

Na tomto místě bych rád poděkoval v první řadě vedoucímu mé diplomové práce Ing. Davidu Sámkovi za cenné rady a připomínky a pomoc při tvorbě této diplomové práce. Dále bych chtěl také poděkovat firmě Mechanika p.v Prostějov za vstřícný přístup a cenné praktické rady při výrobě vzorkového dílu.

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

Ve Zlíně, 24. 05. 2005

.....

jméno diplomanta

Abstrakt

Laserové popisování je proces s několika vstupními a výstupními parametry, které je nutno řídit, k dosažení kvalitního a ekonomického výsledku.

Konkrétně, monitorujeme na vstupu výkon laseru a rychlost posuvu. Na výstupu pak hloubku drážky a čtyři parametry drsnosti povrchu. R_a – průměrnou aritmetickou úchylku profilu a R_z – největší úchylku profilu, v podélném a příčném směru.

Umělé neuronové sítě nám umožňují tento proces s několika proměnnými optimalizovat a řídit. Další výhodou je také schopnost neuronových sítí „učit se“ a tak dále zvyšovat přesnost výsledku.

Laser scribing process has more than one input and output parameters, that need to be controlled for the quality and economic production.

Particularly, laser strength and rate of feed is monitored on the input. Slot depth and four parameters of surface roughness are measured on the output. R_a – average arithmetic profile deviation and R_z – highest profile deviation, both in lengthwise and crosswise direction.

Artificial neural networks are used for optimization and controlling this process. Subsequent advantage of artificial neural networks is “learning ability” to rise production accuracy.

OBSAH

ÚVOD	7
I. TEORETICKÁ ČÁST	8
1 NEURONOVÉ SÍTĚ	9
1.1 HISTORIE	9
1.2 DĚLENÍ SÍTÍ, ZÁKLADNÍ POJMY	11
1.3 PŘENOSOVÁ FUNKCE	12
1.4 OBECNÉ SCHÉMA NEURONOVÉ SÍTĚ	13
1.5 PRINCIP FUNKCE SÍTĚ	14
2 TYPY SÍTÍ	16
2.1.1 Perceptron	16
2.1.2 Vícevrstvá síť s algoritmem „backpropagation“	17
2.1.3 Hopfieldova síť	18
2.1.4 Síť CLN (Competitive Learning Network)	19
2.1.5 Síť BAM (Bidirectional Associative Memory)	20
2.1.6 Kohonenova síť	21
2.1.7 Síť ART (Adaptive Resonant neTwork)	22
3 PRINCIP FUNKCE LASERU	24
3.1 TYPY LASERŮ	28
3.1.1 Pevnolátkové lasery	29
3.1.2 Kapalinové lasery	30
3.1.3 Plynové lasery	30
3.1.4 Polovodičové lasery	31
3.1.5 Excimerové lasery	32
3.1.6 Chemické lasery	32
3.1.7 EUV lasery	33
3.1.8 Rentgenové lasery	33
3.1.9 Vláknové lasery	34
4 LASEROVÉ OBRÁBĚNÍ PLASTŮ	35
4.1 LASEROVÉ POPISOVÁNÍ	36
4.1.1 Popisování vychylováním laserového paprsku	36
4.1.2 Popisování maskovací metodou	37
4.1.3 Způsoby laserového popisování	39
4.2 VÝHODY A NEVÝHODY LASEROVÉHO POPISOVÁNÍ	40
II. PRAKTICKÁ ČÁST	41
5 STANOVENÍ CÍLE DIPLOMOVÉ PRÁCE	42
6 VSTUPNÍ DATA	43
6.1 NAMĚŘENÁ DATA	45
6.2 ROZDÍL MEZI PODÉLNOU A PŘÍČNOU DRSNOSTÍ	50
6.2.1 Rozdíl laserového gravírování v podélném a příčném směru	50
6.2.2 Princip měření drsnosti	51
6.2.3 Chyba měření u podélné drsnosti	51
7 VÝSTUPNÍ DATA	52
7.1 VOLBA UMĚLÉ NEURONOVÉ SÍTĚ	52
7.1.1 Popis programu pro aplikaci Matlab	52
7.2 VÝSLEDKY UMĚLÉ NEURONOVÉ SÍTĚ	54
7.2.1 Závislost jednoho vstupního na jednom výstupním parametru	55

7.2.2	Závislost dvou vstupních na dvou výstupních parametrech.....	56
7.2.3	Závislost třech vstupních na dvou výstupních parametrech.....	59
7.2.4	Závislost pěti vstupních na dvou výstupních parametrech.....	62
ZÁVĚR.....		65
SEZNAM POUŽITÝCH ZDROJŮ		67
SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK.....		68
SEZNAM OBRÁZKŮ.....		69
SEZNAM TABULEK		71
SEZNAM PŘÍLOH.....		72

ÚVOD

Laserové popisování (gravírování) je proces, ve kterém se vyskytuje několik vstupních i výstupních parametrů, které je nutno řídit tak, aby se dosáhlo kvalitního a zároveň ekonomicky efektivního výsledku.

U laserového popisování v našem případě monitorujeme:

VSTUP

- výkon laseru
- rychlost posuvu paprsku

VÝSTUP

- hloubku drážky
- drsnost povrchu, a to:

R_{a1} - průměrná aritmetická úchylka v podélném směru

R_{z1} - největší výška profilu v podélném směru

R_{a2} - průměrná aritmetická úchylka v příčném směru

R_{z2} - největší výška profilu v příčném směru

Vyskytují se zde tedy dva vstupní parametry ovlivňující pět výstupních parametrů, přičemž změna každého jednotlivého vstupního parametru má jiný vliv na výstup a navíc tyto proměnné nemají lineární průběh, což dále komplikuje predikci.

Neuronových sítí se využívá s výhodou všude tam, kde je potřeba řídit a optimalizovat systém, který má několik vstupních i výstupních parametrů, čehož při použití jiných optimalizačních metod dosáhnout nelze nebo lze jen velmi obtížně. Výhodou neuronových sítí je také schopnost učit se a tak i dále zvyšovat pravděpodobnost správnosti predikovaného výsledku.


Neuronové sítě tedy nahrazují – automatizují - v procesu laserového popisování metodu optimalizace kvalifikovaného odhadu zkušeným pracovníkem.

I. TEORETICKÁ ČÁST

1 NEURONOVÉ SÍTĚ

1.1 Historie

Historie vzniku a stále pokračujícího vzniku vývoje umělých neuronových sítí (dále jen neuronových sítí) spadá do první poloviny 20. století, kdy byla publikována první práce o neuronech a jejich modelech Američanem W. S. McCullochem. Ve 40. letech tohoto století pak se svým studentem W. Pittsem vypracoval model neuronu, který je prakticky používán dodnes (obr. 10). Na základě těchto výsledků v roce 1958 F. Rosenblatt vytvořil první funkční perceptronovou síť, která měla jeden velký nedostatek a to ten, že byla schopna řešit pouze problémy, které byly lineárně separabilní. Poté zájem o neuronové sítě opadl. Jen díky několika průkopníkům, kteří se nedali odradit, vděčíme za to, že v polovině 80. let došlo k renesanci neuronových sítí, jejichž význam stoupá každým dnem. V těchto letech vznikla práce D. Rumelharta, G. Hinton a R. Wiliamse „Learning Internal Representation by Error Propagation“, která pojednává o vícevrstvých sítích, které jsou schopny řešit i problémy, jenž nejsou lineárně separabilní. V 80. letech vznikají i další typy sítí jako Hopfieldova síť, Kohonenova síť a Grossbergova ART síť. Význam a uplatnění neuronových sítí nabývá stále většího významu podobně jako PC v 80. letech.(9)



Obr 1. Model neuronu ze 40. let (9)

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 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.(9)

Několik důležitých rozdílů mezi klasickým PC a neuronovou sítí je uvedeno v Tabulka I.

Tabulka I. Rozdíl mezi PC a neuronovou sítí (9)

Neuronová síť	Počítač
Je určena nastavováním vah, prahů a struktury	Je programován instrukcemi, (if, then, go to, ...)
Paměťové a výkonné prvky jsou uspořádány spolu	Proces a paměť pro něj jsou separovány
Paralelismus	Sekvenčnost
Tolerují odchylky od originálních informací	Netolerují odchylky
Samoorganizace během učení	Neměnnost programu

Využití neuronových sítí je opravdu široké a nabývá čím dál tím více na významu. Lze je použít například na:

- Identifikaci radarových či sonarových signálů
- Predikci chování
- Klasifikaci
- Optimalizaci
- Filtraci signálů

1.2 Dělení sítí, základní pojmy

Technické neuronové sítě se 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 pohybem)
- Bez učitele (Hopfieldova síť, ...)

Podle stylu učení na síť s učícím:

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

To jsou nejpoužívanější typy dělení, které jsou níže rozepsány.

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. Síť s jednou či dvěma vrstvami bývají většinou speciální sítě jako např. Hopfieldova, Kohonenova či ART síť, které mají svůj speciální učící 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 (Obr 3). Zvláštností je např. Hopfieldova síť (Obr 7), 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 neznámá, že spoj s malou vahou můžeme zanedbat, protože nevíme, jaký vliv má tento vstup na celkovou činnost sítě.

Podle algoritmu učení.

Podle algoritmu učení. lze dělit sítě 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.

Učení bez učitele je proces, ve kterém síť vychází 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. (9)

1.3 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 spojité (sigmoida, hyperbolický tangens, ...), nebo s nespojitostí prvního druhu (binární funkce 0-1). Volba funkce závisí na problému, který chceme řešit. Mezi nejpoužívanější funkce patří:


- Perceptron
- Binární
- Logistická (používá se též výraz „sigmoida“)
- Hyperbolický tangens



Obr 2. Nejvíce používaná funkce – logistická (9)

1.4 Obecné schéma neuronové sítě

V technickém slova smyslu si lze představit obecnou neuronovou síť jako síť složenou z několika vrstev, přičemž každá vrstva se skládá z „libovolného“ počtu neuronů. Libovolného samozřejmě jen teoreticky, protože jsme limitováni technickými podmínkami. Kromě vícevrstvých sítí existují také sítě o jedné vrstvě jako např. síť Hopfieldova a Kohonenova. Obecný vzhled vícevrstvé sítě je na Obr 3. Problém vhodného počtu vrstev u vícevrstvých sítí byl vyřešen až ve druhé polovině našeho století. Vlastní funkce neuronové sítě je v podstatě transformační funkce, která přiřazuje jistému vstupnímu obrazu obraz výstupní. (9)




Obr 3. Klasická vícevrstvá síť (2 vrstvy po 3 neuronech) (9)

U vícevrstvých sítí platí, že první vrstva je vždy větvící, což znamená, že neurony ve vstupní vrstvě pouze distribuují vstupní hodnoty do další vrstvy. Každý vstup do neuronu, má přiřazenou tzv. váhu, což je bezrozměrné číslo, které „říká“ jaký význam má daný vstup pro příslušný neuron.

Učící schopnost neuronových sítí spočívá právě v možnosti měnit všechny váhy v síti podle vhodných algoritmů na rozdíl od sítí biologických, kde schopnost se učit založena na možnosti tvorby nových spojení mezi neurony. Fyzicky jsou tedy obě schopnosti se učit založeny na rozdílných principech, nicméně z hlediska logiky ne. V případě vzniku nového spoje-vstupu u biologického neuronu je to stejné, jako když v technické síti je spoj mezi dvěma neurony ohodnocen váhou 0 a tudíž jako vstup pro neuron, do kterého vstupuje

neexistuje. V okamžiku kdy se váha změní z 0 na libovolné číslo, tak se daný spoj zviditelní-vznikne. (9)



Obr 4. Různé topologie sítí (9)

1.5 Princip funkce sítě


Nově vytvořenou, ale také jakoukoliv nenaučenou neuronovou síť považujeme za jakéhosi technického novorozence, který nic neumí. Neumí rozeznávat, klasifikovat, ... Aby se mohla používat, musí být naučena stejně jako kterýkoliv živý jedinec (samozřejmě, že zde se množství informací a délka učení nedá porovnávat). Z tohoto důvodu byly vyvinuty algoritmy, pomocí kterých se příslušná síť dokáže naučit na danou množinu informací. Algoritmus se obvykle dělí na dvě fáze a to na fázi *aktivační* (vybavovací) a *adaptační* (učící), které ke své činnosti potřebují trénovací množinu. Trénovací množina je skupina vektorů obsahující informace o daném problému pro učení. Pokud učíme síť s učitelem, pak jsou to dvojice vektorů vstup-výstup. Jestliže učíme síť bez učitele, pak trénovací množina obsahuje jen vstupní vektory. Pokud používáme jen fázi aktivační, pak mluvíme o vybavování. Tato fáze se používá samostatně jen tehdy, když je síť naučena. Cyklické střídání obou fází je vlastně učení.

Aktivační fáze je proces, při kterém se předložený vektor informací na vstup sítě přepočítá přes všechny spoje včetně jejich ohodnocení vahami až na výstup, kde se objeví odezva sítě na tento vektor ve formě výstupního vektoru. Při učení se tento vektor porovná s vektorem originálním (požadovaným, výstupním) a rozdíl mezi oběma vektory (*lokální odchylka* – chyba) se uloží do paměťové proměnné.

Adaptační fáze je proces, při kterém je minimalizována lokální chyba sítě tak, že se přepočítávají váhy jednotlivých spojů směrem z výstupu na vstup za účelem co největší podobnosti výstupní odezvy s originálním vektorem. Po té se opět opakuje aktivační fáze. Další získaný rozdíl (lokální odchylka) se přičte k předchozímu, atd... Pokud se tímto postupem projde celá trénovací množina, je hotová jedna *epocha*. Celé sumě odchylek za jednu epochu se říká *globální odchylka* – chyba. Pokud je globální odchylka menší než námi požadovaná chyba, pak proces učení skončí. Z výše popsaného je vidět, že proces učení není nic jiného, než přelévání informací ze vstupu na výstup a naopak.

Při učení se v tzv. vstupním prostoru vytvářejí shluky bodů, které představují jednotlivé členy tříd, přičemž každý shluk představuje třídu.

To zda se síť naučí správným odezvám na dané podněty, závisí na více okolnostech, a to na množství vektorů a jejich velikosti, topologii sítě, odlišnosti charakteristických vlastností jednotlivých tříd, přípravě trénovací množiny, a jiných. Schopnost sítě přiřazovat jednotlivé vstupní členy daným třídám je daná tím, že síť v podstatě počítá vzdálenost daného členu od členů již přiřazených a na základě toho usuzuje do jaké třídy daný vektor patří. To samozřejmě může někdy znamenat problém, který se dá odstranit tzv. pravděpodobnostní sítí. (9)



Obr 5. Nelineární hranice mezi třídami (9)


2 TYPY SÍTÍ

Sítě s dopředným šířením

2.1.1 Perceptron

Perceptron byla první síť, která byla schopna učení. Tato síť má nastavitelné váhy u spojů, které vstupují do výstupní vrstvy. Perceptron je tedy z hlediska měnitelných vah jednovrstvou sítí, ale i přesto bývá zařazován mezi vícevrstvé sítě. Perceptron byl Rosenblattem vyvinut na základě existence dvou důležitých poznatků a to na existenci McCullochova-Pittsova modelu neuronu (který měl napevno nastavené váhy a práh) a faktu prezentovaného D. O. Hebbem, že učení u biologických neuronů je realizováno díky změnám v synapsích mezi neurony.

První vrstva v této síti nemá měnitelné váhy. Tato vrstva provádí konstantní transformaci ze vstupu. Druhá vrstva je vrstva s nastavitelnými vahami. Pokud bychom napojili vstupní vektor přímo na výstupní vrstvu, pak bychom dostali tzv. jednovrstvý perceptron. Označení vícevrstvá síť se používá spíše pro sítě, které mají více jak jednu vrstvu s nastavitelnými vahami. Přenosová funkce neuronu perceptronu je skoková. Funkce neuronu je v podstatě transformací vstupního obrazu na výstup. (9)



Obr 6. Schéma sítě Perceptron (9)

2.1.2 Vícevrstvá síť s algoritmem „backpropagation“

Backpropagation je algoritmus, který byl vytvořen pro učení vícevrstevných neuronových sítí s učitelem. Tento algoritmus opravuje-nastavuje váhy jednotlivých spojů zpětným chodem tak, aby jejich velikosti byly z hlediska řešeného problému pokud možno optimální - hledá se globální minimum chybové funkce. Nastavení vah tedy probíhá v opačném směru, než jakým se šíří vstupní informace. U tohoto algoritmu opět rozeznáváme dvě fáze - aktivační a adaptační.

Aktivační fáze.

Při inicializaci sítě se musí nastavit váhy na vhodnou hodnotu, což se dělá obvykle pomocí generátoru náhodných čísel. Váhy se pohybují v rozmezí 0,5 až -0,5. Kromě použití generátoru náhodných čísel existují i jiné metody pro prvopočáteční nastavení vah jako simulované žíhání a genetické algoritmy.

V této fázi se informace obsažená ve vstupním vektoru se šíří ze vstupu na výstup, jak ukazuje obr 3. Vstupní vektor je ve vstupní vrstvě rozvětven a každá "větev" (spoj) je ohodnocen tzv. vahou (hodnota spoje - váha). V každém neuronu, do kterého vstupují takto ohodnocené spoje, se provede jejich součet. Takto získané číslo je použito jako argument přenosové funkce, jejíž výsledná hodnota je výstupem z neuronu, a slouží jako vstupní hodnota do dalších neuronů ve vyšší vrstvě. Pokud se jedná o vrstvu výstupní, pak výstupní hodnota z neuronů je vlastní výstupní vektor.

Aktivační fáze je používána při učení a vybavování sítě. Je to tedy aktivita, při které se vstupní informace dostane na výstup a je zmodifikována momentální množinou vah a přenosovými funkcemi ve vlastních neuronech.

Adaptační fáze (vlastní Backpropagation).

Výstupní vektor (odezva sítě na vstupní vektor) je porovnána s požadovaným originálem a rozdíl mezi oběma vektory je použit pro výpočet nových vah tak, že se nejprve opraví váhy u spojů, které vstupují do výstupní (nejvyšší) vrstvy. Pak jsou opraveny váhy u nižší vrstvy, atd. až se dosáhne vrstvy vstupní, je tato fáze ukončena a opakuje se fáze aktivační.

Při každém porovnávání výstupní odezvy s požadovaným originálem se daný rozdíl uchová v paměťové proměnné a sumarizuje se s dalšími postupně získanými rozdíly. Takto získané číslo za celou trénovací množinu (epochu) se nazývá globální chyba. Tato globální chyba je

po každé epoše kontrolována s chybou, kterou zadal uživatel a pokud je nižší, než chyba zadaná, pak je síť naučena a učení končí. Algoritmus tedy hledá globální minimum chybové funkce.

Chybová funkce a globální minimum.

Algoritmus Backpropagation, nastavuje váhy tak, aby se globální chyba co nejvíce přiblížila k globálnímu minimu chybové funkce. Vlastní globální chyba je tedy pozice na tzv. chybové ploše, která je dána všemi vahami a jejich možnými hodnotami. Vlastní chybová plocha je mnohdy komplikovaná plocha s mnoha lokálními minimy, přičemž „pozice neuronové sítě na této ploše“ je dána aktuálním stavem vah. Z toho je jasné, že pokud startujeme síť na nové učení s nově náhodně nastavenými vahami, jsme při každém startu pokaždé v jiném bodě chybové plochy. Problém vlastního hledání je, že obvykle nevíme, zda momentální minimum kterého jsme dosáhli je globální. (9)

Rekurentní síť

2.1.3 Hopfieldova síť


Tato síť má mezi sebou propojeny všechny neurony, čímž vzniká nová kvalita v jejím chování. Analogické případy jsou známy z přírody už dlouho, např. mraky, sněhové vločky, turbulentní toky a jiné. Pokud máme dynamický systém, který má vhodné lokální stabilní místa ve stavovém prostoru (atraktory), pak lze na takovýto systém pohlížet, jako na asociativní paměť. Představíme-li si vlastní místo lokální stability jako informaci uloženou v tomto dynamickém systému, pak oblast přitažlivosti tohoto místa představuje všechny možné počáteční stavy, ze kterých se stavová trajektorie dostane v konečném čase do výše zmíněného stavu. V terminologii neuronových sítí to znamená, že k narušené informaci (některý z bodů přitažlivosti řešení) bude nalezen její originál (místo lokální stability).

S tím se lidský mozek setkává velmi často, např. když se dostane z paměti dosti poničený, známý obrázek (informace z oblasti přitažlivosti řešení), mozek si dovede vybavit originální vzhled (místo lokální stability) tohoto obrázku - tzv. princip autoasociativní paměti - vybavit si originál z poškozené předlohy.

Hopfieldovy sítě se používá většinou ke klasifikaci a optimalizaci. V této síti jsou neurony spojeny každý s každým (kromě sám se sebou). Vlastní matice vah čtvercová a diagonálně

symetrická (s nulami v hlavní diagonále) díky tomu, že váhy mezi dvěma neurony jsou stejné. Vlastní neurony mají svůj práh a přenosovou funkci. Práh bývá obvykle roven nule a jako přenosová funkce je používána skoková funkce. Vstupní signály nabývají hodnot $+1$ a -1 (bipolární binární), případně 0 a $+1$ (unipolární binární). Signál prochází neuronem tak, že se sečtou jednotlivé vstupy a takto získané číslo se použije jako argument dané přenosové funkce (v našem případě skokové).

Díky své povaze má Hopfieldova síť zajímavou vlastnost - po naučení se na nějaké vstupní vzory umí automaticky vybavit i jejich negativy. (9)



Obr 7. Hopfieldova síť (9)


2.1.4 Síť CLN (Competitive Learning Network)

Sítě CLN jsou sítě s tzv. soutěživými neurony. Každý z neuronů v síti se snaží "vyhrát" nad ostatními. Při tomto způsobu učení se uplatňuje pravidlo, že vítěz (vítězný neuron) bere vše. Při praktické činnosti sítě to znamená, že poté co je síť stabilizována, může být pouze jeden neuron (vítězný) ve stavu ON, nebo-li aktivován. Sítě tohoto typu bývají používány většinou k nalezení tříd v množině vstupních dat při učení bez učitele. Vítězem se stává ten neuron, který reprezentuje třídu, od níž má daný vstupní vektor tu nejmenší vzdálenost (obvykle ve smyslu Hamminga).

Jak je vidět z Obr 8 je její topologie prakticky stejná jako topologie Hopfieldovy sítě s tím rozdílem, že každý neuron má ještě kontakt sám se sebou. Veškeré vstupy od ostatních

neuronu jsou záporného charakteru, což znamená inhibiční (tlumící) účinek od všech jeho "kolegů". Jediný kladný vstup s excitačním (budícím) účinkem je od něj samého. Neurony v této síti se snaží potlačit všechny ostatní a sebe co nejvíce aktivovat. Odtud plyne označení sítě - síť se soutěživými neurony.

Vlastní učení takovéto sítě se skládá opět ze dvou fází, které vzhledem k výše uvedeným faktům nesou v anglosaské literatuře označení jako "competition phase" - fáze soutěžení a "reward phase" - fáze odměny. Ve fázi soutěžení se zjišťuje, který z neuronů vyhrál (byl aktivován) pro daný vstupní vektor a ve fázi odměny jsou tomuto vítězi "za odměnu" upraveny jeho váhy tak, aby se daný vstupní vektor co nejvíce přiblížil středu třídy, která je daným "vítězem" reprezentována. (9)




Obr 8. Schéma sítě CLN (9)

2.1.5 Síť BAM (Bidirectional Associative Memory)

Hopfieldova síť patří mezi tzv. auto asociativní sítě, což znamená, že z poškozeného vstupu "pozná", jaký byl originál.

Tento druh sítí se vyznačuje tím, že jistému vstupnímu vzoru nepřiradí jeho originál, ale asociovaný vzor. Tato vlastnost dána tím, že se při procesu učení vytváří asociace mezi páry vzorů. BAM je v podstatě rezonanční síť, jejíž vybavování probíhá cyklickým "přeléváním" informací ze vstupu na výstup a zpět tak dlouho, dokud není nalezen příslušný vhodný vektor. Neurony v této síti jsou stejné jako v Hopfieldově síti. (9)



Obr 9. Schéma sítě BAM (9)

Sítě se samoorganizací


2.1.6 Kohonenova síť

Pracuje na principu vyhledávání závislosti v datech (shluková analýza) v trénovací množině.

Kohonen definoval dva základní mechanismy, kterými se vyznačují sítě s prostorovou samoorganizací:

- 1) Nalezení vstupního neuronu (vítězného), který nejlépe odpovídá předloženému vstupnímu vzoru
- 2) Modifikace vah u spojů vítěze a jejího nejbližšího okolí (vítězného okolí).

Kohonenova síť má jen jednu vrstvu a obvykle se prezentuje jako plošné uspořádání neuronů, kde každý neuron je zároveň výstupem a je také spojen se svými sousedy. Váhy, které jsou u jednotlivých spojů nám opět slouží k uchování informací o trénovací množině. Výpočetní rychlost této sítě je dána množstvím neuronů, které jsou v síti. Pokud budeme mít velké množství neuronů, pak dosáhneme toho, že vstupní prostor bude velmi dobře pokryt a naopak. Zvláštností u této sítě je, že neurony nemají přenosovou funkci, jen pouze přepočítávají jak "daleko" je vstupní vzor od vzoru, který je zakódován v jejich vahách. (9)



Obr 10. Schéma Kohonenovy sítě (9)


2.1.7 Síť ART (Adaptive Resonant neTwork)

Jedním z důvodů, proč byla vyvinuta síť ART je skutečnost, že v síti CLN není zajištěna stabilita existujících tříd. (tzv. fenomén stability a plastičnosti)

Síť ART, která byla vyvinuta na základě zmíněného fenoménu se vyznačuje vysokou schopností adaptace na neočekávané změny. Adaptivní rezonance je proces kolektivní aktivity chování systému jako celku když dopředné i zpětné šíření informací je souhlasné. Postupem doby byla vyvinuta ART2 a ART3. Rozdíl mezi těmito sítěmi je v tom, že ART1 pracuje pouze s binárními hodnotami.

Základní myšlenka sítě ART1 je taková, že vstupní vektor je porovnán s tzv. prototypovými vektory uschovanými v síti ve smyslu klesající podobnosti, dokud není nalezen prototypový vektor, který je dostatečně blízko vektoru vstupnímu. Tyto prototypové vektory nejsou nic jiného, než váhy jednotlivých spojů mezi vrstvou skrytou a výstupní.

Tato síť v podstatě třídí jednotlivé vstupní vektory do tříd s tím, že je vždy aktivován pouze jeden (nebo také žádný) neuron, který představuje příslušnou třídu. (9)




Obr 11. Schéma sítě ARTLasery (9)

3 PRINCIP FUNKCE LASERU

Vznik stimulované emise, která se stala základem všech kvantových zesilovačů a oscilátorů, poprvé vysvětlil Albert Einstein ve své práci „Ke kvantové mechanice záření“ v roce 1917. První experimentální důkazy o stimulované emisi podali Ladenburg a Kopferman v roce 1928. V roce 1958 bylo navrženo uplatnění principů maseru pro světlo s využitím stimulované emise záření a vytvořeny teoretické základy laserového generátoru. Ve druhé polovině roku 1959 navrhl Townes model laseru, ale pokusy s nim se nepodařily. Až v roce 1960 se podařilo mladému výzkumníkovi z laboratoře Hughes Aircraft Company, T.H.Maimanovi dosáhnout laserový efekt v krystalu syntetického rubínu. Slovo „LASER“ je akronymem anglického názvu Light Amplification by Stimulated of Radiation, což lze přeložit jako „zesilování světla stimulovanou emisí záření“. Definice říká, že laser je kvantový generátor a zesilovač koherentního (vnitřně uspořádaného, sfázovaného) optického záření, které vyniká extrémní monochromaticností (tj. všechny fotony tohoto záření mají stejnou „barvu“, respektive vlnovou délku a frekvenci), nízkou rozbíhavostí (divergencí) svazku (všechny fotony laserového záření se pohybují stejným směrem) a vysokou hustotu přenášeného výkonu či energie. Žádné jiné záření než záření generované laserem tyto vlastnosti nemá.

Vlnové délky laserového záření spadají od mikrovlnné oblasti přes infračervené tepelné záření a viditelné světlo až po rentgenové paprsky (viz Obr 12). 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. (2)



Obr 12. Spektrum elektromagnetických vln (6)

Ačkoliv existuje velké množství různých typů laserových generátorů, každý v sobě zahrnuje tři základní součásti:


- Laserové aktivní prostředí (probíhá v něm zesilování záření)
- Zdroj čerpání (pro excitaci aktivního prostředí)
- Rezonátor (vytváří zpětnou vazbu mezi zářením a aktivním prostředím vedoucí ke vzniku laserových oscilací)

Základní význam pro funkci laseru má proces stimulované emise, který může nastat při interakci excitovaného kvantového systému (atomu, iontu nebo molekuly)

s elektromagnetickým zářením – fotonem, jehož frekvence f odpovídá energetickému rozdílu $E_2 - E_1$ mezi excitovaným a některým níže položeným stavem kvantového systému. Přitom dochází k přechodu kvantového systému do tohoto energeticky chudšího stavu a současně je excitační energie uvolněna emitováním fotonu s energií:

$$hf = E_2 - E_1 \quad (1)$$


Obecný princip laseru je následující: zdroj budící energie zajišťuje, aby se v aktivním prostředí nacházel dostatek kvantových soustav v excitovaném stavu. Poté, co některá kvantová soustava aktivního prostředí přejde náhodně spontánní emisí na nižší hladinu, bude uvolněné kvantum stimulovat i další kvantové soustavy k přechodu na spodní energetickou hladinu a emisi fotonu. (2)



Obr 13. Absorpce, spontánní a stimulovaná emise (7)

Část fotonů se může kvantovými soustavami opět absorbovat. Pokud však bude v aktivním prostředí více kvantových soustav v excitovaném stavu (inverze populace hladin) bude se optické záření s řetězovou reakcí zesilovat. Spontánní emise se stane zanedbatelnou vzhledem k emisi stimulované a generované záření nabude jednotné povahy, tj. bude koherentní a monochromatické. Aby se zajistila směrovost laserového záření, formuje se prostředí do tvaru dlouhého válce a je umístěno uvnitř optického rezonátoru (viz Obr 13). Pokud je aktivní prostředí s inverzním obsazením hladin uzavřeno v optickém rezonátoru (tvořeném obvykle dvěma navzájem proti sobě umístěnými rovinnými nebo také sférickými zrcadly), zpětná vazba laserového záření (odraz zpět do aktivního prostředí) umožní vznik generátoru elektromagnetických kmitů. Překročí-li zesílení světla v aktivním prostředí ztráty při jednom průchodu mezi zrcadly, začne laser emitovat záření na vlnové délce charakteristické pro dané aktivní laserové prostředí. Aby bylo možné vyvážit laserový

svazek z rezonátoru, je jedno ze zrcadel polopropustné. Na Obr 14 jsou vyznačeny kvantové soustavy v základním (1.) a v excitovaném (2.) stavu, stimulovaná emise a energetické hladiny kvantových soustav E_1 a E_2 . (2)



Obr 14. Optický rezonátor s aktivním prostředím (2)

Od záření běžných světelných zdrojů (plynové výbojky, žárovky) se laserové světlo liší svými vlastnostmi:

- záření je prostorově koherentní (vlny emitované z různých míst aktivního prostředí mají pevný fázový vztah)
- záření se v prostoru nešíří všemi směry, ale v úzkém svazku – fokusací na malou plochu lze dosáhnout extrémně vysoké hustoty výkonu (přibližně 10^{14} Wcm^{-2})
- záření je časově koherentní (laser emituje postupné vlnění se zanedbatelnými fázovými nestabilitami). S tím souvisí vysoká přesnost frekvence záření (monochromaticnost).

Laser umožňuje generovat extrémně krátké světelné impulsy. Při použití pulzního laseru lze v úzké oblasti vlnových délek uvolnit optický výkon o hodnotách od 10^{10} do 10^{13} W . (2)

3.1 Typy laserů

Existuje mnoho různých tříd laserů, jejich základní princip je stejný, ale liší se výrazně konstrukcí a realizací jednotlivých částí. Dělení laserů do jednotlivých skupin probíhá podle několika kritérií.

Podle skupenství aktivního prostředí - pevnolátkové

- kapalinové

- plynové

- plazmatické

- polovodičové (laserové diody)

Podle režimu generace - kontinuální (označované zkratkou CW)

- pulsní - režim volné generace (délka pulsů 10^{-4} s)

- režim spínání zisku (Q-spínání, 10^{-8} s)

- režim synchronizace módů (pulsy 10^{-12} s)

Podle způsobu čerpání - opticky čerpané

- čerpané elektrickým výbojem

- čerpané chemickou reakcí

- čerpané elektronovým svazkem

- čerpané radioaktivním zářením

Podle vlnové délky generovaného laserového paprsku - submilimetrové

- infračervené

- viditelné

- ultrafialové (EUV)

- rentgenové

3.1.1 Pevnolátkové lasery

Jsou to opticky čerpané pevnolátkové iontové lasery jejichž aktivní prostředí tvoří matrice – krystalické nebo amorfní (sklo, keramika) izolanty, dopované příměsí vhodných iontů. Byly vyzkoušeny snad tisíce různých kombinací dopantů a matric. Asi nejznámější představitel této skupiny je červeně zářící rubínový laser, jehož aktivní prostředí tvoří safír dopovaný chromem – rubín. Nejrozšířenějším a dnes asi nejlépe technicky zvládnutým pevnolátkovým laserem je laser označovaný jako Nd:YAG. Jeho aktivním prostředím je neodymem (Nd^{+3}) dopovaný yttrium aluminium ganát (YAG). Tento laser našel bohaté uplatnění jak v průmyslu, tak v medicíně a vědě. Generuje za pokojové teploty v impulsním i kontinuálním režimu na vlnové délce 1064 nm, případně s menší účinností i na vlnové délce 1320 nm. Metodami nelineární optiky lze dosáhnout generace záření na vlnové délce 532 nm (druhá harmonická frekvence – SHG). Nd:YAG laser dosahuje na vlnové délce 1064 nm v kontinuálním režimu (CW) maximálního výkonu od stovek do tisíce wattů, impulsním režimu se dosahuje energie pulsů do desítek joulů. Délka impulsů od zlomku sekund do 5 ps, podle druhu použité modulace jakosti rezonátoru. Jeho hlavní výhoda spočívá ve vlastnostech použitého aktivního prostředí – krystalická látka je velmi stabilní, vyniká vysokou hustotou energie a akumulací schopností umožňující generovat krátké vysokovýkonové pulsy. Konstrukce pevnolátkových laserů je v porovnání s plynovými lasery podstatně kompaktnější, údržba se omezuje na výměnu čerpacích výbojek. Příznivá je i kratší vlnová délka v porovnání s CO_2 laserem – záření Nd:YAG laseru lze snadno přenášet optickými vlákny na vzdálenosti několika desítek metrů. Nevýhodou je relativně nižší účinnost 2 – 3%, značný elektrický příkon výkonových systémů (až 200 kW) a s tím spojená nutnost vodního chlazení systému. Tyto nedostatky se již dnes pokouší odstranit několik výrobců nahrazením lampového čerpání čerpáním polovodičovými diodami. Takové systémy naopak vynikají vysokou účinností (15 až 20%), řádově nižší spotřebou elektrické energie a chladicí vody a jiné lasery vynikají kompaktností a nízkou hmotností. Nevýhodou je však dosud velmi vysoká cena vysokovýkonových polovodičových laserových diod, která brání rozšíření takovýchto laserových systémů. (2,3)

3.1.2 Kapalinové lasery

Jako aktivní prostředí kapalinových laserů se až na výjimky používají opticky buzené roztoky organických barviv. Jejich široké fluorescenční spektrum umožňuje spojitě přeladovat vlnovou délku záření generovaného těmito lasery. Pomocí několika typů barviv a využitím metod nelineární optiky lze tak prakticky pokrýt pásmo vlnových délek od 300 nm do 1500 nm. Typickým představitelem je rhodamonový laser generující pulsní záření od zelené až po červenou oblast spektra. Podstatnou nevýhodou těchto laserů je toxicita a nepříliš dlouhá životnost aktivního prostředí, které se účinkem tepla a světla rozkládá. Ve většině případů dochází k jejich nahrazování přeladitelnými pevnolátkovými lasery. (2)

3.1.3 Plynové lasery

Aktivní prostředí plynových laserů tvoří atomy (He-Ne laser), ionty (Ar laser), molekuly (CO₂ laser) či jejich směsi v plynné fázi, přičemž inverze obsazení nastává mezi energetickými hladinami některé složky. V případě atomů a iontů jde převážně o energetické hladiny v elektronovém obalu, ale u molekul se tyto základní hladiny dále štěpí na vibrační a rotační stavy. Tato různorodost se pak odráží v rozsáhlém spektru vlnových délek plynových laserů. Plynové lasery pracují převážně v kontinuálním režimu, ale existují i výkonné pulsní systémy. Pro buzení se používá široká škála fyzikálně – chemických procesů. V současnosti je technicky možné uskutečnit u CO₂ laserů tyto metody buzení:

- a) doutnavý výboj - je nejčastější a dochází při něm k dobrému rozložení hustoty náboje.
- b) proudem elektronů - dosahuje se intenzivní inverzní populace. Zdrojem proudu elektronů je např. urychlovač.
- c) adiabatickou expanzí - prudké ochlazení horkého plynu vede k dosažení inverzní populace.
- d) optické buzení - principiálně je možné buzení světlem, ale je málo účinné. Používá se ale buzení CO₂ laserů např. pomocí výkonných infračervených laserů.

Používají se čtyři hlavní uspořádání CO₂ laserů, které se liší zejména možnostmi dosahovaných výkonů:


- a) Lasery s výbojkou. Mají malé rozměry. Výkon je asi do 100 W. Většinou mají vodní chlazení. Plyny jsou nastalo uzavřeny ve výbojce a mají tak vlivem rozpadu CO₂ na CO malou životnost (asi 10 000 h).
- b) Lasery s pomalým průtokem plynu. Průtok aktivního plynu znamená na jedné straně více odvádět teplo a dosahovat vyšších výkonů, ale na druhé straně znamená složitější konstrukci. Během provozu se plynule spotřebovávají plyny. Výkon běžných laserů tohoto typu pro technologické práce je do 3,5 kW
- c) Lasery s rychlým průtokem plynu. Tyto dovolují ještě intenzivnější odvod tepla a dosahují tak 3 - 4 vyššího výkonu nežli v případě b). Tyto typy laserů se již neobejdou bez výměníku tepla. Místo vývěvy se používá kompresor. Objemový průtok plynu je zde až 400 l.s-1. Literatura uvádí, že výkon komerčních technologických laserů tohoto typu je do 40 kW.
- d) TEA CO₂ laser (Transversal Excitation at Atmospheric Pressure Laser). Laser je buzen impulsním výbojem za atmosférického tlaku. Plyn je dodáván v externích náplních. Pracuje pouze v pulsním režimu, o frekvenci do 200 Hz, velikost výstupního režimu je až 50 MW.

Nespornou výhodou plynových laserů je jejich vysoká účinnost, pohybující se v desítkách procent (CO₂ laser – 40%). (2,7)

3.1.4 Polovodičové lasery

Polovodičové lasery jsou dnes vůbec nejrozšířenějšími lasery. Často se pro ně používá označení laserová dioda. Od ostatních laserů se liší tím, že nepracují s přechodem elektronů mezi diskrétními hladinami, nýbrž se u nich vyskytují elektronové přechody mezi vodivostním a valenčním pásmem polovodiče. Rozměry aktivních prvků diodových laserů jsou velmi malé např. 1 x 0,1 x 0,1 mm. Zejména u GaAs dochází k velmi silnému zesílení na velmi malých vzdálenostech (řádově desítky mm). Výkon v pulsu GaAs diodového laseru je až 100 W při vlnové délce záření 830 - 920 nm. Pro technologické účely se proto běžně sdružují jednotlivé laserové diody do polí. Současné technologické diodové lasery mají výkon do 4 kW. Polovodičové lasery se vyznačují vysokou účinností (běžně až 50%).

Uplatnění nalezly především v telekomunikacích a ve výpočetní technice. Dnes se jich také stále častěji používá pro čerpání pevnolátkových laserů a tak vznikají vysoce výkonné miniaturní a flexibilní laserové generátory. (2)



Obr 15. Polovodičový laser s heterostrukturou (4)

3.1.5 Excimerové lasery

Excimerové lasery jsou plynové pulsní lasery, jejichž pracovní náplň tvoří směs halogenidů a vzácných plynů – např. Krypton-Fluor, Argon-Fluor. Aktivní prostředí je buzeno elektrickým výbojem. Hlavním důvodem použití těchto laserů je velmi krátká vlnová délka (157 nm, 193 nm, 248 nm) umožňující velmi přesné obrábění s přesností na zlomky mikrometrů. Tyto lasery našli široké uplatnění ve fotolitografii. Energie impulsů excimerových laserů dosahuje jednotky až desítky joulů, střední výkon bývá maximálně stovky wattů- účinnost takovýchto systémů je relativně dobrá – až 10%. Hlavní nevýhoda spočívá ve složité údržbě a velmi nákladném provozu. Vzhledem k malému rozšíření excimerových laserů je značná i jejich pořizovací cena. (7)

3.1.6 Chemické lasery

V chemických laserech vzniká energie chemickou reakcí vstupních komponentů. Podstatou vzniku inverzní populace je potom chemicky nerovnovážný stav v důsledku neustálé konkurence chemických reakcí. Laserový efekt je dosažen díky změnám energetických stavů vibračně-rotálních módů molekul (podobně jako u CO₂ laserů).

Intenzívním vývojem již dlouhou dobou prochází hlavně HF lasery (reakce vodíku a fluoru) a DF lasery (reakce deuteria s fluorem). Výzkum ukázal, že až 70 % energie chemické reakce se využije na přechod vibračně-rotálních módů do excitovaných stavů, což vytváří

podmínky pro vznik intenzivní inverzní populace. Účinnost chemických laserů se pohybuje kolem 10 %. (7)


3.1.7 EUV lasery

Jedná se o lasery vyzařující v oblasti extrémně ultrafialového záření EUV ve vlnovém rozpětí 11 až 14 nm. Přestože v oblasti EUV se již nějaké pokusy odehrály ve Fraunhoferově institutu ILT, kde byly už dokonce vyvinuty zdroje tohoto záření na bázi laserem indukované plazmy nebo i plazmy vznikající při elektrických výbojích v plynech, naprosto nadčasovou novinkou veletrhu Laser 2003 bylo předvedení skutečného, již hotového prototypu EUV laseru XTS 13-35 od společnosti Lambda Physik s vyzařováním na vlně 13,5 nm. U tohoto prototypu, navíc s možností přeladění na vlnový rozsah v rozpětí 5 až 10 nm, se už dosahuje výkonu 35 W a energie 35 mJ při pulzu 100 ns. (4)

3.1.8 Rentgenové lasery

Měkké rentgenové záření má vlnovou délku 1 - 0,1 nm, tvrdé rentgenové záření má pak vlnovou délku 0,1 - 0,001 nm. Zesílení elektromagnetických vln v oblasti měkkého rentgenova záření byly hlášeny již v 70. letech. Ale teprve v roce 1985 Matthews z LLNL (Lawrence Livermore National Laboratory, USA) uskutečnil laserový efekt v oblasti tvrdého rentgenova záření.

Schéma rentgenového laseru čerpaného výkonnými pulsními Nd:YAG lasery je uvedeno na Obr 16. Plazma vzniká po dopadu pulsu laseru na selenový terčík. Selenová fólie po zásahu vysokou energií exploduje a vzniká plazma skládající se z iontů selenu. Životnost odpovídajících kvantových stavů na vnitřních kvantových drahách je velmi krátká (10^{-13} s). To vede k tomu, že je nutno dodávat při čerpání řádově 1000 - krát více energie a zvýšit až 10 000 - krát frekvenci čerpacích pulsů oproti klasickým laserům, které pracují v oblasti viditelného spektra. Při snaze o dosažení malých vlnových délek nastává problém s účinností laserového efektu (u měkkého RTG můžeme počítat s účinností okolo 10^{-5}). (7)



Obr 16. Schéma rentgenového laseru (7)

3.1.9 Vláknové lasery

Jako velmi perspektivní alternativou k pevnolátkovému Nd:YAG laseru a plynovému CO₂ laseru se v poslední době objevují vláknové lasery. Aktivní prostředí laserů tvoří křemenná vlákna dopovaná prvky vzácných zemin (Ytterbium, Erbium, Neodym). Vláknové lasery pracují v kontinuálním režimu a emitují záření na vlnových délkách od 1000 do 1500 nm. Pro čerpání těchto laserů se s výhodou používají nízkovýkonové polovodičové laserové diody, které vynikají dobrou kvalitou laserového svazku, vysokou životností, účinností a nízkou cenou. Tyto vlastnosti na sebe přebírá i výsledný vláknový laser, který využívá možnosti paralelního spřažení velkého množství nízkovýkonových laserů do jednoho systému, takže lze snadno navrhnout systém jehož výsledný generovaný výkon se může pohybovat od stovek wattů až po desítky kW. Doposud jsou komerčně dostupné vláknové lasery s výkonem 2 – 4 kW. Kromě nízké spotřeby elektrické energie a vysoké účinnosti vynikají tyto lasery malou hmotností, vysokou spolehlivostí (neobsahují složité pohyblivé díly a čerpadla jako CO₂ lasery, ani nevyžadují vodní chlazení jako Nd:YAG lasery) a kvalitou laserového svazku. Díky dosahovanému výkonu mohou v budoucnu nahradit i vysokovýkonové CO₂ lasery a mohly by přinést značné rozšíření laserových technologií do běžné praxe. (2)

4 LASEROVÉ OBRÁBĚNÍ PLASTŮ

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 (2):

$$R = 29000 \sqrt{\frac{l}{m_r g}} \quad (2)$$

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

Energii jednoho fotonu ve svazku elektromagnetického záření popisuje rovnice (3):

$$E_p = hf = \frac{hc}{l} \quad (3)$$

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 je nástroj bez kontaktu s materiálem a bez setrvačností, odpadá tedy opotřebení, výměna a prostoj nástroje. Laserový svazek lze snadno prostorově a časově ovládat, lze obrábět v libovolném prostředí, a to i místa pro jiné nástroje nepřístupná.
- Monochromaticnost, koherence a nepatrná prostorová rozbíhavost paprsků způsobují, že svazek lze soustředit na plošku o minimálním průměru, který je roven dvojnásobku vlnové délky laseru. (7)

4.1 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 značkovaném materiálu. U laserového popisování rozlišujeme dvě metody:

4.1.1 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. (Obr 17). 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 18 (7)



Obr 17. Princip popisování vychylováním paprsku (7)




Obr 18. Porovnání standardní a ploché čočky (7)

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). (7)


4.1.2 Popisování maskovací metodou

U maskovací metody je laserovým paprskem osvětlena kovová maska, která obsahuje zapisovaný 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. 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 (Obr 19). Větší popisované plochy se dá dosáhnout použitím tzv. „kyvadlového zrcadla“, kdy se laserový paprsek pohybuje podél masky (Obr 20). Touto technologií můžeme popisovanou plochu až zdvojnásobit. Nevýhodou maskovací metody je, že ke každému novému znaku je nutno vytvořit novou masku. (7)



Obr 19. Princip maskovací metody popisování (7)




Obr 20. Princip technologie kyvadlového zrcadla (7)

4.1.3 Způsoby laserového popisování

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

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 (Obr 21a). 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 21b). Stíny na stěnách drážek vytvářejí s povrchem materiálu viditelný kontrast. Zvláštním případem popisování pomocí rytí, je odstraňování povrchové vrstvy (Obr 21c). Produkt má další povrchovou vrstvu s odlišnou barvou, která se lokálním působením laseru odpaří. Vznikne tak viditelný kontrast mezi podkladovým materiálem a povrchovou vrstvou. (7)



Obr 21. Lokální změna barvy nebo povrchové struktury (7)

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 nezatěžujeme. Fotolytické obrábění je doménou UV laserů. (7)

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. (7)

4.2 Výhody a nevýhody laserového popisování

Laserové značení výrobků poskytuje oproti konvenčním metodám značení (inkoustový tisk, tamponový 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

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 do stroje konvenčního. (7)

II. PRAKTICKÁ ČÁST

5 STANOVENÍ CÍLE DIPLOMOVÉ PRÁCE

Cílem této diplomové práce je návrh vhodné umělé neuronové sítě, její naučení na technologii laserového popisování prostřednictvím reálných naměřených dat a využití této sítě na predikci výstupních dat, přičemž sledujeme závislosti až 5-ti různých vstupních parametrů na dvou výstupních parametrech.

Při procesu laserového gravírování jsou zadávány hodnoty výkonu a posuvu jako vstupní parametry. V této diplomové práci jsou hodnoty výkonu P a posuvu f uváděny jako výstupní parametry a to proto, že predikce neuronovou sítí je zařazena před laserovým gravírováním, takže výstupní hodnoty z umělé neuronové sítě jsou vstupními hodnotami v procesu laserového gravírování.

Pro vstupní proměnné byly použity hodnoty hloubky vygravírování h a drsnost vygravírované polchy R_a a R_z a to v příčném i podélném směru.

Navrhoval jsem čtyři typy umělých neuronových sítí pro čtyři různé problémy:

- Závislost 5 vstupních na 2 výstupních parametrech
- Závislost 3 vstupních na 2 výstupních parametrech
- Závislost 2 vstupních na 2 výstupních parametrech
- Závislost 1 vstupního na 1 výstupním parametru

Vstupní proměnné jsem snižoval z toho důvodu, že jsem tím odstranil značné nelineární závislosti mezi hodnotami drsnosti v příčném směru, které ovlivňovali hodnoty pro mě zajímavější drsnosti ve směru kolmém. Tím jsem se snažil vyloučit chybu která vzniká u podélné drsnosti, jak je dále hlouběji popsáno.

Navíc bylo možné lépe sledovat závislosti zpočátku všech pěti vstupních proměnných na výstupních proměnných, až postupně vliv jednotlivých vstupních proměnných na výstupních proměnných.

Ubráním vstupních hodnot jsem se snažil o odstranění vlivu ostatních v těch konkrétních případech nesledovaných závislostí, které by ovlivňovaly výsledek na výstupu.

Díky tomu ovšem někdy vznikaly v krajních oblastech chyby, způsobené nesmyslným požadavkem na naučenou umělou neuronovou síť (např. malá hloubka u vysokých hodnot výkonu atp.) jak je také dále rozvedeno.

6 VSTUPNÍ DATA

Vstupní data byla naměřena z laserem vygravírovaného vzorkového dílu z materiálu PMMA vyrobeného firmou Mechanika p.v. Prostějov.




Obr 22. Schéma výkresu vzorkového dílu

U stroje CO₂ laser Mercury L-30 na kterém bylo gravírování prováděno je pro ovládání používán klasický driver tiskárny a z toho důvodu jsou všechny vstupní parametry u tohoto stroje zadávány v procentech.

pozn. podrobný popis technických dat tohoto stroje je uveden v příloze.

Tabulka II. 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



Obr 23. Sken vzorkového dílu


pozn. dva čtverce, které se nacházejí mimo původní polohu v pravé části (s: 80%, P: 60% a s: 80%, P: 70%) jsou opravy. Sken s rozlišením 600 DPI je uveden v příloze.

6.1 Naměřená data

Všechny naměřené hodnoty hloubky h byly měřeny 5-krát, hodnoty drsností R_{a1} , R_{z1} , R_{a2} a R_{z2} byly měřeny 8-krát a uvedené hodnoty jsou jejich aritmetické průměry.

Tabulka III. Závislosti drsnosti R_{a1} [μm] na výkonu P [%] a posuvu f [%]


$\begin{matrix} P \\ f \end{matrix}$	10%	20%	30%	40%	50%	60%	70%	80%	90%	100%
10%	10,31	14,23	20,37	22,04	20,47	19,83	24,32	25,82	24,78	22,56
20%	3,35	14,33	16,35	18,1	19,81	18	19,1	19,61	20,23	18,93
30%	5,09	10,05	10,29	12,69	15,35	20,14	20,99	19,46	17,96	18,78
40%	3,72	5,62	10,47	12,12	10,57	11,18	10,06	11,85	13,04	14,57
50%	2,97	5,51	6,12	11,87	10,61	8,98	8,8	12,25	13,27	13,12
60%	2,41	3,01	5,85	6,8	10,24	6,6	9,83	11,32	9,96	9,82
70%	1,58	3,91	5,16	5,86	8,43	5,71	5,83	9,56	8,88	9,55
80%	0,53	2,95	4,76	4,22	7,26	8,27	7,33	6,03	6,7	7,94
90%	0,44	2,41	2,63	5,08	5,02	4,4	5,91	5,26	6,44	4,02
100%	1,08	2,32	3,22	3,71	3,15	4,96	3,45	6,52	5,91	4,81



Obr 24. 3D graf závislosti drsnosti R_{a1} [μm] na výkonu P [%] a posuvu f [%]


Tabulka IV. Závislosti drsnosti R_{z1} [μm] na výkonu P [%] a posuvu f [%]

$\begin{matrix} P \\ F \end{matrix}$	10%	20%	30%	40%	50%	60%	70%	80%	90%	100%
10%	44,08	68,1	117,78	126,63	116,36	120,98	135,45	152,61	130,15	119,37
20%	20,17	64,78	90,06	102,27	119,79	109,64	117,46	110,92	121,71	108,57
30%	25,97	54,05	64,58	65,58	88,6	106,11	112,34	106,26	100,27	113,59
40%	21,23	27,62	57,77	64,33	55,07	56,44	54,44	59,4	66,24	71,37
50%	18,02	27,98	31,91	52,8	47,9	45,89	43,35	58,53	62,78	63,78
60%	14,15	19,23	28,86	34,94	48,18	36,57	50,07	56,59	50,04	51,04
70%	10,74	21,07	27,99	31,89	41,36	33,79	31,68	46,69	46,99	49,35
80%	3,51	17,04	24,86	23,64	35,98	44,59	38,67	35,58	36,24	42,41
90%	3,49	14,95	16,44	29,1	29,07	26,27	31,25	38,5	38,27	21,47
100%	8,23	15,34	19,23	22,39	18,84	28,48	20,2	33,53	32,74	27,7

Obr 25. 3D graf závislosti drsnosti R_{z1} [μm] na výkonu P [%] a posuvu f [%]


Tabulka V. Závislosti drsnosti R_{a2} [μm] na výkonu P [%] a posuvu f [%]

$\begin{matrix} P \\ f \end{matrix}$	10%	20%	30%	40%	50%	60%	70%	80%	90%	100%
10%	18,38	21,3	25,96	22,57	26,52	30,45	30,63	33,08	29,39	23,29
20%	16,79	22,39	27,44	30,4	28,68	35,07	31,97	38	32,09	31,71
30%	12,74	20,39	19,18	21,21	22,97	24,11	24,21	23,23	24,11	25,74
40%	10,82	15,16	19,22	24,43	18,15	21,49	21,98	22,32	25,44	22,36
50%	8,33	15,95	18,15	20,46	20,23	23,39	22,15	24,03	22,97	23,22
60%	5,85	12,39	12,37	14,72	17,13	17,11	19,68	19,3	22,2	18,85
70%	4,25	9,41	14,33	14,34	16,94	18,13	18,47	19,74	21,32	21,99
80%	1,89	10,79	12,12	13,63	16,82	16,28	17,38	18,53	19,41	24,98
90%	1,25	8,39	11,27	13,52	14,1	16,08	22,7	22,47	25,18	24,47
100%	1,14	8,1	11,79	13,52	14,76	15,99	18,51	18,1	18,68	17,86

Obr 26. 3D graf závislosti drsnosti R_{a2} [μm] na výkonu P [%] a posuvu f [%]


Tabulka VI. Závislosti drsnosti R_{z2} [μm] na výkonu P [%] a posuvu f [%]

$\begin{matrix} P \\ f \end{matrix}$	10%	20%	30%	40%	50%	60%	70%	80%	90%	100%
10%	101,57	118,23	144,68	125,11	158,13	175,41	164,53	182,38	156,58	181,86
20%	80,84	121,86	152,03	168,71	157,34	198,56	183,79	196,15	165,59	167,36
30%	69,48	93,73	102,13	116,08	124,31	130,25	124,71	135,5	149,1	145,72
40%	50,12	78,38	101,96	113,9	106,21	118,79	120,55	123,89	149,01	127,93
50%	38,97	73,06	89,3	106,65	108,35	125,61	126,8	126,6	132,61	126,45
60%	30,02	65,34	72,9	79,91	94,78	98,13	95,34	100,51	131,14	106,34
70%	23,36	51,13	78,2	89,29	96,88	98,35	113,44	108,36	112,91	124,49
80%	15,36	44,17	68,86	77,75	94,1	94,26	110,3	104,47	101,35	133,31
90%	12,29	39,85	62,32	77,36	81,6	97,08	140,29	126,24	133,39	131,4
100%	12,02	38,32	54,44	74,11	88,12	93,47	107,6	105,81	102,63	102,87

Obr 27. 3D graf závislosti drsnosti R_{z2} [μm] na výkonu P [%] a posuvu f [%]

Tabulka VII. Závislosti hloubky h [μm] na výkonu P [%] a posuvu f [%]

$\begin{matrix} P \\ f \end{matrix}$	10%	20%	30%	40%	50%	60%	70%	80%	90%	100%
10%	223,4	419,2	492,8	775,2	1018	1217,8	1341,6	1419,4	1537	1627,6
20%	72,8	141,8	239,8	288	357,4	418,8	487	535,2	554,6	620,8
30%	50	85,8	121,4	166,8	203,4	237,2	268,6	262,6	306	330,2
40%	34,2	61,6	85,6	117,8	141,4	182,4	215,6	227,8	233,8	244,6
50%	11,6	31	63,6	85,2	101,6	129,8	164,8	157,2	176,2	169,4
60%	4	31,8	54,8	76,6	90,6	106,4	127,8	137	145,2	147,2
70%	2,2	7,6	22,6	34,8	66,8	68,2	82,6	108,4	107,8	104,4
80%	2,6	3,8	16,8	30,2	46,8	60,8	69,4	109,4	83,4	65,4
90%	0	1,2	8,6	25,2	48,6	50,4	51,2	67,2	51,6	58,8
100%	0	2,6	7,4	14,8	39	50	49,6	41,6	53,2	53,8

Obr 28. 3D graf závislosti drsnosti R_{a2} [μm] na výkonu P [%] a posuvu f [%]

6.2.2 Princip měření drsnosti

Drsnoměr Surftest SJ-301 na kterém byly měřeny vzorky pracuje tímto principem:

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 rovnoběžné s osou obrábění pro stanovení hodnot drsnosti v podélném směru (R_{a1} , R_{z1}) a v ose kolmé na směr obrábění pro stanovení hodnot drsnosti v příčném směru (R_{a2} , R_{z2}). Měření se pak opakuje na každém čtverci 8-krát v podélném i příčném směru a uvedené hodnoty jsou jejich aritmetickým průměrem.

6.2.3 Chyba měření u podélné drsnosti

Jak dokazuje i Tabulka III až Tabulka VI a graf na Obr 24 až na Obr 27, tak hodnoty podélné i příčné drsnosti se značně mění v důsledku chyby měření, přičemž chyba měření vzniká u podélné drsnosti tak, že při měření drsnosti v této ose závisí na pozici měřicího hrotu drsnoměru a není možné zjistit jestli se drsnost měří v minimu laserové stopy, na její stěně nebo v jejím maximu, takže můžeme obdržet několik naprosto rozdílných hodnot drsnosti, u jednoho vzorku.

7 VÝSTUPNÍ DATA

Jako výstupní data jsem sledoval 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 uvedena předchozí Tabulka II.

7.1 Volba umělé neuronové sítě

Umělá neuronová síť se zpracovávala v aplikaci Matlab.

Volil jsem umělou neuronovou síť s přenosovou funkcí tansig (hyperbolický tangens), která má maximum v bodě 1 a minimum v bodě -1, abych na výstupu nedostával nereálné hodnoty (výkon nebo posuv přes 100%). Závislost mezi vstupními a výstupními daty není lineární proto je výhodné zvolit funkci nelineární.

Podle toho jakou predikci vyžadujeme od umělé neuronové sítě, volíme některé parametry.

V našem případě je to konkrétně:

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

7.1.1 Popis programu pro aplikaci Matlab

Aplikaci Matlab musíme nejprve zadat učící data. Tento program je pro vytvoření umělé neuronové sítě z jednou vstupní vrstvou s počtem 5-ti neuronů (5 vstupních parametrů), jednou skrytou vrstvou o počtu 15 neuronů a jednou výstupní vrstvou o počtu 2 neuronů (2 výstupní parametry).

Z důvodu obsáhlosti výpisu programu jsem neuváděl celou řadu vstupních dat.

vstup umělé neuronové sítě

```
P=[10.31 14.23 20.37 22.04 20.47 19.83 24.32 25.82 24.78 22.56 3.35 ...5.91 4.81;...  
44.08 68.1 117.78 126.63 116.36 120.98 135.45 152.61 130.15 119.37 ...32.74 27.7;...  
101.57 118.23 144.68 125.11 158.13 175.41 164.53 182.38 156.58 ...102.63 102.87;...  
223.4 419.2 492.8 775.2 1018 1217.8 1341.6 1419.4 1537 1627.6 72.8 ...53.2 53.8];
```

Kde: 1.řádek jsou data drsnosti R_{a1} , 2.řádek R_{z1} , 3.řádek R_{a2} a 4. řádek R_{z2}

(pozn. Aplikace Matlab pracuje s desetinou tečkou na místo čárky, jednotlivá data se od sebe oddělují mezerou příp. tabulátorem)

výstup umělé neuronové sítě

```
T=[10 20 30 40 50 60 70 80 90 100 10 20 30 40 50 60 70 80 90 100 10 20 30 ... 90 100;...  
10 10 10 10 10 10 10 10 10 10 10 20 20 20 20 20 20 20 20 20 20 30 30 30 30 30... 100 100];
```

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

normalizace výstupních dat na interval $[-1;1]$

```
[tn,mint,maxt] = premnmx(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.

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

nastavení maximální délky učení na 250 cyklů (epoch)

```
net.trainParam.epochs = 250;
```

vyvolání učení sítě

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

test sítě na učící data

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


zpětná denormalizace na původní rozsah

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

vykreslení výsledku testu

```
plot(Y')
```

Tímto vytvoříme a naučíme umělou neuronovou síť a do takto naučené sítě můžeme posílat vstupní data (drsnost, hloubku), které síť zpracuje podle zjištěné naučené závislosti a na výstupu dostaneme ekvivalentní predikovaný výsledek (výkon, posuv).



Obr 30. Blokové schéma umělé neuronové sítě

7.2 výsledky umělé neuronové sítě

V této kapitole jsem navrhoval čtyři typy umělých neuronových sítí.


Počet vstupních dat jsem ubíral proto, aby se daly u prvních jednoduchých typů umělých neuronových sítí vysledovat závislosti pouze jedné vstupní proměnné na jedné výstupní proměnné a výsledek nebyl ovlivňován složitými nelineárními závislostmi ostatních hodnot, které jsem v daném případě nesledoval.

Postupně jsem snižoval obsah vstupních parametrů až do sledování závislosti z původních pěti na jeden vstupní parametr ovlivňující dva výstupní parametry, proto abych dostal čím dál konkrétnější pohled jak ovlivňují jednotlivé parametry sledované výstupy.


Snižování vstupních proměnných mělo taky ten význam, že jsem odstranil hodnoty drsnosti v příčném směru a zůstali jen hodnoty drsnosti v kolmém směru. U hodnot drsnosti ve směru podélném se vyskytovali značné nelineárnosti, způsobené, jak se domnívám, chybou měření, která je dále popsána. Odstraněním této části vstupních dat jsem se ji snažil vyloučit kvůli upřesnění výsledku.

Z důvodu vysledování závislosti jen jednoho konkrétního vstupního parametru na výsledek, jsem zadával konstantní vstupní hodnoty mimo té, kterou jsem sledoval. Tímto postupem, v některých případech vznikaly v krajních oblastech predikce chyby, způsobené nesmyslným požadavkem na naučenou umělou neuronovou síť (např. velká drsnost při nízkých hodnotách výkonu atp.), která pak ve výsledku navrhla na počátku nebo konci predikce grafu chybu (pokles nebo růst funkce tam, kde by jsme čekali opak).

7.2.1 Závislost jednoho vstupního na jednom výstupním parametru



Obr 31. Blokové schéma umělé neuronové sítě 1




Obr 32. Graf závislosti výkonu P na hloubce h na při konstantním posuvu f 10%

V tomto případě je vidět nejjednodušší příklad predikce pomocí umělé neuronové sítě, kde sledujeme vliv jednoho vstupního parametru (P nebo f) na jednom výstupním parametru (h) a i to jak se síť snaží proložit predikovaný výsledek mezi naměřená data (rozdíl mezi predikovanými a naměřenými daty).

Čím delší učení (počet epoch) budeme po umělé neuronové síti vyžadovat, tím více se bude snažit síť prokládat predikovaný výsledek těsněji mezi naměřenými hodnotami, za cenu rozkolísání predikované funkce mezi naměřenými hodnotami.


To může vést v důsledku k nepřesnosti predikce mezi body měření, kde budou hodnoty sledované výstupní funkce značně kolísat.

Obr 33. Graf závislosti posuvu f na hloubce h při konstantním výkonu P 100%


Vliv učení sítě lze pozorovat na grafu z Obr 32, kdy je síť méně naučena než na grafu z Obr 33. Na grafu z Obr 33 je vidět podstatně větší snaha predikce přiblížit se naměřeným hodnotám než na grafu předchozím.

Neplatí zde ale že, čím delší učení tím lepší výsledek a nastává tzv. „nedoučení sítě“ nebo „přeučení sítě“. Bohužel neexistuje žádné pravidlo které by určovalo přesnou hranici počtu epoch. Je tedy třeba experimentovat s délkou učení a přibližnou aproximací dosáhnout co možná nejpřesnějšího výsledku.


7.2.2 Závislost dvou vstupních na dvou výstupních parametrech




Obr 34. Blokové schéma umělé neuronové sítě 2



Obr 35. Graf závislosti posuvu f a výkonu P na hloubce h při konstantní drsnosti $R_{a2} = 20 \mu\text{m}$



Obr 36. Graf závislosti výkonu P a posuvu f na drsnosti R_{a2} při konstantní hloubce $h = 200 \mu\text{m}$

Obr 37. Graf závislosti výkonu P a posuvu f na hloubce h a drsnosti R_{a2} Tabulka VIII. Hodnoty R_{a2} , R_{z2} , h , pro přepočítání osy x

h	50	70	90	110	130	150	170	190	210	230	250	270
R_{a2}	8	9	10	11	12	13	14	15	16	17	18	19
h	290	310	330	350	370	390	410	430	450	470	490	
R_{a2}	20	21	22	23	24	25	26	27	28	29	30	

Na tomto typu umělé neuronové sítě je vidět závislost posuvu f a výkonu P na hloubce h a drsnosti R_{a2} . Z grafu na Obr 35 je patrná tendence výkonu P klesat a posuvu f také klesat, klesající výkon P sice drsnost snižuje, ale klesající posuv f zvyšuje.


Posuv f se snižuje ale snižuje s vyšším gradientem, což v součtu znamená že se drsnost bude zvyšovat.

Z grafu na Obr 36 je tendence výkonu P i posuvu f růst. Výkon ovšem roste z vyšším gradientem, což je stejný případ jako v grafu předchozím, akorát opačného smyslu. U grafu na Obr 36 je patrný sklon ke stagnaci posuvu i výkonu, což může být způsobeno zadáním konstantní hodnoty hloubky $h = 200 \mu\text{m}$ čímž se dostáváme ke konci predikce k nereálným požadavkům na umělou neuronovou síť.


Z grafu na Obr 37 lze sledovat zpočátku téměř konstantní hodnoty výkonu P , což se ale umělá neuronová síť snaží vykompenzovat velkým gradientem snížení posuvu f a v druhé části grafu se funkce mění opačným směrem. Posuv f v jedné chvíli dokonce mírně roste, ovšem výkon P v tom samém okamžiku roste s podstatně vyšším gradientem.

Tento graf má oba vstupní parametry (hloubku h a drsnost R_{a2}) nekonstantní a tudíž se nedá celá závislost zobrazit do grafu. Z toho důvodu je uvedena Tabulka VIII, která uvádí přepočtenou x -ovou hodnotu z hloubky h na drsnost R_{a2} , pro znázornění všech veličin do grafu by jsme potřebovali 3D graf.

7.2.3 Závislost třech vstupních na dvou výstupních parametrech




Obr 38. Blokové schéma umělé neuronové sítě 3




Obr 39. Graf závislosti výkonu P a posuvu f na hloubce h při konstantní drsnosti


$$R_{a2} = 12,5 \mu\text{m} \text{ a } R_{z2} = 70 \mu\text{m}$$



Obr 40. Graf závislosti výkonu P a posuvu f na drsnosti R_{a2} při konstantní hloubce $h = 50 \mu\text{m}$ a $R_{z2} = 70 \mu\text{m}$



Obr 41. Graf závislosti výkonu P a posuvu f na drsnosti R_{z2} při konstantní hloubce $h = 650 \mu\text{m}$ a $R_{a2} = 12,5 \mu\text{m}$



Obr 42. Graf závislosti výkonu P a posuvu f na hloubce h při nekonstantních hodnotách drsnosti R_{a2} a R_{z2}

Tabulka IX. Hodnoty R_{a2} , R_{z2} , h , pro přepočet osy x

h	25	50	75	100	125	150	175	200	225	250
R_{a2}	6	7	8	9	10	11	12	13	14	15
R_{z2}	30	35	40	45	50	55	60	65	70	75
h	275	300	325	350	375	400	425	450	475	500
R_{a2}	16	17	18	19	20	21	22	23	24	25
R_{z2}	80	85	90	95	100	105	110	115	120	125

U tohoto typu neuronové sítě již nelze vykreslit graf, který by byl schopen zobrazit veškeré závislosti. Při nekonstantních vstupních hodnotách dostaneme 3 různé na sobě nezávislé parametry závislé na dvou výstupních parametrech, takže by bylo za potřeby 4D (4 rozměrový) graf. Uvedl jsem tedy 2D grafy Obr 39, Obr 40 a Obr 41, vždy pro jeden proměnný a dva konstantní vstupní parametry a pro všechny parametry proměnné jsem uvedl 2D graf na Obr 42 a Tabulka IX pro převod jednotek osy x (hloubka h) v tomto grafu.

Z grafu na Obr 39 lze pozorovat klesání posuvu f a nárůst výkonu P při rostoucí hloubce h . U nízkých hodnot hloubky h je vidět stagnaci výkonu P vyváženou poklesem posuvu f a ke konci opačný stav, kdy posuv f stagnuje a umělá neuronová síť se snaží ke zvyšovat hloubku h výkonem P .


U nejvyšších hodnot hloubky h je vidět snížení výkonu P , což opět můžeme připsat chybě, která vznikla v důsledku zadání konstantních hodnot ostatních parametrů a tím chybě v okrajových částech predikce, jak již bylo zmiňováno dříve.

Z grafu na Obr 40 lze pozorovat opět klesání posuvu f a nárůst výkonu P při zvyšující se drsnosti R_{a2} a v počátku predikce výkonu P je opět vidět chyba v důsledku zadání konstantních hodnot ostatních parametrů.


Z grafu na Obr 41 lze znova pozorovat klesání posuvu f a nárůst výkonu P při zvyšující se drsnosti R_{z2} a také v počátku predikce u výkonu P a tentokrát i posuvu f a zde i na konci je vidět chyba v důsledku zadání konstantních hodnot ostatních parametrů.

Z grafu na Obr 42 lze pozorovat klesání posuvu f a nárůst výkonu P , ovšem teď při všech měnících se hodnotách všech vstupních parametrů (drsnosti R_{a2}, R_{z2} , i hloubka h), také zde nenastává chyba v okrajových částech predikce.


7.2.4 Závislost pěti vstupních na dvou výstupních parametrech



Obr 43. Blokové schéma umělé neuronové sítě 4



Obr 44. Graf závislosti posuvu f a výkonu P na hloubce h při konstantní drsnosti $R_{a1} = 10 \mu\text{m}$, $R_{z1} = 50 \mu\text{m}$, $R_{a2} = 10 \mu\text{m}$ a $R_{z2} = 50 \mu\text{m}$.



Obr 45. Graf závislosti posuvu f a výkonu P na hloubce h na při nekonstantních hodnotách drsnosti R_{a1} , R_{z1} , R_{a2} a R_{z2}

Tabulka X. Hodnoty R_{a2} , R_{z2} , h , pro přepočítání osy x

h	25	50	75	100	125	150	175	200	225	250
R_{a1}	3,85	4,7	5,55	6,4	7,25	8,1	8,95	9,8	10,65	11,5
R_{z1}	20	24,5	29	33,5	38	42,5	47	51,5	56	60,5
R_{a2}	6	7	8	9	10	11	12	13	14	15
R_{z2}	30	35	40	45	50	55	60	65	70	75
h	275	300	325	350	375	400	425	450	475	500
R_{a1}	12,35	13,2	14,05	14,9	15,75	16,6	17,45	18,3	19,15	20
R_{z1}	65	69,5	74	78,5	83	87,5	92	96,5	101	105,5
R_{a2}	16	17	18	19	20	21	22	23	24	25
R_{z2}	80	85	90	95	100	105	110	115	120	125

Na tomto nejsložitějším typu umělé neuronové sítě je názorně vidět jak ovlivňuje zadání vstupních parametrů výsledek.

Funkce výkonu P a posuvu f v grafu na Obr 44 jsou ovlivňovány jednak zadáním konstantních parametrů (vzniká opět chyba popisovaná již několikrát výše) a i vlivem zařazení podélné drsnosti do vstupních dat umělé neuronové sítě, která se musí učit i značně nelineární závislosti příčné drsnosti R_{a1} a R_{z1} , která je navíc i obtížně měřitelná z důvodu vznikající chyby měření, jak je podrobně popsáno v kapitole 6.2.3 Chyba měření u podélné drsnosti. Tudíž je v grafu na Obr 44 vidět tendence posuvu klesat a výkonu růst s rostoucí se hloubkou h , avšak se značnými chybami (stagnace funkce výkonu P na začátku i konci predikce i posuvu f na konci predikce).

Graf na Obr 45 znázorňuje opět tendenci posuvu P klesat a výkonu f růst, ale při měnících se všech vstupních parametrech (hloubky h a drsností R_{a1} , R_{z1} , R_{a2} a R_{z2}). Jak je patrné, při průběhu funkcí posuvu f a výkonu P nenastává žádný neočekávaný průběh. Nejprve lze pozorovat snižování posuvu f při stagnaci výkonu P a pak zvyšování výkonu P při stagnaci posuvu f .

ZÁVĚR

Cílem této práce bylo nadefinovat takovou umělou neuronovou síť aby byla schopna naučit se proces laserového popisování a predikovat veškeré jeho parametry, v důsledku čehož by se dala zařadit jako automatizovaný člen optimalizace výrobního procesu, která v tuto chvíli probíhá jen na základě odborného odhadu zkušeným pracovníkem. Vyřadil by se tak z výrobního procesu faktor lidské chyby a nutnost odborného posuzování, při čemž by se efektivnost, produktivita i kvalita výroby zlepšila.

Ve všech čtyřech případech které jsem vypracoval se mi podařilo nadefinovat takovou umělou neuronovou síť, která dovede predikovat výstupní hodnoty i mimo body měření s dobrými výsledky.

Přesnost predikovaného výsledku závisí i na počtu naměřených dat. Logicky platí závislost čím více dat, tím větší přesnost. Pracoval jsem s naměřenými daty o objemu 5x100 (5 hodnot, 100 vzorků). Má-li ale umělá neuronová síť nahradit zkušenosti odborného pracovníka, potřebovala by vstupních dat podstatně více – zkušenost pracovník také nedostane z výroby 100 výrobků. Přesnost predikce také přímo závisí na přesnosti měření vstupních dat.

V některých případech predikce jsem se setkal s chybou v krajních částech rozsahu vstupních dat, což bylo způsobeno zadáním konstantní hodnoty vstupních parametrů, z důvodů vysledování vlivu pouze jednoho ze vstupních parametru, takže v okrajových oblastech to vedlo k nesmyslným požadavkům na naučenou umělou neuronovou síť (např. velká hloubka při nízkých hodnotách výkonu atp.), která pak ve výsledku navrhla chybovou predikci např. Obr 44.

Výhodou aplikace Matlab kterou jsem používal k práci s umělou neuronovou sítí je, že již existuje jako hotový nástroj s vestavěnými utilitami, které zajišťují snadnou a jednoduše pochopitelnou práci, takže není nutno dopodrobna studovat složité matematické funkce a závislosti a dokonce ani do detailu studovat princip funkce neuronů. Uživatel může brát umělou neuronovou síť v aplikaci Matlab jako „funkční člen“, který může využívat i bez detailní znalosti principu jeho funkčnosti.

Výhoda umělé neuronové sítě spočívá v tom, že nalezení někdy i silně nelineárních závislostí mezi 5-ti vstupními a 2-mi výstupními parametry je jinými metodami dosažitelná jen velmi obtížně a nebo vůbec nedosažitelná.

Nevýhodou umělých neuronových sítí je problematika délky učení, kdy se nedá předem stanovit přesný počet epoch, který by zajistil nejpřesnější výsledky. Při zadání malého počtu epoch vznikne tzv. nedoučení sítě, umělá neuronová síť proloží predikci mezi naměřené body jen přibližně, avšak intervaly mezi těmito body jsou proloženy smysluplně. Při zadání příliš vysokého počtu epoch vznikne tzv. přeučení sítě a nastává opačný problém, kdy se umělá neuronová síť snaží proložit predikci velmi přesně naměřenými body. V tomto případě je přesnost predikce vysoká v blízkém okolí naměřených bodů, ovšem v intervalech mezi těmito hodnotami značně kolísá.

Cena aplikace Matlab je relativně vysoká, např. v porovnání s aplikací Excel, která se dá ovšem použít pouze pro aproximace – jeden vstupní na jeden výstupní parametr – kdy predikci stanovíme z naměřených dat lineární regresí. Pro složitější aproximaci by bylo stejně nutno použít některou s pokročilejších aplikací např. Mathematica, Maple nebo Statgraphics, které se ale již cenově vyrovnají aplikaci Matlab.

V současném stavu lze umělou neuronovou síť využít v praxi pro predikci jen částečně. Umí predikovat výstupní hodnoty posuvu a výkonu na zadané vstupní hodnoty drsnosti a hloubky, které musí pracovník nastavit na gravírovacím stroji. V budoucnu by se dalo této síti použít pro plně automatizované ovládání stroje, kde by umělá neuronová síť tvořila součást software k obsluze stroje.

SEZNAM POUŽITÝCH ZDROJŮ

- (1) ZELINKA, Ivan. Umělá inteligence I: Neuronové sítě a genetické algoritmy. 1.vyd., Brno: PC-DIR, 1998. 126 s. ISBN: 80-214-1163-5
- (2) ŠULC, Jan. Lasery a jejich aplikace, PDF dostupné z URL: <<http://www.plslaser.cz/pdf/lasery.pdf>>
- (3) ŠULC, Jan. Průmyslové aplikace laserových systémů, PDF dostupné z URL: <<http://www.plslaser.cz/pdf/prumysl.pdf>>
- (4) STRUMBAN. Lasery a optoelektronika. 1.vyd., Praha 1989. 248 s.
- (5) PETROVÁ, Libuše. Optimalizace procesu laserového řezání plastů. Diplomová práce, 1999. 95s.
- (6) RŮŽIČKA, Zdeněk. Výzkum použití laseru a paseru při opracování plastů. Diplomová práce, 1995
- (7) KRYŠTŮFEK, Miroslav. Řezání polymerních materiálů laserem. Diplomová práce, 2000, 120s.

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

b	- váha neuronu
c	- rychlost světla
DPI	- density per inch (hustota na palec)
E_p	- energie jednoho fotonu
f	- frekvence, posuv laserového paprsku
h	- Planckova konstanta ($6,626 \cdot 10^{-34}$), hloubka vygravírovaného povrchu
P	- výkon laserového paprsku
R	- hloubka proniknutí záření
R_{a1}	- průměrná aritmetická úchylka drsnosti v příčném směru
R_{a2}	- maximální úchylka drsnosti v příčném směru
R_{z1}	- průměrná aritmetická úchylka drsnosti v podélném směru
R_{z2}	- maximální úchylka drsnosti v podélném směru
W	- prahová hodnota neuronu
γ	- konduktivita
λ	- vlnová délka
μ	- relativní permeabilita

SEZNAM OBRÁZKŮ

Obr 1.	Model neuronu ze 40. let (9)	9
Obr 2.	Nejvíce používaná funkce – logistická (9).....	12
Obr 3.	Klasická vícevrstvá síť (2 vrstvy po 3 neuronech) (9)	13
Obr 4.	Různé topologie sítí (9).....	14
Obr 5.	Nelineární hranice mezi třídami (9).....	15
Obr 6.	Schéma sítě Perceptron (9).....	16
Obr 7.	Hopfieldova síť (9).....	19
Obr 8.	Schéma sítě CLN (9).....	20
Obr 9.	Schéma sítě BAM (9).....	21
Obr 10.	Schéma Kohonenovy sítě (9).....	22
Obr 11.	Schéma sítě ARTLasery (9).....	23
Obr 12.	Spektrum elektromagnetických vln (6).....	25
Obr 13.	Absorpce, spontánní a stimulovaná emise (7)	26
Obr 14.	Optický rezonátor s aktivním prostředím (2).....	27
Obr 15.	Polovodičový laser s heterostrukturou (4)	32
Obr 16.	Schéma rentgenového laseru (7)	34
Obr 17.	Princip popisování vychylováním paprsku (7)	37
Obr 18.	Porovnání standardní a ploché čočky (7).....	37
Obr 19.	Princip maskovací metody popisování (7).....	38
Obr 20.	Princip technologie kyvadlového zrcadla (7).....	38
Obr 21.	Lokální změna barvy nebo povrchové struktury (7)	39
Obr 22.	Schéma výkresu vzorkového dílu.....	43
Obr 23.	Sken vzorkového dílu	44
Obr 24.	3D graf závislosti drsnosti R_{a1} [μm] na výkonu P [%] a posuvu f [%]	45
Obr 25.	3D graf závislosti drsnosti R_{z1} [μm] na výkonu P [%] a posuvu f [%]	46
Obr 26.	3D graf závislosti drsnosti R_{a2} [μm] na výkonu P [%] a posuvu f [%]	47
Obr 27.	3D graf závislosti drsnosti R_{z2} [μm] na výkonu P [%] a posuvu f [%]	48
Obr 28.	3D graf závislosti drsnosti R_{a2} [μm] na výkonu P [%] a posuvu f [%]	49
Obr 29.	Závislost vlivu výkonu na drsnost povrchu. Příklad: a) malý výkon b) střední výkon c) velký výkon	50
Obr 30.	Blokové schéma umělé neuronové sítě.....	54
Obr 31.	Blokové schéma umělé neuronové sítě 1.....	55
Obr 32.	Graf závislosti výkonu P na hloubce h na při konstantním posuvu f 10%.....	55
Obr 33.	Graf závislosti posuvu f na hloubce h při konstantním výkonu P 100%	56
Obr 34.	Blokové schéma umělé neuronové sítě 2.....	56
Obr 35.	Graf závislosti posuvu f a výkonu P na hloubce h při konstantní drsnosti $R_{a2} = 20 \mu\text{m}$	57
Obr 36.	Graf závislosti výkonu P a posuvu f na drsnosti R_{a2} při konstantní hloubce $h = 200 \mu\text{m}$	57
Obr 37.	Graf závislosti výkonu P a posuvu f na hloubce h a drsnosti R_{a2}	58
Obr 38.	Blokové schéma umělé neuronové sítě 3.....	59
Obr 39.	Graf závislosti výkonu P a posuvu f na hloubce h při konstantní drsnosti $R_{a2} = 12,5 \mu\text{m}$ a $R_{z2} = 70 \mu\text{m}$	59
Obr 40.	Graf závislosti výkonu P a posuvu f na drsnosti R_{a2} při konstantní hloubce $h = 50 \mu\text{m}$ a $R_{z2} = 70 \mu\text{m}$	60

Obr 41.	Graf závislosti výkonu P a posuvu f na drsnosti R_{z2} při konstantní hloubce $h = 650 \mu\text{m}$ a $R_{a2} = 12,5 \mu\text{m}$	60
Obr 42.	Graf závislosti výkonu P a posuvu f na hloubce h při nekonstantních hodnotách drsnosti R_{a2} a R_{z2}	61
Obr 43.	Blokové schéma umělé neuronové sítě 4.....	62
Obr 44.	Graf závislosti posuvu f a výkonu P na hloubce h při konstantní drsnosti $R_{a1} = 10 \mu\text{m}$, $R_{z1} = 50 \mu\text{m}$, $R_{a2} = 10 \mu\text{m}$ a $R_{z2} = 50 \mu\text{m}$	63
Obr 45.	Graf závislosti posuvu f a výkonu P na hloubce h na při nekonstantních hodnotách drsnosti R_{a1} , R_{z1} , R_{a2} a R_{z2}	63

SEZNAM TABULEK

Tabulka I.	rozdíl mezi PC a neuronovou sítí (9).....	10
Tabulka II.	přepočtová tabulka jednotek výkonu P a posuvu f	44
Tabulka III.	závislosti drsnosti R_{a1} [μm] na výkonu P [%] a posuvu f [%]	45
Tabulka IV.	závislosti drsnosti R_{z1} [μm] na výkonu P [%] a posuvu f [%]	46
Tabulka V.	závislosti drsnosti R_{a2} [μm] na výkonu P [%] a posuvu f [%]	47
Tabulka VI.	závislosti drsnosti R_{z2} [μm] na výkonu P [%] a posuvu f [%]	48
Tabulka VII.	závislosti hloubky h [μm] na výkonu P [%] a posuvu f [%]	49
Tabulka VIII.	hodnoty R_{a2} , R_{z2} , h , pro přepočet osy x	58
Tabulka IX.	hodnoty R_{a2} , R_{z2} , h , pro přepočet osy x	61
Tabulka X.	hodnoty R_{a2} , R_{z2} , h , pro přepočet osy x	64

SEZNAM PŘÍLOH

- P 1 : 3D grafy z Obr 24 až Obr 28 (..\Přílohy\3D grafy.xls)
- P 2 : Detailní sken vygravírovaného vzorkového dílu (..\Přílohy\Deska600DPI.jpg)
- P 3 : Všechny použité grafy (..\grafy.xls)
- P 4 : Převedené vstupní data pro aplikaci Matlab (..\Přílohy\Vstupní data\InputMatlab.xls)
- P 5 : Zkomprimované programové soubory pro aplikaci Matlab (..\Přílohy\Matlab.zip)
- P 6 : Stroje a přístroje použité v experimentální části (..\Přílohy\Stroje přístroje.doc)
- P 7 : Vstupní data (..\Přílohy\Vstupní data\Vstupní data.doc)
- P 8 : Diplomová práce (..\Diplomová práce – Svítek 2005.doc)