

VERIFIKACE NEURONOVÉHO MODELU NA CO₂ LASERU MERCURY L 30

Bc. Michal Jakšík

Diplomová práce
2006



Univerzita Tomáše Bati ve Zlíně
Fakulta technologická

Univerzita Tomáše Bati ve Zlíně

Fakulta technologická

Ústav výrobního inženýrství

akademický rok: 2005/2006

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Michal JAKŠÍK**

Studijní program: **N 3909 Procesní inženýrství**

Studijní obor: **Konstrukce technologických zařízení**

Téma práce: **Verifikace neuronového modelu na CO2 laseru
Mercury L 30**

Zásady pro vypracování:

1. Vypracujte rešerši na dané téma
2. Připravte vzorek z PMMA na CO2 laseru Mercury L30. Na tomto vzorku proveďte měření drsností a hloubek drážek
3. Na získaných datech ověřte funkčnost neuronového modelu pro nastavení CO2 laseru Mercury L 30. V případě nepřesností model modifikujte.
4. Proveďte závěrečné vyhodnocení dané metody a možnosti dalšího zpracování

Rozsah práce:

Rozsah příloh:

Forma zpracování diplomové práce: **tištěná**

Seznam odborné literatury:

1. BÍLA, J. Umělá inteligence a neuronové sítě v aplikacích. Praha: ČVUT, 1996. ISBN 80-01-01275-1

2. ZELINKA, I. Umělá inteligence. Brno: VUT Brno, 1998. ISBN 80-214-1163-5

3. SOCHOR, V. Lasery a koherentní svazky. Praha: Academia, 1990. ISBN 80-200-0354-1

4. ENGST, P., HORÁK, M. Aplikace laserů. Praha: SNTL, 1989

Vedoucí diplomové práce:

Ing. David Sámek
Ústav výrobního inženýrství

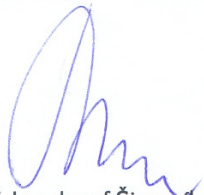
Datum zadání diplomové práce:

14. února 2006

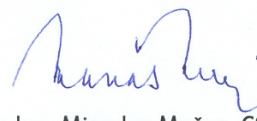

Termín odevzdání diplomové práce:

31. května 2006

Ve Zlíně dne 12. ledna 2006



prof. Ing. Josef Šimoník, CSc.
děkan



doc. Ing. Miroslav Maňas, CSc.
ředitel ústavu

ABSTRAKT

Cílem této práce je verifikovat neuronový model laserového mikroobrábění na CO₂ laseru Mercury L30. V teoretické části je popsán princip umělých neuronových sítí, laseru a laserového popisování.

V praktické části jsou vytvořeny a verifikovány umělé neuronové sítě pro nastavení kroku posuvu laserového paprsku na 500 a na 1000 DPI. Je sledován vliv nastavení CO₂ laseru Mercury L30, konkrétně posuvu, výkonu a kroku nastavení laserového paprsku na kvalitu obrobené plochy - drsnost a hloubku drážky.

Klíčová slova: neuron, umělá neuronová síť, laser, laserové popisování

ABSTRACT

The aim of this master's thesis is to verify the neural model of laser machining on the CO₂ laser Mercury L30 machine. The principles of the artificial neuron networks, laser and the laser scribing is described in the theoretical background chapter.

The experimental part consists of creation and verification of the artificial neural networks for setting of the working feed step of a laser beam in resolution of 500 and 1000 DPI. Furthermore, the surface roughness and groove depth dependence on the setting of the CO₂ laser Mercury L30 machine (working feed step, feed, power of laser beam) was investigated.

Keywords: Neuron, artificial neural network, laser, laser scribing

Děkuji vedoucímu mé diplomové práce Ing. Davidu Sámkovi, Ph.D. za odborné vedení, cenné rady, kritické připomínky a za péči, kterou věnoval přípravě a realizaci mé diplomové práce.

Dále děkuji firmě Mechanika Prostějov za vstřícný přístup a cenné praktické rady při výrobě vzorkových dílů.

Prohlašuji, že jsem na celé diplomové práci pracoval samostatně a použitou literaturu jsem citoval.

Ve Zlíně, 16. 05. 2006

.....

Bc. Michal Jakšík

OBSAH

ÚVOD.....	9
I TEORETICKÁ ČÁST	10
1 NEURONOVÉ SÍTĚ.....	11
1.1 HISTORIE	11
1.2 POPIS NEURONU.....	14
1.3 STRUKTURA NEURONOVÝCH SÍTÍ.....	14
1.4 ROZDÍL MEZI OSOBNÍM POČÍTAČEM (PC) A NEURONOVOU SÍTÍ.....	15
1.5 UMĚLÁ NEURONOVÁ SÍŤ.....	17
1.5.1 Vrstvová struktura umělé neuronové sítě.....	17
1.6 DĚLENÍ NEURONOVÝCH SÍTÍ, ZÁKLADNÍ POJMY	18
1.7 PŘENOSOVÁ FUNKCE	22
1.8 DVOUVRSTVÉ SÍTĚ.....	24
1.9 ALGORITMY TRÉNOVÁNÍ NEURONOVÝCH SÍTÍ.....	24
1.10 POSTUP PŘI TVORBĚ UMĚLÉ NEURONOVÉ SÍTĚ	26
1.10.1 Volba typu umělé neuronové sítě a její struktury.....	26
1.10.2 Tréninková a testovací množina dat.....	27
1.10.3 Trénování neuronového modelu.....	28
1.11 VYUŽITÍ NEURONOVÝCH SÍTÍ.....	29
2 LASER.....	31
2.1 HISTORIE VZNIKU LASERU	33
2.2 ZÁKLADNÍ POJMY	35
2.3 KONSTRUKČNÍ SLOŽENÍ LASERU.....	38
2.3.1 Tvar paprsku laseru	39
2.4 TYPY, ROZDĚLENÍ A POPIS LASERŮ	39
2.4.1 Pevnolátkové lasery.....	41
2.4.1.1 Rubínový a neodymový laser.....	41
2.4.1.2 Kontinuální Nd:YAG laser	43
2.4.2 Kapalinové lasery	45
2.4.2.1 Aktivní prostředí.....	45
2.4.2.2 Buzení barvivových laserů.....	45
2.4.3 Plynové lasery	46
2.4.3.1 CO ₂ laser	46
2.4.3.2 Helium Neonový laser	50
2.4.4 Molekulární lasery.....	50
2.4.5 Plazmatické lasery	51
2.4.6 Nové druhy laserů	51
2.4.7 Porovnání laserů.....	52

2.5	OBRÁBĚNÍ LASEREM.....	54
2.5.1	Laserové popisování.....	55
2.5.1.1	Způsoby laserového popisování.....	58
2.5.1.2	Vliv materiálu na laserové popisování.....	59
2.5.2	Laserové svařování.....	60
2.5.3	Laserové vrtání.....	63
2.5.4	Laserové řezání.....	64
2.5.5	Využití laseru při obrábění.....	66
3	STANOVENÍ CÍLŮ DIPLOMOVÉ PRÁCE	68
II	PRAKTICKÁ ČÁST.....	69
4	POPIS PŘÍSTROJŮ A MATERIÁLU	70
4.1	POPIS CO ₂ LASERU MERCURY L30.....	70
4.2	PŘÍSTROJ NA MĚŘENÍ DRSNOSTI SURFTTEST SJ-301	71
4.3	LINEÁRNÍ VÝŠKOMĚR „LINEAR HEIGHT“ LH-600 B	72
4.4	POLYMETYLMETAKRYLÁT (PMMA)	73
5	VERIFIKACE.....	75
5.1	PŘÍPRAVA ZKUŠEBNÍHO DÍLU.....	75
5.2	MĚŘENÍ DAT.....	77
5.2.1	Princip měření drsnosti	77
5.2.2	Princip měření hloubky vygravírované drážky.....	78
5.2.3	Statistická analýza naměřených dat.....	78
5.3	NAMĚŘENÁ DATA.....	79
5.4	VLASTNÍ VERIFIKACE.....	83
5.5	ZPŘESNĚNÍ MODELU	85
5.6	VYHODNOCENÍ VERIFIKACE.....	88
6	VLIV NASTAVENÍ KROKU POSUVU LASEROVÉHO PAPRSKU.....	89
6.1	NAMĚŘENÁ DATA.....	89
6.2	VOLBA UMĚLÉ NEURONOVÉ SÍTĚ	97
6.2.1	Specifikace tvorby programu v software Matlab	98
6.3	VYTVOŘENÍ UMĚLÉ NEURONOVÉ SÍTĚ	98
6.4	TESTOVÁNÍ UMĚLÉ NEURONOVÉ SÍTĚ	100
6.5	VLASTNÍ VERIFIKACE.....	102
6.6	VYHODNOCENÍ VÝSLEDKŮ UMĚLÉ NEURONOVÉ SÍTĚ.....	106
7	DISKUSE VÝSLEDKŮ	108
7.1	SHRNUTÍ VERIFIKACE A APLIKACE MODELŮ UMĚLÉ NEURONOVÉ SÍTĚ	108
7.2	SHRNUTÍ ZÁVISLOSTÍ Vlivu NASTAVENÍ LASERU MERCURY L30 NA VÝSLEDKY MIKROOBRÁBĚNÍ PMMA.....	110
7.2.1	Vliv nastavení kroku posuvu laserového paprsku na hloubku obrobené drážky	110

7.2.2	Vliv nastavení kroku posuvu laserového paprsku na střední aritmetickou úchylku	111
7.2.3	Vliv nastavení kroku posuvu laserového paprsku na maximální výšku profilu	111
ZÁVĚR		113
SEZNAM POUŽITÉ LITERATURY.....		114
SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK		115
SEZNAM OBRÁZKŮ		117
SEZNAM TABULEK.....		120
SEZNAM PŘÍLOH.....		122

ÚVOD

Umělé neuronové sítě byly vytvořeny na základě jednoduchých modelů neuronů - funkčních buněk nervového systému živých organismů. Většina současných aplikací umělých neuronových sítí využívá selektivní a generalizační vlastnosti těchto struktur. Některé novější struktury jsou navíc schopné řešit i úlohy složitějšího typu, jako jsou např. optimalizační úlohy. Teorie neuronových sítí je relativně nový vědecký obor, který zkouší implementovat do současných technologií zpracování dat algoritmy převzaté od živých organismů. Tyto snahy jsou zatím sice v počátku, výsledky však ukazují velmi perspektivní budoucnost. [2]

Laserové popisování je proces, ve kterém se vyskytuje několik vstupních a výstupních parametrů, které je nezbytné nastavit tak, aby bylo dosaženo výsledku splňujícího kvalitativní a ekonomicky efektivní požadavky.

V případě řešeného problému v rámci této Diplomové práce je monitorováno:

VSTUP

- výkon laseru
- rychlost posuvu paprsku

VÝSTUP

- hloubku drážky
- drsnost povrchu, a to:

R_a - průměrná aritmetická úchylka v příčném směru

R_z - největší výška profilu v příčném směru

Vyskytují se zde tedy dva vstupní parametry ovlivňující tři výstupní parametry, přičemž změna každého jednotlivého vstupního parametru má jiný vliv na výstup a navíc tyto proměnné nemají lineární průběh, což dále komplikuje tvorbu neuronového modelu.

Umělé neuronové sítě během své relativně krátké existence jsou v současnosti využívány v mnoha odvětvích lidských činností kde je třeba optimalizovat a vhodně nastavit systém, ve kterém se nachází několik vstupních a výstupních parametrů. Při užití jiných známých aproximačních metod těchto výhod nelze dosáhnout, nebo je jejich dosažení obtížné. Nespornou výhodou neuronových sítí je jejich schopnost učit se a tak dále zvyšovat pravděpodobnost správnosti navrženého nastavení.

Z ekonomického hlediska tedy neuronové sítě přináší zásadní ekonomický přínos, svou schopností učit se problematice plně dokáží nahradit kvalifikovaný odhad zkušeného pracovníka.

I. TEORETICKÁ ČÁST

1 NEURONOVÉ SÍTĚ

1.1 Historie

Neuronové sítě jsou mimořádně úspěšné již déle než patnáct let. Historie umělých neuronových sítí zahrnuje též období od roku 1943 do roku 1969, které lze považovat za dobu vzniku oboru. Ve 40. letech minulého století fyziologové McCulloch, Pitts a Hebb ve svých pojednáních o modelech chování nervové soustavy živých organismů nejen podali vysvětlení příčin tzv. podmíněných reflexů, ale také zavedli normu grafického znázorňování struktury umělých neuronových sítí. Od roku 1943 je zvykem znázorňovat umělou nervovou buňku jako kroužek (vrchol grafu) a nazývat ji zkráceně neuron a směr toku signálu označovat šipkou (orientovaná hrana grafu). Používání orientovaných grafů s ohodnocenými hranami, které se od té doby vžilo, zavedli McCulloch a Pitts.

Matematikům a elektronikům trvalo déle než deset let, než pro neuronové sítě našli uplatnění. V letech 1958 až 1959 Rosenblatt, Windrow a Hoff realizovali dva elektronické modely neuronové sítě včetně mechanismů jejich učení. Počátkem 60. let byla v Bellových laboratořích použita umělá neuronová síť ke konstrukci nelineárních filtrů určených pro potlačování šumu vznikajícího v dálkových telefonních kabelech. Jde o jeden z paradoxů vývoje, kdy to, co je nové (v roce 1960), jednoduché a funguje, je prostě používáno (dodnes) a ani se o tom pořádně neví. Spolu s tím začali teoretici i praktici rozvíjet a realizovat složitější konstrukce neuronových sítí bez ohledu na to, zda budou užitečné, spolehlivé a funkční.

V 60. letech tak vznikla velká euforie, v rámci které se dokonce polemizovalo s von Neumannovou koncepcí počítačů s centrální jednotkou, řadičem, pamětí a programem. Předpokládalo se totiž, že brzy budou problémy řešeny bez programování a s využitím nových typů tzv. neuropočítačů, které se od lidí naučí řešit úlohy prostřednictvím zobecňování konkrétních poznatků. Ze současného pohledu jde o zřejmě neuskutečnitelný, ale krásný sen.

Ani po více než 40-ti letech uvnitř počítače umělý mozek stále ještě není a namísto toho, aby se počítače od lidí něco přiučily a pochopily, o co jim jde, musí se lidé učit obsluhovat stále vyšší verze programového vybavení. V průběhu 60. let sílily snahy konstruktérů počítačů nahradit složité logické obvody sítěmi jednoduchých elektronických neuronů. Matematickými odvozeními se však brzy zjistilo, že existují takové logické obvody, jejichž ná-

hrada neuronovou sítí je složitější než klasické řešení. Proto se může stát, že určit optimální strukturu sítě a nalézt váhy spojení mezi neurony je časově velmi náročné.

V roce 1984 spustil Hopfield druhou vlnu zájmu o neuronové sítě tím, že zkonstruoval neuronové sítě zvané autoasociativní. V 80. letech odborníci věřili tomu, že autoasociativní neuronové sítě pomohou detekovat vojenské cíle z radiolokátorových a jiných pozorování. To vedlo dokonce ke vzniku firem, které vyvíjely, vyráběly a dodávaly speciální čipy s paralelními Hopfieldovými autoasociativními obvody. Posléze se zjistilo, že autoasociativní paměti tohoto typu mají malé paměťové schopnosti, malou spolehlivost vybavování asociací

a navíc vytvářejí falešné představy neexistujících objektů. Tak se stalo, že do roku 1989 čipy s Hopfieldovou pamětí nebyly k sehnání, protože podléhaly přísnému embargu, zatímco v současnosti je nikdo nevyrábí a navíc ani neshání.


Teoretické, praktické i marketingové nadšení z neuronových sítí ovšem trvá víceméně od roku 1984 až do současné doby. Například v roce 1987 Rummelhart zveřejnil koncepci několikvrstevných sítí se spojeným chováním. Tento typ neuronových sítí je dodnes komerčně dodáván jako karta do osobního počítače nebo jako programové vybavení. V roce 1988 Kohonen přišel s úplně novou myšlenkou neuronové sítě, která nepotřebuje ani učitele, ani nemá zbloudilé asociace, ale sama o sobě mění své vnitřní chování, aniž by se od člověka dozvěděla, zda se chová dobře nebo špatně. V takovém případě se hovoří o samoorganizujících se mapách (SOM) založených na soutěživosti mezi paralelními neuronovými buňkami. Sám Kohonen tyto sítě realizoval elektronicky a použil je k analýze lidské řeči. Prvním výsledkem učení sítí SOM bylo úspěšné rozpracovávání hlásek a fonémů. Umělá neuronová síť SOM je důležitým a silným nástrojem pro analýzu dat, a to zejména v oblastech bankovníctví, finančních transakcí, pojišťovnictví, marketingu a technické diagnostiky. Roku 1990 se začaly neuropočítače ve velké míře komerčně využívat. Stalo se tak díky profesoru matematiky Hechtu Nielsenovi. Velmi správně vytipoval konkrétní aplikaci: odstranění šumu

z elektrokardiogramu. Dále pochopil roli neuropočítače jako hardwarového klíče a nutnost dodávat neuronovou síť již jako naučenou. Tím totiž odpadají problémy se spolehlivostí a spotřebou času na učení u koncového zákazníka.

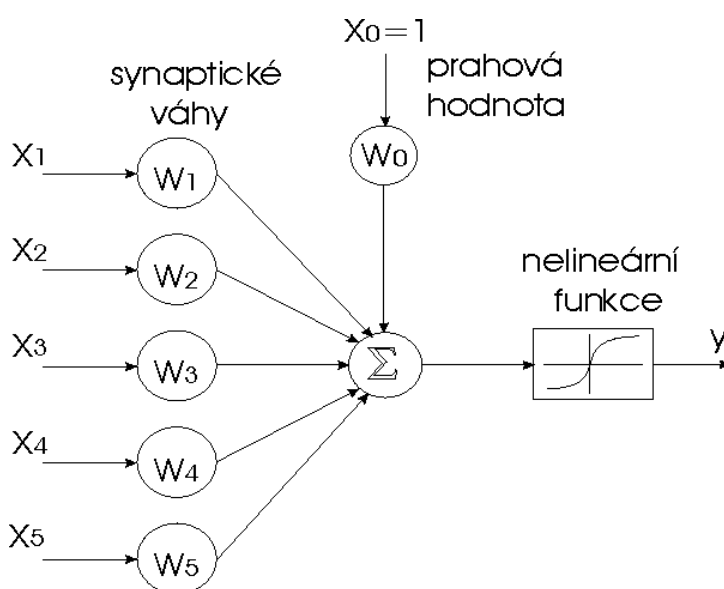
Existuje ještě mnoho jiných typů sítí založených na dalších principech. Jde např. o neuronové sítě s radiální bází (Radial Basis Function – RBF), modulární neuronové sítě a fuzzy neuronové sítě. Sítě RBF jsou založeny na zohlednění vzdáleností od etalonů, modulární

sítě nacházejí kompromisy z několika dílčích řešení a fuzzy neuronové sítě určují řešení s využitím fuzzy logiky.

Nárůst počtu typů neuronových sítí však neřeší následující implementační paradox. Kdo je konzervativní, volí jednoduchou síť se spolehlivým učením a je spokojen s tím, že chyba je menší než 10 %. Druhou možností je sledovat moderní či módní trendy, volit složitou strukturu sítě se složitou metodou učení a divit se, že v rozporu s optimistickým očekáváním je chyba sítě ještě větší. Neuronovou síť lze těžko předem seznámit se všemi situacemi, které mohou nastat. Proto je důležité, aby byla co nejlépe připravena i na situace, které ještě nezažila. V této souvislosti se hovoří o schopnosti zobecňovat. Zde opět platí okřídlené „někdy méně znamená více,“. Čím méně neuronů a vazeb mezi nimi, tím lépe je síť schopna zobecňovat. Lépe dokážou zobecňovat také sítě s malými absolutními hodnotami vah. [3]



Obr. 1 Model neuronu ze 40. let



Obr. 2 Jednoduchý popis neuronu

1.2 Popis neuronu

Z Obr. 1 je jasná funkce jednoho neuronu. Vstupní hodnoty jsou vynásobeny příslušnými váhovými koeficienty a sečtou se. Na výsledek součtu se aplikuje funkce (obecně nelineární) a výsledná hodnota funkce je přivedena na vstup jiných neuronů pomocí výstupní části. Na Obr. 2 je navíc vidět, že neuron má jeden zvláštní vstup, který není připojený k výstupu žádného neuronu ale přivádí konstantní veličinu do neuronu. Tato veličina funguje jako prahová hodnota při aktivování výstupu. Když suma váženého součtu vstupů nepřesahuje prahovou hodnotu, tak se neuron neaktivuje a jeho výstup zůstane nezměněný. [3]

Matematický popis neuronu

$$y = F\left(\sum_{i=1}^n x_i \cdot w_i + x_0\right) \quad (1)$$

kde:

x_i - je hodnota na i -tém vstupu,

w_i - je váha i -tého vstupu,

x_0 - je prahová hodnota,

n - je celkový počet vstupů,

F - je obecná nelineární funkce,


y - je hodnota výstupu.

1.3 Struktura neuronových sítí

Zatímco strukturu živých nervových tkání lze pro vysoký stupeň provázanosti jednotlivých nervových buněk znázornit jen obtížně, struktura umělé neuronové sítě je výrazně jednodušší. Umělé sítě nemají přesně napodobit živý mozek nebo jeho část. Cílem matematiků i techniků je navrhnout co nejjednodušší síť, která ještě řeší daný problém.

Struktura neuronové sítě se znázorňuje s využitím symboliky teorie grafů. Na Obr. 2 je schéma elementární sítě tvořené dvěma výstupními neurony napájenými ze tří vstupních neuronů. Hodnoty signálů na vstupu sítě jsou označeny x_1 , x_2 , x_3 , hodnota výsledného signálu je y_1 a y_2 , směr toku signálu ze vstupů k výstupu je znázorněn šipkami u jednotlivých hran spojujících uzly a w_0 , w_1 , w_2 , w_3 jsou hodnoty vah, které hrají roli při výpočtu

hodnoty y_1 a y_2 z hodnot x_1 , x_2 , x_3 . Do vstupních neuronů (označeny červeně) jsou coby vstupní údaje pro řešení dané úlohy typicky přiváděny signály z okolí. Z výstupních neuronů potom vystupuje signál, jehož hodnota představuje číselnou formu řešení. Výstupních neuronů může být několik a společně vytvářejí druhou vrstvu sítě, jak je ukázáno na Obr. 3 (zde jsou vynechány symboly jednotlivých vah a orientace směru toku signálu; v takovém případě se předpokládá, že šipky směřují zleva doprava; výstupní neurony jsou označeny zeleně). Vzhledem k tomu, že síť na Obr. 3 má jen dvě vrstvy, jednu se třemi vstupními a druhou se dvěma výstupními neurony, je záznamem její topologie dvojice čísel 3-2. [4]



Obr. 3 Umělá neuronová síť 3-2

1.4 Rozdíl mezi osobním počítačem (PC) a neuronovou sítí

Rozdíl mezi klasickým počítačem a neuronovou sítí je ten, že při používání klasického PC musíme vytvořit program, který řeší daný problém. Do tohoto programu obvykle zahrneme ve formě podmínek a rozhodovacích instrukcí veškeré dostupné informace. Jestliže je program postaven před problém, který nepatří do třídy známých problémů, ale je dost odlišný, je obvykle buď ignorován, nebo v lepším případě je obsluha upozorněna, že se vyskytl neznámý případ, který byl odložen bokem. V takovém případě musí opět nastoupit programátor a program upravit, pokud ale použijeme neuronovou síť, nemusíme vymýšlet žádný algoritmus a v případě vhodné konfigurace a dobrého učení naše umělá neuronová síť zareaguje správným způsobem a novou informaci zařadí s velkou pravděpodobností do správné třídy. Není potřeba žádné úpravy sítě. Samozřejmě, že nic na světě není neměnné, takže jak vzrůstá počet nových informací, je pravděpodobné, že vzniknou i nové třídy informací, na které se síť musí doučit a případně pozměnit i konfiguraci. Ale to se dá obejít bez přítomnosti člověka. [1]

Několik důležitých rozdílů mezi klasickým PC a neuronovou sítí je uvedeno v Tab. 1.

Tab. 1 Rozdíl mezi PC a umělou neuronovou sítí [1]

Umělá neuronová síť	Počítač
Je určena nastavováním vah, prahů a struktury	Je programován instrukcemi
Paměťové a výkonné prvky jsou uspořádány spolu	Proces a paměť pro něj jsou separovány
Paralelismus	Sekvenčnost
Tolerují odchylky od originálních informací	Netolerují odchylky
Samooorganizace během učení	Neměnnost programu

1.5 Umělá neuronová síť


Je zřejmé, že jediný neuron není schopen vykonat příliš složitou funkci. Síla systému, využívající umělé neurony, je ve struktuře, v síti velkého počtu neuronů. Umělá neuronová síť je vlastně pole jednoduchých výkonných prvků - neuronů. Takovéto uspořádání má velkou flexibilitu a spolehlivost. Umožňuje různě propojovat vstupy a výstupy neuronů, zvýhodnit či potlačit některé vstupy a minimalizovat vliv nesprávně fungujícího neuronu na celkový výsledek.

Samozřejmě i tento systém má nevýhody. Největší problémy se vyskytují při realizaci velmi složitých struktur, kde se velký počet propojení mezi neurony realizuje velmi obtížně. Dalším problémem je, že neexistuje jednoznačný postup při syntéze složitějších struktur. [5]

1.5.1 Vrstvová struktura umělé neuronové sítě

Neurony jsou většinou sdružovány do vrstev, jak to ukazuje Obr. 4. Výstupy z n -té vrstvy jsou přivedeny na vstup obecně každého neuronu ve vrstvě $n+1$. První vrstva se nazývá vstupní či rozdělovací vrstva a má za úkol přijímat hodnoty z okolí pro zpracování a přivést je na vstup každého neuronu následující vrstvy. Poslední vrstva nese název výstupní a hodnoty na jejím výstupu jsou odezvou celého systému na vstupní vzorky. Vnitřní vrstvy

se nazývají skryté vrstvy. Jejich počet závisí na složitosti funkce, kterou má síť vykonat a na zvoleném typu sítě. [5]



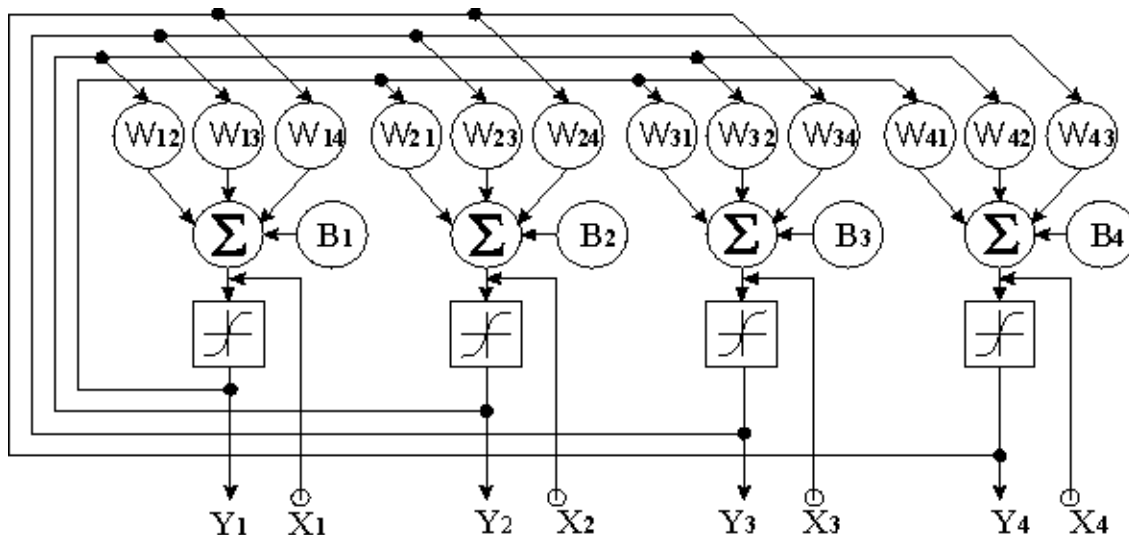
Obr. 4 Vrstvová struktura umělé neuronové sítě

1.6 Dělení neuronových sítí, základní pojmy


Neuronové sítě lze rozdělit do dvou hlavních skupin podle struktury: na sítě s dopředným šířením signálu a na sítě se zpětnou vazbou. V současnosti se nejčastěji používají struktury s dopředným šířením signálu, kde výstupy z jedné vrstvy jsou vedeny na vstup následující vrstvy, jak to ukazuje Obr. 4. Výstupy z poslední, výstupní vrstvy jsou výstupy z celé sítě.

Neuronové sítě s dopředným šířením signálu lze rozdělit do dvou skupin podle funkce kterou realizují, a to na lineární a nelineární. Tato funkce samozřejmě není totožná s výstupní funkcí jednoho neuronu. Sítě lineární jsou schopné realizovat pouze lineární matematické funkce, tj. funkce skládající se ze součtů a z násobení. [5]

Jednoduchý příklad lineární funkce může být logická funkce AND realizovaná pomocí jednoho neuronu podle Obr. 6. Příklad ukazuje rozdíl mezi výstupní funkcí neuronu a mezi funkcí sítě. Síť může pracovat jako klasifikátor, který rozdělí dvourozměrný prostor, definovaný binárními vstupy $[x_1, x_2]$, $x_1, x_2 \in \{0, 1\}$ na dva poloprostory, první definovaný prvky $[0, 0]$, $[0, 1]$, $[1, 0]$ a druhý definovaný prvkem $[1, 1]$.



Obr. 5 Hopfieldova síť



Obr. 6 Realizace binární funkce AND pomocí jednoho neuronu

Umělé neuronové sítě se dále dělí podle několika kritérií

Podle počtu vrstev:

- S jednou vrstvou (Hopfieldova síť, Kohonenova síť, ...)
- S více vrstvami (ART síť, Perceptron, ...)

Podle typu algoritmu učení:

- S učitelem (síť s dopředným šířením)
- Bez učitele (Hopfieldova síť, ...)

Podle stylu učení na síť s učením:

- Deterministickým (např. algoritmus Backpropagation)
- Stochastickým (náhodné nastavování vah)


Podle počtu vrstev

Dělení podle počtu vrstev znamená, že rozlišujeme z kolika vrstev se daná síť skládá. Existují sítě s jednou vrstvou, se dvěma, třemi a více vrstvami. Sítě s jednou či dvěma vrstvami bývají většinou speciální sítě jako např. Hopfieldova, Kohonenova či ART síť, které mají svůj speciální učicí algoritmus a topologii, zatímco pro sítě se třemi a více vrstvami se obvykle používá klasická vícevrstvá síť s algoritmem Backpropagation. Pro topologii sítí platí obvykle pravidlo, že každý neuron bývá spojen s každým neuronem ve vyšší vrstvě.

Zvláštností je např. Hopfieldova síť (Obr. 5), ve které je spojen každý neuron se všemi ostatními. Každý spoj je ohodnocen vahami, které mohou nabývat různých hodnot a vyjadřují, jaký význam tento spoj má pro daný neuron. To ovšem neznamená, že spoj s malou vahou můžeme zanedbat, protože nevíme, jaký vliv má tento vstup na celkovou činnost sítě.

Sítě s dopředným šířením mají dopřednou architekturu sítě. Využívají pevného počtu vrstev a neuronů v těchto vrstvách. Počet vstupů je záležitostí volby vhodného typu struktury modelu vstupů dle řešené problematiky.

Základní jednotkou perceptronových sítí je perceptron, kde x jsou vstupy, p je počet vstupů, w je váha spoje, b je prahová hodnota (bias), f je aktivační funkce a a je výstup perceptronu. Aktivační funkcí perceptronu je silně omezená funkce, jejíž výstupní hodnoty nabývají pouze 0 nebo 1 v závislosti na vstupních hodnotách.



Obr. 7 Schéma perceptronu

Podle algoritmu učení

Podle algoritmu učení. Lze dělit síť na učení s učitelem a bez učitele.

Učení s učitelem znamená, že se síť snaží přizpůsobit svou odezvu na vstupní informace tak, aby se její momentální výstup co nejvíce podobal požadovanému originálu.

Charakteristickou vlastností nelineárních neuronových sítí s dopředním šířením signálu je schopnost učení. Fáze učení předchází fázi vlastní práce a slouží k určení váhových koeficientů a tak vlastně k uložení informací do paměti systému. Učení se může probíhat dvěma způsoby, s učitelem a bez učitele. Při prvním způsobu je síť trénována pomocí dvojic vstupní vzorek a příslušný, očekávaný výstupní vzorek. Trénovací vstupní vzorky jsou vybrány

z celkové množiny vstupních vzorků tak, aby plně popsaly všechny vlastnosti množiny důležité pro danou úlohu. V této fázi nenatréované síti přiložíme vstupní vzorek. Na základě skutečné odezvy a očekávané odezvy se upravují váhové koeficienty. Během trénování se na vstupy sítě přivedou všechny trénovací vzorky, obecně vícekrát a navíc v náhodném pořadí. Po natréování síť musí správně reagovat na všechny trénovací vzorky a dále má pracovat dobře i pro ostatní vzorky množiny. Aby síť pracovala dobře potřebujeme velký počet trénovacích vzorků. Obecně platí, že čím větší je počet trénovacích vzorků, tím přesněji bude síť pracovat. Příkladem takové sítě je síť "back-propagation", která je pravděpodobně nejčastěji používaným typem.

Při učení bez učitele máme jenom trénovací vzorky, ale neexistují očekávané výstupní vzorky. Tyto výstupní vzorky, příslušející k jednotlivým vstupním vzorkům se určí během procesu učení. Váhové koeficienty se postupně nakonfiguruje tak, aby pro každý vstupní trénovací vzorek existoval jediný aktivní výstup. Tak na konci trénování dosáhneme toho, že přivedením trénovacího vzorku se aktivuje vždy jediný, jednoznačně určený výstup.

Učení bez učitele je proces, ve kterém síť vychází pouze z informací, které jsou obsaženy ve vstupních vektorech.

Podle stylu učení

Styl učení v podstatě znamená, jak se přistupuje k zjištění vah sítě. V případě, že se jedná o zjištění výpočtem, pak mluvíme o deterministickém učení.

Jestliže jsou však váhy získávány pomocí generátoru náhodných čísel, pak mluvíme o stochastickém stylu učení. Tento způsob získání vah sítě se obvykle používá jen při startu sítě. [5]

1.7 Přenosová funkce

Pro správný chod neuronu a neuronových sítí je důležité, jakou přenosovou funkci zvolíme. Přenosová funkce udává, jaká bude odezva na výstupu na vstupní podnět. Jsou různé druhy funkcí u kterých obecně platí, že jejich hodnota má být v intervalu -1 až $+1$ a že mají být spojitě (sigmoida, hyperbolický tangens, ...), nebo s nespojitostí prvního druhu (binární funkce 0-1). Volba funkce závisí na problému, který chceme řešit. Mezi nejpoužívanější funkce patří:


Bipolární

Binární

Logická (používá se též výraz „sigmoida“)

Funkce hyperbolický tangens (Tan-Sigmoid Transfer Function)

Aktivační funkce hyperbolický tangens nabývá výstupních hodnot neuronu v rozsahu hodnot -1 až $+1$. Aktivační funkce se využívá typicky u Elmanových neuronových sítí.




Obr. 8 Schéma přenosové aktivační funkce tansig

Lineární aktivační funkce (Linear Transfer Function) purelin

Přenosová funkce purelin má lineární vztah mezi vstupní a výstupní hodnotou neuronu.


Ve většině neuronových sítí se využívá jako aktivační funkce poslední výstupní vrstvy neuronové sítě.



Obr. 9 Schéma přenosové aktivační funkce purelin

Saturovaná lineární aktivační funkce (Saturating Linear Transfer Function)

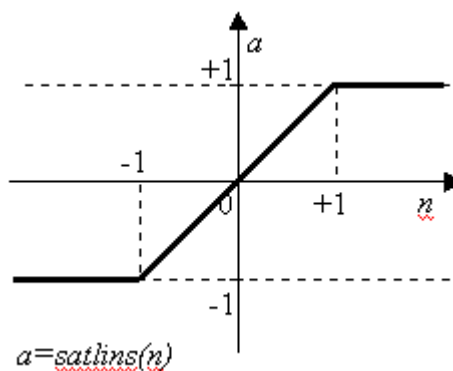
Saturovaná přenosová funkce satlin omezuje velikost vstupního signálu v rozsahu hodnot 0 až +1. Funkce kopíruje vstupní hodnoty na výstupu funkce, pouze při záporných vstupních hodnotách je na výstupu funkce vždy 0.



Obr. 10 Schéma přenosové aktivační funkce satlin

Symetrická saturovaná lineární aktivační funkce (Symmetric Saturating Linear Transfer Function)

Saturovaná přenosová funkce satlins omezuje velikost vstupního signálu v rozsahu hodnot 0 až +1. Funkce kopíruje vstupní hodnoty na výstupu funkce, pouze při záporných vstupních hodnotách je na výstupu funkce vždy 0. [3]




Obr. 11 Schéma přenosové aktivační funkce satlins

1.8 Dvouvrstvé sítě

Dvouvrstvé sítě se snadno učí a umějí dobře zobecňovat, ale nedokážou se zcela přizpůsobit každé situaci. To souvisí s nelineární podstatou obecného rozhodovacího procesu. Proto se

v mnoha úlohách používají třívrstvé i vícevrstvé neuronové sítě. První vrstva se nazývá vstupní, poslední vrstva výstupní a mezilehlé vrstvy se označují jako skryté (hidden – h). Na Obr. 12 je ukázána třívrstvá síť se třemi vstupními, dvěma skrytými (označeny modře) a třemi výstupními neurony. Taková síť má topologii 3-2-3. [5]



Obr. 12 Hierarchická síť 3-2-3 se skrytou vrstvou [5]

1.9 Algoritmy trénování neuronových sítí

Pokud je vybrána architektura neuronové sítě, pak je nezbytnou záležitostí nastavení jejich parametrů. Tyto se nastavují přímo, nebo během činnosti nastavení parametrů sítě, tj. trénování. U mnohvrstevných sítí to jsou tyto parametry: počet vrstev, počet neuronů

v jednotlivých vrstvách a váhy pro všechny spoje mezi neurony. Často je celková architektura mnohvrstvé neuronové sítě neměnná a algoritmus trénování nastavuje pouze váhové a prahové hodnoty. Principem algoritmu trénování je minimalizace chyb mezi výstupem neuronové sítě a cílovým (požadovaným) výstupem.

Trénování může být náročné na výpočet, ale z hlediska identifikační procedury je nejjednodušší fází v identifikaci. Není náročné vytvořit tréninkový algoritmus prostřednictvím počítače, ale je důležité zvolit správný softwarový produkt pro tvorbu tréninkového algoritmu.

Trénování je optimalizační algoritmus pro nalezení minima kritéria. Je to iterativní vyhledávací algoritmus, který na základě vyhodnocení hodnoty kritéria znovu nastaví parametry sítě a to tak dlouho, dokud nedosáhne požadované přesnosti nebo v předem stanoveném maximálním počtu iterací. Po každé iteraci jsou znovu nastaveny parametry neuronové sítě podle vybraného algoritmu trénování. Různé varianty algoritmů trénování se liší ve způsobu, jakým postupují k minimu zvoleného kritéria a velikosti iteračního kroku.

Metody trénování se liší přístupem množiny tréninkových dat. Jedná se o dva způsoby přístupu k datům:

skupinový přístup (off-line) - tréninková data jsou před začátkem trénování již dána a aktualizace parametrů neuronové sítě probíhá ve všech iteracích na základě předem známých požadovaných vstup-výstupních hodnot. Metody, které pracují s tímto přístupem dat jsou dále rozděleny do dvou skupin:

Metody prvního řádu: Tato skupina metod pouze rozvíjí gradientní informaci o kritériu. Gradientní nebo prudce klesající metoda byla popsána. Konkrétní implementace metody se nazývá zpětně-propagační algoritmus.

Metody druhého řádu: Tato skupina metod využívá také derivaci druhého řádu (Hessiánova matice) nebo jejich několika aproximací. K této skupině metod patří např. Newtonova metoda, quasi-Newtonova metoda, Gauss-Newtonova metoda, pseudo-Newtonova metoda a Levenberg-Marquardtova metoda. Metody druhého řádu jsou doporučeny z hlediska jejich rychlé konvergence a také proto, že se vyznačují vysokou robustností.

postupný přístup (on-line) - tréninková data jsou při hledání optimálních parametrů neuronové sítě dodávány postupně, v každém iteračním kroku jsou dostupná pouze data aktuální v daném časovém okamžiku. Přístup je využíván v případě, že tréninková data jsou závislá na aktuálním dynamickém chování modelovaného systému, jehož vlastnosti se v čase mění. [3]

1.10 Postup při tvorbě umělé neuronové sítě

Při tvorbě umělé neuronové sítě je potřeba zadat množinu učicích dat. V závislosti na požadovaných výstupních parametrech a požadované funkci umělé neuronové sítě se musí nadefinovat samotná struktura umělé neuronové sítě (počet vrstev). Každé vrstvě je přiřazen počet neuronů a přenosová funkce. Dalšími definovanými prvky umělé neuronové sítě je počet učicích cyklů (epoch), případně hodnota střední kvadratické chyby MSE

1.10.1 Volba typu umělé neuronové sítě a její struktury

V současnosti existuje řada typů neuronových sítí, avšak některé z hlediska jejich principu činnosti nejsou v oblasti identifikace a modelování systémů použitelné, protože počet jejich parametrů je příliš velký (časová náročnost na stanovení výstupu neuronové sítě a hledání optimálních hodnot parametrů. Neuronové sítě mají své parametry, jejichž hodnoty musí být nastaveny dle řešené problematiky. Jestliže bude počet parametrů příliš velký, je obtížné najít optimální parametry sítě, proto z hlediska jednoduché aplikovatelnosti neuronových sítí se využívá nejčastěji dopředná perceptronová síť. Rekurentní síť nachází své uplatnění v oblasti optimalizace a robotiky.

Struktura dopředné sítě opět z hlediska požadavku minimálního počtu parametrů zpravidla využívá pouze dvě vrstvy. Ve skryté vrstvě se z principu činnosti umělé neuronové sítě využívá nelineární aktivační funkce a ve výstupní vrstvě se využívá lineární aktivační funkce pro upravení výsledného rozsahu hodnot na výstupu sítě. Nelineárních aktivačních funkcí existuje řada. V rámci časové náročnosti při řešení příkladů řízení základních systémů byla použita pouze tansigmoidální aktivační funkce, která je aplikována nejčastěji. Záměrem je v budoucnosti provést podrobné zhodnocení použitelnosti aktivačních funkcí pro řízení jednotlivých základních typů systémů a uživateli a čtenáři této publikace nabídnout pouze ty nejvýkonnější aktivační funkce.

Počet a typ vstupů neuronové sítě se řeší v rámci volby vhodné struktury modelu. Počet neuronů ve skryté vrstvě se zpravidla zvyšuje od nejnižšího možného počtu (2 skryté neurony) až po potřebný počet, kdy se ještě prudce snižuje výsledná hodnota minimalizačního kritéria a vzrůstá kvalita neuronové sítě. Pokud je při dalším zvyšování počtu neuronů rozdíl výsledných hodnot minimalizačního kritéria malý, případně může také hodnota minima-

lizačního kritéria narůstat, pak je další zvyšování počtu skrytých neuronů nadbytečné a vede na jev zvaný přetečení ("overfitting"). [3]

1.10.2 Tréninková a testovací množina dat

Sestavení tréninkové a testovací množiny dat je pro výsledný neuronový model velmi důležitou fází při hledání optimálního neuronového modelu. Předávaná data představují učebnici a tréninkový algoritmus pak učitele pro předání potřebných informací k dosažení naučeného modelu schopného provádět potřebnou činnost. Jestliže se v učebnici vyskytuje překlep (porucha nebo šum při získávání dat), pak se projeví na nevhodném chování modelu.

Tréninková množina dat je složena z vektorů požadovaných vstupních a požadovaných výstupních dat takových, které umožní získání parametrů neuronové sítě pomocí algoritmu trénování tak, aby tato neuronová síť měla požadované vlastnosti. Rozsah vstupního signálu a následně získaného výstupního signálu by měl pokrývat celou pracovní oblast. V případě, že část této pracovní oblasti nebude obsažena v rámci dat tréninkové množiny, pak v této části oblasti bude neuronová síť vykazovat špatné hodnoty a to v důsledku nesprávně zvoleného rozsahu dat v tréninkové množině. Při trénování neuronové sítě rozhodně nevádí rozsah, který bude např. 50% zasahovat mimo pracovní oblast, pokud je to možné. Mnohem nepříznivější situace nastane, pokud požadované vstupní a výstupní signály nepokrývají celou pracovní oblast.

Fáze experimentu představuje u simulačních příkladů základních systémů generování odezvy systému na zvolený signál tak dlouho, dokud nebudou splněny některé nezbytné požadavky:

Získání dostatečného množství dat, která budou pokrývat dostatečným počtem dat celý pracovní rozsah, v němž má model pracovat.

Odstranit poruchy a šum (v případě reálných systémů),

Odstranit nežádoucí data nebo skupinu dat, podle nichž by se model naučil nevhodnému chování.

Malé množství dat bude znamenat, že nebudou předány všechny potřebné informace o modelovaném systému, takže výsledný model nebude postačující. Velké množství dat může znamenat, že dojde k duplicitním informacím o modelovaném systému, které nebudou v rámci přesnosti zcela stejné, pak při učení nebude zřejmé, která ze dvou takřka duplicitních informací s malou odlišností v nižších řádech, je ta správná informace. Hledání kompromi-

su mezi nimi bude mít za následek rovněž nevhodné chování modelu. Správně by měla být každá dvojice hodnot jedinečná. Ve skutečnosti je tento náročný požadavek vyřešen v principu samotnou strukturou neuronové sítě, která obsahuje jako vstupy také minulé hodnoty. Při praktickém provedení experimentu pro základní typy systémů je postačující jako nejmenší množství dat 50 vzorků tréninkové množiny dat pro systémy proporcionální se setrvačností 1. řádu, pro ostatní typy systémů tento počet vzrůstá maximálně na 500 vzorků. [3]

1.10.3 Trénování neuronového modelu

Vybraný algoritmus trénování má také vliv na získání nejlepšího modelu pro daný systém. V odborné literatuře bylo publikováno již mnoho testů na vhodný typ tréninkového algoritmu pro různé typy neuronových sítí. V případě proporcionálních sítí má nejlepší výsledky při trénování Levenberg-Marquardtův algoritmus.

Časová náročnost tréninkového algoritmu závisí na počtu vzorků tréninkové množiny dat, protože v každé iteraci tréninkového algoritmu se pracuje se všemi vzorky dat, a na celkovém počtu iterací tréninkového algoritmu.

Zcela zásadní vliv na kvalitu výsledku má počáteční nastavení parametrů neuronové sítě, což je mnohem podstatnější než algoritmus trénování. Protože není možné na začátku zvolit takové parametry, které by vedly k nalezení globálního minima v prohledávaném prostoru možných řešení, jediným možným řešením je vždy pro každý hledaný model provést několikrát trénování na základě stejné tréninkové množiny dat a stejné struktury neuronové sítě, ale s jinými počátečními parametry. Z takto získaných kandidátů na model neuronové sítě pak vybrat nejvhodnější model s nejlepšími výsledky testování modelu. [3]

1.11 Využití neuronových sítí

Umělé neuronové sítě se během doby, kdy byl již takřka před sto lety vypracován jejich první model rozšířily do mnoha technických i vědních oborů. V praxi se neuronové sítě nejvíce využívají ke klasifikaci, funkční aproximaci, nebo modelování funkcí při použití množství trénovacích dat.

Tab. 2 Tradiční použití neuronových sítí

Úloha	Vhodné neuronové sítě
Logické obvody	HEEB, HAMM, MLP1
Odstranění šumu	MLP1, MLP2, RBF, MOD
Řeč a výslovnost	MLP2, SOM
Komprese	COUNT
Dolování dat (data mining)	OLAM, HEBB, SOM
Optické rozpoznání znaků	HEEB, OLAM, HAMM, MLP1, MLP2, RBF, SOM

Neuronové sítě jsou nyní nejvíce využívány v těchto odvětvích lidských činností:

Inženýrství – automatické řízení, zpracování signálů; řízení výroby, rozpoznávání textů, písma, obrazů.

Kriminalistika – otisky prstů

Ekonomika – Modelování vývoje trhu, tj. předpověď vývoje kurzů a cenných papírů; rozhodování o přidělování půjček a nebo při určování velikosti splátek i ověřování podpisů na šecích.

Fyzika – Modelování jevů ve statistické mechanice.

Chemie – Předpověď fyzikálně-chemických vlastností sloučenin; řízení chemické výroby; analýza dat z analytických měřících přístrojů; analýza spektroskopických dat-klasifikace sloučenin; předpověď sekundární a terciální struktury proteinu.

Biologie – Interpretace nukleových sekvencí.

Statistika – Flexibilní lineární a nelineární regrese a klasifikace

Lékařství – Návrh diagnózy na základě příznaků a výsledků laboratorních vyšetření, tj. diagnóza testů na rakovinu; analýza rentgenových snímků.

Neuropsychologie – Modelování psychických funkcí

Neurofyziologie – zkoumání sensorických systémů motoriky, rozpoznávání a produkce řeči; modelování neurofyziologie mozku.

Další oblastí využití je zemědělství (ohodnocení a třídění ovoce); meteorologie (předpověď počasí); astronomie (klasifikace galaxií).

Plastikářský průmysl – Umělé neuronové sítě se v plastikářském průmyslu používají zejména pro optimalizaci, kontroly průmyslového zpracování plastů, vývoj polymerních kaučuků, zpracování naměřených dat, řízení technologického procesu při zpracování plastů a testování a identifikace plastů. [5]

Řízení procesů

Adaptivní regulátor, regulace s otevřeným regulačním obvodem, regulace s uzavřeným regulačním obvodem, diagnostika poruchy, chemická produkce, vstřikovací strojní operace, ropná destilace, čištění odpadních vod.

Kvalita kontroly a průmyslová kontrola

Testování plastů, sledování cíle, kontrola kvality potravin, kontrola kvality vůně parfémů, sledování chemických barviv v textilním průmyslu, analýza počítačových čipů, kontrola kvality nápojů.

Optimalizace a analýza

Produkce časového rozvrhu, produkce pro laboratoře, časové rozvržení oprav strojů, analýza předpovědi poruch strojů, optimální návrh výrobku (produktu). [5]

2 LASER

Slovo laser pochází z angličtiny. Je složené z počátečních písmen anglického názvu: Light Amplification by Stimulated Emission of Radiation, což by se dalo přeložit jako zesílení světla pomocí vynucené (stimulované) emise záření. Český název pro laser je kvantový generátor světla. Z názvu je zřejmé, že laser vydává světlo. Laserové světlo je monochromatické (jednobarevné) koherentní (uspořádané) a má malou divergenci (rozbíhavost). Laser je zařízení, které přeměňuje dodávanou energii na laserové světlo.

Energii můžeme dodávat různým způsobem, například opticky (světlem výbojky), chemicky, elektricky atd. Vzhled samotných laserů je velmi různorodý. Záleží hlavně na druhu laseru, na jeho konstrukci a v neposlední řadě na jeho použití.

Laser je vynálezem dvacátého století a za čtyřicet let své existence se stal nedílnou součástí našeho života. Setkáváme se s ním v mnoha oborech lidské činnosti. Předměty opracované laserem potkáváme na každém kroku a ani si někdy neuvědomujeme, že právě předmět, který držíme v ruce, má něco společného s laserem.

Výkon laseru je množství vyzářené energie za určitý čas, označuje se ve wattech (W). Množství vyzářené energie se udává v jednotkách zvaných joule (J). Jestliže svítí laser nepřetržitě, většinou vystačíme s pouhým označením výkonu. Jestliže však laser pracuje v krátkých záblescích, které trvají milisekundy (ms) až pikosekundy (ps) a dokonce i femtosekundy (fs), je pro odborníky důležité vědět, jak kratičké jsou a jak je velká vyzářená energie. Čím kratší je doba trvání záblesku, tím větší je špičková energie a výkon. Tak je možné v nepatrném zlomku sekundy vyzářit veliké množství energie (nejen jednotky, desítky, stovky, ale i tisíce joulů). Výkony laserů se v takových případech pohybují nejen ve wattech (W), kilowattech (KW), ale i megawattech (MW), gigawattech (GW) a dokonce i v terawattech (TW).

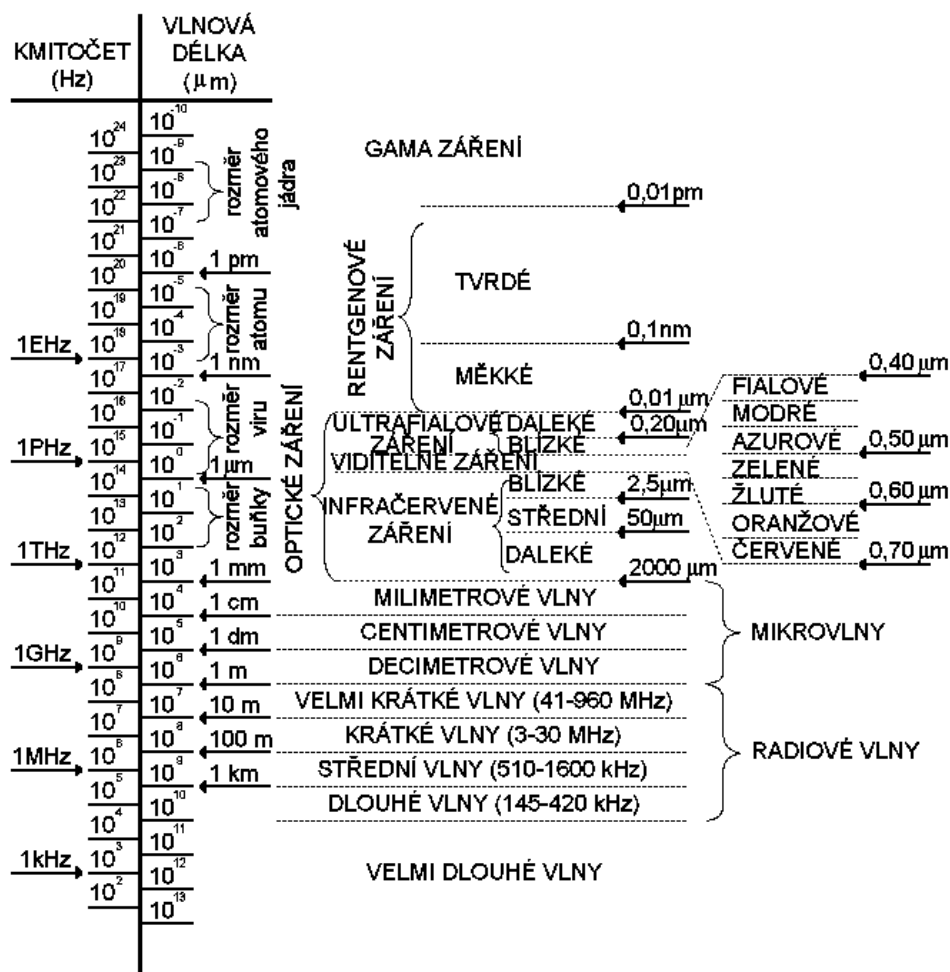
Účinnost je poměr mezi množstvím energie dodané do zařízení a množstvím energie, které z něho vystupuje. V různých typech laserů totiž dochází k různě velkým ztrátám. Účinnost laserů, která se pohybuje v rozmezí od 0,1% do 80%, je často hlavním faktorem pro jejich použití. Významná je především v případech, kdy je důležitý vysoký výstupní výkon laserů, tj. při použití tzv. výkonových laserů. Do laseru musíme sice přivádět více energie než jí získáme, ale vyplatí se to. Laser totiž opouští paprsek zvláštních a pro nás výhodných vlastností. Jsou to monochromaticnost (jednobarevnost), koherence (uspořádanost) a malá

divergence (rozbíhavost). Díky těmto charakteristickým vlastnostem nacházejí lasery stále větší uplatnění v nejrůznějších oborech.

Vlnové délky laserového záření spadají od mikrovlnné oblasti přes infračervené tepelné záření a viditelné světlo až po rentgenové paprsky (viz Obr. 13). Energetický potenciál laserového paprsku může být použit k obrábění i těžce obrobitelného materiálu a předpokládá se, že prostřednictvím laserového paprsku bude možné uvolnit také energie skryté v jádru atomu. Laser je tedy přístroj zkonstruovaný na principech kvantové mechaniky, generující záření zcela unikátních vlastností, které má nesčetné množství aplikací.

Elektromagnetická vlna se šíří ve vakuu rychlostí $c = 2,997925 \cdot 10^8 \text{ m} \cdot \text{s}^{-1}$.

Čím menší je vlnová délka záření, tím větší je energie fotonu a hmotnost (hybnost) fotonu. Radiové vlny o frekvenci 100 MHz nedokáží vlivem své malé energie změnit vodivost např. u fotodiody. Ale světlo (430-750 MHz) má již dostatek energie, aby změnu vodivosti provedlo.



Obr. 13 Spektrum elektromagnetických vln

2.1 Historie vzniku laseru

Cesta, která vedla k sestrojení prvního přístroje, začala už před staletími. O světelný paprsek se s zajímali už staří Řekové, ovšem znalosti o podstatě světla se až do 17. století nijak podstatně nezměnily.

Teprve až v 17.století se podařilo Isaacu Newtonovi rozložit bílé světlo skleněným hranolem na spektrum barev a ukázal, že se bílé světlo skládá z mnoha barev. Newton si tehdy představoval, že světlo má korpuskulární (částicový) charakter. Se svou teorií dokázal vysvětlit všechny tehdy známé vlastnosti světla, jako je odraz, lom a další.

Jeho současník Christian Huyghes však podstatu světla viděl ve vlnění, které se šíří prostorem stejnou rychlostí všemi směry z každého bodu na povrchu svítícího tělesa. Měl také pravdu. Spor rozhodl až v 19.století svými pokusy s ohybem a interferencí světla Thomas Young. Interference je záležitost čistě vlnová, je to vlastně interakce (vzájemné působení) dvou stejných světelných vln (stejnou frekvenci a amplitudu) v daném okamžiku a místě. Vlnové rozruhy se vzájemně sčítají. Setkají-li se ve fázi, je výsledkem zesílení, v proti fázi zase zeslabení.


Co se vlastně vlní? Na tuto otázku odpověděl na přelomu padesátých a šedesátých let 19. století svými výpočty James Clerk Maxwell. Svou teorií překlenul propast mezi optickými a elektromagnetickými jevy. Z jeho teorie vyplynulo, že světlo není nic jiného než vlnění elektromagnetického pole.

Se senzační hypotézou přišel v roce 1900 Max Planck. Prohlásil, že záření, světlo, je tvořeno malými částčkami energie – „kvanty“. Energie každého kvanta je úměrná kmitočtu záření. Tak byly položeny základy kvantové fyziky. Podle ní má světlo charakter vlnový a korpuskulární (částicový).

Planckova kvanta energie byla později nazvána fotony. Fotony letí prostorem a při srážce s jinou částicí se chovají jako částice. Mezi sebou se však fotony interferují jako vlny. Planckova hypotéza však nevysvětlovala principy vyzařování a pohlcování záření atomy. To se povedlo v letech 1912 – 1913 dánskému fyzikovi Nielsnu Bohrovi. Ten vypracoval planetární model vodíku, podle něhož obíhají elektrony kolem jádra po vymezených drahách podobně jako planety kolem slunce. Přeskočí-li elektron z jedné dráhy na druhou, může atom získat nebo ztratit energii v podobě elektromagnetického záření. Energie atomu se změní právě o vyzářené nebo pohlcené kvantum.

Historie laseru začíná v roce 1917, kdy Albert Einstein ukázal, že kromě jevů jako jsou spontánní emise a absorpce, musí existovat ještě stimulovaná emise. Následující krok směrem k vynálezu laseru udělal ruský fyzik V.A. Fabrikant, který v roce 1939 poukázal na možnost použití stimulované emise k zesilování elektromagnetického záření procházejícího prostředím. Později v roce 1951, spolu s M.M. Vudynským a F.A. Butajevovou přihlásili patent na metodu zesilování elektromagnetického záření (ultrafialového, viditelného, infračerveného a pásma radiových vln) tím způsobem, že záření prochází prostředím, ve kterém je vytvořen nerovnovážný stav. Stav takového charakteru, že je preferováno obsazení horních energetických stavů atomů. popř. jiných elementů prostředí.

Po prve byla tato idea realizována pro zesilování záření v mikrovlnné oblasti. V roce 1952 moskevští fyzikové N.G. Basov a A.M. Prochorov na konferenci o radiospektroskopii referovali o molekulárním svazkovém generátoru – MASERu pracujícím se svazkem molekulárního čpavku. Prakticky současně byla vyjádřena myšlenka použití stimulované emise k zesílení a generaci milimetrových vln americkým fyzikem Ch.H. Townesem. V roce 1954 byl sestrojen první molekulární generátor. Realizace maseru dala vznik novému vědnímu oboru – kvantové elektronice. Basov, Prochorov a Townes dostali společně za vynález maseru Nobelovu cenu v roce 1964. [10]



Obr. 14 Fotografie prvně sestrojeného laseru (Theodore Maiman)


Mezi realizací prvního maseru a prvního laseru uplynulo šest let. V roce 1955 Basov a Prochrov navrhli optické buzení a prostředek pro dosažení populační inverze. V roce 1957 pak

Basov uvažoval o využití polovodičových materiálů pro kvantové oscilátory a realizoval optický rezonátor leštěnými planoparalelními stěnami na polovodičovém čipu. V témže roce Fabrikant a Butajevová pozorovali zesílení optického záření v experimentu s elektrickým výbojem procházejícím směsí par rtuti, vodíku a helia. V roce 1958 Prochorov, Schawlow a Townes vyslovili nezávisle na sobě ideu, že jev stimulované emise, užitý v maseru, může být použit i v infračervené a optické oblasti spektra. R.H.Dicke (Princeton University) navrhl použití otevřeného rezonátoru pro realizaci kladné zpětné vazby v optické oblasti. V roce 1960 Theodore Maiman publikoval článek o generaci záření ve viditelné oblasti světla v rubínové tyči. Byl vynalezen rubínový laser. V témže roce (1960) A.Javan, W.R.Bennett a D.R.Herriott demonstrovali laserová akce ve směsi plynů helia a neonu. V roce 1960 se podařilo zkonstruovat první vodíkový maser. Od roku 1961 začal bouřlivý vývoj různých typů laserů zároveň s vývojem laserové technologie. První polovodičový laser byl sestaven v roce 1962. V České republice se maser objevil v roce 1962 a laser o rok později. [6]

2.2 Základní pojmy

Laser (Light Amplification by Stimulated Emission of Radiation) představuje zesílení elektromagnetického záření pomocí vynucené (stimulované) emise. Laserové světlo je monochromatické (jednobarevné) koherentní (uspořádané) a má malou divergenci

Z definice vyplývá, že laser je zařízení, které přeměňuje dodávanou energii na laserové světlo. [12]



Obr. 15 Srovnání světla vyzařovaného laserem se světlem žárovky

FOTON – představuje nejmenší částičku (kvantum) světla. Podle principů kvantové mechaniky není možné dělit energii nesenou elektromagnetickým zářením do nekonečna.

Energie fotonu je dána vlnovou délkou příslušného elektromagnetického záření. Čím kratší je vlnová délka, tím větší je energie fotonu

ZÁKLADNÍ STAV - základní stav kvantové soustavy je stav s nejnižší energií. Není-li kvantová soustava vystavena vnějšímu působení, je pravděpodobné, že se nachází právě v tomto stavu.

EXCITOVANÝ STAV – excitovaný stav kvantové soustavy je takový, kdy je její energie vyšší než v základním stavu. Energie kvantové soustavy může nabývat různých hodnot z určité množiny povolených stavů. Tato množina tzv. energetických hladin je z principu diskrétní, ale v některých případech natolik hustá, že se hovoří o kvazispojitém spektru elektromagnetických hladin. Tento stav není trvalý a kvantová soustava po čase samovolně přechází do stavu s nižší energií – excituje se.

EXCITACE – děj, při kterém přechází kvantová soustava ze stavu s nižší energií do stavu s vyšší energií. K tomu, aby tento děj nastal musí kvantová soustava přijmout zcela přesné množství tzv. excitační energie charakteristické pro daný přechod, odpovídající rozdílu energie kvantové soustavy před a po excitaci. Excitace (vzbuzení) kvantové soustavy lze dosáhnout různými prostředky. Opačný proces se nazývá deexcitace. Při tomto ději kvantová soustava energii uvolňuje.

AKTIVNÍ PROSTŘEDÍ LASERU – je systém kvantových soustav schopných pod vlivem přívodu excitační (budící) energie přejít do excitovaného stavu a setrvat v něm dostatečně dlouhou dobu.

BUZENÍ – je způsob, jakým je do aktivního prostředí dodávána excitační energie. Způsob buzení závisí na použitém aktivním prostředí. Buzení může být zajištěno optickým zářením, elektrickým výbojem, elektronovým svazkem, chemickou reakcí, expanzí plynu atd. Zdroje buzení mohou pracovat jak kontinuálně, tak pulzně.

LASEROVÝ REZONÁTOR – je soustava minimálně dvou zrcadel zajišťující kladnou zpětnou vazbu záření do aktivního prostředí. Jedno zrcadlo má obvykle co největší reflexi pro odpovídající vlnovou délku laserového záření. Reflexe druhého se řídí způsobem vyvážení energie z rezonátoru.


LASEROVÝ PAPERSEK – normální zdroj světla, například žárovka, emituje zcela neuspořádané široké spektrum různých vlnových délek od ultrafialového záření až k infračerveným tepelným paprskům. Souhrn těchto paprsků vnímá lidské oko jako žlutobílé světlo šířící se mnoha směry. Laser naproti tomu vysílá velmi směrové monochromatické energetické koherentní paprsky, které se jinak v přírodě nevyskytují.

KOHERENTNÍ ZÁŘENÍ – od běžného nekoherentního světla se liší tím, že na dlouhém úseku mezi jednotlivými vlnami laserového paprsku existuje pevná časová a prostorová vazba fáze. Zatím co světlo běžných zdrojů je chaotické, laserové světlo je zvláštním způsobem uspořádané.

INVERZE POPULACE ENERGETICKÝCH HLADIN - uvnitř aktivního prostředí je nutnou podmínkou pro to, aby docházelo k zesilování světla. Nastává v okamžiku, kde jsou v aktivním prostředí vyšší měrou zastoupené excitované kvantové soustavy oproti soustavám v základním stavu.

ZISK AKTIVNÍHO PROSTŘEDÍ – charakterizuje úroveň inverze populace hladin, respektive schopnosti zesilovat záření.

ABSORPCE - foton při střetu s atomem odevzdá svoji energii, atom přejde na vyšší energetickou úroveň, na níž může jistou, ale omezenou dobu setrvat (doba života vzbuzeného atomu).




Obr. 16 Absorpce, spontánní a stimulovaná emise

EMISE - při návratu vzbuzeného atomu na svoji původní energetickou úroveň, dojde k předání rozdílové energie buď vyzářením (zářivý přechod) nebo ve formě tepla (nezářivý přechod).

SPONTÁNNÍ EMISE - v případě většího souboru částic jednotlivé atomy absorbují a emitují fotony nezávisle na sobě. Vzniklé záření má zcela náhodnou fázi, frekvenci, amplitudu, je nekoherentní a nemonochromatické. Příkladem zářivého přechodu je LED dioda, zářivka, žárovka. Příkladem nezářivého přechodu je ohřívání těles při absorpci slunečních paprsků.

STIMULOVANÁ EMISE - možnost stimulované emise poprvé popsal Einstein (1917). Předpokládal, že atom byl při nějakém předchozím aktu absorpce převeden na vzbuze

úroveň, na níž v důsledku konečné doby života setrvává. A právě v tomto okamžiku na tento atom dopadne foton, jehož energie přesně odpovídá energetickému rozdílu mezi "původní" a "vzbuzenou" hladinou atomu. Dopadající foton stimuluje vzbuzený atom k návratu na původní hladinu a k vyzaření fotonu, který má stejné vlastnosti (frekvenci a fázi) jako dopadající. Výsledkem jsou dva stejné fotony. [10]



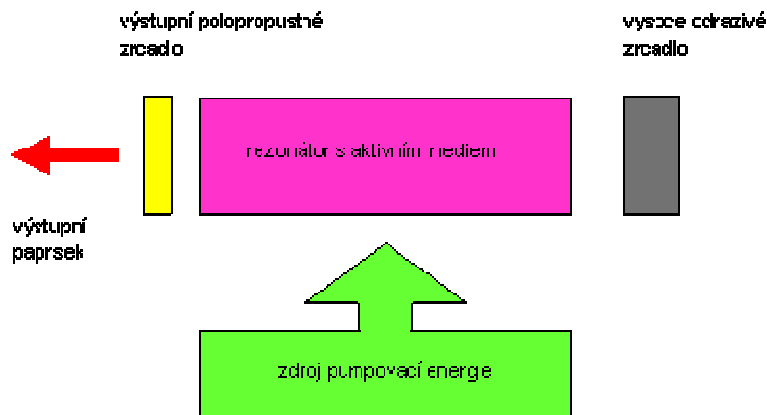
Obr. 17 Základní stav atomu

2.3 Konstrukční složení laseru

Každý laser se skládá ze tří částí : z aktivního prostředí, z budícího zdroje a z rezonančního systému.

Aktivním prostředím laserů může být pevné, kapalné, nebo plynné prostředí. Aktivní prostředí je jedna z nejdůležitějších částí laseru, protože v něm vzniká stimulovaná emise.

Zdroje buzení aktivního prostředí jsou různé a to podle toho, zda jde o krystalový, nebo plynný laser. Pro krystalový laser se jako zdroje buzení užívá výboje, pro plynný laser je zdrojem buzení vysokofrekvenční generátor, který ionizuje plynné prostředí. Buzení aktivního prostředí je třeba proto, aby se atomy nebo ionty tvořící toto prostředí přivedly do nabuzeného stavu.




Obr. 18 Základní konstrukce laseru

Rezonanční systém je v podstatě tvořen rovinnými zrcadlovými stěnami na krystalový laser přímo napařenými, nebo u plynného laseru uzavírajícími výbojovou trubici. Rezonanční systém spolu s aktivním prostředím tvoří Fabryho-Perotův interferometr. [10]

2.3.1 Tvar paprsku laseru

Tvar paprsku laseru je určen tvarem zrcadel rezonátoru, případně optickou soustavou na výstupu laseru.



Obr. 19 Tvar paprsku laseru

2.4 Typy, rozdělení a popis laserů

Lasery mohou být klasifikovány dle mnoha hledisek, např.:

podle aktivního prostředí :

pevnotátkové lasery

polovodičové lasery

plynové lasery

kapalinové lasery

plazmatické lasery

podle vlnových délek optického záření, které vysílají :

infračervené lasery

lasery viditelného pásma

ultrafialové lasery

rentgenové lasery

podle typu kvantových přechodů (energetických hladin zúčastněných při laserovém kvantovém přechod) :

molekulární(rotační, rotačně-vibrační, vibrační)

elektronové

jaderné

podle typu buzení - lasery buzené :

opticky

elektronovým svazkem

elektronovým svazkem

tepelnými změnami

chemicky

rekombinací

injekcí nosičů náboje

podle délky generovaného impulsu – lasery :

s dlouhými impulsy

s krátkými impulsy

s velmi krátkými impulsy (pikosekundové, femtosekundové)

2.4.1 Pevnolátkové lasery


2.4.1.1 Rubínový a neodymový laser

Rubínový laser byl první realizovaný laser. Jako aktivní je zde rubín

Rubín je vlastně safír (Al_2O_3), v němž malá část trojmocných iontů hliníku je změněna v ionty chrómu. Podle jejich koncentrace se mění i zbarvení rubínu. U krystalů pro průmyslové použití je koncentrace asi 1/2 hmotnostních, zbarvení je temně červené, pro laserové krystaly je koncentrace nízká, jen 0,05%, zbarvení je růžové,. Doba života aktivní částice na vzbuzevané úrovni je poměrně dlouhá ($t = 3$ ms při pokojové teplotě) a zvětšuje se s klesající teplotou ($t = 4,2$ při 3K). [10]

Tab. 3 Základní fyzikální vlastnosti růžového rubínu [10]


Koncentrace Cr^{3+}	0,05% hm., tj. $1,6 \cdot 10^{19}$ částic $\cdot \text{cm}^{-3}$
Teplota tavení	2040 °C
Hustota	3,98 g $\cdot \text{cm}^{-3}$
Teplotní roztažnost	$6,7 \cdot 10^{-6} \text{ } ^\circ\text{C}^{-1}$
Tepelná vodivost	0,092 cal $\cdot \text{cm}^{-1} \cdot ^\circ\text{C} \cdot \text{s}$ při 300K 2,3 cal $\cdot \text{cm}^{-1} \cdot ^\circ\text{C} \cdot \text{s}$ při 77K
Modul pružnosti	$5,5 \cdot 10^7$
Permitivita	11,5
Index lomu n_0	1,763 při $\lambda = 700\text{nm}$
Teplotní závislost n	$1,6 \cdot 10^{-6} \text{ } ^\circ\text{C}^{-1}$



Obr. 20 Schéma rubínového laseru [10]

2.4.1.2 *Kontinuální Nd:YAG laser*

Nd:YAG laserový systém, pracuje na vlnové délce 1,06 μm . Celková účinnost kontinuálních, opticky buzených laserů není vysoká. Pohybuje se v rozmezí 0,1 až 4%, většinou však 1%. Je tedy důležité vědět, kde, kolik a na co se energie spotřebuje (téměř veškerá na teplo). Posléze se zaměřit na její minimalizaci. A tím také zabránit poškození nebo zničení částí laseru. [10]



Obr. 21 Základní schéma kontinuálního Nd:YAG laseru [10]

Části kontinuálního Nd:YAG laseru

Kontinuální Nd:YAG lasery jsou k dostání s výkony od několika miliwattů po kilowaty. Ačkoliv jsou od sebe poměrně rozdílné, všechny pracují na stejném principu, jak ukazuje Obr. 21. Aktivním materiálem je tyčka z yttrio-hlinitého granátu, v němž je část trojmocných iontů yttria (+) substituována trojmocnými ionty (+) chrómu. Tyčka je buzena opticky (kontinuálně). Tyčka je umístěna mezi dvěma zrcadly rezonátoru.

Tyčka aktivního materiálu

Tyčky, pro Nd:YAG lasery mají obvykle 1 až 4 mm v průměru a jejich délka se pohybuje od 25 do 150 mm. Preferují se menší průměry, pro menší nároky na chlazení. Obvykle jsou konce tyčky opatřeny antireflexní vrstvou pro vlnovou délku 1,06 μm , na níž laser emituje. Tyčka se umístí do křemenné nebo skleněné water jacket. Chladí se průtokem vody po povrchu tyčky. Konce tyčky jsou těsně uchyceny O-kroužky, které je chrání před světlem optického čerpání.

Systém optického čerpání

Optická čerpací lampa pro Nd:YAG lasery je buď křemeno-halogenová lampa nebo kryptonová arc lampa. Při použití křemeno-halogenové lampy se chladí její konce. Kryptonové arc lampy jsou obecně ve vlastní water jacket a chladí se jejich katoda. Lampy jsou uvnitř budící dutiny (většinou eliptické), která je také vodou chlazená nebo v některých typech zaplavená. Eliptická dutina může být povlakována jedním z několika materiálů. Zlato má nejlepší odrazivost, ale není trvanlivé. Častá je chromová ražba, která je kompromisem mezi odrazivostí a stárnutím. Běžné jsou i dutiny dvojeleptické.

Optický rezonátor

Rezonátor Nd:YAG laseru se obecně skládá ze dvou zrcadel, které jsou umístěny odděleně od konců aktivního materiálu. Na výběr je několik rezonátorů, ale všechny mají alespoň jedno sférické zrcadlo. Běžně se používají dvě zrcadla s velkým rádiusem. Totálně odrazné zrcadlo (HR) má odrazivost kolem 99,9% a odrazivost výstupního, "polopropustného", se pohybuje kolem 99% u malých, a kolem 91% u velkých laserů. Optické rezonátory Nd:YAG laserů jsou většinou seřiditelné nebo vyměnitelné pro multimódový nebo TEM00 režim.

Chladicí systém

Chladicí systém je jeden z nejdůležitějších subsystémů laseru. Malé lasery jsou většinou osazeny otevřeně cirkulujícím systémem. V těchto případech by voda měla být přefiltrována, aby se zabránilo kontaminaci nebo znečištění. Větší laserové systémy používají uzavřený okruh, kde médiem je buď voda nebo roztoku vody a ethylenglykolu (1,2-Ethandiol - "glykol"). Médium se ochlazuje mražením, ale běžně se chladí i vodními nebo vzduchovými výměníky. Chladicí médium proudí od tyčky aktivního materiálu (pro její maximální ochlazení) přes lampu do dutiny. Zastavení ochlazování rychle vede ke zničení uchycení trubičky, lampy i trubičky samotné.

Energetické ztráty v Nd:YAG laseru

Kvantová účinnost je energie výstupního fotonu dělená energií potřebnou k jeho emisi. V případě Nd:YAG laseru je energie výstupního fotonu dělená energií fotonu z čerpací lampy.

Provozní účinnost h kontinuálního laseru je dána rovnicí: [10]

$$h = \frac{P_{out}}{P_{in}} \cdot 100 \quad [\%] \quad (2)$$

kde P_{out} je výstupní výkon vyzářeného světla a P_{in} je vstupní elektrická energie. Měření se provádí za ustálených podmínek, zejména teploty.

2.4.2 Kapalinové lasery

2.4.2.1 Aktivní prostředí

Aktivním prostředím kapalinových laserů jsou z převážné části roztoky organických barviv nebo speciálně připravené kapaliny dopované ionty vzácných zemin. Aktivním prostředím jsou ionty organických barviv v různých kapalných rozpouštědlech, jakými jsou např. voda, etylalkohol, metylalkohol, toulén, benzen, aceton, cyklohexan, glycerin a další. Nejznámějším a prakticky nejdůležitějším aktivním prostředím barvivových laserů je Rhodamin 6G. Patří ke skupině xanthenových barviv. Významnou charakteristikou barvivových laserů je šířka čáry generované vzhledem k šířce čáry luminiscenční. Tak jako u pevnolátkových laserů i barvivové lasery mají šířku absorpční a luminiscenční čáry v okolí 0,1 μm . Šířka generované laserové čáry ovšem může být až řádu 10-4 μm nebo menší. Generovaná vlnová délka může být tedy měněna spojitě uvnitř hranic daných šířkou luminiscenční čáry. Lasery, u kterých generovaná vlnová délka může být plynule měněna, nazýváme lasery přeladitelnými. [6]

2.4.2.2 Buzení barvivových laserů

Pro buzení barvivových laserů se užívá optického záření. Optické buzení těchto laserů je nekoherentní nebo koherentní, pulsní nebo kontinuální a příčné nebo podélné.

Při koherentním buzení je barvivové aktivní prostředí ozařováno zářením pomocného laseru na kmitočtu odpovídajícím absorpčnímu pásmu daného barviva. Účinnost barvivových laserů buzených koherentně zářením pomocného laseru dosahuje řádu desítek procent.

Při nekoherentním čerpání se pro buzení barvivových laserů užívá podobného uspořádání jako u pevnolátkových laserů. Účinnost nekoherentně čerpaných barvivových laserů dosahuje maximálně 10%. [6]

Využití barvivových laserů

Použití barvivových laserů je především ve spektroskopii. Novou aplikací je využití možnosti naladění přesné vlnové délky v medicíně – ve fotodynamické terapii, kdy se působením záření přesné vlnové délky ničí rakovinotvorný nádor předem „napuštěný“ speciálním

organickým barvivem (barvivo se působením záření rozpadá a volný generovaný kyslík ničí rakovinotvorné buňky). [6]

2.4.3 Plynové lasery

Plynové lasery jsou lasery s aktivním prostředím v plynné fázi. Inverze populace hladin je vytvářena mezi energetickými hladinami některé ze složek plynu, tj. atomů (atomární lasery), iontů (iontové lasery), molekul (molekulární lasery). Většina plynových laserů pracuje v kontinuálním režimu, ale byly vyvinuty i lasery s mimořádně vysokým výkonem pracující v impulsním provozu.

Při průchodu aktivním prostředím bývá optický svazek méně deformován než u laserů s kondenzovaným prostředím, neboť plyny jsou obecně homogennější. Nevýhodou plynových laserů je poměrně malá objemová hustota počtu částí, která se odráží v malých objemových výkonech.

Plynové lasery je možné budít:

- elektrickým výbojem
- chemickou reakcí
- fotodisociací
- rychlou expanzí plynu
- průchodem svazku rychlých elektronů
- nebo opticky

2.4.3.1 CO_2 laser

CO_2 laser – aktivními molekulami jsou molekuly oxidu uhličitého. Ke stimulované emisi dochází při kvantových přechodech mezi různými vibračně-rotačními pod hladinami základního elektronického stavu molekuly. Elektrický výboj se zapaluje ve směsi plynů CO_2 , N_2

a He. V klasickém konstrukčním uspořádání bývá základem CO_2 laseru výbojová trubice T s vnitřním průměrem několika centimetrů naplněná směsí plynů $CO_2:N_2:He$ při tlaku několika kPa. CO_2 lasery mají poměrně vysokou účinnost (cca 10%), jsou široce využívané. Vedle elektrického buzení existuje i řada systémů CO_2 laseru založených na jiných principech buzení (např. chemickou reakcí nebo rychlým ochlazením přehřátého plynu).

Aktivním prostředím CO laseru jsou molekuly oxidu uhelnatého. Laserové přechody se uskutečňují mezi vibračně-rotačními hladinami základního elektronového stavu této

dvouatomové molekuly. CO lasery vyzařují infračervené záření v pásmu 5 až 6,5 μm a vyznačují se dobrou účinností a velkými výstupními výkony. Buzení CO laseru je provádí obdobnými metodami jako u CO₂ laseru a to především elektrickým výbojem nebo elektronovým svazkem. V CO laserech, kde nejsou kladeny žádné nároky na spektrální čistotu výstupního svazku, se dosahuje účinnosti až 50 %. Jejich většímu rozšíření brání jedovatost CO. [6]

CO₂ lasery třídy I byly objeveny jako první a dnes patří mezi nejrozšířenější. Běžné CO₂ lasery obvykle obsahují:

- Vodní nebo olejové chlazení dvouvrstvé trubice
- Malý průtok plynu (1-20 litrů za minutu; záleží na velikosti a výkonu laseru)
- Střídavou excitaci, rovnoběžnou s proudem plynu
- Malý proud (3 - 100 mA)
- Malý tlak plynu (1,3 - 4 kPa)
- Průměr trubice 1 - 2 cm
- Výstupní výkon kolem 50 W na metr délky [10]

Nejdůležitější faktor, ovlivňující výstupní výkon je asi jako u každého laseru rychlost odvádění tepla z trubice. Výměnu tepla s okolím zajišťuje helium srážkami s trubicí. Je sice možné chladit trubicí vzduchem, ale vede ke snížení účinnosti laseru. Menší lasery, používané ve výzkumu se zpravidla chladí vodou. Industriální lasery využívají olejového chlazení se sekundárním olej-voda výměníkem pro lepší stabilitu a jednodušší údržbu. Zvýšení proudu vede ke zvýšení teploty trubice nad možnosti chlazení. Zvětšením průměru trubice prodloužíme dráhu od osy ke stěně a znesnadníme heliu odvádět teplo. Nejlepší řešení je zvýšit průtok plynu a chladit ho mimo trubicí. V největších laserových systémech se navíc část plynu vymění za nový.

CO₂ laser o výkonu 10 kW a účinnosti 25% vygeneruje každou sekundu 7500 J parazitní tepelné energie. Tento tepelný výkon ohřeje za 1 hodinu 80 litrů vody k varu. Ohřev způsobuje zejména pokles účinnosti laseru. [10]



Obr. 22 Schéma CO₂ laseru [10]

Legenda k Obr. 22 : T- výbojová trubice, E- elektroda, Z₁- kovové zrcadlo, Z₂- polopropustné zrcadlo

V Tab. 4 je uveden výpis několika pracovních parametrů CO₂ laserů třídy I:

Tab. 4 Pracovní parametry komerčních CO₂ laserů [10]

Aktivní délka [m]	Výstupní výkon [W]	Směs plynu [CO ₂ :N ₂ :He]	Průtok plynu [l.min ⁻¹]	Výkon/délka [W.m ⁻¹]	Průtok vody [l.min ⁻¹]
1	50	1 : 1,5 : 9,3	1,15	50	2
2	100	1 : 1,5 : 9,3	1,15	50	2
5	275	2 : 1,35 : 9,3	4,01	55	10
6	375	1:08:23	4,26	62,5	10
9	525	06:07,7	4,23	58,3	10
18	1000	02:35,3	14,35	55,6	15

Pro CO₂ lasery se používají čtyři optické materiály, jak ukazuje tabulka IV. Germanium nejpoužívanější výstupní vazební člen pro nízkovýkonové lasery (<100 W) protože je relativně levné. Jeho použití pro vyšší výstupní výkony znemožňuje fakt, že pohlcuje část záření, následkem čehož se zahřívá. To vede k ještě větší absorpci a následnému přehřátí. Následuje znehodnocení materiálu.

Tab. 5 Charakteristiky materiálů

Materiál	Absorpce pro 10,6 μm [cm ⁻¹]	Tepelná vodivost [W.cm ⁻¹]	Relativní cena
Ge	0,032	0,59	3,5
GaAs	0,02	0,48	6
ZnSe	0,005	0,18	5
Si	-	1,63	2

Arsenid galia a Selenid zinku se používají pro vysokovýkonové lasery. Arsenid galia má větší optickou propustnost než Galium a snáší vyšší teploty bez poškození. Nevadí mu ani obří impulsy a proto je pro lasery s vyšším výkonem nejpobulárnější. Selenid zinku má výhodu, která spočívá v transmisi viditelného světla. To zjednodušuje nastavení laseru. Obou materiálů se hojně využívá, ale ZnSe má větší zastoupení pro kontinuální CO² lasery. Ať už je použit kterýkoli z nich, je na místě antireflexní vrstva, neboť mají velkou refrakci.

Křemík (Si) nepropouští vlnové délky 10,6 μm , ale má vynikající tepelné vlastnosti a proti ostatním nízkou cenu. Výroba sférických dílů je také jednodušší než u jiných materiálů. Stal se nejpoužívanější pro nízkovýkonové lasery jako vysoce odrazné zrcadlo, ale je nahrazován kovy (Cu, atd.)

Běžné uspořádání zrcadel rezonátoru je v Tab. 6. Kulová zrcadla s velkým rádiusem efektivně využívá trubici a usnadňují jejich nastavení. Planparalelní zrcadla využívají aktivní medium nejlépe, ale problémy vznikají při jejich seřizování. Tyto varianty se aplikují na lasery, jejichž výkon se pohybuje kolem 1 kilowatu. Jako kompromis mezi nimi jsou zrcadla,

z nichž jedno je rovinné a jedno sférické. Tato varianta se uplatňuje ve většině systémů. U laserů s vyššími výstupními výkony (>150 W) se používají kovová zrcadla, chlazená vodou. [10]

Tab. 6 Konfigurace zrcadel rezonátoru [10]

Výstupní výkon [W]	Výstupní zrcadlo - rádius [m] / odrazivost [%]	Rádius vysoce odrazivého zrcadla [m]	Konfigurace dutiny
50	∞ / 85	10	Planárně sférický
100	∞ / 85	10	Sférický s velkým rádiusem
250	∞ / 65	10	Planárně sférický
1000	∞ / 27	∞	Planparalelní

2.4.3.2 Helium Neonový laser

Je plynový laser, jehož aktivním prostředím jsou vzbuzené atomy neonu, excitované v doutnavém výboji ve směsi helia a neonu. Elektronové výboje předávají při nepružných srážkách část své kinetické energie vnitřním stavům atomů a vyvolávají jejich přechod na vyšší energetické hladiny. Populace hladin atomů je určována nejen buzením, ale i současně probíhající relaxací. [10]



Obr. 23 He-Ne laser s výkonem 10 mW [10]

2.4.4 Molekulární lasery

Molekuly mají ve srovnání s atomy a ionty poměrně složitá spektra energetických hladin. V molekulách je možné vytvářet inverzi populace hladin mezi energetickými hladinami různého typu. Inverze mezi dvěma elektronickými stavy umožňuje generovat ultrafialové nebo viditelné záření. Příkladem laserů tohoto typu jsou vodíkový laser, dusíkový laser a excimerové lasery. Inverze mezi vibračně-rotacími hladinami vede ke generaci infračerveného záření (CO₂ laser, CO laser).

Vodíkový laser – aktivním prostředím je vodík. Elektronové kvantové přechody v molekulárním vodíku jsou používány pro generaci ultrafialového záření v oblasti vlnových délek 140 až 165 nm a 100 až 120 nm. Buzení se provádí elektrickým výbojem. Laser pracuje zpravidla v tzv. režimu zesílené spontánní emise (tj. bez zrcadel tvořících optický rezonátor).

Dusíkový laser – laser s molekulárním dusíkem jako aktivním prostředím může generovat záření ve třech oblastech optického spektra a to:

- ultrafialové záření (337 až 328 nm)
- viditelné a blízké infračervené (754 až 1235 nm)

- infračervené (3,29 až 3,47 μm a 8,15 až 8,21 μm)

Největšího využití se dusíkovému laseru dostalo jako generátoru laserového ultrafialového sváření s vlnovou délkou 337,1 nm. Buzení se provádí elektrickým výbojem. Dosahované zesílení je veliké a laser může pracovat bez optického rezonátoru.

Excimerové lasery – excimer je nestabilní molekula, která vzniká jen na přechodnou dobu v důsledku vzájemného působení vzbuzeného atomu s atomem v základním stavu. Aktivním prostředím laserů jsou excimery. Dosud známé excimerové lasery pracují buď s excitovanými dimery vzácných plynů (např. Ar^2), s halogenidy vzácných plynů (např. KrF), nebo

s oxidy vzácných plynů (např. XeO). Buzení excimerových laserů se provádí elektrickým výbojem, nebo svazkem rychlých elektronů. Buzením elektronovým svazkem dosahujeme vyšší účinnosti než buzením elektrickým výbojem (až 10 krát). [10]

2.4.5 Plazmatické lasery

V plazmatickém laseru je inverze populace vytvářena uvnitř chladnouceho plazmatu. U těchto laserů se používají ionty argonu s vlnovou délkou 747 nm, ionty kadmia s vlnovou délkou 537,8 nm a ionty rtuti s vlnovou délkou 567 nm. Plazmatické lasery s aktivním prostředím vytvořeným mnohonásobně nabitými ionty jsou jednou z cest k vytvoření rentgenového laseru. Rentgenový laser je zdrojem koherentního rentgenového záření. U rentgenových laserů jsou ještě mnohé konstrukční problémy. Jedním z těchto problémů je že potřebná zrcadla s vysokou odrazivostí v oblasti vlnových délek 10 nm prakticky neexistují. [6]

2.4.6 Nové druhy laserů

Prudký rozvoj zaznamenávají diodami čerpané pevnolátkové lasery. Jedná se především o Nd:YAG lasery, u kterých jsou pro čerpání energie z krystalu dosud používané výbojky nahrazeny laserovými diodami, příp. diodovými lasery.

Výhody těchto laserů:

vyšší účinnost

menší spotřeba elektrické energie

menší celkové rozměry

delší trvanlivost diod oproti výbojkám (životnost diod je cca 10.000 hodin)

menší provozní náklady

Dalším vývojovým stádiem diodami čerpaných pevnolátkových laserů jsou kotoučové lasery. U tohoto typu laserů je krystal používaný dosud ve tvaru válce nebo desky nahrazen kotoučem o tloušťce 0,3 mm a průměru 7 mm. U kotoučových laserů lze kotouč vyrobit z krystalu Yb:YAG, čímž se oproti krystalu z Nd:YAG zvýší účinnost čerpání ze 76 % na 91 %. Současné výkony kotoučových laserů jsou do 350 W, ale do budoucna bude možné vyrobit kotoučové lasery o výkonu řádově kW (skládáním několika kotoučů) a tím umožnit jejich použití pro obrábění a integraci do obráběcích strojů a center.

Nového vývojového stádia dosáhly vysoce výkonové diodové lasery, u kterých je funkce založena na vzniku stimulované emise záření v aktivním polovodičovém materiálu. Na rozdíl od ostatních druhů laserů se děje přechod elektronů mezi dovolenými energetickými pásy a ne mezi energetickými hladinami. Buzení je realizováno fotony, svazkem elektronů nebo elektrickým polem. Polovodičové lasery generují záření o vlnové délce v rozsahu 808 až 940 nm. Mohou být postaveny lasery o výstupním výkonu 30 W až 8 kW. Výhodou těchto laserů je především kompaktní konstrukce, malé rozměry, vysoká účinnost a hospodárny provoz. Účinnost je až 50 %. Hospodárnost provozu těchto laserů je dána tím, že pro svůj provoz nepoužívá ani lampy ani drahé plyny, ale diody, jejichž životnost je cca 10.000 hodin. U vysoce výkonných diodových laserů má vystupující paprsek tvar obdélníkové plochy. Laser o výstupním výkonu 150 W má po zaostření rozměr stopy 0,6 x 1,2 mm. Lze jej zaostřit i na 1,3 x 1,3 mm nebo na stopu ve tvaru kruhu o průřezu 1,5 mm. [6]

2.4.7 Porovnání laserů

Plynný laser vyzařuje koherentní světelný paprsek kontinuálně a přechod do pulzního pracovního režimu nepůsobí obtíže.

Plynný laser pracuje za pokojových teplot a pro svou funkci nepotřebuje chladit.

Lasery z pevných hmot pracují při teplotách převážně velmi nízkých a jen některé při pokojových teplotách. Mnohé z laserů pracujících při pokojových teplotách však potřebují též vnější chlazení, aby se odvedla tepelná energie, která vzniká v krystalu při absorpci budícího tepelného záření.

U mnohých plyných laserů je vysílaný svazek užší než u laserů z pevných hmot.

Výhodou laserů z pevných hmot je však to, že jsou daleko menší a vyrábějí-li se průmyslově, i levnější. Jejich uvedení do chodu je snadnější, než u plyných laserů.

Většina plyných laserů pracuje v oblasti infračerveného záření, kdežto lasery z pevných hmot pracují zpravidla v oblasti viditelného záření. [9]

2.5 Obrábění laserem

Podstatou laserového obrábění je ohřátí malého, přesně specifikovaného, objemu materiálu na tavicí, vypařovací nebo sublimační teplotu v důsledku absorpce koherentního, monochromatického a málo rozbíhavého svazku elektromagnetického záření o vysoké hustotě výkonu.

Elektromagnetické záření dopadající na materiál se z části odrazí z části může projít materiálem a zbytek materiál absorbuje. Hloubka proniknutí záření do materiálu R je popsána rovnicí:

$$R = 29000 \sqrt{\frac{l}{m, g}} \quad (3)$$

kde R je hloubka proniknutí záření [μm], l je vlnová délka záření laseru [μm], m je relativní permeabilita materiálu a g je konduktivita materiálu [$\text{S}\cdot\text{m}^{-1}$].

Energii jednoho fotonu ve svazku elektromagnetického záření popisuje rovnice:

$$E_p = hf = \frac{hc}{l} \quad (4)$$

kde E_p je energie jednoho fotonu [J], $h = 6,626 \cdot 10^{-34}$ [J.s] je Planckova konstanta, $c = 299\,792\,458$ [m.s⁻¹] je rychlost světla ve vakuu a λ je vlnová délka laseru [m]. (7)

Záření které není odraženo nebo neprojde materiálem bez účinku se absorbuje. Výsledkem je zvýšení kmitavé energie molekul - tedy ohřátí látky.

Polymery jsou makromolekulární látky v jejichž hlavním řetězci jsou převážně jednoduché kovalentní vazby mezi atomy uhlíku, tedy C-C (výjimkou jsou např. silikony, které mají hlavní řetězec na bázi vazeb Si-O). Uhlíková vazba absorbuje maximum energie při vlnové délce 156 nm.

Laserové obrábění má několik výhod:

Vysoká hustota energie soustředěná na malou plochu umožňuje obrábění všech materiálů (i tvrdých a nesnadno obrobitelných), krátké doby a vysoké rychlosti obrábění. Laser poskytuje největší možnou hustotu výkonu ze všech pozemských zdrojů energie. Energie elektromagnetického záření se při interakci s hmotou absorbuje a může se změnit jedině

v teplo. Vysoká teplota pak eroduje materiál. Jak ukazuje Tab. 7 můžeme dosáhnout u laseru velmi vysoké hustoty výkonu.

Laser je nástroj bez kontaktu s materiálem a bez setrvačností, odpadá tedy opotřebení, výměna a prostoje nástroje. Laserový svazek lze snadno prostorově a časově ovládat, lze obrábět v libovolném prostředí, a to i místa pro jiné nástroje nepřístupná.

Tab. 7 Hustota výkonu dosahovaná různými zdroji energie [12]

Zdroj záření	Hustota výkonu ($\text{W}\cdot\text{cm}^{-2}$)
Sluneční světlo	10^2
Svářecí plamen	10^4
Elektrický oblouk GTA (TIG)	10^5
Plazmový oblouk	$5 \cdot 10^5$
Kontinuální elektronový paprsek	10^7
Impulsní elektronový paprsek	10^8
Kontinuální laser	10^8
Laserový impuls normální	10^9
Laserový impuls velký	$10^{14} - 10^{20}$

Monochromaticnost, koherence a nepatrná prostorová rozbíhavost paprsků způsobují, že svazek lze soustředit na plošku o minimálním průměru, který je roven dvojnásobku vlnové délky laseru. [6]

2.5.1 Laserové popisování

Laserové popisování je založeno na místním odpaření materiálu na povrchu daného předmětu. Znaky sloužící k identifikaci předmětů je možno nanášet na polovodičové, keramické


a kovové povrchy, dále na papír, sklo, plasty, feritové elementy atd. Výška znaků je obvykle rovna zlomkům až jednotkám milimetrů, tloušťka odpařené vrstvy materiálu je v řádu mikrometrů. Pro tuto aplikaci se používají výkonové impulsní lasery s energií v impulsu až desítky joulů nebo kontinuální lasery (Nd:YAG laser, excimerové lasery). Předností laserového značkování je bezkontaktní zhotovování znaků a tím vyloučení případných deformací

a napětí ve značkováném materiálu. U laserového popisování rozlišujeme dvě metody:


Popisování vychylováním laserového paprsku

U této metody popisování je znak vytvořen posunováním laserového paprsku po produktu. To se děje pomocí dvou rotačních zrcadel, která se otáčejí kolem os x a y a pohybují tak laserovým paprskem po produktu. Pohyby zrcadel řídí kontrolní systém doplněný vhodným softwarem, díky kterému můžeme na produkt zapsat požadovaný text, číslo, logo nebo čárový kód, apod.

K vytvoření čisté, tenké linky s vysokým kontrastem je nutné laserový paprsek zaostřit na plochu popisovaného produktu. To zajišťuje speciální čočka, která má plochou ostřicí rovinu. Porovnání standardní a ploché čočky je na Obr. 25.



Obr. 24 Princip popisování vychylováním laserového paprsku




Obr. 25 Porovnání standardní a ploché čočky


Rychlost popisování polymerních materiálů se pohybuje v rozmezí 300 – 1000 mm.s⁻¹, pro papír je to okolo 1000 mm.s⁻¹ a pro kovy okolo 100 mm.s⁻¹. Popisovaná plocha se zvětšuje se vzdáleností čočky od produktu (až 245 x 245 mm). [6]

Popisování maskovací metodou

U maskovací metody je laserovým paprskem osvětlena kovová maska, která obsahuje zapsaný znak. Maska je zobrazena na povrch produktu pomocí čočky. Znak na masce je na produkt přenesen jedním světelným impulsem. Maskovací popisování si lze představit jako „světelné razítkování“. K tomuto způsobu popisování je nutné použít impuls s vysokou energií, s výhodou se využívají TEA CO₂ lasery. Rychlost popisování touto metodou je limitována frekvencí pulsů laseru.



Obr. 26 Princip maskovací metody popisování



Obr. 27 Princip technologie kyvadlového zrcadla

V praxi se dosahuje rychlosti až 25 kusů popsaných produktů za sekundu. Popisovaná plocha je omezena hustotou energie laseru potřebné pro daný typ materiálu. Běžná velikost je 10 x 20 mm.

Větší popisované plochy se dá dosáhnout použitím tzv. „kyvadlového zrcadla“, kdy se laserový paprsek pohybuje podél masky. Touto technologií můžeme popisovanou plochu až zdvojnásobit. Nevýhodou maskovací metody je, že ke každému novému znaku je nutno vytvořit novou masku. [6]


2.5.1.1 Způsoby laserového popisování

Popisování polymerních materiálů se provádí změnou barvy, nebo změnou povrchové struktury. Způsoby popisu dělíme na teplotní a fotolytický.

Obr. 28a Působení laserového paprsku s nízkou intenzitou vede k lokálnímu ohřevu materiálu, rozpadu molekulární struktury a následné změně barvy nebo struktury povrchu. Např. rozpad pigmentu v polymerní matrici způsobí lokální změnu barvy. Zvyšováním intenzity laserového paprsku vzroste teplota povrchové vrstvy a dojde k tavení nebo napěnění materiálu. To může mít za následek barevnou změnu materiálu. Dalším zvýšením intenzity laserového paprsku dochází k odpařování materiálu za vzniku drážek.

Obr. 28b Stíny na stěnách drážek vytvářejí s povrchem materiálu viditelný kontrast. Zvláštním případem popisování pomocí rytí, je odstraňování povrchové vrstvy.

Obr. 28c Produkt má další povrchovou vrstvu s odlišnou barvou, která se lokálním působením laseru odpaří. Vznikne tak viditelný kontrast mezi podkladovým materiálem a povrchovou vrstvou. [6]



Obr. 28 Lokální změna barvy nebo povrchové struktury

Ozáření materiálu světlem s dostatečně krátkou vlnovou délkou má za následek fotodegradaci materiálu vedoucí k jeho barevné změně, nebo odpaření. Výhodou této metody je, že popisovaný materiál tepelně nezatežujeme. Fotolytické obrábění je doménou UV laserů. [6]

2.5.1.2 Vliv materiálu na laserové popisování

Obecný polymerní materiál není „čistý“, ale obsahuje nejrůznější příměsi pro optimalizaci zpracovatelských procesů. Laserový popis není tedy závislý jen na typu polymeru, ale také na přísadách. Ty mohou nepříznivě ovlivnit kontrast, hloubku popisování, rychlost popisu, atd. Ne všechny druhy polymerů lze popisovat se stejnou výslednou kvalitou. V těchto případech se do polymeru přidávají tzv. laserové přísady. Jsou to látky, které jsou citlivé na laserové záření a zlepšují tak kvalitu laserového popisu.

Přísady polymerních matric:

Plniva, stabilizátory, retardéry hoření, změkčovadla, pigmenty, antistatické přísady, kluzné přísady (maziva) atd. [6]


Výhody laserového popisování

- Laserové značení výrobků poskytuje oproti konvenčním metodám značení (inkoustový tisk, tampónový tisk atd.) řadu výhod:
- Vysoká kvalita popisu a extrémní reprodukovatelnost
- Trvanlivost vůči opotřebení, působení tepla, chemikálií a UV záření
- Bezkontaktní značení (nehrozí znečištění produktu, nebezpečí deformace a poškrábání, značení nerovných, měkkých, křehkých a tvrdých ploch)
- Absence barviv, rozpouštědel a ochranných fólií (odpadá tedy čištění, doplňování a výměna náplní)
- Vysoké rozlišení, rychlost a přesnost značení
- Velká flexibilita ve výrobním procesu, snadné začlenění do výrobních linek
- Minimální údržba
- Ekonomičnost výroby
- Vytváří trvalé popisy s neomezenou trvanlivostí
- Umožňuje vyjíměčně výrazné kvalitní značky
- Popisuje množství různých materiálů včetně plastických hmot, kompozitů, keramiky, pryže, kovů a slitin
- Píše přímo na výrobek, odstraňuje náklady na nálepky a zjednodušuje výrobní proces
- Popisuje nepravidelné nebo zakřivené povrchy
- Automatické řazení dat umožňuje trvalou identifikaci výrobku a jeho sledovatelnost

- Velmi malá písmena popisu vytvářejí čitelné značky i drobného tisku
- Je to bezkontaktní metoda, která minimalizuje napětí v materiálu
- Pracuje vysokou rychlostí a snižuje výrobní náklady
- Snadno vytváří složitou grafiku i texty
- Podporuje popis čárových kódů a jiných symbolů
- Je to čistý a bezpečný postup, který nevyžaduje kyseliny, inkoust, rozpouštědla, ani jiné chemikálie
- Dovoluje rychlé nastavení a změnu popisek a tím zvyšuje produktivitu práce
- Laserový popis nahrazuje řadu alternativních postupů. Žádný z nich však nenabízí výhody laserového popisování. [6]

Laserový popis má také i své nevýhody:

- Vlastnosti materiálu mohou ovlivnit i vlastnosti laserového popisu
- Často není laserový popis tak kontrastní jako popis inkoustový
- Omezená paleta barev
- Počáteční investice do laserového popisovacího stroje je vyšší, než u konvenčního. [6]



Obr. 29 Příklad laserového popisu chirurgického nástroje

2.5.2 Laserové svařování

Svařování laserem téměř vytlačilo obloukové svařování. Aby bylo použití laserového svařování hospodárné je nutná výroba většího počtu kusů.

Technologické lasery jsou ideálně vhodné pro širokou škálu různých úkolů v oblasti svařování. Jejich výkon se nejčastěji pohybuje se v rozmezí 0,5-9 kW a vystupující laserový paprsek je možné zfokusovat na průměr 0,5 mm a menší, což představuje ideální nástroj pro svařování.

Svařovací proces

Při tavném svařování je pro vytvoření svarového spoje velmi důležitý minimální energetický vstup. Čím nižší je energie vstupující do technologického procesu, tím menším deformacím svarek podléhá. Laser je schopen dodávat vstupující energii ve velmi zfokusované formě, což umožňuje vytvořit hluboký a úzký svar s minimálním teplotně ovlivněným pásmem. Navíc, protože objem roztavené oceli je velmi malý, je možno pracovat i při větších tloušťkách bez přídavného materiálu.

Svařování v jedné vrstvě je možné u materiálů do tloušťky až 12 mm, a to mnohem rychleji než konvenčními metodami.

Vysoká kvalita a reprodukovatelnost svaru je zaručena programovým ovládním manipulátoru i vlastního laseru. Většinu materiálů svařitelných běžnými metodami je možno svařovat i laserem, často mnohem rychleji a s lepšími vzhledovými výsledky. Díky velice malému tepelně ovlivněnému pásmu kolem svaru je v některých případech možné svařovat i materiály, které je velice problematické svařovat konvenčními metodami.

Vynikajícím materiálem pro svařování laserem jsou nerezavějící oceli, kde se dosahují homogenní svary bez pórů, dále nízkouhlíkaté oceli s obsahem uhlíku do 0,3% bez výrazných znečišťujících příměsí a s nízkým obsahem síry. Vhodnými materiály pro laserové svařování jsou i méně obvykle používané materiály, jako titanové, zirkoniové a chromniklové slitiny

a některé slitiny s relativně nízkou elektrickou vodivostí bez prchavých příměsí. Kovy jako hliník nebo měď nejsou příliš vhodné z důvodu vysoké reflexivity povrchu vůči CO₂ záření a vyžadují proto použití speciální postupu a velkou opatrnost. Oceli s vysokým obsahem uhlíku nebo materiály obsahující vměstky (např. mnohé vysoko legované slitiny) jsou svařitelné speciálními svařovacími technologickými postupy a musí být podrobeny tepelnému zpracování před nebo po svařování. Materiály obsahující prchavé příměsí nejsou velmi vhodné pro svařování laserem. Typickým příkladem těchto materiálů jsou mosazi, galvanická ocel, magnetické slitiny a zinek.

Zfokusovaný laserový paprsek je schopen roztavit a částečně i odpařit zpracováváný materiál. Při tomto procesu se na povrchu materiálu vytvoří dutina vyplněná parami kovů o vysokém tlaku a roztaveným materiálem, který je s parami kovu v rovnovážném stavu. Tato dutina funguje jako výborný absorbér laserové energie. Protože tvar této dutiny je hluboký a úzký, zanechává laser hluboký a úzký svar.

Tavná lázeň se chrání před oxidací ochrannou atmosférou, složenou obvykle z dusíku, argonu, oxidu uhličitého nebo helia. Kontrola procesu svařování je zabezpečována ovládním výkonu laseru a regulací svařovací rychlosti. Šířku svaru lze ovlivňovat změnou parametrů dopadajícího laserového paprsku pomocí fokusační optiky nebo změnou vzdálenosti svaru od laserové hlavy.

Příprava svarového spoje při laserovém svařování

Správné sestavení svarového spoje je při laserovém svařování velmi důležitým faktorem. Laser je velice přesný nástroj vyžadující poměrně vysokou úroveň přípravy. Typická šířka stopy při svařování vysokovýkonovým laserem je asi 1 mm a mezera pro svařování by neměla překročit 25% šířky této stopy. Jen tak je zajištěna správná fúze svarových ploch. U většiny laserových svarů se nepoužívá přídavný materiál, proto musí být mezery mezi plochami svaru velice úzké, jinak mohou vznikat vruby.

Laser může být použit i pro svařování s přeplátováním s částečným nebo úplným průvarem. Požadavky pro nastavení šířky mezery mezi plochami budoucího svaru jsou v tomto případě méně přísné.

Další možností používanou při laserovém svařování je oboustranný tupý spoj. V tomto případě vytvoří laserový paprsek jednoduchou stopu po obou stranách na tupo spojovaných součástích.

Při svařování laserem je možné použít také přídavný materiál, a to buď ve formě drátu přidávaného do svaru nebo plnicí kovové vložky. V tomto případě je možno tolerovat větší mezery mezi stěnami budoucího svaru. Přídavným materiálem je možno i ovlivnit chemické složení svaru a zvýšit např. svařitelnost vysokouhlikatých ocelí.

Výhody laserového svařování

Laserové svařování má oproti jiným metodám řadu předností. Mezi nejdůležitější patří:

- Lehce dosažitelný úzký a hluboký svar u širokého spektra materiálů
- Efektivní hluboké svary mohou být provedené u materiálů o tloušťce až 12 mm
- Laserové svařování probíhá s velmi malým vstupem energie na jednotku délky, výsledkem čehož jsou malé deformace, malé zbytkové vnitřní pnutí vzniklé svařováním a malé tepelně ovlivněné pásmo
- Vysoká produktivita práce technologického procesu
- Setrvačnost laserového paprsku je velmi malá, laserové svařování je proto vhodné pro automatizaci

- Laserové svařování probíhá na vzduchu bez použití vakua pouze se speciální inertní přídavnou atmosférou
- Nedochozí k žádnému znečišťování svaru materiálem elektrod
- Laserový paprsek může lokálně svařovat i na místech těžko dostupných, kde by to bylo jinými způsoby svařování obtížné


Typické aplikace technologie svařování materiálů laserem

Obecně se dá říci, že technologie svařování materiálů laserem je vhodná tam, kde je nutné zrealizovat velmi náročné svary z hlediska kvalitativního a z hlediska sériové a hromadné výroby při požadavku automatizace tohoto procesu. [6]

Laserové svařování plastů

Svařuje se na tupo, kde je energie dodávána do spáry a tlak taveniny spojí obě části, nebo se svařuje přeplátováním. Zde je nutné, aby byl jeden materiál pro laserové záření dosti propustný (nejlépe transparentní) a spodní materiál aby dobře absorboval. Vzniklý svár je hladký, bez pórů a vypouklin taveniny, má reprodukovatelnou pevnost. Díky vynikajícímu vzhledu mohou být švy svařovány i na viditelných místech. Svařovat můžeme i termoplasty s reaktoplasty, termoplast s pryží. [12]

Pro svařování plastů postačují výkony do 50 W. Nejlépe se osvědčují malé a kompaktní diodové lasery, jejichž níže výkonné varianty se používají v CD přehrávačích. Rychlost svařování může být až $10 \text{ m}\cdot\text{s}^{-1}$.



Obr. 30 Ukázka svařování nerez plechu 0,5 mm

2.5.3 Laserové vrtání

Vrtání bylo prakticky první aplikací laserů v technologických pracích. Nejprve se vrtaly tenké fólie, později plechy a dnes můžeme vrtat otvory hloubky i nad 50 mm. Typickou aplikací je vrtání rubínových ložiskových kamenů (do hodinek, měřících přístrojů).

Laserové vrtání je založeno na odstraňování materiálu odpařováním. Intenzita svazku musí být vyšší než u svařování, a proto se pro tento účel používá impulsních laserů s délkou impulsu menší než 1 ms. První laserové vrtání bylo provedeno již v roce 1965, kdy byl rubínový laser použit pro vrtání otvorů v diamantových průvlacích pro tažení drátů. V současné době se pro laserové vrtání využívají další pevnolátkové lasery Nd:YAG a Nd:sklo. Nejlepší díry vrtá diodami čerpaný Nd:YAG laser, neboť má lépe stabilizovaný paprsek. Pro vrtání laserem platí: čím je díra delší tím více se odchyluje tvar díry od geometrie (tj. rozdělení energie) paprsku.

Laserové vrtání polymerů

Platí zde stejné zásady jako při vrtání kovů a jiných nekovů. Uplatňuje se jak pulsní režim (perkusní vrtání s energií kolem 30 J/ms), tak i vrtání kontinuálním laserem. Pro pulsní režim je možno použít Nd:YAG laser. V kontinuálním režimu pak dobře pracují zejména diodové lasery, které nahrazují CO₂ lasery. [6]

2.5.4 Laserové řezání

V dnešní technické praxi se čím dál častěji využívají vzhledem k minimalizaci rozměrů konstrukcí s materiály pevnějšími a tvrdšími. Stávají se tak tvrdšími, než běžné konvenční obráběcí nástroje. Podobně lamináty a jiné vrstvené materiály na bázi reaktoplastů a termostoplastů vyztužených aramidovými, skelnými, uhlíkovými a kovovými vlákny jsou materiály, které se klasickým dělením zpracovávají špatně.

V Tab. 8 jsou uvedeny možnosti laserového obrábění některých kovových a nekovových materiálů. Principiálně lze obrábět cokoliv, ale pouze tam, kde nejsou vážnější problémy např. s kvalitou řezu, vrtaného otvoru (v Tab. 8 označeno křížkem). [12]

Při laserovém řezání je snahou odpařit materiál co nejrychleji při zachování co nejmenší oblasti zasažené tepelnými účinky. Nejpoužívanější lasery v tomto oboru jsou kontinuální CO₂ lasery se středním výkonem do 15 kW. Při požadavku na extrémně úzkou štěrbinu řezu je možné vybavit laserové systémy i pevnolátkovými Nd:YAG lasery nebo lasery excimerovými. [6]

Tab. 8 Možnosti laserového řezání [12]

Materiál	Značkování/gravírování	Řezání	Vrtání
Hliník	X		
Keramika	X		
Mosaz	X		
Sklo	X		
Kevlar	X	X	X
Neopren	X	X	X
Nylon	X	X	X
Papír		X	
Plasty	X	X	X
Lamináty	X	X	X
PMMA	X	X	X
PES		X	X
Pryž	X	X	X
Dřevo	X	X	X

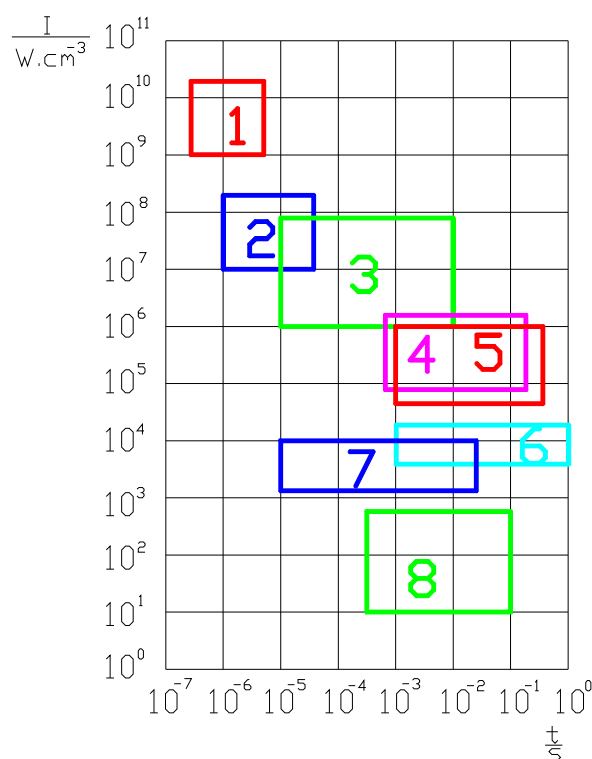
Kvalitně a ekonomicky lze řezat ocel (hlavně třídy 11) od 0,1 do 25 mm, nerez oceli do 12 mm, slitiny Al do tloušťky 8 mm a materiály jako bronz a mosaz a některé exotické materiály do tloušťky 4 mm. Problémem je řezání skla. Dochází k pnutí a odlétávání malých úlomků. Může dojít k prasknutí obrobku.



Obr. 31 Příklady laserového řezání kovových materiálů

2.5.5 Využití laseru při obrábění

Pro výrobu miniaturních součástek se vyžadují procesy obrábění, které garantují vysokou přesnost a výkonnost. Výrobci se nabízejí veliké možnosti laserového přesného mikroobrábění nejrůznějších materiálů s vynikajícími mechanickými, optickými, tribologickými, příp. magnetickými vlastnostmi, jako jsou keramika, sklo, polymery a různé kovy. Zařízení jsou doplněny numericky kontrolovaným systémem založeným na osobním počítači. To umožňuje přesné ustanovení obrobku i spuštění laseru. Vyzařování nanosekundových impulsů v rozsahu UV vlnových délek způsobuje, že dochází k minimálním tepelným vlivům na keramiku, sklo a polymery.



Obr. 32 Možnosti použití laserů [11]

I – hustota výkonu laseru [$\text{W}\cdot\text{cm}^{-3}$], t – čas [s]

Jak je patrné z Obr. 32, laser lze využít na odpaření (sublimaci) materiálu (1), na drážkování a popisování (2), na vrtání a děrování (3), na svařování (4), na povrchové natavování a legování (5), na kalení (6), na obrábění plastů (7) a na polymeraci (8) [11]

Integrace laseru do obráběcího centra má za cíl komplexní obrobení součásti na jedno upnutí a na jednom stroji. Laser lze v obráběcím centru použít dvěma způsoby:

- a) Jako podporu procesu obrábění tak, aby se snížilo opotřebení břitu řezného nástroje, aby bylo možné obrábět vyššími řeznými rychlostmi, anebo aby bylo možné vůbec obrobit těžkoobrobitelné materiály, zde jde o aplikaci obrábění s předehřevem, příp. kombinované obrábění – řezný nástroj a drážkování laserem
- b) Integrací laseru do obráběcího stroje jako přídavného nástroje, přičemž ostatní funkce stroje zůstanou zachovány. Laser doplňuje třískové operace o následující technologie popisování součástí, gravírování, vrtání, kalení, svařování, přesné vyřezávání složitých tvarů, tepelné zpracování, nanášení povlaků, frézování malých, tvarově složitých dutin a vytváření různých tvarů metodou navařování drobných částek kovu laserem. [6]

3 STANOVENÍ CÍLŮ DIPLOMOVÉ PRÁCE

Cílem této diplomové práce je verifikace neuronového modelu pro technologii laserového popisování prostřednictvím reálných naměřených dat a jeho modifikace.

V teoretické části diplomové práce byla zpracována rešerše, na jejímž teoretickém základu budou stavěna praktická měření a verifikace.

V první fázi bude připraven vzorek z PMMA na CO₂ laseru Mercury L30. Na tomto vzorku budou provedena měření drsností a hloubek drážek.

Na získaných datech bude ověřena funkčnost neuronového modelu pro nastavení CO₂ laseru Mercury L30. V případě, že budou zjištěny nepřesnosti, bude model modifikován.

Na základě získaných poznatků o neuronovém modelu budou řešeny možnosti dalšího zpracování neuronového modelu.

Vytvoření umělé neuronové sítě pro stroj Mercury L30 se věnoval již v roce 2005 Richard Svítek ve své diplomové práci. Vzhledem k omezenému množství vstupních dat však umělá neuronová síť vykazovala nepřesnosti a v některých případech predikce chybu v okrajových částech rozsahu vstupních dat.

Dalším cílem diplomové práce bude sledování vlivu nastavení kroku posuvu laserového paprsku na kvalitu povrchu zkušební plochy a následně vliv nastavení kroku posuvu laserového paprsku i na umělou neuronovou síť. K tomuto účelu bude obrobena stejnou technologií identický vzorek za dodržení stejných podmínek s dvojnásobným krokem posuvu laserového paprsku (1000 DPI) a bude sledována závislost zvolené přesnosti obrábění na výsledné výstupní hodnoty.

II. PRAKTICKÁ ČÁST

4 POPIS PŘÍSTROJŮ A MATERIÁLU

4.1 Popis CO₂ laseru Mercury L30

Pro obrábění zkušebních vzorků byl použit komerční CO₂ laser Mercury L-30 firmy Laser-Pro, USA. Zkoušky byly provedeny ve firmě Mechanika Prostějov. Výkon a posuv laserového systému lze měnit. Paprsek laseru je možné fokusovat automaticky na průměr stopy $d = 185 \mu\text{m}$. Maximální hodnota hustoty energetického toku je $q = 1,1 \text{ GWm}^{-2}$. Tvar gravírované plochy se nastavuje pomocí softwaru Corel Draw. Laserem MERCURY L-30 lze popisovat, gravírovat a řezat širokou škálu materiálů, například plasty, pryž, kůži, sklo, povlakovaný kov, kámen, dřevo, keramiku. Tento typ laseru je určen především ke komerčnímu gravírování.

Tab. 9 Technické parametry CO₂ laseru, typ MERCURY L-30

Výkon laseru [W]	30
Typ laseru	CO ₂ laser
Max. pracovní plocha (š x h x d) přední a zadní dvířka zavřena [mm]	800 x 570 x 165
Velikost pracovního stolu [mm]	790 x 530
Vnější rozměry (š x h x d) [mm]	1125 x 720 x 1005
Pohon v osách x, y	DC servo
Řízení rychlosti [mms^{-1}]	Nastavitelné od 1 do 1066
Řízení výkonu [W]	Nastavitelné od 1 do 30
Nastavení osy Z [mm]	Automatické, v rozmení 250
Krok posuvu laserového paprsku [DPI]	1000, 600, 500, 300, 250, 200
Ovládací panel	Čtyřřádkový LCD display
Chlazení	Vzduchové – vodní
Dodavatel	Firma LaserPro, rok výroby 1998

CO₂ laser MERCURY L-30 je vybaven popisovací hlavou, posuvy v osách x a y, bodovou červenou laserovou diodou (pro nastavení přesné pozice místa obrábění), LCD displejem

k navolení času obrábění, přesné pozice, výstupního výkonu a dalších parametrů. Mezi volitelnými položkami je rotační přípravek, dvojitá laserová hlava, řezací podložka, vzduchový filtr, odsávání. Pracovní prostředí by mělo být čisté a bezprašné, teplota pracovní místnosti 15 – 20 °C a s 30% - 40% vlhkostí. [7]



Obr. 33 CO₂ laser Mercury L30

4.2 Příklad na měření drsnosti Surftest SJ-301

K měření drsnosti obrobenej plochy byl použit přístroj Surftest SJ-301 od firmy Mitutoyo, který je určen pro použití v dílenském provozu. Přístrojem SJ-301 lze charakterizovat obrobenu plochu řadou parametrů podle různých národních a mezinárodních norem (JIS, DIN, ISO ANSI). Výsledky měření se zobrazí digitálně a graficky na obrazovce přístroje. Drsnost povrchu se počítá z vertikálního posuvu snímacího hrotu. [7]

Tab. 10 Technické parametry přístroje

Měřicí rozsah [μm]	300
Parametry	$R_a, R_t, R_p, R_q, R_y, R_{pc}, R_{mr}, R_s,$ $R_{sm},$
Filtr	2RC, PC75, GAUSS
Délka pojezdu hrotu [mm]	0,25; 0,8; 2,5; 8
Rozlišení [μm]	0,01
Poloměr snímacího hrotu [μm]	5
Měřicí síla [mN]	4

Rychlost posuvu [mms-1]	0,25; 0,5
-------------------------	-----------



Obr. 34 Přístroj Surfptest SJ 301

4.3 Lineární výškoměr „Linear Height“ LH-600 B

K měření hloubky vygravírovaných drážek byl použit lineární výškoměr LH-600 B od firmy Mitutoyo s dotekem na měření hloubky typu Mitutoyo 12 AAC 072.

Přístroj má široké možnosti vyhodnocení díky přenosu naměřených hodnot na externí počítač nebo k uživatelským programům SPC přes výstup dat RS-232-C.

Tab. 11 Technické parametry LH-600 B

Měřicí rozsah (zdvih)	0 – 972 mm
Číslicový krok (volitelný)	0,0001/0,001/0,01/0,1
Kolmost	6 μm
Přímost	4 μm
Počet jazyků	13
Počet programů	Maximálně 50
Počet hodnot	Maximálně 60000
Hmotnost	24 kg



Obr. 35 Lineární výškoměr LH-600 B

4.4 Polymetylmetakrylát (PMMA)

Vyrábí se již od roku 1927. Monomerem je metylester kyseliny metakrylové, jedná se o čirou kapalinu. PMMA se vyrábí radikálovou (blokovou, suspenzní nebo emulzní) polymerací.

- Blokovaná polymerace – průmyslová: V reaktoru dochází k předpolymeraci při 60 - 100 °C, pak následuje ochlazení a filtrace.

Následuje dokončovací polymerace:

a) diskontinuální - do forem - ve skleněných deskách se stlačitelnou distancí. Mezi desky se nalije předpolymer, vloží se do horkého tunelu o teplotě 40 - 130 °C na dobu 4 - 9 h podle tloušťky stěny.

b) kontinuální - mezi ocelovými pásy - horší kvalita povrchu.

- Suspenzní polymerace: Umožňuje zpracování vytlačováním a vstřikováním.

- Emulzní polymerace: Produkty slouží jako nátěrové hmoty.

Vlastnosti PMMA: sklovitě čirý polymer, částečně propouštějící UV záření, velmi odolný vůči povětrnostnímu stárnutí, je tvarovatelný při 130 - 140 °C, má velkou tepelnou roztažnost, velmi dobré elektroizolační vlastnosti, je pokovovatelný, používá se trvale do 80 °C, dobře se mechanicky obrábí, je rozpustný v aromatických uhlovodících, esterech, ketonech a éterech, zpracovává se vstřikováním při 170 - 220 °C, vytlačováním, tvarováním, mechanickým opracováním.


Využívá se k výrobě desek, trubek, tyčí, profilů, částí svítidel, vstřikovaných výrobků domácí spotřeby (transparentní), krytů kabin letadel, v zubní technice - protetika. Lze jej lepit vlastním roztokem.

5 VERIFIKACE

Jako výstupní data byl sledován výkon P a posuv f . U obou veličin jsou uváděny jednotky v procentech namísto [W] u výkonu a [mm/s] u posuvu z důvodu běžné praxe, protože hodnoty proměnných na stroji CO₂ laser Mercury L-30 jsou zadávána v procentech. Pro případný převod jednotek je dále uvedena Tab. 12. Pro samotnou verifikaci je použit již existující model umělé neuronové sítě Ing. Richarda Svítka, který vykazuje určité nepřesnosti v okrajových částech rozsahů vstupních parametrů. V další části této kapitoly je zmíněn nedostatek řešen dodáním dalších dat vedoucí ke zpřesnění modelu umělé neuronové sítě, aby umělá neuronová síť měla možnost dále se učit a dosáhla vyšší predikované přesnosti.

5.1 Příprava zkušebního dílu

Pro vygravírování zkušebních ploch byla použita deska z polymethylmetakrylátu (PMMA).



Obr. 36 Schéma desky s vygravírovanými zkušebními plochami

Aby bylo dosaženo maximální objektivitu při verifikaci neuronového modelu, byla použita tatáž deska, dle které byla provedena měření při realizaci umělé neuronové sítě pro CO₂ laser Mercury L30.

Zkušební plochy byly obrobena s krokem posuvu laserového paprsku 500 DPI.

Deska byla obrobena ve společnosti Mechanika Prostějov, na CO₂ laseru Mercury L30.

Stroj CO₂ laser Mercury L30, na kterém bylo gravírování prováděno je ovládán přes PC, ke kterému je připojen přes ovladač tiskárny. Grafické návrhy jsou prováděny v software Corel Draw, vstupní hodnoty jsou zde zadávány v procentech. V Tab. 12 jsou uvedeny přepočtové hodnoty výkonu P a posuvu f .

Tab. 12 Přepočtová tabulka jednotek výkonu P a posuvu f

	[%]	[W]		[%]	[mm/s]
Výkon P	10	3	Posuv f	10	106,6
	20	6		20	213,2
	30	9		30	319,8
	40	12		40	426,4
	50	15		50	533
	60	18		60	639,6
	70	21		70	746,2
	80	24		80	852,8
	90	27		90	959,4
	100	30		100	1066

CO₂ laser Mercury L-30 na kterém bylo prováděno gravírování má nastavitelné tyto parametry:

výkon P [%]

posuv f [%]

Krok posuvu laserového paprsku [DPI]

Přičemž parametr krok posuvu laserového paprsku ovlivňuje velikost skoku na další řádek (posuv v ose y) a tím drsnost obrobena plochy. Tento parametr nebyl měněn a při gravírování vzorkového dílu byl nastaven na konstantní hodnotu.

5.2 Měření dat

K měření příčné hodnoty drsnosti R_a a R_z byl použit Surftest SJ-301 od firmy Mitutoyo. Každá hodnota R_a a R_z byla měřena z důvodu snahy o minimalizaci možné chyby měřena desetkrát. Hloubka vygravírované plochy byla měřena přístrojem LH-600 B od firmy Mitutoyo. Aby byla zjištěna přesnost měření, byla u jednotlivých naměřených dat spočítána směrodatná odchylka.

5.2.1 Princip měření drsnosti

Drsnoměr Surftest SJ-301, na kterém byly měřeny vzorky pracuje na tomto principu:

Hrot přístroje se nastaví ve vzorku na začátek vygravírované plochy čtverce, ten se pak posouvá až na konec vygravírované plochy a zapisuje drsnost povrchu v ose kolmé na směr obrábění pro stanovení hodnot drsnosti v příčném směru (R_a , R_z). Měření se pak opakuje na každém čtverci 10-krát v příčném směru a uvedené hodnoty jsou jejich aritmetickým průměrem. Drsnost povrchu lze kvantifikovat mnoha parametry, blíže specifikovanými v ČSN ISO 4287-1.

Početní vztah pro střední aritmetickou úchylku profilu R_a – aritmetický průměr absolutních hodnot odchylek profilu uvnitř vztažné dráhy :

$$R_a = \frac{1}{n} \sum_{i=1}^n |y(x)| \quad (5)$$

Početní vztah pro maximální výšku profilu R_z – je součet výšky Y_p nejvyššího vrcholu od střední čáry a hloubky Y_v od nejnižšího bodu od střední čáry :

$$R_z = |Y_{p_{\max}}| + |Y_{v_{\max}}| \quad (6)$$

Kde

$Y_{v_{\max}}$ – vrchol největšího výstupku

$Y_{p_{\max}}$ – nejnižší bod prohlubně

Při výpočtu parametrů drsnosti používá přístroj filtry (λ_s - filtr definující rozhraní mezi drsnostmi a kratšími složkami vln přítomnými na povrchu) k potlačení vlnitosti. Je rozlišen základní profil (P - profil), který reprezentuje základnu pro číslíkové zpracování profilu pomocí λ_s filtru a pro výpočet parametrů profilu. Dalším je profil drsnosti (R - profil), který je odvozený ze základního profilu potlačením dlouhovlnných složek použitím filtru λ_s .

5.2.2 Princip měření hloubky vygravírované drážky

Přístroj je vybaven displejem s přehledným ovládacím menu v češtině. Před vlastním měřením je nutno nadefinovat nulový bod, což je v řešeném případě neobrobený povrch desky. Měření bylo provedeno automaticky pomocí stisku ovládacího tlačítka.

Měření se provádí na každém obrobeném čtverci 10-krát a uvedené hodnoty jsou jejich aritmetickým průměrem.



Obr. 37 Ovládací displej lineárního výškoměru LH-600 B

5.2.3 Statistická analýza naměřených dat

Statistická analýza naměřených dat byla provedena v software MS Excel 2002 v modulu Popisná statistika.

Aritmetický průměr

Aritmetický průměr je statistická veličina, která v jistém smyslu vyjadřuje typickou hodnotu popisující soubor mnoha hodnot. Definice aritmetického průměru je součet všech hodnot vydělený jejich počtem. [13]

Početní vztah pro aritmetický průměr:

$$\bar{x} = \frac{1}{n} \cdot (x_1 + x_2 + \dots + x_n) = \frac{1}{n} \cdot \sum_{i=1}^n x_i \quad (7)$$

Směrodatná odchylka, rozptyl výběru

Rozptyl a směrodatná odchylka patří mezi tzv. charakteristiky variability souboru.

Směrodatná odchylka charakterizuje jak jsou výsledky měření (náhodné chyby) rozptýlené. Směrodatná odchylka vyjadřuje hranici, kterou může náhodná chyba s určitou pravděpodobností překročit, nebo nepřekročit. Je to číslo udávající nakolik se naměřené hodnoty odchylují v průměru od aritmetického průměru hodnot měřené veličiny. Mezi náhodné chyby patří mimo jiné kolísání teploty, vzduchu prostředí a náhodná působení lidského charakteru. [13]

Rozptyl výběru charakterizuje rozmístění hodnot v souboru kolem průměru. Rozptyl je průměr druhých mocnin odchylek jednotlivých hodnot od zjištěného aritmetického průměru.

Početní vztah pro rozptyl výběru:

$$s^2 = \frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \bar{x})^2 \quad (8)$$

kde:

x_i – i -tá hodnota měřené veličiny

\bar{x} – aritmetický průměr hodnot měřené veličiny

s – směrodatná odchylka

n – počet měřených veličin

s^2 – rozptyl výběru

Početní vztah pro směrodatnou odchylku:


$$s = \sqrt{s^2} \quad (9)$$

5.3 Naměřená data

Níže jsou uvedeny aritmetické průměry naměřených hodnot příčné drsnosti R_a , R_z a hloubky h (Tab. 13 - Tab. 15). Z důvodu snahy o maximální vypovídající hodnotu naměřených dat jsou tyto doplněny 3D grafy vytvořeny v software Matlab, které umožňují zobrazení všech daných sledovaných veličin současně. V přílohách P I – P III jsou naměřená data doplněna o shrnutí statistické analýzy naměřených dat.

Tab. 13 Závislosti drsnosti R_a [μm] na výkonu P [%] a posuvu f [%]


f	P	30%	40%	50%	60%	70%	80%
30%		19,18	21,21	22,96	24,11	24,21	23,19
40%		19,21	20,41	21,09	21,53	22,07	22,26
50%		18,11	20,39	20,3	23,45	22,23	23,95
60%		14,35	14,72	17,08	17,11	19,73	19,41
70%		14,29	14,39	16,89	18,19	18,48	19,75
80%		12,12	13,62	16,83	16,32	17,33	18,58



Obr. 38 3D graf závislosti drsnosti R_a [μm] na výkonu P [%] a posuvu f [%]

Tab. 14 Závislosti drsnosti R_z [μm] na výkonu P [%] a posuvu f [%]


f \ P	30%	40%	50%	60%	70%	80%
30%	102,14	116,08	124,31	130,26	134,72	135,51
40%	101,94	103,92	106,28	118,84	120,48	123,82
50%	89,27	106,57	108,31	125,55	126,91	126,63
60%	72,85	79,98	94,71	95,09	98,4	100,6
70%	78,17	89,42	96,83	98,46	113,59	118,49
80%	68,85	77,83	94,21	94,33	100,44	104,57



Obr. 39 3D graf závislosti drsnosti R_z [μm] na výkonu P [%] a posuvu f [%]

Tab. 15 Závislosti hloubky drážky h [μm] na výkonu P [%] a posuvu f [%]

f	P	30%	40%	50%	60%	70%	80%
30%		121,4	161,8	203,4	237,21	268,6	276,8
40%		85,59	117,81	141,31	182,39	215,62	227,74
50%		63,56	85,27	101,56	129,74	165,13	167,27
60%		54,77	76,59	90,58	106,38	127,86	137,09
70%		22,65	34,83	66,8	68,26	82,72	108,49
80%		16,89	30,26	46,89	60,8	69,46	109,51



Obr. 40 3D graf závislosti hloubky h [μm] na výkonu P [%] a posuvu f [%]

5.4 Vlastní verifikace

Verifikován byl model na bázi umělé neuronové sítě vytvořené v roce 2005 Richardem Svítkem v rámci jeho diplomové práce.

Vstupní data Ra , Rz a h naměřená v kapitole 5.3 byla převedena do maticového tvaru, výsledná matice byla pracovně označena jako matice M s hodnotí 36x3.

$$M=[Ra; Rz; h]$$

Matice M byla vložena na vstup verifikovaného modelu umělé neuronové sítě.

Výstupní data výkonu P a posuvu f byly převedeny do maticového tvaru, výsledná matice byla označena jako matice V s hodnotí 36x2.


$$V=[P; h]$$

Verifikace byla v software Matlab prováděna příkazem *sim*, který simuluje umělé neuronové sítě.

$$VYSTUP=sim(Net500; M)$$

Net500 – označení verifikovaného modelu umělé neuronové sítě

Umělá neuronová síť byla třívrstvá s přenosovou funkcí tansig (viz.Obr. 8) ve všech vrstvách. Počet učících cyklů (epoch) byl nastaven na 20000.



Obr. 41 Schéma modelu umělé neuronové sítě k verifikaci

Tab. 16 Verifikace stávajícího neuronového modelu

Odezva neuronového modelu na verifikační data

<i>P</i>	55.09	70.009	70.289	70.042	61.717	75.919
<i>f</i>	49.533	46.155	33.822	28.695	24.092	51.818
<i>P</i>	61.698	64.699	64.251	70.107	67.069	68.993
<i>f</i>	63.277	33.296	62.58	41.369	32.314	32.249
<i>P</i>	36.998	67.934	68.734	74.992	75.01	73.309
<i>f</i>	42.872	62.746	61.21	50.241	50.675	40.317
<i>P</i>	23.063	26.61	47.345	53.27	37.275	46.837
<i>f</i>	49.232	41.298	60.467	64.203	26.44	36.092
<i>P</i>	32.628	58.864	58.241	59.178	73.483	69.117
<i>f</i>	80.133	90.721	74.236	69.161	76.457	63.542
<i>P</i>	22.552	32.253	63.58	55.533	64.331	64.7
<i>f</i>	78.636	80.419	88.478	77.22	75.635	65.613


Správný výstup

<i>P</i>	30	40	50	60	70	80
<i>f</i>	30	30	30	30	30	30
<i>P</i>	30	40	50	60	70	80
<i>f</i>	40	40	40	40	40	40
<i>P</i>	30	40	50	60	70	80
<i>f</i>	50	50	50	50	50	50
<i>P</i>	30	40	50	60	70	80
<i>f</i>	60	60	60	60	60	60
<i>P</i>	30	40	50	60	70	80
<i>f</i>	70	70	70	70	70	70
<i>P</i>	30	40	50	60	70	80
<i>f</i>	80	80	80	80	80	80

Tab. 17 Chyba výstupní hodnoty při verifikaci

<i>P</i>	25,09	30,009	20,289	10,042	8,283	4,081
<i>f</i>	19,533	16,155	3,822	1,305	5,908	21,818
<i>P</i>	31,698	24,699	14,251	10,107	2,931	11,007
<i>f</i>	23,277	6,704	22,58	1,369	7,686	7,751
<i>P</i>	6,998	27,934	18,734	14,992	5,01	6,691
<i>f</i>	7,128	12,746	11,21	0,241	0,675	9,683
<i>P</i>	6,937	13,39	2,655	6,73	32,725	33,163
<i>f</i>	10,768	18,702	0,467	4,203	33,56	23,908
<i>P</i>	2,628	18,864	8,241	0,822	3,483	10,883
<i>f</i>	10,133	20,721	4,236	0,839	6,457	6,458
<i>P</i>	7,448	7,747	13,58	4,467	5,669	15,3
<i>f</i>	1,364	0,419	8,478	2,78	4,365	14,387

Chyba výstupní hodnoty při verifikaci



Obr. 42 Graf vyjádření absolutní chyby při verifikaci

Z grafu na Obr. 42 a z hodnot v Tab. 16 je zřejmé, že model umělé neuronové sítě po verifikaci vykazoval značné nepřesnosti ve výpočtu optimálních parametrů pro nastavení výkonu P a posuvu f . Největších nepřesností model umělé neuronové sítě dosahoval v krajních hodnotách, kde se hodnota vypočtené chyby v přesnosti výpočtu pohybovaly v hodnotách okolo 30%.

Vzhledem k neuspokojivému výsledku verifikace je nutno provést úpravu stávajícího modelu umělé neuronové sítě.

5.5 Zpřesnění modelu


Při verifikaci se ukázalo, že model umělé neuronové sítě vykazoval nepřesnosti. Na základě tohoto zjištění bylo po konzultaci s vedoucím diplomové práce rozhodnuto vytvořit novou umělou neuronovou síť k verifikaci s původními daty, která bude dále trénována na naměřených verifikačních datech s modifikacemi vedoucími ke zpřesnění v určování výstupních hodnot výkonu P a posuvu f .

Prvotně vytvořená umělá neuronová síť byla navržena s jednou skrytou vrstvou o počtu 2 neurony. Dle dosahovaných výsledků v přesnosti vypočítaných parametrů byl počet neuronů modifikován postupným přidáváním dalších neuronů.

Výsledkem této práce je umělá neuronová síť s dopředným šířením s jednou skrytou vrstvou o počtu 15 neuronů s přenosovou funkcí tansig a výstupní vrstvou se 2-mi neurony a použitou přenosovou funkcí purelin.

```
novasit1 = newff([-1 1; -1 1; -1 1],[15 2],{'tansig' 'purelin'});
```

Počet epoch byl nastaven na celkem 20000 epoch s definovanou cílovou hodnotou střední kvadratické chyby MSE 0,0001.



Obr. 43 Schéma modelu nové vytvořené umělé neuronové sítě

Nově vytvořená umělá neuronová síť již vykazovala poměrně velmi přesnou predikci výstupních dat. Dalšího upřesňování výstupních dat bylo dosahováno modifikací cílové hodnoty střední kvadratické chyby.


Tab. 18 Vypočtená výstupní data modelem umělé neuronové sítě po modifikaci UNS

Odezva neuronového modelu na verifikační data

P	30,075	40	50,427	59,935	69,814	80
f	30,065	30	30,324	29,898	29,935	30
P	30,532	40,29	50,039	60,119	70,053	80
f	40,405	40,185	40,019	40,088	40,074	40
P	30,006	39,907	51,044	60,058	69,696	79,943
f	50,01	49,94	50,71	50,055	49,792	49,954
P	30,013	40,367	50,808	60,132	69,915	80,03
f	60,007	60,297	60,789	60,098	60,061	60,023
P	30,036	39,92	49,975	60,014	69,581	79,696
f	70,032	69,941	69,997	70,017	69,419	69,742
P	30	40	50	60	70	80
f	80	80	80	80	80	80

Tab. 19 Chyba výstupní hodnoty při verifikaci po modifikaci UNS

<i>P</i>	0,075	0	0,427	-0,065	-0,186	0
<i>f</i>	0,065	0	0,324	-0,102	-0,065	0
<i>P</i>	0,532	0,29	0,039	0,119	0,053	0
<i>f</i>	0,405	0,185	0,019	0,088	0,074	0
<i>P</i>	0,006	-0,093	1,044	0,058	-0,304	-0,057
<i>f</i>	0,01	-0,06	0,71	0,055	-0,208	-0,046
<i>P</i>	0,013	0,367	0,808	0,132	-0,085	0,03
<i>f</i>	0,007	0,297	0,789	0,098	0,061	0,023
<i>P</i>	0,036	-0,08	-0,025	0,014	-0,419	-0,304
<i>f</i>	0,032	-0,059	-0,003	0,017	-0,581	-0,258
<i>P</i>	0	0	0	0	0	0
<i>f</i>	0	0	0	0	0	0



Obr. 44 Graf vyjádření chyby výstupní hodnoty při verifikaci po modifikaci UNS

5.6 Vyhodnocení verifikace

Jak je patrné z grafu na Obr. 42 původní model umělé neuronové sítě byl sice relativně dobře naučen na učící data, nicméně při verifikaci vykazoval značný rozptyl výstupních hodnot. Vzhledem k tomu, že při dalším učení vykazovala umělá neuronová síť již známky přeučení, bylo po konzultaci s vedoucím diplomové práce rozhodnuto vytvořit novou umělou neuronovou síť, která bude správně počítat požadované výstupní hodnoty v souladu s učícími i s verifikačními daty. Zároveň byla snaha o maximální jednoduchost ve struktuře umělé neuronové sítě.

Nejprve byla řešena problematika počtu vrstev sítě, zde z důvodu snahy o jednoduchost byly řešeny varianty s jednou skrytou vrstvou. Aktivační funkcí ve skryté vrstvě byla zvolena funkce tansig (viz. Obr. 8). Ve výstupní vrstvě byly testovány výsledky při aplikaci funkcí purelin a satlins (viz. Obr. 9 a Obr. 11). Přesnějších výpočtů bylo dosahováno při užití přenosové aktivační funkce purelin. Vzhledem k výsledkům původní umělé neuronové sítě byla snaha snížit počet neuronů ve skryté vrstvě. Po testování variant počtu neuronů ve skryté vrstvě v intervalu od 5-ti do 25-ti byla jako optimální shledána varianta s počtem 15-ti neuronů. Zásadním problémem bylo určení počtu učících cyklů, tzv. epoch, jelikož při vyšším počtu již umělá neuronová síť vykazovala známky přeučení a naopak při nižším počtu bylo sledovatelné, že se umělá neuronová síť nestihla optimálně z daných vstupních dat naučit počítat požadovaná výstupní data. Jako optimum byl shledán počet učících cyklů v počtu 20000.

Po nadefinování umělé neuronové sítě dle výše uvedených parametrů již umělá neuronová síť začala určovat výstupní hodnoty výkonu P a posuvu f s poměrně vysokým stupněm přesnosti (viz. Obr. 44). Drobné šумы v přesnosti počítaných výstupních hodnot byly dále doladěny nadefinováním hodnoty střední kvadratické chyby MSE. Zde bylo postupně zjištěno, že celý proces učení lze urychlit a souběžně dosáhnout vyšší přesnosti ve výpočtu výstupních dat nadefinováním střední kvadratické chyby na hodnotu 10^{-6} .

Vykazované hodnoty rozdílu ve výpočtu výstupních hodnot výkonu P a posuvu f (viz. Tab. 19) se již pohybují ve velmi nízké úrovni, která aritmetickým průměrem dosahuje u výkonu P hodnotu 0,16% a u posuvu f hodnotu 0,13%, maximální odchylka u výpočtu výkonu P byla 1% a u posuvu f 0,8%.

6 VLIV NASTAVENÍ KROKU POSUVU LASEROVÉHO PAPRSKU

Zkušební deska byla připravována v technologické shodě s původní deskou k verifikaci. Princip měření dat byl totožný s užitými postupy u desky obrobené s krokem posuvu laseru na 500 DPI. Na základě měření získaných hodnot drsností R_a , R_z a hloubky h byl vytvořen model umělé neuronové sítě. Umělá neuronová síť byla naučena počítat vstupní parametry výkonu P a posuvu f , nicméně vzhledem k omezenému množství dat byly očekávány mírné nepřesnosti v predikci. Na základě poznatků získaných při tvorbě modelu umělé neuronové sítě pro desku obrobenou s krokem posuvu na 500 DPI byla umělá neuronová síť stavěna s jednou skrytou vrstvou.

Dle zjištěných naměřených dat drsností R_a , R_z a hloubky h byl proveden experiment, kdy byly porovnávány závislosti vlivu nastavení kroku posuvu laserového paprsku na přesnost umělé neuronové sítě při výpočtu výstupních hodnot výkonu P a posuvu f . Dále byla sledována závislost hloubky obrobené drážky h v souvislosti se stupněm nastavení kroku posuvu.


Dle informací dodavatele laseru Mercury L30 společnosti Elektron, s.r.o. platí poměrově závislost, že se zvyšujícím se krokem posuvu laserového paprsku se přímo úměrně zvyšuje časová náročnost procesu obrábění. Z toho vyplývá, že obrábění s krokem posuvu laserového paprsku 1000 DPI je ve srovnání s 500 DPI časově dvojnásobně dlouhé. Dle praktických informací od firmy Mechanika Prostějov kroky posuvu laserového paprsku pod 500 DPI používány nejsou používány. Menší součásti a přírodní materiály jsou obráběny s krokem posuvu laserového paprsku na 1000 DPI. Přehled stupňů nastavení kroku posuvu laserového paprsku udává Tab. 9.

6.1 Naměřená data

Níže jsou uvedeny aritmetické průměry naměřených hodnot příčné drsnosti R_a , R_z a hloubky h . Z důvodu snahy o maximální vypovídající hodnotu naměřených dat jsou tyto doplněny 3D grafy vytvořených v software Matlab, které umožňují zobrazení všech daných sledovaných veličin. V přílohách P IV – P VI jsou naměřená data doplněna o shrnutí statistické analýzy naměřených dat.

Tab. 20 Závislosti drsnosti R_a [μm] na výkonu P [%] a posuvu f [%]


f	P	30%	40%	50%	60%	70%	80%
30%		9,325	12,586	13,058	13,631	13,745	16,240
40%		9,809	10,725	11,54	11,493	10,840	14,783
50%		7,327	8,187	8,986	10,337	10,072	9,301
60%		7,017	8,724	9,486	9,139	9,977	9,498
70%		6,694	8,163	9,674	10,131	8,797	9,267
80%		6,439	8,013	9,280	8,838	8,077	7,362



Obr. 45 3D graf závislosti drsnosti R_a [μm] na výkonu P [%] a posuvu f [%]

Tab. 21 Závislosti drsnosti R_z [μm] na výkonu P [%] a posuvu f [%]


f	P	30%	40%	50%	60%	70%	80%
30%		51,642	72,619	70,222	75,174	77,845	84,656
40%		52,806	59,433	63,806	63,231	59,934	78,727
50%		41,138	46,026	51,070	54,332	56,229	53,873
60%		39,241	46,439	53,072	56,782	57,110	53,380
70%		36,821	44,304	54,756	51,855	48,215	50,840
80%		35,225	44,839	50,136	47,522	44,347	40,534



Obr. 46 3D graf závislosti drsnosti R_z [μm] na výkonu P [%] a posuvu f [%]

Tab. 22 Závislosti hloubky drážky h [μm] na výkonu P [%] a posuvu f [%]

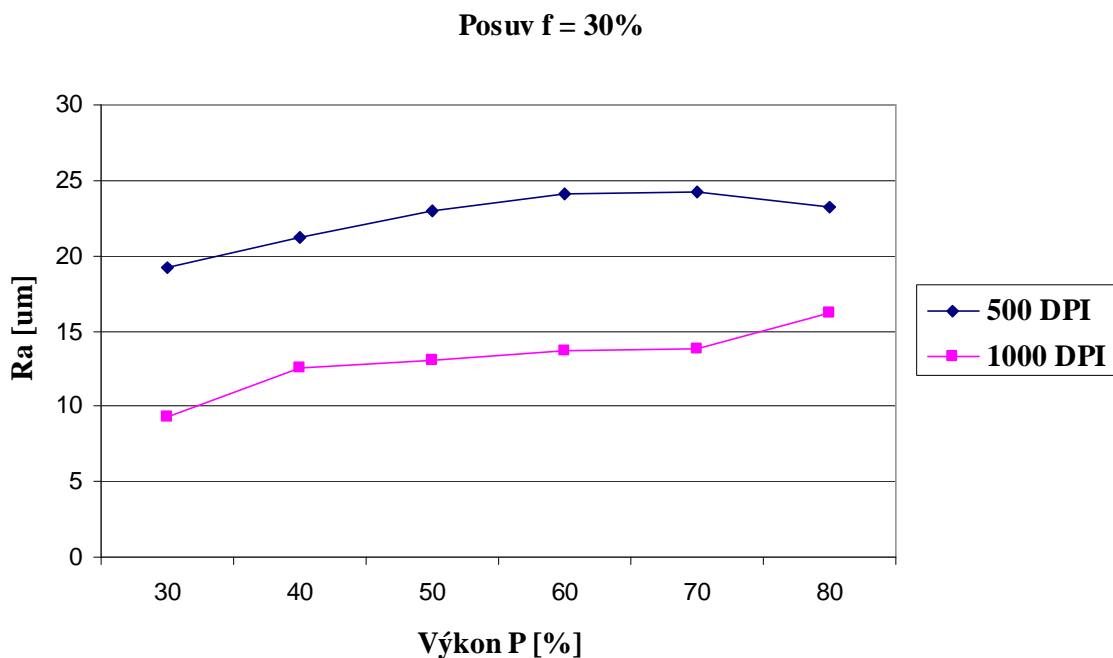
f	P	30%	40%	50%	60%	70%	80%
30%		210,3	360,9	444,0	720,3	591,7	685,0
40%		186,7	292,3	451,0	541,4	601,2	667,1
50%		244,8	337,6	410,8	486,7	546,5	598,3
60%		332,1	111,8	188,4	305,1	257,7	369,3
70%		70,8	72,5	124,8	202,2	257,8	317,2
80%		29,3	36,8	95,6	158,4	225,8	274,8




Obr. 47 3D graf závislosti hloubky h [μm] na výkonu P [%] a posuvu f [%]

Na níže uvedených grafech (Obr. 48 – Obr. 56) jsou znázorněny sledované vzájemné závislosti mezi vstupními a výstupními parametry. Konkrétně byl sledován vliv výkonu P a po-


suvu f na hloubku obrobene drážky h , střední aritmetickou úchylku Ra a maximální výšku profilu Rz . V kapitole 7.2 jsou jednotlivé vztahy dále rozdiskutované.



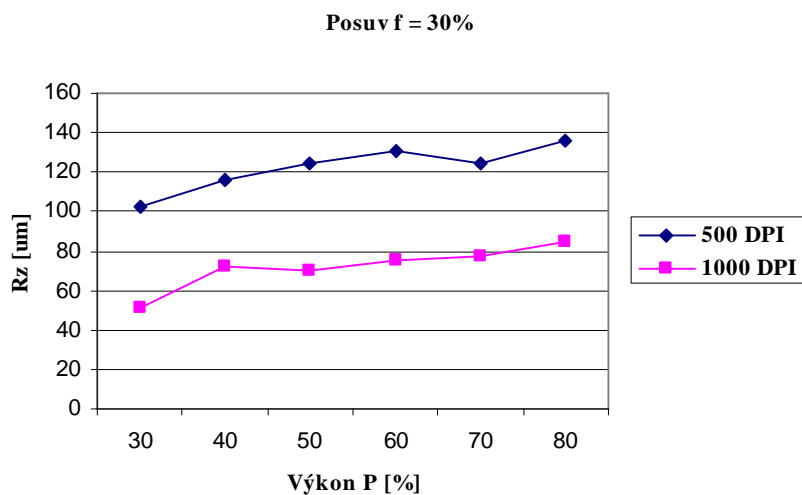
Obr. 48 Graf závislosti střední aritmetické úchylky Ra na výkonu P při konstantním posuvu $f=30\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI




Obr. 49 Graf závislosti střední aritmetické úchylky Ra na výkonu P při konstantním posuvu $f=50\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI




Obr. 50 Graf závislosti střední aritmetické úchlky R_a na výkonu P při konstantním posuvu $f=80\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI



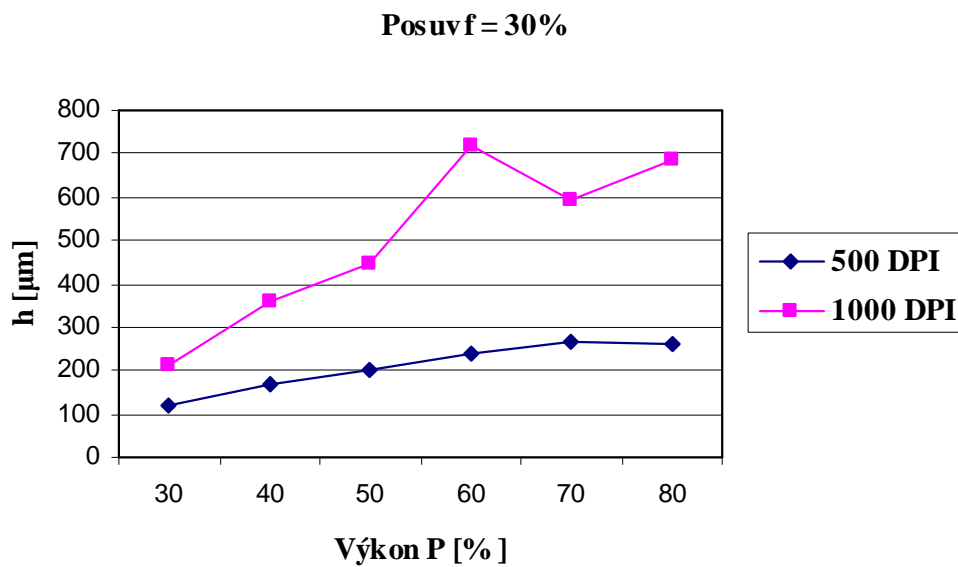
Obr. 51 Graf závislosti maximální výšky profilu R_z na výkonu P při konstantním posuvu $f=30\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI




Obr. 52 Graf závislosti maximální výšky profilu Rz na výkonu P při konstantním posuvu $f=50\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI




Obr. 53 Graf závislosti maximální výšky profilu Rz na výkonu P při konstantním posuvu $f=80\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI



Obr. 54 Graf závislosti hloubky h na výkonu P při konstantním posuvu $f=30\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI



Obr. 55 Graf závislosti hloubky h na výkonu P při konstantním posuvu $f=50\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI



Obr. 56 Graf závislosti hloubky h na výkonu P při konstantním posuvu $f=70\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI

6.2 Volba umělé neuronové sítě

V software Matlab byla zvolena vícevrstvá umělá neuronová síť s dopředným šířením s přenosovou funkcí tansig (hyperbolický tangens, viz. Obr. 8) ve skryté vrstvě a funkce purelin ve výstupní vrstvě (viz. Obr. 9). Počet neuronů ve vstupní a ve výstupní vrstvě je dán řešeným problémem.

V závislosti na požadovaném výpočtu výstupních dat umělé neuronové sítě byly voleny konkrétní parametry :

- počet vrstev sítě
- počet neuronů v jednotlivých vrstvách
- počet učicích cyklů (epoch)

V případě, že umělá neuronová síť vykazuje nepřesný výpočet výstupních parametrů, lze výsledky ovlivnit :

- zpřesnění množiny učicích dat
- změnou přenosové funkce
- počet učicích cyklů (epoch)

- definicí cílové hodnoty střední kvadratické chyby
- počtem vrstev
- počtem neuronů v jednotlivých vrstvách

Snahou však bylo dosáhnout stavu, kdy model umělé neuronové sítě bude co nejjednodušší a souběžně byl samozřejmý požadavek na správnou funkčnost modelu z důvodu snahy o komparaci vypočtených výsledků obou modelů a z toho vyvozených závěrů k řešené problematice sledování vlivu nastavení kroku posuvu laserového paprsku.

Při volbě počtu neuronů ve skryté vrstvě byl nejprve testován model se dvěma neurony a dle dosažených výsledků umělé neuronové sítě byl jejich počet postupně navyšován až na výsledný počet 15-ti neuronů.

6.2.1 Specifikace tvorby programu v software Matlab

Softwaru Matlab musíme nejprve zadat učící data. Tento program je pro vytvoření umělé neuronové sítě s jednou vstupní vrstvou s počtem 3 neuronů (3 vstupních parametrů), jednou skrytou vrstvou o počtu 15 neuronů a jednou výstupní vrstvou o počtu 2 neuronů (2 výstupní parametry).

Software Matlab pracuje s desetinou tečkou na místo čárky, jednotlivá data se od sebe odělují mezerou příp. tabulátorem.

6.3 Vytvoření umělé neuronové sítě

Umělá neuronová síť pro data získaná obrobením kroku posuvu laserového paprsku na 1000 DPI byla pracovně nazvána Net1000.

Vstupní data umělé neuronové sítě

Uvedená data zde nejsou uvedena v celém svém rozsahu z důvodu jejich obsáhlosti. Kompletní vstupní data jsou uvedena v příloze PIV – PVI.

```
P=[9.325 12.586 13.058 13.631 13.745 16.24 9.809 10.725 11.54 11.493 ... 7.362;...  
51.642 72.619 70.222 75.174 77.845 84.656 52.806 59.433 63.806 63.231 ... 40.534;...  
210.3 360.9 444 720.3 591.7 685 186.7 292.3 451 ... 109.4 ];
```

Kde: 1. řádek jsou data drsnosti R_a , 2. řádek R_z , a 3. řádek hloubka h .

Výstupní data umělé neuronové sítě

Uvedená data zde nejsou uvedena v celém svém rozsahu z důvodu jejich obsáhlosti. Kompletní vstupní data jsou uvedena v příloze P IV – P VI.

```
T=[30 40    50    60    70    80    30    40    50    60    70    80;...
    30 30    30    30    30    30    40    40    40    40    40 ..... 80];
```

Kde: 1. řádek jsou data výkonu P , 2. řádek posuvu f

Přepočítání výstupních dat na interval [-1;1]

```
[tn,mint,maxt] = premmx(T);
```

Vytvoření umělé neuronové sítě s dopředným pohybem s jednou skrytou vrstvou o počtu 15 neuronů a výstupní vrstvou se 2-ma neurony a použitou přenosovou funkcí tansig ve skryté vrstvě a purelin ve výstupní vrstvě.

```
Net1000 = newff(minmax(P),[15 2],{'tansig' 'purelin'});
```

Nastavení maximální délky učení na 20000 učicích cyklů (epoch)

```
net1000.trainParam.epochs = 20000;
```

Vyvolání učení sítě

```
net1000 = train(net,P,tn);
```


Test sítě na učicí data

```
yn = sim(net1000,P);
```

Zpětný přepočítání na původní rozsah

```
Y= postmnmx(yn,mint,maxt)
```

Tímto byla vytvořena a naučena umělá neuronová síť a můžeme zadávat vstupní data (drsnost R_a , R_z a hloubku h), které síť zpracuje podle naučené závislosti a na výstupu dostaneme ekvivalentní vypočítaný výsledek (výkon P a posuv f).



Obr. 57 Blokové schéma vytvořené umělé neuronové sítě

6.4 Testování umělé neuronové sítě

Během testování modelu umělé neuronové sítě tato síť z počátku vykazovala odlišná výstupní data výkonu P a posuvu f , což bylo dalším zkoušením postupně vyřešeno postupným snižováním počtu učicích cyklů (epoch) z hodnoty 20000 až na hodnotu 5000. Tato hodnota již umělé neuronové síti stačila k dosažení definované střední kvadratické chyby MSE v hodnotě 0,0001, při které byly umělou neuronovou sítí vykazovány nejpřesnější výpočty. Testování bylo prováděno zadáním vstupních parametrů požadované dosažené drsnosti R_a a R_z a hloubky h . Umělá neuronová síť na základě zadání vstupních parametrů vypočítala výstupní hodnotu výkonu P a posuvu f .

Zde bylo dle vykazovaných průběžných výpočtů výstupních hodnot evidentní, že s klesajícím počtem učicích cyklů model umělé neuronové sítě vykazoval přesnější výstupní data.

Tab. 23 Vypočtená výstupní data modelu umělé neuronové sítě pro desku obrobenou s krokem posuvu laserového paprsku na 1000 DPI

Odezva neuronového modelu na učicí data

P	29,929	40,004	50,003	60,001	70,006	80,11
f	30,061	29,995	30,011	29,986	30,024	30,112
P	29,989	40,042	49,961	60,009	69,999	80,045
f	39,999	39,963	40,069	40,009	39,98	40,042
P	30,019	39,981	50,01	59,951	70	79,99
f	50	50,001	50,007	49,969	50	49,981
P	29,971	39,951	50,01	60,14	70,021	80,083
f	60,003	60,031	60	59,879	60,046	59,911
P	29,985	40,052	50,016	60,014	70,251	79,727
f	70,016	69,966	69,998	69,98	69,768	70,225
P	30,016	40,016	49,97	60,015	69,85	80,017
f	80,02	79,999	80,031	80,002	80,101	80,004


Tab. 24 Chyba výstupní hodnoty při učení umělé neuronové sítě pro desku obrobenu s krokem posuvu laserového paprsku na 1000 DPI

<i>P</i>	0,071	0,004	0,003	0,001	0,006	0,11
<i>f</i>	0,061	0,005	0,011	0,014	0,024	0,112
<i>P</i>	0,011	0,042	0,039	0,009	0,001	0,045
<i>f</i>	0,001	0,037	0,069	0,009	0,02	0,042
<i>P</i>	0,019	0,019	0,01	0,049	0	0,01
<i>f</i>	0	0,001	0,007	0,031	0	0,019
<i>P</i>	0,029	0,049	0,01	0,14	0,021	0,083
<i>f</i>	0,003	0,031	0	0,121	0,046	0,089
<i>P</i>	0,015	0,052	0,016	0,014	0,251	0,273
<i>f</i>	0,016	0,034	0,002	0,02	0,232	0,225
<i>P</i>	0,016	0,016	0,03	0,015	0,15	0,017
<i>f</i>	0,02	0,001	0,031	0,002	0,101	0,004

Z výsledků uvedených v

Tab. 23 a Tab. 24 je zřejmé, že testováním a učení umělé neuronové sítě bylo dosaženo očekávaných výsledků. Chyby výstupních parametrů jsou graficky znázorněny v grafu na Obr. 58.

Umělá neuronová síť byla dále testována zadáváním různých kombinací vstupních parametrů drsností Ra , Rz a hloubky h a byly sledovány vypočítané hodnoty výstupních parametrů výkonu P a posuvu f .



Obr. 58 Graf vyjádření absolutní chyby při učení na učící data po modifikaci UNS

6.5 Vlastní verifikace

Vytvořený model umělé neuronové sítě byl verifikován na další naměřená data. Vstupní data Ra , Rz a h byla převedena do maticového tvaru, výsledná matice byla pracovně označena jako matice N s hodnotostí 36×3 .

$$N=[Ra;Rz;h]$$

Tab. 25 Naměřená verifikační data

Posuv f	Výkon P	Ra [μm]	Rz [μm]	h [μm]	Posuv f	Výkon P	Ra [μm]	Rz [μm]	h [μm]
30%	30%	9,32	51,64	210,40	60%	30%	7,02	39,11	332,20
	40%	12,59	72,44	360,80		40%	8,80	46,50	111,72
	50%	13,06	70,23	444,10		50%	9,50	53,10	188,41
	60%	13,64	75,18	720,20		60%	9,20	56,90	305,19
	70%	13,75	77,85	591,76		70%	10,01	57,09	257,47
	80%	16,24	84,66	685,06		80%	9,52	53,40	369,11
Posuv f	Výkon P	Ra [μm]	Rz [μm]	h [μm]	Posuv f	Výkon P	Ra [μm]	Rz [μm]	h [μm]
40%	30%	9,79	52,81	186,88	70%	30%	6,73	36,70	70,82
	40%	10,73	59,44	292,10		40%	8,22	44,40	72,44
	50%	11,54	63,81	451,06		50%	9,73	54,80	124,51
	60%	11,51	63,22	541,20		60%	10,19	51,80	202,22
	70%	10,84	59,94	601,16		70%	8,80	48,34	257,98

	80%	14,79	78,85	667,20		80%	9,26	50,85	316,90
Posuv f	Výkon P	Ra [μm]	Rz [μm]	h [μm]	Posuv f	Výkon P	Ra [μm]	Rz [μm]	h [μm]
50%	30%	7,41	41,15	244,85	80%	30%	6,28	35,30	30,01
	40%	8,19	46,08	337,68		40%	8,20	44,84	36,88
	50%	9,02	51,10	410,76		50%	9,30	50,14	95,63
	60%	10,40	54,42	486,74		60%	8,84	47,60	158,00
	70%	10,09	56,19	546,55		70%	8,10	44,35	226,00
	80%	9,36	53,90	598,45		80%	7,30	40,52	275,60

Matice N byla vložena na vstup verifikovaného modelu umělé neuronové sítě. Výstupní data výkonu P a posuvu f byly převedeny do maticového tvaru, výsledná matice byla označena jako matice V s hodnotí 36x2.

$$V=[P;f]$$

Verifikace byla v software Matlab prováděna příkazem *sim*, který simuluje umělé neuronové sítě.

$$\text{VYSTUP}=\text{sim}(\text{Net1000}; M)$$

Net1000 – označení verifikovaného modelu umělé neuronové sítě

Nastavení maximální délky učení na 20000 učících cyklů (epoch)

$$\text{Net1000.trainParam.epochs}= 20000$$

Nastavení maximální střední kvadratické chyby MSE

Parametr byl na základě experimentů změněn na 0,00001

Tab. 26 Verifikace stávajícího neuronového modelu (1000 DPI)

Odezva neuronového modelu na verifikační data

P	30,058	43,640	54,566	60,023	70,002	81,050
f	30,021	35,199	34,549	30,072	30,002	32,001
P	31,028	40,006	51,003	60,900	70,002	81,005
f	40,027	42,008	42,004	43,001	42,003	40,003
P	30,004	41,407	53,569	60,002	73,860	82,110
f	51,006	50,009	50,005	50,001	54,690	51,410
P	30,004	40,007	50,017	60,059	70,001	81,520
f	60,003	60,007	60,017	60,081	60,001	64,038
P	30,020	40,003	51,000	60,006	70,018	80,100

<i>f</i>	72,021	72,002	70,001	71,005	70,000	70,120
<i>P</i>	31,015	42,290	50,000	60,020	70,025	84,150
<i>f</i>	80,015	82,180	80,000	80,022	80,022	83,640


Správný výstup

<i>P</i>	30	40	50	60	70	80
<i>f</i>	30	30	30	30	30	30
<i>P</i>	30	40	50	60	70	80
<i>f</i>	40	40	40	40	40	40
<i>P</i>	30	40	50	60	70	80
<i>f</i>	50	50	50	50	50	50
<i>P</i>	30	40	50	60	70	80
<i>f</i>	60	60	60	60	60	60
<i>P</i>	30	40	50	60	70	80
<i>f</i>	70	70	70	70	70	70
<i>P</i>	30	40	50	60	70	80
<i>f</i>	80	80	80	80	80	80

Tab. 27 Chyba výstupní hodnoty při verifikaci

<i>P</i>	0,058	3,640	4,566	0,023	0,002	1,050
<i>f</i>	0,021	5,199	4,549	0,072	0,002	2,001
<i>P</i>	1,028	0,006	1,003	0,900	0,002	1,005
<i>f</i>	0,027	2,008	2,004	3,001	2,003	0,003
<i>P</i>	0,004	1,407	3,569	0,002	3,860	2,110
<i>f</i>	1,006	0,009	0,005	0,001	4,690	1,410
<i>P</i>	0,004	0,007	0,017	0,059	0,001	1,520
<i>f</i>	0,003	0,007	0,017	0,081	0,001	4,038
<i>P</i>	0,020	0,003	1,000	0,006	0,018	0,100
<i>f</i>	2,021	2,002	0,001	1,005	0,000	0,120
<i>P</i>	1,015	2,290	0,000	0,020	0,025	4,150
<i>f</i>	0,015	2,180	0,000	0,022	0,022	3,640

Chyba výstupní hodnoty při verifikaci



Obr. 59 Graf vyjádření chyby výstupní hodnoty při verifikaci

Jak je zřetelné z Obr. 59 a Tab. 27, chyba výstupních hodnot dosahovala svého maxima na hodnotě 5,2%, což je hodnota pro výrobní proces stále ještě přijatelná. I přes veliké úsilí a množství provedených experimentů se nepodařilo umělou neuronovou sít' pro nastavení s krokem posuvu na 1000 DPI naučit počítat natolik přesné výsledky jako předchozí umě-

lou neuronovou sít' pro nastavení kroku posuvu na 500 DPI. Příčina může být ovlivněna mnoha faktory souvisejícími s výrobním procesem.

Při měření vstupních parametrů byly zjištěny nepřesnosti u hloubky obrobených drážek, které byly vykazovány v okrajových částech obrobené drážky.

6.6 Vyhodnocení výsledků umělé neuronové sítě

Z původních cílů, které byly na počátku vytváření modelu umělé neuronové sítě pro desku z PMMA obrobenou s krokem posuvu laserového paprsku na 1000 DPI bylo postupným testováním dodrženo vše vyjma počtu cyklů učení (epoch). Model umělé neuronové sítě potřeboval pro naučení se na učící data 5000 epoch, ovšem při verifikaci začal vykazovat nepřesnosti ve výpočtu. Experimentálně byly upravovány jednotlivé parametry umělé neuronové sítě, jako optimální konfigurace byla zjištěna umělá neuronová sít' s dopředným pohybem s jednou skrytou vrstvou o počtu 15 neuronů s přenosovou funkcí tansig a výstupní vrstvou s přenosovou funkcí purelin. Hodnota střední kvadratické chyby MSE byla nastavena na 0,00001. Tato hodnota byla určena na základě experimentálního testování umělé neuronové sítě. Počet učících cyklů byl zadán na hodnotu 20000 epoch.

Vykazované hodnoty u učení umělé neuronové sítě na učící data rozdílu ve výpočtu výstupních hodnot výkonu P a posuvu f (viz. Tab. 24) se již pohybovaly na velmi nízké úrovni, která aritmetickým průměrem dosahovala u výkonu P hodnotu 0,05% a u posuvu f hodnotu 0,04%, maximální odchylka u výpočtu výkonu P byla 0,27% a u posuvu f 0,23%. Tyto rozdíly jsou v praktickém provozu naprosto zanedbatelné.

Vykazované hodnoty u verifikace umělé neuronové sítě na verifikační data rozdílu ve výpočtu výstupních hodnot výkonu P a posuvu f (viz. Tab. 27) se pohybovaly na vyšší úrovni než u odezvy umělé neuronové sítě na učící data. Aritmetickým průměrem dosahovala u výkonu P hodnotu 1% a u posuvu f 1,2%. Maximální odchylka u výpočtu výkonu P byla 4,6% a u posuvu f 5,2%.

Verifikační data s výjimkou výše uvedených maxim vykazovala poměrně vysokou přesnost. Nepřesnost nad 3% dosažená u výkonu P v 5 případech a u posuvu f ve 4 případech je pro aplikaci ve výrobním procesu ještě přijatelná. Možnou příčinou zvýšené odchylky při výpočtu výstupních parametrů mohou být chyby měření ve vztahu k parametrům obrobených drážek. Při měření totiž byly zjištěny úchyly v krajních oblastech obrobených drážek.

Z naměřených výsledků obrobených drážek lze vyvodit závislosti mezi výkonem P , posuvem f a hloubkou drážky h s kvalitou povrchu (drsností) obrobené plochy.

Vliv na hloubku obrobené drážky má, jak je patrné z uvedených grafů (Obr. 54, Obr. 55 a Obr. 56) nastavení obou výstupních parametrů, tj. výkonu P i posuvu f . Konkrétně se zvyšujícím se výkonem P stoupá hodnota hloubky h . Nejvíce strmý průběh je sledovatelný při nastavení posuvu f na hodnotu 70%. Pouze při nastavení posuvu f na hodnotu 30% je sledovatelný výkyv v růstové tendenci hodnoty hloubky h při nastavení výkonu P na hodnotu 70%, rozdíl v hloubce obrobené drážky zde činí 128,6 μm .

Vliv na střední aritmetickou úchylku Ra a maximální výšku profilu Rz má především nastavení posuvu f . Je patrná závislost klesání hodnoty Ra i Rz v závislosti na zvyšování posuvu f .

7 DISKUSE VÝSLEDKŮ

7.1 Shrnutí verifikace a aplikace modelů umělé neuronové sítě

V první fázi experimentální části diplomové práce byla řešena verifikace modelu umělé neuronové sítě (UNS) určené pro laser Mercury L30 při nastavení kroku posuvu laserového paprsku na 500 DPI. Tato stávající umělá neuronová síť se při verifikaci ukázala jako nepřesná. Tato nepřesnost dle mého názoru byla způsobena malým množstvím učících dat a velkými chybami měření obsaženými v trénovací množině. Dalším faktorem byl pochopitelně i širší pracovní rozsah původní umělé neuronové sítě, která byla učena na rozsah výkonů P a posuvů f v intervalu 10 – 100%, přestože hodnoty z okrajové oblasti pracovního rozsahu byly zatíženy výraznými chybami měření. Tento problém byl řešen vytvořením nové UNS, která je v konečném výsledku svou strukturou jednodušší a výpočtem výstupních hodnot dosahuje vysokého stupně přesnosti.

Ve druhé fázi byla řešena problematika vytvoření modelu UNS pro desku z PMMA obrobenu s dvojnásobným krokem posuvu laserového paprsku (1000 DPI). Byl předpoklad, že UNS bude vypočítávat přesnější výstupní parametry výkonu P a posuvu f . Na základě dodaných učících dat při optimální konfiguraci své struktury vykazovala poměrně přesné hodnoty výkonu P a posuvu f . Dále byla umělá neuronová síť verifikována. Stávající UNS byla na základě verifikačních dat dále modifikována, konkrétně parametr střední kvadratické chyby MSE byl snížen z hodnoty 0,0001 na 0,00001. Nutnost modifikace střední kvadratické chyby byla zjištěna na základě experimentálního testování umělé neuronové sítě. Při nadefinování hodnoty střední kvadratické chyby na 0,00001 bylo dosahováno nejpresnějšího výpočtu hodnot výkonu P a posuvu f . Aby bylo možné dosáhnout střední kvadratické chyby na stanovenou hodnotu bylo třeba zmodifikovat i počet učících cyklů (epoch) z hodnoty 5000 na hodnotu 20000 epoch.

Obě vytvořené umělé neuronové sítě již vykazují známky dobrého naučení se. Ovšem těchto dobrých výsledků bylo dosaženo při relativně malé množině vstupních parametrů, pro její plnou aplikaci do výrobního procesu by bylo zapotřebí dodat podstatně větší množství učících dat. Nicméně stále dynamicky rostoucí implementace výpočetních technologií do výrobního procesu je slibným příslibem do budoucna i pro umělé neuronové sítě, které se na rozdíl od osobních počítačů (viz. Tab. 1) dokáží přizpůsobit konkrétním problémům a dále se na jejich základě zdokonalovat. Z výrobního procesu by tak odpadl jeden

z chybujících faktorů – člověk. Dalším argumentem pro aplikaci umělých neuronových sítí je i ekonomické hledisko, kdy vzniká pouze prvotní finanční náklad na pořízení techniky a software pro umělou neuronovou síť a další náklady spojené s provozem umělé neuronové sítě již jsou v kontrastu se stabilní mzdou kvalifikovaného pracovníka, jehož přítomnost by byla eliminována mnohem nižší. Z krátkodobého pohledu se ale spíše jeví reálná možnost využití umělých neuronových sítí jako pomocníka odborné obsluhy, který na základě zadaných výstupních parametrů pracovníkovi vypočte optimální konfiguraci nastavení vstupních parametrů, které je třeba stroji definovat. Problémem však může být například různorodost jednotlivých plastů se stejného druhu (např. v diplomové práci použitý PMMA), jejichž vlastnosti mohou být ovlivněny složením přísad, stářím materiálu a dalšími vlivy. Tento problém je řešitelný dodáním velkého množství naměřených dat, což ovšem již není z časového hlediska záležitost v řádu měsíců, ale spíše v řádu let. Praktickým řešením pro malosériový, sériový a hromadný výrobní proces při řešení problému s odlišnými vlastnostmi jednotlivých plastů při jejich obrábění laserem by mohlo být zavedení kalibrace jednoho zkušební dílu, který by byl obroben dle parametrů vypočtených umělou neuronovou sítí. Po naměření hodnot hloubky h a drsností R_a a R_z by umělé neuronové síti v případě vykázaných nepřesností ve výpočtu výstupních parametrů výkonu P a posuvu f byly dodány naměřená data. Na jejich základě by již následující výrobky byly obrobena přesně dle požadavku a dle vlastností obráběného plastu. V kusové výrobě by však řešení za pomoci obrobena kalibračního dílu bylo ekonomicky nevýhodné. Proto je zde řešením obrábět nejprve s nižším nastavením kroku posuvu laserového paprsku a postupně dle dosahovaných výsledků tento parametr zvyšovat.

I přes nevýhodu vlivu přísad na materiál, které ovlivňují jeho vlastnosti má další výzkum aplikace umělých neuronových sítí ve výrobním procesu veliký rozvojový potenciál do budoucna a zabývání se jím má význam. V dnešní době jsou již umělé neuronové sítě nezbytným pomocníkem v meteorologii, bankovníctví, medicíně, chemii a v mnoha dalších odvětvích lidských činností.

Vzhledem k nutnosti dosažení co nejefektivnějšího způsobu výroby je velikým příslibem pro lidstvo do budoucna.

7.2 Shrnutí závislostí vlivu nastavení laseru Mercury L30 na výsledky mikroobrábění PMMA

V experimentální části diplomové práce byly na laseru Mercury L30 ve firmě Mechanika Prostějov obrobena 2 desky z PMMA. Rozsah obráběných drážek byl u výkonu P i posuvu f od 30% do 80%. Původní deska, která byla obrobena v roce 2005 s nastavením kroku posuvu laserového paprsku na 500 DPI měla rozsah obráběných drážek u výkonu P i posuvu f od 10% do 100%. Rozsah byl zredukován na základě poznatků získaných v roce 2005, kdy v rozsahu 10 – 20% a 90 – 100% byly zjištěny chyby v krajních částech rozsahu vstupních dat, což vedlo k nesmyslným požadavkům na naučenou umělou neuronovou síť (např. velká hloubka při nízkých hodnotách výkonu, atp.), která pak ve výsledku navrhla chybný výpočet výstupních parametrů.

Dle Tab. 9 lze na CO₂ laseru Mercury L30 nastavit krok posuvu laserového paprsku na hodnoty 1000, 600, 500, 300, 250 a 200 DPI. V rámci diplomové práce byly sledovány hodnoty obroběných drážek při nastavení kroku posuvu laserového paprsku na 500 a 1000 DPI, což jsou ve firmě Mechanika Prostějov dle informací obsluhy laseru nejužívanější hodnoty nastavení.

Laser se za dobu čtyřiceti let od svého vzniku uplatnil v celé řadě oborů. Vývoj laseru i jeho aplikací prochází neustálou inovací, sledující jak nové technické možnosti, tak i přístupnější ekonomie provozu. Obchod s laserovou technikou určenou pro průmyslové zpracování materiálů roste v posledním desetiletí každoročně o dvouciferná procenta. Díky tomu, že postupuje optimalizace systémových koncepcí nasazování laserů a ruku v ruce s tím se rozšiřuje i aplikační spektrum laserů, dospěl vývoj do stadia, kdy jsou lasery považovány za vysoce efektivní a spolehlivé výrobní nástroje či zařízení.

7.2.1 Vliv nastavení kroku posuvu laserového paprsku na hloubku obroběné drážky

Z grafů na Obr. 54, Obr. 55 a Obr. 56 je evidentní závislost zvyšující se hloubky drážky h se zvyšujícím se výkonem P . Z toho plyne, že požadovanou hloubku obroběné drážky lze regulovat zvyšujícím se výkonem. Toto pravidlo neplatilo pouze při nastavení kroku posuvu laserového paprsku na 1000 DPI s posuvem $f=30\%$ a výkonem $P=60\%$, kde došlo ke snížení hloubky drážky o 128,3 μm .

Zajímavou závislostí je i vliv nastavení posuvu f . U všech nastavení posuvu je vždy hlubší drážka h obrobena krokem posuvu na 1000 DPI.

Dále je zřejmé, že při nastavení jemnějšího kroku posuvu laserového paprsku (na 1000 DPI) je hloubka obrobené drážky h hlubší.

7.2.2 Vliv nastavení kroku posuvu laserového paprsku na střední aritmetickou úchylku

Drsnost obrobených ploch byla měřena přístrojem SurfTest SJ-301.

Z grafů na Obr. 48, Obr. 49 a Obr. 50 je viditelný takřka konstantní rozdíl průběhu střední aritmetické úchylky Ra v závislosti na nastavení výkonu P a posuvu f při kroku posuvu laserového paprsku na 500 i 1000 DPI, pohybující se vyjádřeno průměrnou hodnotou v rozdílu 9,15 μm . S rostoucí hodnotou nastavení kroku posuvu laserového paprsku klesá hodnota střední aritmetické úchylky Ra .

Dále je možné sledovat závislost nastavení posuvu f a střední aritmetické úchylky Ra , kde lze konstatovat, že se zvyšujícím se posuvem f se snižuje hodnota střední aritmetické úchylky Ra . S rostoucím výkonem P roste i hodnota střední aritmetické úchylky Ra .

Na základě výše uvedeného tedy lze konstatovat, že nadefinováním vhodné kombinace parametrů posuvu f , výkonu P a nastavení jemnosti kroku posuvu laserového paprsku lze dosáhnout požadované kvality obrobené plochy pro danou konkrétní praktickou aplikaci.

7.2.3 Vliv nastavení kroku posuvu laserového paprsku na maximální výšku profilu

Z grafů na Obr. 51, Obr. 52 a Obr. 53 je viditelný takřka konstantní rozdíl průběhu maximální výšky profilu Rz v závislosti na nastavení výkonu P a posuvu f při kroku posuvu laserového paprsku na 500 i 1000 DPI, pohybující se vyjádřeno průměrnou hodnotou v rozdílu 50,2 μm .

Dle naměřených hodnot lze sledovat závislost nastavení výkonu P na maximální výšku profilu Rz . S rostoucím výkonem roste i hodnota maximální výšky profilu Rz . Dále je zajímavé sledovat průběh maximální výšky profilu Rz při zadaném parametru výkonu $P=80\%$, kdy u posuvu $f=60\%$ a $f=80\%$ dochází k mírnému poklesu u drážky obrobené s krokem posuvu laserového paprsku na 1000 DPI.

Vliv posuvu f na maximální výšku profilu Rz je sledovatelný z uvedených grafů, kde lze naměřené výsledky shrnout s tvrzením, že s rostoucím nastavením posuvu f klesá hodnota maximální výšky profilu Rz .

Z výše uvedeného vyplývá závislost nastavení výkonu P , posuvu f a maximální výšky profilu Rz , kde lze konstatovat, že se zvyšujícím se výkonem P se zvyšuje hodnota maximální

výšky profilu Rz , s rostoucím posuvem f klesá hodnota maximální výšky profilu Rz . Drsnost povrchu lze dále ovlivnit nastavením kroku posuvu laserového paprsku, kdy se zvyšujícím se krokem posuvu klesá hodnota maximální výšky profilu Rz .

Lze tedy konstatovat, že pomocí vhodné konfigurace parametrů posuvu f , výkonu P a nastavení kroku posuvu laserového paprsku je možno dosáhnout požadované výsledné kvality povrchu obráběné plochy.

ZÁVĚR

Cílem této diplomové práce byla verifikace modelu umělé neuronové sítě na CO₂ laseru Mercury L30. Model umělé neuronové sítě byl vytvořen na základě vstupních parametrů získaných měření obrobených drážek na desce z PMMA. S ohledem na strukturu neuronového modelu a jeho výpočetní schopnosti po přidání verifikačních parametrů byl tento model modifikován na jednodušší strukturu, která ve výsledném efektu již počítala požadované výstupní parametry výkonu a posuvu s poměrně vysokou přesností a to v součinnosti s učícími i verifikačními daty. Verifikační parametry byly získány měření po obrobení desky z totožného materiálu při dodržení stejných technologických postupů.

Dále byla sledována závislost nastavení kroku posuvu laserového paprsku na sledované parametry hloubky drážky, střední aritmetické úchytky a maximální výšky profilu při obrábění PMMA. K tomuto účelu byla obrobena deska s nastavením kroku posuvu laserového paprsku na 1000 DPI. Na základě měření drsností R_a , R_z a hloubky h byl vytvořen model umělé neuronové sítě, který se naučil s poměrně vysokým stupněm přesnosti počítat výstupní parametry výkonu a posuvu dle učících dat. Dále byla tato umělá neuronová síť verifikována a modifikována tak, aby dosahovala vyššího stupně přesnosti při výpočtu výstupních parametrů výkonu a posuvu.

Dle výsledných naměřených hodnot hloubky drážky, střední aritmetické úchytky a maximální výšky profilu byly sledovány optimální konfigurace nastavení výkonu a posuvu vedoucí k dosažení požadovaných hodnot hloubky drážky, střední aritmetické úchytky a maximální výšky profilu pro plochy obrobené s krokem posuvu laserového paprsku na 500 a na 1000 DPI.

Aplikace umělých neuronových sítí do výrobního procesu s sebou přináší řadu výhod spojených s nižšími výrobními náklady a odstranění nežádoucích faktorů lidské chyby. Vzhledem k tomu, že se jedná o poměrně novou technologii, lze do blízké budoucnosti predikovat její rozšíření ve výrobním procesu.

SEZNAM POUŽITÉ LITERATURY

- [1] ZELINKA, I. *Umělá inteligence*. Praha : nakladatelství BEN, 2002, 192 s.
ISBN 80-7300-069-5
- [2] HOPFIELD, J.; TANK, D. *Neural Computation of Decisions in Optimization Problems*, Biological Cybernetics, USA : Springer-Verlang, 1985
- [3] NOVÁK, M. a kol. *Umělé neuronové sítě, teorie a aplikace*, Praha : Nakladatelství C. H. Beck, 1998, 382 s. ISBN 80-7179-132-6
- [4] ŠÍMA, J.; NERUDA, R. *Teoretické otázky neuronových sítí*. Matfyzpress, Praha : Matfyzpress, 1996 ISBN 80-85863-18-9
- [5] ŠNOREK, M. *Neuronové sítě a neuropočítače*. Praha : Vydavatelství ČVUT, 2002
156 s. ISBN 80-01-02549-7
- [6] SEDLÁČEK, K. *Laser v mnoha podobách*, Praha : Naše vojsko, 1982, 253 s. ISBN 0-582-178-1
- [7] HENDRYCHOVÁ, B. *Výzkum mikroobrábění polymerních materiálů laserem*. (Diplomová práce) FT UTB Zlín, 2003
- [8] DUŠEK F. *Matlab a Simulink úvod do používání*, Pardubice : Univerzita Pardubice, 2000, 146 s. ISBN 80-7194-273-1.
- [9] TARABA, O.; KODEŠ, J. *Zázraky světla-lasery*. Praha : Vydavatelství ROH, 1965,
68 s. ISBN 24-045-65
- [10] NOVÁK, T. *Lasery [online]*. © 2003-2005, poslední aktualizace 10.3.2005. Dostupné z WWW: < <http://www.lasery.org> >
- [11] LUKOVICS, I. *Konstrukční materiály a technologie*. Zlín : Vydavatelství VUT FT, 1992, 273 s. ISBN 80-214-0399-3
- [12] KRYŠTŮFEK, M., *Řezání polymerních materiálů laserem*. (Diplomová práce) FT UTB Zlín, 2000
- [13] BEDNAŘÍK, F., *Metody statistické analýzy*. Brno : Vydavatelství VUT v redakci MON, 1991, 75 s. ISBN 80-214-0240-7

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

c	Rychlost světla ve vakuu [$\text{m}\cdot\text{s}^{-1}$]
f	Rychlost posuvu laseru udávaná v %
$f()$	Označení přenosové funkce
f_{max}	Maximální hodnota rychlosti posuvu laseru [%]
h	Planckova konstanta [Js]
h	Hloubka obrobené drážky [mm]
I	Hustota výkonu laseru [$\text{W}\cdot\text{cm}^{-3}$]
n	Počet měřených veličin [1]
q	Maximální hodnota energetického toku laseru [$\text{W}\cdot\text{cm}^2$]
s	Směrodatná odchylka [1]
t	Čas [s]
w	Synoptická váha neuronu
w_0	Prahová hodnota neuronu
w_n	Váha neuronu pro vstupní data x_n
x	Vstupní hodnota
x_i	i -tá hodnota měřené veličiny
y	Označení výstupní hodnoty z UNS
N	Neuron
P	Výkon laseru udávaný v %
P_{in}	vstupní elektrická energie Nd:YAG laseru
P_{max}	Maximální hodnota výkonu laseru
P_{out}	výstupní výkon vyzářeného světla Nd:YAG laseru
R	Hloubka proniknutí záření laseru do materiálu [μm]
R_a	Průměrná aritmetická úchylka posuzovaného profilu [μm]
R_z	Největší výška profilu [μm]
T	Teplota [$^{\circ}\text{C}$]
γ	Konduktivita materiálu [Siemens $\cdot\text{m}^{-1}$]
λ	Vlnová délka záření laseru [μm]
λ_s	Filtr k potlačení vlnitosti
μ_r	Relativní permeabilita materiálu
Al	Hliník

AND	Logická funkce
Ar laser	Argonový laser
ART síť	Adaptive resonance theory (adaptivní rezonanční teorie)
COUNT	Síť se zpětným řízením
ČSN	Česká technická norma
DPI	Dots per inch (počet pixelů v 1 čtverečním palci)
HAMM	Hammingova síť
HEBB	Hebbova síť
He-Ne Laser	Helium neodymový laser
LASER	Light Amplification by Stimulated Emission of Radiation (zesilování světla stimulovanou emisí záření)
MLP1	Několika vrstvá síť s bipolárními neurony
MLP2	Několika vrstvá síť se spojitým chováním
MOD	Modulární síť
Nd:Yag	Neodymem (Nd^{+3}) dopovaný yttrito-hlinitým granátem
NS, UNS	Označení neuronové sítě, umělé neuronové sítě
OLAM	Optimální lineární asociativní paměť
PC	Personal Computer (osobní počítač)
PES	Polyetylenstyren
PMMA	Polymethylmetakrylát
PURELIN	Linear transfer function (Lineární aktivační funkce)
RBF	Síť s radiální bází
SATLIN	Saturating Linear Transfer Function (Saturační lineární aktivační funkce)
SATLINS	Symmetric linear saturating transfer function (Symetrická saturační lineární aktivační funkce)
SOM	Kohenovy mapy
TANSIG	Tan-sigmoid transfer function (Tansigmoidální aktivační funkce)
TEA CO ₂ laser	Transversally Excited Atmospheric Pressure (příčně buzený laser za atmosférického tlaku)

SEZNAM OBRÁZKŮ

Obr. 1 Model neuronu ze 40. let	13
Obr. 2 Jednoduchý popis neuronu	13
Obr. 3 Umělá neuronová síť 3-2	15
Obr. 4 Vrstvová struktura umělé neuronové sítě	18
Obr. 5 Hopfieldova síť	19
Obr. 6 Realizace binární funkce AND pomocí jednoho neuronu	19
Obr. 7 Schéma perceptronu	20
Obr. 8 Schéma přenosové aktivační funkce tansig	22
Obr. 9 Schéma přenosové aktivační funkce purelin	23
Obr. 10 Schéma přenosové aktivační funkce satlin	23
Obr. 11 Schéma přenosové aktivační funkce satlins	24
Obr. 12 Hierarchická síť 3-2-3 se skrytou vrstvou [5]	24
Obr. 13 Spektrum elektromagnetických vln	32
Obr. 14 Fotografie prvně sestrojeného laseru (Theodore Maiman)	34
Obr. 15 Srovnání světla vyzařovaného laserem se světlem žárovky	35
Obr. 16 Absorpce, spontánní a stimulovaná emise	37
Obr. 17 Základní stav atomu	38
Obr. 18 Základní konstrukce laseru	39
Obr. 19 Tvar paprsku laseru	39
Obr. 20 Schéma rubínového laseru [10]	42
Obr. 21 Základní schéma kontinuálního Nd:YAG laseru [10]	43
Obr. 22 Schéma CO ₂ laseru [10]	47
Obr. 23 He-Ne laser s výkonem 10 mW [10]	50
Obr. 24 Princip popisování vychylováním paprsku	56
Obr. 25 Porovnání standardní a ploché čočky	56
Obr. 26 Princip maskovací metody popisování	57
Obr. 27 Princip technologie kyvadlového zrcadla	57

Obr. 28 Lokální změna barvy nebo povrchové struktury.....	58
Obr. 29 Příklad laserového popisu chirurgického nástroje.....	60
Obr. 30 Ukázka svařování nerez plechu 0,5 mm.....	63
Obr. 31 Příklady laserového řezání kovových materiálů.....	65
Obr. 32 Možnosti použití laserů [11].....	66
Obr. 33 CO ₂ laser Mercury L30.....	71
Obr. 34 Přístroj Surftest SJ 301	72
Obr. 35 Lineární výškoměr LH-600 B	73
Obr. 36 Schéma desky s vygravírovanými zkušebními plochami	75
Obr. 37 Ovládací displej lineárního výškoměru LH-600 B	78
Obr. 38 3D graf závislosti drsnosti R_a [μm] na výkonu P [%] a posuvu f [%].....	80
Obr. 39 3D graf závislosti drsnosti R_z [μm] na výkonu P [%] a posuvu f [%]	81
Obr. 40 3D graf závislosti hloubky h [μm] na výkonu P [%] a posuvu f [%]	82
Obr. 41 Schéma modelu umělé neuronové sítě k verifikaci	83
Obr. 42 Graf vyjádření absolutní chyby při verifikaci	85
Obr. 43 Schéma modelu nově vytvořené umělé neuronové sítě.....	86
Obr. 44 Graf vyjádření chyby výstupní hodnoty při verifikaci po modifikaci UNS.....	87
Obr. 45 3D graf závislosti drsnosti R_a [μm] na výkonu P [%] a posuvu f [%].....	90
Obr. 46 3D graf závislosti drsnosti R_z [μm] na výkonu P [%] a posuvu f [%]	91
Obr. 47 3D graf závislosti hloubky h [μm] na výkonu P [%] a posuvu f [%]	92
Obr. 48 Graf závislosti střední aritmetické úchylky R_a na výkonu P při konstantním posuvu $f=30\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI.....	93
Obr. 49 Graf závislosti střední aritmetické úchylky R_a na výkonu P při konstantním posuvu $f=50\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI.....	93
Obr. 50 Graf závislosti střední aritmetické úchylky R_a na výkonu P při konstantním posuvu $f=80\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI.....	94
Obr. 51 Graf závislosti maximální výšky profilu R_z na výkonu P při konstantním posuvu $f=30\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI.....	94

Obr. 52 Graf závislosti maximální výšky profilu R_z na výkonu P při konstantním posuvu $f=50\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI.....	95
Obr. 53 Graf závislosti maximální výšky profilu R_z na výkonu P při konstantním posuvu $f=80\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI.....	95
Obr. 54 Graf závislosti hloubky h na výkonu P při konstantním posuvu $f=30\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI	96
Obr. 55 Graf závislosti hloubky h na výkonu P při konstantním posuvu $f=50\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI	96
Obr. 56 Graf závislosti hloubky h na výkonu P při konstantním posuvu $f=70\%$ pro desku s krokem posuvu laserového paprsku 500 a 1000 DPI	97
Obr. 57 Blokové schéma vytvořené umělé neuronové sítě.....	100
Obr. 58 Graf vyjádření absolutní chyby při učení na učící data po modifikaci UNS	102
Obr. 59 Graf vyjádření chyby výstupní hodnoty při verifikaci	105

SEZNAM TABULEK

Tab. 1 Rozdíl mezi PC a umělou neuronovou sítí [1]	17
Tab. 2 Tradiční použití neuronových sítí	29
Tab. 3 Základní fyzikální vlastnosti růžového rubínu [10].....	42
Tab. 4 Pracovní parametry komerčních CO ₂ laserů [10]	48
Tab. 5 Charakteristiky materiálů.....	48
Tab. 6 Konfigurace zrcadel rezonátoru [10]	49
Tab. 7 Hustota výkonu dosahovaná různými zdroji energie [12]	55
Tab. 8 Možnosti laserového řezání [12]	65
Tab. 9 Technické parametry CO ₂ laseru, typ MERCURY L-30.....	70
Tab. 10 Technické parametry přístroje	71
Tab. 11 Technické parametry LH-600 B	72
Tab. 12 Přepočtová tabulka jednotek výkonu P a posuvu f	76
Tab. 13 Závislosti drsnosti R_a [μm] na výkonu P [%] a posuvu f [%]	80
Tab. 14 Závislosti drsnosti R_z [μm] na výkonu P [%] a posuvu f [%].....	81
Tab. 15 Závislosti hloubky drážky h [μm] na výkonu P [%] a posuvu f [%]	82
Tab. 16 Verifikace stávajícího neuronového modelu	84
Tab. 17 Chyba výstupní hodnoty při verifikaci.....	84
Tab. 18 Vypočtená výstupní data modelem umělé neuronové sítě po modifikaci UNS	86
Tab. 19 Chyba výstupní hodnoty při verifikaci po modifikaci UNS	87
Tab. 20 Závislosti drsnosti R_a [μm] na výkonu P [%] a posuvu f [%]	90
Tab. 21 Závislosti drsnosti R_z [μm] na výkonu P [%] a posuvu f [%].....	91
Tab. 22 Závislosti hloubky drážky h [μm] na výkonu P [%] a posuvu f [%]	92
Tab. 23 Vypočtená výstupní data modelu umělé neuronové sítě pro desku obrobenou s krokem posuvu laserového paprsku na 1000 DPI.....	100
Tab. 24 Chyba výstupní hodnoty při učení umělé neuronové sítě pro desku obrobenou s krokem posuvu laserového paprsku na 1000 DPI.....	101
Tab. 25 Naměřená verifikační data	102
Tab. 26 Verifikace stávajícího neuronového modelu (1000 DPI)	103

Tab. 27 Chyba výstupní hodnoty při verifikaci..... 105

SEZNAM PŘÍLOH

- P I** Shrnutí statistické analýzy naměřených dat příčné drsnosti R_a pro desku s krokem posuvu laserového paprsku 500 DPI
- P II** Shrnutí statistické analýzy naměřených dat příčné drsnosti R_z pro desku s krokem posuvu laserového paprsku 500 DPI
- P III** Shrnutí statistické analýzy naměřených dat hloubky vygravírovaných drážek h pro desku s krokem posuvu laserového paprsku 500 DPI
- P IV** Shrnutí statistické analýzy naměřených dat příčné drsnosti R_a pro desku s krokem posuvu laserového paprsku 1000 DPI
- P V** Shrnutí statistické analýzy naměřených dat příčné drsnosti R_z pro desku s krokem posuvu laserového paprsku 1000 DPI
- P VI** Shrnutí statistické analýzy naměřených dat hloubky h pro desku s krokem posuvu laserového paprsku 1000 DPI
- P VII** Elektronická verze diplomové práce s přílohami [CD ROM]

P I. Shrnutí statistické analýzy naměřených dat příčné drsnosti R_a pro deku obrobenou s krokem posuvu laserového paprsku na 500 DPI

Posuv	Výkon	Aritmetický	Směrodatná od-	Výběrový rozptyl
30%	30%	19,18	0,0379	0,0014
	40%	21,21	0,0196	0,0004
	50%	22,96	0,0295	0,0009
	60%	24,11	0,0195	0,0004
	70%	24,21	0,0279	0,0008
	80%	23,19	0,0842	0,0071
40%	30%	19,21	0,0291	0,0008
	40%	20,41	0,0357	0,0013
	50%	21,09	0,0317	0,0010
	60%	21,53	0,0550	0,0030
	70%	22,07	0,0814	0,0066
	80%	22,26	0,0375	0,0014
50%	30%	18,11	0,0308	0,0010
	40%	20,39	0,0503	0,0025
	50%	20,30	0,0441	0,0019
	60%	23,45	0,0435	0,0019
	70%	22,23	0,0403	0,0016
	80%	23,95	0,0472	0,0022
60%	30%	14,35	0,0309	0,0010
	40%	14,72	0,0479	0,0023
	50%	17,08	0,0591	0,0035
	60%	17,11	0,0196	0,0004
	70%	19,73	0,0478	0,0023
	80%	19,41	0,0567	0,0032
70%	30%	14,29	0,0320	0,0010
	40%	14,39	0,0350	0,0012
	50%	16,89	0,0385	0,0015
	60%	18,19	0,1050	0,0110
	70%	18,48	0,0581	0,0034
	80%	19,75	0,2055	0,0422
80%	30%	12,12	0,0776	0,0060
	40%	13,62	0,0524	0,0027
	50%	16,83	0,0527	0,0028
	60%	16,32	0,0486	0,0024
	70%	17,33	0,0380	0,0014
	80%	18,58	0,0497	0,0025

P II. Shrnutí statistické analýzy naměřených dat příčné drsnosti R_z pro desku obrobenou s krokem posuvu laserového paprsku na 500 DPI

Posuv	Výkon	Aritmetický průměr [mm]	Směrodatná odchylka [1]	Výběrový rozptyl [1]
30%	30%	102,14	0,0263	0,0007
	40%	116,08	0,0263	0,0007
	50%	124,31	0,0227	0,0005
	60%	130,26	0,0190	0,0004
	70%	134,72	0,0527	0,0028
	80%	135,51	0,0270	0,0007
40%	30%	101,94	0,0572	0,0033
	40%	103,92	0,0354	0,0012
	50%	106,28	0,0323	0,0010
	60%	118,84	0,0453	0,0020
	70%	120,48	0,0386	0,0015
	80%	123,82	0,0367	0,0013
50%	30%	89,27	0,0355	0,0013
	40%	106,57	0,0392	0,0015
	50%	108,31	0,0359	0,0013
	60%	125,55	0,0390	0,0015
	70%	126,91	0,0494	0,0024
	80%	126,63	0,0492	0,0024
60%	30%	72,85	0,0418	0,0017
	40%	79,98	0,0695	0,0048
	50%	94,71	0,0414	0,0017
	60%	95,09	0,0412	0,0017
	70%	98,40	0,0467	0,0022
	80%	100,60	0,0410	0,0017
70%	30%	78,17	0,0486	0,0024
	40%	89,42	0,1145	0,0131
	50%	96,83	0,0411	0,0017
	60%	98,46	0,0899	0,0081
	70%	113,59	0,0813	0,0066
	80%	118,49	0,0723	0,0052
80%	30%	68,85	0,1721	0,0296
	40%	77,83	0,0532	0,0028
	50%	94,21	0,0591	0,0035
	60%	94,33	0,0405	0,0016
	70%	100,44	0,0435	0,0019
	80%	104,57	0,0479	0,0023

P III. Shrnutí statistické analýzy naměřených dat hloubky drážek h pro desku obrobenou s krokem posuvu laserového paprsku na 500 DPI

Posuv	Výkon	Aritmetický průměr [mm]	Směrodatná odchylka [1]	Výběrový rozptyl [1]
30%	30%	121,40	0,0187	0,0004
	40%	161,80	0,0282	0,0008
	50%	203,40	0,0170	0,0003
	60%	237,21	0,0178	0,0003
	70%	268,60	0,0274	0,0008
	80%	276,80	0,0282	0,0008
40%	30%	85,59	0,0427	0,0018
	40%	117,81	0,0400	0,0016
	50%	141,31	0,0631	0,0040
	60%	182,39	0,0619	0,0038
	70%	215,62	0,0448	0,0020
	80%	227,74	0,0414	0,0017
50%	30%	63,56	0,0354	0,0013
	40%	85,27	0,0424	0,0018
	50%	101,56	0,0374	0,0014
	60%	129,74	0,0333	0,0011
	70%	165,13	0,9411	0,8857
	80%	167,27	0,0377	0,0014
60%	30%	54,77	0,0504	0,0025
	40%	76,59	0,0490	0,0024
	50%	90,58	0,0365	0,0013
	60%	106,38	0,0395	0,0016
	70%	127,86	0,1718	0,0295
	80%	137,09	0,0896	0,0080
70%	30%	22,65	0,0649	0,0042
	40%	34,83	0,0493	0,0024
	50%	66,80	0,0816	0,0067
	60%	68,26	0,0522	0,0027
	70%	82,72	0,0647	0,0042
	80%	108,49	0,0402	0,0016
80%	30%	16,89	0,0585	0,0034
	40%	30,26	0,0532	0,0028
	50%	46,89	0,0482	0,0023
	60%	60,80	0,0451	0,0020
	70%	69,46	0,0467	0,0022
	80%	109,51	0,0634	0,0040

P IV. Shrnutí statistické analýzy naměřených dat příčné drsnosti R_a pro desku obrobenou s krokem posuvu laserového paprsku na 1000 DPI

Posuv	Výkon	Aritmetický průměr [mm]	Směrodatná odchylka [1]	Výběrový rozptyl [1]
30%	30%	9,33	0,3286	0,1080
	40%	12,59	0,7486	0,5604
	50%	13,06	0,7344	0,5393
	60%	13,63	1,0591	0,3217
	70%	13,75	0,8569	0,7342
	80%	16,24	1,3227	1,7494
40%	30%	9,81	0,4216	0,1777
	40%	10,73	0,7742	0,5994
	50%	11,54	0,3440	0,1183
	60%	11,49	0,5631	0,3170
	70%	10,84	0,9739	0,9485
	80%	14,78	0,8926	1,5821
50%	30%	7,33	0,5769	0,3329
	40%	8,19	0,3432	0,1178
	50%	8,99	0,2798	0,0783
	60%	10,34	0,2964	0,0879
	70%	10,07	0,8039	0,6463
	80%	9,30	0,8149	0,6641
60%	30%	7,02	0,2664	0,0710
	40%	8,72	0,4014	0,9640
	50%	9,49	0,5779	0,3340
	60%	9,14	0,3714	0,1379
	70%	9,98	0,5219	0,2724
	80%	9,50	0,7303	0,5334
70%	30%	6,69	0,3581	0,1283
	40%	8,16	0,5024	0,2524
	50%	11,67	0,4907	0,2408
	60%	10,13	0,4079	0,1664
	70%	8,80	0,2942	0,0865
	80%	9,27	0,6207	0,3852
80%	30%	6,44	0,3643	0,1327
	40%	8,01	0,4260	0,1815
	50%	9,28	0,4532	0,2054
	60%	8,84	0,5176	0,2679
	70%	8,08	0,6794	0,4616
	80%	7,36	0,3871	0,1498

P V. Shrnutí statistické analýzy naměřených dat příčné drsnosti R_z pro desku obrobenou s krokem posuvu laserového paprsku na 1000 DPI

Posuv	Výkon	Aritmetický průměr [mm]	Směrodatná odchylka [1]	Výběrový rozptyl [1]
30%	30%	51,64	2,2976	5,2791
	40%	72,62	3,3274	11,0717
	50%	70,22	3,6587	12,3864
	60%	75,17	4,8360	13,3871
	70%	77,85	7,2432	12,4647
	80%	84,66	6,1309	17,5878
40%	30%	52,81	2,3609	5,5740
	40%	59,43	5,8406	12,1130
	50%	63,81	2,2350	4,9951
	60%	63,23	3,8206	14,5969
	70%	59,93	3,0275	9,1656
	80%	78,73	6,3105	19,8229
50%	30%	41,14	3,9054	15,2519
	40%	46,03	3,2370	10,4780
	50%	51,07	2,0941	4,3852
	60%	54,33	3,9027	15,2313
	70%	56,23	2,6383	6,9079
	80%	53,87	4,1273	17,0348
60%	30%	39,24	1,5695	2,4635
	40%	46,44	4,2493	18,0563
	50%	53,07	2,4012	5,7657
	60%	56,78	2,4436	18,9564
	70%	57,11	4,3539	18,9564
	80%	53,38	3,5047	12,2829
70%	30%	36,82	2,4262	5,8863
	40%	44,30	3,4703	12,0430
	50%	54,76	5,3235	18,3397
	60%	51,86	1,4794	2,1887
	70%	48,22	2,7814	7,7364
	80%	50,84	3,4120	11,6417
80%	30%	35,23	1,8234	3,3248
	40%	44,84	2,7182	7,3888
	50%	50,14	1,5465	2,3916
	60%	47,52	4,0789	16,6374
	70%	44,35	3,2794	10,7545
	80%	40,53	3,4594	11,9672

P VI. Shrnutí statistické analýzy naměřených dat hloubky h pro desku obrobenou s krokem posuvu laserového paprsku na 1000 DPI

Posuv	Výkon	Aritmetický Průměr [mm]	Směrodatná odchylka [1]	Výběrový rozptyl [1]
30%	30%	210,3	0,0109	0,0001
	40%	360,9	0,0206	0,0004
	50%	444,0	0,0189	0,0004
	60%	720,3	0,0190	0,0004
	70%	591,7	0,0140	0,0002
	80%	658,0	0,0145	0,0002
40%	30%	186,7	0,0890	0,0079
	40%	292,3	0,0620	0,0038
	50%	451,0	0,0213	0,0005
	60%	541,4	0,0121	0,0001
	70%	601,2	0,0175	0,0003
	80%	667,1	0,0482	0,0023
50%	30%	244,8	0,0580	0,0034
	40%	337,6	0,0139	0,0002
	50%	410,8	0,0101	0,0002
	60%	486,7	0,0720	0,0001
	70%	546,5	0,0350	0,0052
	80%	598,3	0,0660	0,0010
60%	30%	332,1	0,0980	0,0044
	40%	111,8	0,0620	0,0038
	50%	188,4	0,0440	0,0019
	60%	305,1	0,0460	0,0021
	70%	257,7	0,0461	0,0021
	80%	369,3	0,0345	0,0012
70%	30%	70,8	0,0330	0,0011
	40%	72,5	0,0310	0,0001
	50%	124,8	0,0270	0,0007
	60%	202,2	0,0340	0,0012
	70%	257,8	0,0185	0,0003
	80%	317,2	0,0370	0,0014
80%	30%	29,3	0,0250	0,0006
	40%	36,8	0,0280	0,0008
	50%	95,6	0,0140	0,0002
	60%	158,4	0,0496	0,0025
	70%	225,8	0,0330	0,0011
	80%	274,8	0,0310	0,0009