

**ČESKÉ VYSOKÉ
UČENÍ TECHNICKÉ
V PRAZE**

**FAKULTA
ELEKTROTECHNICKÁ**



DIPLOMOVÁ PRÁCE

2024

ANDREA MOŠKOVÁ

České vysoké učení technické v Praze

Fakulta elektrotechnická

Katedra teorie obvodů



Diplomová práce

Detekce emocí z řeči u brzké Parkinsonovy nemoci

Speech emotion detection in early Parkinson's disease

Autor: Bc. Andrea Mošková

Vedoucí práce: Ing. Vojtěch Illner

Vedoucí práce – specialista: Doc. Ing. Jan Ruzs, PhD.

Studijní program: Lékařská elektronika a bioinformatika

Specializace: Zpracování signálů

Praha 2024

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Mošková** Jméno: **Andrea** Osobní číslo: **516326**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra teorie obvodů**
Studijní program: **Lékařská elektronika a bioinformatika**
Specializace: **Zpracování signálů**

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Detekce emocí z řeči u brzké Parkinsonovy nemoci

Název diplomové práce anglicky:

Speech Emotion Detection in Early Parkinson's Disease

Pokyny pro vypracování:

1. Seznamte se s poruchou řeči u Parkinsonovy nemoci a metodami zpracování řečové aktivity.
2. Na základě literatury nastudujte vhodné metody pro parametrizaci emocí z řeči.
3. Připravte rešerši problematiky.
4. Navrhněte algoritmy umožňující automatickou detekci emocí z řeči ze záznamu spontánního popisu obrázků.
5. S pomocí navržených metod proveďte vhodné statistické analýzy a vyhodnoťte nejvhodnější parametry pro odlišení tří typů emocí u pacientů s Parkinsonovou nemocí ve srovnání se zdravými jedinci kontrolní skupiny.

Seznam doporučené literatury:

- [1] Tykalova T, Ruzs J, Cmejla R, Ruzickova H, Ruzicka E. Acoustic Investigation of Stress Patterns in Parkinson's Disease. J Voice 2014;28:129.e1-129.e8.
[2] Koolagudi SG, Rao KS. Emotion recognition from speech: a review. Int J Speech Technol 15:99–117; 2012.
[3] Sechidis K, Fusaroli R, Orozco-Arroyave JR, Wolf D, Zhang YP. A machine learning perspective on the emotional content of Parkinsonian speech. Artif Intell Med. 2021 May;115:102061.

Jméno a pracoviště vedoucí(ho) diplomové práce:

Ing. Vojtěch Illner katedra teorie obvodů FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **18.12.2023**

Termín odevzdání diplomové práce: **24.05.2024**

Platnost zadání diplomové práce: **21.09.2025**

Ing. Vojtěch Illner
podpis vedoucí(ho) práce

doc. Ing. Radoslav Bortel, Ph.D.
podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Diplomantka bere na vědomí, že je povinna vypracovat diplomovou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v diplomové práci.

Datum převzetí zadání

Podpis studentky

Prohlášení

Prohlašuji, že jsem předloženou práci vypracovala samostatně a že jsem uvedla veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze dne

.....

Podpis autora práce

Pod'akovanie

Veľmi rada by som sa poďakovala Ing. Vojtěchovi Illnerovi za vedenie tejto práce, ústretový prístup, veľkú ochotu pomôcť a cenné odborné rady. Rovnako by som sa chcela poďakovať aj druhému vedúcemu Doc. Ing. Janovi Ruzzovi, PhD za veľmi ochotne poskytnuté odborné znalosti a rady.

Abstrakt

Parkinsonovo ochorenie je často sprevádzané rečovými poruchami aj narušeným spracovávaním emócií. Predmetom tejto práce bola analýza emočných rečových prejavov pacientov pomocou vyvinutých automatických metód.

V tejto práci boli použité rečové nahrávky od 20 pacientov a 20 zdravých ľudí, predstavujúce spontánny popis troch skupín obrázkov, ktoré mali za cieľ vyvolať radostný, smutný a emočne neutrálny rečový prejav. Z rečových záznamov boli automatickými algoritmami vypočítané vybrané akustické a lingvistické parametre. Štatistickým spracovaním s využitím RANOVA testov a SVM klasifikácie boli vyhodnotené najvhodnejšie parametre schopné určiť prítomnosť diagnózy a rozlišovať medzi sebou emócie.

Akustické parametre a markre založené na analýze slovných druhov sa javia ako najsenzitívnejšie pre odhalenie ochorenia nezávisle na emóciách (úspešnosť klasifikácie takmer 0,7). Emočné dimenzie *valence*, *arousal*, *dominance* dokázali najlepšie reflektovať rozdiely medzi emóciami a to bez ohľadu na diagnózu (úspešnosť klasifikácie 0,86).

Analýzy ukázali, že rozpoznávanie emočného stimulu funguje veľmi dobre v lingvistickej oblasti. Prejavovanie emócií u pacientov nevykazuje odlišnosti v porovnaní so zdravými ľuďmi. Na rozdiel od predchádzajúcich štúdií nebola potvrdená schopnosť akustických parametrov reflektovať emócie. Závbery však môžu byť skreslené v dôsledku použitia obrázkového stimulu, ktorý nemusel byť schopný vyvolať dostatočne výrazne emocionálne prejavy a to najmä v akustickej doméne.

Kľúčové slová: Parkinsonova choroba, reč, emócie, akustická analýza, lingvistická analýza

Abstract

Parkinson's disease is often accompanied by speech disorders and impaired processing of emotions. The subject of this work was the analysis of emotional speech expressions of patients using developed automatic methods.

In this work, speech recordings from 20 patients and 20 healthy people were used, representing the spontaneous description of three groups of pictures, which were intended to elicit happy, sad and emotionally neutral speech. Selected acoustic and linguistic parameters were calculated from the speech recordings by automatic algorithms. By statistical processing using RANOVA tests and SVM classification, the most suitable parameters capable of determining the presence of a diagnosis and distinguishing between emotions were evaluated.

Acoustic parameters and markers based on part-of-speech analysis appear to be the most sensitive for detecting the disease independent of emotions (classification success rate of almost 0.7). The emotional dimensions of valence, arousal, and dominance were able to best reflect the differences between emotions regardless of the diagnosis (classification success rate 0.86).

The analyzes showed that emotional stimulus recognition works very well in the linguistic domain. The expression of emotions in patients does not show differences compared to healthy people. Unlike previous studies, the ability of acoustic parameters to reflect emotions was not confirmed. However, the conclusions may be distorted due to the use of a picture stimulus, which may not have been able to evoke sufficiently significant emotional manifestations, especially in the acoustic domain.

Keywords: Parkinson's disease, speech, emotions, acoustic analysis, linguistic analysis

Zoznam obrázkov

Obrázok 1: Postup získavania zvolených akustických parametrov zo zvukového signálu.....	26
Obrázok 2: Postup získavania zvolených lingvistických parametrov zo zvukového signálu.	28
Obrázok 3: Krabicové grafy zobrazujúce distribúcie akustických parametrov vypočítaných pre skupiny PD a HC vzhľadom k rečovým úlohám.	35
Obrázok 4: Grafické spracovanie výsledkov parametru polarita získaného pomocou nástroja SenticNet zobrazuje percentuálne zastúpenie prejavov s negatívnou/neutrálnou/pozitívnou polaritou v rámci skupín PD a HC pri každej rečovej úlohe.	36
Obrázok 5: Krabicové grafy zobrazujúce distribúcie SenticNet parametrov vypočítaných pre skupiny PD a HC vzhľadom k rečovým úlohám.	38
Obrázok 6: Krabicové grafy zobrazujúce distribúcie vypočítaných hodnôt v troch emočných dimenziách <i>valence, arousal, dominance</i> pre skupiny PD a HC vzhľadom k rečovým úlohám.....	40
Obrázok 7: Krabicové grafy zobrazujúce distribúcie vybraných parametrov založených na analýze slovných druhov vypočítaných pre skupiny PD a HC vzhľadom k rečovým úlohám.	42
Obrázok 8: Matice zámen sumarizujúce výsledky lineárnych SVM klasifikátorov s <i>leave-one-out</i> validáciou pre úlohu klasifikácie emócií zo všetkých dát bez ohľadu na delenie skupín podľa diagnózy.....	44
Obrázok 9: Matice zámen sumarizujúce výsledky lineárnych SVM klasifikátorov s <i>leave-one-out</i> validáciou pre úlohu klasifikácie emócií u zdravých ľudí.	45
Obrázok 10: Matice zámen sumarizujúce výsledky lineárnych SVM klasifikátorov s <i>leave-one-out</i> validáciou pre úlohu klasifikácie emócií u pacientov s Parkinsonovou chorobou.....	46
Obrázok 11: Inštrukcie a obrázky k rečovej úlohe <i>happy</i> , zameranej na vyvolanie pozitívnych emócií. ...	65
Obrázok 12: Inštrukcie a obrázky k emočne neutrálnej rečovej úlohe <i>neutral</i>	65
Obrázok 13: Inštrukcie a obrázky k rečovej úlohe <i>sad</i> , zameranej na vyvolanie negatívnych emócií.	66

Zoznam tabuliek

Tabuľka 1: Klinické údaje zdravých ľudí a pacientov, ktorých rečové nahrávky sú súčasťou databázy použitej v tejto práci.	23
Tabuľka 2: Príklady slov s extrémnymi hodnotami v jednotlivých dimenziách českej verzie NRC VAD lexikónu. Inšpirácia v [33], [80].	30
Tabuľka 3: Výsledky RANOVA testov (efekty SKUPINA, EMÓCIA, SKUPINAxEMÓCIA) pre akustické parametre.	35
Tabuľka 4: Výsledky RANOVA testov (efekty SKUPINA, EMÓCIA, SKUPINAxEMÓCIA) pre spojité SenticNet parametre.	37
Tabuľka 5: Výsledky RANOVA testov (SKUPINA, EMÓCIA, SKUPINAxEMÓCIA) pre tri emočné dimenzie <i>valence</i> , <i>arousal</i> , <i>dominance</i>	39
Tabuľka 6: Výsledky RANOVA testov (SKUPINA, EMÓCIA, SKUPINAxEMÓCIA) pre vybrané parametre založené na analýze slovných druhov.	41
Tabuľka 7: Vypočítaná presnosť [–] lineárnych SVM klasifikátorov s <i>leave-one-out</i> validáciou pre všetky skúmané klasifikačné úlohy.	43
Tabuľka 8: Mediány a štandardné odchýlky (SD) vypočítaných spojitých parametrov vzhľadom k rečovým úlohám u pacientov s Parkinsonovou chorobou.	67
Tabuľka 9: Mediány a štandardné odchýlky (SD) vypočítaných spojitých parametrov vzhľadom k rečovým úlohám u zdravých ľudí.	68

Obsah

1. Úvod	12
1.1. Parkinsonova choroba.....	12
1.1.1. Poruchy reči pri PD.....	13
1.1.2. Spracovanie emócií pri PD.....	14
1.2. Detekcia emócií v reči	15
1.2.1. Typy emočných databáz.....	16
1.2.2. Akustická analýza	16
1.2.3. Lingvistická analýza	18
1.3. Emócie v reči pri PD	20
1.4. Ciele práce	21
2. Metodika	23
2.1. Spracovávané dáta	23
2.1.1. Účastníci výskumu	23
2.1.2. Rečové úlohy	24
2.1.3. Predspracovanie	24
2.2. Akustické parametre	25
2.3. Lingvistické parametre	27
2.3.1. Emočná analýza na úrovni celých prejavov	28
2.3.2. Emočná analýza s využitím lexikónu.....	29
2.3.3. Analýza slovných druhov.....	30
2.4. Štatistická analýza	31
2.4.1. RANOVA test	31
2.4.2. Klasifikácia	32
3. Výsledky.....	34
3.1. Akustické parametre	34
3.2. Lingvistické parametre	36
3.2.1. Emočná analýza na úrovni celých prejavov	36
3.2.2. Emočná analýza s využitím lexikónu.....	38
3.2.3. Analýza slovných druhov.....	40
3.3. Klasifikácia.....	42
4. Diskusia	47

5. Záver	51
5.1. Zhrnutie	51
5.2. Budúci výskum.....	51
Použitá literatúra	53
Príloha A: Podklady k rečovým úlohám.....	65
Príloha B: Výsledky vypočítaných parametrov	67

1. Úvod

Prvá kapitola práce sa zameriava na teoretický rozbor spracovávanej tematiky. Vysvetľuje základné poznatky o Parkinsonovej chorobe, najmä v súvislosti s poruchami rečovej aktivity a spracovávania emócií. V úvode práce sú zhrnuté aj najvýznamnejšie aspekty úlohy detekcie emócií z reči, možné typy spracovávaných signálov a najvhodnejšie metódy parametrizácie emócií. Kapitola predstavuje doterajší výskum týkajúci sa prejavov emócií v reči pacientov s Parkinsonovou chorobou. Po predstavení problematiky sú v závere kapitoly stanovené ciele práce.

1.1. Parkinsonova choroba

Parkinsonova choroba (*Parkinson's disease, PD*) sa zaraďuje medzi neurodegeneratívne ochorenia a postihuje takmer 2% ľudí starších ako 65 rokov [1]. Vznik PD je podmienený patologickým nahromadením alfa-synukleínu v mozgu, ktorý súvisí s postupnou degeneráciou neurónov zodpovedných za tvorbu dopamínu, v dôsledku čoho sa objavuje dopamínový deficit [2].

Nedostatok dopamínu sa prejavuje hlavnými motorickými príznakmi ako bradykinesia (spomalené vykonávanie pohybu) alebo hypokinesia (obmedzený pohyb), pokojový tras a stuhnutosť [2], [3]. Popri motorických prejavoch sa pridávajú aj ďalšie nemotorické symptómy ako kognitívne poruchy, problémy so spánkom, depresia alebo apatia [3]. V súvislosti s PD je taktiež pozorované narušenie rozpoznávania aj prejavovania emócií [4]. Ochorenie sa klinickými príznakmi (pokojový tras, spomalené pohyby, stuhnutosť), ktoré odhalia diagnózu, manifestuje až relatívne neskoro, v pokročilej fáze, keď je poškodenie mozgu rozsiahle a deficit dopamínu veľmi výrazný [3], [5].

V súčasnosti neexistuje možnosť liečby, ktorá by dokázala ochorenie úplne zastaviť a umožniť vyliečenie pacienta, avšak využíva sa dopaminergná medikácia či neurochirurgické zásahy s cieľom zmierniť motorické príznaky [2]. Tieto postupy však môžu významne ovplyvňovať aj náladu a emocionálne prežívanie pacientov s PD [6], [7]. Monitorovanie škály a intenzity prejavovaných emócií sa preto môže uplatniť pri nastavovaní liečebného plánu.

1.1.1. Poruchy reči pri PD

Charakteristickým znakom PD sú aj mnohoraké akustické problémy s rečou, ktoré postihujú až 90 % pacientov a spadajú pod diagnózu motorickej rečovej choroby nazývanej hypokinetická dysartria, ktorá sa viaže k narušenej funkcii bazálnych ganglií [8], [9], [10].

U pacientov s PD sa rečové poruchy prejavujú najskôr a najvýraznejšie na úrovni hlasu, neskôr sa pridávajú aj deficity artikulácie a plynulosti reči [10]. Najvýznamnejšie abnormálne charakteristiky reči v prípade hypokinetickej dysartrie predstavuje monotónnosť, nízka hlasitosť, malý rozsah hlasitosti či obmedzený dôraz [8], [11]. Medzi dôležitými znakmi hypokinetickej dysartrie možno spomenúť aj nerovnomernú rečovú rýchlosť, krátke a veľmi rýchle úseky reči, kde sa prejavuje neschopnosť správne vyslovovať jednotlivé slabiky či slová idúce za sebou, ďalej aj opakovanie foném a prítomnosť nevhodných alebo príliš dlhých páuz v reči [8], [11].

Akustické rečové abnormality predstavujú v prípade PD citlivý marker, ktorý dokáže predpovedať nástup neurodegeneratívneho ochorenia, už niekoľko rokov pred objavením sa klinických príznakov [12]. Pre ich odhalenie a popis však treba zvoliť vhodnú metódu posudzovania rečovej aktivity, ktorých existuje niekoľko [8]:

- a) percepčné (hodnotenie zvukovej stránky rečového prejavu odborníkom),
- b) akustické (kvantitatívna analýza zvukového rečového signálu),
- c) fyziologické (zameranie sa na svalovú a neuronálnu aktivitu iniciujúcu alebo kontrolujúcu reč),
- d) založené na vizuálnom zobrazovaní (náhľad do činnosti horného dýchacieho a tráviaceho traktu počas reči).

Percepčné a akustické metódy sa viažu na produkovaný zvukový signál a umožňujú tak posudzovať dôležitú akustickú stránku reči. Percepčné metódy sú v klinickej praxi považované za základ v rámci stanovovania diagnóz rečových porúch, avšak vyznačujú sa subjektivitou, veľkou časovou náročnosťou a vysokou cenou [8]. Akustické metódy naopak umožňujú podrobnú vizualizáciu rečového signálu, jeho kvantifikáciu a objektívne hodnotenie rečovej aktivity [8].

Akustická analýza rečovej aktivity v súvislosti s PD spočíva v spracovávaní nahrávok rečových testov ako trvalá fonácia, rýchle opakovanie slabík, čítanie alebo monológ [13]. Zo signálov sú následne vypočítané rôzne parametre súvisiace napríklad so základnou hlasivkovou frekvenciou, intenzitou signálu, rýchlosťou reči či spektrálnou informáciou, s cieľom zachytiť rečové abnormality typické pre ochorenie a odlíšiť tak pacientov s PD od zdravých jedincov [13].

Výskumy reči zamerané na lingvistickú stránku ukazujú, že deficity na jazykovej úrovni predstavujú marker zhoršovania kognitívnych funkcií, ktorý sa v súvislosti s PD môže uplatniť v rámci včasnej diagnostiky a pri predpovediach riziku konvergenie k rôznym neurodegeneratívnym ochoreniam [14], [15].

1.1.2. Spracovanie emócií pri PD

Emocionálne poruchy sa zaraďujú medzi nemotorické symptómy PD, ktoré negatívne ovplyvňujú schopnosť pacientov fungovať v spoločnosti a môžu popri hlavných symptómoch ochorenia tiež významne prispievať k zníženiu kvality života pacientov [4], [16], [17].

Spracovávanie emócií u pacientov s diagnózou PD bolo predmetom mnohých rôzne zameraných štúdií, ktorých výsledky nie sú vždy konzistentné, čo je možné pripísať odlišnostiam medzi výskumami na úrovni použitej metodiky (modalita emočného stimulu, typ úlohy, pozorovaná emócia) aj klinického profilu subjektov (úroveň kognitívneho a motorického poškodenia, depresia, medikácia) [4], [17], [18]. Možno z nich však usudzovať, že PD narúša komunikáciu na úrovni percepcie emočnej informácie a zároveň oslabuje aj schopnosť vyjadrovania emócií [4], [16]. Tieto poruchy naznačujú zapojenie dopaminergných dráh a bazálnych ganglií do procesu spracovávania emócií [4].

Deficit rozpoznávania emócií je u pacientov s PD prítomný v prípade spracovávania emocionálnej prozódie aj mimiky druhých ľudí a prejavuje sa najmä v súvislosti s negatívnymi emóciami ako smútok, znechutenie, strach či hnev [4], [16], [17]. Navyše sa pri ochorení objavujú aj problémy s rozpoznávaním intenzity emočného obsahu v čítanom texte [19].

Narušenie vyjadrovania emócií sa týka rečového prejavu aj výrazov tváre [4], [17]. Amimia predstavuje obmedzenú expresivitu tváre súvisiacu s porušením motoriky svalov a spôsobuje, že tváre pacientov s PD nesú stuhnutý výraz, ktorým nie je možné adekvátne vyjadrovať emócie [4]. Ako vysvetlenie porúch emočného rečového prejavu sa ponúka uvažovať motorický pôvod, teda vplyv hypokinetickej dysartrie [8], [17]. Avšak na druhú stranu motorické poruchy možno nedokážu uspokojivo vysvetliť všetky rečové abnormality a príčinu je vhodné hľadať aj v narušení vnútorného prežívania emócií [20].

Doterajší výskum vyjadrovania emócií prostredníctvom reči u pacientov s PD bude bližšie predstavený v kapitole 1.3.

1.2. Detekcia emócií v reči

Emócie sú previazané s vnútorným subjektívnym prežívaním a manifestujú sa spontánnymi fyziologickými či motorickými reakciami organizmu na rôznorodé podnety z vonkajšieho okolia alebo interné stimuly ako napríklad premýšľanie či spomínanie [4], [21]. Sú dôležitou súčasťou bežnej ľudskej komunikácie. Emočný obsah je možné vyjadrovať viacerými formami súčasne, napr. výberom slov na jazykovej úrovni, fyzickými prejavmi mimiky a gestikulácie alebo hlasom [22].

Ľudská reč je komplexná motorická aktivita, ktorá predstavuje jedinečný komunikačný nástroj, umožňujúci vyjadrovanie myšlienok, emócií a interakciu človeka s okolitým prostredím [8]. Rečový signál je jednoducho zaznamenateľný a ľahko dostupný, navyše spája až dve modalities emočného vyjadrovania (hlas a slová). Predstavuje teda výborný zdroj dát, pre výskum ľudských emócií.

Systémy na rozpoznávanie emócií z reči (*speech emotion recognition*, SER), ktoré je možné definovať ako súbor postupov spracúvajúcich rečové signály s cieľom odhaliť a klasifikovať v nich emočný obsah [23], sa už viac ako dve desaťročia rýchlo rozvíjajú [24]. Motiváciou pre zahrnutie emočného spracovávanie do systémov s rečovým rozhraním je zvýšenie ich prirodzenosti a efektivity [25]. SER systémy sa môžu uplatňovať v oblasti automobilov, kde monitorovanie mentálneho stavu vodiča prispieje k zlepšeniu bezpečnostných stratégií [26], [27]. Sledovanie emočného obsahu hovorov zabezpečí skvalitnenie služieb v call centrách [28]. Skúmanie vzťahu reči a emócií má opodstatnenie v oblasti medicíny, keďže kognitívne a emočné poruchy môžu ovplyvňovať rečový prejav a naopak motorické rečové poruchy obmedzovať schopnosť vyjadrovania emócií [8]. Skúmanie emočného obsahu reči môže priniesť náhľad do mentálneho zdravotného stavu a uplatniť sa ako diagnostický nástroj pre rôzne ochorenia [29], [30].

Analýza emócií v reči je ovplyvnená voľbou modelu pre ich reprezentáciu. Prvým prístupom je diskretný model, ktorý spracováva emócie ako oddelené kategórie (napr.: hnev, šťastie, znechutenie, strach, smútok, prekvapenie, prípadne neutrálna kategória ako referencia) [23], [24], [31]. Ďalšou možnosťou je dimenzionálny model, ktorý popisuje emócie kontinuálne pomocou niekoľkých dimenzií [23], [24]. Používaná je najmä dimenzia *valence*, ktorá odráža polaritu a *arousal*, ktorá popisuje intenzitu vyjadrovanej emócie [23], [24], [32], [33]. So skúmaním vyjadrovaných emócií súvisí aj analýza sentimentu, ktorá spočíva v posúdení polaritu prejavu, teda v klasifikácii obsahu na pozitívny, negatívny alebo prípadne neutrálny [34].

Skúmanie prejavov emócií v reči je ďalej podmienené získaním rečových signálov a identifikovaním vhodných parametrov, ktoré vykazujú koreláciu s emóciami.

1.2.1. Typy emočných databáz

Pre skúmanie emócií z reči je nutné disponovať vhodnou databázou rečových signálov, ktorej kvalita významne ovplyvňuje analýzu. Existuje viacero prístupov pre získavanie rečových signálov. Prístupy podmieňujú charakter prítomného emočného obsahu, ktorý tak môže byť [23], [35]:

- a) simulovaný,
- b) vyvolaný,
- c) prirodzený.

Simulované alebo hrané databázy sú tvorené rečovými prejavmi subjektov, pričom subjekty boli požiadané prednášať vybrané vety a prácou s hlasom do nich vnášať požadované emócie [23], [35]. Prípadne sa majú subjekty pokúsiť čo najpresnejšie imitovať určitý vzorový prejav [20]. Vďaka svojej jednoduchosti ide o najrozšírenejšiu metódu získavania intenzívneho emočného obsahu z reči [35]. Na druhú stranu sú však simulované emócie oproti skutočným výraznejšie, až prehnané [35], [36], [37], čo obmedzuje spoľahlivosť a aplikovateľnosť výsledkov analýz na reálne dáta.

Rečové signály s vyvolaným emočným obsahom vznikajú vystavením subjektov simulovaným emocionálnym situáciám, ktoré majú za cieľ vyvolať žiadanú emóciu [23], [35]. V porovnaní s hranými prejavmi sa viac približujú reálnej reči s prirodzenými emóciami a emočný obsah je v nich menej výrazný [23], [35], [38]. Zaznamenávané sú voľné rečové prejavy, v ktorých sú emócie indukované využitím rôznorodých, napríklad audiovizuálnych [39] stimulov alebo interakciou subjektu s uspôsobeným počítačovým systémom [38], [40].

Rečové databázy s prirodzenými emóciami predstavujú záznamy spontánnych prejavov z reálnych situácií, ako relácie v rádiu či hovory z call centier [23], [28], [35]. Tento typ databáz obsahuje v porovnaní s ostatnými najprirodzenejšie vyjadrené emócie, najviac sa približujúce bežnému ľudskému prejavu, ale na druhú stranu sa k nim však viažu mnohé limitácie: prítomnosť viacerých vzájomne sa prekrývajúcich emócií, šum v pozadí, legálne či etické prekážky v súvislosti so šírením databáz a aj nutnosť anotácie dát, ktorá je časovo náročná a subjektívna [23], [35], [37].

1.2.2. Akustická analýza

Hlas obohacuje slová o neverbálnu zvukovú informáciu vyjadrujúcu emócie, ktoré ľudia dokážu z reči prirodzene vnímať a chápať [41]. Akustické parametre popisujú zvukovú stránku

reči, teda spôsob „ako“ je niečo povedané [42]. Analýza emócií v rečových prejavoch spočíva v extrakcii vhodných akustických parametrov, ktoré emócie vystihujú.

Reč predstavuje nestacionárny signál, pri ktorého spracovaní sa uplatňuje prístup segmentácie na niekoľko milisekundové časové okná. V rámci jednotlivých segmentov sa signál považuje za stacionárny a z každého sú počítané lokálne deskriptory [37], [43]. S cieľom zníženia počtu spracovávaných parametrov a zjednodušenia analýzy je možné lokálne deskriptory sumarizovať pomocou globálnych deskriptorov, ktoré predstavujú štatistické operátory ako priemer, štandardná odchýlka, rozptyl, minimum, maximum a podobne [37], [43].

Akustické parametre, ktoré sú na základe štúdií venujúcich sa rozpoznávaniu emócií z reči najvhodnejšie, je možné rozdeliť do nasledujúcich kategórií [23]:

- a) prozodické,
- b) spektrálne a keprálne,
- c) parametre odrážajúce kvalitu hlasu.

Prozódia zahŕňa vyjadrovacie prostriedky ako intonácia, intenzita či dĺžka páuz, ktoré sa uplatňujú v rečovom prejave a sú zodpovedné za prirodzené znenie reči [35]. Prozodické parametre dokážu veľmi dobre zachytiť emočný obsah reči [35], [40], [44]. Najčastejšie používané parametre sú odvodené zo základnej hlasivkovej frekvencie F_0 , časovania reči a intenzity [23], [35], [40]. Základná hlasivková frekvencia súvisí s vibráciami hlasiviek a podmieňuje intonáciu v reči [23], [35]. Intenzita alebo energia sa vzťahuje k amplitúde rečového signálu, teda k hlasitosti a pod časovanie reči možno zahrnúť napríklad rečovú rýchlosť alebo dĺžky páuz [23]. Emócie charakterizované vyššou mierou vzrušenia (napríklad radosť) sú v reči manifestované zvýšenou strednou hodnotou F_0 , väčšou variabilitou F_0 a prejav môže byť rýchlejší i hlasnejší v porovnaní s neutrálnou rečou [45]. Naopak pri prejavovaní smútku a napríklad aj v prípade depresie je reč monotónnejšia, pomalšia a sprevádzaná dlhšími pauzami [29], [45].

Spektrálne a keprálne parametre sú odvodené z frekvenčnej domény rečového signálu, v ktorej sú zaznamenané charakteristiky vokálneho traktu filtrujúceho produkovaný zvuk [23], [35]. Medzi často používané patria mel-frekvenčné keprálne koeficienty (*mel-frequency cepstral coefficients*, MFCC) [35], ktoré vychádzajú z kosínovej transformácie logaritmu spektra na mel-frekvenčnej škále a reprezentujú obálku krátkodobého výkonového spektra [46]. MFCC dokážu veľmi dobre zachytiť relevantné informácie z rečového signálu [46], [47], avšak sú závislé na veku, pohlaví a nahrávacích podmienkach, ako typ či pozícia mikrofónu [48]. MFCC by mohli odrážať emočné informácie lepšie ako ostatné akustické parametre [49].

Kvalita hlasu môže byť popisovaná charakteristikami ako dýchavičnosť či drsnosť a parametrami *jitter*, *shimmer* alebo *harmonics to noise ratio* [23], [40]. Oproti iným akustickým parametrom však majú nižšiu schopnosť reflektovať emócie v reči [40] a sú považované za menej významné a doplnkové deskriptory [23]. Navyše sú ovplyvňované nahrávacími podmienkami a vhodnejšie pre krátke, kontrolované rečové úlohy, ktoré nedostatočne reprezentujú bežný rečový prejav [50].

Analýza reči kombinujúca viacero typov akustických parametrov dokáže efektívnejšie rozpoznať emócie v porovnaní s prístupom využívajúcim iba jeden typ parametru, pretože vplyv emócie sa väčšinou neprejaví iba v jednej dimenzii reči a rôzne typy akustických parametrov prinášajú navzájom komplementárne informácie [35].

1.2.3. Lingvistická analýza

Úloha detekcie emócií v reči nemusí byť limitovaná iba na zvukovú analýzu, keďže emócie môžu byť v reči vyjadrované aj na verbálnej úrovni [22]. Lingvistické parametre mapujú obsahovú stránku reči a emócie reflektované výberom slov. Pre odvodenie lingvistických parametrov je najskôr potrebné získať textový prepis rečového signálu využitím systému pre automatické rozpoznávanie reči (*automatic speech recognition*, ASR), ktorého kvalita ovplyvňuje výsledky analýzy. Presnosť ASR však v dnešnej dobe dosahuje veľmi vysokú úroveň, ktorá je porovnateľná s ľudskými schopnosťami [51], [52].

V rečovom alebo textovom prejave sa k jednotlivým emóciám často viažu špecifické slová, ktoré sú v kontexte danej emócie všeobecne používané [28]. Jeden z možných prístupov k lingvistickej analýze emócií spočíva vo vyhľadávaní emocionálnych kľúčových slov, ktoré sú charakterizované väzbou k určitej emócii, pričom sila väzby je numericky vyjadrená [28], [42], [53]. Skúmanie emocionálnej hodnoty jednotlivých slov nezávisle, nemusí byť dostatočne efektívne a prejavy môže byť výhodné posudzovať na úrovni skupín slov alebo viet [26]. Efektívna lingvistická analýza emócií a sentimentu v rečovom prejave založená na posudzovaní jednotlivých slov je však podmienená dostupnosťou dostatočne širokej anotovanej databázy slov. Manuálna tvorba takejto databázy je veľmi časovo náročná.

V dnešnej dobe sú k dispozícii rozsiahle elektronické slovníky alebo lexikóny obsahujúce rôznou formou anotované slová z hľadiska sentimentu a emócií, ktoré dané slová vyjadrujú. Slovám je napríklad možné priradiť skóre v škálach ako *valence* (polarita), *arousal* (intenzita, aktivácia) a *dominance* (dominancia) [33]. Iné slovníky slovám asociujú polaritu (pozitívny/negatívny) a prípadne aj informáciu o zaradení k nejakej konkrétnej emócii [54]. Hoci

lexikóny sú najčastejšie dostupné v angličtine, existujú aj možnosti pre iné jazyky a medzi nimi i pre češtinu [33], [54].

Ďalej existujú nástroje schopné analyzovať prejavy ako celok, odhadnúť ich celkovú polaritu, určiť vyjadrovanú emóciu i jej intenzitu, napr. SenticNet [55], [56]. Nástroje sú však často limitované na analýzu textov v niekoľkých vybraných jazykoch, primárne v angličtine. Originálny text v jazyku, ktorý zvolený nástroj nepodporuje, môže byť však najskôr preložený do angličtiny a až následne analyzovaný [57], ale je nutné počítať s vplyvom prekladacieho systému na výsledok analýzy.

Posudzovanie rečového či textového prejavu vzhľadom k použitým slovným druhom a ich kategóriám sa tiež ukazuje ako užitočný prostriedok skúmania emócií [24], [40]. Hoci sa analýza založená na použitých slovných druhoch primárne a s veľkým úspechom uplatňuje pri detekcii zhoršených kognitívnych schopností [14], [15], [58], nachádza opodstatnenie aj vo výskume emócií. Napríklad depresia, ktorá je charakteristická hlbokým a dlhotrvajúcim smútkom, sa môže prejavovať častejším používaním zámen v prevej osobe [29].

Lingvistická analýza textu môže spočívať v jeho transformácii na numerické hodnoty prístupom *bag-of-words*, ktorý mapuje normalizovanú frekvenciu výskytu slov z definovaného slovníka v spracovávanom texte a môže byť využitý k skúmaniu emócií [40]. Avšak s narastajúcim objemom textových dát stráca popis založený na frekvencii výskytu opodstatnenie [24].

Ďalšia forma numerickej reprezentácie textu, sprostredkujúca možnosť analýzy emócií je založená na nahradení slov vektormi (*word embedding*) pomocou predtrénovaných jazykových modelov založených na hlbokých neurónových sieťach, ktoré berú ohľad na podobnosť a vzťahy medzi slovami [24], [42]. Využitie hlbokých neurónových sietí pre analýzu textu tak zabezpečí silný nástroj, schopný popísať informácie, ktoré ostatné parametre nie, ale na druhú stranu sa k tomuto prístupu viaže riziko pretrénovania a nízka interpretovateľnosť.

1.3. Emócie v reči pri PD

Doposiaľ bolo realizovaných len relatívne málo štúdií zameraných na podrobnejšie skúmanie rečového prejavu pacientov s PD v súvislosti s vyjadrovaním emócií. Väčšina z nich je postavená na spracovaní rečových signálov so simulovanými emóciami, kde boli participanti vyzvaní prednášať pripravené vety s určitou cieľovou emóciou [20], [59], [60], [61], [62], [63], [64], [65].

Najstaršie štúdie sa opierali iba o subjektívne hodnotenia malého počtu poslucháčov, ktorí bodovali schopnosť subjektov s PD a zdravých kontrol vystihnúť žiadanú emóciu [59], [60], [61], [62]. Výsledky všetkých ukazujú na zníženú schopnosť vyjadrovania emócií prostredníctvom reči v prípade PD. Niektoré z týchto štúdií pripúšťajú multimodálny pôvod rečových porúch, súvisiaci s narušením motoriky aj emocionálneho prežívania [60], ale objavili sa aj závery ukazujúce skôr na motorické pozadie [61]. Jedna štúdia odhalila súvislosť medzi zhoršeným mentálnym stavom a narušeným prežívaním emócií [62].

Pell et al. [63] pristúpili k analýze trochu odlišne a 20 poslucháčov nechali odhadovať zamýšľanú emóciu v prejavoch aj jej intenzitu. Podľa výsledkov mali poslucháči v prípade parkinsonickej reči viac problémov so správnym identifikovaním emócií. Často sa reč pacientov javila ako smutná alebo neutrálna. Intenzita vyjadrenej emócie u pacientov bola všeobecne považovaná za veľmi nízku. V inej štúdií [66] mali poslucháči popísať dojem, ktorý nadobudli z hovoriacej osoby na jednotlivých nahrávkach, pričom išlo o monológy pacientov alebo zdravých jedincov. Osoby s PD boli charakterizované ako menej zaujaté, menej šťastné či menej priateľské.

Ďalej boli realizované aj výskumy, využívajúce akustickú analýzu, ktorá spočívala v extrakcii akustických parametrov z rečových signálov a umožňovala tak objektívne posúdenie narušenia emocionálnych prejavov v prípade PD [20], [64], [65]. Skupinu krátko diagnostikovaných pacientov využívajúcich medikáciu bolo možné odlišiť od zdravých ľudí na základe merania priemerných hodnôt F0 a amplitúdy signálu v hraných emočných prejavoch [64]. Subjekty mali v rámci danej štúdie prečítať stanovené vety takým spôsobom, aby imitovali postupne šesť rôznych emócií. Möbes et al. [20] tiež spolupracovali s krátko diagnostikovanými pacientami užívajúcimi medikáciu, pričom boli posudzované odlišnosti v rozsahu F0 a intenzity v ich emočných a neemočných rečových prejavoch v porovnaní so zdravými ľuďmi. Signifikantné rozdiely boli zistené iba v prípade prejavov s emóciami, z čoho autori usudzujú, že rečové poruchy pri PD sú ovplyvnené aj narušeným spracovávaním emócií a nielen motorickými deficitmi. Zhao et al. [65] využili rôzne akustické parametre a metódy klasifikácie založené na strojovom učení s cieľom rozlišovania emócií v rečových prejavoch zdravých ľudí a pacientov s PD. Snažili sa aj o vytvorenie klasifikátora schopného odlišovať skupiny navzájom.

Novšie štúdie využívajú pre spracovanie reči modely založené na strojovom učení [46] a na hlbokých neurónových sieťach [67], [68]. Modely boli natréňované na simulovaných emočných databázach zdravých jedincov a následne spracovávali spontánne rečové prejavy. Sechidis et al. [46] dokázali pomocou modelu pracujúceho s MFCC parametrami hodnotiť s akou pravdepodobnosťou znejú rečové prejavy šťastne. Boli tak objektívne potvrdené predchádzajúce závery vychádzajúce z dojmov poslucháčov, že parkinsonická reč znie menej šťastne. Predmetom inej štúdie [67] bol vývoj nástroja schopného z rečového signálu hodnotiť emočný stav z hľadiska troch dimenzií: *pleasure*, *arousal*, *dominance*. Cieľom bolo odlíšiť skupiny zdravých jedincov a pacientov s PD, ale aj odhaliť prítomnosť depresie u pacientov s PD. Rozlišovanie medzi depresívnymi a nedeprívnymi pacientami vykazovalo vyššiu úspešnosť. Iný model spracúvajúci spektrogramy rečových signálov bol vyvinutý s cieľom klasifikácie emócií v spontánnych rečových prejavoch ľudí s PD [68].

Niektoré výskumy [63], [64], [69] sa zameriavali aj na využívanie dôrazu v slovách a vetách, ktorý tiež môže byť prostriedkom pre komunikáciu emócií. Výsledky ukazujú, že v prípade PD je schopnosť správne využívať v reči dôraz narušená.

Dá sa usúdiť, že v rámci problematiky vyjadrovania emócií v reči pri diagnóze PD bolo realizovaných niekoľko rôzne zameraných štúdií. Možno však pozorovať nedostatok analýz zameriavajúcich sa na rečové nahrávky, ktoré by obsahovali prirodzenejšie emócie a ktoré by pochádzali od nemedikovaných pacientov. Zároveň bola doposiaľ v rámci výskumov iba relatívne málo využívaná lingvistická analýza a zatiaľ nikto neskúmal dohromady akustickú stránku reči aj rôzne lingvistické prístupy v rámci jednej ucelenej štúdie.

1.4. Ciele práce

Predmetom tejto práce bude exploratívna analýza vyjadrovania emócií prostredníctvom reči pri Parkinsonovom ochorení s úmyslom rozšírenia poznatkov týkajúcich sa danej diagnózy. Mohli by sa uplatniť napríklad pri vývoji nových diagnostických metód alebo pomôcť lepšie porozumieť vnútornému stavu pacientov, čo by prispelo k efektívnejšiemu nastaveniu liečby.

V rámci práce budú aplikované algoritmy na výpočet špecifických parametrov, vychádzajúcich z aktuálnej literatúry, s cieľom odhaliť rozdiely v prejavovaní emócií medzi pacientami s PD a zdravými kontrolami. Predmetom skúmania bude akustická aj lingvistická stránka rečových prejavov. Metódy budú použité k parametrizácii zvukových záznamov spontánneho popisu obrázkov v českom jazyku získaných od pacientov s PD aj od zdravých ľudí.

S využitím štatistickej analýzy budú určené najvhodnejšie parametre schopné rozlišovať medzi sebou emócie aj demonštrovať prípadné rozdiely v prejavovaní emócií medzi pacientami a zdravými ľuďmi.

Ďalej budú vytvorené klasifikátory zamerané na zhodnotenie schopnosti odlišenia jednotlivých typov emócií a oboch skupín pomocou použitých metód.

Dosiahnuté výsledky budú analyzované v kontexte doterajších poznatkov z danej problematiky. Taktiež bude posúdená efektivita a validita použitého postupu vyvolávania emócií pomocou obrázkových stimulov, ktorá v súvislosti s výskumom prejavovania emócií pri PD nebola doposiaľ použitá.

2. Metodika

2.1. Spracovávané dáta

2.1.1. Účastníci výskumu

Spracovávané rečové nahrávky boli získavané v rokoch 2021 – 2023 a pochádzajú od dvoch skupín česky hovoriacich subjektov. Skupinu PD tvorí 20 pacientov vo veľmi skorej a nijakým spôsobom neliečenej fáze Parkinsonovho ochorenia. Skupina HC (*healthy controls*) zahŕňa 20 zdravých kontrol. Obe skupiny sa vyznačujú podobnou vekovou distribúciou a približne rovnomerným zastúpením žien a mužov. Klinické dáta prezentuje Tabuľka 1.

Tabuľka 1: Klinické údaje zdravých ľudí a pacientov, ktorých rečové nahrávky sú súčasťou databázy použitej v tejto práci.

Forma zápisu: priemerná hodnota \pm štandardná odchýlka (minimum–maximum). Skratky:

BDI-II = Beck Depression Inventory, second edition; HC = healthy controls (zdravé kontroly);

MDS-UPDRS III = Movement Disorder Society-Unified Parkinson's Disease Rating Scale, part III;

MoCA = Montreal Cognitive Assessment; PD = Parkinson's disease (Parkinsonova choroba).

HC	Zastúpenie pohlaví	9 žien, 11 mužov
	Vek	63,5 \pm 12,1 (41–83)
	MDS-UPDRS III	6,3 \pm 4,4 (1–17)
	MDS-UPDRS III speech part	0,3 \pm 0,5 (0–1)
	BDI-II	4,0 \pm 3,4 (0–12)
	MoCA	26,6 \pm 2,5 (22–30)
	Počet rokov školskej dochádzky	16,1 \pm 2,6 (12–21)
PD	Zastúpenie pohlaví	9 žien, 11 mužov
	Vek	64,2 \pm 12,1 (43–84)
	Počet rokov trvania syndrómov	2,7 \pm 2,4 (0,4–10,4)
	MDS-UPDRS III	30,9 \pm 10,8 (18–52)
	MDS-UPDRS III speech part	1,0 \pm 0,3 (0–2)
	BDI-II	7,9 \pm 5,9 (0–20)
	MoCA	25,6 \pm 2,9 (17–30)
Počet rokov školskej dochádzky	16,1 \pm 3,1 (12–22)	

Závažnosť motorických príznakov bola posudzovaná podľa skóre z vyšetrenia MDS-UPDRS III (*Movement Disorder Society-Unified Parkinson's Disease Rating Scale, part III*) [70]. Hodnoty sa pohybujú na škále od 0 do 132 a platí, že vyššie skóre indikuje výraznejšie motorické poruchy. Súčasťou rovnakého motorického vyšetrenia bolo aj posúdenie

kvality reči (MDS-UPDRS III *speech part*). Reč bola ohodnotená pomocou skóre v intervale od 0 (žiadne rečové problémy) do 4 (ťažko zrozumiteľná reč). Využitím MoCA (*Montreal Cognitive Assessment*) [71] boli hodnotené kognitívne schopnosti účastníkov na škále od 0 do 30 (čím nižšie skóre, tým nižšia kognitívna výkonnosť). Na základe BDI-II (*Beck Depression Inventory, second edition*) [72] boli u účastníkov posudzované príznaky depresie v rozsahu hodnôt od 0 do 63. Skóre stúpa so závažnosťou príznakov depresie.

2.1.2. Rečové úlohy

Cieľom použitých rečových úloh bolo získanie zvukových záznamov, ktoré by zachytávali emócie čo najviac sa približujúce prirodzeným. Analyzované nahrávky obsahujú spontánne rečové prejavy subjektov, ktoré boli ovplyvnené vizuálnym stimulom zameraným na vyvolanie žiadanej emócie.

Každému účastníkovi boli postupne prezentované tri skupiny obrázkov, ktoré obsahuje Príloha A. Každá skupina cieľila na vyvolanie inej emócie a zahŕňala štyri obrázky. Účastníci boli vyzvaní voľne opísať obrázky v jednotlivých skupinách a odhadnúť, čo podľa ich názoru každú štvoricu spája a čo ľudia na obrázkoch vyobrazení asi pociťujú. Podľa inštrukcií mali o každej štvorici rozprávať približne 1 minútu. Skupiny obrázkov zobrazovali radostné (príjemné, pozitívne), smutné (stresujúce, negatívne) a emocionálne neutrálné situácie.

Rečové signály boli nahrávané v tichých priestoroch, kde prenikalo minimum rušivého hluku z okolia. Každý subjekt absolvoval všetky rečové úlohy v rámci jediného sedenia. Nahrávania boli vedené rečovým odborníkom, ktorý dodržiaval štandardizovaný protokol. Pri získavaní nahrávok bol používaný kvalitný hlavový kondenzátorový mikrofón (Beyerdynamic Opus 55, Heilbronn, Nemecko), ktorý bol umiestňovaný približne 5 cm od úst hovoriaceho subjektu. Nahrávané signály boli vzorkované s frekvenciou 48 kHz a 16-bitovou kvantifikáciou.

2.1.3. Predspracovanie

Rečové nahrávky boli vopred zostrihané, tak, aby jedna úloha, teda opis jednej skupiny obrázkov, predstavoval jeden samostatný zvukový záznam. Zo začiatku a konca jednotlivých zostrihaných nahrávok boli odstránené nerečové časti, aby každý výsledný záznam zahŕňal iba užitočný signál. Na každého účastníka tak pripadajú tri zvukové záznamy, reprezentujúce tri rôzne emócie: radostnú (pozitívnu), neutrálnu a smutnú (negatívnu). Dohromady bolo

na následné analýzy k dispozícii 2 x 20 x 3 = 120 samostatných signálov o dĺžke $55,9 \pm 26,7$ s (priemer \pm štandardná odchýlka).

2.2. Akustické parametre

Na základe poznatkov naštudovaných v rámci teoretického rozboru problematiky v úvodnej kapitole predstavujú akustické parametre založené na základnej hlasivkovej frekvencii (F0), intenzite signálu, aspektoch časovania reči a MFCC najvhodnejšie spôsoby pre kvantifikovaný popis emócií v rečovom prejave. Taktiež sa na týchto parametroch prejavujú rečové poruchy pacientov s PD v porovnaní so zdravými ľuďmi [8], [13], [46], [65]. Automatické výpočty akustických parametrov boli realizované v prostredí Matlab (MathWorks, Natick, MA). Proces ich získavania sumarizuje Obrázok 1.

Dĺžka rečových páuz

Najskôr boli v signáloch determinované rečové úseky využitím detektoru rečovej aktivity [73]. Použitý algoritmus vychádza z analýzy výkonového spektra signálu a odhadu šumu. Na výstupe priradí každej vzorke signálu hodnotu 0 alebo v prípade zaznamenania rečovej aktivity 1. Neprerušované úseky bez rečovej aktivity (označené 0) dlhšie ako 60 ms boli považované za pauzy. Eliminácia nerečových úsekov nepresahujúcich 60 ms sa v súvislosti s akustickou analýzou reči pacientov s PD osvedčila v predošlých štúdiách [13]. Pre každú nahrávku bol v rámci tejto práce vypočítaný medián dĺžky trvania rečových páuz.

Základná hlasivková frekvencia

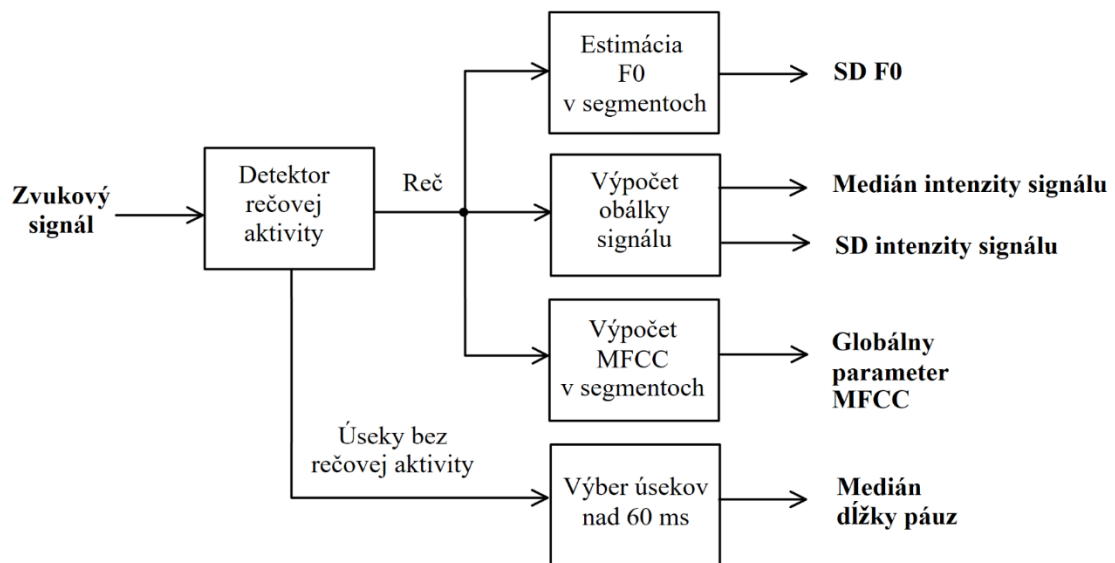
Signál v aktívnych rečových úsekoch (determinovaných podľa vyššie spomínaného detektoru rečovej aktivity) bol segmentovaný na 10 ms časové okná, v ktorých bola estimovaná základná hlasivková frekvencia F0. Použitý bol algoritmus [74], ktorý pracuje na princípe porovnávania spektra vstupného signálu a spektra pílového signálu. Algoritmus bol už skôr doporučený ako robustný a presný nástroj na výpočet priebehu F0 [75]. Výstup algoritmu predstavuje hodnotu F0 pílového signálu, ktorého spektrum najviac zodpovedá spektru vstupného signálu. Z hodnôt F0 v jednotlivých segmentoch bola určená štandardná odchýlka (*standard deviation*, *SD*). Parameter je prevedený z jednotky Herz na semitóny (logaritmickej škále) s cieľom minimalizácie rozdielov v F0 medzi pohlaviami [76].

Intenzita signálu

Z rečových častí každého signálu bola vypočítaná jeho obálka prostredníctvom kľzavého priemeru druhej mocniny signálu [77] v 200 ms dlhých časových oknách. Pre výpočet bola použitá funkcia *filter* dostupná v prostredí Matlab. Z výsledkov bol odvodený medián a štandardná odchýlka intenzity signálu v dB.

MFCC

Pre každý signál bolo určených prvých 16 MFCC, pričom nebol uvažovaný nultý koeficient c_0 odzrkadľujúci energiu signálu. Koeficienty boli počítané z 30 ms dlhých segmentov z rečových úsekov pomocou funkcie *mfcc* dostupnej v prostredí Matlab. Pri analýze bol použitý globálny parameter, ktorý zachováva vysokú informačnú hodnotu MFCC [47]. Jeho výpočet najskôr spočíval v určení štandardných odchýlok jednotlivých koeficientov naprieč segmentami a následne bol z týchto hodnôt stanovený priemer.



Obrázok 1: Postup získavania zvolených akustických parametrov zo zvukového signálu.

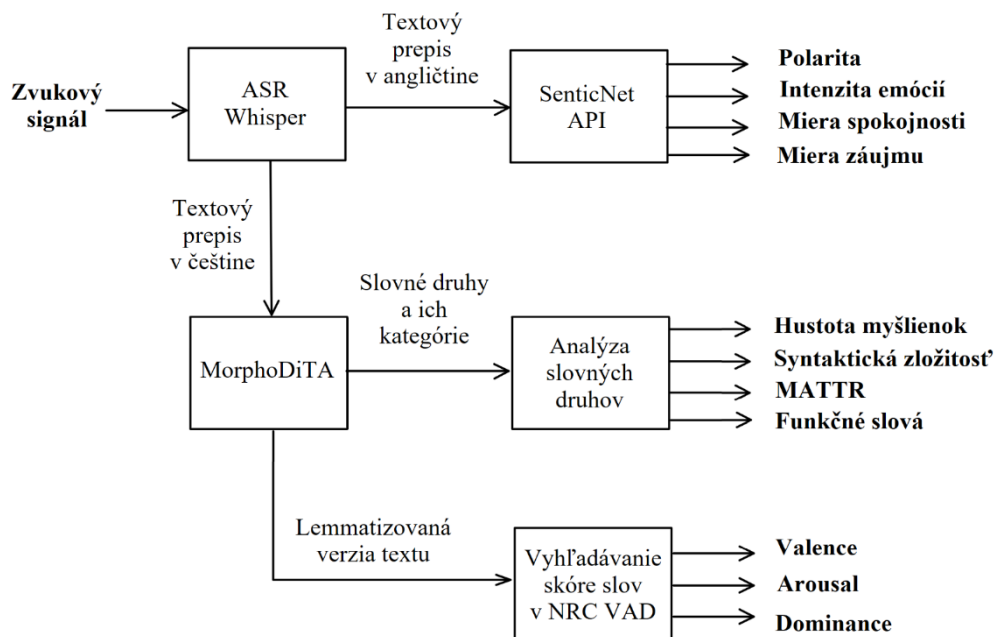
2.3. Lingvistické parametre

Analýza slovného obsahu rečového prejavu je podmienená získaním textového prepisu reči. V rámci práce bola použitá voľne dostupná neurónová sieť Whisper [51], ktorá predstavuje automatický systém na rozpoznávanie reči a dokáže určiť jazyk rečovej nahrávky, realizovať jej prepis vo viacerých jazykoch aj jej preklad do angličtiny. Whisper ponúka päť veľkostí modelov v Python implementácii, ktoré sa odlišujú v plnení požiadaviek presnosti a rýchlosti. V rámci práce bol použitý najväčší a najpresnejší model.

Výstupom spracovania zvukových signálov bol textový prepis nahrávok v českom jazyku. Záznamy však boli cez Whisper spracované ešte raz za účelom získania textových prekladov všetkých nahrávok v angličtine. Motiváciou pre preklad bola skutočnosť, že nie všetky metódy zvolené pre následnú analýzu sú schopné spracovávať texty v českom jazyku.

Na textových prepisoch v českom jazyku bola vykonaná morfológická analýza ktorá každému slovu priradila *lemma* (základný slovníkový tvar) a *part-of-speech tag* (slovný druh a jeho bližšie špecifikácie). Analýza bola realizovaná prostredníctvom voľne prístupného nástroja MorphoDiTa [78] s využitím aktuálne najnovšieho modelu pre český jazyk (Czech MorfFlex CZ 2.0 + PDT-C 1.0) [79]. Posledná verzia MorphoDiTa 1.11.2 bola stiahnutá ako binárny balíček a spracovanie textov bolo riadené jeho volaním z Python kódu.

Všetky lingvistické parametre vybrané na analýzu budú v tejto časti práce predstavené. Proces ich získavania z rečových nahrávok zhŕňa Obrázok 2.



Obrázok 2: Postup získavania zvolených lingvistických parametrov zo zvukového signálu.

2.3.1. Emočná analýza na úrovni celých prejavov

SenticNet [55] predstavuje znalostnú bázu, ktorá kombináciou lingvistiky, logiky a hlbokých neurónových sietí umožňuje interpretovateľnú reprezentáciu prirodzeného jazyka sprostredkujúcu analýzu emócií a sentimentu. Koncept je nezávislý od oblasti záujmu, uplatňuje sa napríklad v projektoch zameraných na rozhranie človek–stroj, v marketingu aj v medicínskych výskumoch. V rámci tejto práce bol nástroj použitý prostredníctvom voľne dostupných API (*application programming interface*, rozhranie na programovanie aplikácií) [56], ktoré sú schopné realizovať rozmanité úlohy ako detekcia polarity, rozpoznávanie emócií, posúdenie miery toxicity či odhad pravdepodobnosti depresie zo vstupných textových dokumentov.

V čase realizácie tejto práce boli API dostupné pre angličtinu a niekoľko ďalších jazykov, ale nie pre češtinu. Bolo teda nutné aplikovať ich na textové preklady nahrávok v anglickom jazyku, aj napriek riziku straty užitočných informácií. Z dostupných API bolo vybraných iba niekoľko reprezentatívnych a relevantných pre spracovanie v rámci tejto práce. Zvolené API boli volané z Python kódu a umožnili získať nasledujúce parametre z každej nahrávky.

Polarita (*API Polarity Classification*)

Kategorizácia textu na základe polarity na pozitívny, neutrálny alebo negatívny predstavuje základnú úlohu sentimentálnej analýzy. API zvažuje polaritu jednotlivých pojmov vo vstupnom texte a vzťahy medzi nimi pre pochopenie celého kontextu. Napokon priradí textu celkovú polaritu prostredníctvom jednej z kategorických značiek POSITIVE, NEUTRAL alebo NEGATIVE. [56]

Intenzita emócií (*API Intensity ranking*)

Emočná informácia v prejave môže byť vyjadrovaná rôznou intenzitou, čo ovplyvňuje celkový význam. Slovo „dobrý“ neznamená to isté, čo slovo „úžasný“, pretože pojmy sa líšia v sile vyjadrenia pozitívnej emócie. Parameter odráža intenzitu vyjadrovanej emocionálnej informácie v texte na škále od 0 do 100. [56]

Miera záujmu (*API Engagement measurement*)

Parameter hodnotí ako veľmi pútavý sa javí opisovaný kontext. Je založený na skúmaní polarity, intenzity a rozpoznávaní emócií. Odráža postoj a názor subjektu. Skúmanému textu priradil skóre od - 100 (nezáujem) do 100 (záujem). [56]

Miera spokojnosti (*API Well-being assessment*)

Parameter reflektuje aktuálne vnútorné rozpoloženie subjektu. Vstupný text bol ohodnotený na škále od - 100 (výrazný stres, nepríjemné pocity) do 100 (pocit blaha, spokojnosti). [56]

2.3.2. Emočná analýza s využitím lexikónu

V ďalšom kroku analýzy boli v skúmaných záznamoch vyhľadávané emócie reprezentované viacdimenzionálnym modelom. Pre analýzu bol zvolený lexikón *NRC Valence, Arousal, and Dominance* (NRC VAD) [33]. Slovník obsahuje približne 20 000 pojmov anotovaných numerickými hodnotami na škále od 0 po 1 v dimenziách *valence* (1 – príjemný, 0 – nepríjemný), *arousal* (1 – vzrušený, 0 – pokojný) a *dominance* (1 – plná kontrola, 0 – žiadna kontrola). Lexikón bol pôvodne vytvorený pre angličtinu, ale vznikli aj jeho preklady do viac než 100 ďalších jazykov. Keďže existuje aj česká verzia, spracovávané mohli byť originálne prepisy nahrávok

v českém jazyku, čo bolo motiváciou k realizácii tejto časti analýzy. Príklady českých slov s okrajovými hodnotami v jednotlivých dimenziách lexikónu prezentuje Tabuľka 2.

Tabuľka 2: Príklady slov s extrémnymi hodnotami v jednotlivých dimenziách českej verzie NRC VAD lexikónu. Inšpirácia v [33], [80].

Dimenzia	Slovo	Skóre	Slovo	Skóre
<i>Valence</i>	toxický	0,008	šťastný	1,000
	vrah	0,010	smích	0,980
	chaos	0,016	svoboda	0,969
<i>Arousal</i>	bavlna	0,071	agresivní	0,971
	uvolňující	0,087	šilenství	0,965
	spát	0,090	hurikán	0,958
<i>Dominance</i>	křehký	0,069	vítězný	0,972
	nedostatečné	0,093	monumentální	0,955
	líný	0,096	intenzita	0,952

Jednotlivé slová z každého prejavu boli vyhľadávané vo zvolenom slovníku, k čomu však bolo nutné použiť lemmatizované verzie prepisov získané prostredníctvom MorphoDiTa. Hodnoty *valence*, *arousal* a *dominance* (VAD) boli zaznamenané pre každé slovo z prejavu, ktoré bolo zahrnuté v lexikóne. Napokon boli pre každý prejav stanovené priemerné hodnoty všetkých troch dimenzií. Spracovanie prebiehalo v prostredí Matlab. Podobným prístupom s využitím rovnakého českého lexikónu boli z emočného hľadiska skúmané rečové nahrávky pacientov so schizofréniou v práci [80].

2.3.3. Analýza slovných druhov

Lingvistické parametre vychádzajúce z rozpoznania slovných druhov a ich bližších kategórií sa uplatňujú vo výskume viacerých neurodegeneratívnych ochorení, najmä ako marker poklesu kognitívnych funkcií [14], [15], [58], [81]. V rámci tejto exploratívnej analýzy bolo vybraných niekoľko parametrov s cieľom preskúmať či vykazujú rozdiely aj v závislosti na emóciách u pacientov s PD v porovnaní so zdravými jedincami. Pre výpočet nasledujúcich parametrov bol použitý výstup nástroja MorphoDiTa a programovací jazyk Python.

Hustota myšlienok (*Idea density*)

Parameter popisuje pomer faktov a vlastných tvrdení k celému prejavu subjektu. Za nositeľov myšlienok sa považujú slovesá, prídavné mená, príslovky, predložky a spojky. Výsledná hodnota parametru bola stanovená ako ich súčet vydelený celkovým počtom slov prejavu. [81]

Syntaktická zložitosť (*Syntactic complexity*)

Marker odráža mieru členitosti textu do súvetí. Jeho hodnota je stanovená ako počet slov indikujúcich zvýšenú gramatickú zložitosť a vnorenosť akými sú podrad'ovacie spojky (pretože, že,...), vzťahné zámená (ktorý, keď... pri uvádzaní vedľajších viet), slovesá a podstatné mená, vydelený celkovým počtom slov v prejave. Zastúpenie podrad'ovacích spojok a vzťahných zámen je pri výpočte brané do úvahy s dvojitou váhou, pretože sú najvýznamnejšími indikátormi vyššej členitosti. [81]

MATTR (*Moving-average type–token ratio*)

Parameter odráža bohatosť slovníka nezávisle na dĺžke prejavu. Okno stanovenej dĺžky postupne iteruje celým textom, pričom sa vždy posunie o jedno slovo. V každej iterácii je v aktuálnom výseku určený pomer unikátnych slov k celkovému počtu slov. Finálny parameter zodpovedá priemeru hodnôt zo všetkých výsekov. [14]

Funkčné slová (*Function words*)

Funkčné slová zahŕňajú zámená, predložky, spojky, pomocné slovesá a častice. Sú dôležité pre tvorbu gramaticky správnych viet. Ich absencia spôsobuje nižšiu zrozumiteľnosť aj plynulosť reči. Hodnota parametru bola stanovená ako pomer počtu funkčných slov k počtu všetkých slov v prejave. [58]

2.4. Štatistická analýza

2.4.1. RANOVA test

Všetky subjekty vykonávali tri úlohy, ktoré sa navzájom líšili vzhľadom k vyjadrovanej emócií. Išlo teda o opakované merania, a preto bol v rámci štatistickej analýzy použitý pre každý parameter so spojitými hodnotami test RANOVA (*repeated measures analysis of variance*)

so štruktúrou 2 skupiny (PD/HC) x 3 úlohy (*happy/neutral/sad*). RANOVA predstavuje vzhľadom k štruktúre dát najvhodnejší typ testu. V prípade splnenia podmienky sféricity (rozdiely meraní medzi všetkými dvojicami úloh majú rovnaký rozptyl), ktorú ošetruje funkcia *ranova* v prostredí Matlab [82] zvolená pre túto štatistickú analýzu, by mal byť test dostatočne robustný bez ohľadu na splnenie podmienky normálneho rozloženia dát [83]. RANOVA test bol nasledovaný post hoc analýzou s LSD (*least significant difference*) korekciou.

Použitý RANOVA test skúmal tri rôzne efekty. Efekt úlohy (EMÓCIA) neberie do úvahy delenie dát podľa skupín, ale odráža schopnosť alebo neschopnosť parametru rozlišovať niektoré úlohy medzi sebou a teda reflektovať emócie. Signifikantný efekt skupiny (SKUPINA) by ukazoval na prejav ochorenia u pacientov s PD na skúmanom parametri bez ohľadu na rôzne rečové úlohy. Štatisticky významná interakcia medzi skupinou a emóciou (SKUPINAxEMÓCIA) by značila rozdiely v prejavovaní sa nejakej emócie u pacientov s PD oproti zdravým jedincom. Pri vyhodnocovaní výsledkov bola uvažovaná štatistická hladina významnosti 5 %.

2.4.2. Klasifikácia

Prostredníctvom RANOVA testov boli vypočítané parametre posudzované individuálne. Avšak pomocou klasifikácie bolo možné pri úlohe rozlišovania emócií a skupín vyhodnocovať aj efekt kombinovania viacerých parametrov.

Klasifikácia bola v rámci tejto práce realizovaná využitím metódy SVM (*support vector machines*) s lineárnym jadrom. SVM je algoritmus strojového učenia založený na hľadaní nadroviny, ktorá čo najlepšie separuje tréningové dáta v priestore [84]. Metóda je určená pre binárne klasifikačné úlohy, avšak pre rozlišovanie viacerých tried je možné kombinovať výstupy z niekoľkých binárnych SVM, ktoré porovnávajú napríklad dve triedy medzi sebou alebo jednu triedu voči ostatným [85].

Pre implementovanie klasifikácie bol zvolený Matlab. Využitím funkcie *fitcsvm* bol trénovaný lineárny model SVM pre binárnu úlohu rozlišovania skupín PD a HC. Vytvorenie klasifikátora rozlišujúceho tri uvažované emócie si vyžadovalo funkciu *fitcecoc*, pričom boli trénované až tri verzie využívajúce buď PD dáta samostatne, HC dáta samostatne alebo dáta oboch skupín dohromady.

Výkonnosť klasifikátorov bola vyhodnocovaná krížovou validáciou typu *leave-one-out*, ktorej princíp spočíva vo využitých $n-1$ pozorovaní na natrénovanie SVM modelu a jedno zvyšné pozorovanie je vytvoreným modelom klasifikované prostredníctvom funkcie *predict*. Postup bol opakovaný n -krát tak, aby v každej iterácii bolo vynechané iné pozorovanie. Nakoniec bola

z výsledkov klasifikácií jednotlivých modelov určená celková úspešnosť ako pomer správne klasifikovaných pozorovaní ku všetkým n iteráciám.

Všetky štyri typy klasifikátorov (rozlišujúce skupiny PD a HC, emócie iba v skupine PD, emócie iba v skupine HC, emócie v oboch skupinách) boli vytvárané pre päť skupín parametrov:

- a) akustické (kapitola 3.1),
- b) vypočítané prostredníctvom SenticNet (kapitola 3.2.1),
- c) získané pomocou NRC VAD lexikónu (kapitola 3.2.2),
- d) odvodené z analýzy slovných druhov (kapitola 3.2.3),
- e) všetky dohromady.

Spolu bolo realizovaných $4 \times 5 = 20$ rôznych klasifikačných úloh, ktoré boli vyhodnocované na základe vypočítanej presnosti a matice zámen (*confusion matrix*).

3. Výsledky

Nasledujúca časť práce predstavuje výsledky štatistických testov aj vytvorených klasifikátorov, ktoré spracovávali vypočítané parametre definované v predchádzajúcej kapitole.

Distribúcie spojitéch parametrov v rámci skupín subjektov vzhľadom k jednotlivým úlohám boli reprezentované formou krabicových grafov. Krabicové grafy obsahujú medián, interkvartilový interval, minimálne i maximálne hodnoty, ktoré ešte nie sú považované za odľahlé hodnoty a prípadne aj vyznačené odľahlé pozorovania. Pre doplnenie a upresnenie informácií zobrazených v krabicových grafoch obsahuje Príloha B tabuľky sumarizujúce mediány a štandardné odchýlky pre všetky spojité parametre naprieč skupinami a rečovými úlohami.

3.1. Akustické parametre

Z rečových nahrávok boli vypočítané vybrané akustické parametre podľa kapitoly 2.2. Výsledky ich štatistickej analýzy prostredníctvom RANOVA testov prezentuje Obrázok 3. Tabuľka 3 obsahuje krabicové grafy, ktoré odhaľujú rozloženie daných parametrov vzhľadom k rečovým úlohám a skupinám.

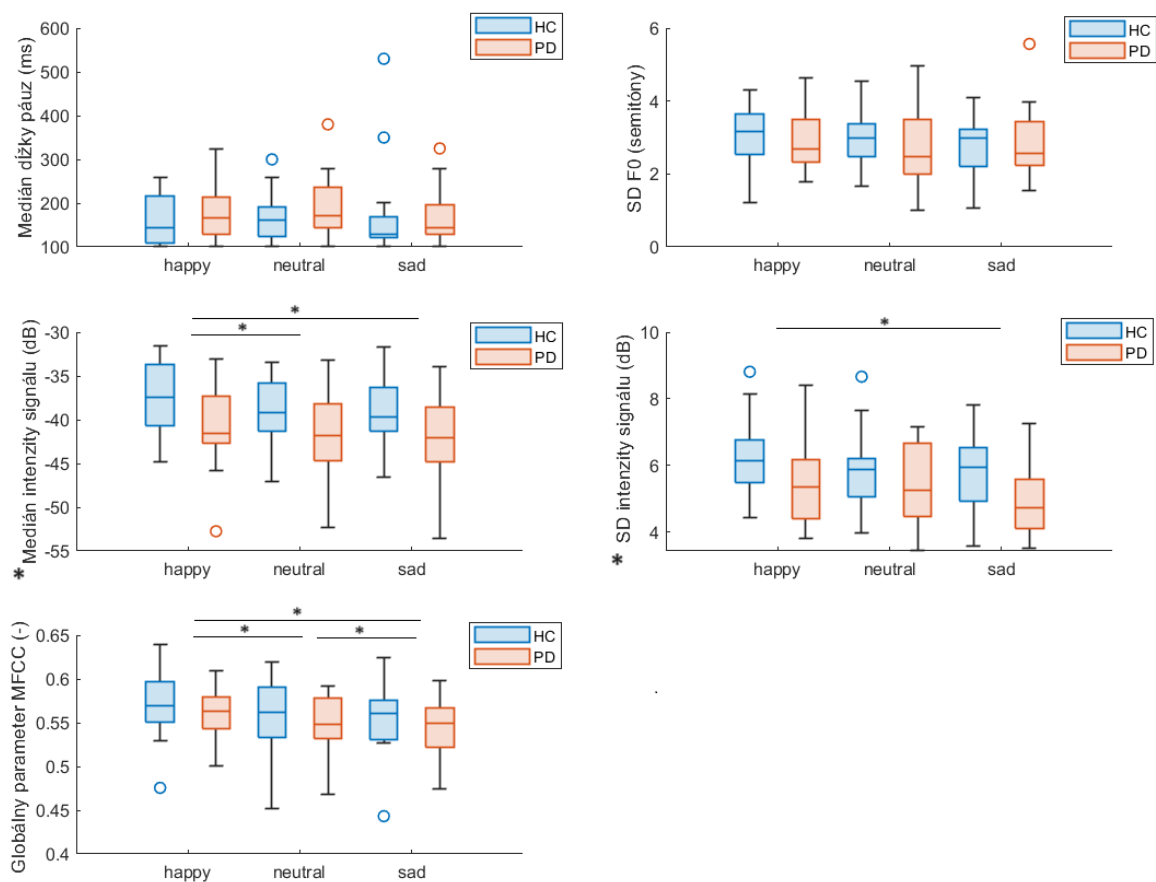
RANOVA testy ukazujú signifikantné rozdiely v dimenzii SKUPINA v prípade mediánu aj štandardnej odchýlky intenzity signálu. Vo všetkých rečových úlohách dosahujú distribúcie týchto dvoch parametrov u pacientov nižších mediánových hodnôt. Štatisticky významný efekt SKUPINA nebol u ostatných sledovaných parametrov zaznamenaný, hoci na základe grafov je možné pozorovať vo všetkých úlohách systematicky nižšie mediánové hodnoty SD F0 i globálneho parametru MFCC a naopak vyššie mediánové hodnoty dĺžky rečových páuz u pacientov s PD v porovnaní so zdravými kontrolami.

U viacerých akustických parametrov bol zaznamenaný signifikantný efekt EMÓCIA značiaci rozdiely medzi rečovými úlohami. Štatisticky významné rozdiely medzi všetkými dvojicami úloh boli odhalené v prípade globálneho parametru MFCC. Signifikantne odlišné hodnoty pri vyvolaní šťastnej emócie v porovnaní so smutnou vykazovali parametre medián aj SD intenzity signálu. Medián intenzity signálu dosahoval podľa post hoc analýzy výrazne rozdielnych hodnôt aj v prípade dvojice úloh *happy-neutral*. RANOVA test neukázal, že by boli dĺžky páuz a SD F0 typom rečovej úlohy štatisticky významne ovplyvnené.

Ani v prípade jediného parametra nebola zaznamenaná signifikantná interakcia medzi skupinou a emóciou.

Tabuľka 3: Výsledky RANOVA testov (efekty SKUPINA, EMÓCIA, SKUPINAxEMÓCIA) pre akustické parametre.

Parameter	SKUPINA		EMÓCIA		SKUPINAxEMÓCIA	
	F-štatistika	p-hodnota	F-štatistika	p-hodnota	F-štatistika	p-hodnota
Medián dĺžky páuz	0,48	0,493	0,50	0,607	0,75	0,475
SD F0	0,09	0,770	1,26	0,289	0,91	0,405
Medián intenzity signálu	4,28	0,045	31,54	<0,001	0,44	0,647
SD intenzity signálu	4,31	0,045	4,59	0,013	2,16	0,122
Globálny parameter z MFCC	1,11	0,299	22,24	<0,001	0,02	0,984




Obrázok 3: Krabicové grafy zobrazujúce distribúcie akustických parametrov vypočítaných pre skupiny PD a HC vzhľadom k rečovým úlohám.

Signifikantný efekt SKUPINA ($p < 0,05$) bol označený hviezdikou pred názvom zodpovedajúceho parametru na vertikálnej osi. V krabicových grafoch parametrov, u ktorých vyšiel štatisticky významný ($p < 0,05$) efekt EMÓCIA, boli hviezdikou vyznačené dvojice emócií, medzi ktorými boli post hoc analýzou identifikované signifikantné rozdiely.

3.2. Lingvistické parametre

3.2.1. Emočná analýza na úrovni celých prejavov

V rámci analýzy pomocou nástroja SenticNet bola určovaná polarita textových prepisov preložených do angličtiny. Parameter by mal korelovať s typom rečovej úlohy. Podľa grafických výsledkov (Obrázok 4) je zrejmé, že pri vyvolaní šťastnej emócie výrazne prevažuje pozitívna polarita a naopak pri opise obrázkov, ktoré by mali vyvolať smútok je polarita väčšiny prejavov negatívna. Pri emočne neutrálnej rečovej úlohe boli prejavy pacientov aj zdravých kontrol hodnotené prevažne ako pozitívne a neutrálna hodnota parametru nebola zaznamenaná ani v jedinom prípade.



Obrázok 4: Grafické spracovanie výsledkov parametru polarita získaného pomocou nástroja SenticNet zobrazuje percentuálne zastúpenie prejavov s negatívnou/neutrálnou/pozitívnou polaritou v rámci skupín PD a HC pri každej rečovej úlohe.

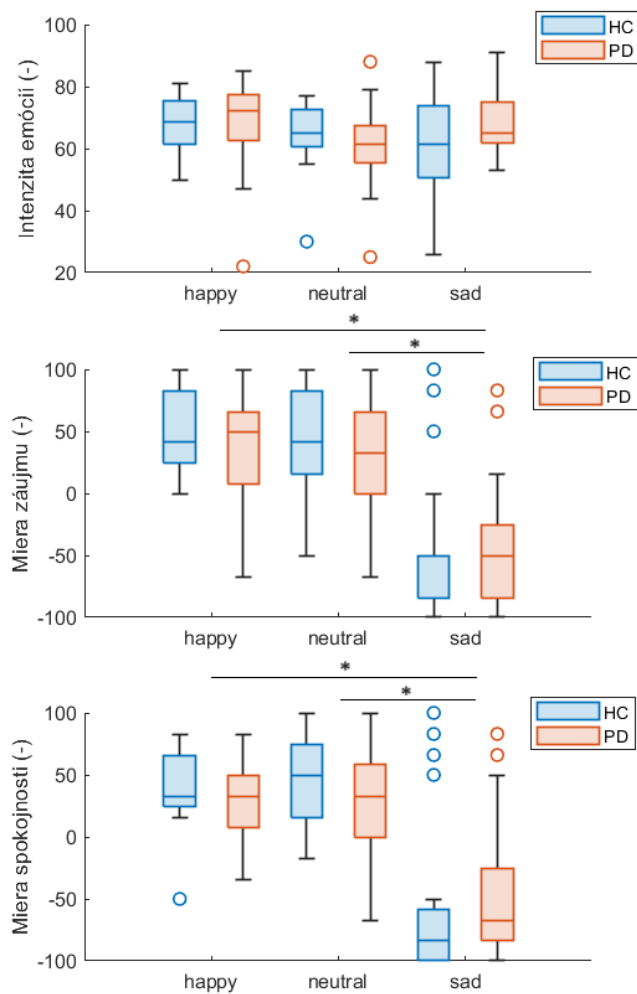
Výsledky RANOVA testov pre spojité parametre získané prostredníctvom nástroja SenticNet a popísané v kapitole 3.2.1 sumarizuje Tabuľka 4. Parametre miera záujmu aj miera spokojnosti odrážajú rozdiely medzi rečovými úlohami, keďže vykazujú signifikantný efekt EMÓCIA. Post hoc analýza odhalila výrazné rozdiely pri dvojiciach úloh *sad-neutral* a *sad-happy* v prípade oboch spomenutých parametrov. Pri rečovej úlohe zameranej na vyvolanie smutných emócií dosahujú oba parametre výrazne nižších hodnôt než pri ostatných dvoch úlohách, o čom vypovedá

aj Obrázok 5, ktorý prezentuje krabicové grafy pre všetky vybrané spojité parametre. Štatisticky významný rozdiel v intenzite emócií medzi jednotlivými úlohami nebol zaznamenaný. V prípade všetkých úloh dosahoval parameter približne zhodných výsledkov.

Signifikantný rozdiel medzi skupinami PD a HC ani interakcia SKUPINAxEMÓCIA neboli v rámci tejto časti analýzy zaznamenané.

Tabuľka 4: Výsledky RANOVA testov (efekty SKUPINA, EMÓCIA, SKUPINAxEMÓCIA) pre spojité SenticNet parametre.

Parameter	SKUPINA		EMÓCIA		SKUPINAxEMÓCIA	
	F-štatistika	p-hodnota	F-štatistika	p-hodnota	F-štatistika	p-hodnota
Intenzita emócií	0,16	0,688	1,55	0,219	1,59	0,210
Miera záujmu	0,31	0,580	41,69	<0,001	1,38	0,258
Miera spokojnosti	0,87	0,356	40,33	<0,001	0,82	0,444



Obrázok 5: Krabicové grafy zobrazujúce distribúcie SenticNet parametrov vypočítaných pre skupiny PD a HC vzhľadom k rečovým úlohám.

V krabicových grafoch parametrov, u ktorých vyšiel štatisticky významný ($p < 0,05$) efekt EMÓCIA, boli hviezdíčkou vyznačené dvojice emócií, medzi ktorými boli post hoc analýzou identifikované signifikantné rozdiely.

3.2.2. Emočná analýza s využitím lexikónu

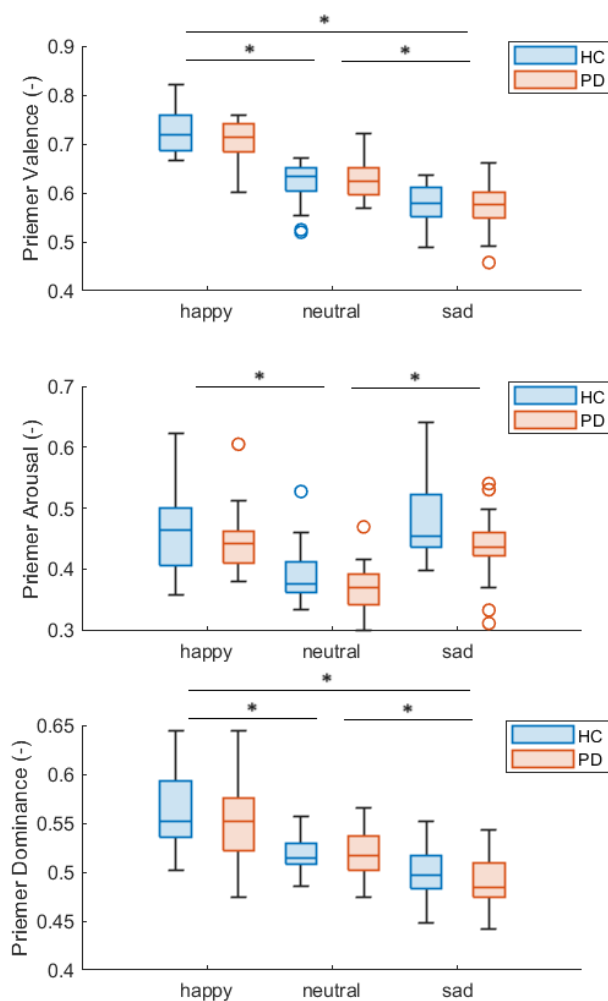
Rečovým prejavom bolo v rámci ďalšej oblasti analýzy prisudzované skóre v troch emočných dimenziách *valence*, *arousal* a *dominance* podľa postupu z kapitoly 2.3.2. Výsledky porovnania daných troch parametrov naprieč skupinami a rečovými úlohami pomocou testov RANOVA prezentuje Tabuľka 5. Obrázok 6 sumarizuje krabicové grafy zobrazujúce distribúcie týchto sledovaných parametrov vzhľadom ku skupinám a emóciám.

U všetkých troch sledovaných dimenzií sa prejavil výrazne signifikantný efekt EMÓCIA ($p < 0,001$), ktorý indikuje, že je možné pomocou daných parametrov rozlišovať niektoré rečové úlohy a teda emócie. Podľa post hoc analýzy sa signifikantné rozdiely v prípade *dominance* a *valence* vyskytli medzi všetkými dvojicami rečových úloh. *Arousal* dosahoval signifikantne nižšie skóre v prejavoch opisujúcich neutrálne obrázky v porovnaní s oboma zostávajúcimi rečovými úlohami.

RANOVA test neodhalil štatisticky významný efekt interakcie SKUPINAxEMÓCIA ani signifikantný rozdiel medzi skupinami.

Tabuľka 5: Výsledky RANOVA testov (SKUPINA, EMÓCIA, SKUPINAxEMÓCIA) pre tri emočné dimenzie *valence*, *arousal*, *dominance*.

Parameter	SKUPINA		EMÓCIA		SKUPINAxEMÓCIA	
	F-štatistika	p-hodnota	F-štatistika	p-hodnota	F-štatistika	p-hodnota
Priemer <i>valence</i>	0,32	0,572	110,70	< 0,001	0,60	0,550
Priemer <i>arousal</i>	3,34	0,075	56,72	< 0,001	0,78	0,461
Priemer <i>dominance</i>	0,59	0,446	50,65	< 0,001	0,53	0,593



Obrázok 6: Krabicové grafy zobrazujúce distribúcie vypočítaných hodnôt v troch emočných dimenziách *valence, arousal, dominance* pre skupiny PD a HC vzhľadom k rečovým úlohám.

V krabicových grafoch parametrov, pri ktorých vyšiel štatisticky významný ($p < 0,05$) efekt EMÓCIA, boli hviezdíčkou vyznačené dvojice emócií, medzi ktorými boli post hoc analýzou identifikované signifikantné rozdiely.

3.2.3. Analýza slovných druhov

Výsledky RANOVA testov týkajúcich sa parametrov vychádzajúcich z rozpoznávania slovných druhov prezentuje Tabuľka 6. Krabicové grafy porovnávajúce distribúcie parametrov naprieč skupinami a rečovými úlohami zobrazuje Obrázok 7.

P-hodnota nižšia ako 0,05 vypovedá o signifikantne odlišnej syntaktickej zložitosti medzi nahrávkami skupín PD a HC. Podľa krabicových grafov dosahujú rečové prejavy pacientov nižšie

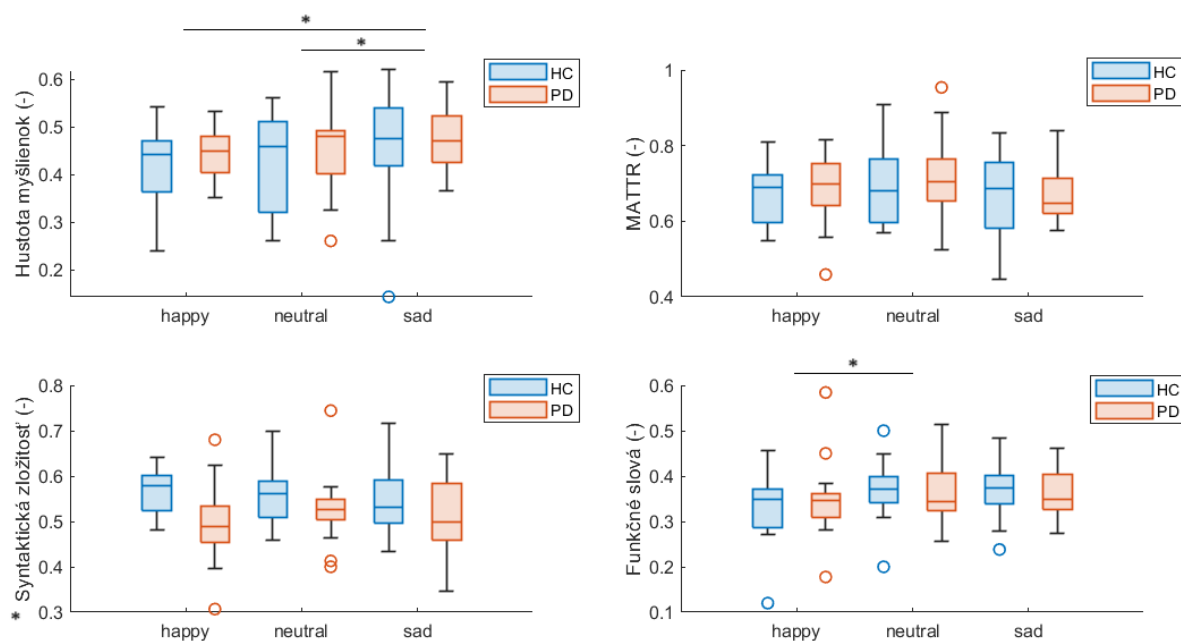
mediány syntaktickej zložitosti v porovnaní so zdravými jedincami u všetkých úloh. U ostatných parametrov nebol podľa RANOVA testu prítomný štatisticky významný rozdiel medzi skupinami.

Signifikantný efekt EMÓCIA bol zaznamenaný pri používaní funkčných slov v rečových prejavoch. Post hoc analýza ukázala, že pri opise obrázkov zobrazujúcich šťastné situácie bol medián zastúpenia funkčných slov signifikantne nižší než pri opisovaní súboru emočne neutrálnych obrázkov. P-hodnotu nižšiu ako stanovená hladina 0,05 pri efekte EMÓCIA dosiahol aj parameter odrážajúci hustotu myšlienok. Post hoc porovnaním bolo zistené, že pri rečovej úlohe *sad* dosahuje parameter signifikantne odlišných výsledkov než pri ostatných dvoch úlohách.

Ani pri jednom sledovanom parametri viažucom sa na analýzu slovných druhov nebola testom RANOVA odhalená štatisticky signifikantná interakcia medzi rečovými úlohami a skupinami.

Tabuľka 6: Výsledky RANOVA testov (SKUPINA, EMÓCIA, SKUPINAxEMÓCIA) pre vybrané parametre založené na analýze slovných druhov.

Parameter	SKUPINA		EMÓCIA		SKUPINAxEMÓCIA	
	F-štatistika	p-hodnota	F-štatistika	p-hodnota	F-štatistika	p-hodnota
Hustota myšlienok	1,00	0,324	4,90	0,010	0,33	0,719
MATTR	0,17	0,684	2,20	0,117	0,10	0,903
Syntaktická zložitosť	8,45	0,006	0,95	0,391	1,22	0,301
Funkčné slová	0,00	0,960	3,36	0,040	0,47	0,625



Obrázok 7: Krabicové grafy zobrazujúce distribúcie vybraných parametrov založených na analýze slovných druhov vypočítaných pre skupiny PD a HC vzhľadom k rečovým úlohám.

Signifikantný efekt SKUPINA ($p < 0,05$) bol označený hviezdíčkou pred názvom zodpovedajúceho parametru na vertikálnej osi. V krabicových grafoch parametrov, u ktorých vyšiel štatisticky významný ($p < 0,05$) efekt EMÓCIA, boli hviezdíčkou vyznačené dvojice emócií, medzi ktorými boli post hoc analýzou identifikované signifikantné rozdiely.

3.3. Klasifikácia

V rámci tejto práce boli rečové prejavy parametrizované z hľadiska niekoľkých oblastí. Pomocou SVM klasifikácie s lineárnym jadrom bola overovaná schopnosť skupín viacerých parametrov z jednotlivých oblastí rozlišovať sledované emócie a taktiež odhaľovať diagnózu PD. Ďalej bola posudzovaná aj výkonnosť kombinácie všetkých vypočítaných parametrov dohromady. Efektivita klasifikátorov bola validovaná pomocou techniky *leave-one-out* a Tabuľka 7 sumarizuje ich klasifikačné presnosti vypočítané podľa kapitoly 2.4.2.

Tabuľka 7: Vypočítaná presnosť [-] lineárnych SVM klasifikátorov s *leave-one-out* validáciou pre všetky skúmané klasifikačné úlohy.

Využívané parametre	PD vs HC	Emócie	Emócie – iba HC	Emócie – iba PD
Akustické parametre	0,658	0,308	0,117	0,217
SenticNet	0,417	0,575	0,583	0,633
Slovné druhy	0,667	0,358	0,300	0,267
VAD	0,517	0,858	0,800	0,867
Všetky parametre spolu	0,642	0,900	0,750	0,833

Na základe výsledných presností klasifikátorov možno pozorovať, že parametre vychádzajúce zo slovných druhov a akustickej analýzy dosiahli pri rozlišovaní pacientov od zdravých kontrol približne rovnakú úspešnosť takmer 0,7. Klasifikácia skupín PD a HC kombinujúca všetky analyzované parametre bolo podobne efektívna ako tieto dva samostatné prístupy. Naopak emočné dimenzie *valence*, *arousal*, *dominance* ani markre získané pomocou nástroja SenticNet neboli podľa výslednej nízkej presnosti pre túto úlohu vhodné.

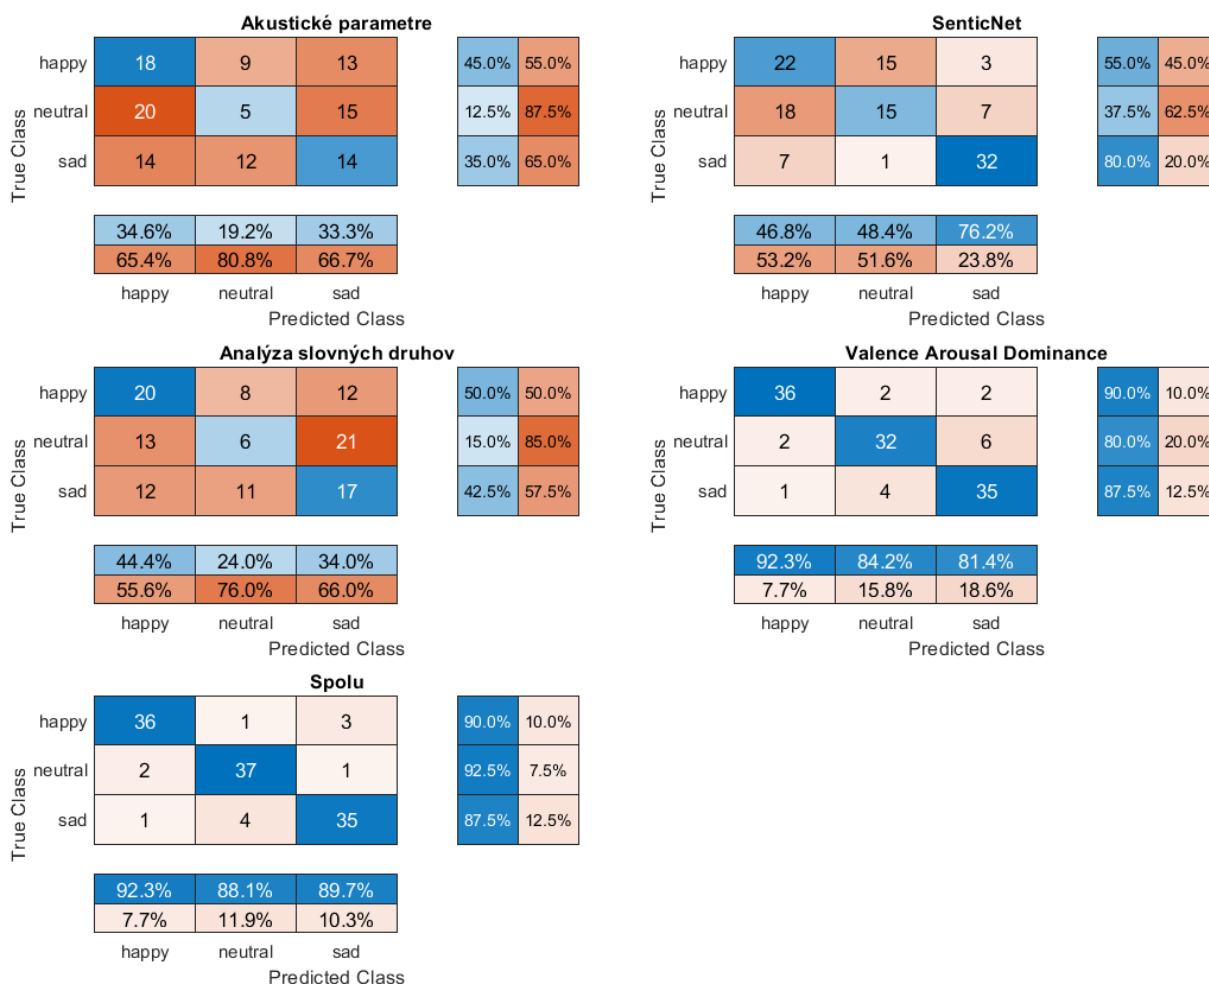
Pri rozlišovaní emócií zo všetkých dát bez ohľadu na diagnózu neboli parametre odvodené z akustickej stránky rečových prejavov a z analýzy slovných druhov užitočné. SenticNet parametre dokázali rozlišovať emócie efektívnejšie než diskriminovať skupiny PD a HC. SVM s emočnými dimenziami *valence*, *arousal*, *dominance* dosiahol porovnateľnú úspešnosť takmer 0,9 ako klasifikátor kombinujúci všetky parametre a oba výrazne prekonal ostatné prístupy.

Výsledné presnosti klasifikovania emócií individuálne v skupinách HC a PD približne zodpovedajú výsledkom dosiahnutým bez uvažovania diagnózy. Pri klasifikácii v skupine HC sú výsledky takmer vo všetkých oblastiach mierne horšie než v prípade skupiny PD.

Výsledky klasifikácie emócií boli okrem celkovej presnosti hodnotené aj prostredníctvom matíc zámen so zámerom posúdiť rozdiely pri rozlišovaní jednotlivých emócií medzi sebou. Matice zámen prezentujú absolútne aj percentuálne vyjadrené počty správne (senzitivita) a nesprávne zaradených pozorovaní v rámci uvažovaných tried ako aj úspešnosť predikcie každej triedy.

Obrázok 8 zobrazuje výsledné matice zámen pre úlohu klasifikácie emócií bez ohľadu na diagnózu. Klasifikácia využívajúca parametre vypočítané pomocou SenticNet dosahovala najvyššiu presnosť predikcie aj najvyššiu senzitivitu pre úlohu *sad* a vykazovala zjavný problém pri rozlišovaní úloh *neutral* a *happy*. V prípade rozlišovania emócií na základe emočných dimenzií *valence*, *arousal*, *dominance*, ale aj pri klasifikácii kombinujúcej všetky parametre bola

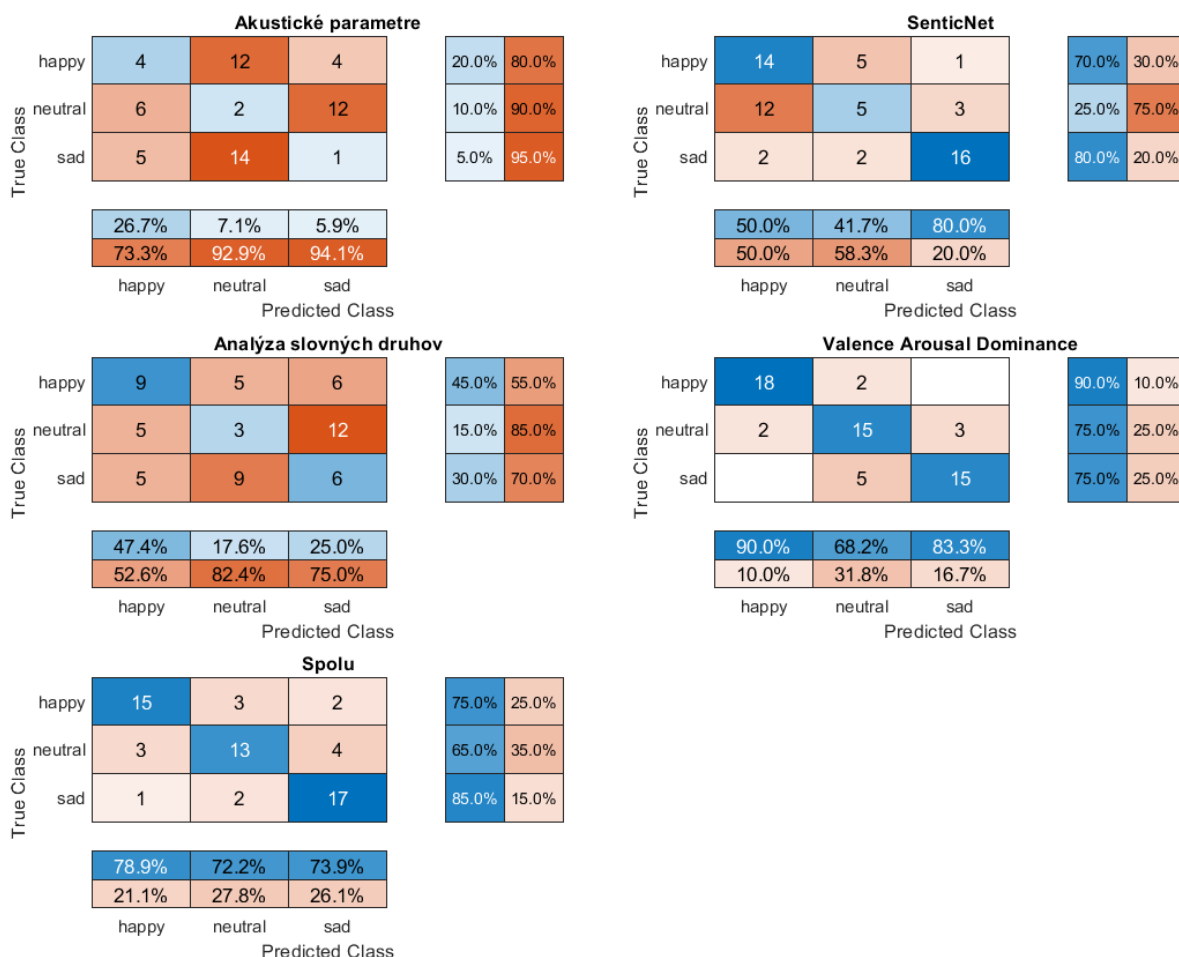
presnosť predikcie aj senzitivita pre jednotlivé emócie porovnateľná a veľmi vysoká (od 80 % do 92,3 %).



Obrázok 8: Matice zámen sumarizujúce výsledky lineárnych SVM klasifikátorov s *leave-one-out* validáciou pre úlohu klasifikácie emócií zo všetkých dát bez ohľadu na delenie skupín podľa diagnózy. Napravo od každej matice zámen sa zobrazujú percentuálne zastúpenia korektne (senzitivita, modrá farba) a chybné (oranžová farba) klasifikovaných pozorovaní každej triedy. Pod maticami je percentuálne vyjadrené koľkokrát bola každá trieda správne (modrá farba) a nesprávne (oranžová farba) predikovaná.

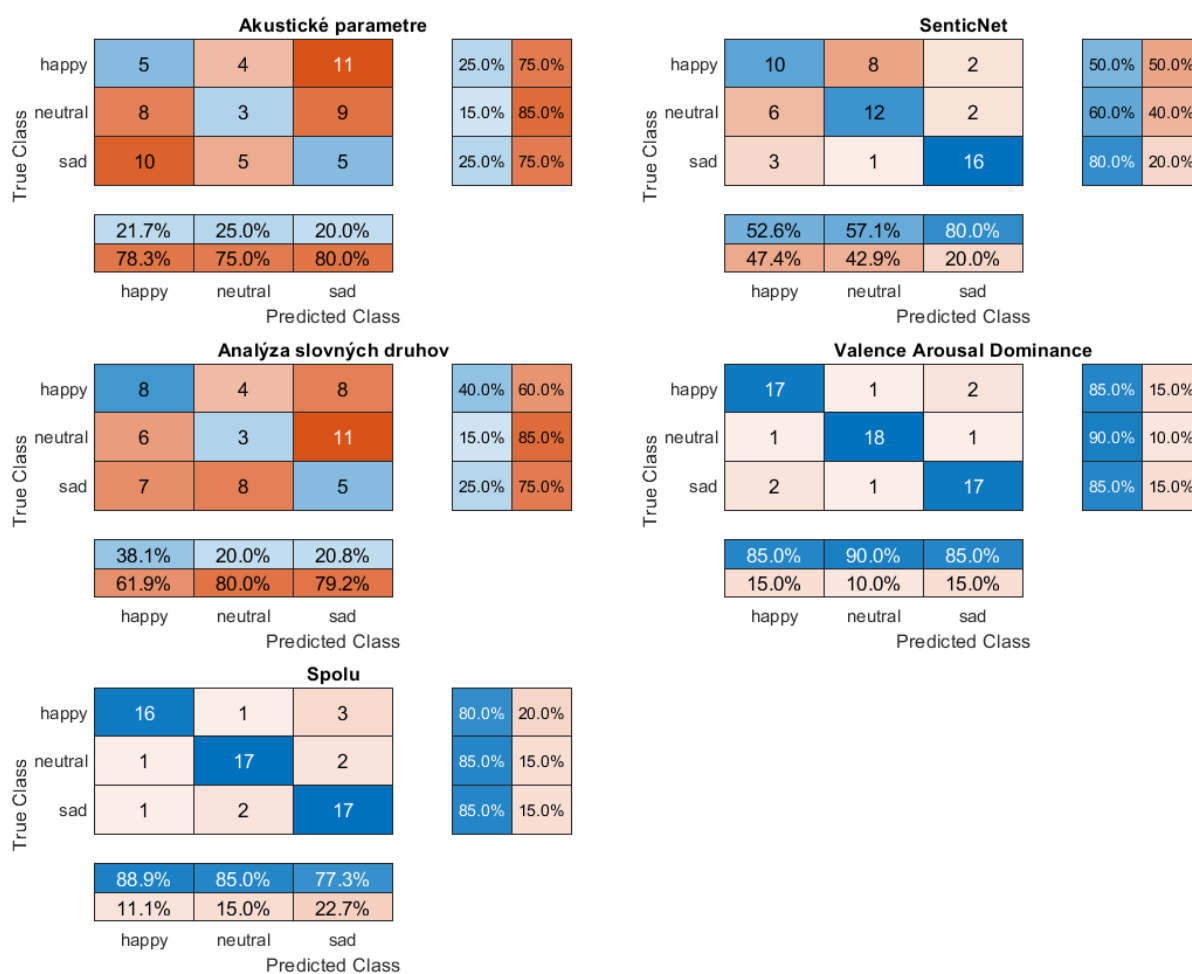
Obrázok 9 sumarizuje matice zámen pre rozlišovanie emócií iba u zdravých ľudí a Obrázok 10 sa vzťahuje ku klasifikácii emócií u pacientov s PD. Evidentné problémy sa vyskytli pri rozlišovaní úloh *neutral* a *happy* v prípade parametrov vychádzajúcich z analýzy slovných druhov u oboch skupín. Pri klasifikácii s dimenziami VAD aj pri kombinácii všetkých parametrov

boli uvažované emócie rozlišované s porovnateľnou a vysokou presnosťou v prípade dát od pacientov s PD. Avšak u dát od zdravých ľudí bola zaznamenaná nižšia presnosť predikcie triedy *neutral* pri klasifikácii s VAD parametrami a nižšia senzitivita pre triedu *neutral* v prípade klasifikátora pracujúceho so všetkými parametrami.



Obrázok 9: Matice zámien sumarizujúce výsledky lineárnych SVM klasifikátorov s *leave-one-out* validáciou pre úlohu klasifikácie emócií u zdravých ľudí.

Napravo od každej matice zámien sa zobrazujú percentuálne zastúpenia korektne (senzitivita, modrá farba) a chybné (oranžová farba) klasifikovaných pozorovaní každej triedy. Pod maticami je percentuálne vyjadrené koľkokrát bola každá trieda správne (modrá farba) a nesprávne (oranžová farba) predikovaná.



Obrázok 10: Matice zámien sumarizujúce výsledky lineárnych SVM klasifikátorov s *leave-one-out* validáciou pre úlohu klasifikácie emócií u pacientov s Parkinsonovou chorobou. Napravo od každej matice zámien sa zobrazujú percentuálne zastúpenia korektne (senzitivita, modrá farba) a chybné (oranžová farba) klasifikovaných pozorovaní každej triedy. Pod maticami je percentuálne vyjadrené koľkokrát bola každá trieda správne (modrá farba) a nesprávne (oranžová farba) predikovaná.

4. Diskusia

Diplomová práca sa zameriavala na skúmanie emočného obsahu rečových nahrávok od čerstvo diagnostikovaných a nemedikovaných pacientov s PD aj od zdravých ľudí. Predmetom analýzy bola akustická stránka, lingvistická oblasť slovných druhov aj emócie reflektovaný vo význame slov. Doposiaľ sa žiadna z podobne zameraných štúdií nevenovala naraz toľkým oblastiam. Ďalší rozdiel oproti väčšine predchádzajúcich podobných výskumov predstavuje použitá rečová databáza, ktorá namiesto nahrávok s hranými emóciami zahŕňa prirodzené rečové prejavy s emóciami vyvolávanými obrázkovými stimulmi.

Z rečových nahrávok troch rôznych emočných úloh od 20 zdravých ľudí a 20 pacientov boli pomocou automatických metód vypočítané parametre podľa kapitoly 2. Na základe štatistických analýz prostredníctvom RANOVA testov a SVM klasifikácie boli identifikované markery schopné rozpoznať diagnózu PD aj rozlišovať medzi sebou emócie. Táto kapitola práce sa zaoberá interpretáciou a porovnaním dosiahnutých výsledkov s doterajšími znalosťami z oblasti výskumu Parkinsonovho ochorenia.

V rámci akustickej oblasti vypovedajú poznatky z literatúry a závery predošlých štúdií o prejavovaní sa hypokinetickej dysartrie na reči pacientov bez ohľadu na vyjadrované emócie a ide napríklad o nízku hlasitosť či monohlasnosť [8], [13], [64], [69]. Signifikantne nižšie hodnoty mediánu a štandardnej odchýlky intenzity rečových prejavov pacientov oproti zdravým ľuďom vo všetkých skúmaných rečových úlohách v tejto práci, potvrdzujú uvedené závery. Analýzy naznačili aj tendenciu pacientov produkovať všeobecne monotónnejšiu reč (nižšia variabilita F0) v porovnaní so zdravými ľuďmi, čo tiež predstavuje známu charakteristiku parkinsonickej reči [8], [13], [69]. Rozdiely medzi skupinami však v prípade tejto práce neboli štatisticky významné, čo môže byť spôsobené krátkym trvaním symptómov PD s nízkou mierou narušenia reči. Akustické parametre sa medzi ostatnými testovanými markermi prejavili ako jedny z najsenzitívnejších pre odhalenie prítomnosti PD.

Výsledky RANOVA testov poukázali na schopnosť parametrov založených na meraní intenzity signálu (hlasitosť prejavu) a MFCC reflektovať rozdiely medzi určitými emóciami, čo je v súlade s niektorými doterajšími poznatkami [23], [35], [37], [40], [43], [64]. Naopak charakteristiky ako dĺžka rečových páuz a variabilita základnej hlasivkovej frekvencie neboli emóciami ovplyvnené, čo predstavuje rozdiel oproti doterajším záverom [35], [37], [40], [43], [64]. Vzhľadom na nízku úspešnosť klasifikácie emócií pri zdravých ľuďoch aj pri pacientoch (0,31 pri zmiešaní skupín, 0,12 pre HC, 0,22 pre PD) bolo nakoniec možné usúdiť, že akustické parametre neboli v tejto práci schopné dostatočne rozlišovať emócie v jednotlivých úlohách. Napríklad štúdia [65] však vypovedala o efektívite kombinácie

viacerých akustických parametrov pri klasifikácii emócií u zdravých ľudí aj u pacientov s PD. Rozpory s predchádzajúcimi výskumami by sa dali vysvetliť použitím iného typu emočnej databázy. V prvom rade simulované emočné databázy, ktoré boli v predchádzajúcich štúdiách prevažne využívané, obsahujú výraznejšie emócie než voľný prejav [35], [36], [37] a rozdiel medzi emóciami môže byť preto v ich prípade ľahšie identifikovateľný. Navyše možno usudzovať, že použité obrázkové stimuly nemuseli byť dostatočne intenzívne, aby dokázali vyvolať silné emócie schopné významne sa prejaviť v akustickej stránke reči.

V prípade analýz na základe lingvistických parametrov vychádzajúcich zo slovných druhov je podľa výsledkov RANOVA možné podľa nižšej syntaktickej zložitosti viet, ktorá popisuje mieru členitosti textu, odlíšiť pacientov od zdravých ľudí. Navyše kombinácia zvolených lingvistických parametrov konkuruje pri klasifikácii skupín s úspešnosťou 0,67 akustickým parametrom. Podobné lingvistické parametre odrážajú podľa doterajších štúdií kognitívne deficity v súvislosti s Parkinsonovým ochorením [14], [15], ale aj s inými neurodegeneratívnymi ochoreniami [58]. Možno preto predpokladať, že parametre z tejto oblasti identifikovali v rámci práce rozdiely v kognitívnych schopnostiach medzi skupinami, hoci skóre z kognitívnych vyšetrení ani počet rokov školskej dochádzky (Tabuľka 1) nevykazovali medzi pacientami a zdravými ľuďmi odlišnosti.

RANOVA testy naznačili významnými výsledkami pri efekte EMÓCIA, že hustota myšlienok či miera používania funkčných slov dokážu odrážať rozdiely medzi emóciami. V rámci štúdií sa len občas objavujú zmienky o uplatnení analýzy slovných druhov pri rozlišovaní emócií [40] či odhaľovaní depresie [29]. Konkrétne parametre použité v práci pravdepodobne neboli doposiaľ v súvislosti s emóciami testované a výsledky tak nie je možné porovnať. Táto oblasť lingvistických parametrov sa však nepreukázala ako efektívna pri SVM klasifikácii emócií, keďže vo všetkých prípadoch dosahovala úspešnosť okolo 0,3. Pre rozlišovanie emócií sa tak nezdá vhodná a vysvetľuje to aj všeobecne nízku mieru využívania podobných parametrov pri emočných analýzach.

Analýza sledujúca emočné dimenzie VAD ukázala, že obsah rečových prejavov subjektov bez ohľadu na diagnózu zodpovedal cieľným emóciám. Parameter *valence* presne odrážal polaritu, ktorá mala byť obrázkami vyjadrovaná. *Arousal* popisujúci intenzitu vyjadrovaných emócií dosahoval v porovnaní s emočne neutrálnou úlohou štatisticky významnejších hodnôt pri úlohách s emočným obsahom (*happy*, *sad*). Výsledky v dimenzii *dominance* sa zhodujú s predpokladmi, založenými na literatúre, ktoré tvrdia, že skóre v tejto dimenzii dosahuje nižších hodnôt pri negatívnych pocitoch súvisiacich so strachom či úzkosťou vyznačujúcich sa pocitom nízkej kontroly nad situáciou a naopak vyššími hodnotami pri radostných pocitoch [86]. Trojrozmerný model VAD je považovaný za veľmi efektívny prostriedok modelovania širokej

škály emócií [86]. Tieto predpoklady potvrdzuje vysoká úspešnosť klasifikácie prejavov na základe emócií pomocou emočných dimenzií VAD (úspešnosť okolo 0,8 v prípade oboch samostatných skupín a aj pri zmiešaní dát). Metóda sa tak javí ako veľmi vhodná pre rozlišovanie emócií v obsahu rečových alebo textových prejavov u zdravých ľudí a rovnako aj u pacientov s PD.

V prípade analýzy slovného obsahu prejavov ako celkov pomocou nástroja SenticNet boli bez ohľadu na diagnózu radostné emócie korektne reflektované signifikantne vyššou mierou spokojnosti a záujmu oproti negatívnymi emóciami ako smútok. Marker polarita tiež zvládol rozlišovať rečové prejavy s pozitívnymi a negatívnymi emóciami, avšak emočne neutrálnu úlohu nedokázal identifikovať. Aj ďalšie parametre z tejto oblasti analýzy vykazovali problémy v rozlišovaní neutrálnej úlohy a to nezávisle na skupine. Svedčia o tom výsledky RANOVA testov (úloha *neutral* nevykazovala signifikantné odlišnosti naraz od oboch zvyšných úloh pri žiadnom z parametrov) a aj nižšie výsledky klasifikácie (okolo 0,6 vo všetkých prípadoch) v porovnaní s analýzou na základe VAD, kde bol tiež sledovaný významom slov. Navyše nebol podľa nástroja SenticNet zaznamenaný rozdiel v intenzite prejavovaných emócií naprieč úlohami. Nižšia presnosť rozlišovania emočne neutrálnych prípadov už bola v doterajších výskumoch reportovaná [87]. Tieto zistenia sú však v rozpore s výsledkami analýzy pomocou VAD, v ktorej emočné dimenzie *valence* (polarita) aj *arousal* (intenzita) dokázali veľmi presne odlišovať emočne neutrálny prejav od ostatných. Rozdiely v prípade nástroja SenticNet však môžu byť pripísané strate informácií, ktorá sa viaže na preklad prejavov do angličtiny.

Nijaká emočná dimenzia z VAD ani parametre SenticNet reflektujúce obsah reči nevykazovali signifikantné rozdiely medzi skupinami pacientov a zdravých ľudí, ktoré by boli prítomné nezávisle na rečovej úlohe. Klasifikácia skupín pomocou SVM v prípade týchto oblastí tiež nedosiahla významnú úspešnosť (VAD 0,52 a SenticNet 0,42). Možno sa teda domnievať, že diagnóza sa všeobecne na výbere slov v reči neprejavuje. Avšak v jednej štúdií [67], ktorá skúmala bežné rečové prejavy bez vyvolaných emócií sa podarilo na základe dimenzií podobného trojrozmerného modelu (*pleasure, arousal, dominance*) identifikovať pacientov s PD s pomerne dobrým výsledkom. Štúdiá však využívala robustné neurónové siete, ktoré mohli byť efektívnejšie než metódy zvolené v tejto práci.

Klasifikácia emócií (v prípade bez delenia na diagnózu) pomocou parametrov zo všetkých oblastí dohromady mierne prekonala úspešnosťou 0,9 jednotlivé samostatné oblasti. Tento výsledok môže znamenať, že sledované oblasti sa navzájom dopĺňajú.

V prípade klasifikácie emócií samostatne u zdravých ľudí boli dosiahnuté výsledky úspešnosti takmer vo všetkých oblastiach mierne nižšie v porovnaní s klasifikáciou založenou na dátach iba od pacientov (Tabuľka 7). Jav možno pripísať relatívne malej veľkosti datasetov vzniknutých

po rozdelení pôvodnej databázy podľa diagnózy, čo mohlo viesť k mierne zavádzajúcim výsledkom. Hodnoty výslednej úspešnosti vzhľadom k použitém datasetom mierne oscilujú, ale trendy v klasifikácii emócií sú však zhodné pre obe skupiny samostatne aj pre ich zmiešanie. Ukazujú, že VAD prístup je najefektívnejší, SenticNet parametre za ním mierne zaostávajú a slovné druhy i akustické parametre sa zdajú menej vhodné.

Ani v prípade jednej skúmanej oblasti nebol RANOVA testami identifikovaný parameter, ktorý by vykazoval interakciu skupiny a emócie, teda rozdiely v prejavovaní sa niektorej emócie u pacientov s PD v porovnaní so zdravými ľuďmi. Približne zhodné tendencie pri klasifikácii emócií nezávisle na skupine aj v oboch skupinách samostatne (Tabuľka 7) tiež naznačujú, že prejavovanie emócií čerstvo diagnostikovaných pacientov sa zhoduje s prejavmi zdravých ľudí v akustickej aj lingvistickej oblasti. Lingvistické rozdiely v prejavoch pacientov a zdravých ľudí v závislosti na rôznych emóciách doposiaľ neboli inou štúdiou vyhodnocované, takže tieto výsledky nie je možné porovnať. Dá sa však uvažovať, že by sa rozdiely v prejavovaní emócií pacientov v lingvistickej oblasti oproti zdravým ľuďom mohli vyskytnúť až v pokročilých štádiách diagnózy a súvisieť aj s výraznejším kognitívnym deficitom. Alebo by sa mohli objaviť pri úplne spontánnych prejavoch, kde nie je výber slov podmienený obsahom obrázkov. V súvislosti s akustickou oblasťou niektoré doterajšie výskumy tvrdili, že prejavovanie emócií v reči pacientov vykazuje odlišnosti od zdravých ľudí objavujúce sa pri niektorých objektívnych akustických meraniach [20], [64]. Po akustickej stránke boli aj na základe subjektívnych hodnotení poslucháčov šťastné emócie v parkinsonickej reči menej výrazné a ťažšie identifikovateľné než u zdravých ľudí [63]. Tieto rozpory vo výsledkoch v porovnaní s doterajším výskumom môžu byť opäť pripísané rozdielom v použitých emočných databázach (predošlé štúdie využívali najmä hrané databázy s výraznejšími emóciami) a použitým obrázkovým stimulom, ktoré nemuseli byť dostatočne intenzívne, aby vyvolali akusticky výrazné emócie, na základe ktorých by sa dali prejavy medzi skupinami porovnávať.

5. Záver

5.1. Zhrnutie

V rámci diplomovej práce boli podľa dostupnej literatúry popísané poruchy rečových prejavov pri diagnóze PD a metódy ich automatického vyhodnocovania. Boli predstavené aj metódy parametrizácie reči, ktoré sa na základe rozsiahlej analýzy doterajších štúdií osvedčili pre popis emócií v rečových prejavoch. Práca sa ďalej venovala zhrnutiu doterajších poznatkov z oblasti detekcie emócií v reči pacientov s PD. Na rečové nahrávky spontánneho popisu obrázkov boli aplikované vybrané metódy implementované pomocou nástrojov Matlab a Python s cieľom automatickej detekcie emócií a odhalenia prípadných rozdielov v prejavoch emócií v reči u pacientov oproti zdravým ľuďom. Pomocou štatistických metód (RANOVA, SVM klasifikácia) boli identifikované najvhodnejšie parametre schopné odhaliť v reči emócie aj diagnózu PD.

Emočné dimenzie *valence*, *arousal*, *dominance* mapujúce obsahovú stránku reči dokázali podľa výsledkov najlepšie odlišiť radosť aj smútok od emočne neutrálnych prejavov a zhodne v prípade zdravých ľudí aj pacientov s PD.

Výsledky ďalej ukázali, že akustické parametre (najmä merania intenzity signálu) a markery založené na analýze slovných druhov (najmä syntaktická zložitosť) sú schopné odlišovať reč pacientov od reči zdravých ľudí nezávisle na emóciách.

Analýzy nepreukázali rozdiely v prejavovaní emócií medzi zdravými ľuďmi a pacientmi s PD ani v jedinej skúmanej oblasti. Výsledky nepotvrdili doterajšie pozorovania, ktoré pripisovali akustickým parametrom významnú schopnosť detegovať emócie v reči, hoci pripustili, že parametre založené na intenzite signálu a MFCC dokážu reflektovať niektoré rozdiely medzi emóciami u zdravých ľudí a rovnako aj u pacientov s PD. Závery však môžu byť ovplyvnené limitáciami použitej metódy vyvolávania emócií pomocou obrázkových stimulov a mali by byť overené ďalšími štúdiami.

5.2. Budúci výskum

Táto práca predstavuje prvú ucelenú analýzu prejavovania emócií vo viacerých rečových dimenziách u pacientov s PD. Prispela tak k rozšíreniu poznatkov o diagnóze a naznačila uplatnenie emočných parametrov *valence*, *arousal*, *dominance* pri detekcii emócií v rečových prejavoch pacientov, čo môže byť základ pre ďalšie rozširujúce výskumy.

V budúcom výskume by sa však mohli uplatniť iné druhy stimulov, ktoré by boli schopné vyvolať v reči výraznejšie emócie. Napríklad audiovizuálny stimul by pôsobil naraz na viac zmyslov a mal tak väčší potenciál vyvolať dostatočne silné emócie. Najvhodnejšie by však bolo skúmať emočné prejavy v prirodzených rečových databázach, ktoré by napríklad boli anotované samotnými subjektami. Mohlo by ísť o nahrávky z reálnych situácií ako telefonáty. Ďalej by bolo užitočné experimenty realizovať vo väčšej mierke, či už z pohľadu počtu účastníkov, ale aj počtu sledovaných emócií.

Použitá literatúra

- [1] DE RIJK, M.C.; LAUNER, L.J.; BERGER, K.; BRETELER, M.M.; DARTIGUES, J.F. et al. Prevalence of Parkinson's disease in Europe: A collaborative study of population-based cohorts. Neurologic Diseases in the Elderly Research Group. Online. *Neurology*. 2000, roč. 54, č. 11, s. 21-23. [cit. 2024-01-25].
- [2] POEWE, Werner; SEPPI, Klaus; TANNER, Caroline M.; HALLIDAY, Glenda M.; BRUNDIN, Patrik et al. Parkinson disease. Online. *Nature Reviews Disease Primers*. 2017, roč. 3, č. 1. ISSN 2056-676X. Dostupné z: <https://doi.org/10.1038/nrdp.2017.13>. [cit. 2024-01-25].
- [3] RODRIGUEZ-OROZ, Maria C; JAHANSHAHI, Marjan; KRACK, Paul; LITVAN, Irene; MACIAS, Raúl et al. Initial clinical manifestations of Parkinson's disease: features and pathophysiological mechanisms. Online. *The Lancet Neurology*. 2009, roč. 8, č. 12, s. 1128-1139. ISSN 14744422. Dostupné z: [https://doi.org/10.1016/S1474-4422\(09\)70293-5](https://doi.org/10.1016/S1474-4422(09)70293-5). [cit. 2024-01-25].
- [4] PÉRON, Julie; DONDAINE, Thibaut; LE JEUNE, Florence; GRANDJEAN, Didier a VÉRIN, Marc. Emotional processing in Parkinson's disease: A systematic review. Online. *Movement Disorders*. 2012, roč. 27, č. 2, s. 186-199. ISSN 0885-3185. Dostupné z: <https://doi.org/10.1002/mds.24025>. [cit. 2024-01-25].
- [5] BERNHEIMER, H.; BIRKMAYER, W.; HORNYKIEWICZ, O.; JELLINGER, K. a SEITELBERGER, F. Brain dopamine and the syndromes of Parkinson and Huntington Clinical, morphological and neurochemical correlations. Online. *Journal of the Neurological Sciences*. 1973, roč. 20, č. 4, s. 415-455. ISSN 0022510X. Dostupné z: [https://doi.org/10.1016/0022-510X\(73\)90175-5](https://doi.org/10.1016/0022-510X(73)90175-5). [cit. 2024-01-25].
- [6] CASTRIOTO, Anna; LHOMMÉE, Eugénie; MORO, Elena a KRACK, Paul. Mood and behavioural effects of subthalamic stimulation in Parkinson's disease. Online. *The Lancet Neurology*. 2014, roč. 13, č. 3, s. 287-305. ISSN 14744422. Dostupné z: [https://doi.org/10.1016/S1474-4422\(13\)70294-1](https://doi.org/10.1016/S1474-4422(13)70294-1). [cit. 2024-04-13].
- [7] BEAULIEU-BOIRE, Isabelle a LANG, Anthony E. Behavioral effects of levodopa. Online. *Movement Disorders*. 2015, roč. 30, č. 1, s. 90-102. ISSN 0885-3185. Dostupné z: <https://doi.org/10.1002/mds.26121>. [cit. 2024-04-13].

- [8] DUFFY, Joseph R. *Motor speech disorders: substrates, differential diagnosis, and management*. Third edition. St. Louis, Missouri: Elsevier, [2013]. ISBN 978-0-323-07200-7.
- [9] LOGEMANN, Jeri A.; FISHER, Hilda B.; BOSHER, Benjamin a BLONSKY, E. Richard. Frequency and Cooccurrence of Vocal Tract Dysfunctions in the Speech of a Large Sample of Parkinson Patients. Online. *Journal of Speech and Hearing Disorders*. 1978, roč. 43, č. 1, s. 47-57. ISSN 0022-4677. Dostupné z: <https://doi.org/10.1044/jshd.4301.47>. [cit. 2024-01-25].
- [10] HO, Aileen K.; IANSEK, Robert; MARIGLIANI, Caterina; BRADSHAW, John L. a GATES, Sandra. Speech Impairment in a Large Sample of Patients with Parkinson's Disease. Online. *Behavioural Neurology*. 1999, roč. 11, č. 3, s. 131-137. ISSN 0953-4180. Dostupné z: <https://doi.org/10.1155/1999/327643>. [cit. 2024-01-25].
- [11] DARLEY, Frederic L.; ARONSON, Arnold E. a BROWN, Joe R. Differential Diagnostic Patterns of Dysarthria. Online. *Journal of Speech and Hearing Research*. 1969, roč. 12, č. 2, s. 246-269. ISSN 0022-4685. Dostupné z: <https://doi.org/10.1044/jshr.1202.246>. [cit. 2024-01-25].
- [12] POSTUMA, R. B.; LANG, A. E.; GAGNON, J. F.; PELLETIER, A. a MONTPLAISIR, J. Y. How does parkinsonism start? Prodromal parkinsonism motor changes in idiopathic REM sleep behaviour disorder. Online. *Brain*. 2012, roč. 135, č. 6, s. 1860-1870. ISSN 0006-8950. Dostupné z: <https://doi.org/10.1093/brain/aws093>. [cit. 2024-01-25].
- [13] RUSZ, J.; CMEJLA, R.; RUZICKOVA, H. a RUZICKA, E. Quantitative acoustic measurements for characterization of speech and voice disorders in early untreated Parkinson's disease. Online. *The Journal of the Acoustical Society of America*. 2011, roč. 129, č. 1, s. 350-367. ISSN 0001-4966. Dostupné z: <https://doi.org/10.1121/1.3514381>. [cit. 2024-01-25].
- [14] ŠUBERT, Martin; ŠIMEK, Michal; NOVOTNÝ, Michal; TYKALOVÁ, Tereza; BEZDÍČEK, Ondřej et al. Linguistic Abnormalities in Isolated Rapid Eye Movement Sleep Behavior Disorder. Online. *Movement Disorders*. 2022, roč. 37, č. 9, s. 1872-1882. ISSN 0885-3185. Dostupné z: <https://doi.org/10.1002/mds.29140>. [cit. 2024-03-17].
- [15] ŠUBERT, Martin; NOVOTNÝ, Michal; TYKALOVÁ, Tereza; HLAVNIČKA, Jan; DUŠEK, Petr et al. Spoken Language Alterations can Predict Phenoconversion in Isolated Rapid Eye Movement Sleep Behavior Disorder: A Multicenter Study. Online.

- Annals of Neurology*. 2024, roč. 95, č. 3, s. 530-543. ISSN 0364-5134. Dostupné z: <https://doi.org/10.1002/ana.26835>. [cit. 2024-03-17].
- [16] COUNDOURIS, Sarah P.; ADAMS, Alexandra G.; GRAINGER, Sarah A. a HENRY, Julie D. Social perceptual function in parkinson's disease: A meta-analysis. Online. *Neuroscience & Biobehavioral Reviews*. 2019, roč. 104, s. 255-267. ISSN 01497634. Dostupné z: <https://doi.org/10.1016/j.neubiorev.2019.07.011>. [cit. 2024-01-25].
- [17] PRENGER, Margaret T. M.; MADRAY, Racheal; VAN HEDGER, Kathryne; ANELLO, Mimma; MACDONALD, Penny A. et al. Social Symptoms of Parkinson's Disease. Online. *Parkinson's Disease*. 2020, roč. 2020, s. 1-10. ISSN 2042-0080. Dostupné z: <https://doi.org/10.1155/2020/8846544>. [cit. 2024-01-25].
- [18] GRAY, Heather M. a TICKLE-DEGNEN, Linda. A meta-analysis of performance on emotion recognition tasks in Parkinson's disease. Online. *Neuropsychology*. 2010, roč. 24, č. 2, s. 176-191. ISSN 1931-1559. Dostupné z: <https://doi.org/10.1037/a0018104>. [cit. 2024-01-25].
- [19] HAZAMY, Audrey A. a ALTMANN, Lori J. P. Emotional Sentence Processing in Parkinson's Disease. Online. *Journal of Speech, Language, and Hearing Research*. 2022, roč. 65, č. 11, s. 4291-4299. ISSN 1092-4388. Dostupné z: https://doi.org/10.1044/2022_JSLHR-22-00021. [cit. 2024-01-25].
- [20] MÖBES, Janine; JOPPICH, Gregor; STIEBRITZ, Frank; DENGLER, Reinhard a SCHRÖDER, Christine. Emotional speech in Parkinson's disease. Online. *Movement Disorders*. 2008, roč. 23, č. 6, s. 824-829. ISSN 0885-3185. Dostupné z: <https://doi.org/10.1002/mds.21940>. [cit. 2024-01-25].
- [21] GRANDJEAN, Didier; SANDER, David a SCHERER, Klaus R. Conscious emotional experience emerges as a function of multilevel, appraisal-driven response synchronization. Online. *Consciousness and Cognition*. 2008, roč. 17, č. 2, s. 484-495. ISSN 10538100. Dostupné z: <https://doi.org/10.1016/j.concog.2008.03.019>. [cit. 2024-01-25].
- [22] BENSON, John. Emotion and Expression. Online. *The Philosophical Review*. 1967, roč. 76, č. 3. ISSN 00318108. Dostupné z: <https://doi.org/10.2307/2183623>. [cit. 2024-01-25].

- [23] AKÇAY, Mehmet Berkehan a OĞUZ, Kaya. Speech emotion recognition: Emotional models, databases, features, preprocessing methods, supporting modalities, and classifiers. Online. *Speech Communication*. 2020, roč. 116, s. 56-76. ISSN 01676393. Dostupné z: <https://doi.org/10.1016/j.specom.2019.12.001>. [cit. 2024-01-25].
- [24] SCHULLER, Björn W. Speech emotion recognition. Online. *Communications of the ACM*. 2018, roč. 61, č. 5, s. 90-99. ISSN 0001-0782. Dostupné z: <https://doi.org/10.1145/3129340>. [cit. 2024-01-25].
- [25] COWIE, R.; DOUGLAS-COWIE, E.; TSAPATSOUKIS, N.; VOTSIS, G.; KOLLIAS, S. et al. Emotion recognition in human-computer interaction. Online. *IEEE Signal Processing Magazine*. 2001, Roč. 18, č. 1, s. 32-80. ISSN 10535888. Dostupné z: <https://doi.org/10.1109/79.911197>. [cit. 2024-01-25].
- [26] SCHULLER, B.; RIGOLL, G. a LANG, M. Speech emotion recognition combining acoustic features and linguistic information in a hybrid support vector machine-belief network architecture. Online. In: *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*. IEEE, 2004, I-577-80. ISBN 0-7803-8484-9. Dostupné z: <https://doi.org/10.1109/ICASSP.2004.1326051>. [cit. 2024-01-25].
- [27] ZEPF, Sebastian; HERNANDEZ, Javier; SCHMITT, Alexander; MINKER, Wolfgang a PICARD, Rosalind W. Driver Emotion Recognition for Intelligent Vehicles. Online. *ACM Computing Surveys*. 2021, roč. 53, č. 3, s. 1-30. ISSN 0360-0300. Dostupné z: <https://doi.org/10.1145/3388790>. [cit. 2024-03-25].
- [28] CHUL MIN LEE a NARAYANAN, S.S. Toward detecting emotions in spoken dialogs. Online. *IEEE Transactions on Speech and Audio Processing*. 2005, roč. 13, č. 2, s. 293-303. ISSN 1063-6676. Dostupné z: <https://doi.org/10.1109/TSA.2004.838534>. [cit. 2024-01-25].
- [29] DESOUZA, Danielle D.; ROBIN, Jessica; GUMUS, Melisa a YEUNG, Anthony. Natural Language Processing as an Emerging Tool to Detect Late-Life Depression. Online. *Frontiers in Psychiatry*. 2021, roč. 12. ISSN 1664-0640. Dostupné z: <https://doi.org/10.3389/fpsy.2021.719125>. [cit. 2024-01-25].
- [30] HANSEN, Lasse; ZHANG, Yan-Ping; WOLF, Detlef; SECHIDIS, Konstantinos; LADEGAARD, Nicolai et al. A generalizable speech emotion recognition model reveals depression and remission. Online. *Acta Psychiatrica Scandinavica*. 2022, roč. 145, č. 2,

- s. 186-199. ISSN 0001-690X. Dostupné z: <https://doi.org/10.1111/acps.13388>. [cit. 2024-01-25].
- [31] EKMAN, P a OSTER, H. Facial Expressions of Emotion. Online. *Annual Review of Psychology*. 1979, roč. 30, č. 1, s. 527-554. ISSN 0066-4308. Dostupné z: <https://doi.org/10.1146/annurev.ps.30.020179.002523>. [cit. 2024-03-09].
- [32] RUSSELL, James A. A circumplex model of affect. Online. *Journal of Personality and Social Psychology*. 1980, roč. 39, č. 6, s. 1161-1178. ISSN 1939-1315. Dostupné z: <https://doi.org/10.1037/h0077714>. [cit. 2024-03-09].
- [33] MOHAMMAD, Saif. Obtaining Reliable Human Ratings of Valence, Arousal, and Dominance for 20,000 English Words. Online. In: *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*. Stroudsburg, PA, USA: Association for Computational Linguistics, 2018, s. 174-184. Dostupné z: <https://doi.org/10.18653/v1/P18-1017>. [cit. 2024-03-09].
- [34] NANDWANI, Pansy a VERMA, Rupali. A review on sentiment analysis and emotion detection from text. Online. *Social Network Analysis and Mining*. 2021, roč. 11, č. 1. ISSN 1869-5450. Dostupné z: <https://doi.org/10.1007/s13278-021-00776-6>. [cit. 2024-03-16].
- [35] KOOLAGUDI, Shashidhar G. a RAO, K. Sreenivasa. Emotion recognition from speech: a review. Online. *International Journal of Speech Technology*. 2012, roč. 15, č. 2, s. 99-117. ISSN 1381-2416. Dostupné z: <https://doi.org/10.1007/s10772-011-9125-1>. [cit. 2024-01-25].
- [36] WILLIAMS, Carl E. a STEVENS, Kenneth N. Emotions and Speech: Some Acoustical Correlates. Online. *The Journal of the Acoustical Society of America*. 1972, roč. 52, č. 4B, s. 1238-1250. ISSN 0001-4966. Dostupné z: <https://doi.org/10.1121/1.1913238>. [cit. 2024-01-25].
- [37] EL AYADI, Moataz; KAMEL, Mohamed S. a KARRAY, Fakhri. Survey on speech emotion recognition: Features, classification schemes, and databases. Online. *Pattern Recognition*. 2011, roč. 44, č. 3, s. 572-587. ISSN 00313203. Dostupné z: <https://doi.org/10.1016/j.patcog.2010.09.020>. [cit. 2024-01-25].
- [38] BATLINER, A.; FISCHER, K.; HUBER, R.; SPIKER, J. a NÖTH, E. Desperately seeking emotions: Actors, wizards and human beings. Online. *Proceedings of the ISCA*

- Workshop on Speech and Emotion: A Conceptual Framework for Research*. 2000, s. 195-200. Dostupné z: <https://api.semanticscholar.org/CorpusID:8775936>. [cit. 2024-01-25].
- [39] HUANG, Kun-Yi; WU, Chung-Hsien; KUO, Yu-Ting; YEN, Hsiao-Hsuan; JANG, Fong-Lin et al. Data collection of elicited facial expressions and speech responses for mood disorder detection. Online. In: *2015 International Conference on Orange Technologies (ICOT)*. IEEE, 2015, s. 42-45. ISBN 978-1-4673-8237-3. Dostupné z: <https://doi.org/10.1109/ICOT.2015.7498502>. [cit. 2024-01-25].
- [40] SCHULLER, Björn; BATLINER, Anton; SEPPI, Dino; STEIDL, Stefan; VOGT, Thurid et al. The relevance of feature type for the automatic classification of emotional user states: low level descriptors and functionals. Online. In: *Interspeech 2007*. ISCA: ISCA, 2007, s. 2253-2256. Dostupné z: <https://doi.org/10.21437/Interspeech.2007-612>. [cit. 2024-01-25].
- [41] BLANTON, Smiley. The voice and the emotions. Online. *Quarterly Journal of Speech*. 1915, roč. 1, č. 2, s. 154-172. ISSN 0033-5630. Dostupné z: <https://doi.org/10.1080/00335631509360475>. [cit. 2024-01-25].
- [42] ATMAJA, Bagus Tris; SASOU, Akira a AKAGI, Masato. Survey on bimodal speech emotion recognition from acoustic and linguistic information fusion. Online. *Speech Communication*. 2022, roč. 140, s. 11-28. ISSN 01676393. Dostupné z: <https://doi.org/10.1016/j.specom.2022.03.002>. [cit. 2024-01-25].
- [43] ANAGNOSTOPOULOS, Christos-Nikolaos; ILIOU, Theodoros a GIANNOUKOS, Ioannis. Features and classifiers for emotion recognition from speech: a survey from 2000 to 2011. Online. *Artificial Intelligence Review*. 2015, roč. 43, č. 2, s. 155-177. ISSN 0269-2821. Dostupné z: <https://doi.org/10.1007/s10462-012-9368-5>. [cit. 2024-01-25].
- [44] FRICK, Robert W. Communicating emotion: The role of prosodic features. Online. *Psychological Bulletin*. 1985, roč. 97, č. 3, s. 412-429. ISSN 1939-1455. Dostupné z: <https://doi.org/10.1037/0033-2909.97.3.412>. [cit. 2024-01-25].
- [45] MURRAY, Iain R. a ARNOTT, John L. Toward the simulation of emotion in synthetic speech: A review of the literature on human vocal emotion. Online. *The Journal of the Acoustical Society of America*. 1993, roč. 93, č. 2, s. 1097-1108. ISSN 0001-4966. Dostupné z: <https://doi.org/10.1121/1.405558>. [cit. 2024-04-22].

- [46] SECHIDIS, Konstantinos; FUSAROLI, Riccardo; OROZCO-ARROYAVE, Juan Rafael; WOLF, Detlef a ZHANG, Yan-Ping. A machine learning perspective on the emotional content of Parkinsonian speech. Online. *Artificial Intelligence in Medicine*. 2021, roč. 115. ISSN 09333657. Dostupné z: <https://doi.org/10.1016/j.artmed.2021.102061>. [cit. 2024-01-25].
- [47] ILLNER, Vojtěch; KRÝŽE, Petr; ŠVIHLÍK, Jan; SOUSA, Mário; KRACK, Paul et al. Which aspects of motor speech disorder are captured by Mel Frequency Cepstral Coefficients? Evidence from the change in STN-DBS conditions in Parkinson's disease. Online. In: *INTERSPEECH 2023*. ISCA: ISCA, 2023, s. 5027-5031. Dostupné z: <https://doi.org/10.21437/Interspeech.2023-1744>. [cit. 2024-03-17].
- [48] RUSZ, Jan; NOVOTNY, Michal; HLAVNICKA, Jan; TYKALOVA, Tereza a RUZICKA, Evzen. High-Accuracy Voice-Based Classification Between Patients With Parkinson's Disease and Other Neurological Diseases May Be an Easy Task With Inappropriate Experimental Design. Online. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2017, roč. 25, č. 8, s. 1319-1321. ISSN 1534-4320. Dostupné z: <https://doi.org/10.1109/TNSRE.2016.2621885>. [cit. 2024-03-22].
- [49] METZE, Florian; POLZEHL, Tim a WAGNER, Michael. Fusion of Acoustic and Linguistic Features for Emotion Detection. Online. In: *2009 IEEE International Conference on Semantic Computing*. IEEE, 2009, s. 153-160. ISBN 978-1-4244-4962-0. Dostupné z: <https://doi.org/10.1109/ICSC.2009.32>. [cit. 2024-01-25].
- [50] ŠIMEK, Michal a RUSZ, Jan. Validation of cepstral peak prominence in assessing early voice changes of Parkinson's disease: Effect of speaking task and ambient noise. Online. *The Journal of the Acoustical Society of America*. 2021, roč. 150, č. 6, s. 4522-4533. ISSN 0001-4966. Dostupné z: <https://doi.org/10.1121/10.0009063>. [cit. 2024-03-22].
- [51] RADFORD, Alec; KIM, Jong Wook; XU, Tao; BROCKMAN, Greg; MCLEAVEY, Christine et al. Robust Speech Recognition via Large-Scale Weak Supervision. Online. In: *Proceedings of the 40th International Conference on Machine Learning*. PMLR, 2023, s. 28492-28518. Dostupné z: <https://proceedings.mlr.press/v202/radford23a.html>. [cit. 2024-03-15].
- [52] ILLNER, Vojtěch; TYKALOVÁ, Tereza; NOVOTNÝ, Michal; KLEMPÍŘ, Jiří; DUŠEK, Petr et al. Toward Automated Articulation Rate Analysis via Connected Speech in Dysarthrias. Online. *Journal of Speech, Language, and Hearing Research*. 2022, roč.

- 65, č. 4, s. 1386-1401. ISSN 1092-4388. Dostupné z: https://doi.org/10.1044/2021_JSLHR-21-00549. [cit. 2024-03-22].
- [53] CHUANG, Ze-Jing a WU, Chung-Hsien. Multi-Modal Emotion Recognition from Speech and Text. Online. *International Journal of Computational Linguistics & Chinese Language Processing*. 2004, roč. 9, č. 2, s. 45–62. Dostupné z: <https://aclanthology.org/O04-3004>. [cit. 2024-01-25].
- [54] MOHAMMAD, Saif M. a TURNEY, Peter D. CROWDSOURCING A WORD–EMOTION ASSOCIATION LEXICON. Online. *Computational Intelligence*. 2013, roč. 29, č. 3, s. 436-465. ISSN 0824-7935. Dostupné z: <https://doi.org/10.1111/j.1467-8640.2012.00460.x>. [cit. 2024-03-09].
- [55] CAMBRIA, Erik; LIU, Qian; DECHERCHI, Sergio; XING, Frank a KWOK, Kenneth. SenticNet 7: A commonsense-based neurosymbolic AI framework for explainable sentiment analysis. Online. In: *Proceedings of the Thirteenth Language Resources and Evaluation Conference*. Marseille. European Language Resources Association, 2022, s. 3829-3839. Dostupné z: <https://aclanthology.org/2022.lrec-1.408.pdf>. [cit. 2024-03-15].
- [56] *Sentic APIs*. Online. SenticNet. Dostupné z: <https://sentic.net/api/>. [cit. 2024-03-15].
- [57] DENECKE, Kerstin. Using SentiWordNet for multilingual sentiment analysis. Online. In: *2008 IEEE 24th International Conference on Data Engineering Workshop*. IEEE, 2008, s. 507-512. ISBN 978-1-4244-2161-9. Dostupné z: <https://doi.org/10.1109/ICDEW.2008.4498370>. [cit. 2024-01-25].
- [58] ŠUBERT, Martin; NOVOTNÝ, Michal; TYKALOVÁ, Tereza; SRPOVÁ, Barbora; FRIEDOVÁ, Lucie et al. Lexical and syntactic deficits analyzed via automated natural language processing: the new monitoring tool in multiple sclerosis. Online. *Therapeutic Advances in Neurological Disorders*. 2023, roč. 16. ISSN 1756-2864. Dostupné z: <https://doi.org/10.1177/17562864231180719>. [cit. 2024-03-17].
- [59] SCOTT, S; CAIRD, F I a WILLIAMS, B O. Evidence for an apparent sensory speech disorder in Parkinson's disease. Online. *Journal of Neurology, Neurosurgery & Psychiatry*. 1984, roč. 47, č. 8, s. 840-843. ISSN 0022-3050. Dostupné z: <https://doi.org/10.1136/jnnp.47.8.840>. [cit. 2024-01-25].
- [60] BLONDER, Lee Xenakis; GUR, Raquel E. a GUR, Ruben C. The effects of right and left hemiparkinsonism on prosody. Online. *Brain and Language*. 1989, roč. 36, č. 2, s.

- 193-207. ISSN 0093934X. Dostupné z: [https://doi.org/10.1016/0093-934X\(89\)90061-8](https://doi.org/10.1016/0093-934X(89)90061-8). [cit. 2024-01-25].
- [61] CAEKEBEKE, J F; JENNEKENS-SCHINKEL, A; VAN DER LINDEN, M E; BURUMA, O J a ROOS, R A. The interpretation of dysprosody in patients with Parkinson's disease. Online. *Journal of Neurology, Neurosurgery & Psychiatry*. 1991, roč. 54, č. 2, s. 145-148. ISSN 0022-3050. Dostupné z: <https://doi.org/10.1136/jnnp.54.2.145>. [cit. 2024-01-25].
- [62] BENKE, Th.; BÖSCH, S. a ANDREE, B. A Study of Emotional Processing in Parkinson's Disease. Online. *Brain and Cognition*. 1998, roč. 38, č. 1, s. 36-52. ISSN 02782626. Dostupné z: <https://doi.org/10.1006/brcg.1998.1013>. [cit. 2024-01-25].
- [63] PELL, M; CHEANG, H a LEONARD, C. The impact of Parkinson's disease on vocal-prosodic communication from the perspective of listeners. Online. *Brain and Language*. 2006, roč. 97, č. 2, s. 123-134. ISSN 0093934X. Dostupné z: <https://doi.org/10.1016/j.bandl.2005.08.010>. [cit. 2024-01-25].
- [64] CHEANG, Henry S. a PELL, Marc D. An acoustic investigation of Parkinsonian speech in linguistic and emotional contexts. Online. *Journal of Neurolinguistics*. 2007, roč. 20, č. 3, s. 221-241. ISSN 09116044. Dostupné z: <https://doi.org/10.1016/j.jneuroling.2006.07.001>. [cit. 2024-01-25].
- [65] ZHAO, Shunan; RUDZICZ, Frank; CARVALHO, Leonardo G.; MARQUEZ-CHIN, Cesar a LIVINGSTONE, Steven. Automatic detection of expressed emotion in Parkinson's Disease. Online. In: *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2014, s. 4813-4817. ISBN 978-1-4799-2893-4. Dostupné z: <https://doi.org/10.1109/ICASSP.2014.6854516>. [cit. 2024-01-25].
- [66] JAYWANT, ABHISHEK a PELL, MARC D. Listener impressions of speakers with Parkinson's disease. Online. *Journal of the International Neuropsychological Society*. 2010, roč. 16, č. 1, s. 49-57. ISSN 1355-6177. Dostupné z: <https://doi.org/10.1017/S1355617709990919>. [cit. 2024-01-25].
- [67] PÉREZ-TORO, P. A.; VASQUEZ-CORREA, J. C.; ARIAS-VERGARA, T.; KLUMPP, P.; SCHUSTER, M. et al. Emotional State Modeling for the Assessment of Depression in Parkinson's Disease. Online. In: EKŠTEIN, Kamil; PÁRTL, František a KONOPÍK, Miloslav (ed.). *Text, Speech, and Dialogue. Lecture Notes in Computer Science*. Cham:

- Springer International Publishing, 2021, s. 457-468. ISBN 978-3-030-83526-2. Dostupné z: https://doi.org/10.1007/978-3-030-83527-9_39. [cit. 2024-01-25].
- [68] KHAN, Habib; ULLAH, Mohib; AL-MACHOT, Fadi; ALAYA CHEIKH, Faouzi a SAJJAD, Muhammad. Deep learning based speech emotion recognition for Parkinson patient. Online. *Electronic Imaging*. 2023, roč. 35, č. 9, s. 298--1-298-6. ISSN 2470-1173. Dostupné z: <https://doi.org/10.2352/EI.2023.35.9.IPAS-298>. [cit. 2024-01-25].
- [69] TYKALOVA, Tereza; RUSZ, Jan; CMEJLA, Roman; RUZICKOVA, Hana a RUZICKA, Evzen. Acoustic Investigation of Stress Patterns in Parkinson's Disease. Online. *Journal of Voice*. 2014, roč. 28, č. 1, s. 129.e1-129.e8. ISSN 08921997. Dostupné z: <https://doi.org/10.1016/j.jvoice.2013.07.001>. [cit. 2024-01-25].
- [70] GOETZ, Christopher G.; TILLEY, Barbara C.; SHAFTMAN, Stephanie R.; STEBBINS, Glenn T.; FAHN, Stanley et al. Movement Disorder Society-sponsored revision of the Unified Parkinson's Disease Rating Scale (MDS-UPDRS): Scale presentation and clinimetric testing results. Online. *Movement Disorders*. 2008, roč. 23, č. 15, s. 2129-2170. ISSN 0885-3185. Dostupné z: <https://doi.org/10.1002/mds.22340>. [cit. 2024-04-13].
- [71] NASREDDINE, Ziad S.; PHILLIPS, Natalie A.; BÉDIRIAN, Valérie; CHARBONNEAU, Simon; WHITEHEAD, Victor et al. The Montreal Cognitive Assessment, MoCA: A Brief Screening Tool For Mild Cognitive Impairment. Online. *Journal of the American Geriatrics Society*. 2005, roč. 53, č. 4, s. 695-699. ISSN 0002-8614. Dostupné z: <https://doi.org/10.1111/j.1532-5415.2005.53221.x>. [cit. 2024-04-13].
- [72] CIHAROVA, Marketa; CÍGLER, Hynek; DOSTÁLOVÁ, Veronika; ŠIVICOVÁ, Gabriela a BEZDICEK, Ondrej. Beck depression inventory, second edition, Czech version: demographic correlates, factor structure and comparison with foreign data. Online. *International Journal of Psychiatry in Clinical Practice*. 2020, roč. 24, č. 4, s. 371-379. ISSN 1365-1501. Dostupné z: <https://doi.org/10.1080/13651501.2020.1775854>. [cit. 2024-04-13].
- [73] JONGSEO SOHN; NAM SOO KIM a WONYONG SUNG. A statistical model-based voice activity detection. Online. *IEEE Signal Processing Letters*. 1999, roč. 6, č. 1, s. 1-3. ISSN 1070-9908. Dostupné z: <https://doi.org/10.1109/97.736233>. [cit. 2024-03-23].
- [74] CAMACHO, Arturo a HARRIS, John G. A sawtooth waveform inspired pitch estimator for speech and music. Online. *The Journal of the Acoustical Society of America*. 2008,

roč. 124, č. 3, s. 1638-1652. ISSN 0001-4966. Dostupné z: <https://doi.org/10.1121/1.2951592>. [cit. 2024-03-09].

- [75] ILLNER, Vojtech; SOVKA, Pavel a RUSZ, Jan. Validation of freely-available pitch detection algorithms across various noise levels in assessing speech captured by smartphone in Parkinson's disease. Online. *Biomedical Signal Processing and Control*. 2020, roč. 58. ISSN 17468094. Dostupné z: <https://doi.org/10.1016/j.bspc.2019.101831>. [cit. 2024-03-23].
- [76] SIMPSON, Adrian P. Phonetic differences between male and female speech. Online. *Language and Linguistics Compass*. 2009, roč. 3, č. 2, s. 621-640. ISSN 1749-818X. Dostupné z: <https://doi.org/10.1111/j.1749-818X.2009.00125.x>. [cit. 2024-03-23].
- [77] HLAVNÍČKA, Jan; ČMEJLA, Roman; TYKALOVÁ, Tereza; ŠONKA, Karel; RŮŽIČKA, Evžen et al. Automated analysis of connected speech reveals early biomarkers of Parkinson's disease in patients with rapid eye movement sleep behaviour disorder. Online. *Scientific Reports*. 2017, roč. 7, č. 1. ISSN 2045-2322. Dostupné z: <https://doi.org/10.1038/s41598-017-00047-5>. [cit. 2024-03-23].
- [78] STRAKA, Milan a STRAKOVÁ, Jana. *MorphoDiTa: Morphological Dictionary and Tagger*. Online. LINDAT/CLARIAH-CZ digital library at the Institute of Formal and Applied Linguistics (ÚFAL), Faculty of Mathematics and Physics, Charles University, 2014. Dostupné z: <http://hdl.handle.net/11858/00-097C-0000-0023-43CD-0>. [cit. 2024-03-15].
- [79] STRAKA, Milan a STRAKOVÁ, Jana. *Czech Models (MorFlex CZ 2.0 + PDT-C 1.0) for MorphoDiTa 220710*. Online. LINDAT/CLARIAH-CZ digital library at the Institute of Formal and Applied Linguistics (ÚFAL), Faculty of Mathematics and Physics, Charles University, 2014. Dostupné z: <http://hdl.handle.net/11234/1-4794>. [cit. 2024-03-15].
- [80] BENDOVIÁ, Karolína. *Analýza promluv pacientů se schizofrenií*. Online, Diplomová práce, vedoucí prof. Ing. Roman Čmejla, CSc., Mgr. Bc. Juraj Jonáš. Praha: České vysoké učení technické v Praze, Fakulta elektrotechnická, Katedra teorie obvodů, 2024. Dostupné z: <https://dspace.cvut.cz/handle/10467/113305>. [cit. 2024-05-13].
- [81] BELTRAMI, Daniela; GAGLIARDI, Gloria; ROSSINI FAVRETTI, Rema; GHIDONI, Enrico; TAMBURINI, Fabio et al. Speech Analysis by Natural Language Processing Techniques: A Possible Tool for Very Early Detection of Cognitive Decline? Online.

- Frontiers in Aging Neuroscience*. 2018, roč. 10. ISSN 1663-4365. Dostupné z: <https://doi.org/10.3389/fnagi.2018.00369>. [cit. 2024-03-17].
- [82] *Mauchly's Test of Sphericity*. Online. MathWorks. Dostupné z: <https://www.mathworks.com/help/stats/mauchlys-test-of-sphericity.html>. [cit. 2024-03-20].
- [83] BLANCA, María J.; ARNAU, Jaume; GARCÍA-CASTRO, F. Javier; ALARCÓN, Rafael a BONO, Roser. Non-normal Data in Repeated Measures ANOVA: Impact on Type I Error and Power. Online. *Psicothema*. 2023, roč. 35, č. 1, s. 21-29. Dostupné z: <https://doi.org/10.7334/psicothema2022.292>. [cit. 2024-03-20].
- [84] JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor; TIBSHIRANI, Robert; JAMES, Gareth et al. Support Vector Machines. Online. In: *An Introduction to Statistical Learning. Springer Texts in Statistics*. New York, NY: Springer US, 2021, s. 367-402. ISBN 978-1-0716-1417-4. Dostupné z: https://doi.org/10.1007/978-1-0716-1418-1_9. [cit. 2024-03-25].
- [85] ALLWEIN, Erin L.; SCHAPIRE, Robert E. a SINGER, Yoram. Reducing multiclass to binary: a unifying approach for margin classifiers. Online. *Journal of Machine Learning Research*. 2000, roč. 1, s. 113-141. Dostupné z: <https://www.jmlr.org/papers/volume1/allwein00a/allwein00a.pdf>. [cit. 2024-03-25].
- [86] RUSSELL, James A a MEHRABIAN, Albert. Evidence for a three-factor theory of emotions. Online. *Journal of Research in Personality*. 1977, roč. 11, č. 3, s. 273-294. ISSN 00926566. Dostupné z: [https://doi.org/10.1016/0092-6566\(77\)90037-X](https://doi.org/10.1016/0092-6566(77)90037-X). [cit. 2024-04-14].
- [87] LALITHA, S.; TRIPATHI, Shikha a GUPTA, Deepa. Enhanced speech emotion detection using deep neural networks. Online. *International Journal of Speech Technology*. 2019, roč. 22, č. 3, s. 497-510. ISSN 1381-2416. Dostupné z: <https://doi.org/10.1007/s10772-018-09572-8>. [cit. 2024-05-13].

Príloha A: Podklady k rečovým úlohám

* Stručne **popište** nasledujúci obrázky. Co majú **obrázky spoločného** a jak si myslíte, že se **lidé na nich cítí**?



Obrázok 11: Inštrukcie a obrázky k rečovej úlohe *happy*, zameranej na vyvolanie pozitívnych emócií.

* Stručne **popište** nasledujúci obrázky. Co majú **obrázky spoločného** a jak si myslíte, že se **lidé na nich cítí**?



Obrázok 12: Inštrukcie a obrázky k emočne neutrálnej rečovej úlohe *neutral*.

* Stručně popište následující obrázky. Co mají obrázky společného a jak si myslíte, že se lidé na nich cítí?



Obrázok 13: Inštrukcie a obrázky k rečovej úlohe *sad*, zameranej na vyvolanie negatívnych emócií.

Príloha B: Výsledky vypočítaných parametrov

Tabuľka 8: Mediány a štandardné odchýlky (SD) vypočítaných spojitých parametrov vzhľadom k rečovým úlohám u pacientov s Parkinsonovou chorobou.

Parameter	Typ úlohy						
	happy		neutral		sad		
	Medián	SD	Medián	SD	Medián	SD	
Akustické parametre	Medián dĺžky páuz [ms]	165,00	56,62	172,50	69,72	145,00	61,65
	SD F0 [semitóny]	2,673	0,789	2,462	1,140	2,568	0,945
	Medián intenzity signálu [dB]	-41,510	4,755	-41,809	4,869	-42,008	4,988
	SD intenzity signálu [dB]	5,358	1,281	5,242	1,179	4,716	1,006
	Globálny parameter z MFCC [-]	0,564	0,031	0,548	0,035	0,550	0,033
SenticNet	Intenzita emócií [-]	72,000	14,449	61,500	13,231	65,000	10,364
	Miera záujmu [-]	50,000	51,476	33,000	42,766	-50,000	57,981
	Miera spokojnosti	33,000	31,396	33,000	48,447	-67,000	59,940
Analýza slovných druhov	Hustota myšlienok [-]	0,450	0,050	0,480	0,089	0,471	0,066
	MATTR [-]	0,698	0,090	0,705	0,103	0,647	0,077
	Syntaktická zložitosť [-]	0,488	0,079	0,527	0,069	0,498	0,078
	Funkčné slová [-]	0,347	0,077	0,345	0,063	0,348	0,051
Valence	Priemer valence [-]	0,713	0,040	0,625	0,039	0,577	0,050
Arousal	Priemer arousal [-]	0,443	0,052	0,369	0,038	0,437	0,055
Dominance	Priemer dominance [-]	0,552	0,043	0,517	0,022	0,484	0,027

Tabuľka 9: Mediány a štandardné odchýlky (SD) vypočítaných spojitých parametrov vzhľadom k rečovým úlohám u zdravých ľudí.

Parameter	Typ úlohy						
	happy		neutral		sad		
	Medián	SD	Medián	SD	Medián	SD	
Akustické parametre	Medián dĺžky páuz [ms]	145,000	56,699	160,000	54,690	130,000	100,615
	SD F0 [semitóny]	3,178	0,839	2,993	0,667	2,984	0,755
	Medián intenzity signálu [dB]	-37,461	4,154	-39,140	3,956	-39,662	4,129
	SD intenzity signálu [dB]	6,150	1,195	5,882	1,071	5,941	1,129
	Globálny parameter z MFCC [-]	0,569	0,037	0,562	0,039	0,560	0,038
SenticNet	Intenzita emócií [-]	68,500	8,769	65,000	10,432	61,500	15,916
	Miera záujmu [-]	41,500	33,421	41,500	43,107	-84,000	61,665
	Miera spokojnosti	33,000	30,756	50,000	33,870	-84,000	67,875
Analýza slovných druhov	Hustota myšlienok [-]	0,441	0,083	0,459	0,103	0,475	0,114
	MATTR [-]	0,690	0,078	0,680	0,103	0,685	0,107
	Syntaktická zložitosť [-]	0,578	0,052	0,562	0,062	0,530	0,077
	Funkčné slová [-]	0,349	0,070	0,370	0,059	0,375	0,061
Valence Arousal Dominance	Priemer valence [-]	0,719	0,045	0,635	0,045	0,579	0,046
	Priemer arousal [-]	0,465	0,069	0,375	0,046	0,455	0,062
	Priemer dominance [-]	0,552	0,040	0,514	0,021	0,497	0,027