

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ
ÚSTAV TELEKOMUNIKACÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF TELECOMMUNICATIONS

ANALÝZA RUČNĚ PSANÉHO PROJEVU U PACIENTŮ POSTIŽENÝCH
NEUROLOGICKÝMI ONEMOCNĚNÍMI

DIPLOMOVÁ PRÁCE
MASTER'S THESIS


AUTOR PRÁCE
AUTHOR

Bc. ZOLTÁN GALÁŽ

BRNO 2013



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ
ÚSTAV TELEKOMUNIKACÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF TELECOMMUNICATION

ANALÝZA RUČNE PSANÉHO PROJEVU U PACIENTŮ POSTIŽENÝCH NEUROLOGICKÝMI ONEMOCNĚNÍMI

ANALYSIS OF HAND-WRITTEN TEXT OF PATIENTS WITH NEUROLOGICAL DISORDERS

DIPLOMOVÁ PRÁCE
MASTER'S THESIS


AUTOR PRÁCE
AUTHOR

Bc. ZOLTÁN GALÁŽ

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. JIŘÍ MEKYSKA

BRNO 2013



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav telekomunikací

Diplomová práce

magisterský studijní obor
Telekomunikační a informační technika

Student: Bc. Zoltán Galáž

ID: 121019

Ročník: 2

Akademický rok: 2012/2013

NÁZEV TÉMATU:

Analýza ručně psaného projevu u pacientů postižených neurologickými onemocněními

POKYNY PRO VYPRACOVÁNÍ:

Analýza ručně psaného projevu je jedna z neinvazivních metod, pomocí které je možné diagnostikovat neurologická onemocnění jako např. Parkinsonova či Alzheimerova nemoc. U pacienta se mohou projevat vady jako mikrografie, rigidita či dyskinze. Cílem této práce je rozbor aktuální problematiky analýzy ručně psaného projevu a návrh a implementace diagnostického systému Parkinsonovy nemoci v jazyku Matlab, C/C++ nebo Java.

DOPORUCENÁ LITERATURA:

- [1] EICHHORN, T. E.; GASSER, T.; MAI, N.; MARQUARDT, C.; ARNOLD, G.; SCHWARZ, J.; OERTEL, W. H. Computational analysis of open loop handwriting movements in Parkinson's disease: A rapid method to detect dopaminergic effects. *Movement Disorders*, 1996, roč. 11, s. 289–297. ISSN: 1531-8257.
- [2] BIDEI-ILDEI, C.; POLLAK, P.; KANDEL, S.; FRAIX, V.; ORLIAGUET, J. P. Handwriting in patients with Parkinson disease: Effect of L-dopa and stimulation of the sub-thalamic nucleus on motor anticipation. *Human Movement Science*, 2011, roč. 30, s. 783–791. ISSN: 0167-9457.
- [3] TUCHA, O.; MECKLINGER, L.; THOME, J.; REITER, A.; ALDERS, G. L.; SARTON, H.; NAUMANN, M.; LANGE, K. W. Kinematic analysis of dopaminergic effects on skilled handwriting movements in Parkinson's disease. *Journal of Neural Transmission*, 2006, roč. 113, s. 609–623. ISSN: 0300-9564.

Termín zadání: 11.2.2013

Termín odevzdání: 29.5.2013

Vedoucí práce: Ing. Jiří Mekyska.

Konzultanti diplomové práce:

prof. Ing. Kamil Vrba, CSc.
Předseda oborové rady

Výzkum popsáný v této diplomové práci byl realizován v laboratořích podpořených z projektu SIX; registrační číslo CZ.1.05/2.1.00/03.0072, operační program Výzkum a vývoj pro inovace.

UPOZORNENÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následku porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

V rámci diplomovej práce bola preštudovaná problematika analýzy ručne písaného prejavu. Bol navrhnutý a následne realizovaný systém automatickej diagnostiky Parkinsonovej nemoci na základe analýzy ručne písaného prejavu. Tento systém pozostáva z viacerých modulov a bol realizovaný v programovom prostredí MATLAB. V prvej časti systému sú záznamy jednotlivých písomno-kresliacich cvičení podrobené predspracovaniu a úprave do formy vhodnej pre segmentáciu. Následne sú tieto záznamy rozdelené na záznamy na ploche tabletu a na záznamy nad plochou tabletu. V ďalšom kroku sú záznamy segmentované metódou dvojfázovej automatickej segmentácie. Nasleduje extrakcia jednotlivých príznakov. Z extrahovaných príznakov sú vypočítané tzv. vysokoúrovňové príznaky. Všetky príznaky sú podrobené štatistickej analýze a výsledky tejto analýzy sú exportované do súboru vhodného pre klasifikáciu. Klasifikácia prebieha pomocou navrhnutého modelu, realizovaného v programovom prostredí RapidMiner. Výstupom navrhnutého systému je natrénovaný model, schopný klasifikácie Parkinsonovej nemoci na základe analýzy ručne písaného prejavu.

KLÍČOVÁ SLOVA

Ručne písaný prejav, neurologické onemocnění, motorické vady, ťahy, segmentácia, príznaky, neurónová sieť, algoritmus, klasifikácia.

ABSTRACT

The master's thesis deals with the analysis of the hand-written text. There is a design and a realization of a system for the purpose of diagnosing a Parkinson's disease based on the analysis of hand-written text. The system consists from several modules and it is programmed in the programming environment of MATLAB. The first module provides pre-processing of the records to adjust records to the form suitable for the segmentation. Afterwards, the records are divided into those with signals onto the surface of the tablet and those with the signals above the surface of the tablet. In the next module the records are segmented by the two-phase method of automatic segmentation. High-level features are calculated from the extracted features. The results of the statistical analysis are exported in the form suitable for the classification process. The classification is performed by the proposed model made in the programming environment of RapidMiner. The output of designed system is the trained model capable of automatic classification of the Parkinson's disease by the analysis of the hand-written text.

KEYWORDS

Hand-written text, neural disorders, motoric disorders, strokes, segmentation, features, neural network, algorithm, classification.

GALÁŽ, Z. *Analýza ručně psaného projevu u pacientů postižených neurologickými onemocněními*. Brno: Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií, 2013. 98 s. Vedoucí diplomové práce Ing. Jiří Mekyska.

PREHLÁSENIE

Prehlasujem, že svoju diplomovú prácu na téma Analýza ručne psaného projevu u pacientů postížených neurologickými onemocněními som vypracoval samostatne pod vedením vedúceho diplomovej práce a s použitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor uvedenej diplomovej práce ďalej prehlasujem, že v súvislosti s vytvorením tejto práce som neporušil autorské práva tretích osôb, predovšetkým som nedovoleným spôsobom nezasiahol do cudzích autorských práv osobných a som si plne vedomí následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona č. 121/2000 Sb., o autorskom práve, o právach súvisiacich s autorským právom a o zmene niektorých zákonov (autorský zákon), vo znení neskorších predpisov, vrátane možných trestnoprávnych dôsledkov vyplývajúcich z ustanovení časti druhej, hlavy VI. diel 4 Trestného zákonníku č. 40/2009 Sb.

V Brne dňa

.....

(podpis autora)

POĎAKOVANIE

Rád by som poďakoval vedúcemu mojej diplomovej práce, pánovi inžinierovi Jiřímu Mekyskovi, za veľmi kvalitné vedenie práce, potrebnú pomoc a poskytnutie dôležitých materiálov potrebných pre realizáciu tejto diplomovej práce.

V Brne dňa

.....

(podpis autora)

OBSAH

Zoznam obrázkov	xiii
Zoznam tabuliek	xvi
Úvod	18
1 Ručne písaný prejav v oblasti neurologických onemocnení	20
1.1 Neurologické onemocnenia a ich prejav na ručne písaný prejav.....	20
1.1.1 Parkinsonova nemoc	21
1.1.2 Alzheimerova nemoc	22
1.1.3 Schizofrénia	23
1.1.4 Dyskinézia	23
1.1.5 Huntingtonova nemoc.....	24
1.2 Získavanie dát pre analýzu ručne písaného prejavu	24
2 Analýza ručne písaného prejavu	26
2.1.1 Archimedova špirála	27
2.1.2 Elipsa	29
2.1.3 Spojené a kurzívou písané písmená „l“	30
2.1.4 Písanie slabík, slov a viet.....	30
2.1.5 Spájanie bodov.....	31
2.2 Automatická segmentácia písomného prejavu	31
2.3 Kvalitatívne hodnotenie ručne písaného prejavu.....	33
3 Metódy analýzy ručne písaného prejavu	35
3.1 Parametre hodnotiace ručne písaný prejav	35
3.1.1 Počet ťahov za sekundu	35
3.1.2 Celková doba písania	36
3.1.3 Výška ťahu.....	37
3.1.4 Dĺžka ťahu	38
3.1.5 Dĺžka trvania ťahu	39

3.1.6	Tlak na hrot pera	39
3.1.7	Rýchlosť písania	41
3.1.8	Počet zmien rýchlosti písania	42
3.1.9	Akcelerácia	42
3.1.10	Stredný počet zmien akcelerácie.....	43
3.1.11	Koeficient šmyku	43
3.2	Parametre používané pri analýze rečového prejavu	44
3.2.1	Spektrogram.....	44
3.2.2	Základná frekvencia signálu	44
3.2.3	Jitter	45
3.2.4	Medián výkonovej spektrálnej hustoty	46
3.2.5	Lineárna predikčná analýza	47
3.2.6	Spektrálny tok	49
3.2.7	Reálne kepstrum	51
3.3	Parametre hodnotiace kvalitu a intenzitu signálu	52
3.3.1	Krátkodobá energia	53
3.3.2	Krátkodobá intenzita	53
3.3.3	Krátkodobá stredná hodnota prechodov signálu nulovou úrovňou	55
3.3.4	Krátkodobá autokorelačná funkcia	55
3.3.5	Harmonicita signálu	56
3.4	Parametre založené na teórii chaosu	57
3.4.1	Korelačná dimenzia	57
3.4.2	Najväčší Laypunovov exponent.....	58
3.4.3	Fraktálna dimenzia.....	58
4	Klasifikácia ručne písaného prejavu	60
4.1	Algoritmus <i>k</i> -najbližších susedov (kNN)	60
4.2	Metódy podporných vektorov (SVM)	61
4.3	Umelé neurónové siete (ANN)	62
4.3.1	Model neurónu	63
4.3.2	Viacvrstvové neurónové siete	63

4.3.3	Algoritmus učenia backpropagation	64
4.4	Lineárna regresia.....	64
5	Návrh systému	65
5.1	Vývojový diagram	65
5.2	Popis systému	66
6	Praktická časť	67
6.1	Predspracovanie testovacích dát	67
6.1.1	Rozdelenie na jednotlivé cvičenia	67
6.1.2	Segmentácia jednotlivých cvičení	68
6.2	Výpočet parametrov	70
6.2.1	Parametre hodnotiace ručne písaný prejav	70
6.2.2	Parametre používané pre analýzu rečového prejavu.....	72
6.2.3	Parametre hodnotiace kvalitu a intenzitu signálu	73
6.2.4	Parametre založené na teórii chaosu	73
6.3	Spracovanie parametrov	73
6.4	Klasifikácia	75
6.4.1	Model klasifikácie.....	75
6.4.2	Výsledky klasifikácie.....	80
7	Záver	84
	Literatúra	86
	Zoznam symbolov, veličín a skratiek	91
	Zoznam príloh	96
A	OBSAH PRILOŽENÉHO CD	97
B	VZOR VYPLNENEJ ŠABLÓNY PRE PÍSMNÉ CVIČENIA	98
C	MODEL TESTOVANIA ÚSPEŠNOSTI KLASIFIKÁCIE	99

ZOZNAM OBRÁZKOV

Obr. 1.1:	Tablet určený pre získavanie dát pre analýzu ručne písaného prejavu. Prebraté z ([46]).	24
Obr. 1.2:	Zobrazenie Azimutu a „Nadmorskej výšky“ pera pri písaní.	25
Obr. 2.1:	Zobrazenie Archimedovej špirály ($f_{vz} = 200$ Hz): a) zdravého človeka; b) pacienta trpiaceho Parkinsonovou nemocou.....	27
Obr. 2.2:	Vyjadrenie bodov na osi y ako $y = f(t)$ Archimedovej špirály ($f_{vz} = 200$ Hz): a) zdravého človeka; b) pacienta trpiaceho Parkinsonovou nemocou. 28	
Obr. 2.3:	Zobrazenie priebehov záznamov cvičenia, pri ktorom sú kreslené elipsy ($f_{vz} = 200$ Hz): a)zobrazenie elíps písaných v rýchlom slede cez seba; b)vyjadrenie bodov daných elíps na osi y ako $y = f(t)$; c) zobrazenie elipsy kreslenej pacientom s miernou poruchou motorického aparátu; d) závislosť osi y danej elipsy na čase.	29
Obr. 2.4:	Záznam cvičenia, pri ktorom sú písané písmená „l“, spojených a písaných v rôznych rýchlostiach ($f_{vz} = 200$ Hz): a) zobrazenie cvičenia písania jedného písmena ako závislosť osi y na osi x ; b) závislosť osi y tohto priebehu na čase.....	30
Obr. 2.5:	Zobrazenie pohybu pera pri písaní na podložke a pohybe nad podložkou pri vykonávaní písomného cvičenia, pri ktorom pacienti píšú zadanú vetu	31
Obr. 2.6:	Zobrazenie Hammingovho okna ($N_{FFT} = 1024$): a) v časovej oblasti; b) vo frekvenčnej oblasti (modulové spektrum).	32
Obr. 3.1:	Zobrazenie tlaku hrotu stylusu na povrch tabletu pri vykonávaní písomno-kresliacich cvičení (modrý priebeh = H, červený priebeh = PD): a) priebeh Archimedovej špirály; b) priebeh elipsy; c) priebeh slova „les“; d) priebeh vety podľa predlohy.	40
Obr. 3.2:	Zobrazenie spektrálnych charakteristík priebehu elipsy ako závislosti osi y na čase ($N_{FFT} = 256$, $f_{vz} = 200$ Hz): a) spektrogram; b) modulové frekvenčné spektrum.....	44
Obr. 3.3:	Priebehy spektrálneho toku Archimedovej špirály: a) priebeh spektrálneho toku písomného prejavu pacienta s Parkinsonovou nemocou pre záznamy na osi x (modrý priebeh) záznamy na osi y (červený priebeh); b) priebeh spektrálneho toku zdravého človeka pre záznamy na osi x (modrý priebeh) záznamy na osi y (červený priebeh).	50
Obr. 3.4:	Priebehy Archimedovej špirály a elipsy a im odpovedajúce priebehy reálneho kepra: a) priebeh záznamu Archimedovej špirály na osi x , v závislosti na	

- priebehu časového razítka t [ms] (modrý priebeh) a odpovedajúceho reálneho kepstra (červený priebeh); b) priebeh záznamu elipsy na osi y , v závislosti na priebehu časového razítka t [ms] (modrý priebeh) a odpovedajúceho reálneho kepstra (červený priebeh). Hodnoty priebehov a ich kepstier sú pre názornosť normalizované..... 52
- Obr. 3.5: Záznam cvičenia, pri ktorom sú kreslené elipsy v rýchлом slede cez seba pacienta trpiaceho Parkinsonovou nemocou ($f_{vz} = 200$ Hz): a) zobrazenie cvičenia písania jednej elipsy ako závislosť osi x na osi t [ms]; b) zobrazenie cvičenia písania jednej elipsy ako závislosť osi y na osi t [ms]; c) STE priebehu a; d) STE priebehu b; e) STI priebehu a; f) STI priebehu b. 54
- Obr. 3.6: Zobrazenie priebehu Archimedovej špirály: a) priebeh záznamu na osi y Archimedovej špirály, v závislosti na priebehu na osi x pacienta diagnostikovaného na prítomnosť Parkinsonovej nemoci; b) priebeh záznamu na osi y Archimedovej špirály, v závislosti na priebehu na osi x pacienta, navyše umelo zašumená bielím šumom..... 56
- Obr. 3.7: Zobrazenie autokorelačnej funkcie priebehov zobrazených na Obr. 3.6: a) priebeh autokorelačnej funkcie záznamu na osi y Archimedovej špirály, v závislosti na priebehu na osi x ; b) autokorelačná funkcia umelo zašumeného priebehu zobrazeného na Obr. 3.6, konkrétne priebehu b). 56
- Obr. 4.1: Proces klasifikácie algoritmu kNN pre počet najbližších susedov rovný $k = 5$. V tomto prípade by bol neznámy vzor klasifikovaný ako oranžová hviezda, pretože v k -tici najbližších susedov zastúpenie tejto triedy prvkov svojim počtom prevyšuje ostatné..... 61
- Obr. 4.2: Zobrazenie rozdelenia (lineárne separovateľnej) množiny dát algoritmom SVM, ktorý hľadá tzv. deliacu nadrovinu schopnú separovať vstupnú množinu dát..... 62
- Obr. 6.1: Zobrazenie prvej časti modelu klasifikácie, tj. importovanie vstupnej množiny a jej rozdelenie na tréningovú a testovaciu množinu. V pravom okraji je zobrazené nastavenie parametra *ratio*, ktorý odpovedá pomeru veľkosti tréningovej a testovacej množiny, plus sa tu nachádza zobrazenie časti importovanej matice mapametrov s označením atribútu *label* označujúceho stav človeka, ktorý dané cvičenie vykonával, tj. PD / H. 76
- Obr. 6.2: Zobrazenie časti modelu klasifikácie, v ktorej je vykonávaný predvýber parametrov z množiny všetkých parametrov pomocou algoritmu mRMR.. 77
- Obr. 6.3: Zobrazenie časti modelu klasifikácie, v ktorom prebieha výber parametrov podľa ich prislúchajúcich váh, vypočítaných v bloku mRMR. 77
- Obr. 6.4: Zobrazenie časti modelu klasifikácie vykonávajúcej výber parametrov, podľa úspešnosti klasifikácie vstupnej množiny pri ich použití. Obrázok zachytáva

interné časti bloku FS a taktiež interné časti bloku Validation, tj. časť tréovania klasifikátora a časť aplikácie natrénovaného klasifikátora na tréovaciu množinu..... 78

Obr. 6.5: Zobrazenie finálnej časti modelu klasifikácie parametrov, ktorá vykonáva klasifikáciu testovacej množiny pomocou modelu naučeného dátami z tréovacej množiny a vypočíta percentuálnu úspešnosť klasifikácie. 79

Obr. 6.6: Zobrazenie percentuálnej úspešnosti klasifikácie navrhnutým modelom pre jednotlivé písomno-kresliace cvičenia pri výbere zvolených klasifikátorov. Graf odpovedá hodnotám uvedeným v tabuľke, vid' Tab. 6.2..... 81

Obr. 6.7: Zobrazenie úspešnosti klasifikácie: a) jednotlivých cvičení zvolenými klasifikátormi; b) jednotlivých klasifikátorov pre všetky cvičenia..... 82

ZOZNAM TABULIEK

- Tab. 3.1: Zobrazenie štatistických parametrov počtu ťahov za jednotku času [s] a celkového počtu ťahov v danom cvičení pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané z cvičenia číslo 9, tj. písania vety podľa predlohy. .. 36
- Tab. 3.2: Zobrazenie štatistických parametrov celkovej doby písania [s] pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané z cvičenia číslo 9, tj. písania vety podľa predlohy. 36
- Tab. 3.3: Zobrazenie štatistických parametrov výšky ťahu pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané z cvičenia číslo 9, tj. písania vety podľa predlohy. 38
- Tab. 3.4: Zobrazenie štatistických parametrov dĺžky ťahu pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané z cvičenia číslo 9, tj. písania vety podľa predlohy. 38
- Tab. 3.5: Zobrazenie štatistických parametrov dĺžky trvania ťahu [s] pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané z cvičenia číslo 9, tj. písania vety podľa predlohy. 39
- Tab. 3.6: Zobrazenie štatistických parametrov tlaku na hrot pera pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané zo všetkých písomno-kresliacich cvičení. 41
- Tab. 3.7: Zobrazenie štatistických parametrov rýchlosti písania pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané zo všetkých písomno-kresliacich cvičení. 41
- Tab. 3.8: Zobrazenie štatistických parametrov akcelerácie (zrýchlenia) písania pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané zo všetkých písomno-kresliacich cvičení. 42
- Tab. 3.9: Zobrazenie štatistických parametrov koeficientu šmyku písania pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané zo všetkých písomno-kresliacich

cvičení.	43
Tab. 3.10: Zobrazenie štatistických parametrov základnej frekvencie písania pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje pre cvičenia 1 a 2, tj. pre Archimedovu špirálu a elipsu.	45
Tab. 3.11: Zobrazenie stredných hodnôt LPC koeficientov pre záznamy cvičení 1 a 2 pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Záznamy sú diferencované na záznamy na osi x a y.	49
Tab. 3.12: Zobrazenie štatistických parametrov spektrálneho toku pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje pre cvičenia 1 a 2, tj. pre Archimedovu špirálu a elipsu pre závislosti na osi x a y.	50
Tab. 3.13: Zobrazenie štatistických parametrov krátkodobej energie vypočítanej z ručne písaného prejavu pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje pre cvičenia 1 a 2, tj. pre Archimedovu špirálu a elipsu pre závislosti na osi x a y.	53
Tab. 3.14: Zobrazenie štatistických parametrov fraktálnych dimenzií vypočítaných z ručne písaného prejavu pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje pre cvičenia 1 a 2, tj. pre Archimedovu špirálu a elipsu pre závislosti na osi x a y.	59
Tab. 6.1: Zobrazenie percentuálnej úspešnosti klasifikácie navrhnutým modelom klasifikácie ručne písaného prejavu. V tabuľke sú zaznamenané stredné hodnoty z desiatich testovacích cyklov $\pm$ std.	80
Tab. 6.2: Zobrazenie percentuálnej úspešnosti klasifikácie jednotlivých klasifikátorov. Hodnoty odpovedajú aritmetickému priemeru dát uvedených v tabuľke Tab. 6.1.	81
Tab. 6.3: Zobrazenie percentuálnej úspešnosti klasifikácie pacientov na základe zvolených cvičení pre všetky klasifikátory. Hodnoty v tabuľke odpovedajú aritmetickému priemeru dát uvedených v tabuľke Tab. 6.1.	82
Tab. 6.4: Zobrazenie najsignifikantnejších parametrov, ktoré navrhnutý systém klasifikácie zvolil ako najvhodnejšie pre jednotlivé cvičenia pri testovaní nastavenými klasifikátormi.	83

ÚVOD

Už od prvopočiatkov ľudskej existencie bolo dorozumievanie sa jednou zo základných požiadaviek na prežitie. Počínajúc jednoduchými motorickými signálmi využívanými pri love, cez najrôznejšie zvuky pripomínajúce skôr zvieracie ako ľudské hlasy, až po prvé náznaky komunikácie prostredníctvom vopred dohodnutých, premyslených výrazov, teda slov. Ako sa ľudský mozog formoval a naše verbálne schopnosti rástli, vznikali prvé nárečia. Neskôr vznikli jazyky a s postupným vývinom ľudskej civilizácie sa začala vynárať potreba komunikácie prostredníctvom ďalšieho komunikačného prostriedku. Týmto prostriedkom sa stalo písmo, ktoré dovolilo ľuďom dorozumievať sa na diaľku, vydláždilo cestu obchodu a výrazne prispelo ku kultúrnemu rozmachu. Písmo sa stalo prostriedkom vzdelávania a umožnilo zaznamenať poznané, a tým uľahčilo ďalší pokrok ľudskej rasy. Písaním si človek zlepšuje svoje motorické schopnosti, ako aj kognitívne (poznávacie) a vizuálne vnímanie. Písmo sa stalo taktiež istým kritériom inteligencie a ľudských schopností. Dnes už je písanie považované za samozrejmú a človek, ktorý ho neovláda je považovaný za nevzdelaného.

Aj v dnešnej dobe modernej civilizácie, značne ovplyvnenej technológiou, je písmo stále jedným so základných a neoddeliteľných komunikačných prostriedkov. S písmom prichádzame do styku deň čo deň a sme svedkami mnohých foriem a tvarov písma, jeho rôznej kvality a čitateľnosti a ďalších iných charakteristík, ktoré môžu byť písmu priradené. Časom sa teda logicky objavila otázka, čo ovplyvňuje toto písmo? Aké sú dôsledky a príčiny toho, že každý človek píše trochu inak? Pri pozorovaní písma staršieho človeka je možné pozorovať isté črty, ktoré sú charakteristické a vyskytujú sa pravidelne. Naopak existujú isté javy (parametre), ktoré sú naopak ojedinelé a ich výskyt je zriedkavejší. Tieto parametre sa stali štúdiom mnohých vied a ich skúmanie sa javí do budúcnosti ako veľmi perspektívne. Či už vo vývoji technologickom, ako je napr. digitálny podpis, a najmä vo vývoji medicínskom. Konkrétne využitie štúdia písma v medicíne je napr. pri výskume neurologických ochorení ako je Parkinsonova nemoc, Alzheimerova nemoc, schizofrénia a iné. Písmo ako také nám však môže o človeku prezradiť oveľa viac. Odráža sa v ňom nálada danej osoby, aktuálny emočný stav, miera stresu, už spomínaný zdravotný stav a veľa ďalších faktorov.

Jednou z príčin zmeny písma, konkrétne ide o degradáciu kvality daného písomného prejavu a niekedy až k úplnej strate schopnosti písať, je napr. pôsobenie určitej neurologickej poruchy, alebo choroby, ako je napr. prekonanie mŕtvice. Je vedeckým faktom ([13], [26], [29]), že ľudia s istými neurologickými ochoreniami vykazujú rôzne vady písma. Práve toto zistenie viedlo k rapidnému nárastu záujmu o túto problematiku a následnému vývoju nových, tzv. neinvazívnych metód získavania poznatkov na základe spracovania a analýzy písma. Vďaka expanzívnemu vývinu nových technológií a rýchlemu pokroku na poli hardwaru je možné získavať poznatky

o písomnom prejave ľudí postihnutých neurologickými onemocneniami omnoho rýchlejšie a efektívnejšie. V dnešnej dobe sú vytvorené isté metódy a vyvíjajú sa štandardy pre získavanie a spracovanie týchto údajov. Ich podrobná analýza a následná klasifikácia, napr. pomocou umelých neurónových sietí, dokáže určiť jednotlivé poruchy písma. Týmto sa vytvára pole pre nové testy, ktoré by mohli napomáhať lekárom pri určovaní daných neurologických onemocnení. Pacient, u ktorého sa predpokladá určitá neurologická nemoc, by mohol byť najprv vystavený týmto testom. Získané dáta by mohli slúžiť lekárom ako ďalšia pomôcka pri rozhodovaní. Taktiež by sa dalo tieto metódy využiť ako preventívne cvičenia napr. pre ľudí po určitom veku, kedy sa predpokladá vyššia pravdepodobnosť výskytu neurologického onemocnenia. Ďalej by analýza ručne písaného prejavu mohla byť použitá napríklad ako indikátor pokroku pri použitej medicíne. Tieto tzv. neinvazívne metódy získavania poznatkov sú aj pre pacienta menej nepríjemné a najmä v počiatočných testoch nepôsobia na pacienta tak negatívne a odstrašujúco.

V práci je snaha o komplexnú analýzu ručne písaného prejavu pomocou viacerých metód. Jednotlivé metódy sú podrobne preštudované. Jedná sa o metódy spracovania písaného prejavu, metódy odvodené zo spracovania rečových signálov a metódy hodnotiace kvalitu a úroveň signálu. Tieto metódy spolu úzko súvisia. Ďalej je v práci snaha o implementáciu parametrov založených na teórii chaosu. V práci je snaha o kombináciu týchto parametrov za účelom najpresnejšej diagnózy Parkinsonovej nemoci. Získané parametre (príznaky) sú následne klasifikované pomocou viacerých klasifikátorov, ako sú napr. umelé neurónové siete, za účelom diagnostiky Parkinsonovej nemoci. V práci je rozobratá aj metóda automatickej dvojfázovej segmentácie písomného prejavu.

V prvej kapitole diplomovej práce sú rozobraté jednotlivé neurologické onemocnenia a ich dopad na ručne písaný prejav. Ďalej je v tejto kapitole popísaný spôsob získavania záznamov ručne písaného prejavu na základe písomno-kresliacich cvičení, podľa šablóny uvedenej v prílohe B. Druhá kapitola sa zaoberá analýzou ručne písaného prejavu. Popisuje jednotlivé cvičenia, segmentáciu záznamov a kvalitatívne hodnotenie ručne písaného prejavu. Tretia kapitola sa venuje metódam analýzy ručne písaného prejavu vo forme extrakcie príznakov (parametrov). Jedná sa o parametre hodnotiace ručne písaný prejav, parametre používané na analýzu rečového prejavu, parametre popisujúce kvalitu a intenzitu signálu a parametre založené na teórii chaosu. V štvrtej kapitole je rozobratá klasifikácia ručne písaného prejavu. Sú tu uvedené rôzne metódy klasifikácie, ako napr. algoritmus k najbližších susedov, umelé neurónové siete atď. V piatej kapitole je uvedený návrh systému automatickej detekcie Parkinsonovej nemoci. Posledná, šiesta kapitola sa zaoberá praktickou realizáciou navrhnutého systému, klasifikáciou výsledkov analýzy rečového prejavu. V tejto kapitole sú uvedené výsledky klasifikácie parametrov zvolenými klasifikátormi.

Výsledkom diplomovej práce je natrénovaný model automatickej detekcie Parkinsonovej nemoci na základe analýzy ručne písaného prejavu.

1 RUČNE PÍSANÝ PREJAV V OBLASTI NEUROLOGICKÝCH ONEMOCNENÍ

Písanie, tak ako rečový prejav, je nemimovoľná, kontrolovaná aktivita. Písmo vzniká koordinovaným pohybom prstov, zápästia a lakť'a ([15], [41]). Prsty ovplyvňujú vertikálny smer pohybu a tým do určitej miery aj tvar písma, napr. jeho výšku. Zápästie spolu so spodnou časťou ruky ovplyvňujú jeho horizontálne charakteristiky ([41]). Písmo ako už bolo spomínané je závislé na mnohých faktoroch. Bolo dokázané, že kvalita písma sa mení spolu s vekom človeka ([18]). Starší človek píše pomalšie, pretože písanie už u neho často nebýva automatizované a musí sa naň viac sústrediť. Väčšinou sa u neho prejavuje aj tzv. „roztrepánie“ písma a robí dlhšie prestávky pri písaní jednotlivých slov ([18], [24]). Ďalej je faktom, že ženy píšu inak než muži, a to bez rozdielu na vek ([2], [43], [44]). Bolo taktiež zistené, že dominantná ruka má na kvalitu písma minimálny vplyv. Naopak verbálna inteligencia, vzdelanie, prax v písaní a najmä už spomínaná prítomnosť neurologických onemocnení, majú na písmo ako také značný dopad ([24]).

1.1 Neurologické onemocnenia a ich prejav na ručne písaný prejav

Charakteristickou vlastnosťou ľudského pohybového aparátu je jeho schopnosť vykonávať motorické sekvencie hladko a nepretržite, teda bez páуз medzi jednotlivými po sebe nasledujúcimi prvkami danej motorickej činnosti (sekvencie). Posledné štúdie dokázali, že táto schopnosť bola umožnená vďaka kapacite motorického systému predvídať súčasti pohybových sekvencií a paralelne spracovávať jednotlivé úkony už počas vykonávania danej činnosti. Na rozdiel od zdravých ľudí majú však pacienti postihnutí určitým neurologickým onemocnením, ako je napr. Parkinsonova nemoc, značné problémy s vykonávaním sekvencií motorických činností, medzi ktoré patrí reč, písmo, koordinované pohyby ako je chôdza a mnohé iné. Takto postihnutí ľudia čiastočne strácajú schopnosť pohybového aparátu predpovedať nasledujúce úkony a paralelne ich spracovávať. Majú taktiež tendenciu vykonávať tieto sekvenčné pohyby po jednotlivých segmentoch. Váhanie a dlhšie pauzy medzi jednotlivými úkonmi, sprevádzané ďalšími príznakmi ako je napr. tremor (trasenie), mimovoľné šklbavé pohyby, výrazným spôsobom ovplyvňujú ručne písaný prejav týchto pacientov. Mnohé vedecké štúdie sa zaoberajú neurologickými onemocneniami a ich dopadom na ľudskú koordináciu, manipulačné schopnosti, hovorený prejav a taktiež ich vplyvom na ručne písaný prejav. Bolo dokázané, že analýzou písma je možné diagnostikovať choroby ako je napr. schizofrénia ([10], [11]) dystonia ([47]), Parkinsonova ([11], [41], [48]), či Alzheimerova nemoc ([25], [28], [50]), obsedantne kompulzívna choroba ([11]), tremor ([47]), mikrografia ([33]), demencia ([25]) a mnohé iné. Nižšie sú jednotlivé

neurologické onemocnenia uvedené znova, spolu s podrobným popisom a ich dôsledkami na analýzu ručne písaného prejavu.

1.1.1 Parkinsonova nemoc

Parkinsonova nemoc ([5], [13], [29]) je charakterizovaná ako závažné progresívne neurologické onemocnenie. Je to druhé najčastejšie neurodegeneratívne onemocnenie (neurodegeneratívne značí postupné poškodzovanie nervového tkaniva). Prejavuje sa najmä u ľudí staršieho veku (najviac u ľudí nad 60 rokov a vyššie). Vzniká v dôsledku úbytku tvorby dopamínu v mozgu (konkrétne ide o nedostatok dopamínu v tzv. bazálnych gangliách, ktoré sa podieľajú na riadení motoriky). Dopamín sa tvorí v mozgu, predovšetkým v tzv. strednom mozgu, v jadre zvanom „substantia nigra“ (čierne jadro). Je to chemická látka, ktorá prenáša vzruchy v mozgu, tzv. neurotransmitter. Neuróny v mozgu sú vybavené špeciálnymi receptormi, citlivými na výskyt špecifického neurotransmiteru (napr. dopamínu, adrenalínu, histamínu atď.). Absencia, alebo zmenšenie množstva dopamínu má za následok zhoršenie paralelného spracovania podnetov a motorických schopností pacientov, pretože dopamín má rozhodujúci vplyv na kognitívnu funkciu mozgu a prenos informácií medzi jednotlivými neurónmi. Aj u zdravého jedinca dochádza počas života k úbytku dopamínu. Nie však v takom množstve ako u človeka postihnutého Parkinsonovou nemocou. Dôvod odumierania buniek tvoriacich dopamín nie je zatiaľ známy. U pacientov diagnostikovaných na výskyt Parkinsonovej nemoci nie je pozorovaný dopad tohto onemocnenia na dĺžku života, výrazne však pôsobí na kvalitu života. Súčasná medicína nie je schopná Parkinsonovu nemoc úplne vyliečiť. Preto jej liečba spočíva hlavne v potlačení príznakov, ktorými sú napr. bolesti pohybového aparátu, spánkové problémy, degradácia rečového a písomného prejavu. Pre pacientov diagnostikovaných na Parkinsonovu nemoc sú charakteristické tieto vady písma, ktoré sú v diplomovej práci dôkladne preskúmané:

1. **Tremor** (trasenie) ([29], [47]) – ide o najznámejší a najcharakteristickejší prejav Parkinsonovej nemoci. Nedostatok dopamínu, ktorý by pôsobil tlmivo (teda ako inhibítor) a motorické schopnosti pacienta by neboli narušené, spôsobí práve viditeľne zvýšené trasenie končatín, napr. rúk. Tremor je rytmický mimovoľný oscilačný pohyb, ktorý je dobre pozorovateľný práve pri analýze ručne písaného prejavu a je v práci podrobne preštudovaný a otestovaný. V práci je skúmaný tremor pri písaní (tzv. kinetický tremor), ale je taktiež snaha o detekciu a následnú analýzu trasenia pri kľudovom stave (tzv. kľudový tremor), resp. vo fáze kedy pacient nepíše. Práve táto štúdia by mohla prispieť k zlepšeniu detekcie a diagnostiky Parkinsonovej nemoci a stať sa jedným z ukazovateľov vážnosti tohto onemocnenia.
2. **Rigidita** (svalová stuhnutosť) ([13], [29]) – je ďalším typickým príznakom nedostatku dopamínu v bazálnych gangliách. Svaly postihnutej oblasti (najčastejšie končatiny) sú aj v pokoji napnuté a kladú odpor pri akomkoľvek

pohybe. Pohyb pôsobí trhane, čo je dôsledkom trvalého zvýšenia pokojového svalového tonusu. Typickým príznakom rigidity býva u pacientov tendencia k neustálemu predkláňaniu (hrbeniu) sa. Pri analýze ručne písaného prejavu sa prejavuje neplynulým pohybom a zvýšeným tlakom na hrot pera, spôsobeným zhoršením jemnej motoriky prstov, zápästia a predlaktia.

3. **Mikrografia** (zmenšovanie písma) ([26], [29]) – je charakteristická tým, že keď ľudia postihnutí Parkinsonovou nemocou začnú písať, veľkosť písma je normálna. Postupne však píšu stále menším a menším písmom. Písmo týchto ľudí je tiež menej čitateľné. Je to dobre pozorovateľný príznak, ktorý je v práci podrobne preštudovaný a otestovaný.
4. **Bradykinéza** (spomalenie a zmenšenie rozsahu pohybov) ([5], [11], [48]) – je ďalším z prejavov typických pre Parkinsonovu nemoc. Prejavuje sa pri takmer všetkých pohybových aktivitách. Pacienti majú problém s vykonávaním bežných aktivít, reagujú spomalene a nie sú schopní vykonávať určité motorické aktivity v takom rozsahu ako zdraví ľudia. Typickým príznakom je minimálna mimika tváre, tzv. „maskovitý výraz“, monotónnosť rečového prejavu a taktiež obmedzená schopnosť písať. Písanie trvá pacientom dlhšiu dobu a pri vyššom štádiu Parkinsonovej nemoci dochádza k neustálemu zhoršovaniu čitateľnosti písma. V posledných štádiách tejto nemoci môže dôjsť až k úplnej strate schopnosti písať.
5. **Akinézia** (nepohyblivosť, resp. stav strnulej nehybnosti) ([42]) – ide o prejav Parkinsonovej nemoci vo vyvinutom štádiu. Pacient len s veľkým úsilím dokáže vykonávať rôzne pohyby. Stráca reflexívne pohyby. Akinézia výrazne ovplyvňuje udržiavanie rovnováhy a držanie tela pacientov. Toto postihnutie sa prejavuje, najčastejšie v oblasti končatín a krku, zvýšenou stuhnutosťou svalov. Písomný prejav takto postihnutých ľudí sa stáva značne nečitateľný. Pacienti v pokročilom štádiu akinézie postupne úplne strácajú schopnosť jemnej motoriky prstov a rúk, tým pádom aj schopnosť písať.

1.1.2 Alzheimerova nemoc

Alzheimerova nemoc ([8], [14]) je neurodegeneratívna porucha mozgu, pri ktorej dochádza k postupnému zániku mozgových buniek a tým k následnému ubúdaniu mozgovej hmoty. Alzheimerova nemoc postihuje najmä pacientov vyššieho veku (rovnako ako pri Parkinsonovej nemoci ide najviac o ľudí nad 60 rokov a vyššie). Alzheimerova nemoc vo vyvinutom štádiu vedie k postupnej demencii, v dôsledku práve spomínaného odumierania mozgových buniek. V súčasnej dobe sa odhaduje, že pacientov trpiacich touto chorobou je vo svete okolo 20 miliónov, pričom v Českej Republike je toto číslo približne 80 000. Presná príčina vzniku Alzheimerovej nemoci zatiaľ vedcom nie je známa. Taktiež neexistuje liek, ktorý by túto nemoc úplne vyliečil. Liečba spočíva v minimalizácii príznakov a k spomaleniu degenerácie mozgovej kôry pacientov. Zmeny v schopnosti písať môžu byť jedny z prvotných príznakov

Alzheimerovej nemoci. Pacienti, ktorí ňou trpia, majú problémy s písaním určitých slov a často si pletú slová, ktoré síce znejú podobne, ale majú rozličný význam, tzv. homonymá. Písanie ako také je komplexná aktivita zahŕňajúca viaceré fázy. Osoba, ktorá píše, musí zistiť čo chce vyjadriť, nájsť korešpondujúce slová a správnu gramatiku a až potom danú myšlienku fyzicky napísať. Tento sled činností je pre zdravého človeka normálny a bežný. Ľudia trpiaci Alzheimerovou nemocou však v dôsledku poškodenia mozgu postupne tieto aktivity vykonávajú so stále väčšou obtiažou. Pre pacientov diagnostikovaných na Alzheimerovu nemoc býva typické tvorenie jednoduchých viet. Pri písomnom prejave často ukončia vetu predčasne a rukopis sa stáva čím ďalej tým viac nečitateľným. Nemoc tiež poznamenáva pamäť a pre pacientov je často problémom vybaviť si správne výrazy a slová.

1.1.3 Schizofrénia

Schizofrénia (tzv. rozkolenosť mysle) ([10], [11], [17]) je závažné dlhodobé chronické neuropsychiatrické ochorenie. Jeho presná príčina nie je vedcom doposiaľ známa. Zhodujú sa však na tom, že je spôsobená vzájomným pôsobením viacerých faktorov. Medzi tieto faktory patria napr. isté genetické predpoklady, trauma (poškodenie) mozgu, v priebehu alebo krátko po pôrode a tiež dôsledky spoločenskej izolácie alebo nadmerného stresu. Schizofrénia ovplyvňuje schopnosť postihnutého človeka sústredene myslieť. Myšlienky sa mu mihajú, nedokáže udržať pozornosť a ľahko sa nechá vyrušiť. Pacienti diagnostikovaní na schizofréniu majú ťažkosti posúdiť a rozhodnúť, čo je a čo nie je v danej situácii dôležité. Nie sú schopní usporiadať svoje myšlienky do zmysluplných sekvencií. Ich myseľ sa stáva útržkovitou a dezorganizovanou. Častým prejavom tejto nemoci je taktiež tzv. „počutie hlasov“, halucinácie a bludné predstavy. Ďalším charakteristickým príznakom schizofrénie je tendencia pacientov odpútať sa od reálneho sveta a stiahnuť sa do seba. Tento jav sa nazýva autizmus. Vyjadrovacie schopnosti pacientov postihnutých týmto onemocnením sú taktiež poznamenané. Pacienti často opakujú už použité slová a výrazy, zvyknú vytvárať nové slová, v jednej vete vyjadrujú protichodné názory. Ich písanie je pomalšie ako u zdravého človeka aj keď nejde vyslovene o bradykinéziu. Pri ručne písanom prejave je pozorovateľná častá zmena tlaku na hrot pera a mierne prejavy mikrografie. Schizofrénia je závažná choroba, ktorá sprevádza pacienta dlhodobo. Sú dokonca prípady kedy pacienti potrebujú celoživotnú liečbu.

1.1.4 Dyskinézia

Dyskinezia (symptóm nekontrolovaných pohybov) ([48]) je neurologické onemocnenie, ktoré vedie k poruche pohybového aparátu. Často sa objavuje po dlhodobom alebo nadmernom užívaní neuroleptík (antipsychotík). Dyskinézia sa môže prejaviť rôzne. Od mierneho trasu rúk, grimás, tikov úst a jazyka, nadmerného žmurkania, až po nekontrolovateľné pohyby (najčastejšie hornej časti tela). Vo vyvinutejšom štádiu dyskinézie sa stávajú aj bežné úkony, ako napr. chôdza, pre

pacientov takmer nemožnými. Pacienti, u ktorých bola zistená dyskinézia, nie sú schopní písať čitateľne, práve kvôli mimovoľným pohybom a nadmernému traseniu rúk. V ručne písanom prejave ľudí postihnutých dyskinéziou, je teda rovnako, ako u tzv. „parkinsonikov“, prítomný značný tremor.

1.1.5 Huntingtonova nemoc

Huntingtonova nemoc ([1], [11], [16]) je vážne dedičné neurodegeneratívne ochorenie. Huntingtonova nemoc patrí medzi tzv. tripletové ochorenia. Tie vznikajú na základe zmenenej dedičnej informácie (tzv. mutácie). Toto ochorenie nie je smrteľné, no z pohľadu dnešnej medicíny je neliečiteľné. Liečba spočíva v podávaní neuroleptík a psychologickej liečbe, ktorá má uľaviť pacientom a minimalizovať dopad Huntingtonovej nemoci na ich život. Objavuje sa behom 30. až 50. roku života. Príznaky sa však môžu prejaviť aj skôr (do 20. roku). Vtedy je táto nemoc klasifikovaná ako juvenilná Huntingtonova nemoc. Tak ako Parkinsonova nemoc, Huntingtonova nemoc napáda časť mozgu nazývanú bazálne gangliá. Táto súvislosť vyúsťuje do spoločných príznakov oboch ochorení. Typickými príznakmi Huntingtonovej nemoci sú neovládateľné „šklbavé“ pohyby končatín, hlavy a trupu, depresia, postupná demencia, strata kognitívnych funkcií ako sú reč, vizuálna pamäť, poznávanie a používanie predmetov, schopnosť písomného prejavu a iné. Pacient nedokáže udržať určité stabilné postavenie rúk.

1.2 Získavanie dát pre analýzu ručne písaného prejavu


Pacienti, ktorí sa majú podrobiť neinvazívnemu testovaniu neurologickej činnosti na základe štúdie ručne písaného prejavu, sú najprv vyšetrení a následne zoznámení s jednotlivými cvičeniami. Samotný záznam prebieha pomocou digitálneho tabletu, viď Obr. 1.1.



Obr. 1.1: Tablet určený pre získavanie dát pre analýzu ručne písaného prejavu. Obrázok prebratý z ([46]).

Testovanie pomocou tohto tabletu má simulovať prirodzené podmienky pri písaní. To znamená, že pacient počas testovania nie je pripojený na žiadne prístroje. Je pohodlne usadený a pero k tabletu, tzv. stylus drží prirodzene v dominantnej ruke. To umožňuje aj zdravým pacientom písať zrozumiteľnejšie a viac priblížiť testovanie prirodzenému písaniu napr. na papier, ktoré je u zdravého človeka sprevádzané veľkou mierou automatizácie.

Elektronický stylus je zariadenie, ktoré pozostáva z viacerých senzorov a je vyrobené tak, aby sa písanie s ním čo možno najviac podobalo písaniu s obyčajným guľôčkovým perom. Tablet je počas testovania pripojený k mikropočítaču a zaznamenáva aktuálnu pozíciu pera vzhľadom na osy x-y, tlak na hrot pera, azimut (uhol natočenia pera vzhľadom na horizontálnu os tabletu, tj. natočenie a sklon písma, ktoré môže nadobúdať hodnôt od 0° - 359°) a tzv. „nadmorskú výšku“ (eleváciu), ktorá predstavuje vertikálnu polohu pera pri písaní (min = 0° , tj. pero je položené na písacej ploche, max. = 90° , tj. pero je držané kolmo na plochu tabletu), vid' Obr. 1.2.



Obr. 1.2: Zobrazenie Azimutu a „Nadmorskej výšky“ pera pri písaní.

Digitálny tablet teda dokáže zaznamenávať viacero rôznych signálov naraz. To je veľkou výhodou testovania neurologických onemocnení na základe analýzy ručne písaného prejavu. Napr. pri testovaní zvukových nahrávok (reči atď.) hrá veľkú úlohu odhlučnenie miestnosti, šum na pozadí a aj samotné testovanie je náročnejšie. Testovanie pomocou digitálneho tabletu je naopak jednoduché a taktiež pomocou jednej činnosti, ktorú pacient vykonáva, je možné zaznamenávať simultánne až 5 parametrov, popísaných vyššie. Takto získané dáta sú následne podrobené dôkladnej analýze za účelom extrakcie príznakov hodnotiacich písomný prejav na základe viacerých kritérií. V práci bude využívaná databáza získaná zo záznamov testovania ručne písaného prejavu pacientov pomocou digitálneho tabletu.

2 ANALÝZA RUČNE PÍSANÉHO PREJAVU

Mierne kognitívne poruchy, degradácia rečového či písomného prejavu môžu byť prechodnou etapou medzi normálnym stavom ľudského mozgu a prejavom neurologického onemocnenia. Štúdium ručne písaného prejavu je možné použiť ako indikátor neurologických onemocnení v prvotných štádiách vývinu, kedy iné metódy často nebývajú aplikované. Popríklad je možné analýzu písma využiť ako doplnujúci testovací prostriedok, ktorý nie je časovo náročný a dá sa vykonávať preventívne. Zhoršovanie poznávacích funkcií je taktiež prejavom starnutia mozgu a demencie. Je preto potrebné komplexné vyšetrenie a podrobná analýza ručne písaného prejavu, ktorá dokáže medzi jednotlivými poruchami, či naopak prirodzeným stavom starnutia presne rozhodovať, tj. klasifikovať tieto poruchy a ich závažnosť a priradiť ich jednotlivým stavom ľudského mozgu.


Z biomedicínskeho hľadiska majú písmo a ľudská reč mnoho spoločného. Je možné ich spracovávať ako jednorozmerné signály a ich použitie je v praxi často kombinované. Na písmo je teda možné aplikovať radu algoritmov digitálneho spracovania rečových signálov ako je napr. spektrálna analýza, analýza pomocou keprálnej transformácie, lineárna predikčná analýza a iné. Z dát získaných od pacientov je teda možné vypočítať príznaky charakterizujúce jednotlivé metódy. V práci je snaha o výpočet daných príznakov. Jedná sa o príznaky počítané z parametrov získaných pomocou digitálneho tabletu. V práci sú využívané parametre ako napr. tlak na hrot pera, frekvencia písania jednotlivých ťahov a mnohé iné. Z polohy pera pri písaní v určitom časovom okamžiku a celkovej doby písania je možné vypočítať rýchlosť písania ako prvú deriváciu polohy pera podľa času. Zrýchlenie ako parameter hodnotiaci počet zmien rýchlosti písania v čase, je počítané ako prvá derivácia rýchlosti podľa času. Koeficient šmyku, ktorý je dôležitým parametrom pri hodnotení plynulosti písomného prejavu je počítaný ako prvá derivácia zrýchlenia podľa času. Ďalej je v práci využitá celková doba trvania ťahu spolu s informáciou o polohe a pohybe pera pri stave, kedy pacient nepíše a stylus má nad plochou tabletu. V práci je snaha o zaradenie parametrov analyzujúcich rečový prejav do systému automatickej detekcie Parkinsonovej nemoci na základe analýzy ručne písaného prejavu. Spomínané metódy sú navyše kombinované s parametrami hodnotiacimi kvalitu a intenzitu signálu, ako je napr. krátkodobá energia signálu, počet prechodov signálu nulovou úrovňou atď. Ďalej je v práci snaha o začlenenie parametrov založených na teórii chaosu a ich aplikáciu pri diagnostike Parkinsonovej nemoci. Vypočítané príznaky sú následne klasifikované pomocou viacerých klasifikátorov (napr. umelých neurónových sietí, algoritmu SVM, atď.), za účelom identifikácie jednotlivých prejavov Parkinsonovej nemoci.

Vyšetrenie pomocou digitálneho tabletu prebieha formou písomných, resp. kresliacich cvičení. Ich cieľom je získať širokú škálu dát, ktoré môžu byť analyzované na prítomnosť motorických dysfunkcií indikujúcich prítomnosť neurologických onemocnení v skorších štádiách vývinu. Tieto cvičenia sú založené na systéme

neinvazívnej kvantifikácie motorických funkcií na základe kinematických a fyziologických znakov odvodených z ručne písaného prejavu. Výhodou získavania poznatkov pomocou digitálneho tabletu je bezpečnosť, rýchlosť, presnosť a najmä prenositeľnosť. Šablónu týchto cvičení, ktorá bola použitá pre získavanie dát pomocou digitálneho tabletu použitých v práci je možné nájsť v prílohe B. Jednotlivé cvičenia sú popísané v nasledujúcich podkapitolách.

2.1.1 Archimedova špirála

Archimedova špirála ([22], [47], [48]), je rovinná krivka, ktorá predstavuje trajektóriu bodov pohybujúcich sa na krivke určitou rýchlosťou v_1 podľa daného pravidla, zatiaľ čo priamka sa otáča okolo pevného bodu rýchlosťou v_2 . Archimedova špirála je definovaná takto: „ak sa priamka v rovine otáča rovnomernou rýchlosťou okolo počiatku, ktorý je nehybný a definovaný bod na priamke sa po nej pohybuje rovnakou rýchlosťou smerom od počiatku, opisuje tento bod Archimedovu špirálu“. Platí pre ňu teda, že rýchlosti v_1 a v_2 sa rovnajú. Na Obr. 2.1 je zobrazenie Archimedovej špirály zdravého človeka a pacienta, u ktorého je viditeľný tremor.



Obr. 2.1: Zobrazenie Archimedovej špirály ($f_{vz} = 200$ Hz): a) zdravého človeka; b) pacienta trpiaceho Parkinsonovou nemocou.

Krivka, ktorú vytvára Archimedova špirála je v polárnych súradniciach definovaná podľa vzťahu

$$\theta = k + ar_a^{n_a}, \quad (2.1)$$

kde a , n_a sú konštantné parametre a platí, že $a, n_a \in \mathbb{R}$. Parameter k určuje orientáciu špirály a n určuje rád špirály. V práci bude využitá špirála rádu $n_a = 1$. θ je uhol [rad], ktorý zvierá bod na špirále s počiatkom špirály a r_a je vzdialenosť tohto bodu od počiatku a je definovaná ako

$$r_a = \sqrt{(x - x_0)^2 + (y - y_0)^2}, \quad (2.2)$$

Premenné x , y sú tzv. súradnice, definované v kartézskom súradnicovom systéme. V tomto systéme je Archimedova špirála vyjadrená podľa vzťahov


$$x = a\theta \cos(\theta) + x_0, \quad (2.3)$$

$$y = a\theta \sin(\theta) + y_0, \quad (2.4)$$

kdex₀ a y_0 ; $x_0, y_0 \in \mathbb{R}$, vyjadrujú posunutie počiatku špirály v závislosti na počiatku súradného systému. Pri použití kartézskej súradnej sústavy je uhol θ možné vyjadriť ako

$$\theta = \tan^{-1} \left(\frac{y-y_0}{x-x_0} \right). \quad (2.5)$$

Archimedovu špirálu je možné rozvinúť v jednorozmerný signál ako závislosť polohy osi y na čase. Na Obr. 2.2 je možné vidieť porovnanie tejto závislosti pre zdravého človeka a pacienta trpiaceho neurologickým ochorením. Je viditeľné, že priebehy sa mierne líšia a vo vysokofrekvenčných zložkách sa v priebehu b) vyskytuje šum, ktorý je však z tohto grafu zle viditeľný. V práci je snaha o detekciu šumu, tj. tremoru v písomnom prejave pacientov trpiacich Parkinsonovou chorobou, ako aj iných doprovodných javov tohto neurologického ochorenia. Viac o jednotlivých metódach analyzujúcich Archimedovu špirálu, ako aj ostatné záznamy cvičení, viď kapitolu 3.




Obr. 2.2: Vyjadrenie bodov na osi y ako $y = f(t)$ Archimedovej špirály ($f_{vz} = 200$ Hz): a) zdravého človeka; b) pacienta trpiaceho Parkinsonovou chorobou.

Takto získaný priebeh je možné analyzovať pomocou viacerých kvalitatívnych parametrov ako sú napr. rýchlosť písania, čas písania, tlak na hrot pera, prítomnosť tremoru a iné. Pomocou týchto metód je možné detekovať prítomnosť tremoru, či nepodmieneným pohybom ruky spôsobeným neurologickým ochorením. Analýzu Archimedovej špirály je možné využiť k diagnóze dyskinézie, bradykinézie alebo rigidity, ako jedny z hlavných príznakov Parkinsonovej choroby.

2.1.2 Elipsa

Elipsa ([9], [20]), alebo tzv. „nuly“ je rovinná krivka, ktorá sa radí do triedy kužeľosečiek. Je možné ju definovať ako: „množinu všetkých bodov roviny majúcich od dvoch pevných bodov F_1, F_2 (F_1, F_2 sú tzv. ohniská elipsy) konštantný súčet vzdialeností $l_x + l_y$ “. Jedná sa o cvičenie, pri ktorom pacient kreslí tieto elipsy v rýchlom slede jednu na druhú. Tak ako Archimedovu špirálu bolo možné aj elipsu rozvinúť do jednorozmerného signálu ako závislosti bodov na osi y na čase. Zobrazenie cvičenia, pri ktorom sú kreslené elipsy je možné vidieť na Obr. 2.3.




Obr. 2.3: Zobrazenie priebehov záznamov cvičenia, pri ktorom sú kreslené elipsy ($f_{vz} = 200$ Hz): a) zobrazenie elíps písaných v rýchlom slede cez seba; b) vyjadrenie bodov daných elíps na osi y ako $y = f(t)$; c) zobrazenie elipsy kreslenej pacientom s miernou poruchou motorického aparátu; d) závislosť osi y danej elipsy na čase.

Tento obrázok zobrazuje elipsy písané v rýchlom slede cez seba a vyjadrenie tohto priebehu ako závislosť osi y na čase a jednu elipsu kreslenú pacientom s miernou poruchou motorického aparátu a taktiež jej vyjadrenie ako závislosť osi y na čase. Z obrázkov je možné vidieť, že frekvencia písania jednotlivých elíps sa podstatne líši,

čo môže byť príznakom bradykinézie, viac viď kapitolu 1.1.1, ako jedného z doprovodných príznakov Parkinsonovej nemoci.

2.1.3 Spojené a kurzívou písané písmená „l“

Ide o cvičenie, kedy pacient píše určitý počet (4 – 8) jednoduchých vzorov, v tomto prípade písmen „l“, spojených a písaných v rôznych rýchlostiach ([5], [10], [13], [40], [41]). Pomocou tohto cvičenia je možné sledovať dynamiku ťahu pri písaní a taktiež je toto cvičenie dobrým ukazovateľom mikrografie. Ďalej toto cvičenie indikuje dopad neurologickej poruchy na automatizáciu pohybov, ktoré zdravý človek vykonáva sekvenčne a často nepodmienené. Existuje štúdia, ktorá hovorí, že písanie, resp. normálny rukopis je vykonávaný pomocou motorickej pamäte a je automatizovaný. Automatizácia písomného prejavu je myslená tak, že zdravý človek pri písaní neuvažuje nad písaným znakom. Pohyby pri písaní nasledujú v rýchлом slede za sebou a zraková spätná väzba je až sekundárnym vnemom. Pre pacienta postihnutého napr. Parkinsonovou nemocou je písanie takýchto cvičení náročné. Pacienti potrebujú mať vizuálnu väzbu so svojim písomným prejavom a samotné písanie trvá dlhšiu dobu. Taktiež sa u nich prejavuje tremor, ktorý degraduje tvar písaných vzorov. Pre tieto vlastnosti je spomínané cvičenie využívané napr. na diagnózu Parkinsonovej nemoci. Záznam tohto cvičenia je možné vidieť na Obr. 2.4.




Obr. 2.4: Záznam cvičenia, pri ktorom sú písané písmená „l“, spojených a písaných v rôznych rýchlostiach ($f_{vz} = 200$ Hz): a) zobrazenie cvičenia písania jedného písmena ako závislosť osi y na osi x; b) závislosť osi y tohto priebehu na čase.

2.1.4 Písanie slabík, slov a viet

Ide o cvičenie, pri ktorom pacient píše buď slovo, slovné spojenie alebo vetu. Na dlhších úsekoch napr. viet je dobre pozorovateľná dynamika písania a najmä mikrografia ([26], [34], [42]). Pri tomto cvičení je navyše možné skúmať pohyb ruky na ploche tabletu, aj nad ňou, viď Obr. 2.5. To umožňuje pozorovať tzv. kľudový tremor

tzv. dominantnej ruky. Existujú totiž prípady, kedy sa aktívny tremor u pacienta trpiaceho určitým neurologickým onemocnením pri písaní neprejaví do takej miery ako kľudový tremor pri prechode medzi jednotlivými písmenami, resp. slovami, kedy má ruku nad úrovňou tabletu. V práci bude tomuto príznaku venovaná dôkladná analýza.



Obr. 2.5: Zobrazenie pohybu pera pri písaní na podložke a pohybe nad podložkou pri vykonávaní písomného cvičenia, pri ktorom pacienti píšú zadanú vetu .

2.1.5 Spájanie bodov

Pri tomto cvičení je pacientovi predložený vzor, na ktorom je sieť rôznych bodov. Tieto body má rýchlo spojiť rovnou čiarou. Toto cvičenie sa v praxi využíva pri diagnóze Alzheimerovej nemoci ([50]).

2.2 Automatická segmentácia písomného prejavu

Záznamy ručne písaného prejavu je pred samotnou analýzou za účelom extrakcie parametrov hodnotiacich ručne písaný prejav nutné v časovej oblasti rozdeliť na menšie časti, tzv. segmenty. V práci je použitá tzv. dvojfázová automatizovaná segmentácia, pozostávajúca z nasledovných krokov:

1. Jednotlivé záznamy sú v prvom kroku segmentované na ťahy. Ťah (stroke) je základným a najmenším merateľným prvkom ručne písaného prejavu. Ťahy sú charakterizované ako jednoduché plynulé pohyby pera zhora nadol a naopak (vertikálny pohyb) a pohyby pera zo strany na stranu (horizontálny pohyb). Sú oddeľované určením bodov, na ktorých sa mení rýchlosť písania (tj. vo výskyte lokálnych extrémov daného záznamu). Viac o konkrétnej realizácii segmentácii na ťahy v navrhnutom systéme detekcie Parkinsonovej nemoci na základe ručne písaného prejavu je možné sa dočítať v kapitole 6.1.2.

2. Po rozdelení záznamov na jednotlivé ťahy, sú tieto ťahy ďalej segmentované metódou váhovania signálu tzv. „okienkovou“ funkciou. Metóda váhovania spočíva v násobení časového priebehu signálu zvolenou váhovacou funkciou (postupnosťou). Tento typ segmentácie môže byť popísaný vzťahom


$$r_i[n] = s[n] \cdot w[n - im], \quad (2.6)$$

kde $r_i[n]$ je i -ty segment, m je krok segmentácie ($m \in \mathbb{N}$) a $w[n]$ je daná váhovacia funkcia. Násobeniu dvoch signálov v časovej oblasti odpovedá konvolúcia vo frekvenčnej oblasti. Spektrum segmentovaného signálu je teda rovné ([38])

$$Y(e^{j\omega}) = \frac{1}{2\pi} S(e^{j\omega}) * W(e^{j\omega}), \quad (2.7)$$

kde $S(e^{j\omega})$ je spektrum pôvodného signálu a $W(e^{j\omega})$ je spektrum váhovacej funkcie (tzv. „okna“). V práci je na segmentáciu použité Hammingove okno, vid' Obr. 2.6, definované ako ([32])

$$w[n] = 0,54 - 0,46 \cos\left(\frac{2\pi n}{N-1}\right). \quad (2.8)$$



Obr. 2.6: Zobrazenie Hammingovho okna ($N_{\text{FFT}} = 1024$): a) v časovej oblasti; b) vo frekvenčnej oblasti (modulové spektrum).

V práci sú v prvej fáze segmentácie jednotlivé ťahy oddeľované metódou určenia prechodu polohy stylusu. Konkrétne sa jedná o polohu, kedy sa stylus dotýka plochy tabletu, teda pacient aktívne píše konkrétny ťah a polohy nad plochou tabletu, kedy pacient začína písať nový ťah. Pre túto povahu ťahov sú v práci určité priebehy, ako je napr. Archimedova špirála alebo elipsa, ktoré sú písané v jedinom ťahu, v prvej fáze segmentácie, ponechané bez zmeny.

V druhej fáze segmentácie sú jednotlivé ťahy (konkrétne cvičenia realizované v jedinom ťahu, tj Archimedova špirála a elipsa) ďalej rozdelené na segmenty. Ostatné

cvičenia sú segmentované len na ťahy. Je tomu tak preto, lebo po rozdelení týchto cvičení na ťahy je ich dĺžka (počet vzoriek ťahu) príliš malý na to, aby mohli byť tieto ťahy ďalej segmentované. Viac o tomto procese, ako aj o procese segmentácie realizovanej v navrhnutom systéme, vid' kapitolu 6.1.2. Dĺžka segmentov je pre jednotlivé cvičenia určená automatizovane, a to tak, aby v rámci jedného segmentu bola vždy obsiahnutá minimálne jedna perióda segmentovaného signálu. Podrobnosti ohľadom zisťovania periódy skúmaného záznamu, vid' kapitolu 6.2, konkrétne realizáciu výpočtu periódy navrhnutou funkciou, využívajúcou autokorelačnú metódu odhadu základnej frekvencie vstupného signálu.

2.3 Kvalitatívne hodnotenie ručne písaného prejavu

Kvalita a automatizovanosť ručne písaného prejavu sú v diplomovej práci skúmané z viacerých hľadísk. Analýza záznamov jednotlivých cvičení pozostáva z výpočtu parametrov s využitím viacerých metód, podrobne popísaných v kapitole 6.2. V práci je snaha o kombináciu týchto metód za účelom komplexnej analýzy ručne písaného prejavu a následnej klasifikácie výsledkov, v zmysle detekcie prítomnosti neurologického onemocnenia. V práci sú použité parametre vybrané z nasledujúcich metód:

1. **Metódy hodnotiace ručne písaný prejav** – Sú to metódy počítajúce parametre, ktorých výpočet nie je časovo náročný a využívajú v plnom rozsahu dáta získané z digitálneho tabletu. Jednotlivé parametre sú podrobne popísané v kapitole 3.1. V práci sú použité parametre, vybrané z nasledujúcej množiny parametrov:
 - a. Počet ťahov za sekundu (SF = stroke frequency).
 - b. Celková doba písania (MT = movement time).
 - c. Výška ťahu (SS = stroke size).
 - d. Dĺžka ťahu (SL = stroke length).
 - e. Dĺžka trvania ťahu (SD = stroke duration).
 - f. Tlak na hrot pera (WP = writing pressure).
 - g. Rýchlosť písania (WV = writing velocity).
 - h. Počet zmien rýchlosti písania (NCV = number of changes in direction of writing velocity).
 - i. Akcelerácia písania (WA = writing acceleration).
 - j. Počet zmien akcelerácie (NCA = number of changes in direction of writing acceleration).
 - k. Koeficient šmyku (WJ = writing jerk).
2. **Metódy používané pri analýze rečového prejavu** – Analýza rečového prejavu je tak ako analýza ručne písaného prejavu používaná na diagnózu neurologických onemocnení. Nie všetky parametre používané pre analýzu rečového signálu sa dajú použiť aj na písmo. Sú však také, ktoré v práci budú otestované a bude snaha o ich začlenenie do analýzy ručne písaného prejavu,

v kombinácii s parametrami hodnotiacimi ručne písaný prejav ako taký. Tieto parametre využívajú analýzu signálu vo frekvenčnej oblasti, kepstrálnu analýzu, výkonovú spektrálnu hustotu a iné metódy spracovania rečových signálov. Konkrétny popis spomínaných parametrov je uvedený v kapitole 3.2. V práci budú použité parametre z nasledovnej množiny parametrov:

- a. Spektrogram.
- b. Základná frekvencia signálu (F_0).
- c. Kolísanie základnej frekvencie signálu ($J = \text{jitter}$).
- d. Medián výkonovej spektrálnej hustoty (MPSD = median of power spectral density).
- e. Lineárna predikčná analýza (LPC = linear predictive analysis).
- f. Spektrálny tok (SPECF = spectral flux).
- g. Reálne kepstrum.

3. **Metódy hodnotiace kvalitu a intenzitu signálu** – Jedná sa o metódy, ktoré hodnotia úroveň šumu v signále, harmonicitu atď. V práci je snaha o ich využitie pri detekcii tremoru ako jedného z hlavných príznakov Parkinsonovej nemoci. Podrobný popis týchto parametrov je uvedený v kapitole 3.3. Ako zástupcovia tejto skupiny parametrov (metódy) sú v práci použité parametre vybrané z nasledujúcej množiny parametrov:

- a. Krátkodobá energia (STE = short-time energy).
- b. Krátkodobá intenzita (STI = short-time intensity).
- c. Krátkodobá stredná hodnota prechodov signálu nulovou úrovňou (ZCR = zero-crossing rate).
- d. Krátkodobá autokorelačná funkcia (STAF = short-time autocorrelation function).
- e. Harmonicita signálu (HNR = harmonic-to-noise ratio).

4. **Metódy založené na teórii chaosu** – Sú to metódy hodnotiace náhodnosť signálu. Ručne písaný prejav je z časti deterministický proces. Preto sú parametre počítané pomocou týchto metód dobrým indikátorom hladiny šumu v signále, teda tremoru, ktorý sa prejaví ako zvýšená hladina chaotickosti daného priebehu. Napr. ak je Archimedova špirála rozložená ako závislosť $y = f(t)$, vid' Obr. 2.2, je zrejme, že ide o kvázi-periodický priebeh a jeho náhodnosť by mala byť minimálna. Ak však toto cvičenie vykonáva pacient trpiaci neurologickým onemocnením prejavujúcim sa určitými motorickými dysfunkciami, je možné tieto vady detegovať ako zvýšenú hladinu náhodnosti záznamu konkrétneho cvičenia. Viac o týchto metódach je možné nájsť v kapitole 3.4. V práci sú použité parametre vybrané z nasledujúcej množiny parametrov:

- a. Fraktálna dimenzia (FD = fractal dimension).
- b. Najväčší Laypunovov exponent (LLE = largest Laypunov exponent).
- c. Korelačná dimenzia (CD = correlation dimension).

3 METÓDY ANALÝZY RUČNE PÍSANÉHO PREJAVU

3.1 Parametre hodnotiace ručne písaný prejav

Parametre počítané pomocou týchto metód sú založené na skúmaní pohybu prstov, zápästia a lakťa dominantnej ruky pri písaní. Odzrkadľuje sa v nich napr. dynamika pohybov, plynulosť a automatizovanosť písania. Tieto parametre teda popisujú motorické vlastnosti pacientov a sú dobrým ukazovateľom tzv. motorických dysfunkcií, ktoré sú jedným z prvotných ukazovateľov neurologických onemocnení. Konkrétne parametre použité v diplomovej práci sú vybrané z množiny parametrov popísanej v nasledujúcich podkapitolách.

3.1.1 Počet ťahov za sekundu

Tento parameter vyjadruje počet jednotlivých ťahov za jednotku času (sekundu). Pomocou frekvencie písania sa dá určiť rýchlosť písania ([15], [33], [34]). Rýchlosť písania ručne písaného prejavu je v práci použitá pri detekcii bradykinézie, ktorá sa vyznačuje tým, že pacienti trpiaci Parkinsonovou nemocou vykazujú spomalené pohyby motorického aparátu, písanie jednotlivých ťahov je u týchto pacientov pomalšie ako u zdravých ľudí. Spomínaná motorická dysfunkcia je spravidla doprevádzaná ďalšími charakteristickými črtami, typickými pre Parkinsonovu nemoc, ako sú napr. časté prestávky medzi jednotlivými ťahmi, trasenie (tremor), doprevádzaný mikrografiou a zvýšeným tlakom na hrot pera.

Tento parameter je v práci testovaný na záznamoch z cvičení, pri ktorých má zmysel uvažovať jednotlivé ťahy. Jedná sa teda o cvičenia 3 – 9, kedy pacienti píšú slovo, slovné spojenie alebo vetu, vid' Obr. 2.5. V tabuľke, vid' Tab. 3.1, je zobrazenie štatistických parametrov počtu ťahov za sekundu, ako aj celkového počtu ťahov vykonaných pre zvolené písomno-kresliace cvičenie. V tabuľke sú uvedené hodnoty pre všetky záznamy cvičenia číslo 9, tj. písania vety podľa predlohy. Z tabuľky je možné vidieť, že frekvencia písania jednotlivých ťahov (jej stredná hodnota) je pre pacientov trpiacich Parkinsonovou nemocou vyššia ako u zdravých ľudí. Taktiež je u týchto pacientov pozorovaný celkový väčší počet ťahov potrebný na zvládnutie daného cvičenia. Toto zistenie odpovedá predpokladu, že pacienti na rozdiel od zdravých ľudí majú poškodenú jemnú motoriku prstov a zápästia, preto pri písaní predloženej vety potrebujú na jej zvládnutie viacero ťahov. Signifikantný rozdiel je aj v parametri určujúcom rozptyl týchto parametrov, kde napr. pre celkový počet ťahov v spomínanom cvičení, je rozptyl počtu ťahov pre pacientov s Parkinsonovou nemocou až štvornásobne vyšší ako pre zdravých ľudí. Viac informácií o konkrétnej realizácii tohto parametra, vid' kapitolu 6.2.1.

Tab. 3.1: Zobrazenie štatistických parametrov počtu ťahov za jednotku času [s] a celkového počtu ťahov v danom cvičení pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané z cvičenia číslo 9, tj. písania vety podľa predlohy.

Parametre	PD ¹ [S_F ²]	PD [S_N ³]	H ⁴ [S_F]	H [S_N]
Stredná hodnota	7,1374	19,0001	5,1899	16,0001
Rozptyl (var.)	36,5414	97,0001	6,9723	25,0001
Smerod. odchylka	6,0451	10,0001	2,6405	5,0001
Min. hodnota	1,8864	10,0001	2,2679	9,0001
Max. hodnota	29,2582	51,0001	14,9335	26,0001
Medián	4,9313	17,0001	4,5361	15,0001
*Hodnoty S_F a S_N sú zaokrúhlené na vyššie celé číslo + 0,0001				

3.1.2 Celková doba písania

Jedná sa o celkový čas písania konkrétneho cvičenia, počínajúc prvým a končiac posledným ťahom. Tento parameter je taktiež použitý na detekciu bradykinézie, resp. Parkinsonovej nemoci ([3], [5], [15], [50]). V tabuľke, vid' Tab. 3.2 sú zobrazené štatistické ukazovatele celkovej doby písania pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí..

Tab. 3.2: Zobrazenie štatistických parametrov celkovej doby písania [s] pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané z cvičenia číslo 9, tj. písania vety podľa predlohy.

Parametre	PD	H
Stredná hodnota	21,4534	15,5539
Rozptyl (var.)	569,7891	38,6955
Smerod. odchylka	23,8703	6,2206
Min. hodnota	6,1701	8,2151
Max. hodnota	149,7451	38,3801
Medián	16,4025	13,8875

Z tabuľky je vidno, že celková doba písania u pacientov s Parkinsonovou nemocou je väčšia, čo je znakom prítomnosti Bradykinézie. Tieto parametre sú dobrými ukazovateľmi motorickej dysfunkcie pohybového aparátu. Z tabuľky je ďalej vidno, že pacienti diagnostikovaní na výskyt Parkinsonovej nemoci na rozdiel od zdravých ľudí

¹ PD = tzv. „Parkinson's disease“, tj. pacient diagnostikovaný na Parkinsonovu nemoc

² S_F = tzv. „stroke frequency“, tj. počet ťahov za sekundu

³ S_N = tzv. „number of strokes“, tj. celkový počet ťahov (pre zvolené cvičenie)

⁴ H = tzv. „Healthy“, tj. zdravý človek

vykazujú omnoho väčší rozptyl celkovej doby písania, ako aj podstatný rozdiel v maximálnej a minimálnej dobe, ktorú potrebujú na zvládnutie zadaného písomno-kresliaceho cvičenia. Celková doba písania je v práci počítaná pre všetky cvičenia. Viac o konkrétnej realizácii (výpočte) tohto parametra, viď kapitolu 6.2.1

3.1.3 Výška ťahu

Ide o parameter vyjadrujúci vertikálnu amplitúdu ťahu. U pacientov postihnutých neurologickým onemocnením sa vyskytuje zvýšená variabilita výšky ťahu, konkrétne sa jedná o zmenšovanie výšky ťahu ([5], [11], [13], [34]), tzv. mikrografia. Presná príčina zmenšovania výšky ťahu nie je presne známa. Podľa rôznych vedeckých článkov môže byť spôsobená jednak tým, že písanie dlhších slovných spojení má väčšie požiadavky na súbežné spracovanie informácií a zahŕňa dlhodobejšiu koordináciu prstov, zápästia a lakťa, čo pre pacientov trpiacich neurologickým onemocnením býva problémom. Ďalej sa vedci domnievajú, že určitý vplyv na zmenšovanie výšky ťahu má aj pozícia pacientovej ruky. Táto úvaha vychádza z toho, že ako človek píše dominantnou rukou, tak postupne posúva ruku v smere písania, čo zvyšuje extenziu v zápästnom a lakt'ovom kĺbe a zvyšuje tuhosť držania pera. Keďže pacienti trpiaci neurologickou poruchou majú často problémy s pohybovým aparátom a menšiu jemnú motoriku prstov a zápasia, tieto faktory sú pre nich závažnejšie ako pre zdravých ľudí. Z týchto faktov bolo experimentálne zistené, že zmenšenie výšky ťahu sa u pacientov prejavuje so zvyšujúcimi sa nárokmi na súbežné spracovanie textu (dlhších vzorov, či slovných spojení).

Tento príznak je teda dobrým ukazovateľom mikrografie, ako jedného z hlavných vedľajších príznakov Parkinsonovej nemoci. V diplomovej práci je výška ťahu počítaná pre cvičenia, pri ktorých má zmysel diferencovať jednotlivé ťahy, tj. cvičenia 3 – 9. Tabuľka, viď Tab. 3.3, zobrazuje testovanie výšky ťahu pre pacientov trpiacich Parkinsonovou nemocou a zdravých ľudí pre ťahy vykonané na povrchu digitálneho tabletu (tzv. stav [ON]), ako aj pre ťahy vykonávané pri prechode na nový ťah (tzv. stav [OFF]). Z tabuľky je vidno, že stredná hodnota výšky ťahu, medián a taktiež maximálna výška ťahu je u pacientov PD poznateľne nižšia, čo potvrdzuje predpoklad výskytu mikrografie, a to aj pri pohyboch nad povrchom tabletu.

V kombinácii s dátami uvedenými v tabuľkách Tab. 3.1 a Tab. 3.2, je možné pozorovať, že pacienti trpiaci Parkinsonovou nemocou vykonávajú písomné cvičenie pomalšie, tj. celková doba písania je v porovnaní so zdravými ľuďmi dlhšia. Taktiež vykonávajú tieto ťahy pomalšie, na dané cvičenie je ich viac (potrebujú viacero páuz, tj. prechodov na nový ťah) a z tabuľky Tab. 3.3 je možné k týmto zisteniam priradiť ďalší charakteristický črt motorickej dysfunkcie spôsobenej neurologickým onemocnením, mikrografiu. Všetky tieto zistenia odpovedajú predpokladom a ukazujú, že do budúcnosti majú tieto cvičenia potenciál pre zaradenie do systému diagnostiky Parkinsonovej nemoci na základe analýzy ručne písaného prejavu. Tieto parametre sú taktiež súčasťou systému navrhnutého v diplomovej práci. Viac o navrhnutom systéme, viď kapitolu 5.

Konkrétny popis realizácie výpočtu výšky ťahu v tomto systéme, vid' kapitolu 6.2.1.

Tab. 3.3: Zobrazenie štatistických parametrov výšky ťahu pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané z cvičenia číslo 9, tj. písania vety podľa predlohy.

Parametre	PD [ON ⁵]	PD [OFF ⁶]	H [ON]	H [OFF]
Stredná hodnota	110,1378	131,4079	123,5091	161,2083
Rozptyl (var.)	0,8448	0,9812	0,8822	1,6642
Smerod. odchylka	29,0661	44,5107	29,7027	40,7947
Min. hodnota	44,9804	45,5882	68,1251	74,2511
Max. hodnota	153,3001	244,5455	193,1001	276,1667
Medián	111,1251	133,0729	117,4152	154,7937
*Za výšku ťahu je v testovaní uvažovaná y-ová súradnica daného ťahu				

3.1.4 Dĺžka ťahu

Tento parameter popisuje dĺžku jednotlivých ťahov. V práci je tak ako výška ťahu použitý na detekciu mikrografie, kedy sa dĺžka ťahu s časom zmenšuje, resp. makrografie, kedy sa dĺžka ťahu s časom naopak zväčšuje ([10], [11], [33]). V tabuľke, vid' Tab. 3.4 je, tak ako pre parameter výška ťahu, zobrazená závislosť dĺžky ťahu pre pacientov trpiacich Parkinsonovou nemocou a zdravých ľudí pre ťahy vykonané na povrchu digitálneho tabletu (tzv. stav [ON]), ako aj pre ťahy vykonávané pri prechode na nový ťah (tzv. stav [OFF]).

Tab. 3.4: Zobrazenie štatistických parametrov dĺžky ťahu pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané z cvičenia číslo 9, tj. písania vety podľa predlohy.

Parametre	PD [ON]	PD [OFF]	H [ON]	H [OFF]
Stredná hodnota	0,0203	0,0192	0,0241	0,0227
Rozptyl (var.)	2,1150	2,2633	1,8115	1,2627
Smerod. odchylka	0,0046	0,0048	0,0043	0,0036
Min. hodnota	0,0114	0,0107	0,0159	0,0158
Max. hodnota	0,0309	0,0291	0,0360	0,0309
Medián	0,0201	0,0183	0,0228	0,0225
*Všetky hodnoty sú normalizované hodnotou $1 \cdot 10^5$				

⁵ ON = stav vykonávania písomno-kresliaceho cvičenia, kedy má pacient pero na povrchu tabletu, tj. vykonáva ťah (aktívna plocha ťahu).

⁶ OFF = stav vykonávania písomno-kresliaceho cvičenia, kedy má pacient pero nad povrchom tabletu, tj. prechádza na nový ťah (pasívna plocha ťahu)

Štatistické parametre vypočítané z dát dĺžky ťahu nedávajú tak dobré výsledky ako dáta o výške ťahu, je tu však pozorovateľný rozdiel variácie dĺžky ťahu pacientov PD a zdravých ľudí, najmä pri pohybe nad povrchom tabletu t.j. pri prechode na nový ťah, ktorá odpovedá predpokladu zvýšenej hladiny tremoru pri kľudovom stave písomného prejavu. Konkrétna realizácia výpočtu dĺžky ťahu je podrobne popísaná v kapitole 6.2.1.

3.1.5 Dĺžka trvania ťahu

Jedná sa o ďalší parameter popisujúci jednotlivé ťahy vykonané pri písaní. Tento parameter je v práci spolu s celkovou dobou písania a počtom ťahov za sekundu využitý pri detekcii bradykinézie ([5], [11], [39]).

V tabuľke Tab. 3.5 sú zobrazené štatistické parametre vypočítané pre dĺžky trvania ťahov jednak pre pacientov trpiacich Parkinsonovou nemocou, ako pre zdravých ľudí a to pre záznamy na povrchu ako nad povrchom digitálneho tabletu. Z tabuľky je vidno, že pacienti s Parkinsonovou nemocou píše jednotlivé ťahy cvičenia (v tabuľke sa nachádzajú dáta vypočítané pre cvičenie číslo 9) dlhšie ako zdraví ľudia, čo spolu s parametrom popísaným v kapitole 3.1.2 odpovedá prítomnosti Bradykinézie v ručne písanom prejave týchto pacientov.


Tab. 3.5: Zobrazenie štatistických parametrov dĺžky trvania ťahu [s] pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané z cvičenia číslo 9, t.j. písania vety podľa predlohy.

Parametre	PD [ON]	PD [OFF]	H [ON]	H [OFF]
Stredná hodnota	0,7042	0,4141	0,6672	0,3473
Rozptyl (var.)	0,1031	0,1287	0,0869	0,0157
Smerod. odchylka	0,3210	0,3588	0,2949	0,1251
Min. hodnota	0,2165	0,1082	0,2435	0,1655
Max. hodnota	1,5333	2,2119	1,3815	0,7039
Medián	0,6398	0,3315	0,6045	0,3271
*dĺžka trvania ťahu je počítaná ako počet vzorkov daného ťahu, podelený vzorkovacou frekvenciou, kde $f_{vz} = 200\text{Hz}$.				

3.1.6 Tlak na hrot pera

Popisuje vertikálny tlak stylusu na plochu tabletu. Tlak na hrot pera je dôležitým parametrom pri určovaní jednak povahových vlastností jedincov a taktiež porúch písania ([15], [24], [33], [44]). U Pacienta, u ktorého je zaznamenaný zvýšený tlak na povrch tabletu počas testovania, je vyššia pravdepodobnosť výskytu určitej poruchy, buď motorického aparátu (napr. písárska kľč), alebo sa tento jav môže v kombinácii s inou dysfunkciou písomného prejavu prejaviť ako prvotný indikátor výskytu

neurologického ochorenia. Na obrázku, vid' Obr. 3.1, je vidno priebehy tlaku na hrot pera pre všetky typy cvičení. V práci je tento parameter použitý pri detekciu rigidity, ktorá je významným doprovodným príznakom Parkinsonovej nemoci.



Obr. 3.1: Zobrazenie tlaku hrotu stylusu na povrch tabletu pri vykonávaní písomno-kreslaciach cvičení (modrý priebeh = H, červený priebeh = PD): a) priebeh Archimedovej špirály; b) priebeh elipsy; c) priebeh slova „les“; d) priebeh vety podľa predlohy.

V tabuľke, vid' Tab. 3.6, sú zobrazené štatistické parametre vypočítané pre všetky písomno-kresliace cvičenia, rozdelené do štyroch skupín. Tabuľka obsahuje vypočítané hodnoty pre pacientov trpiacich Parkinsonovou nemocou, ako aj zdravých ľudí. Vo všeobecnosti je z výsledkov možné tvrdiť, že pacienti práve kvôli motorickým dysfunkciám a celkovému poškodeniu motorického aparátu vykazujú zvýšený tlak na hrot pera, odpovedajúci výskytu rigidity. V kombinácii s parametrom popísaným v kapitole 3.1.3, ktorého testovaním sa v práci overila prítomnosť mikrografie, je možné tvrdiť, že pacienti diagnostikovaní na výskyt Parkinsonovej nemoci sa pri vykonávaní písomného cvičenia (napr. vety podľa predlohy, viac vid' kapitolu 2.1.4) v dôsledku menšej motoriky pohybového aparátu dominantnej ruky snažia kompenzovať menšiu citlivosť a stabilitu písomného prejavu práve zvýšeným tlakom na hrot pera v kombinácii so zmenšovaním výšky ťahu, tj. mikrografiou. Viac o tomto parametre, jeho zaradení do systému automatizovanej detekcie Parkinsonovej nemoci na základe analýzy ručne písaného prejavu a jeho konkrétnej realizácii, vid' kapitolu 6.2.1.

Tab. 3.6: Zobrazenie štatistických parametrov tlaku na hrot pera pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané zo všetkých písomno-kresliacich cvičení.

Cvičenia	cv. 1		cv. 2		cv. 3 - 8		cv. 9	
Parametre	PD	H	PD	H	PD	H	PD	H
Stred. hodnota	0,0257	0,0237	0,0304	0,0311	0,0307	0,0301	0,0304	0,0298
Rozptyl (var.)	6,9517	7,5418	3,6047	2,0972	1,6449	2,2397	1,8999	2,3123
Smer. odchyl.	0,0083	0,0087	0,0061	0,0046	0,0041	0,0047	0,0044	0,0048
Min. hodnota	0,0071	0,0067	0,0031	0,0112	0,0131	0,0091	0,0135	0,0095
Max. hodnota	0,0341	0,0332	0,0355	0,0347	0,0346	0,0331	0,0335	0,0325
Medián	0,0306	0,0263	0,0322	0,0321	0,0315	0,0313	0,0311	0,0309
* Všetky hodnoty sú normalizované hodnotou $1 \cdot 10^5$								

3.1.7 Rýchlosť písania

Jedná sa o prvú deriváciu dĺžky ťahu podľa času ([6], [9], [21], [24]). Tento parameter úzko súvisí s parametrom popísaným v kapitole 3.1.1. V diplomovej práci je aplikovaný na záznamy cvičení kreslenia Archimedovej špirály, elipsy a písaní slov, slovných spojení a viet. Pomocou detekcie rýchlosti písania jednotlivých ťahov je možné detekovať bradykinéziu. V tabuľke Tab. 3.7 sú zobrazené štatistické parametre pre všetky cvičenia, rozdelené v pomere rovnakom ako v Tab. 3.6.

Tab. 3.7: Zobrazenie štatistických parametrov rýchlosti písania pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané zo všetkých písomno-kresliacich cvičení.

Cvičenia	cv. 1		cv. 2		cv. 3 - 8		cv. 9	
Parametre	PD	H	PD	H	PD	H	PD	H
Stred. Hod.	16,7419	19,1219	7,5091	8,7541	0,0157	0,0096	0,3407	0,4233
Rozptyl	92,8885	69,8361	31,5671	21,5175	7,3425	2,6255	0,0299	0,0281
Smer. odch.	9,6379	8,3568	5,6185	4,6387	0,0857	0,0512	0,1728	0,1674
Min. hod.	4,7651	7,3231	2,8271	3,2322	0,0002	0,0003	0,1261	0,1774
Max. hod.	44,0632	43,0531	36,1301	28,1812	0,9413	0,9221	0,7881	0,8293
Medián	14,1921	17,2621	5,7884	7,1608	0,0051	0,0052	0,2921	0,3939
* Hodnoty cvičenia 3 – 8 sú normalizované hodnotou $1 \cdot 10^3$								

Z tabuľky je možné vidieť, že pacienti trpiaci Parkinsonovou nemocou pri vykonávaní jednotlivých cvičení vykazujú menšiu rýchlosť písania ťahov v porovnaní so zdravými ľuďmi, čo je príznakom Bradykinézie, popísanej v kapitole 1.1.1.

3.1.8 Počet zmien rýchlosti písania

Popisuje mieru automatizácie písania, tj. ako veľmi je písanie kontrolované. Toto je dôležitý faktor u mnohých neurologických onemocnení. Pacient, ktorý trpí napr. Parkinsonovou nemocou nie je schopný písať plno-automatizovane ako zdravý človek. Prejaví sa to zvýšeným počtom zmien rýchlosti v jednotlivých ťahoch, ako počet lokálnych extrémov funkcie závislosti rýchlosti písania týchto ťahov na čase ([9], [15], [24], [41]). Tento parameter do systému diagnostiky Parkinsonovej nemoci na základe analýzy ručne písaného prejavu nie je.

3.1.9 Akcelerácia

Tento parameter vyjadruje prvú deriváciu rýchlosti písania podľa času, resp. druhú deriváciu dĺžky ťahu podľa času ([11], [13], [24], [34], [41]). Na rozdiel od rýchlosti písania tento parameter neudáva ako rýchlo pacient píše, čiže ho nie je možné použiť na detekciu bradykinézie. Udáva však ako veľmi je písomný prejav premenlivý, resp. ako často sa mení rýchlosť písania. V tabuľke Tab. 3.8 sú uvedené výsledky štatistického zhodnotenia akcelerácie písania pre všetky cvičenia pacientov trpiacich Parkinsonovou nemocou a zdravých ľudí.

Z tabuľky je vidno, že tak ako rýchlosť písania, tak aj akcelerácia je poznamenaná bradykinéziou. Na tomto parametre je však markantný rozdiel vo variácii zrýchlenia písomného prejavu pacientov s Parkinsonovou nemocou, kedy variácia zrýchlenia napr. pre cvičenie, pri ktorom pacienti kreslia elipsy v rýchlom slede cez seba, je dvojnásobná. Variácia zrýchlenia môže byť taktiež príznakom zvýšenej hladiny tremoru pri aktívnej fáze vykonávania ťahu. Testovanie ukázalo, že tento parameter, spolu s rýchlosťou písania je dobrým ukazovateľom bradykinézie, ako jedného z hlavných príznakov Parkinsonovej nemoci.

Tab. 3.8: Zobrazenie štatistických parametrov akcelerácie (zrýchlenia) písania pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané zo všetkých písomno-kresliacich cvičení.

Cvičenia	cv. 1		cv. 2		cv. 3 - 8		cv. 9	
Parametre	PD	H	PD	H	PD	H	PD	H
Stred. Hod.	10,8851	12,6063	4,6899	5,3953	0,0131	0,0067	0,1691	0,2094
Rozptyl	49,3202	34,7097	16,5964	8,6095	7,3528	2,6192	0,0083	0,0072
Smer. odch.	7,0228	5,8915	4,0739	2,9342	0,0857	0,0512	0,0909	0,0848
Min. hod.	2,5588	4,6144	1,5947	1,9477	0,0001	0,0001	0,0609	0,0849
Max. hod.	30,0804	29,6389	31,1055	17,1959	0,9396	0,9214	0,4073	0,4263
Medián	8,2955	11,4286	3,4954	4,4683	0,0028	0,0027	0,1398	0,1883
* Hodnoty cvičenia 3 – 8 sú normalizované hodnotou $1 \cdot 10^3$								

3.1.10 Stredný počet zmien akcelerácie

Tak ako NCV, sa aj NCA používa na kvantifikáciu automatizácie písania. Je vyjadrený ako stredný počet lokálnych extrémov funkcie závislosti zrýchlenia písania jednotlivých ťahov na čase ([9], [15], [24], [41]). U zdravého človeka sa predpokladá približne konštantná rýchlosť písania. Ak tento parameter nadobúda vysoké hodnoty, je pravdepodobné, že pacient trpí poruchou písania. Tento parameter, tak ako NCV nie je v diplomovej práci zaradený do navrhnutého systému.

3.1.11 Koeficient šmyku

Koeficient šmyku je parameter, ktorý je počítaný ako tretia derivácia dĺžky ťahu podľa jednotky času [s]. Pomocou tohto parametra sa popisuje plynulosť pohybu pera pri písaní a koordinácia pohybového aparátu. Vo vedeckých článkoch bol tento príznak spomínaný v spojení s detekciou Alzheimerovej nemoci a ľahkými poruchami poznávacích funkcií ([5], [6], [40], [50]).

V tabuľke, vid' Tab. 3.9 sú zobrazené štatistické parametre vypočítané z koeficientov šmyku pre všetky cvičenia pacientov trpiacich Parkinsonovou nemocou, ako aj zdravých ľudí. Z tabuľky je opäť vidno značne vyššej variácie parametra popisujúceho plynulosť pohybov pre pacientov s Parkinsonovou nemocou, čo je spôsobené motorickou dysfunkciou, konkrétne sa jedná o zvýšenú hladinu tremoru v pohybe pri písaní. Ďalej je z tabuľky badateľná menšia hodnota koeficientu šmyku pre pacientov ako pre zdravých ľudí čo odpovedá spomínanej neplynulosti pohybu. Pre tieto zistenia je koeficient šmyku, ako jeden z parametrov popisujúcich (hodnotiacich) ručne písaný prejav, v diplomovej práci taktiež zaradený do systému automatickej detekcie Parkinsonovej nemoci. Viac o tomto parametre a jeho konkrétnej realizácii je možné nájsť v kapitole 6.2.1.


Tab. 3.9: Zobrazenie štatistických parametrov koeficientu šmyku písania pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje parametre vypočítané zo všetkých písomno-kresliacich cvičení.

Cvičenia	cv. 1		cv. 2		cv. 3 - 8		cv. 9	
Parametre	PD	H	PD	H	PD	H	PD	H
Stred. Hod.	10,6947	12,3878	4,5943	5,2936	0,0129	0,0067	0,1652	0,2048
Rozptyl	47,7911	33,7504	16,0068	8,3367	7,3306	2,6193	0,0079	0,0068
Smer. odch.	6,9131	5,8095	4,0009	2,8873	0,0856	0,0512	0,0887	0,0826
Min. hod.	2,5092	4,5199	1,5521	1,9063	0,0001	0,0001	0,0596	0,0831
Max. hod.	29,5211	29,2151	30,5555	16,8896	0,9396	0,9214	0,3969	0,4154
Medián	8,1352	11,2588	3,4954	4,3870	0,0027	0,0027	0,1365	0,1849
* Hodnoty cvičenia 3 – 8 sú normalizované hodnotou $1 \cdot 10^3$								

3.2 Parametre používané pri analýze rečového prejavu

3.2.1 Spektrogram

Jedná sa o jednoduchú a prehľadnú metódu zobrazenia zastúpenia frekvenčných zložiek v skúmanom signále počas jeho časového priebehu. Na horizontálnu os je vyneseny čas a na vertikálnu os je vynesená frekvencia. Podľa intenzity farieb spektrogramu je možné pozorovať informáciu o každej frekvencii zastúpenej v sledovanom signále. V diplomovej práci slúži spektrogram iba ako doprovodný priebeh, podporujúci jednotlivé vypočítané parametre. Zobrazenie spektrogramu priebehu elipsy ako funkcie $y = f(t)$ a frekvenčného modulového spektra je možné vidieť na Obr. 3.2.



Obr. 3.2: Zobrazenie spektrálnych charakteristík priebehu elipsy ako závislosti osi y na čase ($N_{\text{FFT}} = 256$, $f_{\text{vz}} = 200$ Hz): a) spektrogram; b) modulové frekvenčné spektrum.

3.2.2 Základná frekvencia signálu

Základná frekvencia, alebo tzv. „pitch“, odpovedá frekvencii prvej harmonickej zložky jednotlivých záznamov písomno-kresliacich cvičení. Jej prevrátená hodnota sa nazýva základná perióda. Keďže záznamy ručne písaného prejavu určitých cvičení, konkrétne Archimedovej špirály a elipsy, rozložené na závislosti osi y na čase sú kvázi-periodické, vid'. Obr. 2.2 alebo Obr. 2.3, je možné zistiť periódu týchto priebehu, rovnú základnej perióde, tj prevrátenej hodnote ich základnej frekvencie. V práci je spomínaná perióda využitá pri výpočte rýchlosti písania jednotlivých ťahov, vid'. kapitolu 3.1.7.

V tabuľke Tab. 3.10 sú zobrazené štatistické parametre tohto parametra pre cvičenia 1 a 2, tj. segmentované cvičenia Archimedovej špirály a elipsy pre pacientov trpiacich Parkinsonovou nemocou a zdravých ľudí. Tieto parametre boli v práci testované jednak pre záznamy polohy pera na osi x , ako aj pre záznamy pera na osi y . Z tabuľky je viditeľný rozdiel základnej frekvencie pacientov s Parkinsonovou nemocou a zdravých ľudí, ktorý odpovedá výsledkom zobrazeným v tabuľkách Tab. 3.1, Tab.

3.2, Tab. 3.5 a Tab. 3.7, ktoré popisujú výskyt Bradikinézie v priebehu záznamov písomno-kresliacich cvičení týchto pacientov.

Tab. 3.10: Zobrazenie štatistických parametrov základnej frekvencie písania pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje pre cvičenia 1 a 2, tj. pre Archimedovu špirálu a elipsu.

Cvičenia	cv. 1				cv. 2			
Priebeh	na osi x		na osi y		na osi x		na osi y	
Parametre	PD	H	PD	H	PD	H	PD	H
Stred. Hod.	0,6037	0,6378	0,7577	0,8733	1,4913	1,7047	1,3809	1,6266
Rozptyl	0,2108	0,0957	0,4197	0,3544	2,6384	0,9929	1,5333	1,1559
Smer. odch.	0,4591	0,3094	0,6479	0,5953	1,6243	0,9965	1,2383	1,0751
Min. hod.	0,1276	0,1533	0,0703	0,2151	0,1464	0,1637	0,1043	0,1976
Max. hod.	1,8498	1,3929	3,4293	3,5235	17,4381	5,1179	10,4321	6,0945
Medián	0,4841	0,5938	0,6157	0,7574	1,0667	1,4061	0,9547	1,2778

3.2.3 Jitter

Jitter, alebo kolísanie základnej frekvencie, je ďalším parametrom, ktorý pracuje so základnou frekvenciou písania jednotlivých ťahov. Zdravý človek píše s malou variabilitou základnej frekvencie. Pacienti trpiaci neurologickými onemocneniami ako je napr. Parkinsonova nemoc, majú v dôsledku tohto onemocnenia poškodenú jemnú motoriku prstov a zápästia, doprevádzanú tremorom a inými charakteristickými vadami, vid' kapitolu 1.1.1. Tento parameter testuje ako sa základná frekvencia písomného prejavu mení počas vykonávania jednotlivých písomných cvičení, konkrétne cvičenia, pri ktorom pacienti kreslia Archimedovu špirálu a cvičenia, kedy kreslia elipsy v rýchlom slede cez seba.

Výsledok testovania tohto parametra je v tabuľke popisujúcej základnú frekvenciu písomného prejavu, vid' kapitolu 3.2.2, konkrétne Tab. 3.10. Z tabuľky je vidno, že pacienti trpiaci Parkinsonovou nemocou majú podstatne väčšiu variabilitu (rozptyl) základnej frekvencie počas vykonávania týchto cvičení, čo odpovedá predpokladom spomínaným vyššie. Najmarkantnejší rozdiel je pri pohybe pera na si x pri cvičení č. 2, kedy je variácia základnej frekvencie pacientov s Parkinsonovou nemocou až vyše dvojnásobná oproti zdravým ľuďom. Testovanie ukazuje, že jitter, alebo kolísanie základnej frekvencie písomného prejavu je dobrým ukazovateľom stavu zhoršenej motorickej funkčnosti pohybového aparátu, je teda zaradený do systému automatickej detekcie Parkinsonovej nemoci na základe analýzy ručne písaného prejavu.

3.2.4 Medián výkonovej spektrálnej hustoty

Výkonová spektrálna hustota ([7], [19]) je parameter určujúci výkon signálu v určitom frekvenčnom pásme. Odhad výkonovej spektrálnej analýzy môže byť vypočítaný pomocou viacerých metód. Jednou z týchto metód je tzv. periodogram, definovaný ako (nasledujúce vzťahy sú prebraté z literatúry ([36]))

$$P_{xx}(e^{j\omega}) = \sum_{m=-(N-1)}^{N-1} r_{xx}[m] e^{-j\omega m}, \quad (3.1)$$

kde $r_{xx}[m]$ je autokorelačná postupnosť počítaná pomocou vzťahu

$$r_{xx}[m] = \frac{1}{2N+1} \sum_{n=-N}^N x^*[n]x[n+m]. \quad (3.2)$$

Periodogram môže byť taktiež definovaný s použitím DFT ako

$$\begin{aligned} P_{xx}(e^{j\omega}) &= \frac{1}{N} \left| \sum_{n=0}^{N-1} x[n] e^{-j\omega n} \right|^2 \\ &= \frac{1}{N} |X(e^{j\omega})|^2. \end{aligned} \quad (3.3)$$

V práci je signál (záznamy vybraných cvičení) najprv rozdelený na segmenty. Tieto segmenty sú následne podrobené analýze výkonovej spektrálnej hustoty. Tento postup odpovedá tzv. neparametrickým metódam odhadu PSD. Tieto metódy pre výpočet spektra skúmaného priebehu využívajú algoritmus FFT. Vzťah pre výpočet výkonovej spektrálnej hustoty podľa (3.3) prejde do tvaru

$$P_{xx}(e^{j2\pi f_k}) = \left| \sum_{n=0}^{N-1} x[n] e^{-jk \frac{2\pi}{N} n} \right|^2, \quad (3.4)$$

kde $k = 0, 1, \dots, N-1$. Periodogram je teda počítaný v N frekvenčných bodoch f_k . V diplomovej práci je pre výpočet PSD použitá tzv. Welchova metóda priemerovania modifikovaných periodogramov. Pri tejto metóde je použitá segmentácia s prekrývaním jednotlivých segmentov. Analyzované dáta sú teda rozdelené podľa

$$s_i[n] = s_i[n + iD]. \quad (3.5)$$

Hodnota iD je počiatočným bodom i -tej postupnosti, $i = 0, 1, \dots, L-1$. L je počet po sebe idúcich segmentov. V práci je použitá hodnota presahu rovná 50%. Modifikovaný periodogram podľa Welchovej metódy je definovaný ako

$$\tilde{P}_{xx}^{(i)}(e^{j2\pi f}) = \frac{1}{MU} \left| \sum_{n=0}^{M-1} x_i[n] w[n] e^{j2\pi f n} \right|^2, \quad (3.6)$$

kde $i = 0, 1, \dots, L-1$, U je normalizačný koeficient

$$U = \frac{1}{M} \sum_{n=0}^{M-1} w^2[n]. \quad (3.7)$$

Odhad výkonovej spektrálnej hustoty počítanej pomocou Welchovej metódy je definovaný ako aritmetický priemer modifikovaných periodogramov

$$P_{xx}^w(e^{j2\pi f}) = \frac{1}{L} \sum_{i=0}^{L-1} \tilde{P}_{xx}^{(i)}(e^{j2\pi f}). \quad (3.8)$$

V práci je výkonová spektrálna hustota použitá pre výpočet jej mediánu. Táto metóda je použitá na zistenie stredného výkonu v určitom pásme skúmaného priebehu. Výpočet mediánu PSD prebieha nasledovne

$$\text{med} \left(P_{xx}^w(e^{j2\pi f}) \right) = P_{xx}^w(e^{j2\pi f}) \left\lceil \frac{n+1}{2} \right\rceil, \quad (3.9)$$

ak bude počet vzoriek výkonovej spektrálnej hustoty nepárny. Pre páry počet vzoriek musí platiť

$$\text{med} \left(P_{xx}^w(e^{j2\pi f}) \right) = \frac{1}{2} \left(P_{xx}^w(e^{j2\pi f}) \left\lceil \frac{n}{2} \right\rceil + P_{xx}^w(e^{j2\pi f}) \left\lceil \frac{n}{2} + 1 \right\rceil \right), \quad (3.10)$$

Pre pacientov diagnostikovaných na výskyt neurologického onemocnenia je na zázname písomného cvičenia predpokladaná určitá namodulovaná hodnota šumu. Tým pádom výkonová spektrálna hustota v tomto pásme by mala byť väčšia. V diplomovej práci bola snaha o meranie výkonovej spektrálnej hustoty v obmedzenom pásme frekvencií. Bol predpoklad, že tremor pacientov trpiacich Parkinsonovou nemocou je v rozmedzí od 0Hz do f_p , pričom bude predpokladané, že $f_p < 10\text{Hz}$.

Testovanie však ukázalo, že medián výkonovej spektrálnej hustoty nie je parametrom použiteľným pre testovanie množstva šumu v priebehoch záznamov písomno-kresliacich cvičení. Je tomu tak pretože priebehy týchto cvičení (konkrétne cvičenia 1 a 2) sú pri priemete záznamov na osi x a y v čase kvázy-periodické až periodické. Väčšina energie týchto priebehov je preto sústredená v prvej harmonickej zložke. Pri konkrétnej realizácii mediánu PSD, viď kapitolu 6.2.2, teda z priebehov PSD vypočítaných pre tieto cvičenia nie je možné určiť medián.

3.2.5 Lineárna predikčná analýza

Lineárna predikčná analýza (LPC), ([7], [32], [35]) je jednou z najčastejšie používaných metód spracovania rečového signálu a je využívaná v mnohých aplikáciách, ako sú napr. mobilné komunikácie, kodéry, diagnostika neurologických onemocnení na základe analýzy rečového prejavu a iné. Základom tejto metódy je predpoklad, že každú vzorku signálu $\tilde{s}[n]$ je možné vopred určiť (predikovať) na základe znalosti p predchádzajúcich vzoriek. Túto tzv. doprednú predikciu je možné zapísať ako (nasledujúce vzťahy sú prebraté z ([36]))

$$\begin{aligned} \tilde{s}[n] &= -a_p[1]s[n-1] - a_p[2]s[n-2] - \dots - a_p[p]s[n-p] = \\ &= -\sum_{i=1}^p a_p[i]s[n-i], \end{aligned} \quad (3.11)$$

$a_p[i]$ sú lineárne predikčné koeficienty a p je rád prediktoru. Keďže predikcia je len odhad budúcich vzoriek na základe predchádzajúcich, je potrebné určiť tzv. chybu doprednej predikcie definovanú podľa vzťahu

$$\begin{aligned}
e[n] &= s[n] - \tilde{s}[n] = s[n] + \sum_{i=1}^p a_p[i] s[n-i] = \\
&= \sum_{i=0}^p a_p[i] s[n-i],
\end{aligned} \tag{3.12}$$

kde $a_p[0] = 1$. Ak je chyba doprednej predikcie $e[n]$ podrobená Z-transformácii je možné ju pokladať za výstup filtra s prenosovou funkciou $A(z)$ definovanou ako

$$\begin{aligned}
Z\{e[n]\} &= Z\{s[n] + \sum_{i=1}^p a_p[i] s[n-i]\}, \\
E(z) &= S(z) [1 + \sum_{i=1}^p a_p[i] z^{-i} z^{-i}], \\
A(z) &= \frac{E(z)}{S(z)} = 1 + [\sum_{i=1}^p a_p[i] z^{-i} z^{-i}].
\end{aligned} \tag{3.13}$$

$A(z)$ je nazývaná prenosovou funkciou tzv. analyzujúceho filtra. Tento filter je používaný v systémoch pracujúcich s lineárnou predikciou. Pomocou lineárnych predikčných koeficientov je vytvorený systém, na ktorého vstup je privedený vstupný signál a na jeho výstupe je biely šum. Tento proces je teda možné invertovať a vytvoriť tzv. syntezujúci filter, ktorý slúži na vytvorenie náhodného procesu s charakterom bieleho šumu a je daný ako

$$H(z) = \frac{1}{A(z)} = \frac{1}{1 + [\sum_{i=1}^p a_p[i] z^{-i} z^{-i}]} \tag{3.14}$$

Vhodný rád prediktora p je pre systémy pracujúce s rečovým signálom je možné nájsť pomocou nasledujúceho vzťahu ([31])

$$p = \frac{f_{vz}}{1000} + 4. \tag{3.15}$$

Pre navrhovaný systém, teda systém pracujúci s písomným prejavom, podobný vzťah neexistuje. V práci bude použitý rád prediktora rovný $p = 9$.

Chybová funkcia doprednej lineárnej predikcie je vyjadrovaná v normovanom tvare ako $\epsilon_p^e = E(|e[n]|^2)$. Minimalizácia tejto funkcie vedie na sústavu lineárnych rovníc v tvare ([36])

$$\mathbf{\Gamma}_p \cdot \mathbf{a}_p = \gamma_p, \tag{3.16}$$

kde a_p sú lineárne predikčné koeficienty, $\mathbf{\Gamma}_p$ je matica autokorelačných koeficientov γ_p . Táto matica má tzv. Toeplitzovský tvar a jej riešenie je v zmysle výpočtu a_p najčastejšie vykonávané použitím Levinsonovho-Durbinovho algoritmu.

V práci je snaha o zaradenie LPC do návrhu systému diagnostiky Parkinsonovej nemoci na základe analýzy ručne písaného prejavu. Tieto LPC koeficienty by mohli byť dobrým ukazovateľom náhodnosti signálu, resp. schopnosti prediktora určiť nasledujúcu vzorku na základe predchádzajúcich vzoriek sledovaného priebehu. V tabuľke Tab. 3.11 sú zobrazené priemerné hodnoty jednotlivých LPC koeficientov počítané pre záznamy cvičení 1 a 2 pacientov PD a zdravých ľudí.

Tab. 3.11: Zobrazenie stredných hodnôt LPC koeficientov pre záznamy cvičení 1 a 2 pre pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Záznamy sú diferencované na záznamy na osi x a y .

Cvičenia	cv. 1				cv. 2			
Priebeh	na osi x		na osi y		na osi x		na osi y	
LPC k.	PD	H	PD	H	PD	H	PD	H
1.	1	1	1	1	1	1	1	1
2.	-1,0327	-1,0291	-1,1009	-1,1524	-1,0757	-1,1003	-1,1495	-1,1652
3.	-0,0049	-0,0029	-0,0285	0,0178	0,0095	0,0133	0,0388	0,0505
4.	0,0027	-0,0001	0,0284	0,0221	0,0062	0,0141	0,0359	0,0298
5.	-0,0002	0,0015	-0,0031	0,0187	0,0131	0,0105	0,0241	0,0212
6.	0,0015	0,0007	0,0271	0,0093	0,0048	0,0085	0,0071	0,0071
7.	0,0003	-0,0006	0,0029	0,0011	0,0076	0,0073	0,0053	0,0065
8.	0,0023	0,0016	0,0099	0,0111	0,0041	0,0059	-0,0012	-0,0004
9.	-0,0008	-0,0009	0,0018	-0,0073	0,0051	0,0053	-0,0001	-0,0021
10.	0,0328	-0,0312	0,0639	0,0814	0,0308	0,0403	0,0494	-0,0633

Z tabuľky je vidno, že jednotlivé LPC koeficienty sa pre priebehy pacientov a zdravých ľudí takmer nelíšia, a to ani pre priebehy záznamov na osi x , ani priebehy záznamov na osi y . Je to spôsobené tým, že priebehy záznamov pacientov, konkrétne priebehy záznamov na osi x a y podľa času nie sú príliš odlišné. Relatívne viditeľná zmena v priebehu signálu zobrazeného v priemete záznamu na osi x ku záznamu na osi y je pri priemetoch $y = f(t)$ alebo $x = f(t)$ minimálna, vid' napr. Obr. 2.1 a Obr. 2.2, ktoré zobrazujú spomínané priebehy pre Archimedovu špirálu. LPC koeficienty sú aj napriek týmto zisteniam pokusne zaradené do navrhnutého systému. Viac o konkrétnej realizácii LPC v navrhnutom systéme, vid' kapitolu 6.2.2.

3.2.6 Spektrálny tok

Spektrálny tok je parameter, ktorý kvantitatívne vyjadruje zmenu výkonového spektra signálu v čase. Tento parameter je v diplomovej práci počítaný ako normovaný rozdiel výkonového spektra aktuálneho segmentu a výkonového spektra segmentu predchádzajúceho. Normovaným rozdielom je myslená euklidovská vzdialenosť dvoch normovaných výkonových spektier, definovaná ako ([27]).

$$S_{\text{flux}}(k) = \sum_{i=0}^{N-1} \sqrt{(S_k(i) - S_0)^2 (S_{(k-1)}(i) - S_0)^2}, \quad (3.17)$$


kde S_0 je normalizačný faktor, ktorý je počítaný ako aritmetický priemer strednej hodnoty výkonových spektier pre všetky nahrávky daného cvičenia.

V tabuľke Tab. 3.12 sú uvedené štatistické hodnoty tohto parametra pre cvičenia 1 a 2, tj. pre cvičenia, pre ktoré má zmysel diferencovať segmenty v zmysle krátkych úsekov vytvorených násobením váhovacou postupnosťou.

Tab. 3.12: Zobrazenie štatistických parametrov spektrálneho toku pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje pre cvičenia 1 a 2, tj. pre Archimedovu špirálu a elipsu pre závislosti na osi x a y .

Cvičenia	cv. 1				cv. 2			
Priebeh	na osi x		na osi y		na osi x		na osi y	
Parametre	PD	H	PD	H	PD	H	PD	H
Stred. Hod.	0,9871	2,4806	4,1011	2,4671	3,5266	2,8454	4,3017	3,7172
Rozptyl	1,3063	60,0433	137,5273	7,6232	34,8962	20,8188	43,9559	23,1554
Smer. odch.	1,4303	7,7488	11,7272	2,7611	5,9073	4,5628	6,6284	4,8121
Min. hod.	0,1604	0,2668	0,4695	0,6188	0,2537	0,5189	0,6689	0,8818
Max. hod.	5,8213	42,5282	73,0587	12,5291	72,6316	50,5565	84,7255	52,7314
Medián	0,5418	0,6026	1,2001	1,4736	2,6158	2,2311	3,2651	2,9691

Na obrázku, vid' Obr. 3.3 je zobrazený priebeh spektrálneho toku pre kresliace cvičenie, pri ktorom pacienti kreslia Archimedovou špirálou, a to pre záznamy na osi x aj pre záznamy na osi y . Z obrázku je zjavné, že pacienti s Parkinsonovou nemocou vykazujú vyššie hodnoty parametra spektrálny tok pre dané cvičenie, a to v oboch záznamoch.



Obr. 3.3: Priebehy spektrálneho toku Archimedovej špirály: a) priebeh spektrálneho toku podozrivého prejavu pacienta s Parkinsonovou nemocou pre záznamy na osi x (modrý priebeh) záznamy na osi y (červený priebeh); b) priebeh spektrálneho toku zdravého človeka pre záznamy na osi x (modrý priebeh) záznamy na osi y (červený priebeh).

Z tabuľky Tab. 3.12 je vidieť veľké rozdiely najmä v rozptyle spektrálneho toku pre pacientov s Parkinsonovou nemocou a zdravých ľudí. Napr. pre cvičenie 2 je

spektrálny tok závislosti bodov na osi y pre týchto pacientov vyše desaťnásobný. Svedčí to o nepravidelnosti pohybov pri vykonávaní cvičenia a zvýšenej hladiny šumu spôsobenej prítomnosťou tremoru v písomnom prejave. Spektrálny tok je taktiež zaradený do navrhnutého systému ako parameter sledujúci zmenu spektrálnych charakteristík jednotlivých ľudí pri vykonávaní jednotlivých cvičení. Viac o konkrétnej realizácii tohto parametra v navrhnutom systéme, viď kapitolu 6.2.2.

3.2.7 Reálne kepstrum

Kepstrálna analýza patrí medzi nelineárne metódy spracovania signálov. Medzi najčastejšie aplikácie tejto analýzy patrí tzv. homomorfná filtrácia (dekonvolúcia). Je založená na zobecnenom princípe superpozície. Základným princípom zobecneného princípu superpozície je platnosť vzťahu

$$\mathcal{H}\{f(a) \cdot f(b)\} = \mathcal{H}\{f(a)\} + \mathcal{H}\{f(b)\}, \quad (3.18)$$

kde $\mathcal{H}$ predstavuje transcendentálnu funkciu (napr. $\ln$, e atď.). Je to transformácia, ktorá vytvorí z násobku dvoch funkcií ich súčet.

Homomorfná dekonvolúcia je proces, pomocou ktorého je možné oddeliť signály vzniknuté ich vzájomnou konvolúciou, tzv. konvolučnú zmes signálov. Jedná sa o postupnosť krokov využívajúcich kepstrálnu transformáciu a je definovaná pomocou vzťahov

$$s[n] = f[n] * g[n], \quad (3.19)$$

$$\text{DFT}\{s[n]\} = \text{DFT}\{f[n] * g[n]\}, \quad (3.20)$$

$$S[k] = F[k] \cdot G[k], \quad (3.21)$$

$$\ln(S[k]) = \ln(F[k] \cdot G[k]) = \ln(F[k]) + \ln(G[k]), \quad (3.22)$$

$$\hat{S}[k] = \hat{F}[k] + \hat{G}[k], \quad (3.23)$$

$$\text{IDFT}\{\hat{S}[k]\} = \text{IDFT}\{\hat{F}[k]\} + \text{IDFT}\{\hat{G}[k]\}, \quad (3.24)$$

$$\hat{s}[n] = \hat{f}[n] + \hat{g}[n]. \quad (3.25)$$

Vo vzťahu (3.23) je výsledný signál transformovaný do tzv. nelineárnej časovej oblasti, už definovaný súčtom, ktorý sa dá oddeliť filtráciou váhovou postupnosťou, tzv. oknom. Po úprave signálu je $\hat{s}[n]$ transformovaný späť do lineárnej časovej oblasti použitím opačného postupu. V tomto postupe je transformačná funkcia $\ln$ nahradená k nej inverznou funkciou e .


Komplexné kepstrum, ako výsledok kepstrálnej transformácie, podrobne popísanej vyššie, je definované ako ([36])

$$\hat{c}[n] = \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln(S(e^{j\omega})) e^{j\omega} d\omega. \quad (3.26)$$

V diplomovej práci je použité tzv. reálne kepstrum. Reálne kepstrum je reálna časť komplexného kepstra $c[n] = \text{Re}\{\hat{c}[n]\}$. Pri použití Wienerovho-Činčinovho teorému je možné výpočet reálneho kepstra vykonávať pomocou autokorelačnej postupnosti γ_p , definovanej ako

$$c[n] = \frac{1}{2} Z^{-1} \left\{ \ln \left(\Gamma_p(z) \right) \right\}. \quad (3.27)$$

V práci bola kepstrálna transformácia, konkrétne reálne kepstrum testované pre jednotlivé priebehy Archimedovej špirály a elipsy. Po výpočte reálneho kepstra pre tieto priebehy nakoniec tento parameter do analýzy ručne písaného priebehu zaradený nebol. Je tomu tak pretože väčšina hodnôt reálneho kepstra týchto priebehov je rovná nule a nenesie teda žiadnu užitočnú informáciu, využiteľnú pri klasifikácii záznamov spomínaných cvičení (v rámci „post-processingu“, viď kapitolu 6.3 by spomínané záznamy, pre práve spomínanú skutočnosť, boli z matice parametrov odstránene). Konkrétny príklad priebehu Archimedovej špirály a elipsy a im odpovedajúceho reálneho kepstra je možný vidieť na Obr. 3.4.



Obr. 3.4: Priebehy Archimedovej špirály a elipsy a im odpovedajúce priebehy reálneho kepstra: a) priebeh záznamu Archimedovej špirály na osi x , v závislosti na priebehu časového razítka t [ms] (modrý priebeh) a odpovedajúceho reálneho kepstra (červený priebeh); b) priebeh záznamu elipsy na osi y , v závislosti na priebehu časového razítka t [ms] (modrý priebeh) a odpovedajúceho reálneho kepstra (červený priebeh). Hodnoty priebehov a ich kepstier sú pre názornosť normalizované.

3.3 Parametre hodnotiace kvalitu a intenzitu signálu

Jedná sa o parametre, ktorých stanovenie nie je výpočetne náročné. Sú počítané ako v časovej, tak aj v spektrálnej oblasti. Hodnotia energiu signálu, úroveň šumu v signále, periodicitu a iné vlastnosti daných priebehov. V práci sú použité konkrétne parametre STE, STI, ZCR. Využitie, či naopak nevyužitie jednotlivých parametrov je vysvetlené v im prislúchajúcich podkapitolách.

3.3.1 Krátkodobá energia

Slúži k výpočtu energie jednotlivých segmentov. Funkciu krátkodobej energie je možné definovať ako ([30])

$$E = \sum_{k=0}^{N-1} x[k]^2, \quad (3.28)$$

kde $x[k]$ je vzorka signálu, k je poriadie daného vzorku v segmente a N je počet vzorkov segmente. Pribeh krátkodobej energie priebehu jednej elipsy je zobrazený na Obr. 3.5, konkrétne sa jedná o priebehy c) a d).

V tabuľke Tab. 3.13 sú zobrazené štatistické parametre vypočítané pre vektory krátkodobých energií jednotlivých záznamov pre cvičenia 1 a 2 pacientov diagnostikovaných na výskyt Parkinsonovej nemoci, v závislosti na osi x a y . Viac o krátkodobej energii a jej konkrétnej realizácii v navrhnutom systéme automatickej detekcie Parkinsonovej nemoci, vid'. kapitolu 6.2.3.

Tab. 3.13: Zobrazenie štatistických parametrov krátkodobej energie vypočítanej z ručne písaného prejavu pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje pre cvičenia 1 a 2, tj. pre Archimedovu špirálu a elipsu pre závislosti na osi x a y .


Cvičenia	cv. 1				cv. 2			
Pribeh	na osi x		na osi y		na osi x		na osi y	
Parametre	PD	H	PD	H	PD	H	PD	H
Stred. Hod.	3,3448	3,0287	0,7853	0,0861	0,1699	0,7548	0,0333	0,0182
Rozptyl	5,8385	6,8709	16,2281	0,0159	2,8313	82,7291	0,0080	0,0005
Smer. odch.	2,4163	2,6212	4,0284	0,1262	1,6826	9,0955	0,0897	0,0225
Min. hod.	0,3481	0,5325	0,0016	0,0006	0,0001	0,0000	0,0004	0,0008
Max. hod.	12,7114	13,3056	24,9471	0,6352	22,3379	114,7221	0,9567	0,1880
Medián	2,9977	2,4176	0,0625	0,0477	0,0306	0,0081	0,0212	0,0086
*Všetky hodnoty v tabuľke sú normalizované hodnotou $1 \cdot 10^8$								

3.3.2 Krátkodobá intenzita

Je ďalšou metódou spracovania signálu v časovej oblasti. Jej priebeh pre záznam kresliaceho cvičenia, pri ktorom pacienti kreslili elipsy v rýchlom slede cez seba (konkrétne sa tak ako v kapitole 3.3.1 jedná o priebeh jednej elipsy), je možné pozorovať na Obr. 3.5, konkrétne priebehy e) a f). Krátkodobá intenzita je svojim matematickým vyjadrením veľmi podobná vzťahu pre výpočet krátkodobej energie a je definovaná podľa vzťahu ([30])

$$I = \sum_{k=0}^{N-1} |x[k]|, \quad (3.29)$$

Obr. 3.5 názorne zobrazuje podobnosť priebehov krátkodobej energie a krátkodobej intenzity pre rovnaký záznam cvičenia, ktorý odpovedá predpokladu podobnosti týchto dvoch cvičení. V práci sú využité oba tieto priebehy, a to pre cvičenia, pri ktorých pacienti kreslia Archimedovu špirálu a elipsy v rýchлом slede cez seba. Viac o realizácii krátkodobej intenzity v navrhnutom systéme viď kapitolu 6.2.3.



Obr. 3.5: Záznam cvičenia, pri ktorom sú kreslené elipsy v rýchлом slede cez seba pacienta trpiaceho Parkinsonovou nemocou ($f_{vz} = 200$ Hz): a) zobrazenie cvičenia písania jednej elipsy ako závislosť osi x na osi t [ms]; b) zobrazenie cvičenia písania jednej elipsy ako závislosť osi y na osi t [ms]; c) STE priebehu a; d) STE priebehu b; e) STI priebehu a; f) STI priebehu b.

3.3.3 Krátkodobá stredná hodnota prechodov signálu nulovou úrovňou

Jedná sa o metódu spracovania signálu v časovej oblasti. Napriek tomu je však frekvenciu prechodov signálu nulovou úrovňou možné do istej miery považovať za funkciu popisujúcu spektrálny charakter signálu. Veľkou výhodou tejto metódy je jej nezávislosť od energie signálu. Krátkodobú strednú hodnotu prechodov signálu nulovou úrovňou je možné počítať podľa ([30])

$$Z_{cr} = \sum_{k=0}^{N-1} |\text{sign}(x[k]) - \text{sign}(x[k-1])| / 2, \quad (3.30)$$

$$\text{sign}(x[k]) = \begin{cases} +1 & \text{ak } x[k] > 0 \text{ alebo } x[k] = 0 \wedge x[k-1] > 0, \\ -1 & \text{ak } x[k] < 0 \text{ alebo } x[k] = 0 \wedge x[k-1] < 0. \end{cases} \quad (3.31)$$

Pre tieto vzťahy platí, že $x[k]$ je vzorka signálu, k je poradie vzoriek v danom segmente a N je počet vzoriek v segmente.

Tento priebeh nie je v práci vykreslený a v konečnom dôsledku je v rámci „post-processingu“, alebo tzv. spracovania výsledkov testovania parametrov, vid' kapitolu 6.3, z matice parametrov vypustený. Je tomu tak pretože priebehy, pre ktoré je počítaný, teda Archimedova špirála a elipsa, sú pri priemete závislosti pera na osi x v čase a závislosti pera na osi y v čase, takmer periodické. ZCR je teda pre jednotlivé segmenty konštantný.


3.3.4 Krátkodobá autokorelačná funkcia

Autokorelačná funkcia udáva podobnosť signálu samého so sebou, posunutého o k vzoriek. Pre výpočet autokorelačnej funkcie je potrebné, aby analyzovaný segment obsahoval aspoň jednu periódu signálu. Veľkosť segmentu je v diplomovej práci určovaná pomocou automatizovanej dvojfázovej segmentácie, vid' kapitolu 2.2. Autokorelačná funkcia signálu je počítaná ako ([36])


$$R(m) = \sum_{n=0}^{N-1} x(n) \cdot x(n+m). \quad (3.32)$$

V práci bola snaha o zaradenie krátkodobej autokorelačnej funkcie do systému detekcie podobných vzorov v signále, resp. ako ukazovateľ periodicity daného priebehu. Tento parameter bol v rámci testovania aplikovaný na priebeh Archimedovej špirály a elipsy ako funkcie $y = f(x)$. Tieto priebehy sú kvázi-periodické a pomocou autokorelačnej funkcie bola v práci určovaná hodnota podobnosti, resp. určitá miera nepravidelnosti, svedčiaca o prítomnosti tremoru.

Jednotlié priebehy sú však aj po umelom zašumení, tj. pri prítomnosti tremoru a navyše pridaní ďalšieho rušenia, vid' Obr. 3.6 takmer nerozpoznatelné. Konkrétne v charakteristike jednotlivých záznamov pri zobrazení krátkodobej autokorelačnej funkcie, vid' Obr. 3.7, nie je jednoznačne možné určiť prítomnosť šumu ako degradáciu autokorelačnej funkcie priebehu, tj. pomocou tohto parametra nie je možné s dostatočnou pravdepodobnosťou určiť prítomnosť motorickej disfunkcie.



Obr. 3.6: Zobrazenie priebehu Archimedovej špirály: a) priebeh záznamu na osi y Archimedovej špirály, v závislosti na priebehu na osi x pacienta diagnostikovaného na prítomnosť Parkinsonovej nemoci; b) priebeh záznamu na osi y Archimedovej špirály, v závislosti na priebehu na osi x pacienta, navyše umelo zašumená bielym šumom.



Obr. 3.7: Zobrazenie autokorelačnej funkcie priebehov zobrazených na Obr. 3.6: a) priebeh autokorelačnej funkcie záznamu na osi y Archimedovej špirály, v závislosti na priebehu na osi x ; b) autokorelačná funkcia umelo zašumeného priebehu zobrazeného na Obr. 3.6, konkrétne priebehu b.

Krátkodobá autokorelačná funkcia, ako funkcia hodnotiaca prítomnosť tremoru, resp. šumu v priebehu jednotlivých písomno-kresliacich cvičení, nie je v navrhnutom systéme využitá ako jeden z parametrov diagnostikujúcich Parkinsonovu nemoc.

3.3.5 Harmonicita signálu

Tento parameter vyjadruje stupeň periodicity skúmaného priebehu. Harmonicita býva označovaný aj ako HNR (harmonic-to-noise ratio). Z názvu vyplýva, že ide o porovnanie úrovne energie v „užitočnom“ signále a úrovne energie (výkonu) šumu. V aplikáciách pracujúcich s rečovým signálom býva tento parameter použitý v tzv. detektoroch rečovej aktivity. Harmonicita, nie je do navrhnutého systému zaradená.

3.4 Parametre založené na teórii chaosu

Sú parametre skúmajúce vlastnosti dynamického systému. Dynamický systém je každý systém, ktorý sa vyvíja v čase. V praxi sú tieto metódy využívané na meranie chovania skúmaného systému zmysle jeho komplexnosti a správania v tzv. fázovom priestore. Parametre založené na teórii chaosu teda určujú stupeň náhodnosti skúmaného priebehu. V práci sú vyberané parametre tohto typu z nasledujúceho zoznamu parametrov:

1. **Parametre určujúce dynamiku fázového priestoru** – Stav dynamického procesu v čase môže byť určený pomocou bodu v tzv. fázovom priestore. Fázový priestor je abstraktný matematický priestor, zastúpený stavovými premennými systému. Parametre patriace do tejto skupiny sú napr.:
 - a. Korelačná dimenzia.
 - b. Najväčší Laypunovov exponent.
2. **Parametre merajúce komplexnosť procesu** – Jedná sa o parametre hodnotiace náhodnosť dynamického procesu. V práci je použitý a testovaný nasledujúci parameter z tejto skupiny:
 - a. Fraktálna dimenzia.

3.4.1 Korelačná dimenzia

Korelačná dimenzia je parameter, ktorý štatisticky meria geometriu zhľuku bodov v tzv. fázovom priestore. Táto kvantita odpovedá počtu nezávislých premenných potrebných na vygenerovanie korešpondujúceho dynamického procesu (tiež známa ako stupeň nezávislosti). Čím je systém komplexnejší, tým má vyššiu dimenziu, teda potrebuje viac týchto premenných potrebných k popísaniu jeho dynamiky. Na výpočet korelačnej dimenzie sa používa napr. tzv. Grassberger-procacia estimátor. Grassberger-procacia estimátor určuje vzdialenosť medzi každým párom bodov vo fázovom priestore na základe výpočtu korelačného integrálu, definovaného ako (nasledujúce vzťahy sú prebraté z ([12]))

$$c_m(r) = \frac{1}{[N-(m-1)\tau][N-(m-1)\tau-1]} \times \sum_{i=1}^{N-(m-1)\tau} \left(\sum_{j=i+1}^{N-(m-1)\tau} \theta(r - \|\vec{X}_i - \vec{X}_j\|) \right), \quad (3.34)$$

kde X_i reprezentuje rekonštruovaný vektor fázového priestoru, $\|\vec{X}_i - \vec{X}_j\|$ predstavuje Euklidovskú vzdialenosť dvoch vektorov, r je rádus okolo X_i a $\theta(x)$ je Heavisideova funkcia. Korelačný integrál je určený vytvorením hypersféry o polomere r okolo uzavretej skupiny bodov a výpočtom priemerného počtu bodov uzavretých v tejto hypersfére. $c_m(r)$ je počítaný v širokom rozsahu polomerov zvyšovaním dimenzie m a vykreslením závislosti $\log_2(c_m(r)) = f(\log_2(r))$ je možné zobrazit krivku, ktorá je lineárna na určitej časti priebehu. Linearitu tejto krivky je možné určiť ako smernicu, tj.

prvú deriváciu závislosti

$$slope = \frac{\log_2(c_m(r_h)) - \log_2(c_m(r_l))}{\log_2(r_h) - \log_2(r_l)}, \quad (3.35)$$

kde (r_h, r_l) rozsah polomerov r , pre ktoré je táto závislosť lineárna. Tzv. odhadovaná dimenzia $d(m)$ je následne počítaná ako

$$d(m) = \frac{\frac{1}{n} \sum_{i=1}^n slope(i)}{r_h - r_l}. \quad (3.36)$$

Pri zvyšovaní tzv. obkolesujúcej dimenzie m sa funkcia $d(m)$ postupne dostáva do saturácie, kedy hodnota $d(m)$ ostáva konštantná. Táto hodnota sa rovná korelačnej dimenzii CD . Korelačná dimenzia nie je do systému automatickej detekcie Parkinsonovej nemoci na základe analýzy ručne písaného prejavu zaradená.

3.4.2 Najväčší Laypunovov exponent

Najväčší Laypunovov exponent hodnotí stabilitu dynamického systému. Chaotické správanie dynamického systému rastie exponenciálne. Táto exponenciálna nestabilita je charakterizovaná práve Laypunovovými exponentami, ktoré kvantifikujú priemer exponenciálneho rastu konvergenzie alebo divergencie v blízkosti trajektórie fázového priestoru. Laypunovov exponent je meradlom závislosti systému na počiatočných podmienkach. Je známe, že chaotický systém má aspoň jeden pozitívny Laypunovov exponent. V praxi sa na výpočet tohto parametra používa tzv. Wolfov algoritmus, definovaný (nasledujúce vzťahy sú prebraté z ([12]))

$$p(k) = \frac{1}{N t_s} \sum_{n=1}^N \left(\frac{\|y^{n+k} - y^{nn+k}\|}{\|y^n - y^{nn}\|} \right), \quad (3.37)$$

kde y^{nn} je tzv. najbližší susedný bod bodu y^n . Závislosť $p(k)$ na počte časových krokov k môže byť rozdelená do troch fáz. Počas fáze 2 vzdialenosť medzi jednotlivými bodmi rastie exponenciálne podľa $e^{(\lambda_1 t_s k)}$, pokiaľ neprekročí hranicu validity lineárnej aproximácie toku okolo referenčného orbitu $\{y^{n+k}\}$. Najväčší Laypunov exponent λ_1 je určený ako smernica lineárneho segmentu vzťahu $p(k) = f(k)$. Najväčší Laypunovov exponent, podobne ako Korelačná dimenzia nie je zaradený do navrhnutého systému.

3.4.3 Fraktálna dimenzia

Fraktálna dimenzia (FD) predstavuje určitú časť dimenzie geometrického objektu. Fraktálna dimenzia môže byť pokladaná za relatívnu mierku počtu základných stavebných blokov, tvoriacich daný objekt. Odhad FD je vykonávaný jednak v časovej oblasti a taktiež v tzv. fázovom priestore. V prvom type odhadu je časový priebeh skúmaného signálu považovaný ako geometrický útvar. V druhom type je signál považovaný za skupinu bodov vo fázovom priestore.

V práci je použitý odhad Fraktálnej dimenzie v časovej oblasti, ktorá ponúka priame spojenie medzi variáciou komplexnosti a zmenou skúmaného signálu v čase. Pomocou tohto parametra je možné zistiť abnormality priebehu signálu. V práci je na výpočet Fraktálnej dimenzie použitý Petrosianov algoritmus. Pri tomto algoritme je nutné daný signál najprv previesť do binárnej podoby, resp. podoby (+1, − 1) a nasledovne na neho aplikovať vzťah ([12])

$$FD = \frac{\log_{10}(n)}{\log_{10}(n) + \log_{10}\left(\frac{n}{n + \frac{4N_A}{10}}\right)}, \quad (3.38)$$

kde n je dĺžka bitovej sekvencie a N_A je počet zmien znamienok. Tento parameter je používaný pre časovú postupnosť prekrývajúcich sa segmentov skúmaného signálu a preto je vhodným kandidátom pre zaradenie do navrhovaného systému diagnostiky Parkinsonovej nemoci.

V tabuľke Tab. 3.14 sú zobrazené štatistické hodnoty vypočítané pre Fraktálne dimenzie cvičenia 1 a 2 pacientov trpiacich Parkinsonovou nemocou a zdravých ľudí. Tabuľka ukazuje, že tento parameter nadobúda zväčša mierne vyššie hodnoty pre pacientov PD, čo odpovedá zvýšenej hladine náhodnosti v ich písomnom prejave, tj. prítomnosti tremoru. Tento parameter je zaradený do navrhnutého systému.

Tab. 3.14: Zobrazenie štatistických parametrov Fraktálnych dimenzií vypočítaných z ručne písaného prejavu pacientov diagnostikovaných na výskyt Parkinsonovej nemoci a zdravých ľudí. Tabuľka zobrazuje pre cvičenia 1 a 2, tj. pre Archimedovu špirálu a elipsu pre závislosti na osi x a y .

Cvičenia	cv. 1				cv. 2			
Priebeh	na osi x		na osi y		na osi x		na osi y	
Parametre	PD	H	PD	H	PD	H	PD	H
Stred. Hod.	0,1653	0,1502	0,2042	0,1607	0,6988	0,4680	0,6992	0,4765
Rozptyl	0,0015	0,0009	0,0198	0,0016	0,1700	0,1811	0,1687	0,1801
Smer. odch.	0,0389	0,0302	0,1406	0,0399	0,4123	0,4256	0,4108	0,4244
Min. hod.	0,1113	0,0835	0,1130	0,0911	0,0299	0,0633	0,0376	0,0628
Max. hod.	0,2528	0,2003	1,0031	0,2504	1,0134	1,0105	1,0114	1,0156
Medián	0,1667	0,1434	0,1842	0,1670	1,0024	0,1676	1,0026	0,1675

4 KLASIFIKÁCIA RUČNE PÍSANÉHO PREJAVU

Klasifikácia je vo všeobecnosti proces triedenia vstupnej množiny dát do určitých skupín výstupných dát, na základe posudzovania ich vlastností. V diplomovej práci sa jedná o klasifikáciu záznamov ručne písaného prejavu pacientov diagnostikovaných na výskyt neurologického onemocnenia, podľa parametrov extrahovaných metódami analýzy ručne písaného prejavu, podrobne popísanými v kapitole 3, na Pacientov trpiacich Parkinsonovou nemocou a zdravých ľudí..

V práci je snaha o natrénovanie klasifikátora, schopného odlíšiť záznam zdravého človeka od pacienta trpiaceho Parkinsonovou nemocou. V dnešnej dobe existuje mnoho klasifikátorov založených na rôznych algoritmoch, od tých najjednoduchších po zložitejšie, vyžadujúcich strojové učenie. Sú taktiež nazývané metódami rozpoznávania vzorov. V práci je použitá klasifikácia pomocou algoritmov najbližších susedov, tzv. algoritmy kNN, metódy pomocných (podporných) vektorov, viacvrstvových neurónových sietí s algoritmom spätného šírenia chyby, tzv. MLP (multi-layer perceptron), metódy rozhodujúcich stromov (konkrétne tzv. Random forest), Bayesové siete a lineárna regresia, z ktorých niektoré sú podrobne popísané v nasledujúcich podkapitolách.

4.1 Algoritmus k -najbližších susedov (kNN)


Metóda rozpoznávania kNN, alebo metóda najbližších susedov zaradí neznámu vzor dát do tej skupiny, ktorej predstavitelia sú najviac zastúpení v danej k -tici najbližších susedov. Jedná sa o neparametrickú metódu klasifikácie vzorov, ktorá na rozdiel od parametrických metód ako je napr. GMM, nepredpokladá znalosť pravdepodobnostných charakteristík jednotlivých tried. Metóda kNN je založená na hľadaní priamo a posteriornej pravdepodobnosti.

Pri výpočte kNN pracujeme s trénovacou množinou $\{(x_i, \omega_i)\}$, kde $i = 1 \dots K$, x_i je vzor, ktorému je priradená príslušná trieda ω_i a K je veľkosť trénovacej množiny. Pre neznámy prvok je hľadané také x_k , že platí

$$\|x'_k - x\| = \min \|x'_i - x\|_{i=1 \dots k}. \quad (4.1)$$

Na obrázku, viď Obr. 4.1 je ilustračne zobrazený proces klasifikácie kNN, pre $k = 5$. Výpočet vzdialenosti daných vzorov, je väčšinou počítaný pomocou Euklidovskej vzdialenosti týchto bodov v tzv. Euklidovskom priestore.

Metódy klasifikácie pomocou algoritmov kNN sú vhodné pre triedenie dát do menších skupín. Táto vlastnosť vyhovuje požiadavkám práce, a preto je zaradená do systému klasifikácie Parkinsonovej nemoci na základe analýzy ručne písaného prejavu.




Obr. 4.1: Proces klasifikácie algoritmu kNN pre počet najbližších susedov rovný $k = 5$. V tomto prípade by bol neznámy vzor klasifikovaný ako oranžová hviezda, pretože v k -tici najbližších susedov zastúpenie tejto triedy prvkov svojim počtom prevyšuje ostatné.

4.2 Metódy podporných vektorov (SVM)

Metódy podporných vektorov patria medzi tzv. kernel-based metódy strojového učenia. Vstupné dáta klasifikujú do jednotlivých tried pomocou podporných vektorov. Táto metóda hľadá nadrovinu, ktorá by v priestore príznakov rozdelila trénovacie dáta. Pretože rozdeľujúca nadrovina je lineárnou funkciou, je učenie pomocou SVM radené medzi binárne klasifikátory, tj. medzi klasifikátory, ktoré rozdeľujú vstupnú množinu dát na dve triedy. Oddeliteľnosť dát v priestore príznakov pomocou lineárnej funkcie pre lineárne neseparovateľné zhľuky dát je dosiahnutá tzv. jadrovou transformáciou. Jedná sa o transformáciu priestoru príznakov do priestoru vyššej dimenzie, v ktorej sú tieto príznaky lineárne separovateľné. Na obrázku Obr. 4.2 je ilustračne zobrazený priebeh klasifikácie vstupnej množiny dát algoritmom SVM.

Tak ako metódy klasifikácie založené na algoritmoch najbližších susedov, aj metódy podporných vektorov vykonávajú klasifikáciu v niekoľkých fázach:

1. **Fáza učenia** – v prvej fáze klasifikácie je každý bod o N príznakov umiestnený do odpovedajúceho miesta v N -rozmernom priestore. Tak ako pre algoritmy kNN má každý bod pevne definovanú triedu. Po vytvorení zhľukov dát algoritmus hľadá príslušnú rozdeľujúcu nadrovinu pomocou tzv. podporných vektorov.
2. **Fáza klasifikácie** – každý bod vstupnej množiny bodov je opäť umiestnený do priestoru a podľa rozdelenia tohto priestoru deliacou nadrovinou je následne priradený do odpovedajúcej triedy.



Obr. 4.2: Zobrazenie rozdelenia (lineárne separovateľnej) množiny dát algoritmom SVM, ktorý hľadá tzv. deliacu nadrovinu schopnú separovať vstupnú množinu dát.

Algoritmus podporných vektorov je takisto ako algoritmus najbližších susedov zaradený do systému automatickej detekcie Parkinsonovej nemoci na základe analýzy ručne písaného prejavu. Tieto algoritmy sú v diplomovej práci realizované a testované modelom klasifikácie, realizovaným v programovom prostredí RapidMiner, ktorý je možné vidieť v prílohe C. Viac o navrhnutom modeli vid' kapitolu 6.4. Výsledky úspešnosti týchto klasifikátorov, ako aj všetkých klasifikátorov použitých v navrhnutom modeli je možné nájsť v kapitole 6.4.2.

4.3 Umelé neurónové siete (ANN)

Umelé neurónové siete sú systémy, ktorých funkčnosť vychádza z funkcie ľudského mozgu. Jedná sa o spojenie obrovského množstva paralelne pracujúcich základných funkčných blokov, zvaných neuróny. Neuróny sú bunky nervového systému živých organizmov uložené v šedej mozgovej kôre. Umelá neurónová sieť je matematický systém spracúvajúci informácie zo svojho okolia, modelujúci funkciu ľudského mozgu. Jedná sa o adaptabilný stroj schopný učiť sa. Znalosť o neznámom procese, uložená vo forme váh umelej neurónovej siete, môže byť v praxi využitá pri analýze a riadení neznámeho procesu. Vo všeobecnosti je neurónová sieť zložená z veľkého množstva neurónov a spojení medzi nimi, nazývanými tiež synapsie, ktoré sú stimulované vstupným signálom na základe ktorého produkujú výstupný signál (pre biologické neuróny tzv. nervový vzruch). Výstupný signál je pred vstupom do ďalšieho neurónu v danej neurónovej sieti násobený váhami uloženými v synapsiách. Učenie neurónovej siete je založené na modifikácii jej váh v dynamickom tréningovom procese, v závislosti na učiacom pravidle.

4.3.1 Model neurónu

Model neurónu, zvaný tiež perceptron, sa skladá z viacerých častí, pričom ich názvy sú zvolené analogicky s biologickým neurónom. Jedná sa o tieto časti:

1. **Vstupné časti** – skladajú sa zo vstupov neurónu, ktorých môže byť N a k nim prislúchajúcich nastaviteľných váh (tzv. synaptických váh). Podľa hodnoty váhových koeficientov môže mať daný vstup excitačný (zosilňujúci), či inhibičný (utlmujúci) charakter.
2. **Funkčne časti** – tvoria tzv. aktivačná funkcia a prah neurónu. Je to výkonná jednotka neurónu, ktorá rozhodne o hodnote výstupu z daného neurónu.
3. **Výstupné časti** – jedná sa o výstup neurónu. Je vždy jeden a môže byť zároveň vstupom viacerých iných neurónov. Samotné pospájanie vstupov a výstupov neurónov spolu s nastavenými synaptickými váhami týchto spojov vytvára zložitú neurologickú sieť.

Perceptron prijíma vstupné signály $\bar{x} = (x_1, x_2, x_3, \dots, x_{n+1})$ cez synaptické váhy tvoriace váhový vektor $\bar{w} = (w_1, w_2, w_3, \dots, w_{n+1})$. Výstup perceptronu je definovaný podľa nasledujúceho vzťahu

$$y_{\text{perceptron}} = f(\sum_{j=1}^n w_j x_j - \theta), \quad (4.4)$$

Kde f je aktivačná funkcia neurónu, w_j j -ta synaptická váha, x_j j -ta vstupná hodnota a θ je prah neurónu. Aktivačná funkcia býva často realizovaná pomocou funkcie *sign* definovanej ako

$$\text{sign}(x) = \begin{cases} +1, & \text{ak } x \geq 0 \Leftrightarrow \sum_{j=1}^n w_j x_j \geq \theta \\ -1, & \text{ak } x < 0 \Leftrightarrow \sum_{j=1}^n w_j x_j < \theta \end{cases} \quad (4.5)$$

4.3.2 Viacvrstvové neurónové siete

Perceptron dokáže klasifikovať len dáta, ktoré sú tzv. lineárne separovateľné. Pre tento nedostatok sa pri klasifikácii zložitejšieho rozloženia vstupnej množiny dát prechádza na viacvrstvové neurónové siete. Tieto neurónové siete dokážu spoľahlivo separovať aj omnoho komplexnejšiu množinu dát. Existujú dva typy viacvrstvových neurónových sietí. Jedná sa o siete s dopredným šírením a siete rekurentné (so spätnou väzbou). V práci je použitá dopredná viacvrstvová neurónová sieť využívajúca metódu spätného šírenia chyby, tzv. error backpropagation vid' kapitolu 4.3.3. Táto sieť sa skladá z viacerých vrstiev. Prvá vrstva neurónov, tzv. vstupná vrstva, má funkciu vstupu danej neurónovej siete, posledná vrstva je tzv. výstupná. Všetky vrstvy medzi nimi sú tzv. skryté vrstvy, ktoré vykonávajú samotnú funkciu strojového učenia adaptáciou svojich váh na základe spätného šírenia chyby.

4.3.3 Algoritmus učenia backpropagation

Jedná sa o algoritmus učenia s učiteľom. To znamená, že neurónovej sieti sú postupne predkladané vzory, ktorých príslušnosť k jednotlivým triedam je vopred známa, na základe ktorých sieť postupne adaptuje váhy svojich synaptických spojov až pokiaľ sieť nie je tzv. „naučená“, tj. učiace proces nie je u konca. Proces učenia pri použití algoritmu spätného šírenia chyby pozostáva z viacerých fáz:

1. **Fáza inicializácie váh** – v tejto fáze sa všetky váhy neurónovej siete nastavujú na náhodné hodnoty v určitom definovanom intervale.
2. **Fáza predloženia vzoru** – neurónovej sieti je predložený vzor z trénovacej množiny a postupne sa v jednotlivých skrytých vrstvách počítajú výstupy podľa vzťahov

$$y = S(\sum_{i=1}^n w_i x_i + \theta), \quad (4.6)$$

$$S(\varphi) = \frac{1}{1 + e^{-\varphi}}. \quad (4.7)$$

3. **Fáza výpočtu chyby učenia** – v tejto fáze je vypočítaná tzv. energia výstupu neurónovej siete podľa vzťahu

$$E = \frac{1}{2} \sum_{i=1}^n (y_i - d_i)^2, \quad (4.8)$$

kde n je počet výstupných neurónov, y_i je i -ty výstup a d_i je i -ty požadovaný výstup. Táto energia je použitá ako prírastok k celkovej energii počítanej cez všetky vzory. Následne je vypočítaná chyba učenia pre výstupnú vrstvu neurónovej siete

$$\delta_i^0 = (d_i - y_i^0) \gamma y_i^0 (1 - y_i^0). \quad (4.9)$$


4. **Fáza spätného šírenia chyby** – vypočítaná chyba sa spätne šíri smerom ku vstupu neurónovej siete. Na základe vypočítanej chyby sú adaptívne menené váhy jednotlivých synaptických spojení medzi neurónmi.
5. **Ukončenie výberu vzorov z trénovacej množiny** – pokiaľ boli sieti predložené všetky vzory z trénovacej množiny, pokračuje algoritmus fázou 6. Ak nie, vracia sa späť na fázu 2 a celý postup sa znovu iteratívne opakuje.
6. **Ukončenie procesu učenia** – pokiaľ hodnota chybovej funkcie po poslednej iterácii klesla pod vopred definované minimum, sieť sa pokladá za naučenú a proces učenia je ukončený.

4.4 Lineárna regresia

Predstavuje aproximáciu zadaných hodnôt pomocou polynómu prvého rádu metódou najmenších štvorcov. Inak povedané, lineárna regresia hľadá priamku v grafe vstupného priebehu, a to takú, ktorá prechádza niekoľkými bodmi tak, aby súčet druhých mocnín odchýliek jednotlivých bodov od priamky bol minimálny. Vo všeobecnosti sa jedná o algoritmus aproximujúci priebehy funkcií so zložitým priebehom, tj. tzv. vyhladzovanie.

5 NÁVRH SYSTÉMU

5.1 Vývojový diagram



5.2 Popis systému

Navrhnutý systém pozostáva z viacerých častí, tzv. modulov, ktoré je možné vidieť v kapitole 5.1. V prvom bloku tohto systému prebieha rozdelenie záznamov jednotlivých cvičení (korpusu) na základe polohy pera (stylusu) pri vykonávaní písomno-kresliacich cvičení podľa šablóny, na záznamy pera na ploche tabletu a na záznamy pera nad plochou tabletu. Následne sú záznamy segmentované. Na základe typu cvičenia táto segmentácia prebieha dvojako. Cvičenia, ktoré pacienti vykonávajú vo viacerých ťahoch, ako sú napr. cvičenia písania slov, slovných spojení a viet (viď kapitolu 2.1.4), sú dané záznamy rozdelené na jednotlivé ťahy. Pre priebehy cvičení, ktoré pacienti vykonávajú v jednom ťahu, ako sú napr. Archimedova špirála a elipsa, je tento krok preskočený a záznamy týchto cvičení sú rozdelené na menšie časti, tzv. segmenty. V rámci diplomovej práce je rozdelenie na segmenty vykonávané metódou násobenia jednotlivých si záznamov váhovaciu postupnosťou (inak tzv. „oknom“). Viac o realizácii segmentácie vo navrhnutom systéme, viď kapitolu 6.1.2. V druhom bloku prebieha extrakcia príznakov (parametrov), podrobne popísaných v kapitole 2.3. Konkrétna realizácia výpočtu príznakov použitých vo vytvorenom systéme je rozobratá v kapitole 6.2. V treťom bloku podľa charakteru príznakov prebieha extrakcia tzv. vysokoúrovňových príznakov. Jedná sa o štatistické zhodnotenie viacdimenzionálnych príznakov, ako sú vektory a matice vo forme štatistických hodnôt ako sú medián, smerodajná odchýlka a iné. V diplomovej práci je tento proces využitý napr. pri výpočte mediánu výkonovej spektrálnej hustoty, rýchlosti písania, akcelerácie atď. Pre jednodimenzionálne príznaky, tj. skaláry, je tento proces vykonávaný za účelom štatistického zhodnotenia týchto príznakov. V štvrtom bloku systému sú tieto výsledky upravené do matice príznakov, ktorá je podrobne popísaná v kapitole 6.3, a následne vyexportované do súboru vhodného pre klasifikáciu navrhnutým modelom klasifikácie, viď prílohu B. V piatom a poslednom bloku systému, sú všetky vypočítané parametre zaradené do modelu testovania úspešnosti klasifikácie pri výbere najlepších parametrov pre jednotlivé cvičenia. Výsledkom tohto testovania je súbor parametrov, pri použití ktorých dosahuje navrhnutý systém najpresnejšiu klasifikáciu vstupných dát vo forme záznamu písomno-kresliaceho cvičenia do tried PD/H. Výstupom systému je teda natrénovaný model automatickej detekcie Parkinsonovej nemoci na základe analýzy ručne písaného prejavu.

6 PRAKTICKÁ ČASŤ

Testovanie automatickej detekcie Parkinsonovej nemoci na základe ručne písaného prejavu, je v diplomovej práci realizované v programových prostrediach programov MATLAB a RapidMiner. Testovanie prebiehalo na testovacích záznamoch získaných za pomoci neurologickej kliniky fakultnej nemocnice u sv. Anny v Brne. Konkrétne sa jednalo o záznamy 68 ľudí, z toho 32 mužov (H – 12, PD – 20) a 36 žien (H – 15, PD – 21). Jednalo sa o záznamy písomných a kresliacich cvičení podľa šablóny, viď prílohu B. Tieto záznamy boli získané s použitím digitálneho tabletu Wacom Intuos 4M, ktorého vzorkovacia frekvencia je 200 Hz. Viac o tomto procese, viď kapitolu 1.2. Dáta použité pre testovanie a následnú klasifikáciu pochádzajú jednak od pacientov klasifikovaných na prítomnosť Parkinsonovej nemoci, ako aj od zdravých ľudí. Úlohou navrhnutého systému je dané záznamy klasifikovať do týchto dvoch tried (kategórií), s čo možno najväčšou presnosťou. Testovanie a následné vytváranie natrénovaného modelu automatickej detekcie Parkinsonovej nemoci je realizované vo viacerých krokoch, podrobne popísaných v nasledujúcich podkapitolách.

6.1 Predspracovanie testovacích dát

Databáza záznamov ručne písaného prejavu použitá v diplomovej práci pozostáva zo záznamov 78 ľudí. Každému človeku bol predložený vzor šablóny písomných a kresliacich cvičení. Všetky cvičenia majú svoj vlastný záznam a sú uložené v súbore *.xml. Pred samotným výpočtom parametrov, je potrebné jednotlivé záznamy predspracovať. Jedná sa o načítanie dát z databázy a ich rozdelenie na jednotlivé cvičenia a následná segmentácia, popísaná v kapitole 2.2.

Dôležitou skutočnosťou pri testovaní navrhnutého modelu je, že dáta, sú testované zvlášť pre záznamy na osi x a pre záznamy na osi y (pre parametre diferencujúce polohu pera na osi x a na osi y). Toto je zohľadnené pri samotnom predspracovaní týchto dát vo forme segmentácie, viď nižšie, ako aj pri samotnom výpočte parametrov a následnej klasifikácii.

6.1.1 Rozdelenie na jednotlivé cvičenia

Vstupné dáta, tj. záznamy jednotlivých cvičení, sú v práci najprv načítané do programového prostredia MATLAB s použitím vytvorených *.m súborov a následne sú rozdelené na jednotlivé cvičenia. Tento proces prebieha v niekoľkých krokoch, podrobne popísaných nižšie:

- Pomocou súboru **gen_file_list.bat** je v prvom kroku vygenerovaný dokument **list.txt**, ktorý obsahuje cesty ku všetkým záznamom v testovacej z databázy. Záznamy sú typu *.svc a ich podrobný popis je uložený v súbore typu *.xml s názvom **corpus_PAR_CZ_003_writing.xml**.

- Skript **gen_database_info.m** načíta vytvorený textový súbor list.txt. Funkciou **read_SVC.m** tieto záznamy načíta do štruktúry ciest k testovacím súborom, ktorú uloží do súboru *.mat ako **test_info.mat**.
- V ďalšom kroku sú skriptom **gen_spec_list.m** vytvorené *.mat súbory ciest k jednotlivým cvičeniam (Arch. špirála, elipsy atď.). Skript najprv načíta súbor test_info.mat, vytvorený v predchádzajúcom kroku. Zo štruktúry uloženej v tomto súbore vyberie príslušnosť daného záznamu k jednotlivému cvičeniu, na základe konvencie mien jednotlivých súborov. Takýmto spôsobom sú cesty ku všetkým záznamom v databáze rozdelené na cvičenia, ktoré sú uložené do vytvorených súborov:
 - **arch_sp_list.mat**
 - **elip_list.mat**
 - **others_list.mat**
 - **sentense_list.mat**.
- V poslednom kroku tejto fázy sú funkciami **read_[cvičenie].m** vytvorené štruktúry jednotlivých cvičení. Obsahujú cesty k záznamom v štruktúre ako aj maticu záznamov všetkých pozorovaných veličín popísaných v kapitole 1.2. Konkrétne sa jedná o maticu v tvare:

[os-x][os-y][čas. razítko][poloha ON/OFF][tlak][náklon][elevácia]

Všetky tieto pozorované veličiny však v práci využité nie sú. Pre výpočet parametrov sú použité parametre, poloha pera na osi x, poloha pera na osi y a tlak pera na hrot pera. Na konci tejto fázy predspracovania sú vytvorené *.mat súbory pre jednotlivé cvičenia, konkrétne:

- **arch_sp.mat** – obsahuje záznamy cvičenia 1, tj. záznamy kresliaceho cvičenia, pri ktorom pacienti kreslili Archimedovu špirálu
- **elip.mat** – obsahuje záznamy cvičenia 2, tj. záznamy kresliaceho cvičenia, pri ktorom pacienti kreslili elipsy rýchlo cez seba.
- **others.mat** – obsahuje záznamy cvičenia 3 – 8, tj. záznamy písomných cvičení, pri ktorých pacienti písali písmená „l“, slabiky, slová a slovné spojenia.
- **sentense.mat** – obsahuje záznamy cvičenia 9, tj. záznamy písomného cvičenia, pri ktorom pacienti písali vopred určenú vetu.

6.1.2 Segmentácia jednotlivých cvičení

Po vytvorení *.mat súborov pre jednotlivé cvičenia, je potrebné tieto záznamy rozdeliť na menšie úseky, tj. segmentovať. V práci sú využité dva typy segmentácie, podrobne popísané v kapitole 2.2. Konkrétne sa jedná o tieto typy segmentácie:

- segmentácia na ťahy,
- segmentácia váhovacou postupnosťou.

Cvičenia, ktoré boli pri testovaní a vytváraní záznamov vykonávané v jedinom ťahu, ako napríklad Archimedova špirála a elipsa, nie sú v práci segmentované na ťahy. Tieto cvičenia sú segmentované len na menšie časti (segmenty), pomocou adaptívnej metódy násobenia záznamov váhovacou postupnosťou, ktorá berie na zreteľ fakt, že v každom segmente, pokiaľ to je možné musí byť zachovaná aspoň jedna perióda segmentovaného signálu. Pôvodne boli dáta segmentované tak, aby v každom segmente boli obsiahnuté minimálne dve periódy skúmaného priebehu. Testované priebehy sú však príliš krátke a výsledný počet segmentov, v závislosti na ich dĺžke, tým pádom nebol vyhovujúci. Segmentácia týchto cvičení prebieha nasledovne:

- Skriptom **perioda.m** je zistená základná perióda všetkých cvičení, ktoré sú touto metódou segmentované. Konkrétne sa jedná o už spomínaný záznam Archimedovej špirály a taktiež je touto metódou segmentovaný priebeh cvičenia, pri ktorom pacienti kreslili elipsy. Tieto priebehy, konkrétne ich x-ová a y-ová časť sú pri priemeti do roviny priebehu na osi x – čas a priebehu na osi y – čas, kvázy-periodické až periodické, viď kapitolu 2.1.1 a 2.1.2. Perióda týchto priebehov, ktorá je rovná základnej perióde, je v práci vypočítaná s využitím autokorelačnej metódy určovania základnej periódy, resp. frekvencie. V práci je na tento výpočet použitá funkcia **f0_autokor.m**. Výstupom skriptu **perioda.m** sú matice v tvare:

[perióda na osi x][perióda na osi y]

pre všetky záznamy spomínaných cvičení. Tieto matice sú následne uložené do súboru *.mat, ako **period_arch_sp** a **period_elip**.

- Po vypočítaní základnej periódy sú všetky cvičenia násobené váhovacou postupnosťou s využitím Hammingovho okna. V práci je použitá tzv. segmentácia s prekryvom jednotlivých segmentov. Prekryv je zvolený 50%. Po segmentácii sú segmentované priebehy uložené do *.mat súborov, konkrétne do súborov **arch_sp_seg.mat** a **elip_seg.mat**.

Cvičenia, ktorých vykonávanie je predpokladané vo viacerých ťahoch, sú naopak segmentované na jednotlivé ťahy pomocou funkcie **separate_strokes.m**, konkrétne sa jedná o cvičenia 3 – 9. Táto funkcia za hranicu jednotlivých ťahov predpokladá zmenu stavu polohy pera na povrchu tabletu, tj. že pacient prechádza na nový ťah pri zdvihnutí a opätovnom položení pera na plochu tabletu. Medzi týmito cvičeniami sa nachádzajú aj krátke záznamy typu „l“. Tieto záznamy sú považované za jeden ťah, a preto nie sú segmentované. Po ukončení fáze segmentácie na ťahy, sú segmentované súbory uložené do súborov typu *.mat, ako **others_seg.mat** a **sentense_seg.mat**.

Pri týchto cvičeniach je dôležité spomenúť, že keďže je za hranicu ťahov považované zodvihnutie, resp. polozenie pera na plochu tabletu, zaznamenávaná je aj poloha pera nad povrchom tabletu. Tieto dáta sú v práci taktiež použité, spolu s informáciou o polohe pera na povrchu tabletu.

6.2 Výpočet parametrov

Testovanie, resp. výpočet parametrov hodnotiacich ručne písaný prejav, je v diplomovej práci realizovaný skriptom **param_testing.m**, ktorý v prvom kroku načíta súbory typu *.mat, konkrétne záznamy segmentovaných cvičení daných typov popísaných v podkapitole 6.1.2. Následne počíta určené parametre. Po výpočte daného parametra je hodnota spätne zapísaná do štruktúry, z ktorej bol tento parameter počítaný. Na konci testovania sú tieto štruktúry opätovne uložené do jednotlivých *.mat súborov ako arch_sp_seg.mat, elip_seg.mat, others_seg.mat a sentence_seg.mat. V práci sú počítané viaceré typy parametrov popísané v nasledujúcich podkapitolách.

6.2.1 Parametre hodnotiace ručne písaný prejav

V práci sú na výpočet týchto parametrov, ktorých podrobný popis je uvedený v kapitole 3.1 vytvorené funkcie, volané v skripte param_testing.m. Konkrétne sa jedná o tieto funkcie:

- **m_f_writing.m** – jedná sa o funkciu, ktorá počíta počet ťahov za jednotku času, vid' kapitolu 3.1.1, konkrétne sekundu. Za ťah sa považuje zmena stavu ON/OFF polohy pera na tablete, popísaná v kapitole 6.1.1. Pre povahu cvičenia, sú na vstup funkcie privedené len záznamy cvičení 3 – 9, tj. others_seg.mat a sentence_seg.mat.
- **m_mov_time.m** – funkcia počítajúca celkovú dobu písania, popísanú v kapitole 3.1.2. Tento výpočet je aplikovaný na všetky záznamy cvičení, pretože sa nerozlišuje počet ťahov a ani jednotlivé segmenty, ale celkový počet vzorkov na dané cvičenie, podelený vzorkovacou frekvenciou.
- **m_s_size.m** – táto funkcia určuje výšku ťahu, vysvetlenú v kapitole 3.1.3. Opäť je pre svoju povahu aplikovaná iba na záznamy, pri ktorých má zmysel hovoriť o jednotlivých ťahoch, tj. cvičenia 3 – 9. Za výšku ťahu je považovaná y-ová súradnica jednotlivých ťahov.
- **m_s_length.m** – jedná sa o funkciu počítajúcu dĺžku jednotlivých ťahov, vid' kapitolu 3.1.4. Dĺžka ťahu je počítaná ako suma (súčet) druhých odmocnín súčtov druhých mocnín x-ových a y-ových prírastkov na úseku medzi dvoma vzorkami daného ťahu. Tak ako pre funkcie m_s_size.m a m_f_writing.m, aj pre funkciu m_s_length.m, je za vstup považované len cvičenie, pri ktorom má zmysel diferencovať jednotlivé ťahy, tj. cvičenie 3 – 9.

- **m_s_duration** – tj. dĺžka trvania ťahu, viď kapitolu 3.1.5, je funkcia počítajúca dĺžku trvania jednotlivých ťahov [s]. Za ťah považuje iba záznamy, ktoré majú viac ako určitý počet vzorkov. Je tomu tak pretože digitálny tablet použitý pre získanie záznamov zaznamenáva aj okamžik po ukončení cvičenia. Tento pohyb sa však už nepovažuje za ťah. Tento parameter je počítaný ako počet vzorkov daného ťahu, podelený vzorkovacou frekvenciou. Je opäť počítaný len pre cvičenia 3 – 9.
- **m_p_writing** – je funkcia počítajúca štatistické parametre tlaku na hrot pera pri vykonávaní písomných a kresliacich cvičení. Je použitá na všetky záznamy cvičení, tj. arch_sp_seg.mat, elip_seg.mat, other_seg.mat a sentence_seg.mat. Konkrétne počíta nasledujúce parametre:
 - strednú hodnotu
 - medián
 - maximálnu hodnotu
 - minimálnu hodnotu
 - varianciu (rozptyl)
 - smerodajnú odchýlku
 - kovarianciu
- **m_a_writing** – funkcia počíta rýchlosť písania, popísanú v kapitole 3.1.7. V práci je rýchlosť písania počítaná ako dĺžka jednotlivých ťahov delená časom (časovým razítkom). Táto funkcia považuje záznam Archimedovej špirály a elipsy za jeden ťah a taktiež ich používa ako vstup spolu so záznamami z cvičení 3 – 9. Výsledkom funkcie sú jednak vektory rýchlostí pre jednotlivé vzorky časového razítka, ako aj celková priemerná rýchlosť pre dané ťahy.
- **m_a_writing** – je funkcia počítajúca akceleráciu (zrýchlenie) písania, ktoré je podrobne popísané v kapitole 3.1.9. Tento parameter je v práci určený ako podiel rýchlosti písania daného ťahu a času. Zrýchlenie, tak ako rýchlosť písania považujú Archimedovu špirálu a elipsu za vstup funkcie a akcelerácia týchto vstupov je opäť počítaná pre jeden ťah. Výsledkom tejto funkcie sú, rovnako ako pre rýchlosť písania, vektory akcelerácií pre jednotlivé vzorky časového razítka, ako aj celková priemerná akcelerácia písania pre jednotlivé ťahy.
- **m_j_writing** – tzv. „writing jerk“, alebo inak koeficient šmyku, je parameter, ktorý vyjadruje deriváciu zrýchlenia písania podľa času. V práci je počítaný ako podiel zrýchlení písania a časového razítka. Výsledkom funkcie je opäť vektor koeficientov šmyku pre jednotlivé vzorky časového razítka, ako aj celkový priemerný koeficient šmyku pre jednotlivé ťahy. Funkcia pracuje tak ako predchádzajúce cvičenia so všetkými záznamami cvičení.

6.2.2 Parametre používané pre analýzu rečového prejavu

Tieto parametre sú v diplomovej práci riešené prostredníctvom funkcií volaných v skripte `param_testing.m`. Jedná sa o parametre, bežne využívané pri analýze rečového signálu. Pre charakter signálov, reprezentujúcich záznamy ručne písaného prejavu, je možné ich použiť podobne ako na analýzu rečového signálu. Podrobný popis parametrov použitých v práci je uvedený nižšie. Sú realizované nasledovnými funkciami:

- **m_pitch.m** – jedná sa o funkciu počítajúcu základnú periódu signálu, spomínanú v kapitole 3.2.2 a v kapitole 6.1.2, kde je základná perióda využitá pri segmentácii záznamov ručne písaného prejavu na segmenty pomocou metódy váhovacej postupnosti. Základná perióda je počítaná pre záznamy cvičení 1 a 2, teda pre záznamy Archimedovej špirály a elipsy.
- **m_lpc_coef** – je funkcia počítajúca lineárne predikčné koeficienty jednotlivých záznamov, využívajúca funkciu **lpc.m**. LPC koeficienty sú v diplomovej práci počítané pre cvičenia, ktoré bolo možné segmentovať na segmenty pomocou váhovacej postupnosti, teda pre cvičenia 1 a 2.
- **m_median_psd** – táto funkcia počíta medián výkonovej spektrálnej hustoty, viď kapitolu 3.2.4. Je určený na základe zistenia mediánu celkovej energie priebehu daného záznamu, presnejšie, ktorý vzorok signálu odpovedá vzorku, na ktorom sa nachádza hodnota mediánu výkonovej spektrálnej hustoty. Celková energia signálu je počítaná ako kumulatívny súčet energií, tj. výkonovej spektrálnej hustoty na mocninu rovnú dvom. Tento parameter však do systému po jeho testovaní zaradený nie je, pretože jednotlivé priebehy záznamov cvičení sú takmer periodické, tj. ich výkonová spektrálna hustota prudko klesá, pretože väčšina energie je sústredená v prvej harmonickej zložke signálu. Počítanie mediánu PSD teda v tomto prípade nemá zmysel. Tento parameter bol testovaný na priebehoch 1 – 8.
- **m_spec_flux** – alebo inak spektrálny tok, je parameter určujúci ako rýchlo sa výkonová spektrálna hustota skúmaného signálu mení v čase. V práci je počítaný ako suma rozdielov normalizovaných výkonových spektier predchádzajúceho a nasledujúceho vzorku na druhú. Podrobný popis tohto parametra, viď kapitolu 3.2.6. V diplomovej práci je počítaný pre záznamy cvičení 1 a 2.

Parametre ako jitter a reálne kepstrum v práci realizované nie sú. Kepstrálna analýza nie je do systému zaradená kvôli kvázy-periodickému charakteru jednotlivých záznamov, kedy z priebehu kepstra nie je poznateľná žiadna užitočná informácia, pretože takmer celý priebeh funkcie kepstra je rovný nule.

6.2.3 Parametre hodnotiace kvalitu a intenzitu signálu

Medzi tieto parametre sú v diplomovej práci zaradené parametre hodnotiace krátkodobé charakteristiky signálu ako napr. krátkodobá energia signálu. Nasledujúce parametre sú v navrhovanom systéme, tak ako predchádzajúce parametre, počítané pomocou funkcií volaných v skripte `param_testing.m`. Konkrétne sa jedná o funkcie:

- **m_energy.m** – jedná sa o funkciu počítajúcu krátkodobú energiu jednotlivých priebehov pomocou funkcie **energy.m**. Viac o krátkodobej energii, viď kapitolu 3.3.1. Tento parameter je v práci počítaný pre záznamy cvičení, ktoré sú segmentované na kratšie úseky, segmenty, tj. Archimedovu špirálu a elipsu.
- **m_intensity.m** – funkcia počítajúca krátkodobú intenzitu pomocou funkcie **intensity.m**. Je veľmi podobná krátkodobej energii a v práci bolo pri testovaní dokázané, že ich priebehy sa podobajú. Viac o krátkodobej intenzite, viď kapitolu 3.3.2. Tak ako krátkodobá energia, aj krátkodobá intenzita je v práci počítaná pre záznamy cvičení 1 a 2.
- **m_zcr.m** – jedná sa o funkciu počítajúcu krátkodobý počet prechodu signálu nulovou úrovňou popísaný v kapitole 3.3.3, pomocou funkcie **zcr.m**. Tento parameter je opäť počítaný pre záznamy cvičení 1 a 2.

6.2.4 Parametre založené na teórii chaosu

Ako zástupca tejto skupiny parametrov, je v práci je použitý parameter Fraktálna dimenzia, podrobne popísaná v kapitole 3.4.3, realizovaný funkciou **m_fractal_dim.m**. Tento parameter je počítaný pre záznamy cvičení Archimedovej špirály a elipsy.

6.3 Spracovanie parametrov

Po dokončení výpočtu parametrov popísaných v predchádzajúcich kapitolách, sú tieto parametre spätne uložené do súborov *.mat, konkrétne do segmentovaných záznamov jednotlivých cvičení, tj.

- Arch_sp_seg.mat
- Elip_seg.mat
- Others_seg.mat
- Sentence_seg.mat

Ďalším krokom pred samotnou klasifikáciou parametrov je ich spracovanie do podoby vhodnej na klasifikovanie, ktoré je v diplomovej práci realizované pomocou algoritmov, podrobne popísaných v kapitole 4. Proces klasifikácie realizovanej v diplomovej práci je podrobne popísaný v kapitole 6.4.

Spracovanie parametrov vypočítaných zo záznamov ručne písaného prejavu do podoby vhodnej na klasifikáciu navrhnutým modelom klasifikácie prebieha vo viacerých krokoch. Jedná sa o nasledujúce kroky:

- Dáta v podobe vektorov, ako napr. vektor rýchlostí písania, vektor akcelerácií atď. sú spracované s použitím štatistických parametrov popísaných v kapitole 6.1.1, pri popise tlaku na hrot pera pri vykonávaní jednotlivých písomno-kresliacich cvičení. Tie sú následne vložené do odpovedajúcich štruktúr a uložené vo forme súborov *.mat, z ktorých boli parametre načítané. Tento proces je aplikovaný na parametre všetkých záznamov segmentovaných cvičení.
- Ďalej je potrebné vytvoriť maticu záznamov jednotlivých štatistických parametrov všetkých cvičení, vykonaných všetkými pacientami a túto potom previesť do súboru vhodného na klasifikáciu.
- V súbore všetkých záznamov sa vyskytujú prípady, kedy niektorí pacienti nevykonali všetky písomné alebo kresliace cvičenia. Tieto je treba pred klasifikáciou taktiež ošetriť a klasifikovať iba záznamy cvičení, ktorých sa zúčastnili všetci pacienti.

Spomínané požiadavky, tj. výpočet štatistických parametrov, vytvorenie matice parametrov a jej následná úprava, sú v diplomovej práci realizované súbormi (*.m), konkrétne sa jedná o nasledujúce skripty, resp. funkcie:

- **patients.m** – jedná sa o skript, ktorý v prvom kroku načíta všetky potrebné súbory *.mat obsahujúce štatistické parametre všetkých cvičení. Po načítaní dát je zistený počet jednotlivých cvičení a počet všetkých parametrov. Na základe týchto hodnôt je vytvorená matica parametrov, iteratívne plnená dátami všetkých pacientov pre dané cvičenia. Matica má tvar:

```

[      ] [Label 1.1 cv. _ štat. par. ] .....
1. pacient - [PD/H] [ hodnota par. 1. pacienta ] .....
2. pacient - [PD/H] [ hodnota par. 2. pacienta ] .....
.           .           .
.           .           .
.           .           .

```

V popise matice sa ako prvý riadok používa tzv. vektor značiek (labelov) pre korešpondujúce cvičenia vo formáte:

cv[číslo cvičenia]_[subčíslo cvičenia]_[x/y]_[parameter].

Napr. cv2_4_w_a_mean je označenie pre cvičenia číslo 2, tj. záznam kresliaceho cvičenia, pri ktorom pacienti kreslili elipsy rýchlo cez seba. Podčísle 4 značí, že sa jednalo o 4. záznam elipsy (niektoré cvičenia mali viacero záznamov), x/y označuje či sa daný parameter vzťahuje pre záznam

polohy pera na osi x, alebo záznam na osi y (toto sa týka len určitých cvičení, napr. tlak na hrot pera nerozlišuje os x a y) a nakoniec `w_a_mean` je označenia pre strednú hodnotu akcelerácie písania.

Ďalej je pre klasifikáciu nutné do tejto matice zahrnúť označenia stavu pacienta, tj. či sa jedná o pacienta diagnostikovaného na Parkinsonovu nemoc (PD = Parkinson disease), alebo o zdravého človeka (H = healthy). Tieto „značky“ sú v matici umiestnené do prvého stĺpca.

Spomínaná matica je plnená iteratívne, a to tak, že skript hľadá v načítaných *.mat súboroch záznamy jednotlivých cvičení pre *i*-teho pacienta, pre konkrétne cvičenia. Ak záznam nájde, je uložený do matice. Ak nie, v matici (realizované tzv. polom „cell array“) ostáva prázdne miesto.

- **M_param.m** - skript patients.m využíva túto funkciu na správne určenia lokácie jednotlivých parametrov v matici, ako aj na dodatočné dopočítanie štatistických parametrov.

V poslednom kroku spracovania parametrov sú skriptom **post_param_proc.m** z matice odstránené riadky, tj. pacienti, ktorí nevykonali všetky cvičenia (v matici sa v danom riadku nachádzala prázdna hodnota, tzv. „empty value“) a stĺpce, tj. záznamy cvičení, ktoré obsahovali hodnoty čísel s rovnakými hodnotami, alebo počet núl daného cvičenia bol väčší ako počet ostatných hodnôt. Takto upravená matica je následne rozdelená na testovacie a trénovacie dáta, ktoré sú nakoniec spolu s maticou všetkých parametrov pomocou funkcie **cell2csv.m** prevedené do súborov *.csv vhodných na klasifikáciu navrhnutým modelom, viď kapitolu 6.4.


6.4 Klasifikácia

6.4.1 Model klasifikácie

Klasifikácia parametrov podrobne popísaných v kapitole 6.2, v diplomovej práci prebieha za pomoci programového prostredia RapidMiner. V práci bol vytvorený model klasifikácie parametrov, viď prílohu C, ktorého úlohou je s využitím zvoleného klasifikátora určiť presnosť klasifikácie vstupnej množiny dát. Vstupná množina je vždy vyberaná z matice parametrov podľa potreby testovania. Algoritmus vykonávaný testovacím modelom pozostáva z viacerých častí:


- V prvej časti klasifikácie sú dáta, resp. vstupná množina importované do modelu blokom **Read CSV** a následne rozdelené na testovacie a trénovacie dáta, rozdelené v pomere 1:3, v bloku **Split data**. Táto časť modelu je zobrazená na Obr. 6.1, kde je taktiež v pravom hornom rohu zobrazený pomer (ratio) rozdelenia vstupnej množiny dát na trénovacie a testovacie dáta. V pravom dolnom rohu je zobrazená časť importovanej množiny vstupov zobrazujúca

„labely“ indikujúce zdravotný stav pacienta, ako aj prvý načítaný parameter.




Obr. 6.1: Zobrazenie prvej časti modelu klasifikácie, tj. importovanie vstupnej množiny a jej rozdelenie na tréningovú a testovaciu množinu. V pravom okraji je zobrazené nastavenie parametra *ratio*, ktorý odpovedá pomeru veľkosti tréningovej a testovacej množiny, plus sa tu nachádza zobrazenie časti importovanej matice mapametrov s označením atribútu *label* označujúceho stav človeka, ktorý dané cvičenie vykonával, tj. PD / H.

- Trénovacia množina je v ďalšom kroku testovaná algoritmom mRMR. Tento algoritmus vykonáva tzv. predvýber parametrov najvhodnejších na klasifikáciu. Výstupom tohto bloku sú váhy jednotlivých parametrov trénovacej množiny, ktoré sú následne privedené na vstup bloku výberu parametrov, podľa spomínaných váh. Tento proces je zobrazený na Obr. 6.2. Obrázok zachytáva časť modelu, kde ako prvý vystupuje blok **mRMR-FS**, ktorý ako je spomínané vyššie vykonáva časovo menej náročný predvýber z množiny parametrov. Počet parametrov volených algoritmom mRMR, sa nastavuje premennou k , zobrazenou na obrázku (ako aj ostatné nastavenie bloku mRMR), v pravej časti obrázku. V práci je pre testovanie jednotlivých cvičení parameter k volený rovný veľkosti trénovacej množiny, resp. počtu parametrov daného cvičenia. Je tomu tak pretože niektoré cvičenia po úprave matice, tj. vynechaní cvičení kde sa nachádza viac núl ako ostatných hodnôt atď, viac vid' kapitolu 6.1, obsahujú relatívne malý počet parametrov a nie je potrebné tento počet redukovať predvýberom určitej menšej skupiny parametrov. Na obrázku je zachytený aj blok **Multiply**, ktorý nevykonáva nič iné, iba kopíruje svoj vstup na zvolený počet výstupov.




Obr. 6.2: Zobrazenie časti modelu klasifikácie, v ktorej je vykonávaný predvýber parametrov z množiny všetkých parametrov pomocou algoritmu mRMR.

- Podľa váh vypočítaných v predchádzajúcom kroku je z množiny tréovacích dát a z množiny testovacích dát vybraných k najlepších parametrov. Výber prebieha v blokoch **Select by Weight**. Zobrazenie tejto časti modelu je na Obr. 6.3. Obrázok zachytáva dvojicu blokov výberu podľa vstupných váh. Horný blok vyberá odpovedajúce parametre z množiny tréovacích dát, ktoré sú následne privedené na vstup bloku výberu parametrov. Spodný blok vykonáva výber parametrov podľa odpovedajúcich váh z množiny testovacích dát. Tie sú následne privedené na validačný blok, kde prebieha klasifikácia testovacích dát modelom naučeným z dát tréovacích. Tento proces je zobrazený a podrobne popísaný nižšie.




Obr. 6.3: Zobrazenie časti modelu klasifikácie, v ktorom prebieha výber parametrov podľa im prislúchajúcich váh, vypočítaných v bloku mRMR.

- Dáta vybrané z trénovacej množiny sú v ďalšom kroku privedené na vstup funkcie výberu najlepších parametrov (FS = feature selection). Tento blok sa skladá z blokov **Validation** (validácie) a **ProcessLog**. ProcessLog je blok logujúci (zaznamenávajúci) priebeh funkcie prebiehajúcej v bloku validácie. Validačný model sa skladá z bloku klasifikátora (na obrázku je zobrazený konkrétne klasifikátor typu, **AutoMLP** = automatic Multi-layer perceptron, resp. z bloku automatickej viacvrstvej neurónovej siete, s algoritmom spätného šírenia chyby), ktorý vykonáva učiacu časť klasifikačného procesu a s blokov **Applier** a **Performance**. V bloku Applier prebieha testovanie dát, ktoré boli v predchádzajúcom bloku súčasťou učiaceho procesu klasifikátora, konkrétne sa jedná o trénovaciu množinu dát (parametrov). Úspešnosť klasifikácie je následne zaznamenávaná blokom Performance, ktorý počíta percentuálnu úspešnosť klasifikácie vybraným parametrom, resp. skupiny parametrov. Výstupom bloku FS sú váhy jednotlivých parametrov, zachytávajúce úspešnosť klasifikácie pri ich použití. Tento proces je zobrazený na Obr. 6.4. Na obrázku je zachytený blok FS. Šípka smerujúca od bloku FS napravo zobrazuje jeho interné bloky, teda blok validácie a logovania úspešnosti tohto procesu. Šípka smerujúca od bloku validácie smerom dolu zobrazuje interné časti bloku validácie, teda zvolený klasifikátor, aplikačný blok a blok počítajúci percentuálnu úspešnosť aplikácie naučeného modelu na klasifikáciu vstupnej množiny dát.



Obr. 6.4: Zobrazenie časti modelu klasifikácie vykonávajúcej výber parametrov, podľa úspešnosti klasifikácie vstupnej množiny pri ich použití. Obrázok zachytáva interné časti bloku FS a taktiež interné časti bloku Validation, tj. časť tréningu klasifikátora a časť aplikácie natrénovaného klasifikátora na trénovaciu množinu.

- Podľa váh vypočítaných v predchádzajúcom kroku sú z množiny testovacích dát vybrané parametre, odpovedajúce najvyšším váham, vypočítaným v bloku FS. Bloky vykonávajúce túto časť navrhnutého modelu sú zhodné s blokmi použitými pri predvýbere parametrov podľa váh vypočítaných algoritmom mRMR. Jedná sa teda o bloky Select by Weights.
- Parametre, vybrané v predchádzajúcom kroku sú nakoniec použité na výslednú klasifikáciu testovacej množiny v bloku druhej validácie, zobrazenej na Obr. 6.5, ktorej výsledkom je percentuálna úspešnosť klasifikácie neznámych dát, tj. testovacej množiny, podľa parametrov vybraných z trénovacej množiny. Aplikáciu modelu klasifikácie naučeného z dát, ktoré sú výstupom bloku FS na testovaciu množinu vykonáva blok **Apply Model**. Blok performance, tak isto ako v bloku FS slúži na výpočet percentuálnej úspešnosti klasifikácie. Jeho vstupom sú výstupné dáta bloku Apply Model.



Obr. 6.5: Zobrazenie finálnej časti modelu klasifikácie parametrov, ktorá vykonáva klasifikáciu testovacej množiny pomocou modelu naučeného dátami z trénovacej množiny a vypočíta percentuálnu úspešnosť klasifikácie.

Klasifikátor zvolený pre učenie a následnú klasifikáciu bloku FS (feature selection) z dát získaných z trénovacej množiny a klasifikátor použitý pre konečnú klasifikáciu testovacej množiny naučeným modelom klasifikácie, sú pri každom testovacom cykle pre zvolený klasifikátor zhodné. Testovanie navrhnutým modelom v diplomovej práci prebieha na parametroch vypočítaných z jednotlivých cvičení, vybraných z matice parametrov, za pomoci „labelov“ popisujúcich tieto cvičenia. Cvičenia sú testované jednotlivo, ako aj po skupinách. Cieľom je získať najvyššie percento úspešnosti klasifikácie. Výsledky testovania navrhnutým modelom vid' kapitolu 6.4.2.

6.4.2 Výsledky klasifikácie

Výsledky testovania úspešnosti klasifikácie ručne písaného prejavu v závislosti na voľbe cvičenia a príslušného klasifikátora sú zobrazené v tabuľke, vid' Tab. 6.1. Dáta zobrazené v tabuľke predstavujú strednú hodnotu vypočítanú z desiatich testovacích cyklov, pre všetky cvičenia, pri výbere zvolených klasifikátorov. Dohromady teda bolo v diplomovej práci vykonaných cca. 360 testovaní úspešnosti klasifikácie navrhnutým modelom. Všetky tieto testovacie cykly prebiehali pre rovnaké nastavenia klasifikátorov určitého typu. Konkrétne sa jednalo o nastavenia (klasifikátory, ktoré v nasledujúcom zozname nie sú uvedené boli pri testovaní ponechané v pôvodnom nastavení jednotlivých parametrov):

- SVM – v práci bol zmenený parameter kernel type – radial. Ostatné parametre boli ponechané v pôvodnom nastavení, definovanom programom RapidMiner.
- kNN – v práci bol zmenený parameter k – 5, tj. algoritmus kNN pri klasifikácii používa dáta, tj znalosť zaradenia do tried od piatich tzv. „najbližších susedov“. Ostatné parametre boli ponechané v pôvodnom nastavení.

Tab. 6.1: Zobrazenie percentuálnej úspešnosti klasifikácie navrhnutým modelom klasifikácie ručne písaného prejavu. V tabuľke sú zaznamenané stredné hodnoty z desiatich testovacích cyklov $\pm$ std.

Klasif.	Úspešnosť klasifikácie [%] $\pm$ std ⁷					
Cvičenia	SVM ⁸	Auto MLP ⁹	Rand. F. ¹⁰	kNN ¹¹	Bayes. Net. ¹²	Linear. Reg. ¹³
cv. 1	63,64 $\pm$ 0,1	45,45 $\pm$ 0,1	45,45 $\pm$ 0,1	54,55 $\pm$ 0,1	45,45 $\pm$ 0,1	45,45 $\pm$ 0,1
cv. 2	72,73 $\pm$ 0,1	63,64 $\pm$ 0,1	72,73 $\pm$ 0,1	54,55 $\pm$ 0,1	45,45 $\pm$ 0,1	63,64 $\pm$ 0,1
cv. 3	45,45 $\pm$ 0,1	45,45 $\pm$ 0,1	45,45 $\pm$ 0,1	54,55 $\pm$ 0,1	45,45 $\pm$ 0,1	54,55 $\pm$ 0,1
cv. 4	54,55 $\pm$ 0,1	45,45 $\pm$ 0,1	45,45 $\pm$ 0,1	54,55 $\pm$ 0,1	45,45 $\pm$ 0,1	45,45 $\pm$ 0,1
cv. 5	54,55 $\pm$ 0,1	54,55 $\pm$ 0,1	72,73 $\pm$ 0,1	81,82 $\pm$ 0,1	54,55 $\pm$ 0,1	72,73 $\pm$ 0,1
cv. 6	54,55 $\pm$ 0,1	54,55 $\pm$ 0,1	54,55 $\pm$ 0,1	81,82 $\pm$ 0,1	63,64 $\pm$ 0,1	72,73 $\pm$ 0,1
cv. 7	72,73 $\pm$ 0,1	72,73 $\pm$ 0,1	63,64 $\pm$ 0,1	54,55 $\pm$ 0,1	63,64 $\pm$ 0,1	54,55 $\pm$ 0,1
cv. 8	63,64 $\pm$ 0,1	63,64 $\pm$ 0,1	81,82 $\pm$ 0,1	81,82 $\pm$ 0,1	54,55 $\pm$ 0,1	54,55 $\pm$ 0,1
spolu ¹⁴	72,73 $\pm$ 0,1	72,73 $\pm$ 0,1	63,64 $\pm$ 0,1	72,73 $\pm$ 0,1	54,55 $\pm$ 0,1	72,73 $\pm$ 0,1
*Cvičenie č. 9 bolo v rámci post-processingu odstránené, vid' kapitolu 6.3.						

⁷ Std = tzv. „Standard deviation“, tj. smerodajná odchylka

⁸ SVM = tzv. „Support vector machine“, tj. metóda podporných vektorov

⁹ Auto MLP = tzv. „automatic Multi-layer perceptron“, tj. automatická viacvrstvá neurónová sieť

¹⁰ Rand. F. = tzv. „Random Forest“, tj. klasifikácia stromovou štruktúrou, tzv. „Náhodným lesom“


¹¹ kNN = tzv. „k-Nearest neighbours“, tj. metóda k najbližších susedov

¹² Bayes. Net = tzv. „naive Bayes network“, tj. Bayesova sieť

¹³ Linear. Reg. = tzv. „Linear Regresion“, tj. Lineárna regresia

¹⁴ Spolu = cvičenia cv. 1 – cv. 8 dohromady, tj. celá matica parametrov (výstup post-processingu)

Na obrázku, vid' Obr. 6.6 sú graficky zobrazené dáta z tabuľky Tab. 6.1. Z grafu na Obr. 6.6 a tabuľky Tab. 6.1 je možné vidieť, že najvyššia percentuálna úspešnosť klasifikácie navrhnutým modelom klasifikácie nepresahuje 80%.



Obr. 6.6: Zobrazenie percentuálnej úspešnosti klasifikácie navrhnutým modelom pre jednotlivé písomno-kresliace cvičenia pri výbere zvolených klasifikátorov. Graf odpovedá hodnotám uvedeným v tabuľke, vid' Tab. 6.2.

Úspešnosti klasifikácie jednotlivých klasifikátorov sú uvedené v tabuľke, vid' Tab. 6.2, ako stredné hodnoty klasifikácie všetkých cvičení pri použití jednotlivých klasifikátorov. Z tabuľky je vidno, že celková úspešnosť klasifikácie, rovná aritmetickému priemeru úspešnosti všetkých zvolených klasifikátorov, nepresahuje 60,44%. Priemerná hodnota úspešnosti klasifikácie zvolených parametrov je približne 59,83%. Z tabuľky je taktiež vidieť, že najvyššiu úspešnosť klasifikácie dát mali algoritmy kNN (66,67 %), algoritmus SVM (63,64 %) a algoritmus Random Forest (60,61 %).


Tab. 6.2: Zobrazenie percentuálnej úspešnosti klasifikácie jednotlivých klasifikátorov. Hodnoty odpovedajú aritmetickému priemeru dát uvedených v tabuľke Tab. 6.1.

Zvolený klasifikátor	SVM	Auto MLP	Rand. F.	kNN	Bayes. N.	Lin. Reg.
Úspešnosť k. [%]	63,64	57,58	60,61	66,67	53,54	60,60

V tabuľke Tab. 6.3 sú uvedené percentuálne úspešnosti klasifikácie jednotlivých cvičení zvolenými klasifikátormi. Dáta z tabuľky Tab. 6.2 a Tab. 6.3 sú zobrazené na obrázku, vid' Obr. 6.7.

Tab. 6.3: Zobrazenie percentuálnej úspešnosti klasifikácie pacientov na základe zvolených cvičení pre všetky klasifikátory. Hodnoty v tabuľke odpovedajú aritmetickému priemeru dát uvedených v tabuľke Tab. 6.1.

Cvičenia	Úspešnosť k. ¹⁵ [%]
cv. 1	49,99
cv. 2	62,12
cv. 3	48,49
cv. 4	48,49
cv. 5	66,67
cv. 6	65,32
cv. 7	65,16
cv. 8	69,70
spolu	68,19
Celková úspešnosť	59,83



Obr. 6.7: Zobrazenie úspešnosti klasifikácie: a) jednotlivých cvičení zvolenými klasifikátormi; b) jednotlivých klasifikátorov pre všetky cvičenia.

¹⁵ Úspešnosť klasifikácie, viac vid' tabuľku Tab. 6.1

V tabuľke Tab. 6.4 sú zobrazené najsignifikantnejšie parametre, ktoré algoritmus FS (feature selection) vybral ako najvhodnejšie pri výsledkoch klasifikácie s najvyššou percentuálnou úspešnosťou.

Tab. 6.4: Zobrazenie najsignifikantnejších parametrov, ktoré navrhnutý systém klasifikácie zvolil ako najvhodnejšie pre jednotlivé cvičenia pri testovaní nastavenými klasifikátormi.

Klasif.	Najsignifikantnejšie parametre daných cvičení		
Cvičenia	1.	2.	3.
cv. 1	STE ¹⁶ _os χ _stred. h.	w. press. ¹⁷ _stred. h.	spec. flux ¹⁸ _os y _max. h.
cv. 2	LPC ¹⁹ _os y _std.	w. press._std.	s. length ²⁰ _var.
cv. 3	w. press._stred. h.	w. freq. ²¹ _stred. h.	w. press._var.
cv. 4	w. vel. ²² _stred. h.	w. jerk ²³ _max. h.	w. press._stred. h.
cv. 5	mov. time ²⁴ _stred. h.	w. vel._stred. h.	w. freq._stred. h.
cv. 6	w. vel._stred. h.	w. press._stred. h.	w. accel ²⁵ _stred. h.
cv. 7	w. press._std.	w. freq._var.	w. press._stred. h.
cv. 8	w. vel._stred. h.	w. press._stred. h.	w. press._std.
spolu	cv. 2_LPC_os y _stred. h. cv. 1_w. vel._stred. h.	cv. 1_pitch ²⁶ _os χ _max. h. cv. 2_s. length_median	cv. 8_w. jerk_stred. h. cv. 2_s. length_var.
*Cvičenie č. 9 bolo v rámci post-processingu odstránené, viď kapitolu 6.3.			

V tabuľke Tab. 6.4 uvedené najsignifikantnejšie parametre sú tvorené pomocou nasledujúcej notácie, platnej pre celú tabuľku:

[cvičenie]_[parameter]_[os x/y]_[štatistický parameter]

Notácia štatistických parametrov v tabuľke:

- stred. h. – stredná hodnota (aritmetický priemer)
- std. – smerodajná odchylka
- max. h. – maximálna hodnota
- var. – variácia (rozptyl)
- median – medián (prostredný prvok množiny)

¹⁶ STE = tzv. „Short-time energy“, tj. krátkodobá energia

¹⁷ W. press. = tzv. „Writing pressure“, tj. tlak na hrot pera

¹⁸ Spec. Flux = tzv. „Spectral flux“, tj. spektrálny tok

¹⁹ LPC = tzv. „Linear predictive coefficients“, tj. Lineárne predikčné koeficienty

²⁰ S. length = tzv. „Stroke length“, tj. dĺžka ťahu

²¹ W. freq. = tzv. „Writing frequency“, tj. frekvencia písania

²² W. vel. = tzv. „Writing velocity“, tj. rýchlosť písania

²³ W. jerk = tzv. „Writing jerk“, tj. koeficient šmyku

²⁴ Mov. Time = tzv. „Movement time“, tj. celková doba písania

²⁵ W. accel = tzv. „Writing acceleration“, tj. akcelerácia (zrýchlenie) písania

²⁶ Pitch = tzv. „Pitch“, tj. základná perióda

7 ZÁVER

Cieľom diplomovej práce bol rozbor aktuálnej problematiky analýzy ručne písaného prejavu a návrh a implementácia diagnostického systému Parkinsonovej nemoci na základe analýzy ručne písaného prejavu. V práci bol navrhnutý systém, implementovaný v programových prostrediach MATLAB a RapidMiner. Jedná sa o systém, ktorého úlohou je načítať jednotlivé záznamy ručne písaného prejavu, spracovať ich do podoby vhodnej na segmentáciu, následne tieto záznamy segmentovať pomocou viacerých metód a pomocou viacerých kritérií. Konkrétne sa jedná o segmentáciu záznamov na záznamy obsahujúce polohu pera na povrchu tabletu a na záznamy obsahujúce polohu pera nad plochou tabletu, segmentáciu na jednotlivé ťahy a segmentáciu násobením váhovacou postupnosťou. Systém následne počíta parametre analyzujúce ručne písaný prejav. Tieto parametre sú ďalej podrobené štatistickej analýze a sú upravené do podoby vhodnej na klasifikáciu. Za týmto účelom bolo v rámci diplomovej práce naprogramovaných celkovo 32 funkcií realizujúcich parciálne operácie nutné pre funkcionality navrhnutého systému. Tieto funkcie boli volané piatimi vytvorenými skriptami.

Po extrakcii parametrov ručne písaného prejavu sú tieto parametre klasifikované navrhnutým modelom klasifikácie. Jedná sa o model počítajúci percentuálnu úspešnosť klasifikácie pri voľbe najvhodnejších parametrov pre zvolený klasifikátor. Výsledkom klasifikácie bola celková úspešnosť správneho zaradenia záznamu ručne písaného prejavu do tried (PD/H) rovná 60,44%. Ako najvhodnejšie cvičenie pre klasifikáciu sa ukázalo cvičenie číslo 8, ktorého percentuálna úspešnosť klasifikácie sa rovnala 69,70%. Toto zistenie podporuje predpoklad, že komplexnejšie motorické pohyby, tj. písanie napr. slovných spojení a viet obsahuje najviac informácie o jednotlivých pohyboch pri vykonávaní tohto cvičenia a to aj v rámci množstva informácie o polohe pera nad plochou tabletu, ktorá sa ukázala ako významný faktor rozlišujúci ručne písaný prejav zdravých ľudí a pacientov trpiacich Parkinsonovou nemocou. Najmenej vhodným cvičením sa ukázalo cvičenie číslo 3 a 4, s úspešnosťou správneho zaradenia vybranými klasifikátormi rovnou 48,48%. Z klasifikátorov sa ako najvhodnejší preukázal algoritmus kNN a SVM, s percentuálnou úspešnosťou klasifikácie 66,67% a 63,64%.

V rámci diplomovej práce taktiež boli preštudované štatistické hodnoty jednotlivých parametrov počítaných pre záznamy písomno-kreliacich cvičení, získaných zo šablóny uvedenej v prílohe B. Bolo zistené, že pacienti diagnostikovaní na výskyt Parkinsonovej nemoci píšú s omnoho väčšou variáciou počtu ťahov za sekundu, odpovedajúcej rýchlosti písania jednotlivých ťahov. Ich celková doba vykonávania písomných cvičení je podstatne vyššia ako u zdravých ľudí. Tento fakt odpovedá výskytu Bradykinézie, ako jedného z významných doprovodných javov Parkinsonovej nemoci. Pri pozorovaní písomného prejavu týchto pacientov je vidieť podstatne vyšší rozptyl dĺžky ťahu a to najmä pri pohyboch nad plochu tabletu, tj., pri prechode na nový ťah. Tento fakt podporuje predpoklad zvýšenej hladiny tremoru pri kľudovom stave

písomného prejavu. Pacienti trpiaci Parkinsonovou nemocou majú v dôsledku motorickej dysfunkcie pohybového aparátu taktiež sklony ku značne zvýšenému tlaku na hrot pera spôsobeného zvýšenou hladinou svalového tonusu. Pri testovaní tohto parametra sa spomínaný jav prejavil u všetkých cvičení. Ďalej boli testované parametre rýchlosti, zrýchlenia písania a tzv. koeficientu šmyku, ktoré popisujú plynulosť písomného prejavu. Bolo zistené, že pacienti s Parkinsonovou nemocou vykazujú menšiu rýchlosť vykonávania jednotlivých cvičení v kombinácii s vyššou smerodajnou odchýlkou spomínaných parametrov, ktorá odpovedá menšej plynulosti písomného prejavu. Ďalej bolo zistené, že pacienti v dôsledku menšej automatizovanosti písomného prejavu, spolu s pôsobením ďalších väd písma vykazujú podstatne vyššie hodnoty spektrálneho toku, čo odpovedá zmene spektra signálu v čase vykonávania cvičenia, tj. zmene základnej frekvencie písania jednotlivých ťahov.

Práca v tejto oblasti, tj. diagnostiky Parkinsonovej nemoci na základe analýzy ručne písaného prejavu, by sa do budúcnosti mala zamerať na výber ďalších parametrov, ktoré by dokázali komplexnejšie pokryť motorické dysfunkcie vyskytujúce sa v ručne písanom prejave pacientov s Parkinsonovou nemocou. Mohlo by sa jednať o kombináciu parametrov popisujúcich plynulosť pohybu, ako napr. spektrálny tok, parametrov hodnotiacich hladinu Bradykinézie, ako je celková doba písania, parametrov popisujúcich hladinu tremoru, ako je napr. výška ťahu pri prechode na nový ťah alebo napr. parametrov hodnotiacich tlak na hrot pera počas vykonávania jednotlivých písomno-kresliacich cvičení. Ďalším krokom zlepšenia percentuálnej úspešnosti klasifikácie by mohlo byť otestovanie väčšieho množstva klasifikátorov, poprípade návrh nových písomných alebo kresliacich cvičení.

LITERATÚRA

- [1] Agostino, R.; Berardelli, A.; Formica, A.; Accornero, N.; Manfredi, M.: Sequential Arm Movements in Patients with Parkinson's Disease, Huntington's Disease and Dystonia. *Brain*, roč. 115, č. 5, 1992: s. 1481–1495.
- [2] Albert, D.; Opwis, K.; Regard, M.: Effect of Drawing Hand and Age on Figural Fluency: A Graphomotor Study with the Five-Point Test in Children. *Child Neuropsychology*, roč. 16, č. 1, 2009: s. 32–41.
- [3] Balas, I.; Llumiguano, C.; Doczi, T.: Ablative Stereotactic Surgery Improves Manual Performance Time in Parkinson's Disease. *Parkinsonism & Related Disorders*, roč. 12, č. 4, 2006: s. 223–227, ISSN 1353-8020.
- [4] Balík, M.: Číslicové zpracování akustických signálů, Skripta FEKT VUT v Brně, 2007
- [5] Bidet-Ildei, C.; Pollak, P.; Kandel, S.; Fraix, V.; Orliaguet, J.-P.: Handwriting in Patients with Parkinson Disease: Effect of L-dopa and Stimulation of the Sub-thalamic Nucleus on Motor Anticipation. *Human Movement Science*, roč. 30, č. 4, 2011: s. 783–791.
- [6] Caligiuri, M. P.; Teulings, H.-L.; Filoteo, J. V.; Song, D.; Lohr, J. B.: Quantitative Measurement of Handwriting in the Assessment of Drug-induced Parkinsonism. *Human Movement Science*, roč. 25, 2006: s. 510–522, ISSN 0167-9457.
- [7] ČERNOCKÝ, J. *Zpracování řečových signálů*. Ústav počítačové grafiky a multimédií, FIT, VUT Brno, 2006.
- [8] Dementia Guide [online]. Dostupné z :
<http://www.dementiaguide.com/symptomlibrary/memorylanguage/writing/description/>
- [9] Eichhorn, T. E.; Gasser, T.; Mai, N.; Marquardt, C.; Arnold, G.; Schwarz, J.; Oertel, W. H.: Computational Analysis of Open Loop Handwriting Movements in Parkinson's Disease: A Rapid Method to Detect Dopamimetic Effects. *Movement Disorders*, roč. 11, č. 3, 1996: s.289–297, ISSN 1531-8257.
- [10] Gallucci, R. M.; Phillips, J. G.; Bradshaw, J. L.; Vaddadi, K. S.; Pantelis, C.: Kinematic Analysis of Handwriting Movements in Schizophrenic Patients. *Biological Psychiatry*, roč. 41, č. 7, 1997: s. 830–833, ISSN 0006-3223.

- [11] Gangadhar, G.; Joseph, D.; Srinivasan, A.; Subramanian, D.; Shivakeshavan, R.; Shobana, N.; Chakravarthy, V.: A Computational Model of Parkinsonian Handwriting that Highlights the role of the indirect pathway in the basal ganglia. *Human Movement Science*, roč. 28, č. 5, 2009: s. 602–618, ISSN 0167-9457.
- [12] GHAZALEH, V.; Farshad, A.; Roozbeh, B.: Pathological assessment of patients' speech signals using nonlinear dynamical analysis. *Computers in Biology and Medicine*, 2010: s. 50–64.
- [13] Gemmert, A.; Teulings, H.-L.; Contreras-Vidal, J.; Stelmach, G.: Parkinsons Disease and the Control of Size and Speed in Handwriting. *Neuropsychologia*, roč. 37, č. 6, 1999: s. 685–694, ISSN 0028-3932.
- [14] Gerontologie [online]. Dostupné z : <http://www.gerontologie.cz/showdoc.do?docid=25>
- [15] Hepp-Reymond, M.-C.; Chakarov, V.; Schulte-Monting, J.; Huehe, F.; Kristeva, R.: Role of Proprioception and Vision in Handwriting. *Brain Research Bulletin*, roč. 79, č. 6, 2009: s. 365–370, ISSN 0361-9230.
- [16] Huntingtonova nemoc [online]. Dostupné z: <http://nemoci.vitalion.cz/huntingtonova-nemoc/>
- [17] Jansen, schizofrénia [online]. Dostupné z : http://www.janssen-cilag.sk/disease/detail.jhtml?itemname=schizophrenia_about
- [18] JIRSÍK, Václav, HRÁČEK, Petr. *Neuronové systémy, expertní systémy a rozpoznávání řeči*. Brno : [s.n.], 2000. 106 s. Skriptum FEKT VUT v Brně.
- [19] JUHÁR, J. *Spracovanie signálov v systémoch automatického rozpoznávania reči*. Ha-bilitačná práca, Katedra elektrotechniky a multimediálnych telekomunikácií, FEI, Technická univerzita v Košiciach, 1999.
- [20] Lepelley, M.-C.; Thullier, F.; Bolmont, B.; Lestienne, F. G.: Age-related Differences in Sensorimotor Representation of Space in Drawing by Hand. *Clinical Neurophysiology*, roč. 121, č. 11, 2010: s. 1890–1897, ISSN 1388-2457.
- [21] Liu, X.; Carroll, C. B.; Wang, S.-Y.; Zajicek, J.; Bain, P. G.: Quantifying Drug-induced Dyskinesias in the Arms Using Digitised Spiral-drawing Tasks. *Journal of Neuroscience Methods*, roč. 144, č. 1, 2005: s. 47–52, ISSN 0165-0270.
- [22] Louis, E. D.; Yu, Q.; Floyd, A. G.; Moskowitz, C.; Pullman, S. L.: Axis is a Feature of Handwritten Spirals in Essential Tremor. *Movement Disorders*, roč. 21, č. 8, 2006: s. 1294–1295, ISSN 1531-8257.

- [23] Manfredi C.; D’Aniello M.; Brusciaglioni P.: Acoustic measure of noise energy in vocal folds operated patients. Electronic Engineering Dept, Univ. of Florence, 50139, Florence, Italy.
- [24] Mergl, R.; Tigges, P.; Schroter, A.; Moller, H.-J.; Hegerl, U.: Digitized Analysis of Handwriting and Drawing Movements in Healthy Subjects: Methods, Results and Perspectives. *Journal of Neuroscience Methods*, roč. 90, č. 2, 1999: s. 157–169, ISSN 0165-0270.
- [25] Morris, J. C.; Storandt, M.; Miller, J. P.; McKeel, D. W.; Price, J. L.; Rubin, E. H.; Berg, L.: Mild Cognitive Impairment Represents Early-Stage Alzheimer Disease. *Arch Neurol*, roč. 58, č. 3, 2001: s. 397–405.
- [26] Ondo, W. G.; Satija, P.: Withdrawal of Visual Feedback Improves Micrographia in Parkinson’s Disease. *Movement Disorders*, roč. 22, č. 14, 2007: s. 2130–2131, ISSN 1531-8257.
- [27] Onset detection and spectral flux [online]. Dostupné z URL: <http://www.badlogicgames.com/wordpress/?p=161>
- [28] Petersen, R. C.; Smith, G. E.; Waring, S. C.; Ivnik, R. J.; Tangalos, E. G.; Kokmen, E.: Mild Cognitive Impairment: Clinical Characterization and Outcome. *Arch Neurol*, roč. 56, č. 3, 1999: s. 303–308.
- [29] PHARMA NEWS [online]. Dostupné z : http://pharmanews.cz/2006_05/parkinson.html
- [30] PSUTKA, J. Komunikace s počítačem mluvenou řečí. 1. vydání. Praha: Academia, 1995. 287 s. ISBN 80-200-0203-0
- [31] PSUTKA, Josef, et al. Mluvíme s počítačem česky. Praha: ACADEMIA, 2006. 752 s. ISBN 80-200-1309-1.
- [32] Quatieri, Thomas F. Discrete-time Speech Signal Processing Principles and Practice. Upper Saddle River: Prentice Hall PTR, 2001. Print.
- [33] Schneider, A.; Baur, B.; Furholzer, W.; Jasper, I.; Marquardt, C.; Hermsdorfer, J.: Writing Kinematics and Pen Forces in Writer’s Cramp: Effects of Task and Clinical Subtype. *ClinicalNeurophysiology*, roč. 121, č. 11, 2010: s. 1898–1907, ISSN 1388-2457.
- [34] Siebner, H. R.; Ceballos-Baumann, A.; Standhardt, H.; Auer, C.; Conrad, B.; Alesch, F.: Changes in Handwriting Resulting from Bilateral High-frequency Stimulation of the Subthalamic Nucleus in Parkinson’s Disease. *Movement Disorders*, roč. 14, č. 6, 1999: s. 964–971, ISSN 1531-8257
- [35] SMÉKAL, Z. Číslicové zpracování řeči (MZPR). Elektronická skripta pro magisterská studia, Ústav telekomunikací, FEEC, VUT Brno, 2009.

- [36] SMÉKAL, Z. *Číslicové zpracování signálů* (MCSI). Elektronická skripta pro magisterská studia, Ústav telekomunikací, FEEC, VUT Brno, 2009.
- [37] SMÉKAL, Z., a SYSEL P. *Číslicové filtry* (BCIF). Elektronická skripta pro bakalářská studia, Ústav telekomunikací, FEEC, VUT Brno, 2004.
- [38] SMÉKAL, Z., a Šebesta V. *Signály a soustavy* (BASS). Elektronická skripta pro bakalářská studia, Ústav telekomunikací], FEEC, VUT Brno, 2010.
- [39] Teulings, H. L.; Contreras-Vidal, J. L.; Stelmach, G. E.; Adler, C. H.: Parkinsonism Reduces Coordination of Fingers, Wrist, and Arm in Fine Motor Control. *Experimental Neurology*, Roč. 146, č. 1, 1997: s. 159–170.
- [40] Teulings, H.-L.; Contreras-Vidal, J. L.; Stelmach, G. E.; Adler, C. H.: Adaptation of Handwriting Size Under Distorted Visual Feedback in Patients with Parkinson's Disease and Elderly and Young Controls. *Journal of Neurology, Neurosurgery & Psychiatry*, roč. 72, č. 3, 2002: s. 315–324.
- [41] Tucha, O.; Mecklinger, L.; Thome, J.; Reiter, A.; Alders, G. L.; Sartor, H.; Naumann, M.; Lange, K. W.: Kinematic Analysis of Dopaminergic Effects on Skilled Handwriting Movements in Parkinson's Disease. *Journal of Neural Transmission*, roč. 113, 2006: s. 609–623, ISSN 0300-9564.
- [42] Unlu, A.; Brause, R.; Krakow, K.: Handwriting Analysis for Diagnosis and Prognosis of Parkinson's Disease. In *Proceedings of the 7th international conference on Biological and Medical Data Analysis*, ISBMDA'06, Springer-Verlag, 2006, ISBN 3-540-68063-2, 978-3-540-68063-5, s. 441–450.
- [43] van Drempt, N.; McCluskey, A.; Lannin, N. A.: A Review of Factors that Influence Adult Handwriting Performance. *Australian Occupational Therapy Journal*, roč. 58, č. 5, 2011: s. 321–328, ISSN 1440-1630.
- [44] van Drempt, N.; McCluskey, A.; Lannin, N. A.: Handwriting in Healthy People Aged 65 Years and Over. *Australian Occupational Therapy Journal*, roč. 58, č. 4, 2011: s. 276–286, ISSN 1440-1630.
- [45] VONDRA, M. Souhrnné keprstrální modely pro syntézu TTS. FEI VUT v Brně, 2001. 78 s. Vedoucí diplomové práce prof. Ing. Zdeněk Smékal, CSc.
- [46] Wacom intuos oficiální web stránka [online]. Dostupné z URL: <http://scr3.golem.de/?d=0903/wacom-intuos4&a=66119&s=1>
- [47] Wang, H.; Yu, Q.; Kurtis, M. M.; Floyd, A. G.; Smith, W. A.; Pullman, S. L.: Spiral analysis – Improved Clinical Utility with Center Detection. *Journal of Neuroscience Methods*, roč. 171, č. 2, 2008: s. 264–270, ISSN 0165-0270.

- [48] Westin, J.; Ghiamati, S.; Memedi, M.; Nyholm, D.; Johansson, A.; Dougherty, M.; Groth, T.: A New Computer Method for Assessing Drawing Impairment in Parkinson's Disease. *Journal of Neuroscience Methods*, roč. 190, č. 1, 2010: s. 143–148, ISSN 0165-0270.
- [49] Wikipedia: The Free Encyclopedia: Window function [online]. 2007 [cit. 8. 11. 2007]. Dostupné z URL: http://en.wikipedia.org/wiki/Window_function
- [50] Yan, J. H.; Rountree, S.; Massman, P.; Doody, R. S.; Li, H.: Alzheimer's Disease and Mild Cognitive Impairment Deteriorate Fine Movement Control. *Journal of Psychiatric Research*, roč. 42, č. 14, 2008: s. 1203–1212, ISSN 0022-3956.

ZOZNAM SYMBOLOV, VELIČÍN A SKRATIEK

$\mathbb{R}$	množina reálnych čísiel
AE	aproximačná entropia
CD	korelačná dimenzia
DFT	diskrétna Fourierova transformácia
FD	fraktálna dimenzia
FFT	rýchla Fourierova transformácia
GMM	Gaussov zmiešaný model
HNR	harmonicita signálu
kNN	klasifikujúci algoritmus, tzv. najbližších susedov
LLE	najväčší Laypunov exponent
LPC	lineárna predikčná analýza
MPSD	medián výkonovej spektrálnej hustoty
MT	celková doba písania
NCA	počet zmien akcelerácie
NCV	počet zmien rýchlosti písania
NNE	normalizovaná energia šumu
PSD	výkonová spektrálna hustota
SD	doba trvania ťahu
SF	počet ťahov za sekundu
SL	dĺžka ťahu
SPECF	spektrálny tok
SS	výška ťahu
STAF	krátkodobá autokorelačná funkcia
STE	krátkodobá energia
STI	krátkodobá intenzita
SVM	metóda podporných vektorov
WA	akcelerácia písania

WJ	koeficient šmyku
WP	tlak na hrot pera
WV	rýchlosť písania
ZCR	počet prechodov signálu nulovou úrovňou
$A(z)$	prenosová funkcia analyzujúceho filtra
a	konštanta definujúca tvar Archimedovej špirály
a_p	lineárne predikčné koeficienty
$c[n]$	reálne kepstrum
$\hat{c}[n]$	komplexné kepstrum
$c_m(r)$	korelačný integrál
$d(m)$	odhadovaná dimenzia
E	krátkodobá energia signálu
E	štatistická stredná hodnota
$E(z)$	Z-transformácia chyby doprednej lineárnej predikcie
e	Eulerovo číslo ($e = \sum_{n=0}^{\infty} \frac{1}{n!} = 2.71828 \dots$)
$e[n]$	chyba doprednej lineárnej predikcie
F_0	základná frekvencia
F_1	ohnisko elipsy
F_2	ohnisko elipsy
$\hat{f}[n]$	inverzná diskretná Fourierova transformácia funkcie $\hat{F}[k]$
$F[k]$	diskretná Fourierova transformácia signálu $f[n]$
$\hat{F}[k]$	prirodzený logaritmus funkcie $F[k]$
$f[n]$	vstupný signál homomorfnej dekonvolúcie
f_k	k -ty frekvenčný bod, v ktorom bude počítaný periodogram
f_p	frekvencia tremoru u pacientov trpiacich Parkinsonovou nemocou
f_{vz}	vzorkovacia frekvencia [Hz]
$G[k]$	diskretná Fourierova transformácia signálu $g[n]$
$\hat{G}[k]$	prirodzený logaritmus funkcie $G[k]$

$g[n]$	vstupný signál homomorfnej dekonvolúcie
$\hat{g}[n]$	inverzná diskretná Fourierova transformácia funkcie $\hat{G}[k]$
$H(z)$	prenosová funkcia tzv. bieliaceho filtra
I	krátkodobá intenzita signálu
j	imaginárna jednotka
J	kolísanie základnej frekvencie signálu
K	veľkosť trénovacej množiny algoritmu kNN
L	počet po sebe idúcich segmentov
l_x	vzdialenosť bodu od referenčného bodu na osi x
l_y	vzdialenosť bodu od referenčného bodu na osi y
N	počet frekvenčných bodov periodogramu
N_L	spodná hranica iteratívneho hľadania NNE
N_H	horná hranica iteratívneho hľadania NNE
N_{FFT}	počet bodov FFT
n_a	rád Archimedovej špirály
$P_{xx}(e^{j\omega})$	periodogram
$\tilde{P}_{xx}^{(i)}(e^{j2\pi f})$	modifikovaný periodogram
$P_{xx}^w(e^{j2\pi f})$	odhad PSD pomocou Welchovej metódy
p	rád prediktora
$p(k)$	iteratívna premenná najväčšieho Laypunovhoexponentu
$R(m)$	krátkodobá autokorelačná funkcia
r	rádus okolia zhľuku bodov pri hľadaní korelačného integrálu
r_a	polomer Archimedovej špirály
r_l	spodná hranica lineárnej časti priebehu smernice $c_m(r)$
r_h	spodná hranica lineárnej časti priebehu smernice $c_m(r)$
$r_i[n]$	i -ty segment počítaný v dvojfázovej automatickej segmentácii
$r_{xx}[m]$	autokorelačná postupnosť pre výpočet periodogramu
S_0	normalizačný faktor pri výpočte spektrálneho toku
$S(e^{j\omega})$	spektrum pôvodného signálu
$S_{\text{flux}}(k)$	spektrálny tok k -teho segmentu

$S[k]$	diskrétna Fourierova transformácia signálu $s[n]$
$\hat{S}[k]$	prirodzený logaritmus funkcie $S[k]$
$\text{sign}(x)$	funkcia signum
slope	smernica priebehu
$s[n]$	signál v časovej oblasti
$\tilde{s}[n]$	predikovaná vzorka signálu pomocou LPC
$\hat{s}[n]$	inverzná diskretná Fourierova transformácia funkcie $\hat{S}[k]$
t	čas [s]
U	normalizačný koeficient modifikovaného periodogramu
v_1	rýchlosť [$\text{m} \cdot \text{s}^{-1}$]
v_2	rýchlosť [$\text{m} \cdot \text{s}^{-1}$]
$W(e^{j\omega})$	spektrum váhovacej postupnosti
$\bar{w}$	vektor synaptických váh umelej neurónovej siete
$w[n]$	váhovacia postupnosť
$w[n - im]$	váhovacia postupnosť posunutá o im vzoriek
$X(e^{j\omega})$	spektrum vstupného signálu $x[n]$
x	bod sledovaného priebehu na osi x
x_0	referenčný bod na osi x
x_i	i -ty vzor v procese klasifikácie prostredníctvom kNN
$\bar{x}$	vstupné signály umelej neurónovej siete
$x[n]$	vstupný signál pre výpočet autokorelačnej postupnosti
$x^*[n]$	komplexne združený vstupný signál $x[n]$
$Y(e^{j\omega})$	spektrum segmentovaného signálu
y	bod sledovaného priebehu na osi y
y_0	referenčný bod na osi y
$y_{\text{perceptron}}$	výstup perceptronu
Z	Z-transformácia
Z^{-1}	spätná Z-transformácia
Z_{cr}	krátkodobá stredná hodnota prechodov signálu nulovou úrovňou

λ_1	najväčší Laypunov exponent
$\mathbf{\Gamma}_p$	Toeplitzovská matica autokorelačných koeficientov
$\mathcal{H}$	transcendentálna funkcia používaná pri homomorfnej filtrácii
ϵ_p^e	chyba doprednej lineárnej predikcie v normovanom tvare
γ_p	autokorelačné koeficienty
π	Ludolphovo číslo $\left(\pi = 4 \sum_{n=0}^{\infty} \frac{(-1)^n}{2n+1} = 3.14159 \dots\right)$
θ	uhol Archimedovej špirály [rad] / prah perceptronu
$\theta(x)$	Heavisideova funkcia
ω	uhlová frekvencia [rad·s ⁻¹]
ω_i	i -ta trieda priradená algoritmom kNN

ZOZNAM PRÍLOH


A	OBSAH PRILOŽENÉHO DVD	97
B	VZOR VYPLNENEJ ŠABLÓNY PRE PÍSOMNÉ CVIČENIA	98
C	MODEL TESTOVANIA ÚSPEŠNOSTI KLASIFIKÁCIE	99

A OBSAH PRILOŽENÉHO DVD

Priložené DVD obsahuje súbory vytvorené v rámci diplomovej práce. Jedná sa o súbory *.mat obsahujúce jednotlivé skripty a funkcie potrebné pre funkčnosť navrhnutého systému automatickej detekcie Parkinsonovej nemoci. Tieto súbory sa nachádzajú v priečinku **diplomova_praca/System**. Ďalej obsahuje súbor s navrhnutým modelom klasifikácie v programovom prostredí RapidMiner. Tento model je možné nájsť v priečinku **diplomova_praca/Klasifikacia**.


Databáza záznamov jednotlivých cvičení na priloženom DVD nie je, pretože sa jedná o dôverné dáta ku ktorým nie je povolený voľný prístup. V zmysle tohto nariadenia na priloženom DVD nie sú obsiahnuté ani vypočítané súbory *.mat obsahujúce segmentované záznamy a vypočítané parametre. Obsah priečinka diplomová práca je teda nasledovný:

- Priečinnok System – obsahuje všetky súbory potrebné pre výpočet parametrov ručne písaného prejavu:
 - o súbory *.m



- o súbor gen_file_lists.bat.
- Priečinnok Klasifikacia – obsahuje vytvorený model klasifikácie v programovom prostredí RapidMiner, param_classification.
- Súbor diplomová práca.pdf.

B VZOR VYPLNENEJ ŠABLÓNY PRE PÍSOMNÉ CVIČENIA

1 	3 l l l l l
	4 le le le le le
	5 les les les les les
	6 lek lek lek lek lek
	7 poro poro poro poro poro
	8 nepo padnou
2 o o o o o	9 Tramvaj dnes už nepojde.

C MODEL TESTOVANIA ÚSPEŠNOSTI KLASIFIKÁCIE

