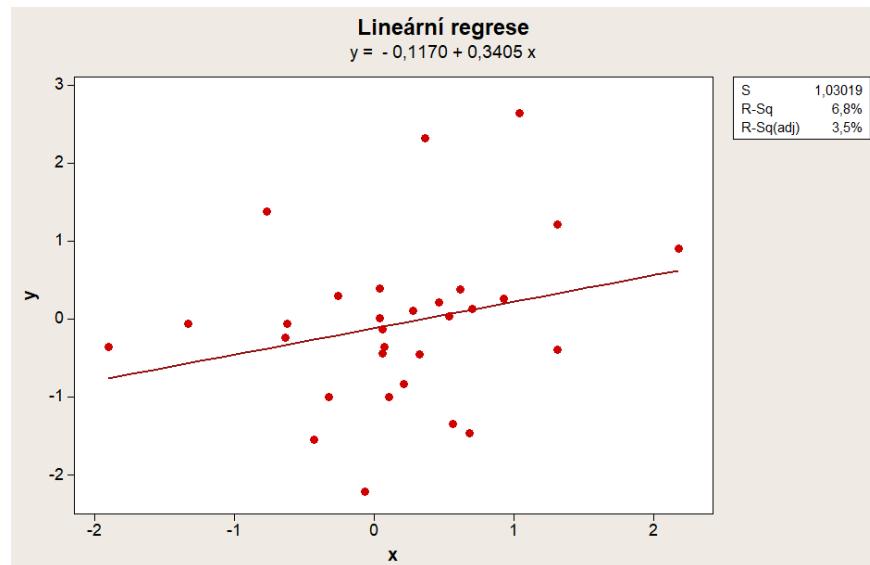
4.1.1 Lineární regrese

Lineární regresi lze považovat za nejméně složitý typ regresní analýzy. Vzhledem k tomu je také nejčastěji používána. Lineární regrese sleduje závislost výstupní veličiny y na vstupní veličině x , kterou můžeme také nazvat slovem prediktor. Tato závislost může být popsána regresní rovnicí. [26]

$$y = \beta_0 + \beta_1 \times x, \text{ kde} \quad (7)$$

- y je závislá proměnná
- β_0, β_1 jsou regresní koeficienty
- x je nezávislá proměnná (prediktor) [26]

Důležité je, aby výsledná přímka co nejlépe vystihovala zkoumaný soubor dat. Za tímto účelem správně volíme koeficienty β_0 a β_1 . Ve výsledném regresním modelu má každá pozorovaná nezávislá hodnota x_i odpovídající skutečnou (empirickou) hodnotu závislé proměnné y_i teoretickou (vypočítanou) hodnotu Y_i , ležící na regresní přímce dle regresní rovnice (7). [25, 26]




Obr. 20 – graf lineární regrese

Metoda nejmenších čtverců

Výsledná regresní křivka by měla co nejlépe vystihovat charakter průběhu funkce zkoumaných dat. To lze chápat tak, že všechny vypočítané teoretické hodnoty Y_i by se měly co nejméně odlišovat od skutečných y_i . To znamená, že rezidua (odchylky mezi empirickými a vypočtenými hodnotami regresní funkce) byly co nejmenší a tak byly co nejlépe kompenzovány všechny kladné a záporné odchylky. Tento způsob se nazývá metoda nejmenších čtverců. [27, 28]

Na obrázku níže můžeme vidět dva bodové grafy se stejnými hodnotami, ale odlišným průběhem lineární regrese. Jako správný lze považovat případ vpravo, kde celkový součet ploch všech čtverců je menší než v případě na levé straně. [30]



Obr. 21 – dva bodové grafy znázorňující metodu nejmenších čtverců [30]

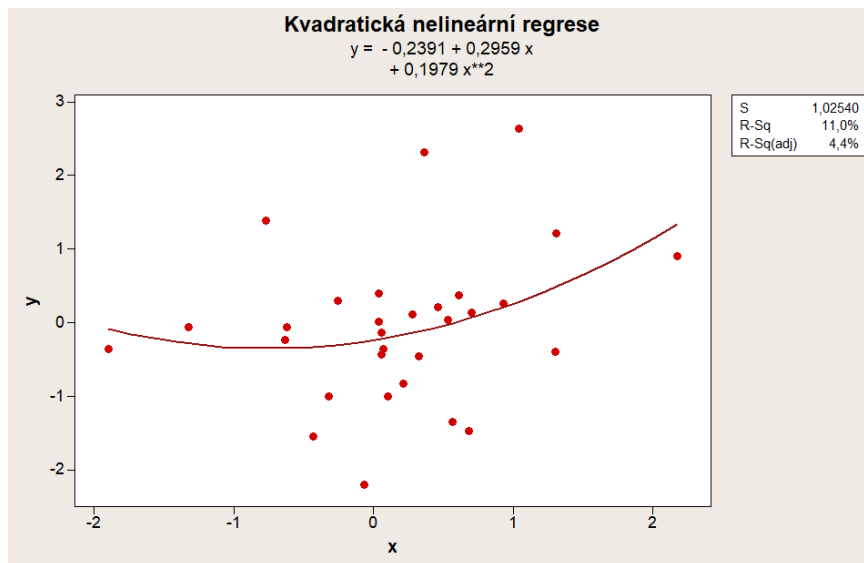
4.1.2 Nelineární regrese

Ve snaze docílit co nejlepšího charakterizování zkoumaných dat regresní funkcí je často nutné upustit od lineární (přímkové) závislosti. V takových případech se nabízí nelineární regrese, která matematicky vychází z předchozího případu a je doplněna o potřebný polynom, který pozmění tvar výsledné křivky. Nelineární regresi lze rozdělit na kvadratickou, kubickou, logaritmickou a hyperbolickou. [23]

Za zmínku stojí především kvadratická a kubická, které lze nazvat jako nelineární regrese druhého a třetího stupně.

Nelineární regresi kvadratickou lze popsat vztahem: [23]

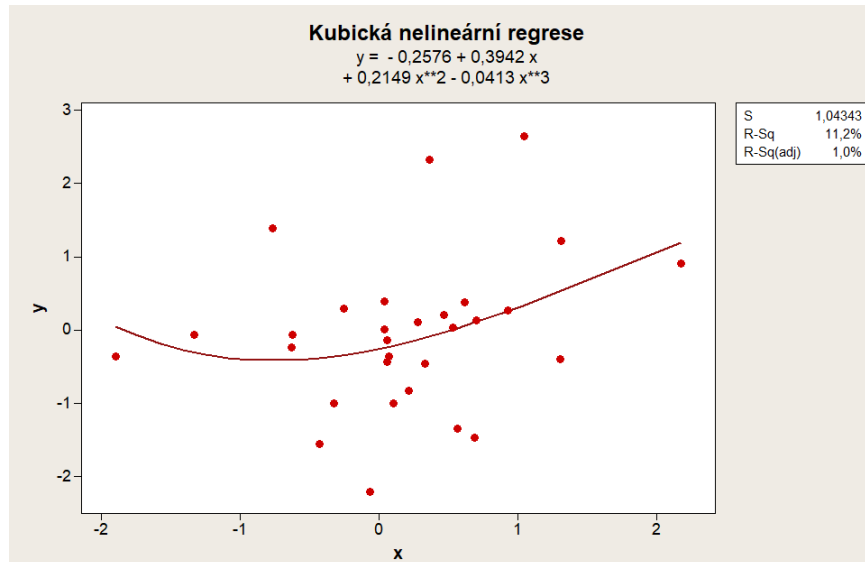
$$y = \beta_0 + \beta_1 \times x + \beta_2 \times x^2 \quad (8)$$



Obr. 22 – graf kvadratické nelineární regrese

Nelineární regresi kubickou lze popsat vztahem: [23]

$$y = \beta_0 + \beta_1 \times x + \beta_2 \times x^2 + \beta_3 \times x^3 \quad (9)$$



Obr. 23 – graf kubické nelineární regrese

Regresní analýzy jsou pro svou jednoduchost a široké praktické užití velmi oblíbeným a často aplikovaným nástrojem. Nicméně u značně nelineárně vyvíjejících se trendů se rapidně snižuje jejich vypovídající hodnota o souboru zkoumaných dat. Takovým průběhem může být právě drsnost heterogenního povrchu, u kterého, jak jsme si dříve uvedli, se mění v závislosti na zkoumané oblasti. V těchto případech je proto nezbytné použít statistický nástroj, kterým jsou neuronové sítě. Tuto vyspělou moderní metodu na vyhodnocování dat blíže popisuje následující kapitola.

5 NEURONOVÉ SÍTĚ

Neuronovou síť lze popsat jako algoritmus, který se svou funkcí podobá lidskému mozku. Ten je tvořen přibližně z 10^{10} nervových buněk, takzvaných neuronů, mezi sebou navzájem propojených řádově ještě vyšším počtem vazeb. V minulosti bylo zjištěno, že tyto neurony mezi sebou komunikují za pomoci elektrických impulzů. [20, 21]

Od počátku prvních počítačů se mnoho programátorů snažilo vytvořit algoritmus, který by napodoboval činnost lidského mozku. Výsledky tohoto snažení daly za vznik nového pojmu s názvem umělá inteligence. V současné době lze princip neuronových sítí nalézt v mnoha dostupných analytických a rozhodovacích programech, které podávají vynikající výsledky v porovnání s běžnými druhy rozhodovacích algoritmů. [20]

5.1 Princip sítě

Jak bylo již popsáno v úvodu, funkce softwarové neuronové sítě je inspirována biologickou neuronovou sítí, ve které je základem všeho nervová buňka neboli neuron. Všechny neurony jsou pak mezi sebou propojeny spoji, které jsou obohaceny váhami. Tyto váhy mají schopnost adaptovat a učit se na základě trénovacích vzorů v datech. Tato přednost dává neuronové síti mnoho nových možností při analyzování dat. [20, 24]

Největší předností neuronových sítí je tedy schopnost učení se, zapamatování si kombinací, které vedou k požadovanému výstupu a poté se u nových vstupů vracet do své paměti, díky které lze odhadnout nový výsledek. V takovém případě lze hovořit o generalizaci (tzv. zevšeobecnění), která patří dalším velkým přednostem neuronových sítí. Tuto dovednost lze popsat jako schopnost správně zareagovat také na vstupy, jež nebyly obsaženy v souboru trénovacích dat, a lze z nich vyvodit určité závěry. Právě proto bývá schopnost učení se považována často za definici umělé inteligence. [20, 24]


Doménou neuronových sítí je schopnost řešení velmi nelineárních úloh. Proto nacházejí uplatnění především tam, kde selhávají klasické matematické modely jako třeba dříve popsaná regrese. U mnohých případů analýzy dat není možné najít jednoduchou matematickou funkci, jež by dokázala popsat celý průběh sledované proměnné. V takové situaci je vhodné použít neuronové sítě. [20, 24]

5.2 Model neuronu

Model neuronu je složen ze tří částí:

- Vstupní
- Výstupní
- Funkční

Jednotlivé vstupy mohou být na základě vah zvýhodněny nebo naopak potlačeny. Informace jsou zpracovány funkční částí a informace jsou generovány na výstupu. Tato výstupní část poté předá výsledné informace na vstupy dalších neuronů.



Obr. 24 – model neuronu [20]

Výstup neuronu $f(\xi)$ je spočítán ve chvíli, kdy suma vstupů do neuronu x_i násobených jejich konkrétními vahami w_i překročí určitou hodnotu, kterou nazýváme práh (θ).

Hodnota y na výstupu je obecně vyjádřena vztahem:


$$y = f(\sum_{i=1}^n x_i \times w_i - \theta), \text{ kde} \quad (10)$$

- f je přenosová funkce
- n je počet vstupů
- x_i je hodnota i -tého vstupu
- w_i je váha příslušná i -tému vstupu
- θ je prahová hodnota [20]

5.3 Perceptron

Frank Rosenblatt (r. 1957) je autorem této nejjednodušší neuronové sítě. Perceptron lze popsat jako jednoduchou neuronovou síť s n vstupy (x_1, x_2, \dots, x_n) a jedním pracovním neuronem, který je spojen se všemi svými vstupy. Každé takové spojení má přiřazenu váhovou hodnotu (w_1, w_2, \dots, w_n).

Perceptron byl původně využíván k rozpoznávání znaků za pomoci pole optických snímačů. Tak byla modelována biologická percepce, což dalo vzniknout názvu perceptron. Tento název se v dnešní době ujal a našel uplatnění v odvětví umělé inteligence pro značení vrstvené neuronové sítě. V této síti se signály šíří od vstupu k výstupu jednosměrně. Perceptronová síť je charakteristická tím, že počet vstupů neuronu je roven počtu neuronů v předchozí vrstvě a současně je jeho počet výstupů roven počtu neuronů v následující vrstvě. Neurony ve stejné vrstvě nejsou mezi sebou nijak propojeny. Síť obsahující tři vrstvy umí provádět jakoukoli logickou funkci a především proto je nejčastěji užívána. [19, 20, 21]



Obr. 25 – perceptron (neuronová síť) s jednou skrytou vrstvou [19]

5.4 Přeučení neuronové sítě

Všeobecně lze říci, že pokud je neuronová síť složena z malého počtu neuronů, tak se její schopnosti popisu závislostí na trénovacích datech snižují. V opačném případě, kdy je síť složena z velkého počtu neuronů, nebude mít problém řádně popsat závislosti v trénovacích datech, nicméně se může snížit schopnost generalizace. To znamená, že výsledek se může zhoršit. Tento jev je popisován jako přeučení sítě (tzv. overfitting). K tomuto přeučení může dojít v situaci, kdy navržený model obsahuje velký počet parametrů na vstupu, ale relativně malý počet pozorování. Maximalizovat výkon sítě na trénovacích datech tedy není cílem. Spíše bychom se měli snažit o nalezení kompromisu mezi trénovacím výkonem a schopností zevšeobecnovat znalosti také na nových datech. [24]

II. PRAKTICKÁ ČÁST

6 STANOVENÍ CÍLŮ DIPLOMOVÉ PRÁCE

Cílem této diplomové práce je navrhnout a ověřit vhodné statistické metody pro globální hodnocení heterogenních povrchů. Pro tento účel bude využito pěti vzorků k jejich proměření a získání potřebných dat. Z dostupné odborné literatury je patrné, že v hodnocení heterogenit běžné statistické metody selhávají. Cílem této práce bude tedy navrhnout funkční neuronovou síť, která bude co nejlépe popisovat průběh drsnosti zkoumaného povrchu a bude schopna tento průběh predikovat na základě vstupních proměnných. Dále bude cílem dokázat, že je tato pokročilá statistická metoda zcela přesahuje možnosti a vypovídající hodnotu běžných regresních analýz.

7 PŘÍPRAVA VZORKŮ A JEJICH VLASTNOSTI

Pro tuto práci bylo nezbytně nutné získat určité množství dat s charakteristickými vlastnostmi pro heterogenní povrch. K tomuto účelu posloužilo pět vzorků (Q1 až Q5) s odlišnými vlastnostmi kvality povrchu jejich řezu. Jednalo se o kruhové výřezy z ocelového plátu o průměru 60 mm a tloušťce 10 mm, které vznikly za použití abrazivního vodního paprsku. Materiál kovu je dle EN ISO značen E335 (dle normy ČSN 11600). Na všech vzorcích je kromě jejich kruhového tvaru patrný výstupek, který sloužil jako plocha náběhu a konce řezného paprsku, aby byly na obvodu kruhu zachovány stejné řezné podmínky. Jako abrazivum byl použit drcený granát s průmyslovým označením GARNET MESH 80 a výstupní tryska vyrobená z karbidu wolframu měla průměr 0,3 mm. Jednotlivé vzorky Q1 až Q5 byly řezány za odlišných řezných podmínek, proto se kvalita jejich povrchu postupně mění od nejméně jakostní Q1 po nejkvalitnější povrch v případě vzorku Q5. Řezná rychlost byla u výroby všech vzorků stejná. Její hodnota činila 10 mm/s. Rozdílný byl tlak výstupního paprsku. V případě vzorku Q1 byla hodnota 240 MPa. U každého dalšího vzorku byla tato hodnota nevyšena o 20 MPa, kdy na posledním vzorku Q5 činila 320 MPa.



Obr. 26 – vzorky Q1 až Q5



Obr. 27 – srovnání jakosti povrchu vzorků Q1 (vpravo) a Q5 (vlevo)

7.1 Úprava vzorků před měřením

Vzhledem k použitému měřicímu přístroji nebylo možné vzorky měřit přímo ve stavu, ve kterém byly dodány. Zkoumaným povrchem byla plocha řezu a bylo tedy potřeba měřit vzorky postavené na výšku. To ovšem nebylo vzhledem k jejich průměru možné, protože rozsah pracovní plochy přístroje to neumožňoval. Všechny vzorky bylo potřeba kvůli tomu rozdělit na dvě části. K tomuto účelu posloužila pásová pila a každý vzorek byl rozdělen na dvě odlišně velké části. Zkoumanou polovinou se dále u měření stala ta menší část. Současně toto nezbytné opatření přispělo ke kvalitnějším a přesnějším výsledkům měření, protože je tak zkoumaný vzorek položen na podložku přístroje velkou rovnou plochou a není potřeba zabránovat balancování v případě plochy válcové.



Obr. 28 – vzorek Q5 po provedení řezu

8 PARAMETRY A PRŮBĚH MĚŘENÍ

8.1 Měřicí přístroj použitý k měření

Za účelem získání kvalitního výběrového souboru hodnot drsnosti heterogenního povrchu byl zvolen dostupný měřicí přístroj Talysurf CLI 500 od výrobce Taylor Hobson. Jedná se o bezkontaktní drsnoměr, který zkoumaný povrch snímá za pomoci laserového paprsku. Jde o konfokální hlavu CLA, která pracuje s rozkladem bílého světla pomocí optiky se spektrální aberací. Odražené paprsky z povrchu vzorku jsou dále vyhodnocovány dle jejich vlnových délek, což má za následek vychýlení hodnot na spektrometru, kdy každé takové hodnotě odpovídá reálná prostorová odchylka. Přístroj je vybaven měřicí podložkou elektronicky polohovatelnou v osách X a Y, což mu umožňuje snímat povrch jak ve 2D, tak ve 3D a právě pro trojrozměrné měření je tento přístroj z výroby předurčen. [29]



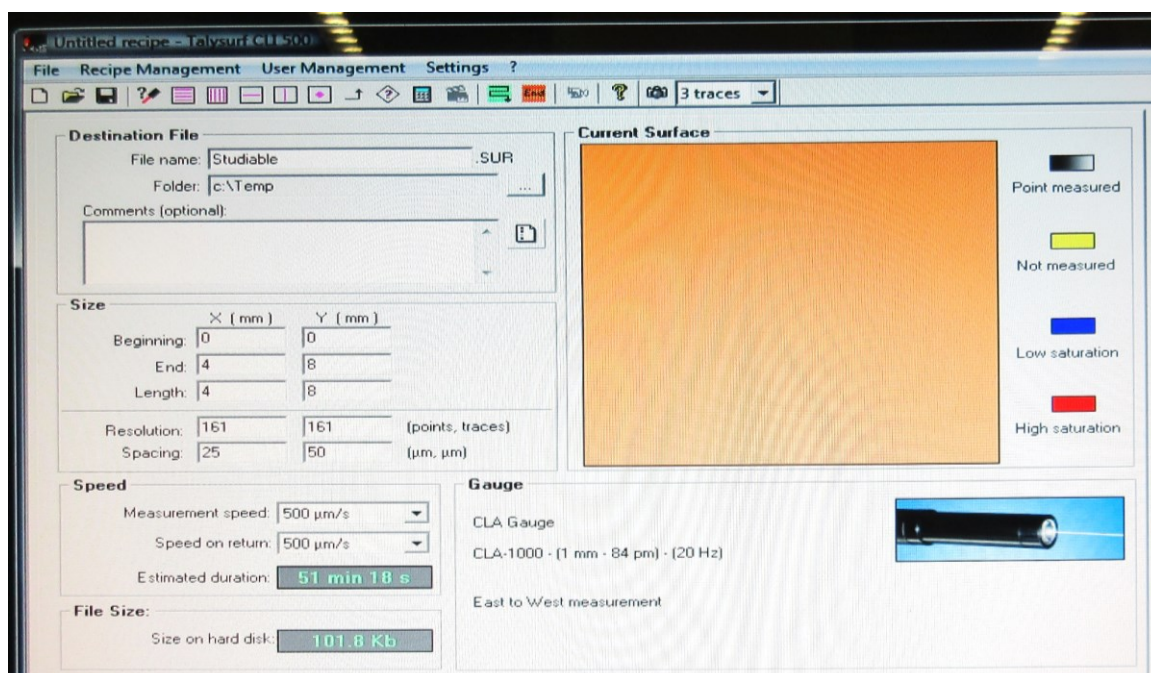
Obr. 29 – bezkontaktní drsnoměr Taylor Hobson Talysurf CLI 500

8.2 Parametry měření

Z důvodu možné opakovatelnosti nebo reprodukovatelnosti měření je nezbytně nutné uvést zde veškeré nastavené parametry měření snímané plochy vzorků. Měřicí přístroj Talysurf CLI 500 je ovládán pomocí vlastního softwaru, který je nainstalován v notebooku přiloženém jako součást přístroje při jeho nákupu. Všechny nastavené parametry v programu jsou přehledně popsány v tabulce níže. Všechny vzorky jsou měřeny jako povrch ve 3D.


Tabulka 1 – přehled nastavených parametrů měření

Měřená dráha v ose X	4 mm
Měřená dráha v ose Y	8 mm
Vzdálenost měřených bodů v ose X	25 μm
Vzdálenost měřených bodů v ose Y	50 μm
Počet měřených bodů a drah	161
Rychlost měření	500 $\mu\text{m/s}$
Rychlost návratu snímače	500 $\mu\text{m/s}$
Čas potřebný k měření	51 minut 18 sekund



Obr. 30 – přehled nastavených parametrů měření v programu k přístroji

Na připraveném vzorku tak byla předmětem zkoumání obdélníková plocha 4x8 mm, kdy kratší strana X byla souběžná s hranou obvodu původního kruhového tvaru.



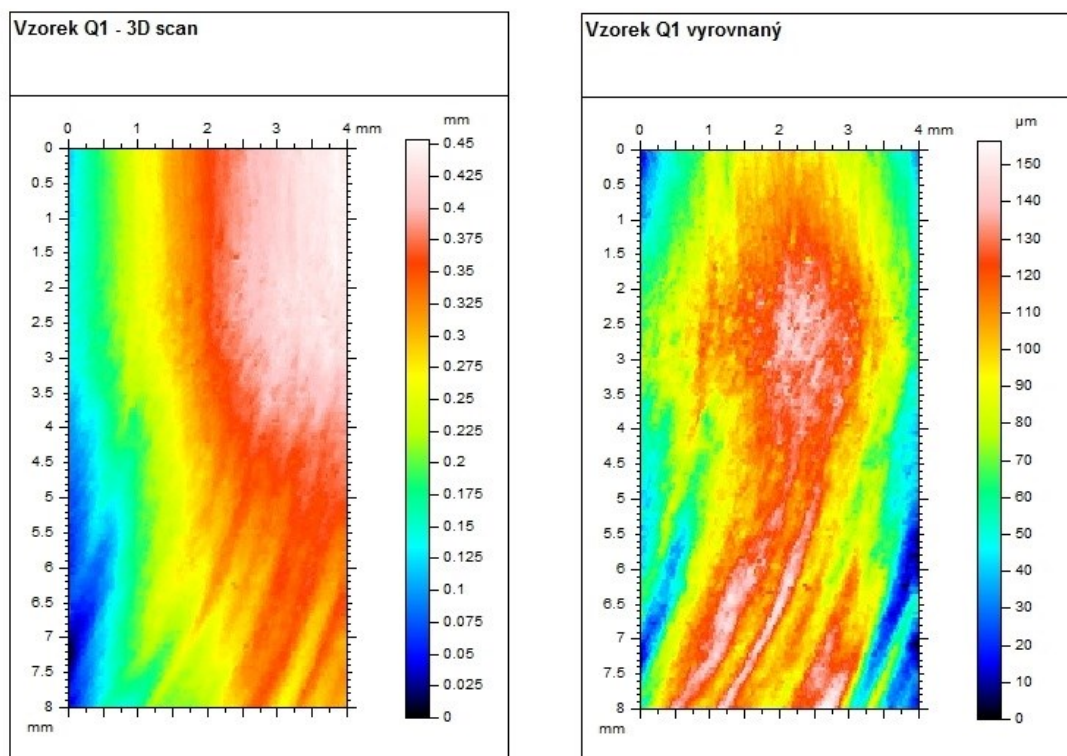
Obr. 31 – připravený vzorek na měření a jeho souřadnicový systém

8.3 Zpracování a export naměřených dat

Veškerá získaná data se vzorků Q1 až Q5 byla po nasnímání přenesena do programu Talymap Gold. Tento software je opět nedílnou součástí použitého drsnoměru a je rovněž nainstalován v dodaném notebooku k tomuto zařízení. V tomto programu proběhlo vykreslení všech povrchů, odfiltrování zakřivení snímané plochy, vytvoření 3D pohledu a jeho následné filtrace na jednotlivé složky povrchu drsnosti. Průběh získání dat bude detailně popsán v této kapitole.

8.3.1 3D scan

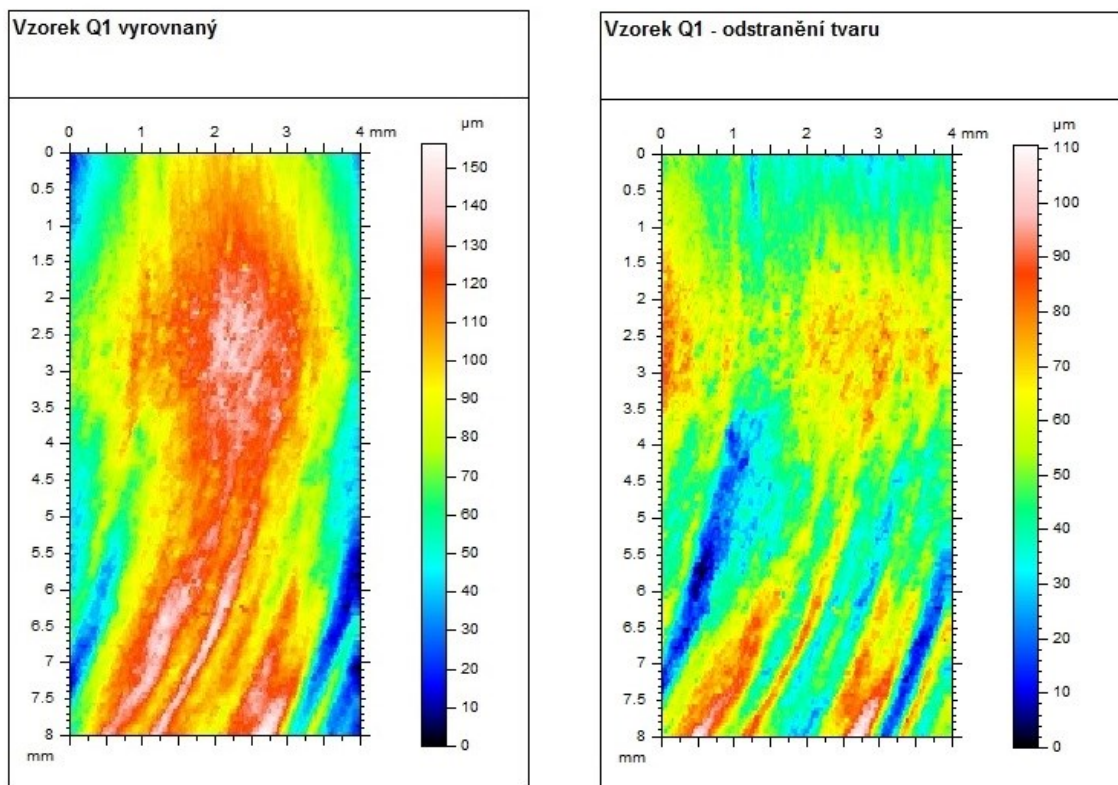
Po přenesení naměřených dat do programu Talymap Gold byl vygenerován 3D scan. Jedná se o barevnou dvourozměrnou plochu s přiřazenou osnovou čísel a barev, kde každá barva vyjadřuje prostorové vychýlení nasnímané plochy. Vzhledem k tomu, že byla měřena válcovitá plocha a nebylo možné při měření zcela přesně nasnímat její nejvyšší vrchol, bylo jako první krok nutné tuto získanou plochu vyrovnat. V tomto případě se prozatím nejednalo o odstranění tvaru a získání roviny pouze s drsností a vlnitostí, nýbrž pouze o docílení toho, že nulový a koncový snímaný bod na ose X budou ve stejné výškové úrovni. Tato operace byla v programu Talymap Gold provedena funkcí „Leveling“.



Obr. 32 – původní 3D scan vzorku Q1 (vlevo) a tentýž 3D scan po vyrovnání (vpravo)


8.3.2 Odstranění tvaru a zobrazení 3D plochy

Po předchozí operaci bylo již možné zobrazit reálný 3D povrch i s jeho válcovitým zakřivením. Právě toto zakřivení neboli tvar povrchu je pro další zpracování a získání potřebných dat nechtěný parametr. Za účelem jeho odstranění byla použita funkce „Form removal“, díky které byla složka tvaru odfiltrována a na nově vzniklém povrchu tak zůstaly jen složky drsnosti a vlnitosti. Rozdíl je dobře patrný na obrázcích níže a také na snížení maximální geometrické odchylky na osnově vedle 3D scanů.




Obr. 33 – srovnání 3D scanu vzorku Q1 po vyrovnání (vlevo) a po odstranění tvaru (vpravo)

Na následujících dvou obrázcích je možné již spatřit charakteristický heterogenní povrch, který je v případě zobrazeného vzorku Q1 nejvíce patrný. Na prvním snímku je zobrazen reálný 3D povrch snímaného vzorku a na následujícím již s odfiltrovaným válcovitým zakřivením.




Obr. 34 – reálný 3D pohled snímaného povrchu vzorku Q1




Obr. 35 – 3D pohled snímaného povrchu vzorku Q1 po odstranění tvaru

8.3.3 Rozklad 3D povrchu na vlnitost a drsnost

Posledním krokem před získáním samotných hodnot charakterizujících snímaný heterogenní povrch bylo potřeba rozložení 3D povrchu pouze na vlnitost a drsnost. Tohoto bylo dosaženo opět v programu Talymap Gold funkcí „Filtering → Waviness + Roughness“. Na obrázcích vlnitosti a drsnosti u vzorku Q1 je opět jasně patrný heterogenní povrch.




Obr. 36 – vlnitost vzorku Q1 v 3D



Obr. 37 – drsnost vzorku Q1 v 3D

8.3.4 Export naměřených hodnot

Závěrem bylo již získání potřebných hodnot charakterizující zkoumaný profil. Toho bylo docíleno sérií kroků, kdy nejprve bylo potřeba vygenerovat diagram zachycující veškeré nerovnosti povrchu o šířce X na celé délce Y po nastavených odstupech 50 μm . Tento diagram zobrazující veškeré nerovnosti byl získán pomocí funkce „Convert into series of profiles“



Obr. 38 – diagram zachycující veškeré nerovnosti povrchu vzorku Q1

Z vytvořeného diagramu bylo již možné získat samotné hodnoty popisující drsnost povrchu dle normy ISO 4287. Toho bylo dosaženo funkcí „Parameters table“. Po tomto kroku vznikla tabulka obsahující veškeré parametry popisující povrch dle normy ISO 4287. V našem případě nás ovšem zajímaly jen určité parametry. Bylo tedy dále potřeba pomocí funkce „Parameter list“ zvolit pouze parametry, které chceme zobrazit.

Vybrané parametry povrchu k dalšímu zpracování:

- Ra průměrná aritmetická úchylka posuzovaného profilu [μm]
- Rz největší výška profilu [μm]
- Rmr materiálový poměr [%]
- Rsm průměrná šířka prvků profilu [μm]


Přesnou charakterizaci a důkladný popis těchto povrchových parametrů je možné nalézt v teoretické části této diplomové práce.

Výsledkem všech dříve popsaných kroků byla tabulka čtyř zvolených parametrů popisující zkoumaný profil po 161 hodnotách u každé veličiny. Taková tabulka byla sestavena pro všechny vzorky Q1 až Q5. Celkově se tedy jednalo o 3220 hodnot. Jistou komplikací a zdržením v práci bylo, že software Talymap Gold neumožňuje výsledky uložit v žádném formátu statistických programů třetích stran. Z tohoto důvodu bylo nutné veškerá získaná data zkopírovat do poznámkového bloku. Ve formátu .txt je přenést na jiný počítač a tam je za velké pozornosti zkopírovat již do vhodného statistického programu, aniž by došlo k záměně hodnot nebo chybě v datech při kopírování. Současně bylo potřeba veškeré desetinné tečky nahradit desetinnou čárkou, protože zvolené statistické programy pro další zpracování jsou optimalizovány pro Evropu a metrický systém. Těmito programy jsou především Minitab 17 Statistical Software pro všestranné statistické operace a program QCExpert pro tvorbu neuronové sítě.

9 ANALÝZA NAMĚŘENÝCH DAT

9.1 Ověření heterogenity povrchu

Při pohledu na nasnímané 3D scany lze konstatovat, že se bez pochyb jedná o heterogenní povrch. Tuto skutečnost však musíme dokázat analýzou dat. Současně můžeme určit, na kolik oblastí se tento heterogenní povrch rozkládá. Touto analýzou se budeme zabývat u vzorku Q1, který má svůj povrch nejvíce heterogenní. Jako první věc je ovšem nutné uvést zde průběh naměřené drsnosti u tohoto vzorku.




Obr. 39 – závislost Ra [µm] na snímané dráze pro vzorek Q1


Na tomto bodovém grafu je patrný značný nárůst hodnot drsnosti Ra na měřené dráze vzorku po ose X v rozmezí 0 - 8 mm. Tohle je samo o sobě dobrým důkazem heterogenního povrchu, nicméně je potřeba zjistit, co vše lze ještě o tomto povrchu konstatovat.

9.1.1 Teorie tří oblastí heterogenního povrchu

Při pohledu na bodový graf si lze všimnout, že se průběh naměřených hodnot pomyslně seskupuje na tři části. Tento aspekt by potvrzoval teorii uvedenou v teoretické části této práce, kde je popisováno, že se mnohé heterogenní povrchy rozdělují na primární, sekundární a terciální oblast. Sekundární oblast lze nazvat jako přechodovou, ale otázkou zůstává, zda je v tomto případě vůbec úvaha teorie tří oblastí správná.

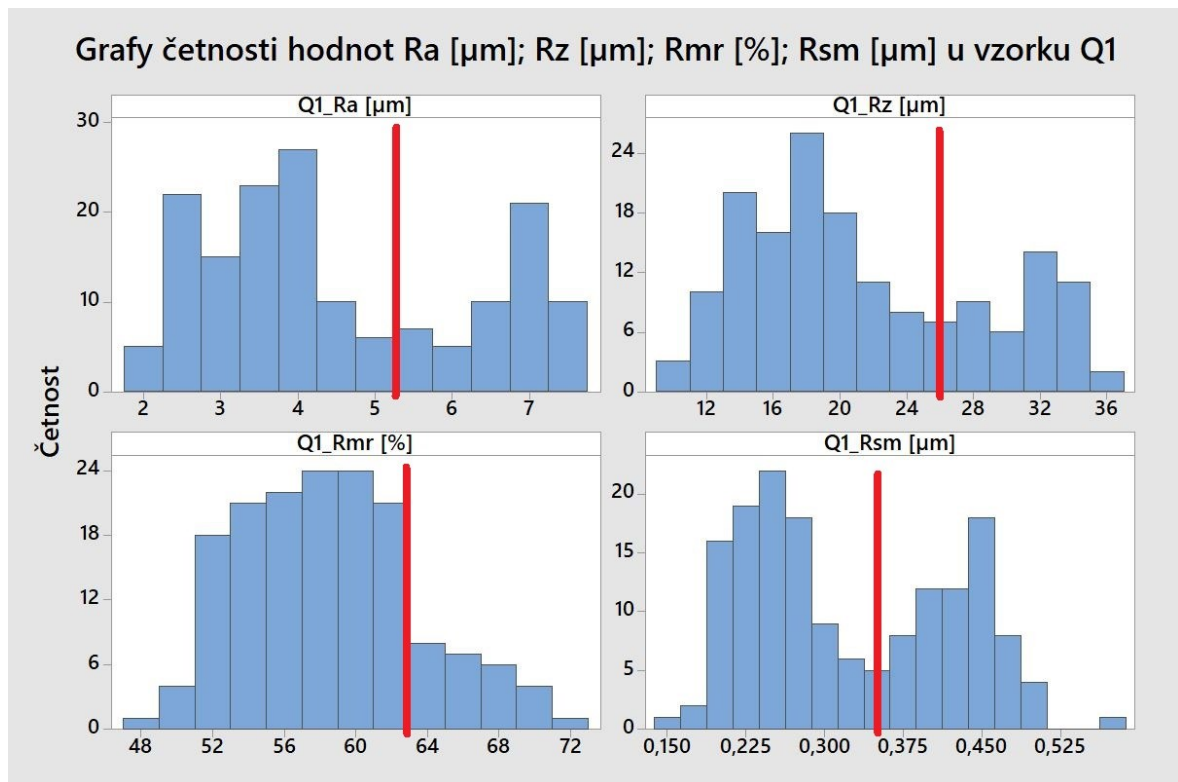


Obr. 40 – závislost Ra [μm] na snímané dráze pro vzorek Q1 s teorií tří oblastí



Obr. 41 – drsnost vzorku Q1 v 3D s teorií tří oblastí


Zdali teorie tří oblastí charakterizuje i náš vzorek Q1 zjistíme velmi snadno. Veškeré čtyři parametry povrchu zpracujeme do sloupcových grafů. Ty nám následně jasně ukážou skutečný počet oblastí na tomto zkoumaném povrchu.



Obr. 42 – grafy četnosti hodnot Ra, Rz, Rmr a Rsm u vzorku Q1

Výsledné grafy doplněné o červené čáry jsou nejdůležitějším důkazem heterogenity povrchu. V první řadě je možné spatřit smíšený výběr obsahující dvě gausovská rozdělení, které jsou odděleny právě přidanou červenou čarou. Přítomnost dvou gausovských rozdělení odporuje vlastnostem homogenního povrchu. Současně lze z počtu těchto gausián určit počet oblastí, na které lze rozdělit zkoumaný heterogenní povrch. V případě parametrů Ra, Rz a obzvláště Rmr je výsledek dobře znám, nicméně není tak patrný jako u parametru Rsm, který tuto teorii zcela potvrzuje. Lze tedy s jistotou říci, že v případě povrchu vzorku Q1 se jedná o charakteristický heterogenní povrch pouze s dvěma oblastmi a to primární (hladkou) a sekundární (drsnu). Přechodová oblast v našem případě není zřetelná. Tímto byla heterogenita vzorku absolutně potvrzena.

Rozdělení na primární a sekundární oblast závislosti parametru Ra na snímané dráze u vzorku Q1 bude dle zjištěných skutečností vypadat přibližně následovně.



Obr. 43 – závislost Ra [μm] na snímané dráze pro vzorek Q1 po rozdělení na primární a sekundární oblast


Vsuvka autora

Plyne z toho jednoduché ponaučení... často se vše na první pohled může jevit jako jasná věc, proto nikdy nedělejme ukvapené závěry.

9.2 Aplikace regresních analýz


Použití regresních analýz zde provedeme především proto, abychom měli v závěru práce s čím porovnat výsledky neuronových sítí. Jako příklad si ponechejme parametr Ra vzorku Q1. Ve všech následujících případech byl nastaven konfidenční interval 95%.

9.2.1 Lineární regrese




Obr. 44 – lineární regrese parametru Ra vzorku Q1

9.2.2 Nelineární regrese kvadratická



Obr. 45 – nelineární kvadratická regrese parametru Ra vzorku Q1

9.2.3 Nelineární regrese kubická



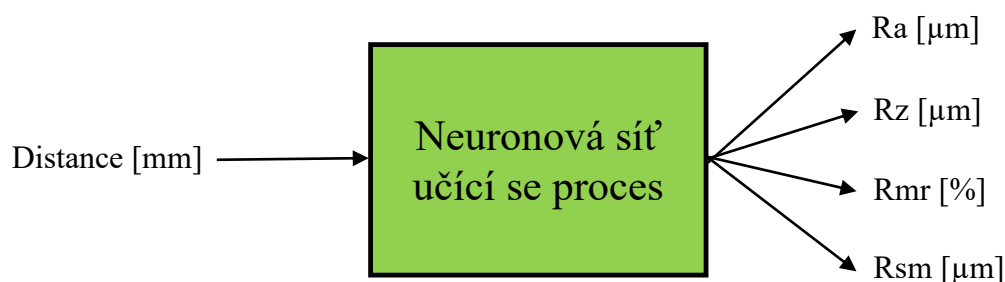
Obr. 46 – nelineární kubická regrese parametru Ra vzorku Q1

9.2.4 Shrnutí výsledků regresních analýz

Jak můžeme vidět, tak u všech tří modelů regresních funkcí je patrné, že nedokáží spolehlivě popsat vývoj zkoumaných dat. Hodnoty R-Sq, které nám popisují vhodnost daného modelu, nevyhází ani s rostoucím polynomem výrazně lépe než v předešlém případě. Je tedy jasně patrné, že regresní analýzy nejsou příliš vhodným nástrojem pro charakterizaci a případnou predikci heterogenních povrchů.


10 NEURONOVÉ SÍTĚ

V této kapitole bude popsán hlavní cíl této diplomové práce, a sice sestavení funkční neuronové sítě na základě naměřených dat. Tato neuronová síť bude sestavena v pokročilém statistickém programu QCExpert. V našem případě se bude ve všech případech jednat o neuronovou síť s jedním vstupem a čtyřmi výstupy, které budou dodány jako soubor dat k naučení. Vstupem je vzdálenost na ose X, která je v souboru dat značena jako „Distance“ [mm], která patří do definičního oboru. Výstupem neuronové sítě jsou predikované výsledky parametrů Ra, Rz, Rmr a Rsm, které se neuronová síť naučila dle reálných dodaných dat.



Obr. 47 – model navržené neuronové sítě

Pro účely predikce těchto čtyř výstupních parametrů povrchu byla navržena neuronová síť ve formě perceptronu o dvou skrytých vrstvách. Počet neuronů v těchto dvou vrstvách byl po několika zkušebních testech zvolen v poměru 7:3. Celá navržená neuronová síť pracuje na principu Rosenblattových perceptronů typu „Back propagation“. Tuto síť lze tedy popsat zkráceně jako BP 1/7/3/4. Jednotlivé čísla vyjadřují počet neuronů v každé vrstvě. Výsledná síť poté bude v případě všech vzorků Q1 až Q5 vypadat následovně.

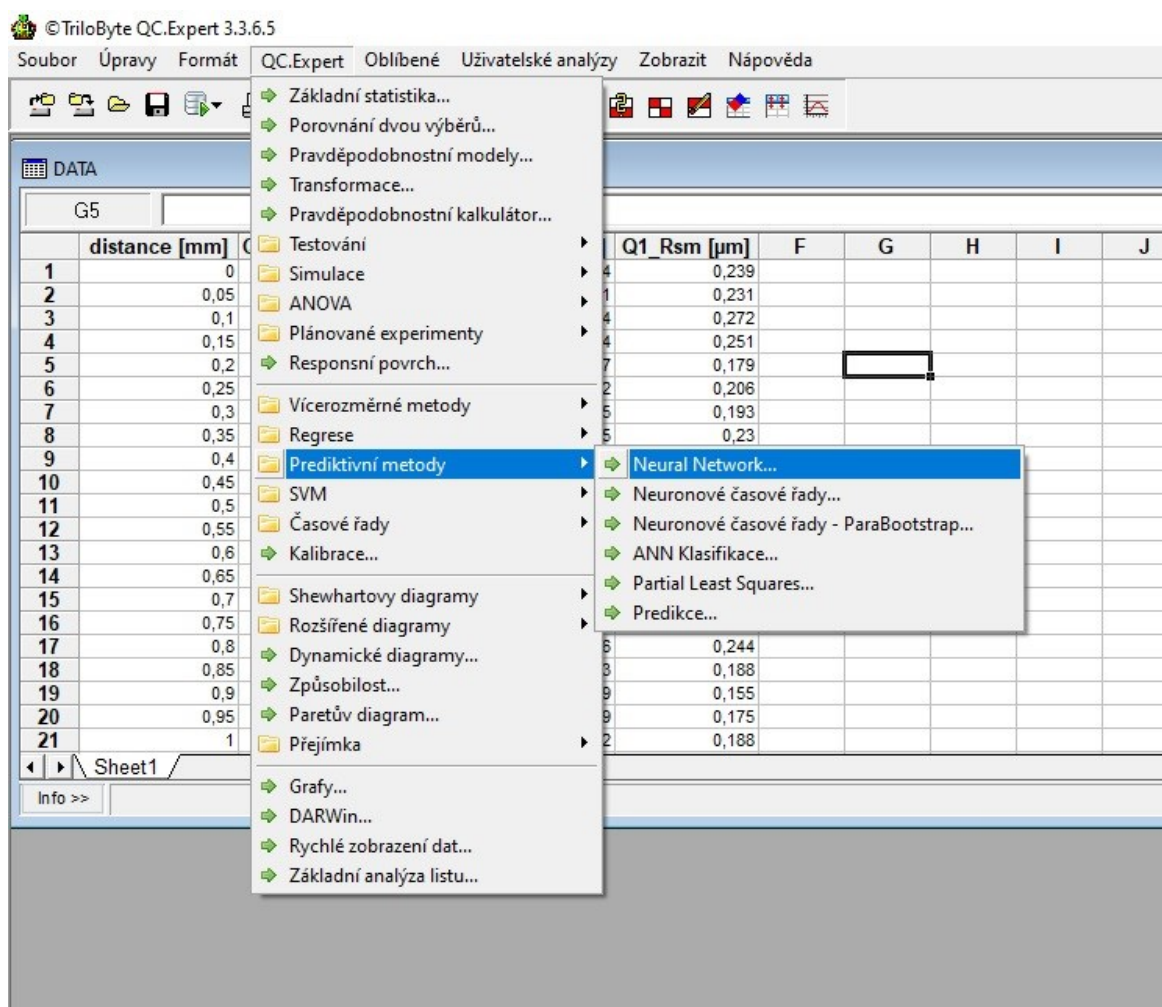


Obr. 48 – navržený perceptron s dvěma skrytými vrstvami

10.1 Sestavení neuronové sítě

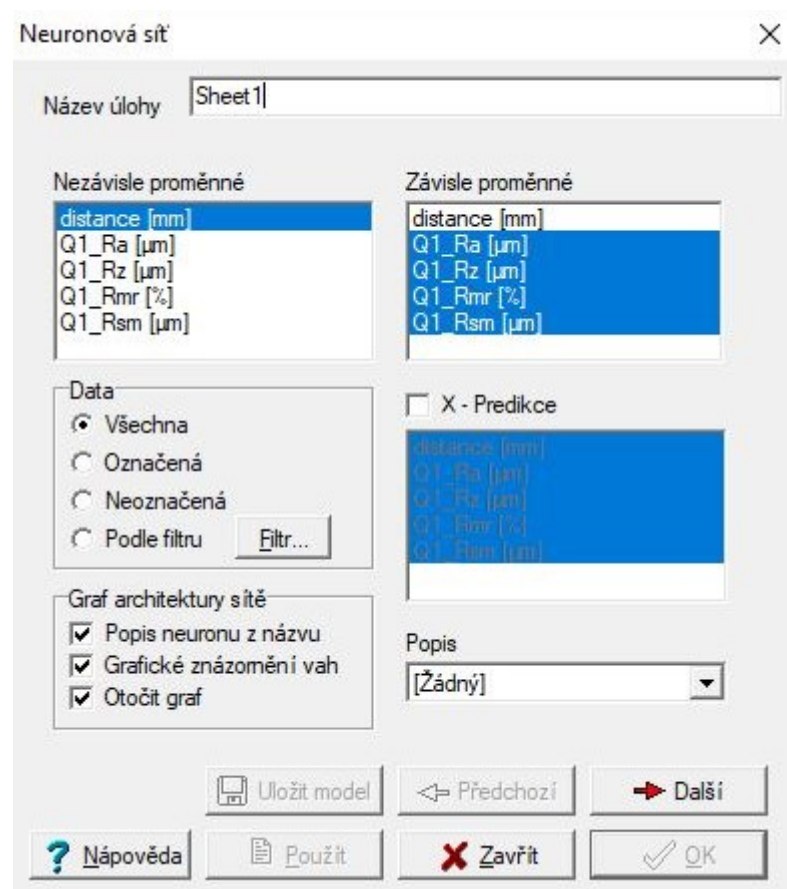
Postup sestavení neuronové sítě bude popsán opět pro vzorek Q1, který má ze všech pěti vzorků nejvíce heterogenní povrch. U zbývajících vzorků byl postup zcela stejný, proto není potřeba ho zde dále popisovat.

Po samotném přenosu a popisu naměřených hodnot do prostředí statistického programu QCExpert verze 3.3.6.5 byl ve složce nástrojů „Prediktivní metody“ vybrán operátor s názvem „Neural Network“.



Obr. 49 – výběr typu prediktivní metody

Po předchozím kroku se v prostředí programu spustilo nové okno pro nastavení parametrů neuronové sítě. V této fázi bylo potřeba z dosazených dat vybrat závislé a nezávislé proměnné. Nezávislou proměnnou byla v našem případě měřená vzdálenost na ose X značená v souboru dat jako „Distance [mm]“. Závislou proměnnou jsou poté všechny čtyři parametry drsnosti zkoumaného povrchu vzorku Q1. U oddílu „Graf architektury sítě“ byly označeny všechny tři možnosti jako žádoucí. Zbývající možnosti v tomto okně zůstaly beze změny, proto bylo možné přejít na další fázi.



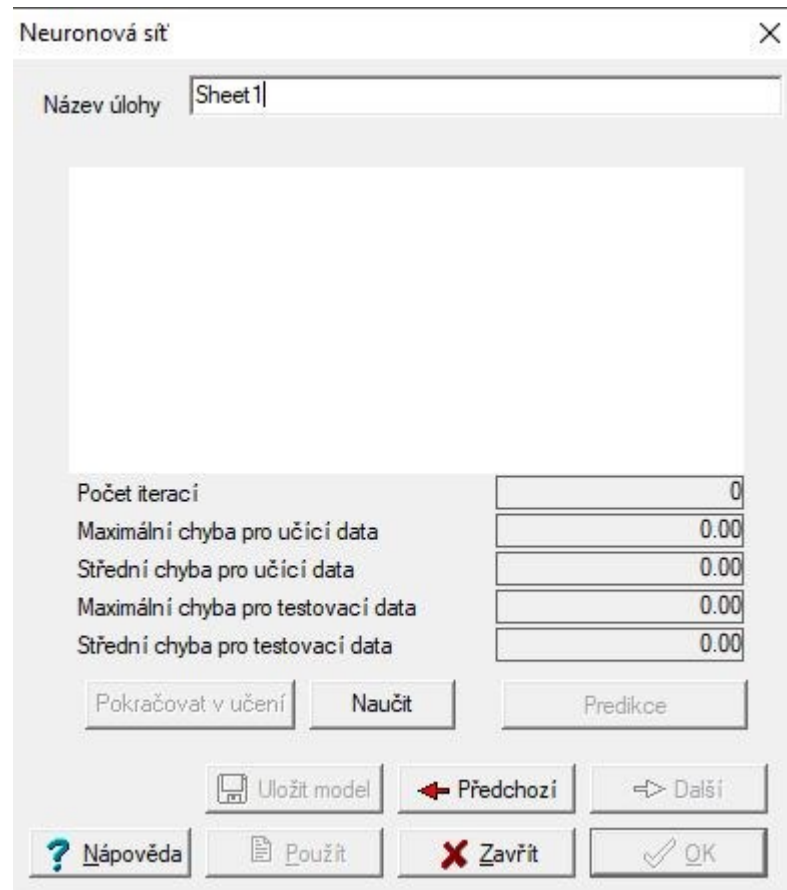
Obr. 50 – nastavení neuronové sítě – fáze 1

Následující fáze nastavení neuronové sítě lze považovat za nejdůležitější. Jako první věc je potřeba si určit počet skrytých vrstev a počet neuronů v těchto vrstvách. Jak bylo dříve uvedeno, tak počet vrstev byl stanoven na dvě a po mnoha zkušebních testech byl počet neuronů ve skrytých vrstvách zvolen v poměru 7:3, tedy v první skryté vrstvě sedm a ve druhé tři. Dalším důležitým polem v tomto okně bylo nastavení počtu iterací neboli počet opakování učícího se procesu. Vzhledem k požadavkům na vysokou přesnost a dostatek času na analyzování byl počet iterací zvolen na 10000. Posledním nastaveným parametrem bylo pole s popisem „Dat pro učení“, do kterého byla nastavena hodnota 70 %. Tuto hodnotu jsme zvolili na základě doporučení expertů na umělou inteligenci ze zdrojů odborné literatury. Jde především o to, že náš soubor dat je v případě navrhované sítě současně učícím i kontrolním výběrem. Je tedy nezbytně nutné, aby pro učení a pro kontrolu bylo využito vždy náhodných 70 % hodnot z dodaného výběrového souboru a byly tak oba výběry nepochybně odlišné. Zbývající možnosti v tomto okně zůstaly opět beze změny.

Počet neuronů ve skrytých vrstvách	
Vrstva	Neuronů
1	7
2	3

Obr. 51 – nastavení neuronové sítě – fáze 2

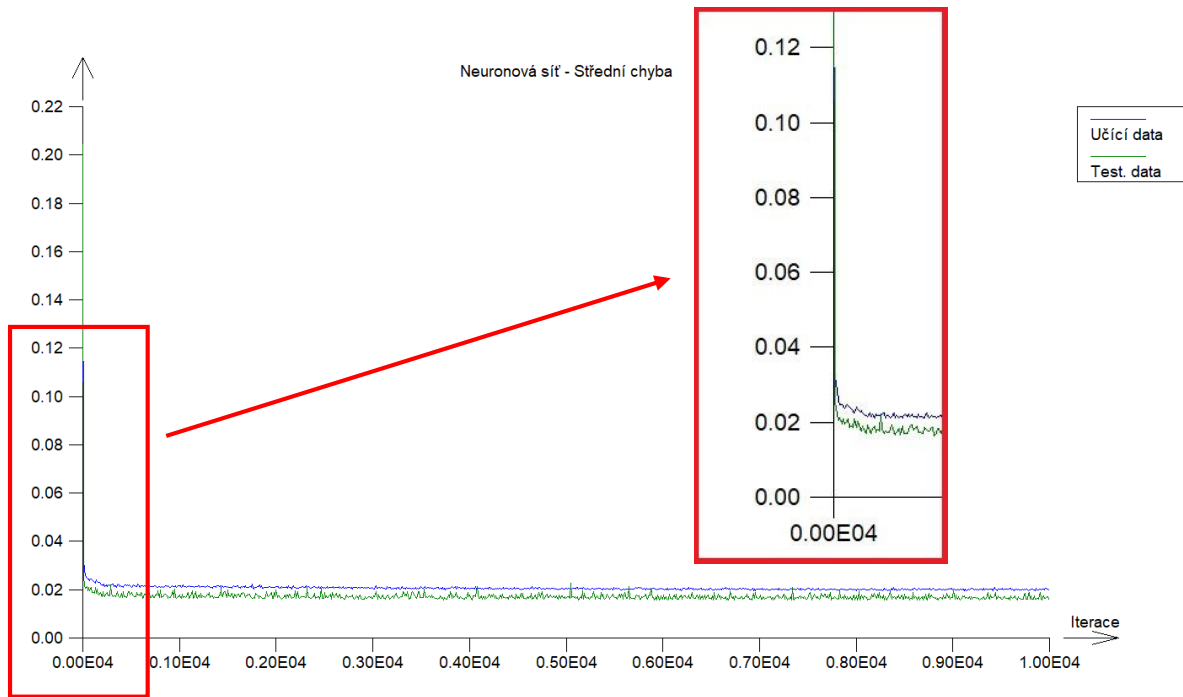
V poslední fázi se spouští samotný proces učení sestavené neuronové sítě. V tomto okně stačí zvolit možnost „Naučit“. V našem případě celý proces trval přibližně 30 sekund.



Obr. 52 – nastavení neuronové sítě – fáze 3

V bílém poli výše vyobrazeného okna během učení sítě vynikaly dvě křivky. Výsledný graf zachycuje vývoj střední chyby s rostoucím počtem iterací. Důkazem, že se navržená neuronová síť pracuje správně a něčemu se naučila je, že na začátku průběhu grafu je možné spatřit velké snížení střední chyby. V případě, kdy by tento průběh vyšel beze změn, tak by to znamenalo, že se síť vůbec ničemu nenaučila a ještě horším případem by bylo, když by střední chyba naopak rostla. V takové situaci by neuronová síť nepracovala vůbec správně a její výsledky by nebylo nijak dále používat.

Hodnoty na pěti řádcích pod bílým polem se během učení sítě neustále měnily s rostoucím počtem iterací. Jejich finální výsledek je vynesena v tabulce číslo 2 níže.



Obr. 53 – průběh střední chyby při učení neuronové sítě pro vzorek Q1

Tabulka 2 – výsledky chyb po naučení neuronové sítě

Počet iterací	10000
Maximální chyba pro učící data	0,1000412086
Střední chyba pro učící data	0,01988650797
Maximální chyba pro testovací data	0,08451821037
Střední chyba pro testovací data	0,01639380265

V protokolu programu QCExpert se po naučení neuronové sítě lze dozvědět, zda byl navržený model významný či nikoli. Ve všech případech našich pěti vzorků byl model významný a p-hodnota byla rovna nule. To znamená, že vytvořená neuronová síť je smysluplná a lze tak výsledek označit za zdárný.

p-hodnota : 0
 Model je významný

Obr. 54 – důkaz významnosti modelu z protokolu programu QCExpert po sestavení a naučení neuronové sítě

Z protokolu po sestavení neuronové sítě můžeme ještě získat kompletní tabulku vah mezi jednotlivými vrstvami a neurony. Tyto hodnoty mohou být využity pro další zpracování.

Tabulka 3 – váhy mezi vrstvami a neurony perceptronu pro vzorek Q1

Vrstva/neuron	1. Váha	2. Váha	3. Váha	4. Váha	5. Váha	6. Váha	7. Váha	bias
2/1	-1,417401622							-2,8771062440
2/2	10,336744200							-7,4127256200
2/3	16,220691750							-0,4469842343
2/4	-11,060949170							-2,2765916110
2/5	15,635296900							12,3136661100
2/6	4,857608346							-5,4524275180
2/7	-18,399033590							2,5622415860
3/1	-1,067762831	6,203155954	7,769503296	-2,41978147	-2,265464490	2,644182520	-10,485435500	-5,9102790680
3/2	0,278990109	-2,622715009	-3,380137488	6,89331686	-12,314752890	-4,790818068	4,053402628	0,1380092597
3/3	0,285868000	-2,145183713	-11,174094920	1,36765837	-1,931580356	-4,119688442	7,386439177	-2,9868877650
4/1	2,946423208	-1,849390882	-0,129695691					-0,7820004043
4/2	2,612599791	-1,605736035	0,140702561					-0,8004991130
4/3	-1,054442297	1,568158608	0,013882645					-0,2607755809
4/4	0,972918488	-0,477276446	-1,092745233					-0,1338683630

10.2 Predikce neuronové sítě

Po dokončení učení neuronové sítě bylo v okně na obrázku 52 možné zvolit pole s nápisem „Predikce“. Po tomto kroku se nám otevřelo okno, kam bylo možné zadávat hodnotu parametru „Distance“ a následně na základě této hodnoty spočítat predikované výsledky neuronovou sítí pro parametry Ra, Rz, Rmr a Rsm pro vzorek Q1. Tyto hodnoty jsou již výsledkem učení neuronové sítě a nejedná se o pouhou interpretaci skutečných naměřených dat.

Neuronová síť - predikce

Nezávisle proměnné		Závisle proměnné	
Proměnná	Hodnota	Proměnná	Hodnota
Distance [mm]	4,5	Q1_Ra [μm]	3,87343614901
		Q1_Rz [μm]	18,06038466466
		Q1_Rmr [%]	56,99287293546
		Q1_Rsm [μm]	0,363426296705

Spočítat

Řádek:

Popis:

Spočítat při posunu

Zavřít

Obr. 55 – predikce závislých proměnných neuronovou sítí

V této fázi bylo již možné získat data pro porovnání s reálnými daty a s regresními funkcemi. Z důvodu, že bylo nutné všechna predikovaná data z programu QCExpert ručně přepisovat, bylo rozhodnuto, že porovnání výsledků bude provedeno pro osm hodnot nezávislé proměnné „Distance“. Tyto hodnoty jsou v rozmezí 1 až 8 mm odstupňované po jednom milimetru. Predikované výsledky jsou zapisovány s označením „N“ za konkrétním značením daného parametru. Je tak patrné, že jejich zdrojem je predikce neuronové sítě.

Tabulka 4 – predikované výsledky parametrů povrchu vzorku Q1

Distance [mm]	Q1_Ra_N [μm]	Q1_Rz_N [μm]	Q1_Rmr_N [%]	Q1_Rsm_N [μm]
1	2,433	12,827	66,210	0,220
2	3,286	17,086	60,113	0,243
3	3,656	18,677	58,361	0,251
4	3,833	18,184	58,106	0,337
5	4,397	20,252	57,232	0,361
6	6,076	26,989	54,858	0,403
7	7,104	31,704	52,936	0,439
8	7,145	31,914	52,828	0,442


10.3 Porovnání výsledků neuronové sítě s reálnými hodnotami

V následujících tabulkách a grafech je možné spatřit porovnání hodnot predikovaných sestavenou neuronovou sítí a reálných naměřených dat vzorku Q1. Pro lepší přehled byly tabulky doplněny o rozdíl mezi těmito hodnotami v číselném i procentuálním vyjádření.

Tabulka 5 – porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q1

Distance [mm]	Q1_Ra [μm]	Q1_Ra_N [μm]	diference [μm]	odchylka [%]
1	2,219	2,433	0,214	9,64
2	3,530	3,286	0,244	6,91
3	3,874	3,656	0,218	5,63
4	3,975	3,833	0,142	3,57
5	4,301	4,397	0,096	2,23
6	6,575	6,076	0,499	7,59
7	6,926	7,104	0,178	2,57
8	7,604	7,145	0,459	6,04

Průměrná procentuální odchylka v případě porovnání parametru Ra vychází 5,52 %.




Obr. 56 – porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q1

Tabulka 6 – porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q1

Distance [mm]	Q1_Rz [μm]	Q1_Rz_N [μm]	diference [μm]	odchylka [%]
1	10,973	12,827	1,854	16,90
2	18,772	17,086	1,686	8,98
3	23,198	18,677	4,521	19,49
4	17,818	18,184	0,366	2,05
5	21,345	20,252	1,093	5,12
6	28,156	26,989	1,167	4,14
7	29,351	31,704	2,353	8,02
8	31,678	31,914	0,236	0,74

Průměrná procentuální odchylka v případě porovnání parametru Rz vychází 8,18 %.




Obr. 57 – porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q1

Tabulka 7 – porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q1

Distance [mm]	Q1_Rmr [%]	Q1_Rmr_N [%]	diference [%]	odchylka [%]
1	65,512	66,210	0,698	1,07
2	59,006	60,113	1,107	1,88
3	60,285	58,361	1,924	3,19
4	57,178	58,106	0,928	1,62
5	58,91	57,232	1,678	2,85
6	58,016	54,858	3,158	5,44
7	54,037	52,936	1,101	2,04
8	49,068	52,828	3,76	7,66

Průměrná procentuální odchylka v případě porovnání parametru Rmr vychází 3,22 %.




Obr. 58 – porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q1

Tabulka 8 – porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q1

Distance [mm]	Q1_Rsm [μm]	Q1_Rsm_N [μm]	diference [μm]	odchylka [%]
1	0,188	0,220	0,032	17,02
2	0,248	0,243	0,005	2,02
3	0,255	0,251	0,004	1,57
4	0,264	0,337	0,073	27,65
5	0,304	0,361	0,057	18,75
6	0,402	0,403	0,001	0,25
7	0,484	0,439	0,045	9,30
8	0,566	0,442	0,124	21,91

Průměrná procentuální odchylka v případě porovnání parametru Rsm vychází 12,31 %.



Obr. 59 – porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q1

Z vynesných tabulek a grafů je patrné, že sestavený model neuronové sítě poměrně přesně popisuje reálná naměřená data. V případech parametrů Ra, Rz a Rmr vzorku Q1 průměrná odchylka srovnávaných hodnot nepřekročila 10 %, což je velmi zdařilý výsledek. U parametru Rsm byl tento výsledek nepatrně horší, nicméně stále přijatelný.

10.4 Porovnání výsledků neuronové sítě s regresní analýzou

V této části práce bude dokázáno, že regresní analýzy i vyšších polynomů selhávají při aplikaci na data heterogenit. Pro porovnání bude použita regresní rovnice, která měla dle dříve vynesných grafů nejvyšší přesnost při aplikaci na parametr Ra pro vzorek Q1. V tomto případě se jedná o nelineární regresi kubickou popsanou následující rovnicí.

$$Ra_{Q1} = 2,679 - 0,1067 \times \text{Dist} + 0,1516 \times \text{Dist}^2 - 0,007359 \times \text{Dist}^3 \text{ [}\mu\text{m]} \quad (11)$$

Na základě této rovnice byly spočítány hodnoty pro osm kontrolních hodnot nezávislé proměnné „Distance“ a byly stejně jako výsledky neuronové sítě porovnány s reálnými hodnotami. Výsledky regresní funkce jsou v tabulce zapsány s přidáním označením „R3“.

Tabulka 9 – porovnání výsledků regresní funkce a reálných hodnot Ra vzorku Q1

Distance [mm]	Q1_Ra [μm]	Q1_Ra_R3 [μm]	diference [μm]	odchylka [%]
1	2,717	2,504	0,213	7,82
2	3,013	3,185	0,172	5,70
3	3,525	3,866	0,341	9,68
4	4,207	4,547	0,340	8,08
5	5,016	5,228	0,212	4,23
6	5,907	5,909	0,002	0,03
7	6,837	6,590	0,247	3,61
8	7,761	7,271	0,490	6,31


Průměrná odchylka parametru Ra vzorku Q1 v případě regresní funkce vychází 5,69 %.

Tabulka 10 – porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q1

Distance [mm]	Q1_Ra [μm]	Q1_Ra_N [μm]	diference [μm]	odchylka [%]
1	2,219	2,433	0,214	9,64
2	3,530	3,286	0,244	6,91
3	3,874	3,656	0,218	5,63
4	3,975	3,833	0,142	3,57
5	4,301	4,397	0,096	2,23
6	6,575	6,076	0,499	7,59
7	6,926	7,104	0,178	2,57
8	7,604	7,145	0,459	6,04

Průměrná odchylka parametru Ra vzorku Q1 v případě neuronové sítě vychází 5,52 %.

Při pohledu na průměrné odchylky obou metod by se dalo říci, že se metody příliš neliší, nicméně opak je pravdou a důkazem toho bude následující graf, kde je možné spatřit průběh hodnot reálného povrchu, výsledky neuronové sítě a výsledky regresní analýzy.



Obr. 60 – srovnání naměřených dat a výsledků neuronové sítě a regresní analýzy parametru Ra vzorku Q1

Výše vynesení graf je nesporným důkazem o selhání regresních analýz v případě hodnocení heterogenních povrchů. Je zcela patrné, že průběh hodnot predikovaných neuronovou sítí téměř koresponduje s průběhem naměřených hodnot skutečného povrchu. Naproti tomu křivka vzniklá dosazením do regresní rovnice má významně odlišný průběh od tvaru zkoumané heterogenity.

10.5 Zhodnocení všech výsledků

Kompletní postup pro sestavení neuronové sítě pro vzorek Q1 byl za stejných podmínek použit rovněž u zbývajících vzorků Q2 až Q5. U těchto vzorků se s jejich rostoucím číslem označením postupně snižuje heterogenita povrchu až do téměř homogenního v případě vzorku Q5. Níže je možné spatřit tabulku s porovnáním průměrných procentuálních odchylek predikovaných parametrů povrchu neuronovou sítí.

Tabulka 11 – přehled průměrných procentuálních odchylek parametrů povrchu predikovaných neuronovou sítí v porovnání s reálnými daty pro vzorky Q1 až Q5

	odchylka Ra [%]	odchylka Rz [%]	odchylka Rmr [%]	odchylka Rsm [%]
Q1	5,52	8,18	3,22	12,31
Q2	8,24	10,79	3,70	19,91
Q3	8,38	11,99	3,45	11,33
Q4	4,36	8,06	3,19	21,79
Q5	7,02	8,81	4,12	6,20

Z tabulky je dobře patrné, že navržená neuronová síť fungovala dobře pro vzorky Q1 a Q5, kdy první z nich je zcela bez pochyb silně heterogenní a druhý v podstatě téměř homogenní povrch. Lze tedy usoudit, že pro vzorky Q2, Q3 a Q4, které se svými vlastnostmi povrchu nachází mezi těmito dvěma rozdílnými povrchy, by bylo vhodné navrhnout jinou neuronovou síť a především udělat důkladný výzkum, který by rozhodoval o tom, co lze ještě považovat za heterogenitu a co už nikoli.

Navržená neuronová síť přinesla velmi uspokojivé výsledky, nicméně je patrné, že její správná funkce je nejlepší jen u značné a naopak u zanedbatelné heterogenity. Nicméně ve všech případech nepřekročila hodnota průměrné procentuální odchylky hodnotu 10% v případě predikce parametru Ra, což je velmi dobrý výsledek.

ZÁVĚR

Po veškerých přípravách, laboratorním měření a extrakci naměřených hodnot bylo v této práci úspěšně dosaženo sestavení neuronové sítě, která dokáže na základě vstupního parametru predikovat výslednou drsnost heterogenního povrchu. V tomto případě byly výsledky u vzorku Q1 více než uspokojivé. Zbývající vzorky se postupně více přibližují homogennímu povrchu, kdy vzorek Q5 už téměř ani nelze nazvat heterogenním. I proto jsou výsledky vzorků Q2, Q3 a Q4 méně zdařilé než v případě vzorku Q1, u kterého byla nepochybnitelně dokázána heterogenita a na kterém bylo dokázáno selhání regresních funkcí při jejich aplikaci na tento datový výběr. Kompletní výsledky vzorků Q2 až Q5 a jejich je možné najít v přílohách této diplomové práce.

Učení neuronových sítí je bez pochyb fascinujícím statistickým nástrojem. Při komplexnějším výzkumu na toto téma by mohla být výsledkem neuronová síť pracující s několika vstupními parametry jako například druh materiálu, jeho tloušťka, řezná rychlost, pracovní tlak, druh abrazivního materiálu nebo průměr výstupní trysky abrazivního paprsku. Všechny tyto parametry by poté sofistikovaná neuronová síť dokázala zpracovat na výstupní hodnoty parametrů vzniklého povrchu. Takový operátor by dokázal uspořit mnoho času a výdajů spojených s optimálním nastavením pracovního stoje a dosažení nejefektivnější výroby. Tímto směrem by podobný výzkum šel posouvat dále, nicméně rozsah tohoto díla by byl několikanásobně objemnější a náročnější.

SEZNAM POUŽITÉ LITERATURY

- [1] BUMBÁLEK, Bohumil, Vladimír ODVODY a Bohuslav OŠŤÁDAL. Drsnost povrchu. 1. vyd. Praha: SNTL, 1989, 338 s
- [2] 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
- [3] 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
- [4] 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
- [5] WHITEHOUSE, David. *Surfaces and their Measurement*. Hermes Penton Science. [2002] 425 s. ISBN 1 9039 9601 5
- [6] NOVÁK, Zdeněk. *Zvyšování kvality hodnocení struktury povrchu*. In: MM Průmyslové spektrum [online]. 2004 [cit. 2021-03-22]. Dostupné z: <https://www.mmspektrum.com/clanek/zvysovani-kvality-hodnoceni-struktury-povrchu>
- [7] NOVÁK, Zdeněk. *Zvýšení kvality hodnocení textury povrchu*. In: MM Průmyslové spektrum [online]. 2011 [cit. 2021-03-22]. Dostupné z: <https://www.mmspektrum.com/clanek/zvyseni-kvality-hodnoceni-textury-povrchu>
- [8] TYKAL, Miroslav. *Normalizace struktury povrchu, současný stav a trendy vývoje*. In: Kvalita a Geometrické specifikace produktů [online]. 2005 [cit. 2021-03-22]. Dostupné z: http://gps.fime.vutbr.cz/STAH_INFO/41_Tykal_TNK7.pdf
- [9] ING. KUBIŠOVÁ, Milena. *Hodnocení jakosti povrchu polymerních dílů nenormativním způsobem*. Zlín, 2018. Dizertační práce. UTB.
- [10] PEŠIČKA, Ladislav, *Geometrická specifikace výrobků strojírenské výroby (GPS)*. Praha: ČNI, 2006. 49 s.

- [11] MAŇKOVÁ, Ildikó. *Progresívne technológie*. Košice: Viena, 2000. Edícia vedeckej a odbornej literatúry. ISBN 80-7099-430-4
- [12] MORÁVEK, Rudolf. *Nekonvenční metody obrábění*. 2. vydání. Plzeň: Západočeská univerzita Plzeň, 1999. 102 s. ISBN 80-7082-518-9
- [13] KUMAR, Manish. *Controlled high pressure slurry injection in water jetting applications-a new approach*. *LSU Master's Theses*. [online]. 2005 [cit. 2021-03-23]. Dostupné z: https://digitalcommons.lsu.edu/gradschool_theses/1676
- [14] MARCEL KOLB. *Waterjet cutting: material processing with a high-pressure waterjet*. München: Moderne industrie, 2006. ISBN 39-378-8954-X.
- [15] SITEK, Libor; FOLDYNA, Josef; ŠVEHLA, Bronislav. *Vodní paprsek ve strojírenství*. *Strojárstvo-strojírenství*, 2004. ISSN 1335-2938
- [16] In-process generation of water ice particles for cutting and cleaning purposes. *Water jetting 20* [online]. 2010. [cit. 2021-03-23]. Dostupné z: <http://e-collection.library.ethz.ch/eserv/eth:2018/eth-2018-01.pdf>
- [17] JAGADISH, Kapil Gupta. *Abrasive Water Jet Machining of Engineering Materials*. Springer International Publishing. 2020, 77 s. ISBN 978-3-030-36001-6
- [18] ZETKOVA, Ivana; JENICEK, Stepan; HRONEK, Ondrej; KOTESOVEC, Vratislav; VRTACEK, Jiri & ZETEK, Miroslav (2018). Influences of Cutting Process Parameters on the Cutting Quality when Water Jet Cutting, Proceedings of the 29th DAAAM International Symposium, pp. 1286-1292, B. Katalinic (Ed.), Published by DAAAM International, ISBN 978-3-902734-20-4, ISSN 1726-9679, Vienna, Austria
- [19] 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
- [20] StatSoft CR s.r.o. *Úvod do neuronových sítí*. [online]. 2013 [cit. 2021-03-23]. Dostupné z: http://www.statsoft.cz/file1/PDF/newsletter/2013_02_05_StatSoft_Neuronove_site_linky.pdf
- [21] BERKA, Petr. *Neuronové sítě*. [online]. [cit. 2021-03 23]. Dostupné z: https://sorry.vse.cz/~berka/docs/izi456/kap_5.4.pdf

- [22] SMITH, Graham T. *Industrial Metrology: Surface and Roundness*. Springer-Verlag London, [2002]. 336 s. ISBN 1852335076 978-1-85233-507-6
- [23] 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
- [24] GRAUPE, Daniel. *Principles of Artificial Neural Networks (2nd Edition)*. University of Illinois, Chicago, USA. 2007, 320 s. ISBN-13 978-981-270-624-9
- [25] MELOUN, Milan a Jiří MILITKÝ. *Kompendium statistického zpracování dat*. Vyd. 3. Praha: Karolinum, 2012. ISBN 978-80-246-2196-8
- [26] MELOUN, Milan a Jiří MILITKÝ. *Statistická analýza experimentálních dat*. Vyd. 2., upr. a rozš. Praha: Academia, 2004. ISBN 80-200-1254-0
- [27] PAOLELLA, Marc S. *Linear Models and Time-Series Analysis: Regression, ANOVA, ARMA and GARCH*. Wiley Series in Probability and Statistics. 2018, 897s. ISBN 9781119431855
- [28] HARRELL, Frank E. jr. *Regression Modeling Strategies: With Applications to Linear Models, Logistic and Ordinal Regression, and Survival Analysis*. Springer International Publishing. 2015, 598s. ISBN 978-3-319-19425-7
- [29] TAYLOR-HOBSON. *Talysurf CLI 500 Operator's Handbook*. 2005, 176 s
- [30] LUMEN LEARNING, *Linear Regression (2 of 4)* [online]. [cit. 2021-03 29]. Dostupné z: <https://courses.lumenlearning.com/wm-concepts/statistics/chapter/linear-regression-2-of-4/>

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

ISO	International Organization for Standardization - Mezinárodní organizace pro normalizaci
GPS	Geometrical Product Specifications – Geometrické požadavky na výrobky
2D	dvourozměrné zobrazení
3D	trojrozměrné zobrazení
Z _p	nejvyššího výstupku profilu
Z _v	nejnižší prohlubně profilu
Z _t	průměrná hodnota výšek prvků profilu v rozsahu základní délky
X _s	šířka prvků profilu
R _p	největší výška výstupku profilu
R _v	největší hloubka prohlubně profilu
R _z	největší výška profilu
R _t	celková výška profilu
R _c	průměrná výška prvků profilu
R _a	průměrná aritmetická úchylka posuzovaného profilu
R _q	průměrná kvadratická úchylka posuzovaného profilu
R _{sk}	šikmost posuzovaného profilu
R _{ku}	špičatost posuzovaného profilu
R _{sm}	průměrná šířka prvků profilu
R _{mr}	materiálový poměr
VKP	obrábění vysokoenergetickým kapalinovým paprskem
AJM	Abrasive Jet Machining
AFM	Abrasive Flow Machining
y	závislá proměnná u lineární regrese
x	nezávislá proměnná (prediktor) u lineární regrese

β_0, β_1	regresní koeficienty
f	přenosová funkce u neuronových sítí
n	počet vstupů
x_i	hodnota i -tého vstupu
w_i	váha příslušná i -tému vstupu
θ	prahová hodnota
BP	Back propagation – zpětné učení
R-Sq	parametr popisující vhodnost modelu regresní analýzy

SEZNAM OBRÁZKŮ

Obr. 1 – Řez povrchem obsahující všechny složky struktury povrchu [5].....	12
Obr. 2 – Tvar povrchu po odfiltrování drsnosti a vlnitosti [5]	12
Obr. 3 – Vlnitost povrchu [5].....	12
Obr. 4 – Drsnost povrchu [5]	13
Obr. 5 – definice střední čáry profilu [5]	15
Obr. 6 – Definice parametru Rz [5]	16
Obr. 7 – průměrná výška prvků profilu [2].....	16
Obr. 8 – aritmetická úchylka profilu Ra [5].....	17
Obr. 9 – různé hodnoty Ra v závislosti na zvolené technologii obrábění [5].....	17
Obr. 10 – průměrná šířka Rsm [5]	18
Obr. 11 – materiálový poměr délek vůči celkové délce profilu [5].....	19
Obr. 12 – princip vzniku Abbot-Firestonovy křivky [22]	20
Obr. 13 – schéma principu vzniku vodního paprsku [13].....	22
Obr. 14 – přehled typů vodních paprsků [14].....	23
Obr. 15 – princip vzniku abrazivního vodního paprsku [14].....	25
Obr. 16 - princip vzniku abrazivního suspenzního paprsku [14].....	26
Obr. 17 – stupně kvality řezu vodním paprskem [18]	27
Obr. 18 – členění obrobeného povrchu na jednotlivé zóny [19]	28
Obr. 19 – struktura profilových čar v oblastech heterogenního povrchu [19].....	29
Obr. 20 – graf lineární regrese	31
Obr. 21 – dva bodové grafy znázorňující metodu nejmenších čtverců [30].....	31
Obr. 22 – graf kvadratické nelineární regrese.....	32
Obr. 23 – graf kubické nelineární regrese.....	33
Obr. 24 – model neuronu [20]	35
Obr. 25 – perceptron (neuronová síť) s jednou skrytou vrstvou [19].....	36
Obr. 26 – vzorky Q1 až Q5	40
Obr. 27 – srovnání jakosti povrchu vzorků Q1 (vpravo) a Q5 (vlevo).....	41
Obr. 28 – vzorek Q5 po provedení řezu.....	41
Obr. 29 – bezkontaktní drsnoměr Taylor Hobson Talysurf CLI 500	42
Obr. 30 – přehled nastavených parametrů měření v programu k přístroji.....	43
Obr. 31 – připravený vzorek na měření a jeho souřadnicový systém.....	44
Obr. 32 – původní 3D scan vzorku Q1 (vlevo) a tentýž 3D scan po vyrovnaní (vpravo) ..	45
Obr. 33 – srovnání 3D scanu vzorku Q1 po vyrovnaní (vlevo) a po odstranění tvaru (vpravo)	46

Obr. 34 – reálný 3D pohled snímaného povrchu vzorku Q1	47
Obr. 35 – 3D pohled snímaného povrchu vzorku Q1 po odstranění tvaru	47
Obr. 36 – vlnitost vzorku Q1 v 3D	48
Obr. 37 – drsnost vzorku Q1 v 3D.....	48
Obr. 38 – diagram zachycující veškeré nerovnosti povrchu vzorku Q1	49
Obr. 39 – závislost Ra [μm] na snímané dráze pro vzorek Q1	51
Obr. 40 – závislost Ra [μm] na snímané dráze pro vzorek Q1 s teorií tří oblastí.....	52
Obr. 41 – drsnost vzorku Q1 v 3D s teorií tří oblastí.....	52
Obr. 42 – grafy četnosti hodnot Ra, Rz, Rmr a Rsm u vzorku Q1	53
Obr. 43 – závislost Ra [μm] na snímané dráze pro vzorek Q1 po rozdělení na primární a sekundární oblast	54
Obr. 44 – lineární regrese parametru Ra vzorku Q1	55
Obr. 45 – nelineární kvadratická regrese parametru Ra vzorku Q1	55
Obr. 46 – nelineární kubická regrese parametru Ra vzorku Q1	56
Obr. 47 – model navržené neuronové sítě	57
Obr. 48 – navržený perceptron s dvěma skrytými vrstvami	57
Obr. 49 – výběr typu prediktivní metody	58
Obr. 50 – nastavení neuronové sítě – fáze 1	59
Obr. 51 – nastavení neuronové sítě – fáze 2	60
Obr. 52 – nastavení neuronové sítě – fáze 3	61
Obr. 53 – průběh střední chyby při učení neuronové sítě pro vzorek Q1	62
Obr. 54 – důkaz významnosti modelu z protokolu programu QCExpert po sestavení a naučení neuronové sítě.....	62
Obr. 55 – predikce závislých proměnných neuronovou sítí	64
Obr. 56 – porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q1	65
Obr. 57 – porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q1	66
Obr. 58 – porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q1	67
Obr. 59 – porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q1	68
Obr. 60 – srovnání naměřených dat a výsledků neuronové sítě a regresní analýzy parametru Ra vzorku Q1	70

SEZNAM TABULEK

Tabulka 1 – přehled nastavených parametrů měření	43
Tabulka 2 – výsledky chyb po naučení neuronové sítě	62
Tabulka 3 – váhy mezi vrstvami a neurony perceptronu pro vzorek Q1	63
Tabulka 4 – predikované výsledky parametrů povrchu vzorku Q1	64
Tabulka 5 – porovnání výsledků neuronové sítě a reálných hodnot R_a vzorku Q1	65
Tabulka 6 – porovnání výsledků neuronové sítě a reálných hodnot R_z vzorku Q1	66
Tabulka 7 – porovnání výsledků neuronové sítě a reálných hodnot R_{mr} vzorku Q1	67
Tabulka 8 – porovnání výsledků neuronové sítě a reálných hodnot R_{sm} vzorku Q1	68
Tabulka 9 – porovnání výsledků regresní funkce a reálných hodnot R_a vzorku Q1	69
Tabulka 10 – porovnání výsledků neuronové sítě a reálných hodnot R_a vzorku Q1	69
Tabulka 11 – přehled průměrných procentuálních odchylek parametrů povrchu predikovaných neuronovou sítí v porovnání s reálnými daty pro vzorky Q1 až Q5	71

SEZNAM PŘÍLOH


Příloha P I: Výsledky pro vzorek Q2

Příloha P II: Výsledky pro vzorek Q3


Příloha P III: Výsledky pro vzorek Q4

Příloha P VI: Výsledky pro vzorek Q5

PŘÍLOHA P I: VÝSLEDKY PRO VZOREK Q2



3D pohled snímaného povrchu vzorku Q2 po odstranění tvaru



Průběh střední chyby při učení neuronové sítě pro vzorek Q2

Výsledky chyb po naučení neuronové sítě

Počet iterací	10000
Maximální chyba pro učící data	0,1086128179
Střední chyba pro učící data	0,01949983411
Maximální chyba pro testovací data	0,13643152
Střední chyba pro testovací data	0,0242972171

Váhy mezi vrstvami a neurony perceptronu pro vzorek Q2

Vrstva/neuron	1. Váha	2. Váha	3. Váha	4. Váha	5. Váha	6. Váha	7. Váha	bias
2/1	-6,831354357							5,8787742890
2/2	7,195995698							-6,5015595520
2/3	3,883961864							2,8695997320
2/4	-6,488337333							5,3937799230
2/5	-13,308416120							0,4867884463
2/6	8,171898687							-7,2871318870
2/7	12,679194040							-2,2085026800
3/1	-4,356772809	3,080533642	7,784040612	-4,0584975	3,368462985	3,717310988	4,420224699	-0,9745820330
3/2	7,183046156	-6,849614718	0,679075021	6,89767435	3,659704975	-7,748738591	-4,757483669	4,2680803590
3/3	-1,902619662	2,095398091	0,794347665	-1,32141978	-2,649824863	2,966875038	-0,065561763	0,1219132569
4/1	1,972121478	-2,607432382	-0,151079264					0,5191769760
4/2	1,343139816	-2,762227079	-0,604030409					0,9071829681
4/3	-1,241035269	-0,650810268	-1,506983623					1,7447500860
4/4	2,118490095	-0,334991250	0,980732211					-1,7492090260


Predikované výsledky parametrů povrchu vzorku Q2

Distance [mm]	Q2_Ra_N [μm]	Q2_Rz_N [μm]	Q2_Rmr_N [%]	Q2_Rsm_N [μm]
1	2,268	11,943	67,546	0,212
2	2,584	13,124	64,937	0,244
3	2,997	14,526	62,181	0,287
4	2,934	14,292	62,419	0,281
5	3,327	15,439	59,275	0,328
6	3,541	16,014	57,436	0,354
7	3,538	15,211	53,181	0,389
8	5,336	26,110	52,641	0,448

Porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q2

Distance [mm]	Q2_Ra [μm]	Q2_Ra_N [μm]	diference [μm]	odchylka [%]
1	1,936	2,268	0,332	17,15
2	2,620	2,584	0,036	1,37
3	3,485	2,997	0,488	14,00
4	2,653	2,934	0,281	10,59
5	3,207	3,327	0,120	3,74
6	3,776	3,541	0,235	6,22
7	3,796	3,538	0,258	6,80
8	5,681	5,336	0,345	6,07

Průměrná procentuální odchylka v případě porovnání parametru Ra vychází 8,24 %.




Porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q2

Porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q2

Distance [mm]	Q2_Rz [μm]	Q2_Rz_N [μm]	diference [μm]	odchylka [%]
1	9,290	11,943	2,653	28,56
2	15,313	13,124	2,189	14,30
3	15,904	14,526	1,378	8,66
4	14,547	14,292	0,255	1,75
5	14,418	15,439	1,021	7,08
6	16,736	16,014	0,722	4,31
7	16,994	15,211	1,783	10,49
8	29,401	26,110	3,291	11,19

Průměrná procentuální odchylka v případě porovnání parametru Rz vychází 10,79 %.




Porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q2

Porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q2

Distance [mm]	Q2_Rmr [%]	Q2_Rmr_N [%]	diference [%]	odchylka [%]
1	63,566	67,546	3,980	6,26
2	68,217	64,937	3,280	4,81
3	61,240	62,181	0,941	1,54
4	66,667	62,419	4,248	6,37
5	60,783	59,275	1,508	2,48
6	56,589	57,436	0,847	1,50
7	53,488	53,181	0,307	0,57
8	49,612	52,641	3,029	6,11

Průměrná procentuální odchylka v případě porovnání parametru Rmr vychází 3,7 %.




Porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q2

Porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q2


Distance [mm]	Q2_Rsm [μm]	Q2_Rsm_N [μm]	diference [μm]	odchylka [%]
1	0,196	0,212	0,016	8,16
2	0,196	0,244	0,048	24,49
3	0,189	0,287	0,098	51,85
4	0,244	0,281	0,037	15,16
5	0,316	0,328	0,012	3,80
6	0,317	0,354	0,037	11,67
7	0,458	0,389	0,069	15,07
8	0,347	0,448	0,101	29,11

Průměrná procentuální odchylka v případě porovnání parametru Rsm vychází 19,91 %.




Porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q2

PŘÍLOHA P II: VÝSLEDKY PRO VZOREK Q3



3D pohled snímaného povrchu vzorku Q3 po odstranění tvaru



Průběh střední chyby při učení neuronové sítě pro vzorek Q3

Výsledky chyb po naučení neuronové sítě

Počet iterací	10000
Maximální chyba pro učící data	0,1964244138
Střední chyba pro učící data	0,05050917308
Maximální chyba pro testovací data	0,1380280288
Střední chyba pro testovací data	0,03926963219

Váhy mezi vrstvami a neurony perceptronu pro vzorek Q3

Vrstva/neuron	1. Váha	2. Váha	3. Váha	4. Váha	5. Váha	6. Váha	7. Váha	bias
2/1	12,444412500							7,1577991180
2/2	-6,251173986							-0,4928394778
2/3	-17,443357350							1,4017813650
2/4	-6,327412496							-0,5214239974
2/5	-16,359287850							13,8162939300
2/6	12,095489900							6,9723335400
2/7	11,650522950							6,6775931700
3/1	-12,334282710	2,934609067	5,034067613	4,62630855	1,685276959	-12,438141340	-11,752982990	-0,2511292670
3/2	6,760064341	2,985765157	-5,073655267	3,07163662	-20,094637100	5,825749042	6,261438057	1,1169543470
3/3	0,892649013	-3,188094254	-4,536755489	-3,08266030	-22,893081230	1,193630871	1,859960179	-2,0305731290
4/1	-0,834721414	1,133887572	2,507796528					-0,6154676968
4/2	-1,175954590	0,166024205	3,739332653					-0,1299314368
4/3	0,384183762	-1,277129598	2,133559183					0,1224408278
4/4	0,449935214	1,603139820	-0,182009932					-1,2799558420


Predikované výsledky parametrů povrchu vzorku Q3

Distance [mm]	Q3_Ra_N [μm]	Q3_Rz_N [μm]	Q3_Rmr_N [%]	Q3_Rsm_N [μm]
1	2,304	11,254	65,581	0,253
2	2,622	13,400	63,729	0,233
3	2,754	13,488	62,173	0,252
4	2,683	13,441	62,996	0,241
5	2,927	13,598	60,316	0,280
6	2,899	13,580	60,601	0,275
7	3,142	13,736	58,275	0,318
8	3,639	16,988	63,369	0,315

Porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q3

Distance [mm]	Q3_Ra [μm]	Q3_Ra_N [μm]	diference [μm]	odchylka [%]
1	2,743	2,304	0,439	16,00
2	2,430	2,622	0,192	7,90
3	2,753	2,754	0,001	0,04
4	2,955	2,683	0,272	9,20
5	2,904	2,927	0,023	0,79
6	2,456	2,899	0,443	18,04
7	3,480	3,142	0,338	9,71
8	3,454	3,639	0,185	5,36

Průměrná procentuální odchylka v případě porovnání parametru Ra vychází 8,38 %.




Porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q3

Porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q3

Distance [mm]	Q3_Rz [μm]	Q3_Rz_N [μm]	diference [μm]	odchylka [%]
1	15,585	11,254	4,331	27,79
2	11,427	13,400	1,973	17,27
3	12,792	13,488	0,696	5,44
4	11,977	13,441	1,464	12,22
5	13,740	13,598	0,142	1,03
6	10,622	13,580	2,958	27,85
7	14,239	13,736	0,503	3,53
8	16,854	16,988	0,134	0,80

Průměrná procentuální odchylka v případě porovnání parametru Rz vychází 11,99 %.




Porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q3

Porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q3

Distance [mm]	Q3_Rmr [%]	Q3_Rmr_N [%]	diference [%]	odchylka [%]
1	67,676	65,581	2,095	3,10
2	65,116	63,729	1,387	2,13
3	61,240	62,173	0,933	1,52
4	56,589	62,996	6,407	11,32
5	63,566	60,316	3,250	5,11
6	61,957	60,601	1,356	2,19
7	57,541	58,275	0,734	1,28
8	62,791	63,369	0,578	0,92

Průměrná procentuální odchylka v případě porovnání parametru Rmr vychází 3,45 %.




Porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q3

Porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q3


Distance [mm]	Q3_Rsm [μm]	Q3_Rsm_N [μm]	diference [μm]	odchylka [%]
1	0,298	0,253	0,045	15,10
2	0,198	0,233	0,035	17,68
3	0,294	0,252	0,042	14,29
4	0,235	0,241	0,006	2,55
5	0,272	0,280	0,008	2,94
6	0,351	0,275	0,076	21,65
7	0,361	0,318	0,043	11,91
8	0,330	0,315	0,015	4,55

Průměrná procentuální odchylka v případě porovnání parametru Rsm vychází 11,33 %.

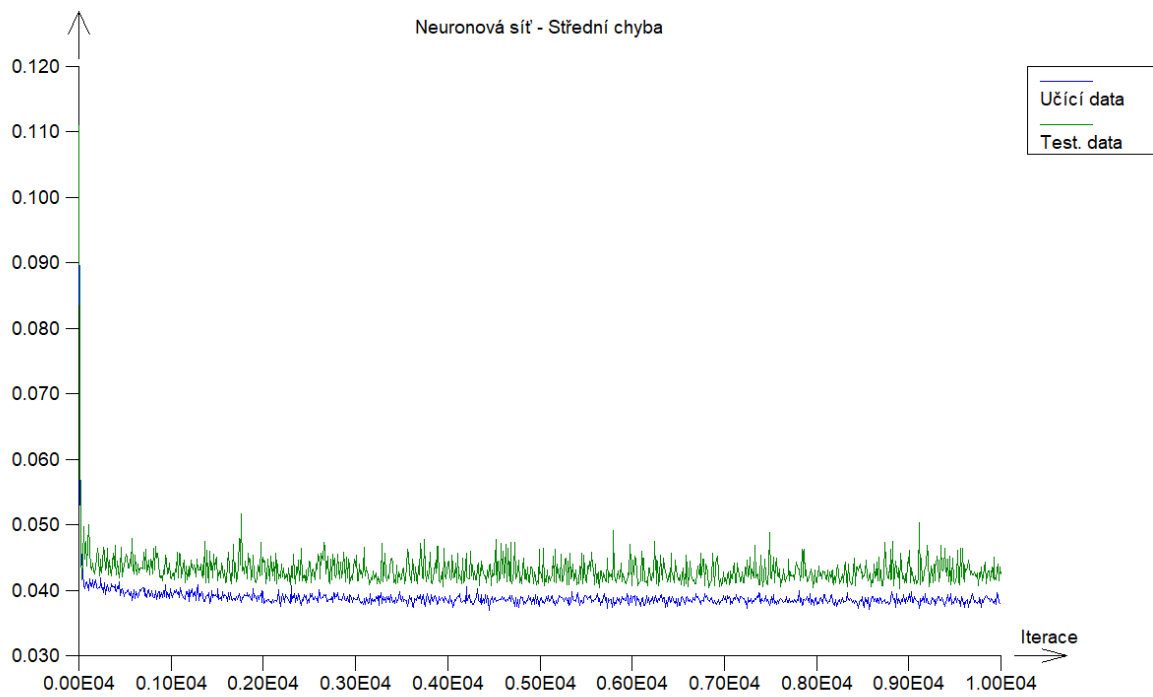


Porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q3

PŘÍLOHA P III: VÝSLEDKY PRO VZOREK Q4



3D pohled snímaného povrchu vzorku Q4 po odstranění tvaru



Průběh střední chyby při učení neuronové sítě pro vzorek Q4

Výsledky chyb po naučení neuronové sítě

Počet iterací	10000
Maximální chyba pro učící data	0,2072560242
Střední chyba pro učící data	0,03818732101
Maximální chyba pro testovací data	0,2659992312
Střední chyba pro testovací data	0,04234563973

Váhy mezi vrstvami a neurony perceptronu pro vzorek Q4

Vrstva/neuron	1. Váha	2. Váha	3. Váha	4. Váha	5. Váha	6. Váha	7. Váha	bias
2/1	9,940075908							-2,4411713260
2/2	3,736549312							-3,4516309630
2/3	-9,728132052							-1,8821371940
2/4	5,588829804							1,7268036340
2/5	3,530028495							-3,2456699280
2/6	18,395840770							7,1830536150
2/7	2,740939226							-0,3829604452
3/1	2,594459192	3,962299249	-4,374436046	5,93569491	2,825916248	16,664059460	4,424478403	-1,0899654630
3/2	-1,236051320	-2,549500310	-7,179499281	2,54534961	-2,501799537	1,063321952	0,278683620	-3,9326197680
3/3	8,924917085	1,930796974	-6,823171940	1,26667190	1,673922708	-3,628522628	0,261616083	-6,6252927220
4/1	1,462380686	0,713141621	1,200070857					-1,1624119130
4/2	1,090467769	-0,387889527	0,821916814					-0,8535256155
4/3	-0,617471115	-2,649959831	-0,752083749					0,6201859371
4/4	-0,059155554	-0,020354498	1,225874028					-0,6271570311


Predikované výsledky parametrů povrchu vzorku Q4

Distance [mm]	Q4_Ra_N [μm]	Q4_Rz_N [μm]	Q4_Rmr_N [%]	Q4_Rsm_N [μm]
1	2,349	11,711	66,714	0,268
2	2,459	12,330	65,960	0,267
3	2,871	14,438	63,483	0,264
4	2,908	14,299	61,538	0,264
5	2,930	14,274	60,697	0,265
6	3,114	15,423	60,094	0,309
7	3,196	15,989	59,824	0,333
8	3,225	16,205	59,798	0,343

Porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q4

Distance [mm]	Q4_Ra [μm]	Q4_Ra_N [μm]	diference [μm]	odchylka [%]
1	2,074	2,349	0,275	13,26
2	2,444	2,459	0,015	0,61
3	2,865	2,871	0,006	0,21
4	2,840	2,908	0,068	2,39
5	2,857	2,930	0,073	2,56
6	3,218	3,114	0,104	3,23
7	2,935	3,196	0,261	8,89
8	3,110	3,225	0,115	3,70

Průměrná procentuální odchylka v případě porovnání parametru Ra vychází 4,36 %.




Porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q4

Porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q4

Distance [mm]	Q4_Rz [μm]	Q4_Rz_N [μm]	diference [μm]	odchylka [%]
1	10,670	11,711	1,041	9,76
2	13,921	12,330	1,591	11,43
3	13,017	14,438	1,421	10,92
4	13,543	14,299	0,756	5,58
5	12,935	14,274	1,339	10,35
6	16,368	15,423	0,945	5,77
7	14,621	15,989	1,368	9,36
8	16,001	16,205	0,204	1,27

Průměrná procentuální odchylka v případě porovnání parametru Rz vychází 8,06 %.




Porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q4

Porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q4

Distance [mm]	Q4_Rmr [%]	Q4_Rmr_N [%]	diference [%]	odchylka [%]
1	66,667	66,714	0,047	0,07
2	65,116	65,960	0,844	1,30
3	63,692	63,483	0,209	0,33
4	62,555	61,538	1,017	1,63
5	63,566	60,697	2,869	4,51
6	62,016	60,094	1,922	3,10
7	68,217	59,824	8,393	12,30
8	58,459	59,798	1,339	2,29

Průměrná procentuální odchylka v případě porovnání parametru Rmr vychází 3,19 %.




Porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q4

Porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q4


Distance [mm]	Q4_Rsm [μm]	Q4_Rsm_N [μm]	diference [μm]	odchylka [%]
1	0,27	0,268	0,002	0,74
2	0,167	0,267	0,100	59,88
3	0,199	0,264	0,065	32,66
4	0,246	0,264	0,018	7,32
5	0,24	0,265	0,025	10,42
6	0,426	0,309	0,117	27,46
7	0,419	0,333	0,086	20,53
8	0,405	0,343	0,062	15,31

Průměrná procentuální odchylka v případě porovnání parametru Rsm vychází 21,79 %.

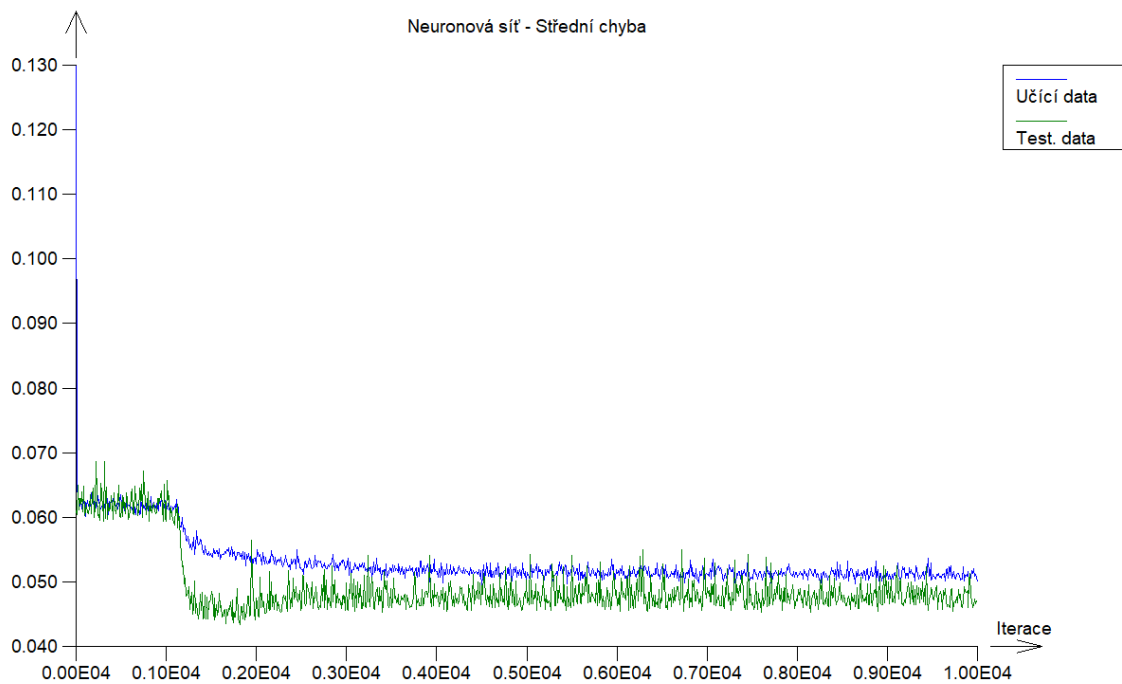


Porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q4

PŘÍLOHA P VI: VÝSLEDKY PRO VZOREK Q5



3D pohled snímaného povrchu vzorku Q5 po odstranění tvaru



Průběh střední chyby při učení neuronové sítě pro vzorek Q5

Výsledky chyb po naučení neuronové sítě

Počet iterací	10000
Maximální chyba pro učící data	0,3370604352
Střední chyba pro učící data	0,05005504221
Maximální chyba pro testovací data	0,1837170089
Střední chyba pro testovací data	0,04726138028

Váhy mezi vrstvami a neurony perceptronu pro vzorek Q5

Vrstva/neuron	1. Váha	2. Váha	3. Váha	4. Váha	5. Váha	6. Váha	7. Váha	bias
2/1	4,357661782							-3,2598212090
2/2	14,417006670							-8,8202542120
2/3	18,401480980							1,2940988290
2/4	20,683673390							-12,5656174100
2/5	1,364204786							-1,3781482630
2/6	14,553750160							8,1256038440
2/7	21,297381910							1,7029705580
3/1	-0,816397133	-0,660917705	-2,783011551	-1,066493513	1,283934697	-3,843088921	-2,793394825	-0,1221255736
3/2	-0,132315999	-0,734426977	-5,381730836	-1,03210301	0,712951366	5,271900059	-7,063780092	-4,2360543110
3/3	-3,275886116	-13,29762255	14,942033360	-20,19120793	-1,198309398	-0,863603198	17,300624310	-11,4391889600
4/1	1,657097997	1,239600079	1,252050431					-1,1763994590
4/2	1,170351948	0,806147740	1,040984543					-0,9255145674
4/3	-1,073298653	-0,474552185	-0,753949817					0,6424118909
4/4	1,279510095	-0,102743420	0,523329999					-0,5376584201


Predikované výsledky parametrů povrchu vzorku Q5

Distance [mm]	Q5_Ra_N [μm]	Q5_Rz_N [μm]	Q5_Rmr_N [%]	Q5_Rsm_N [μm]
1	2,123	11,091	64,727	0,247
2	2,053	10,668	65,821	0,228
3	2,168	11,183	65,411	0,225
4	2,337	12,633	63,412	0,245
5	2,337	12,632	63,413	0,245
6	2,337	12,632	63,413	0,245
7	1,843	9,635	66,963	0,226
8	1,843	9,635	66,963	0,226

Porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q5

Distance [mm]	Q5_Ra [μm]	Q5_Ra_N [μm]	diference [μm]	odchylka [%]
1	2,187	2,123	0,064	2,93
2	2,242	2,053	0,189	8,43
3	2,218	2,168	0,050	2,25
4	2,928	2,337	0,591	20,18
5	2,434	2,337	0,097	3,99
6	2,261	2,337	0,076	3,36
7	1,662	1,843	0,181	10,89
8	1,922	1,843	0,079	4,11

Průměrná procentuální odchylka v případě porovnání parametru Ra vychází 7,02 %.




Porovnání výsledků neuronové sítě a reálných hodnot Ra vzorku Q5

Porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q5

Distance [mm]	Q5_Rz [μm]	Q5_Rz_N [μm]	diference [μm]	odchylka [%]
1	10,102	11,091	0,989	9,79
2	10,972	10,668	0,304	2,77
3	10,802	11,183	0,381	3,53
4	13,587	12,633	0,954	7,02
5	11,226	12,632	1,406	12,52
6	12,892	12,632	0,26	2,02
7	8,071	9,635	1,564	19,38
8	8,491	9,635	1,144	13,47

Průměrná procentuální odchylka v případě porovnání parametru Rz vychází 8,81 %.




Porovnání výsledků neuronové sítě a reálných hodnot Rz vzorku Q5

Porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q5

Distance [mm]	Q5_Rmr [%]	Q5_Rmr_N [%]	diference [%]	odchylka [%]
1	62,016	64,727	2,711	4,37
2	64,778	65,821	1,043	1,61
3	62,016	65,411	3,395	5,47
4	60,465	63,412	2,947	4,87
5	62,791	63,413	0,622	0,99
6	58,915	63,413	4,498	7,63
7	68,992	66,963	2,029	2,94
8	70,543	66,963	3,580	5,07

Průměrná procentuální odchylka v případě porovnání parametru Rmr vychází 4,12 %.




Porovnání výsledků neuronové sítě a reálných hodnot Rmr vzorku Q5

Porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q5

Distance [mm]	Q5_Rsm [μm]	Q5_Rsm_N [μm]	diference [μm]	odchylka [%]
1	0,233	0,247	0,014	6,01
2	0,249	0,228	0,021	8,43
3	0,224	0,225	0,001	0,45
4	0,247	0,245	0,002	0,81
5	0,224	0,245	0,021	9,38
6	0,287	0,245	0,042	14,63
7	0,23	0,226	0,004	1,74
8	0,209	0,226	0,017	8,13

Průměrná procentuální odchylka v případě porovnání parametru Rsm vychází 6,2 %.



Porovnání výsledků neuronové sítě a reálných hodnot Rsm vzorku Q5