

13. Příklady experimentálních aplikací metod rozpoznávání v dalších oblastech

13.1. Aplikace v robotice

Na katedře řídicí techniky FEL ČVUT byla řešena úloha rozpoznávání tvarů objektů uchopených antropomorfní hlavicí robota.

Pro potřeby experimentů byl vyvinut prototyp pětiprsté úchopné hlavice typu umělá ruka, vybavený 659 diskrétními kontaktními taktilními (dotykovými) čidly v maticovém uspořádání, umístěnými „v dlani“ úchopné hlavice, a 14 sekundárními (polohovými) taktilními čidly umístěnými v kloubech „prstů“ hlavice.

Experiment A

Vstup: Údaje ze 673 čidel úchopné hlavice, a to v okamžiku po uchopení objektu (z toho 659 údajů má binární charakter).

Výstup: Klasifikace tvarů objektů do 8 tříd (válece, hranoly trojboké, čtyřboké a pětiboké, jehly trojboké a čtyřboké, kužele, koule), určení typu uchopení (např. u válce je to buď základna v dlani, nebo plášť v dlani) a základních rozměrů.

Klasifikátor byl řešen jako dvojúrovňový, na první úrovni byla odděleně zpracovávána informace z maticového snímače (659 binárních údajů) a informace ze sekundárních čidel, charakterizující konfiguraci aktivních prvků hlavice, tj. prstů. Druhá úroveň klasifikátoru pak zabezpečovala zpracování výstupů obou systémů první úrovně z celkového pohledu. Všechny tři subsystémy byly založeny na strukturálních metodách rozpoznávání, zpracování v každém z nich probíhala ve třech fázích (fázi generativní, fázi syntaktické analýzy a fázi sémantické analýzy) a výsledky subsystému první úrovně byly předávány druhé úrovni ve formě numerické informace.

Činnost subsystému pro zpracování informace z maticového snímače lze ve stručnosti popsat takto:

a) *Generativní fáze.* Dvojměrná informace z maticového snímače je chápána jako „otisk“ trojrozměrného objektu v dlani umělé ruky. Proto je nejprve detekována hranice „otisku“, každému hraničnímu bodu je přiřazen numerický symbol a ve smyslu Freemanova řetězového kódu, tj. každá hraniční křivka je popsána řetězem $s = a_1 \dots a_n$, kde n je počet hraničních bodů. Řetěz je podroben digitální filtraci k odstranění šumu. Každý prvek řetězu je považován za primitivum strukturálního popisu a je mu přiřazen terminální symbol c_i . Výsledkem činnosti generativní fáze je tedy řetěz $C = c_1 c_2, \dots, c_n$.

b) *Fáze syntaktické analýzy.* Na základě trénovací množiny syntakticky korektních řetězů C byly Evansovou metodou inference odvozeny dvě bezkontextové gramatiky

— gramatika G_H pro třídu „hranatých otisků“ (obsahovala 34 pravidel),

— gramatika G_o pro třídu „oblých otisků“ (27 pravidel).

Obě gramatiky měly celkem 21 pravidel shodných. Klasifikace do jedné ze dvou uvedených tříd byla určena gramatikou, pomocí níž bylo možné provést syntaktickou analýzu. Ve sporném případě (řetěz bylo možné zanalyzovat jen pomocí pravidel typických pro obě gramatiky) rozhodoval poměr použitých typických pravidel.

c) *Fáze sémantické analýzy.* Atributová gramatika sémantické analýzy obsahovala celkem 22 pravidel a uvažovalo se 13 atributů. Tato gramatika umožňovala jemnější třídění uvnitř

třídy „oblých otisků“ (2 podtřídy: kružnice, elipsa) i třídy „hranatých otisků“ (12 podtříd: obdélník, čtverec, kosočtverec, lichoběžník...), současně se formalizoval postup výpočtů polohy vrcholů a postup určování relací mezi hranami (pro hranaté otisky) a postup výpočtu poloměrů a os (pro oblé otisky).

Výsledkem činnosti subsystému je popis obrazu indikátorem podtřídy a vektorem vhodných numerických parametrů.

Činnost subsystému pro zpracování informace ze 14 sekundárních taktilních čidel lze popsat takto:

a) *Generující fáze.* Na základě podrobné kinematicko-geometrické analýzy trojčlankových planárních mechanismů (při uvažované strategii řízení procesu uchopení) bylo stanoveno šest typických konfigurací těchto mechanismů (tj. prstů umělé ruky). Pro každý prst (s výjimkou dvojčlankového palce) byla momentální konfigurace detekována prostřednictvím čtyř nezávislých příznakových klasifikátorů, pracujících na principu minimalizace chyby a zpracovávajících údaje ze tří čidel (tj. tří kloubů prstu). Tato konfigurace byla považována za primitivum popisu a byl jí přiřazen terminální symbol. Stav kinematické struktury čtyř trojčlankových mechanismů byl taky popsán řetězem D symbolů délky čtyř.

b) *Fáze syntaktické analýzy.* Cílem syntaktické analýzy bylo prověřit korektnost slova D a eventuálně zabezpečit jeho syntaktickou korekci. Na základě analýzy trénovací množiny byla vytvořena jediná regulární gramatika G a k ní příslušející gramatika rozšířená $G^E = G \cup G^D$, přičemž deformační gramatika G^D reprezentovala jednoduchý deformační model. V modelu byly uvažovány pouze lokální syntaktické deformace, vzdálenost slova D od jazyka $L(G)$ byla definována jako minimální počet použití pravidel deformační gramatiky G^D . Tato pravidla pak byla použita zpětně ke korekci slova D .

c) *Fáze sémantické analýzy.* Atributová gramatika sémantické analýzy obsahovala 62 pravidel a pracovala s 33 atributy. (K atributům patřily i dosud nevyužité údaje z čidel v „palci“ umělé ruky). Sloužila především k ověření popisu vzniklého jako výsledek předchozí fáze z hlediska fyzikální realizovatelnosti, k zařazování objektů do osmi tříd a k výpočtu numerických parametrů (průměr válce, kuželovitost kužele atd.). Pokud syntakticky korektní popis nebyl ověřen, byla z nižší úrovně zpracování (z fáze syntaktické analýzy) vyžádána nová korekce.

Výsledkem činnosti subsystému je popis formou indikátoru třídy a doplňkového (sémantického) vektoru parametrů, vypočtených ve fázi sémantické analýzy.

Systém druhé úrovně komplexního zpracování taktilní informace byl poměrně jednoduchý:

a) *Generativní fáze.* Byla realizována generativní atributovou gramatikou (27 pravidel, 18 atributů), jejímž „vstupem“ byly jak (nenumernické) indikátory tříd (tj. výsledky první úrovně zpracování), tak i příslušné sémantické vektory. „Výstupem“ gramatiky byla jednosymbolová slova (indikátory tříd druhé úrovně zpracování).

b) *Syntaktickou analýzu* jednosymbolových slov nemělo smyslu provádět.

c) *Fáze sémantické analýzy.* Byla opět realizována atributovou gramatikou, tentokrát v „analytickém“ provedení. Cílem činnosti této gramatiky je ověření správné fyzikální interpretace naměřených dat a vygenerování sémantického vektoru globálního řešení.

Výsledky

K vyhodnocení celkové správnosti klasifikace bylo provedeno celkem sto nejrůznějších typů uchopení nejrůznějších objektů.

Průměrná správnost klasifikace do 14 podtříd u subsystému pro zpracování informace z maticového snímače byla 90% (pohybovala se v rozmezí 78 —100 % pro jednotlivé podtřídy), numerické parametry byly určovány s chybou nepřevyšující $2h$ (h je vzdálenost středů dvou sousedních čidel v matici).

U subsystému pro zpracování informace ze sekundárních taktilních čidel bylo dosaženo správnosti klasifikace 96 %, chyba numerických parametrů nebyla větší než 8 %. V generativní fázi vytvořené popisy byly správné v 87 %, další 9 % zlepšení bylo dosaženo ve fázích syntaktické a sémantické analýzy.

Celková správnost klasifikace u dvojúrovňového klasifikátoru byla 97 % (1% jsou chyby, ve 2% nebylo nalezeno řešení) při chybách numerických parametrů nepřevyšujících 8 %.

13.2. Aplikace v lékařské diagnostice

Z celé řady aplikací metod rozpoznávání v oblasti lékařské diagnostiky byly vybrány dva rozsáhlejší experimenty, zabývající se klasifikací psychofyziologických stavů pacientů na základě zpracování křivky EEG, a experiment, týkající se diferenciální diagnostiky cholecystolitiaz.

13.2.1. Příklady aplikací v elektroencefalografii

U obou popisovaných experimentů byla křivka EEG snímána dvojicí elektrod, umístěných v parieto-okcipitální oblasti povrchu lebky. Signál EEG byl nejprve filtrován prostřednictvím čtyř filtrů do těchto frekvenčních pásem:

0,5 - 3,5 Hz (delta-aktivita),

4 - 8 Hz (gama-aktivita),

8 - 13 Hz (alfa-aktivita),

14 - 30 Hz (beta-aktivita).

Uvedené označení pásem je v elektroencefalografii obvyklé.

Výstup každého z filtrů je integrován vždy po dobu $T = 5$ s a výstupní hodnoty integrátorů x_i , $i = 1, \dots, 4$, tvoří čtyřdimenzionální vektor $x = [x_1, \dots, x_4]^T$, charakterizující každý pětisekundový úsek křivky EEG.

Experiment B

Vstup: Vektor x popisující pětisekundový úsek křivky EEG.

Výstup: Určení momentálního psychofyziologického stavu u pacientů s trizomií 21. chromozómu (tj. s Downovým syndromem), přičemž se uvažují 4 okamžité psychofyziologické stavy (4 třídy):

1. Relaxace, oči otevřené,
2. Relaxace, oči zavřené,
3. Mentální aktivita (řešení Ravnova testu), oči otevřené,
4. Mentální aktivita (řešení jednoduchých numerických úloh), oči zavřené.

Ve srovnání s již dříve řešenou, analogicky formulovanou, úlohou

pro zdravé osoby, při jejímž řešení byl užit jednoduchý příznakový klasifikátor, založený na neparametrickém odhadu funkce hustoty pravděpodobnosti, je klasifikace pro pacienty, postižené v různé intenzitě psychomotorickou retardací, poněkud složitější. Proto bylo nutné užít složitější struktury klasifikátoru, využívající jak příznakových, tak strukturálních metod rozpoznávání.

Základní myšlenky klasifikátoru lze stručně vyjádřit takto:

1. Z poznatků v odborné lékařské literatuře a na základě konzultací s lékaři bylo zvoleno pro popis každého pětisekundového úseku celkem sedm příznaků. Šlo o příznaky x_1, x_2, x_3, x_4 a dále o odvozené příznaky $x_5 = x_1/x_2$, $x_6 = x_1/x_3$, $x_7 = x_2/x_3$. Příznaky x_5 , x_6 , x_7 jsou odvozeny, neobsahují novou informaci, avšak transformace čtyřdimenzionálního obrazového prostoru na sedmidimenzionální s sebou přináší lepší separabilitu obrazů jednotlivých tříd.

2. Pro potlačení rozdílů v záznamech EEG, způsobených jednak rozdíly v individuálních fyzických a fyziologických vlastnostech organismů jednotlivých pokusných osob (tloušťka a vlhkost kůže, potivost apod.), jednak specifickými podmínkami konkrétního snímání (blízkost kovových předmětů, plomb apod.), jsou příznaky normovány podle středních hodnot příznaků v prvních 30s měření v 1. stavu (ve fázi klasifikace se systém „naladí“ na příslušného pacienta).

3. První úroveň klasifikace se opírá o shlukovou analýzu ve fázi učení a o metodu „nejbližšího souseda“ ve fázi klasifikace, přičemž se uvažuje 5. třída, tj. třída artefaktů.

Všechny sedmidimenzionální vektory z trénovací množiny, zachycující r-tý stav, byly podrobeny shlukové analýze. Pro každou třídu se obrazy rozdělily do šesti až sedmi přirozených shluků v obrazovém prostoru. Každý shluk je dále zastoupen jediným obrazem, tzv. etalonem shluku, který reprezentuje „těžiště“ shluku.

Příznaková klasifikace podle metody nejbližšího souseda generuje pro každou křivku posloupnost čísel. Každé číslo popisuje pětisekundový úsek a určuje číslo etalonu, ke kterému je obraz pro daný časový interval ve smyslu Euklidovské metriky nejbliže. Považujeme-li čísla etalonů za primitiva (terminální symboly) strukturálního popisu záznamu EEG, odpovídá záznamu řetěz symbolů.

Čísla etalonů z 5. třídy (artefakty) jsou v řetězu nahrazena čísly bezprostředně předcházejících etalonů (předpokládá se, že v průběhu artefaktu nedošlo ke změně psychofyziologického stavu).

4. Syntaktická oprava popisu (1. část fáze syntaktické analýzy). V řetězech z trénovací množiny byla vybrána tzv. „sporná slova“ o délce jednoho až čtyř symbolů. Sporným slovem rozumíme úsek řetězu složený ze symbolů k -té třídy, který se vyskytoval několikanásobně častěji při r -tém psychofyziologickém stavu než při k -tém. Pro každou ze čtyř tříd byla z příslušného seznamu sporných slov inferována gramatika G_r , $r = 1, \dots, 4$. V průběhu klasifikace je generovaný řetěz syntakticky opravován. Při výskytu „sporného slova“ délky jedna až čtyři (tj. slova, které lze generovat některou z gramatik G_r) je „sporné slovo“ nahrazeno posloupností symbolů z r -té třídy.

5. Definitivní rozhodnutí o momentálním psychofyziologickém stavu pacienta se provádí ve 2. části fáze syntaktické analýzy. Pro každou třídu bylo stanoveno konkrétní vážené deformační schéma (byly uvažovány pouze lokální syntaktické deformace). Řetězy délky pěti symbolů (dva symboly před a dva za symbolem reprezentujícím okamžik, pro který se rozhodnutí provádí) jsou potom podrobeny syntaktické analýze s využitím rozšířených gramatik. Řetěz je zařazen k r -té třídě právě tehdy, jestliže součet vah použitých pravidel z deformační gramatiky G^o je minimální. Tím je

realizováno definitivní rozhodnutí o momentálním stavu pacienta.

Výsledky

Křivky EEG získané od šesti pacientů (asi 600 vektorů) byly užity k natrénování klasifikátoru, křivky EEG jiných čtyř pacientů (asi 400 vektorů) byly užity k testování klasifikátoru. Správnost klasifikace pro jednotlivé třídy se pohybovala v rozmezí 82 — 97 % [6.13]. Nejčastěji docházelo k záměně 1. a 3. psychofyziologického stavu, což zřejmě souvisí s tím, že se duševní činnost projevuje u pacientů s trizomií 21. chromozómu méně výrazně než u zdravých osob.

Klasifikace, o níž v experimentu B šlo, má pro lékaře význam například při určování vzájemného podílu neschopnosti soustředit se a nedostatku inteligence u neprospívajících žáků. Samotné výsledky experimentu sloužily jako podklad pro další úvahy psychofyziologů.

Experiment C

Vstup: Data získaná ze záznamu EEG při měření čtyřmi dvojicemi elektrod ve dvou přesně definovaných krátkodobých psychofyziologických stavech (otevřené a zavřené oči, obojí při mentálním klidu), a to vždy po dobu 50 s. Vstupní data tvoří vektor 320 hodnot (2 stavy x 4 dvojice elektrod x 4 frekvenční pásma x 10 pětisekundových intervalů).

Výstup: Klasifikace osoby do jedné ze dvou tříd: normální osoba a osoba psychicky postižená (schizofrenie).

Základní principy navrženého a realizovaného klasifikátoru lze shrnout takto:

1. Vstupní data byla redukována tak, že hodnoty veličin vždy v deseti pětisekundových intervalech byly nahrazeny střední hodnotou. V nové podobě byl každý pacient popsán osmi čtyřdimenzionálními vektory. Pro každý stav a pro každou dvojici elektrod byly příslušné čtyřdimenzionální vektory z trénovací množiny podrobeny hierarchické shlukové analýze, přičemž byly vždy shledány 4 etalony jako těžiště v procesu shlukové analýzy vzniklých shluků. Každý vektor z osmice čtyřdimenzionálních vektorů dosud neklasifikované osoby je v průběhu prvního kroku zpracování podroben klasifikaci metodou nejbližšího souseda, obraz osoby je pak tvořen posloupností osmi etalonů. Považujeme-li každý etalon za primitivum popisu a přiřadíme-li mu terminální symbol, je pak každá osoba popsána řetězem osmi symbolů.

2. Pro každou ze tříd byla na základě řetězů trénovací množiny sestrojena regulární gramatika třídy G_r , $r = 1, 2$, a vážené deformační schéma pro lokální syntaktické deformace.

3. Vlastní klasifikace je prováděna pomocí deterministických konečných automatů, přičemž byly vyvinuty dvě varianty řešení:

a) Byly vytvořeny dva automaty A_r , $r = 1, 2$. Pokud řetěz symbolů (slovo) není akceptován žádným z nich, ve smyslu váženého deformačního schématu je odvozeno slovo ke klasifikovanému slovu nejbližší a to je testováno automaty A_r , $r = 1, 2$. Pokud je testování bezúspěšné, hledá se další „nejbližší“ slovo ve smyslu deformačního automatu atd., až jeden z automatů A_r odvozené slovo akceptuje. Původní slovo je pak přiřazeno do r -té třídy.

b) Bylo vytvořeno $2M$ automatů $A_{r,0}, \dots, A_{r,M}$, $r = 1, 2$ a M je *maximální* povolený počet záměn symbolů ve slově. Neznámé slovo je nejprve testováno automaty $A_{r,0}$ (odpovídají gramatice G_r), pokud není akceptováno, testuje se pomocí $A_{r,1}$ atd., až je nakonec některým z automatů $A_{r,M}$ akceptováno. Pak je slovo (a tím i osoba) zařazena do r -té třídy, přičemž se předpokládá, že vzniklo deformací „ideálního“ slova záměnou m symbolů.

Výsledky

K natrénování klasifikátoru byla použita náhodně vybraná data naměřená u 30 osob (15 normálních osob, 15 psychotiků). Klasifikátor byl testován na dalších 78 osobách (19 normálních osob, 59 psychotiků). Klasifikace byla prováděna opakovaně (pro různé vybrané prvky trénovací a testovací množiny) a pro oba typy řešení klasifikátoru, přičemž správnost příznakové klasifikace se pohybovala v rozmezí 50 — 70 %, po strukturálním zpracování se zvýšila na 65 — 80 %.

Výsledky byly považovány lékaři za neočekávaně dobré, klasifikátor byl dále experimentálně používán ve Výzkumném ústavu psychiatrickém jako nástroj k objektivizaci složitého diagnostického procesu.

13.2.2. Příklad aplikace při diferenciální diagnostice cholecystolitiáz

Diferenciální diagnostika prostých a komplikovaných cholecystolitiáz (blokád žlučovodu) u pacientů před operací má velký význam pro indikaci instrumentálního předoperačního vyšetření žlučovodu. Pokud totiž nejsou při chirurgickém zákroku odstraněny komplikující změny, je nutná dříve či později reoperace.

Experiment D

Vstup: Celkem 16 příznaků, zahrnujících výsledky klinických, cholangiografických a biochemických vyšetření. Jde většinou o příznaky s ordinárními hodnotami, např. příznak „Průběh záchvatu“ může nabývat těchto šest hodnot:

0 — bez horečky a třesavky,

1 — někdy horečka,

- 2 — vždy horečka,
- 3 — někdy horečka s třesavkou,
- 4 — horečka vždy, někdy třesavka,
- 5 — vždy horečka s třesavkou.

Výstup: Klasifikace cholecystolitíáz do dvou tříd: cholecystolitíáza prostá a komplikovaná.

K realizaci klasifikátoru byl použit problémově nezávislý programový systém PREDITAS [6.1], vyvinutý v Ústavu teorie informace a automatizace ČSAV. Systém PREDITAS obsahuje jak moduly pro selekci příznaků na bázi jejich diskriminativnosti, tak i moduly pro vytvoření a natrénování příznakových klasifikátoru. Postup řešení úlohy pomocí systému PREDITAS lze stručně popsat takto:

1. Příznaky byly uspořádány podle významnosti ve smyslu míry diskriminativnosti.

2. Byly natrénovány příznakové klasifikátory, založené na metodě po částech lineární diskriminační funkce (v podstatě jde o paralelní řazení dichotomních klasifikátoru). Rozhodnutí „nelze klasifikovat“ je chápáno jako samostatná třída.

Výsledky

K natrénování klasifikátoru bylo použito údajů od celkem 418 pacientů (z toho 107 s retrospektivně stanovenou komplikovanou cholecystiolitiázou), klasifikátor byl testován na kontrolní skupině 50 pacientů. Rozhodovací pravidla byla vypočtena pro aplikaci 4, 6, 8, 10, 12 a 16 nejinformativnějších příznaků, vybraných podle míry diskriminativnosti. Správnost klasifikace se pohybovala v rozmezí 64-72%, maxima správnosti klasifikace (72%) bylo dosaženo při uvažování 8 příznaků, 24 % případů pak zůstávalo nerozhodnuto a ve 4 % došlo k chybnému rozhodnutí.

13.3. Aplikace v technické diagnostice

13.3.1. Příklad aplikace v energetice

Na katedře výroby a rozvodu elektrické energie FEL ČVUT byly příznakové metody rozpoznávání aplikovány například na zjišťování spolehlivých a výstražných (tj. potenciálně havarijních) provozních stavů částí přenosové soustavy 400 kV elektrizační soustavy ČR. Zkoumaná část elektrizační soustavy obsahovala celkem 16 uzlů, 10 vedení a 7 transformátorů.

Experiment E

Vstup: Celkem 49 numerických příznaků (z toho 17 proudů ve větvích, 16 hodnot napětí v uzlech a 16 vzájemných úhlů fázorů napětí).

Výstup: Rozhodnutí o zařazení situace do dvou tříd:

- a) třídy provozních stavů spolehlivých,
- b) třídy provozních stavů výstražných.

Postup řešení úlohy lze stručně shrnout takto:

1. Byl proveden výběr příznaků metodou, založenou na Karhunenově-Loeově rozvoji. Konkrétně šlo o speciální Fukunagovu-Koontzeovu metodu, pomocí níž bylo extrahováno 10 nových diskriminativních příznaků.


2. K vlastní klasifikaci byl vybrán jednoduchý učící se klasifikátor, založený na nelineárních diskriminačních funkcích.

Výsledky

K natrénování bylo použito údajů z 50 konkrétních provozních situací, dalších 28 situací bylo použito k ověření klasifikátoru. Klasifikátor vždy klasifikoval správně, a to jak při použití původních 49 příznaků, tak i při použití pouhých 10 příznaků extrahovaných.

13.3.2. Příklad aplikace v oblasti elektrotechnické výroby

Na katedře řídicí techniky FEL ČVUT byl připraven a odzkoušen postup pro automatické doladování elektromechanických filtrů při sériové výrobě, a to pomocí učícího se příznakového klasifikátoru. Klasifikátor vlastně provádí v každém kroku doladování a diagnostiku filtru na základě měření útlumové charakteristiky ve 20 frekvencích v rozsahu 128,3 — 131,4 kHz a klasifikuje nevyhovující stavy filtru do osmi tříd (zvýšit C_1 , C_2 , L_1 , L_2 , snížit C_1 , C_2 , L_1 , L_2), obr. 6.1.



Obr. 6.1. Zapojení elektromechanického filtru.

Experiment F

Vstup: 20 numerických příznaků — hodnot útlumové charakteristiky.

Výstup: Rozhodnutí o zařazení nevyhovujících stavů filtrů do již zmíněných osmi tříd.

K řešení úlohy byly použity jednoduché učící se příznakové klasifikátory, pracující s po částech lineární diskriminační funkcí a využívající metodu učení založenou na přímé minimalizaci ztrát. Údaje učitele při trénování klasifikátoru poskytovaly nejzkušenější seřizovačky, které doladovaly filtry po řadu let ručně. .

Výsledky

Ke správnému naladění filtruje vždy potřeba v průměru 3 až 5 kroků, čas potřebný k řešení se pohybuje v rozmezí 5 až 10 s, zatímco zkušená dělnice ladí filtr 5 až 12 min.

13.3.3. Příklad aplikace v oblasti technické diagnostiky spalovacího motoru

Ve spolupráci FEL ČVUT a VÚ ČKD byl navržen a realizován učící se klasifikátor pro diagnostiku trysek vstřikovacích čerpadel u naftových motorů pro lokomotivy. Jako podklad pro rozhodování slouží naměřené průběhy tlaku před vstřikovacím ventilem motoru a ultrazvukový signál měřený tamtéž. Na každém průběhu obou signálů lze pozorovat několik výrazných lokálních extrémů, které nesou informaci o stavu trysky.

Experiment G

Vstup: Osm numerických příznaků, určených z křivky průběhu tlaku a z ultrazvukového signálu (amplituda lokálních extrémů, hodnoty integrálů některých úseků signálů).

Výstup: Rozhodnutí o stavu trysky. Byly uvažovány tři třídy: normální, ucpaná a volná tryska.

Vytvořený klasifikátor využívá po částech lineární diskriminační funkce, k učení byla použita metoda přímé minimalizace ztrát.

Výsledky

Klasifikátor natrénovaný na stu typických průbězích dosahuje asi 80% —90% správnosti klasifikace při rozhodování o průbězích nezařazených do trénovací množiny. Ukazuje se, že kvalita rozhodování je více než na klasifikátoru závislá na kvalitě a přesnosti určování příznaků.

