

České vysoké učení technické v Praze

Fakulta elektrotechnická

Katedra teorie obvodů



Bakalářská práce

Detekce vrásek pro popis hypomimie u Parkinsonovy nemoci

Detection of facial wrinkles for the description of hypomimia
in Parkinson's disease

Autor: Jan Vaník

Vedoucí práce: Ing. Michal Novotný, Ph. D.

Studijní program: Lékařská elektronika a bioinformatika

Praha 2022

Oficiální zadání práce



ZADÁNÍ BAKALÁŘSKÉ PRÁCE

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Vaník** Jméno: **Jan** Osobní číslo: **491878**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra teorie obvodů**
Studijní program: **Lékařská elektronika a bioinformatika**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Detekce vrásek pro popis hypomimie u Parkinsonovy nemoci

Název bakalářské práce anglicky:

Detection of facial wrinkles for the description of hypomimia in Parkinson's disease

Pokyny pro vypracování:

- 1) Seznamte se s problematikou hypomimie u Parkinsonovi nemoci a metodami automatické analýzy obličejové mimiky.
- 2) Na základě dostupné literatury nastavte vhodné metody pro parametrizaci hypomimie pomocí obličejových vrásek u pacientů trpících Parkinsonovou nemocí.
- 3) Porovnejte dostupné automatického hodnocení obličejových vrásek z videozáznamů monologů na volné téma
- 4) S pomocí navržených metod proveďte vhodné statistické analýzy a vyhodnoťte nevhodnější parametry pro popis hypomimie způsobené parkinsonovou nemocí.

Seznam doporučené literatury:

- [1] JANKOVIC, Joseph. Parkinson's disease: clinical features and diagnosis. Journal of neurology, neurosurgery & psychiatry, 2008, 79.4: 368-376.
- [2] GONZALEZ, Rafael C.; WOODS, Richard E.; MASTERS, Barry R. Digital image processing. 2009.
- [3] BOLOGNA, Matteo, et al. Facial bradykinesia. Journal of Neurology, Neurosurgery & Psychiatry, 2013, 84.6: 681-685.
- [4] MAWALE, Ashwini; CHAUGULE, Archana. Facial wrinkles detection techniques and its application. International Journal of Computer Applications, 2016, 134.7: 5-8.

Jméno a pracoviště vedoucí(ho) bakalářské práce:

Ing. Michal Novotný, Ph.D. katedra teorie obvodů FEL

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

Datum zadání bakalářské práce: **02.02.2022** Termín odevzdání bakalářské práce: **20.05.2022**

Platnost zadání bakalářské práce: **30.09.2023**

Ing. Michal Novotný, Ph.D.
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

Student bere na vědomí, že je povinen vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

Datum převzetí zadání

Podpis studenta

Prohlášení

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

V Praze dne

.....

Podpis autora práce

Poděkování

Děkuji v první řadě panu Ing. Michalovi Novotnému, Ph.D. za trpělivost a ochotu při vedení mé bakalářské práce, jeho připomínky a rady, které mi byly velmi nápomocné, a také za korekturu a bezchybnou komunikaci.

Dále také ze srdce děkuji své rodině za materiální a morální podporu při studiu. Při poděkování nemohu zapomenout také na své kamarády ze školních lavic, kteří mé studium obohatili o příjemné zážitky, na které budu i po letech rád vzpomínat.

Abstrakt

Parkinsonova nemoc je druhé nejčastější neurodegenerativní onemocnění. Aktuálně pro něj není dostupná kauzální léčba. K jejímu vyvinutí by mohlo pomoci dřívější diagnóze nemocných jedinců. Ukazuje se, že jedním z ukazatelů je hypomimie – snížení mimiky v obličeji nemocného. Možným hodnotícím prvkem hypomimie je zřejmě i tvorba vrásek, která ale zatím nebyla využita. Z dostupných algoritmů funguje pro detekci vrásek nejvhodněji Frangiho filtr. Hypomimii mohu zkoumat díky nahraným videím, percepčním hodnocením a klinickým datům od zdravých kontrol a de-novo diagnostikovaných pacientů.

Vrásky jsem detekoval ze tří oblastí tváře segmentované pomocí tzv. „významných bodů“ tváře. Oblasti jsou čelo, oblast mezi obočím a v okolí nosu. Pro každou tuto oblast jsem extrahoval tři významné parametry. Ukazuje se, že poměry těchto parametrů se statisticky významně liší pro zdravé kontroly a pacienty. Díky tomu jsem mohl rozlišovat mezi zdravými a nemocnými logistickou regresí, jejíž přesnost byla 0,77. Mezi parametry a klinickými daty souvislost nalezena nebyla, na rozdíl od korelace s percepčním hodnocením, která byla statisticky významná.

Ukazuje se, že je možné automaticky detekované vrásky použít pro detekování hypomimie a mohou poukázat na nemoc i u de-novo pacientů. Největší postupu limitací je nedokonalá segmentace a falešná detekce vrásek.

Klíčová slova: Parkinsonova nemoc, hypomimie, detekce vrásek

Abstract

Parkinson's disease is the second most common neurodegenerative disease. There is no curative treatment. However, it is suggested earlier diagnosis of patients could help with development. One of early signs of Parkinson's disease is hypomimia – lowered movement in the face of affected person. It could be diagnosed by facial wrinkles evaluation, but no research has focused on this phenomenon, yet. Out of available algorithms for wrinkles detection Frangi's filter shows the best performance. I can measure hypomimia thanks to perceptual evaluation, clinical data and recorded videos of de-novo diagnosed patients as well as healthy controls.

I detected wrinkles from three facial segments obtained via "facial landmarks". The areas are forehead, area between eyebrows and nasal area. From each region I extracted three significant parameters. It was shown that ratios of these parameters are significantly different for patients and healthy controls. It leads to possibility of classification between healthy and ill people by logistic regression with accuracy of 0,77. There was no significant correlation between clinical data and extracted parameters. However, there was significant correlation between perceptual evaluation and the parameters.

In conclusion, it is possible to use detected wrinkles to classify between healthy person and even de-novo diagnosed patient. The greatest limitations are imperfect segmentation and false wrinkles detection.

Keywords: Parkinson's disease, hypomimia, wrinkles detection

Seznam použitých zkratek

SNe	substantia nigra pars compacta
GABA	kyselina aminomáselná
NS	nucleus subthalamicus
GPI	globus pallidus internus
SNr	substantia nigra pars reticulata
GPe	globus pallidus externus
PET	pozitronová emisní tomografie
AADC	Dehydroaromatická aminokarboxyláza L-aromatických aminokyselin
COMT	Katechol-O-metyltransferáza
MAOB	Monoaminoxidáza typu B
DBS	Hluboká mozková stimulace
HHF	Hybrid Hessian Filter
HLT	Hessian line tracking
HD	High-definition
MoCA	Montrealský kognitivní test
MDS-UPDRS-III	Movement Disorder Society-Unified Parkinson's Disease Rating Scale, Part III
SSD	Součet druhých mocnin rozdílů
ROC	Receiver Operating Characteristic
AUC	Plocha pod křivkou ROC (Area Under Curve)
ACC	přesnost
SENZ	senzitivita
SPEC	specifita

Obsah

1.	Úvod.....	11
1.1.	Parkinsonova nemoc	11
1.1.1.	Patomechanismus onemocnění	11
1.1.2.	Motorické nervové cesty a dopamin	11
1.1.3.	Ovládání svalů a vliv dopaminu.....	13
1.1.4.	Symptomy	14
1.1.5.	Diagnóza	15
1.1.6.	Léčba.....	16
1.1.7.	Obličejová bradykineze – hypomimie	17
1.2.	Vrásky a jejich detekce	18
1.2.1.	Lokalizace vrásek.....	18
1.2.2.	Detekce vrásek	18
1.2.2.1.	Jednoduché diferenční filtry.....	19
1.2.2.2.	Gaborův filtr.....	20
1.2.2.3.	Marrův-Hilderthův filtr	21
1.2.2.4.	Cannyho filtr	22
1.2.2.5.	Houghova transformace	23
1.2.2.6.	Marked point process	24
1.2.2.7.	Frangiho filtr (Hybrid Hessian filtr).....	24
1.2.2.8.	Hessian line tracking.....	26
1.2.3.	Srovnání algoritmů.....	27
2.	Metodologie	28
2.1.	Dataset.....	28
2.2.	Videa	29
2.3.	Klinická data a percepční analýza.....	29
2.4.	Detekce vrásek a výběr jejich parametrů	29
2.4.1.	Výběr vrásek	29
2.4.2.	Předzpracování.....	29

2.4.3.	Segmentace.....	30
2.4.4.	Ekvalizace histogramu.....	31
2.4.5.	Výběr algoritmu.....	31
2.4.6.	Vstupní argumenty Frangiho filtru	32
2.4.7.	Odstranění falešně detekovaných vrásek.....	32
2.4.8.	Výběr parametrů.....	33
2.5.	Statistická analýza	33
2.6.	Klasifikační experiment.....	33
3.	Výsledky.....	34
3.1.	Detekce vrásek.....	34
3.2.	Analýza parametrů.....	35
3.2.1.	Závislost parametrů	35
3.2.2.	Test normality dat.....	37
3.2.3.	Test odlišnosti skupin	37
3.2.4.	Korelace parametrů s percepčním hodnocením a klinickými daty	39
3.2.5.	Klasifikace zdravých kontrol a pacientů.....	39
4.	Diskuse	41
4.1.	Předzpracování	41
4.2.	Segmentace.....	41
4.3.	Výběr filtru a pofiltrační úpravy.....	41
4.4.	Výběr parametrů.....	41
4.5.	Výsledky analýzy parametrů	42
4.6.	Limitace a další kroky	42
5.	Splnění zadaných cílů.....	43
6.	Závěr.....	44
7.	Zdroje	45

1. Úvod

1.1. Parkinsonova nemoc


Parkinsonova nemoc je progresivní neurodegenerativní onemocnění způsobené úbytkem dopaminergních neuronů v části středního mozku substantia nigra – pars compacta (SNc). Ačkoli doposud nejsou známy příčiny onemocnění, věk se ukazuje jako jeden z rizikových faktorů. Parkinsonova nemoc postihuje zejména lidi starší 50 let, výskyty u mladších ročníků jsou spíše výjimečné. V populaci převládá incidence 0,3 %, která je ale desetkrát vyšší mezi lidmi věku vyššího než 80 let. U lidí nad 65 let se vyskytuje v 2-3 % populace a celkově jde o druhé nejrozšířenější neurodegenerativní onemocnění po Alzheimerově nemoci [1].

1.1.1. Patomechanismus onemocnění

Pro onemocnění je typické ukládání toxické formy proteinu α -synukleinu v dopaminergních neuronech v SNc způsobující jejich odumírání, a následném nedostatku neurotransmiteru dopaminu v oblasti basálních ganglií. Hromaděním α -synukleinu se uvnitř některých buněk mohou vytvářet tzv. Lewyho tělíska. Příčina těchto změn není úplně objasněna a jeví se jako multifaktoriální. Za hlavní faktory se považují převážně: (i) chybná proteosyntéza α -synukleinu, (ii) genetická predispozice, (iii) oxidativní stres, (iv) zánět nervových buněk, (v) špatná funkce mitochondrií a (vi) nerovnováha vápníku uvnitř nervových buněk. Zdá se, že jednotlivé faktory spolu úzce souvisí a navzájem se podporují v rozvoji. Podle nové hypotézy se navíc špatně syntetizovaný a neodbouraný α -synuklein může šířit do mezibuněčného prostoru pomocí axonů, odkud ho přijmou dosud nenakažené nervové buňky [1]. Na Obr. 1 jsou znázorněny faktory ovlivňující chybnou proteosyntézu α -synukleinu, stejně tak jako změny procesů, které slouží k jeho odbourání, a také šíření α -synukleinu do dalších neuronů. Funkce α -synukleinu není zatím zcela jasná [2].

1.1.2. Motorické nervové cesty a dopamin

K přenosu nervového vzruchu dochází v chemických synapsích díky neurotransmiterům s inhibiční či excitační funkcí. Příkladem inhibičního neuronu je kyselina aminomáselná (GABA) a příkladem excitačního neurotransmiteru je acetylcholin. Dopamin může působit jak excitačně, tak inhibičně v závislosti na receptoru neuronu, který na něj reaguje. Excitovaný, resp. inhibovaný neuron produkuje více, resp. méně svého neurotransmiteru k dalším neuronům čímž se v mozku šíří signál [3].



Obr. 1: Tvorb a ukládání špatně syntetizovaného α -synukleinu do Lewyho tělísek, vliv vnějších i vnitřních faktorů a šíření α -synukleinu mezi neurony. Převzato z [1].

Svaly jsou vůlí aktivovány z neuronů v motorické části mozkové kůry, tyto neurony jsou excitovány z thalamu. Původní impulz k vykonání pohybu pochází z (jiného) aktivačního neuronu taktéž v motorické části a do thalamu se dostává třemi cestami [1].

Hyperpřímá cesta

Hyperpřímá cesta (dráha) slouží hlavně k rychlému zastavení pohybu; aktivační neuron excituje neuron v nucleu subthalamicu (STN), který následně excituje neuron v globu pallidu internu (GPi) nebo substantia nigra – pars reticulata (SNr). Tento neuron je inhibiční, tedy díky excitaci vylučuje více GABA, která inhibuje patřičný neuron v thalamu. Rychlost této dráhy spočívá v tom, že axony prvních dvou neuronů jsou myelinizované, což urychluje přenos vzruchu [1, 4].

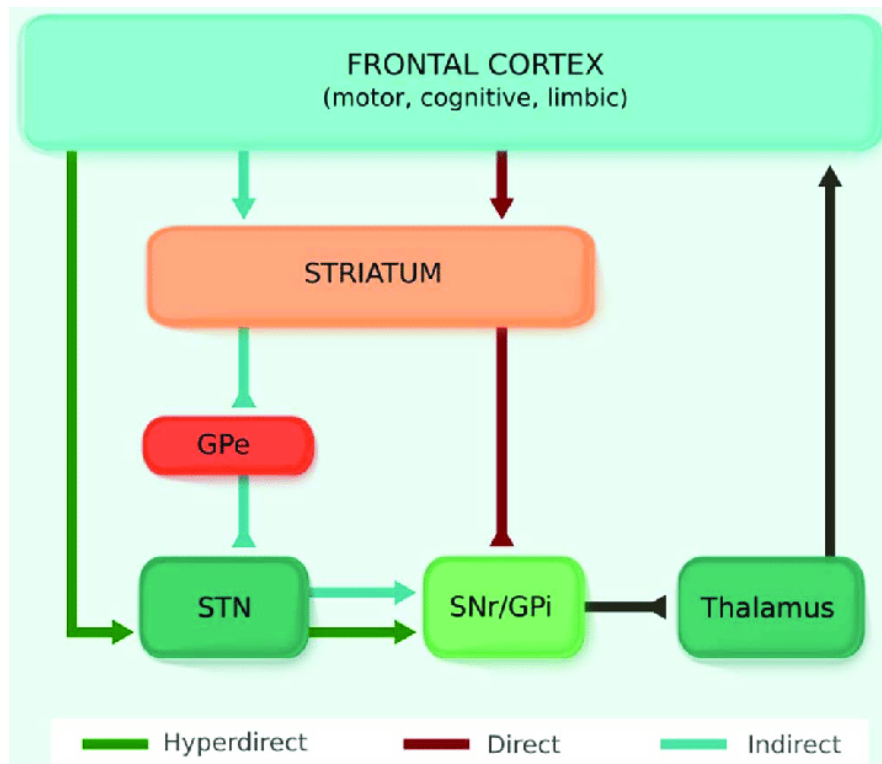
Přímá cesta

Přímá cesta (dráha) odpovídá za iniciaci pohybu a stáhnutí patřičných svalů. Vede přes excitační neuron do striata, odtud inhibičním do GPi nebo SNr a následně inhibičním neuronem do thalamu. Touto dvojnou inhibicí se příslušný neuron v thalamu dostane z obklopení GABA a pohyb se může vykonat [1, 4].

Nepřímá cesta

Funkce nepřímé cesty (dráhy) je uvolňování svalů. Začíná stejně jako přímá dráha, tedy excitačním neuronem do striata, odtud však signál míří přes dva inhibiční neurony skrz globum pallidum externum (GPe) do nucleu subthalamicu. Odtud již signál pokračuje stejně jako v případě hyperpřímé dráhy a ve výsledku tedy inhibuje příslušný neuron v thalamu [1, 4].

Schéma všech tří cest je znázorněno na Obr. 2.



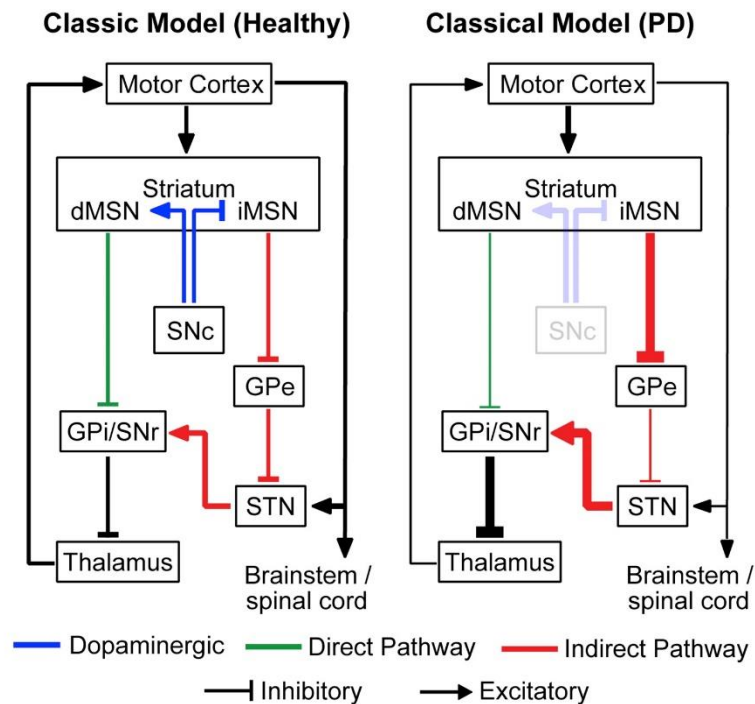
Obr. 2: Inervace motorických nervových drah. Linky zakončené šipkou značí excitační neurony, linky zakončené patkou značí inhibiční neurony. Zelená barva linky značí hyperpřímou cestu, azurová nepřímou a červená přímou. Převzato z [5].

1.1.3. Ovládání svalů a vliv dopaminu

Ohledně volního pohybu nepadá úplná shoda na tom, jak přesně se vzruchy šíří až do svalu. Zjednodušující pohled říká, že sval je inervován jak z přímé, tak nepřímé cesty a to, zda se stáhne nebo uvolní, závisí pouze na tom, která z cest převládne [4].

Dopamin je neurotransmitter, který silně moduluje přímou i nepřímou cestu, dopaminergní neurony v SNc ho vypouštějí do striata. Pokud aktivuje D1 receptor, ty jsou převážně lokalizovány na neuronech přímé cesty, ještě více posílí impuls šířící se přímou cestou, což má za následek prudší stáhnutí svalstva. Naopak D2 receptory, nacházející se z větší míry na neuronech nepřímé cesty, reagují na přítomnost dopaminu inhibicí daného neuronu. Dopamin zde ve výsledku působí proti vzruchům z motorické části mozkové kůry a relaxace svalů pak není tak velká [1, 4].

Je vidět, co udělá nedostatek dopaminu vlivem smrti dopaminergních neuronů. Ve striatu se sníží impulzy pro stah svalstva, které potřebujeme stáhnout, a naopak se zvyšuje jejich relaxace, což v prvotních fázích choroby může vést k problémům s koordinací pohybů a v pozdějších má pacient problém jakýmkoliv pohyb započít [1, 6, 7]. Vliv nedostatku dopaminu na přímou a nepřímou dráhu je ilustrován na Obr. 3. Dopamin produkovaný v SNc žádné jiné nervové dráhy neovlivňuje, například funkce reflexního oblouku vedoucího pouze přes míchu není Parkinsonovou nemocí afektována stejně tak jako hyperpřímá dráha.



Obr. 3: Schéma inervace přímé a nepřímé dráhy. Na levém obrázku správně fungující basální ganglia, na pravém člověk postižený Parkinsonovou nemocí. Je vidět zesílená inhibice neuronu v thalamu. Převzato a upraveno z [8].

1.1.4. Symptomy

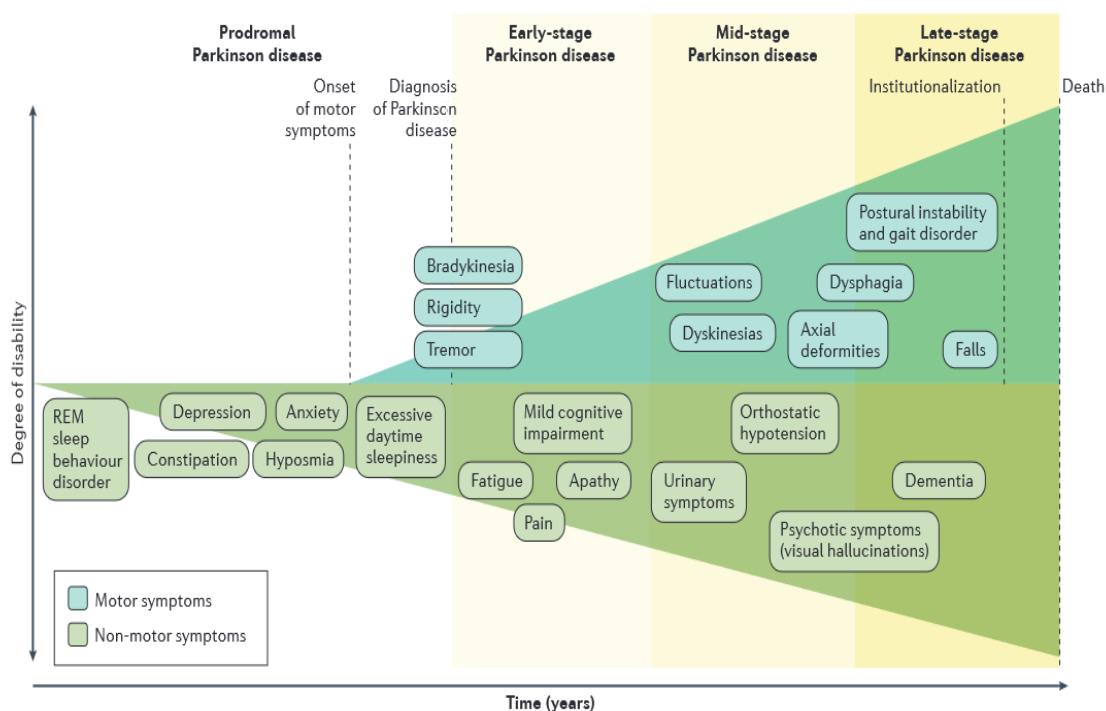
Jako hlavní symptomy Parkinsonovy nemoci se uvádějí čtyři, které shrnuje anglická zkratka TRAP. Patří mezi ně klidový tremor (tremor at rest), ztuhlost (rigidity), akineze (akinesia), někdy taky označována jako bradykineze, a posturální nestabilita (postural instability). Všechny tyto symptomy se nemusí u každého parkinsonika objevit a většina z nich začíná postupnou progresí nemoci. Ukazuje se, že drobná forma některých motorických symptomů může být přítomna mnohem dříve než před samotnou diagnózou [1, 6].

Klidový tremor je charakteristický frekvencí okolo 5 Hz a dominuje na jedné straně těla. Zřejmě se nemusí objevit asi u 11 % postižených, přičemž ti, kteří ho mají, nezažívají takové problémy s posturální nestabilitou a zamrznutím (úplné neschopnosti pohybu) [1, 6].

Symptomy rigidita a akineze se vyskytují nejčastěji spolu a souvisí s nedostatkem dopaminu v přímé a nepřímé motorické dráze [1, 6]. Bradykinezi a rigiditě zejména v obličejové části se budeme věnovat více později.

Posturální nestabilitou trpí pacienti nejčastěji až v závěrečných fázích nemoci a je způsobena nepřirozeným postavením páteře a končetin. V kombinaci s ostatními faktory může vést tento problém k pádům a zlomeninám, které ještě více zasáhnou pacientův zdravotní stav [1, 6].

Mimo komplikace s pohybem přibývají pacientům i potíže navenek nepozorovatelného rázu, které vyvstávají dříve než problémy motorické. První je porucha REM fáze spánku. Není jisté, zda Parkinsonova nemoc je způsobena právě poruchou spánku, či porucha spánku je jedním ze symptomů, který choroba vyvolá. V raných stádiích jsou časté také deprese, pocity úzkosti či zvýšená potřeba spánku během dne. Jak nemoc postupuje přidávají se kognitivní postižení, které vyúsťují až v demenci. Velmi častá je i porucha čichového ústrojí [1, 6]. Progresi nemoci s věkem znázorňuje Obr. 4.

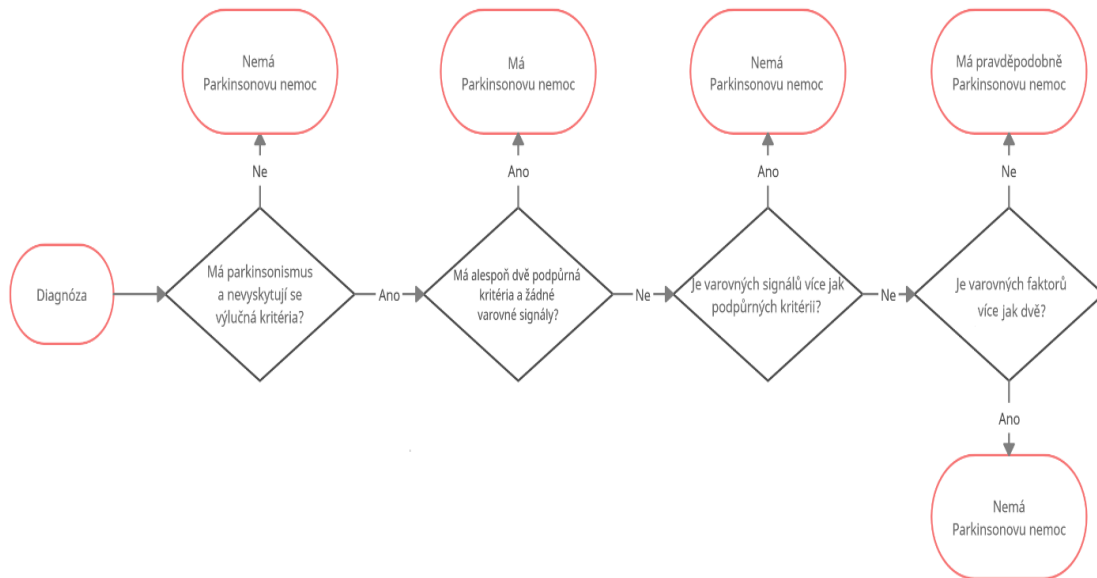


Obr. 4: Přibývající symptomy Parkinsonovy nemoci v průběhu času. Na spodní straně osy symptomy motorické, na horní motorické. Převzato ze zdroje [1].

1.1.5. Diagnóza

Při diagnóze Parkinsonovy nemoci Movement Disorder Society postupuje podle schématu na Obr. 5. Parkinsonismus se definuje jako výskyt bradykineze a alespoň jednoho z dvojice tremor, ztuhlost. Z podpůrných kritérií lze jmenovat výraznou pozitivní reakci na farmakologickou léčbu pomocí léku levodopa, případně poruchu čichového ústrojí. Pokud se objeví jakékoliv výlučné

kritérium, není pacientovi nemoc diagnostikována. Příklady výlučných kritérií jsou: dokumentace jiné choroby, která může parkinsonismus způsobovat, či snímek, který odhaluje, že nedochází k odumírání buněk v SNC. Definují se varovné signály (faktory), které diagnózu Parkinsonovy nemoci samy o sobě nevylučují, ale při jejich větším souběhu už diagnóza vyjde negativně. Z jejich výčtu můžeme zmínit: úplnou absenci progresu motorických symptomů v průběhu pěti let, symetrii parkinsonismu na obou stranách těla nebo opakované pády během tří let po začátku nemoci. Podrobněji diagnózu popisuje Movement Disorder Society. [9]



Obr. 5: Schéma diagnózy Parkinsonovy nemoci. Vytvořeno podle [9].

Ukazuje se, že mnoho symptomů je v drobnější míře patrná již před samotnou diagnózou. Z tohoto důvodu se hledají jakékoliv biomarkery onemocnění, které by přinesly dřívější odhalení jeho výskytu.

Diagnóza kromě příznaků nemoci používá i zobrazovací metody mozku, nejčastěji magnetická rezonance a PET sken. Jejich výhodou je vysoká přesnost, která je ale vykoupena vysokou cenou vyšetření. Vědci se pokoušejí vyvinout krevní testy, ale jejich senzitivita i specifita zatím nebyla příliš vysoká. V začátcích je zatím i diagnóza nemoci pomocí genového sekvenování [1].

1.1.6. Léčba

V současnosti neexistuje možnost Parkinsonovu nemoc vyléčit, ale pouze zmírňovat její symptomy. Lékem, který se podává v určité fázi nemoci nakonec všem pacientům, je levodopa. Po proniknutí hematoencefalickou bariérou se v mozku mění na dopamin, jehož nedostatek vyrovnává. Dlouhodobé působení levodopy vede v řádu let k rozvinutí dyskinezií, tj. nahodilých pohybů, jejichž důvod není zcela znám. Předpokládá se, že vzniká vlivem nestálého přísunu

levodopy do mozku. Řeší se buď konzistentním přísunem levodopy do těla, či omezením látek, které ji odbourávají: hlavně Dekarboxyláza L-aromatických aminokyselin (AADC) a Katechol-O-metyltransferáza (COMT). Nicméně i tak se mohou vyskytnout projevy nemoci, které nereagují na farmakologickou léčbu [1].

Další možností léčby, která se užívá, je zvýšení reabsorpce dopaminu neuronu ze synaptické štěrbině poté, co je do ní dopamin vypuštěn. Toho se docílí inhibicí monoaminooxidázy typu B (MAOB) odpovědné za oxidaci dopaminu v gliových buňkách, čímž se zvýší jeho koncentrace a o to více je vstřebává zpět do neuronu. Využívá se i posílení dopaminových agonistů v receptorech, které způsobí silnou odpověď i při snížené koncentraci dopaminu. Daní za tento typ léčby je, že dopamin se nevyskytuje jen v striatu a zvýšená odezva na něj může poškodit například systém odměňování [1].

Pro vyhnutí se vedlejším efektům levodopy, může být pacientům, kteří nejsou již například dementní, nabídnuta léčba pomocí hluboké mozkové stimulace (DBS). Při zavádění elektrod je ovšem přibližně 0,5 % šance úmrtí vlivem špatného provedení a následným krvácením uvnitř lebky. I přes toto riziko je operace vzhledem k jejím benefitům doporučována. Elektronická stimulace o vysoké frekvenci ve středním mozku pomáhá prakticky vždy s tremorem a s ostatními příznaky také, pokud dříve byla účinná léčba levodopou. V budoucnu může léčba směřovat ke genové nebo spánkové terapii [1, 10, 11].

1.1.7. Obličejová bradykineze – hypomimie

Oproti pohybům horních a dolních končetin mají mimické pohyby odlišný charakter, a to zejména díky (i) vzájemnému zapojení velkého množství menších svalů, (ii) absenci svalových úponů, (iii) odlišné inervaci, absenci opakovaných či střídavých inhibičních vzruchů a zejména (iv) častému mimovolnímu ovládnutí. V porovnání s volným pohybem jsou mimovolní pohyby charakteristické odlišnou inervací [12].

Bradykineze obličejového svalstva se pojí s názvem hypomimie a u Parkinsonovy nemoci se projevuje zejména výrazem bez zájmu – často v anglické literatuře označovaným jako „poker face“ či „masked face“, Typickým projevem parkinsonské hypomimie jsou otevřenější oči (vypadají zahleděně do dále), významné omezení pohybů obličejového svalstva, zploštělé nasolabiální rýhy a pootvření úst v klidu. S těmito projevy se pojí redukce grimasování vedoucí ke snížení počtu spontánních úsměvů, ačkoliv nebylo prokázáno, že by postižený méně doceňoval humor. Na druhou stranu nebyla vyloučena souvislost s depresemi. V rané fázi onemocnění dochází k redukci spontánního mrkání, které je v pokročilých naopak nahrazeno excesivním mrkáním. Zdá se, že všechny výše zmíněné příznaky se zlepšují při léčbě levodopou, narozdíl od DBS, která ne vždy pomůže [12].

Pacienti mají komplikace s výrazným omezením či vymizením spontánních projevů emocí, zejména negativních, jako strach nebo nechuť. Při úmyslném grimasování dochází také k omezení amplitudy pohybu, nicméně toto omezení je výrazně nižší než při pohybech spontánních. Při volném projevu emocí je bradykineze patrná hlavně ve spodní části obličeje, je zde patrná snížená rychlost i amplituda, pozorovaná například na otevírání ústní dutiny. Kinematická analýza volního mrkání neodhalila významnou změnu v rychlosti ani rozsahu pohybu, nicméně parkinsonikovi trvalo déle přepnout z fáze zavírání do fáze otevírání. Zajímavé je, že použití levodopy přechodnou fází ještě více prodlužuje. Reflexní mrknutí nebylo onemocněním ovlivněno, což odpovídá vysvětlení v sekci 1.1.2 [12]

Ačkoliv mnoho studií již zkoušelo odhalit Parkinsonovu nemoc z videí, nenarazili jsme na žádnou, která by za tímto účelem využívala přímo vrásky. Většina aktuálních studií se odvíjí buď od řečové analýzy [13–15] nebo od analýzy významných bodů na obličeji [16–18]. Zde se ukazuje, že analýza statických fotek nevykazuje tak dobré výsledky, jako analýza videí.


1.2. Vrásky a jejich detekce

1.2.1. Lokalizace vrásek

Vrásky jsou záhyby v obličejové kůži, které vznikají pohybem mimických svalů pod nimi. Na obličeji můžeme najít mnoho rozličných vrásek: (i) čelní vrásky, (ii) glabelární svislé vrásky mezi obočím, vrásky (iii) příoční a (iv) příušní, (v) linie tváří, (vi) nasolabiální rýhy, (vii) vrásky okolo úst, (viii) marionetové čáry, (ix) labiomentální záhyb a (x) záhyby na krku. Vrásky se a tvoří se při různých pohybech, například glabelární vrásky vznikají při mračení, vrásky okolo očí naopak při úsměvu [19]. Obličejové vrásky jsou ilustrovány na Obr. 6.

1.2.2. Detekce vrásek

Vráska je v obrazové teorii hranice, tedy soubor vedle sebe ležících bodů s vysokým gradientem obrazové funkce. Body, kde je vysoký gradient obrazové funkce se nazývají hranové body a hranice je kolmá na směr gradientu obrazové funkce v nich. Pro detekci vrásek se mohou použít jak detektory hran, tak i specializovanější detektory liniové a tyto se mohou doplnit složitějšími algoritmy pro potlačení falešně detekovaných vrásek nebo naopak doplnění vrásek nedetekovaných. V následující sekcích si stručně popíšeme většinu algoritmů, které byly k detekci vrásek použity [20], případně by se využít daly. Algoritmy využívající vlastností vrásek k aplikacím jako je odhad věku, které neobsahují samotnou detekci vrásek, neuvádíme [21].



Obr. 6: Obličejové vrásky. HF= čelní horizontální; GF =glabelní, vrásky; PO = přiloční; PA = příušní; CL = linie tváří; NL = nasolabiální rýhy; LL, UL, CM = vrásky okolo úst; ML = marionetové čáry; LM= labiomentální záhyb a NF = záhyby na krku. Převzato z [19].

1.2.2.1. Jednoduché diferenční filtry

Nejjednodušší filtry jsou diferenční okna jako Sebelovo, Robertsovo nebo Prewittovo okno, viz Obr. 7. Konvoluce obrazové funkce s kterýmkoliv z oken dá za vznik odezvě pro každý bod obrazu. Vzniklé odezvy je možné prahovat a body s velkou odezvou jsou označeny za hranové body. Pokud prahujeme absolutní hodnotu odezvy, hrany budou detekovány dvakrát širší. Robertsovo okno neumožňuje jednoduchou volbu směru detekce, zato však je výpočetně nejsnazší. Diference obrazové funkce se dá nahradit její konvolucí s Prewittovým nebo Sobelovým oknem, protože tato okna volbu směru umožňují. Sobelovo okno navíc částečně obraz vyhlazuje a není tedy tolik citlivé na šum. Diference obrazové funkce f ve směru osy x se značí Δf_x a ve směru osy y Δf_y . Gradient obrazové funkce se značí $grad_f$ a definuje se jako $grad_f = (\Delta f_x, \Delta f_y)$. Hranice je pak soubor hranových bodů, který je kolmý na směr gradientu

v nich. Hranice detekované v obrazu tváře, které spadají směrem do námi zvoleného rozmezí jsou označeny za vrásky [22].

-1	0	0	-1
0	1	1	0

Roberts

-1	-1	-1	-1	0	1
0	0	0	-1	0	1
1	1	1	-1	0	1

Prewitt

-1	-2	-1	-1	0	1
0	0	0	-2	0	2
1	2	1	-1	0	1

Sobel

Obr. 7: Základní diferenční okna. Prewittovo a Sobelovo okno vlevo se dají použít jako diference ve směru y a napravo ve směru x. Převzato z [22]


1.2.2.2. Gaborův filtr

Gaborovy filtry fungují na obdobném principu jako výše uvedená okna. Hodnoty okna Gaborova filtru je možné popsat pomocí rovnice (1):

$$g(x, y, \theta, \sigma) = e^{-\frac{x^2+y^2}{\sigma^2}+2\pi\theta i(x\cos(\theta)+y(\sin\theta))}, \tag{1}$$

nicméně různé zdroje uvádějí trochu odlišné definice. Pro účely této práce byla využita definice využitá v programovém prostředí MATLAB.

Parametry θ a σ mění orientaci a šířku filtru, proto tímto způsobem můžeme vygenerovat různě orientovaná okna pro přesnější detekci hran, což je ukázáno na Obr. 8. Odezvy konvoluce mezi vygenerovanými okny a obrazovou funkcí jsou opět prahovány, čímž se získají hrany, které označíme jako vrásky. Gaborův filtr byl dříve využit pro detekci vrásek a následný odhad věku [23].



Obr. 8: Různě natočené Gaborovy filtry. Převzato z [24].

1.2.2.3. Marrův-Hilderthův filtr

Marrův-Hilderthův filtr funguje na principu konvoluce obrazu s oknem Laplaciánu Gaussiánu, a obsahuje diference druhého řádu. Využívá asociativity Laplaciánu funkce a konvoluce. Laplacián funkce f je definován rovnicí (2):

$$\nabla^2 f(x, y) = \frac{df^2}{dx^2} + \frac{df^2}{dy^2}. \quad (2)$$

Pro vyhlazení obrazu se běžně používá 2D Gaussián definovaný rovnicí (3):


$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}, \quad (3)$$

kde σ je volitelný parametr a udává šíři vyhlazování.

Případně je možné namísto dvou konvolucí obrazu nejprve s Gaussiánem a pak počítání Laplaciánu, vytvořit jedno konvoluční okno spočítáním Laplaciánu Gaussiánu, který je popsán rovnicí (4):

$$\nabla^2 G(x, y) = \frac{1}{2\pi\sigma^2} \left(\frac{x^2+y^2+\sigma^2}{\sigma^4} \right) e^{-\frac{x^2+y^2}{\sigma^2}}. \quad (4)$$

Abychom mohli provádět diskretní konvoluci, je nutné vzorkovat hodnoty Laplaceiánu Gaussiánu v celých číslech. Pro nalezení hran, musíme ve filtrovaném obrazu označit průchody nulou, které hrany reprezentují. To se dělá většinou okny 2x2 nebo 3x3, kde na jedné straně okna se nachází 1 a na druhém -1. Po následné konvoluci s těmito okny získáme pro průchody nulou vysoké hodnoty, které můžeme prahovat. Prahované průchody nulou označíme jako vrásky. Laplaceián Gaussiánu je znázorněn spojitě a diskretně na Obr. 9.



Obr. 9: Vlevo spojitý, vpravo diskretní Laplaceián Gaussiánu. Převzato z [22].

1.2.2.4. Cannyho filtr

Cannyho filtrem nazýváme postup, který má čtyři kroky.

- 1) **Vyhazení obrazu Gaussovským filtrem (Gaussiánem) viz (3).**
- 2) **Spočítání gradientu, jeho velikosti a úhlu**

Gradient je vypočten pomocí diferencí, obdobně jako v kapitole 1.2.2.1. Pro jeho velikost použijeme Pythagorovu větu: $|grad_f| = \sqrt{\Delta f_x^2 + \Delta f_y^2}$ a úhel získáme jako $\alpha = arctg \frac{\Delta f_x}{\Delta f_y}$.

- 3) **Potlačení lokálních maxim**

Jako hrany budeme detekovat body s vysokou velikostí gradientu. Protože těchto bodů se může ve směru gradientu nacházet více, budeme z daného směru zahrnovat pouze body, které mají ve směru gradientu jeho velikost největší a ostatní body přestaneme uvažovat.

- 4) **Použití prahování s hysterezí**

Tento proces slouží k potlačení nevýznamných hran. Určíme si dva prahy T_l a T_h . $T_l < T_h$. Body (x, y) , které mají $|grad_f(x, y)| > T_h$ automaticky budeme považovat za hranový bod. Body, které mají $|grad_f(x, y)| > T_l$ budeme určit jako kandidáty na hranové body. Postupně

budeme zkoušet, zda nějaký bod, z kandidátů na hranové body sousedí s hranovým bodem. Pokud ano, je považován za hranový bod. Tento proces opakujeme do konvergence. Hranové body pak můžeme označit za vrásky. [22] I Cannyho filtr byl dříve využit pro detekci vrásek k odhadování věku [25].


1.2.2.5. Houghova transformace

Houghova transformace se liší od předchozích metod hlavně v tom, že detekuje vzory v binárním obraze. Binární obraz si můžeme představit jako transformaci obrazu do binární informace: pixel obsahuje/neobsahuje vrásku. Takovýto výstup může poskytnout například Cannyho filtr. Nejjednodušším vzorem pro demonstraci je přímka. Ta je popsána rovnicí $y = ax + b$. Pokud některý bod (x_i, y_i) náleží této přímce, můžeme rovnici přepsat jako $b = y_i - ax_i$. Z této rovnice můžeme vyjádřit závislost a na b a najít parametry všech možných přímek, které prochází bodem (x_i, y_i) . Myšlenkou je převést všechny hranové body do prostoru parametrů a a b a najít takové parametry a' a b' , pro které platí, že bodem $(a'$ a $b')$ prochází co nejvíce přímek v prostoru parametrů. To se v praxi dělá tak, že se parametry rozdělí na podintervaly a pokud parametrizace určitého bodu daným podintervalem $[a_i, a_j] \times [b_i, b_j]$ prochází, tak danému intervalu přidáme váhu 1. Toto se opakuje pro každý interval a střed daného intervalu je zvolen jako výsledné parametry přímky. Pokud hledáme více přímek, zvolíme odpovídající počet intervalů s největší vahou. Pro tento případ se hodí potlačení okolí maxim, abychom nebrali mnoho podobných přímek. Tento přístup má nevýhodu v tom, že pro vertikální přímku má hodnota parametru a hodnoty blízké $\pm\infty$. Z toho důvodu je přímka parametrizována pomocí rovnice (5):

$$x \cos(\theta) + y \sin(\theta) - \rho = 0.$$

(5)

Výhodou tohoto postupu je, že parametr θ je omezený na interval $(-90^\circ; 90^\circ)$ a vzdálenost od středu je konečná. Poté se postupuje stejně jako u předchozích parametrů; a sice všechny možné parametry jsou rozděleny do podintervalů a je vypočteno okno s největší vahou. Následné přímky splňující naše požadavky označíme za vrásky [22]. Efekt parametrizace je znázorněn na Obr. 10. Také Houghova transformace byla dříve využita pro odhadování věku [26].



Obr. 10: Na levém podobrázku znázorněna parametrizace přímky. Na prostředním převedení bodů do prostoru parametrů. Na podobrázku vpravo rozdělení parametrového prostoru na subintervaly. Převzato z [22].

1.2.2.6. Marked point process

Marked point process někdy označován jako Markov point process je postup pro trasování spojitých hranic. Marked point process byl využíván především k detekci vrásek čelních a příočních [27–29]. Vzhledem k tomu, že popisovat zde celý algoritmus by bylo nad rámec této práce, a navíc některé jeho součásti jsou popsány výše, omezíme se na výčet principiálních kroků:

- 1) **Detekování hran pomocí hranového detektoru**
- 2) **Nalezení úseček pomocí Houghovy transformace**
- 3) **Vytvoření hodnotící funkce pro úsečky, které jsou označeny za vrásky**

Tato hodnotící funkce v sobě má zakomponované různé odměňující a penalizující prvky. Oceňuje, když úsečka sousedí s nějakou jinou, která má podobný sklon, prioritizuje úsečky s větší hodnotou gradientu, a naopak penalizuje úsečky, které jsou osamoceny.

- 4) **Nalezení minima této funkce v celém obrazu pomocí Reversible-jump Markov chain Monte Carlo (RJMCMC) algoritmu**

RJMCMC je algoritmus, který se v jedné iteraci do sady úseček označených jako vrásky náhodnou buď pokusí přidat nebo z ní jednu odebrat. Pakliže dané přidání či odebrání dostatečně zvýší hodnotící funkci, tak je přidání nebo odebrání akceptováno a toto se opakuje určitý počet iterací. Výsledná sada úseček je pak považována za vrásky.

1.2.2.7. Frangiho filtr (Hybrid Hessian filtr)

Frangiho filtr nebo také Hybrid Hessian filtr (HHF) je liniový filtr, neslouží tedy k detekci jakýchkoliv hran. Proces Frangiho filtrace je popsán níže.

Hessián funkce f je ve 2D definován rovnicí 6:

$$H(f(x, y)) = \begin{bmatrix} \frac{\partial^2 f}{\partial x^2} & \frac{\partial^2 f}{\partial x \partial y} \\ \frac{\partial^2 f}{\partial x \partial y} & \frac{\partial^2 f}{\partial y^2} \end{bmatrix}.$$

(6)

Před aplikováním výpočtu Hessiánu je výhodné obrazovou funkci vyhladit Gaussiánem (3). Můžeme využít asociativity derivace a derivovat nejdříve Gaussián a jím následně provést konvoluci s obrazovou funkcí. Tento postup je možné vyjádřit souborem rovnic (7) – (10), jejichž předvýpočet ušetří výpočetní výkon

$$H(G(x, y) \star f(x, y)) = H(G(x, y)) \star f(x, y).$$

(7)

$$\frac{\partial^2 f}{\partial x^2} G(x, y, \sigma) = \frac{\sigma^2 - x^2}{2\pi\sigma^6} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

(8)

$$\frac{\partial^2 f}{\partial x \partial y} G(x, y, \sigma) = \frac{xy e^{-\frac{x^2+y^2}{2\sigma^2}}}{2\pi\sigma^6}$$

(9)

$$\frac{\partial^2 f}{\partial y^2} G(x, y, \sigma) = \frac{\partial^2 f}{\partial x^2} G(x, y, \sigma)^T$$

(10)

Samotný algoritmus vypadá následovně:

Iterace přes $\sigma = \sigma_{min} \dots \sigma_{max}$ (hodnoty odpovídají minimální a maximální šířce vrásky)

1) Pro každý bod (x, y) výpočet vztahu (11)

$$A(x, y, \sigma) := H(G(x, y, \sigma)) \star f(x, y)$$

(11)

2) Výpočet vlastních čísel $\lambda_1(x, y, \sigma)$ a $\lambda_2(x, y, \sigma)$ náležících $A(x, y, \sigma)$ pro každý bod (x, y) .

3) Vyjádření $R(x, y, \sigma) := \left(\frac{\lambda_1(x, y, \sigma)}{\lambda_2(x, y, \sigma)}\right)^2$, $S(x, y, \sigma) := \lambda_1(x, y, \sigma)^2 + \lambda_2(x, y, \sigma)^2$ pro každý bod (x, y) .

4) Vyjádření $\epsilon(x, y, \sigma)$ ze vztahu (12) pro každý bod (x, y) .

$$\epsilon(x, y, \sigma) := \begin{cases} 0 & |\lambda_2 < 0 \\ e^{-\frac{R(x,y,\sigma)}{2\beta_1^2}} \left(1 - e^{-\frac{S(x,y,\sigma)}{2\beta_2^2}} \right) & | \text{jinak} \end{cases}$$

(12)

kde $\beta_{1,2}$ jsou volitelné parametry

Nakonec vyjádření $L(x, y) = \max_{\sigma} \epsilon(x, y, \sigma)$.

Body (x, y) , kde $L(x, y) > 0$ jsou označeny za vrásky a tato hodnota odpovídá jejich hloubce. V závislosti na tom, zda hledáme bílé linie na černém pozadí, anebo naopak tmavé linie na světlém pozadí může rovnice (12) obsahovat podmínku $\lambda_2 < 0$ s opačným znaménkem. Filtr byl původně vyvinut pro detekci žil v oku [30], nicméně po vhodné úpravě parametrů ho lze využít k detekci vrásek [31].

1.2.2.8. Hessian line tracking

Hessian line tracking (HLT) se jmenuje algoritmus, který vylepšuje Frangiho filtr. Při tomto postupu jsou body, označené Frangiho filtrem, jako vrásky pojmenovány jako počáteční vrásky. V každém bodě náležícím počátečním vráskám se ve směru, ve kterém je nejvyšší pravděpodobnost, že vráska bude pokračovat, vytvoří sekvence bodů tak, že v každém z nich se spočítá gradient a následující bod sekvence leží ve směru tohoto gradientu. Sekvence končí ve chvíli, kdy gradient posledního bodu není dost velký. Bodům, které ležely v sekvenci zvýšíme váhu. Po vytvoření všech sekvencí a zvýšení vah patřičných bodů, můžeme body s dostatečně velkou váhou označit za vrásky. HLT, tak jak byl popsán [32], je využíván především pro čelní vrásky k pospojování segmentů do celistvějších útvarů, pro jiné vrásky nemusí být vhodný, protože nebere v potaz směr nahoru [20]. Nemělo by být složité ho však předělat a použít i k detekci jiných vrásek.

1.2.3. Srovnání algoritmů

Pro srovnání teoretické srovnání algoritmů na detekci vrásek slouží následující Tab. 1.

Metoda	Atributy	Veřejně dostupný	Výpočetní náročnost	Možnost volby směru	Typ
Diferenční filtry		Ano – ve vývojovém prostředí MATLAB funkce <i>edge</i>	Nízká	Ano, 2 směry	Hranový
Gaborův filtr		Ano – ve vývojovém prostředí MATLAB funkce <i>imgaborfilt</i>	Nízká	Ano, neomezeně	Hranový
Marrův-Hilderthův filtr		Ano – lze dohledat ¹	Nízká	Ne	Hranový
Cannyho filtr		Ano – ve vývojovém prostředí MATLAB funkce <i>imgaborfilt</i>	Nízká	Ano, v dostupné verzi Ne	Hranový
Houghova transformace		Ano – ve vývojovém prostředí MATLAB funkce	Střední	Ano, neomezeně	Vzorový
Frangiho filtr		Ano – lze dohledat ²	Střední	Ano, neomezeně	Liniový
Marked point process		Ne	Vysoká	Ano, neomezeně	Liniový
Hessian line tracking		Ne	Vysoká	Ano, 6 směřů	Liniový

Tab. 1: Teoretické srovnání algoritmů pro detekci vrásek. Výpočetní náročnost u nedostupných algoritmů je odhadovaná.


¹ Jedna z možných implementací zde <https://www.mathworks.com/matlabcentral/fileexchange/41220-marr-hildreth-edge-detector>

² Jedna z možných implementací zde <https://www.mathworks.com/matlabcentral/fileexchange/24409-hessian-based-frangi-vesselness-filter>

2. Metodologie

2.1. Dataset

Dataset k praktické části obsahuje nahrané minutové monology účastníků studie – pacientů s Parkinsonovou nemocí a zdravých kontrol. Nahrávky jsou rozstříhány na jednotlivé snímky. Na každém snímku bylo spočítáno 68 významných bodů na tváři [33]. Významné body se nachází například v koutcích úst nebo ohraničují obličej. Všech 68 jich je vykresleno na Obr. 11. K pacientům byla poskytnuta klinická data a ke všem účastníkům percepční hodnocení.



Obr. 11: 68 významných bodů na tváři. Převzato z [34].

De-novo pacienti byli nahráváni mezi léty 2015 a 2020 a byli diagnostikováni podle standardů Movement Disorder Society. [9] Výlučná kritéria ze studie byla: (i) dříve používaná léčiva proti Parkinsonově nemoci, (ii) historie jiného vážného neurologického onemocnění nebo jiného stavu ovlivňující pohyb obličeje, (iii) deprese a (iv) terapie pro zlepšení řeči či hypomimie. K nemocným účastníkům studie byla vytvořena skupina 75 zdravých kontrol s odpovídajícím věkem a pohlavím.

Celkově z měření vyšlo 91 de-novo pacientů zahrnující 54 mužů a 37 žen s průměrným věkem 61,0 let směrodatnou odchylkou věku 12,3 let.

Všichni účastníci poskytli písemný souhlas před jejich zahrnutím do studie. Studie dostala povolení od etické komise Všeobecné fakultní nemocnice v Praze a byla provedena s ohledem na Etické zásady pro lékařský výzkum s účastí lidských bytostí.

2.2. Videa

Videa byla natočena digitální kamerou Panasonic Handycam HDR-CX410 umístěnou přibližně jeden metr před hlavou účastníka. Rozlišení těchto videí je 1440 na 1080 pixelů (HD) a snímkovací frekvence 25 snímků za sekundu. Všechna videa obsahují jednodominutové monology na volné téma.

2.3. Klinická data a percepční analýza

V klinických datech je zahrnuto skóre Montrealského kognitivního testování (MoCA) a skóre z testu Movement Disorder Society-Unified Parkinson's Disease Rating Scale, Part III (MDS-UPDRS-III) [35]. Z tohoto testu se také počítaly částečné součty skóre, které daly za vznik nových parametrům, například hodnocení bradykineze.

U zdravých kontrol i pacientů bylo z videí provedeno subjektivní percepční hodnocení hypomimie v rozmezí 0 = žádné postižení, 1 = drobné poškození, 2 = mírné poškození a 3 = střední až vážné poškození mimiky. Toto hodnocení vychází z definice uváděné v MDS-UPDRS III bodě 3.2. Mimika.


2.4. Detekce vrásek a výběr jejich parametrů

2.4.1. Výběr vrásek

Ze všech vrásek uvedených v Lokalizace vrásek jsem se rozhodl pro analýzu třech z nich, jsou jimi: Čelní vrásky, glabelární vrásky a nasolabiální rýhy. Důvodem pro jejich výběr je omezený úhel, ve kterém se tvoří. Vrásky příoční byly vyřazeny z důvodu častého zakrytí nožičkami brýlí a velké citlivosti na úhel otočení hlavy. Linie tváří a příušních vrásek jsou taktéž náchylné na polohu hlavy a vrásky ve spodní části obličeje bývají velice často překryty vousy a knírem, také proto nebyly zahrnuty do budoucích kroků.

2.4.2. Předzpracování

Protože lidské obličeje bývají různě natočené, je výhodné pro budoucí kroky otočit tváře tak, aby oči tvořily horizontální přímkou. Zároveň osa obličeje, kterou prochází i optický střed tváře – špička nosu, by měla být svislá. Toho se dá dosáhnout rotací obrazu okolo špičky nosu o úhel, který svírá osa očí s horizontální přímkou. Pro parametrizaci osy očí jsem proložil významné body číslo 37 až 48 přímkou metodou nejmenších čtverců. Za špičku nosu jsem považoval významný bod číslo 34. Zároveň jsem si obraz převedl do šedotónové oblasti, ve které je možné provádět filtrace a jasové transformace. Otočení obličeje je ilustrováno na Obr. 12.



Obr. 12: Otočení obličeje do roviny. A: neotočené významné body B: otočené významné body.

2.4.3. Segmentace


Obličej lze segmentovat snadno právě díky významným bodům poskytnutým k jednotlivým snímkům. S přihlédnutím k tomu, že jsem je otočil do souřadnicových os, jsem mohl segmentovat do obdélníkových oken rovnoběžných s osami. Tímto postupem byla získána okna pro čelní vrásky, glabelární vrásky a nasolabiální rýhy.

Pro čelní vrásky jsem vybral jako spodní hranici obdélníku výše umístěný významný bod z dvojice 25 a 20. Pravou a levou stranu ohraničují významné body 19 a 26. Výška obdélníku je nastavena tak, aby poměr výšky a šířky byl 1:3.

Glabeledární vrásky jsem získal z okna takového, že pravá a levá hranice jsou x-ové souřadnice významných bodů č. 40 a 43. Spodní straně náleží významný bod 28 a horní se dopočítá, aby výsledkem segmentace byl čtverec.

Nasolabiální rýhy se nachází v obdélníku ohraničeném zleva svislou úsečkou, jejíž prodloužení prochází přesně mezi významnými body 5 a 6, úsečka na opačné straně mezi 13 a 12. Spodní hrana se dotýká nejvýše umístěného bodu z pořadových čísel 51 až 53, aby se v záběru nenacházela ústa. Seshora ohraničuje segment bod č. 30.

Všechna okna jsou znázorněna na Obr. 13.



Obr. 13: Okna pro segmentaci. Modré pro čelní vrásky, zelené pro glabelní vrásky a červené pro nasolabiální rýhy.

2.4.4. Ekvalizace histogramu

U daných segmentů je před samotnou detekcí ještě důležitá ekvalizace histogramu, aby rozdíly mezi pixely kůže byly patrnější, protože kůže nevyužívá celou širší jasové stupnice. Samotná ekvalizace ovšem dělala z méně osvětlených částí kůže skoro černé skvrny, což je nežádoucí. Proto jsem ekvalizaci histogramu omezil tak, že difference ve vyhledávací tabulce této jasové transformace není vyšší než 3.

2.4.5. Výběr algoritmu

Při výběru nejvhodnějšího algoritmu z uvedených v Tab. 1 jsem nejprve vyloučil ty, které nejsou veřejně dostupné, tedy Marked Point Process a Hessian Line Tracking. Výstupy ostatních filtrů jsem vizuálně porovnal a percepčně ohodnotil.

Nevhodné se ukázaly Cannyho filtr a Marrův-Hilderthův filtr, protože se u nich nedal vybrat směr detekce, tudíž detekovaly různé objekty, nejen vrásky. Toto probíhalo navíc ve všech směrech. Diferenční filtry i Gaborův filtr, byly schopné ve většině případů relativně spolehlivě detekovat vrásky, nicméně i tyto filtry navíc detekovaly různé přechody a větší objekty.

Jako jednoznačně nejlepší varianta se jevila dostupná implementace Frangiho filtru [36]. Nejenže měla velmi málo falešně detekovaných nebo přehlédnutých vrásek, ale zároveň

poskytovala informaci o nejpravděpodobnějším pokračování vrásky reprezentovanou proměnnou α . Tento filtr není binární a jeho hodnoty jsou závislé na rozdílu jasu ve vrásce a jejím okolí. To je možné vztáhnout k hloubce vrásky, což může být také důležitý prvek pro hodnocení dynamických změn v obličejové oblasti.

Houghovu transformaci jsem v současné práci nevyužil, jelikož potřebuje binární obraz, který byl ale stejně nejspolehlivěji detekován prahováním výstupu Frangiho filtru. Nicméně Houghovu transformaci by bylo možné použít pro parametrizaci nasolabiálních rýh.

2.4.6. Vstupní argumenty Frangiho filtru

Frangiho filtr umožňuje volbu intervalu šíře detekovaných vrásek. Vrásky čelní a glabelární vrásky bývají užší a vhodné hodnoty parametru σ jsou v intervalu $\langle 1; 3 \rangle$ na rozdíl od širších nasolabiálních rýh, kde se jako vhodný jevil interval $\langle 1; 5 \rangle$. Parametry β_1 a β_2 byly ponechány beze změny, a tedy nastaveny po řadě na 0,5 a 15.

2.4.7. Odstranění falešně detekovaných vrásek

Falešná detekce vrásek byla redukována omezením úhlu detekce. Frangiho filtr kromě šedotónového obrazu s detekovanými liniemi reprezentovanými hodnotami $L(x, y)$ vrací pro každý bod (x, y) i úhly α , kam linie směřují. Z obličejové anatomie je možné odhadnout pravděpodobný směr vrásek a definovat proto, že například vrásky na čele nebudou mít svislý směr, ale spíše se jedná vlasy. Povolené úhly α_f pro vrásky na čele se pohybují v intervalu $\alpha_f \in \langle 1,2; 3,15 \rangle$, $\alpha_g \in \langle 0; 0,4 \rangle$ pro vrásky glabelární a pro nasolabiální $\alpha_n \in \langle 0; 1 \rangle$. Velikosti úhlů jsou v obloukové míře. Hodnotám $L(x, y)$ získaným z výstupu filtru mající α mimo povolený interval byla nastavena hodnota 0.

Proti falešné detekci nosu jako nasolabiálních rýh pomáhá vynulovat prostor v okolí významných bodů 32–36. V této oblasti ještě nastává problém s detekcí jednotlivých vousů kníru jako vrásek. Tomu je možné předejít vyhlazením Gaussovským filtrem před samotnou detekcí. V oblasti glabelárních a čelních vrásek se vyhlazování nedoporučuje, protože se tam vyskytují i jemné vrásky, které by kvůli tomu zůstaly nedetekované. V oblasti glabelárních vrásek okno zasahuje i do části nadočnicových oblouků, které mohou být, stejně jako obroučky případných brýlí, detekovány jako vrásky. Proti tomu pomohlo nastavení hodnot detekovaných v rozích na 0. Tedy pro bod (x, y) je nastaveno $L(x, y) = 0$, splňují-li jeho souřadnice vztah (13).

$$|x - x_{center}| + |y - y_{center}| > \frac{a}{2},$$

(13)

kde x_{center} a y_{center} jsou souřadnice středu čtvercového okna a a značí délku strany okna.

2.4.8. Výběr parametrů

Pro výběr parametrů jsem využil všechny tři oblasti vrásek. Aby výsledky byly porovnatelné mezi pacienty, upravil jsem okna příslušných oblastí na jednotnou velikost pixelů. Pro čelní vrásky byla zvolena velikost 100 x 300 pixelů, pro nasolabiální 100 x 200 pixelů a pro glabelární 100 x 100 pixelů.

U každého pacienta a zdravého člověka máme k dispozici 1501 snímků. Nabízelo se u všech snímků sečíst hodnoty $L(x, y)$ celého vráskového obrázku, čímž jsem získal signál o 1501 hodnotách. Z hodnot tohoto signálu jsem spočítal průměrné množství vrásek a jejich směrodatnou odchylku, čímž jsem získal, průměrné množství vrásek a jak moc se mění množství vrásek v průběhu času. Průměrná hodnota vráskového okna snímků jednoho člověka byla označena jako $sum_{avg-nas}$ (resp. $sum_{avg-for}$ a $sum_{avg-glab}$) pro nasolabiální oblast (resp. čelní oblast a glabelární oblast). Směrodatnou odchylku jsem označil sum_{std} s příponami stejnými jako v předchozím případě.

K detekci pohybu vrásek jsem využil součet druhých mocnin rozdílů (SSD; sum of square differences) proměnné $L(x, y)$ jednotlivých snímků jdoucích po sobě. To lze, protože již všechna vrásková okna byla upravená na stejnou velikost. Získal jsem tedy signál o 1500 hodnotách, ze kterého mohl opět spočítat průměr a směrodatnou odchylku. Značení pro průměr SSD: ssd_{avg} se stejnými příponami jako v předchozím odstavci podle typu vrásek.

2.5. Statistická analýza

Otestoval jsem normalitu parametrů a případně jejich poměrů Kolmogorovým-Smirnovým testem. Parametry a jejich poměry, které prošly testem normality, jsem nadále analyzoval pomocí parametrických testů zahrnujících studentův t-test a Pearsonovy korelace s klinickými daty a percepčním hodnocením. Parametry, které měly nenormální rozložení jsem analyzoval neparametrickým Wilcoxonovým rank sum testem a Spearmanovou korelací.

2.6. Klasifikační experiment

Za účelem ověření využitelnosti navržených parametrů jsem provedl klasifikační experiment. Nejprve jsem natrénoval model logistické regrese na parametrech všech možných kombinací vráskových oken. Díky němu jsem vykreslil Receiver Operating Characteristic (ROC) křivku a spočetl plochu pod ní (AUC; Area Under Curve). Zároveň jsem u kombinací oken vypočítal přesnost (ACC; accuracy), specifitu (SPEC) a senzitivitu (SENZ) logistické regrese parametrů za pomoci metody křížové validace Leave-One-Sample-Out [37]. Na základě těchto výsledků jsem také zjistil, která oblast vrásek hraje pro správnou klasifikaci největší roli.

3. Výsledky

3.1. Detekce vrásek


Ukázka detekce vrásek pomocí Frangiho filtru a mnou navržených úprav ze všech tří segmentovaných oblastí se nalézá na Obr. 14.



Obr. 14: Ukázka detekce vrásek pomocí Frangiho filtru a následných úprav. U nasolabiálních rýh je vidět rozšíření oproti původnímu obrázku, to je způsobeno vyhlazením Gaussiánem.

Pro porovnání významu těchto úprav zde vložím i ukázkou detekce vrásek bez nich. Je zobrazena na Obr. 15. Můžeme si všimnout obrovského množství falešně detekovaných objektů jako vrásek, zejména vlasů jako čelních vrásek, nadočnicových oblouků a obočí jako glabellárních vrásek a špičky nosu jako nasolabiálních rýh.


glaberalární vrásky



glaberalární oblast



nasolabiální rýhy



nasolabiální oblast



čelní vrásky



čelní oblast

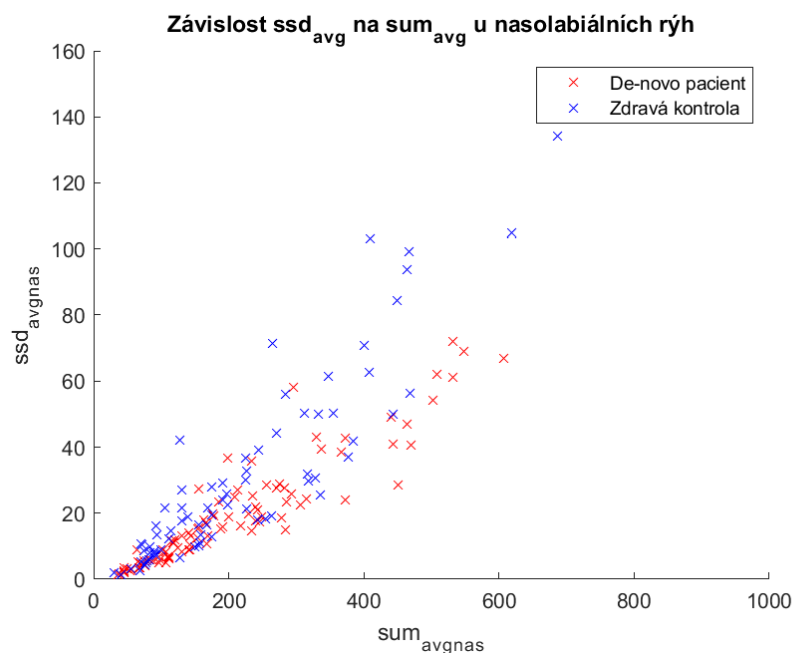


Obr. 15: Ukázka množství falešně detekovaných vrásek Frangiho filtrem bez následných úprav.

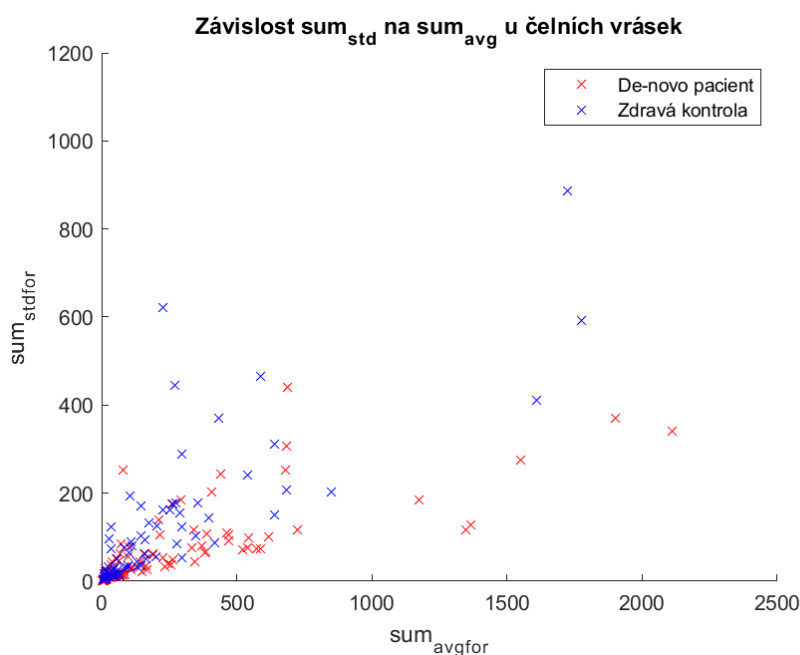
3.2. Analýza parametrů

3.2.1. Závislost parametrů

Vzhledem k tomu, že účastníci studie jsou v různém věku a obličej mají rozličně zvrásněný, zdálo se vhodné zkoumat závislost parametrů ssd_{avg} , a sum_{std} na sum_{avg} . Ukázky dvou vybraných závislostí jsou na Obr. 16 a Obr. 17.



Obr. 16: Závislost průměrného rozdílu mezi vráskovými okny na průměrném množství vrásek. $sum_{avg-nas}$ = průměrné množství nasolabiálních rýh, $ssd_{avg-nas}$ = průměrné množství změny mezi vráskovými okny nasolabiálních rýh.



Obr. 17: Závislost směrodatné odchylky množství vrásek na jeho průměru. $sum_{avg-for}$ = průměrné množství čelních vrásek, $sum_{std-for}$ = směrodatná odchylka množství čelních vrásek.

U obou grafů je pozorovatelné, že zdraví účastníci studie se v grafech pohybují spíše v levé horní části oproti pacientům, kteří jsou lokalizováni v pravé dolní části. Nabídlo se proto udělat poměr těchto dvou dvojic parametrů pro všechny vybrané oblasti vrásek a statisticky je analyzovat. Dále si můžeme všimnout u čelních vrásek, že je mnoho lidí, kterým prakticky žádné čelní vrásky nebyly detekovány – odpovídá tomu četné množství hodnot na x-ové ose blízkých nule na Obr. 17. To bylo způsobeno tím, že vrásky nemají, nebo je překrývají vlasy.

Statistické testy odlišnosti skupin a korelací s klinickými daty včetně percepčního hodnocení vycházely statisticky významně zejména pro dva poměry parametrů $\frac{ssd_{avg}}{sum_{avg}}$ a $\frac{sum_{std}}{sum_{avg}}$ (u všech vráskových oblastí). Pro budoucí zjednodušení je budu po řadě značit jako ssd_{norm} a sum_{norm} . U samostatných parametrů nevykazovaly testy signifikantní výsledky, a proto je v následujících tabulkách neuvádím.

3.2.2. Test normality dat

Pomocí Kolmogorova-Smirnova testu jsem ověřil nulovou hypotézu, že poměry parametrů ssd_{norm} a sum_{norm} pochází z normální distribuce oproti alternativní hypotéze, že z normální distribuce nepochází. V Tab. 2 jsou uvedeny výsledky testování nulové hypotézy h na hladině významnosti 5 % včetně hodnot p , kritických hodnot testu cv a statistických hodnot testu d .

Poměr parametrů	Oblast vrásek	HC ($cv \doteq 0,153$)			PN ($cv \doteq 0,137$)		
		h	p	d	h	p	d
ssd_{norm}	čelní	0	> 0,1	0,138	0	> 0,1	0,120
	nasolabiální	0	> 0,1	0,082	0	> 0,1	0,083
	glabelární	0	> 0,1	0,137	1	< 0,05	0,165
sum_{norm}	čelní	1	< 0,001	0,222	1	< 0,001	0,228
	nasolabiální	0	> 0,1	0,111	1	< 0,05	0,138
	glabelární	1	< 0,05	0,161	0	> 0,1	0,096

Tab. 2: Kolmogorovův-Smirnovův test pro poměry parametrů, nulové hypotézy testovány na hladině významnosti 5 %. ssd_{norm} odpovídá změně vrásek mezi snímky a sum_{norm} odpovídá změně množství vrásek na jednotlivých snímcích. HC = zdravá kontrola, PN = pacient, h = výsledek testování nulové hypotézy, p = hodnota p , d = statistická hodnota testu, cv = kritická hodnota.

Pro testování odlišnosti jsem parametrický t-test mohl provést tedy pouze pro poměr ssd_{norm} u čelních vrásek a nasolabiálních rýh. U ostatních skupin jsem provedl namísto něj neparametrický Wilcoxonův rank sum test. Pro Pearsonovu korelaci jsem mohl použít stejné poměry jako pro parametrický t-test včetně poměru std_{norm} u glabelárních vrásek, protože zde nulová hypotéza nebyla zamítnuta. U zbylých třech poměrů parametrů jsem využil Spearmanovu korelaci.

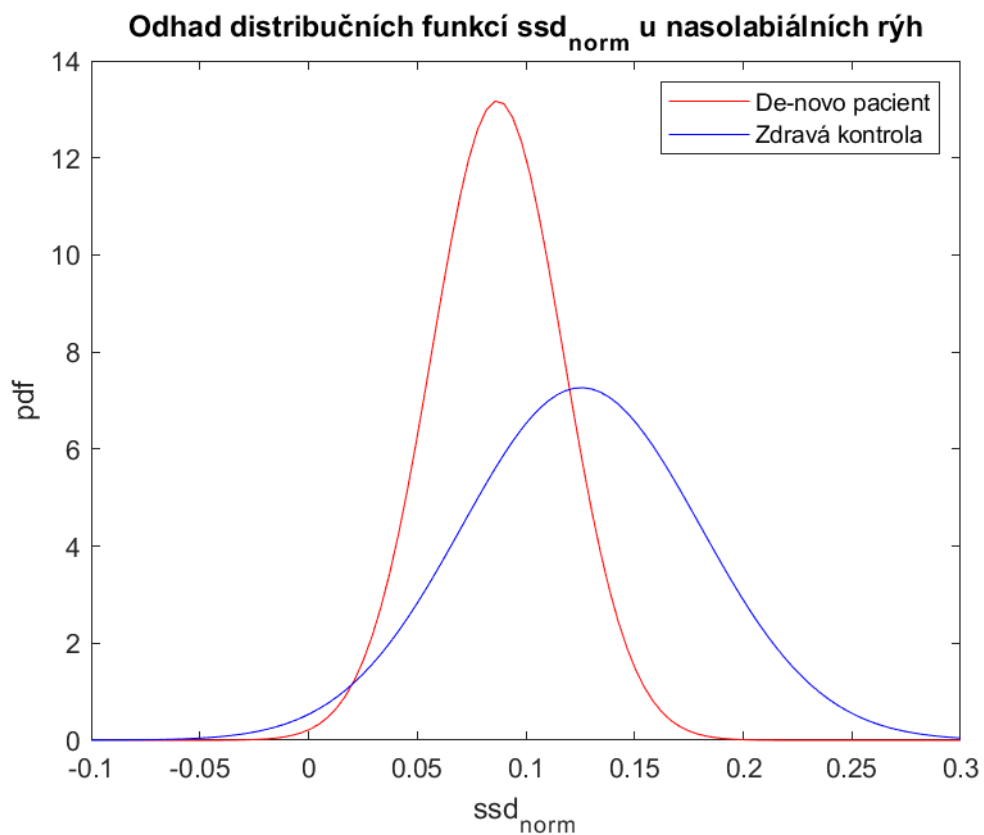
3.2.3. Test odlišnosti skupin

Pro poměry parametrů s normálním rozdělením jsem testoval nulovou hypotézu, že data pacientů a zdravých kontrol pocházejí ze stejného normálního rozdělení oproti alternativní hypotéze, že pocházejí z jiných rozdělení. Pokud je tedy nulová hypotéza zamítnuta, znamená to, že se získaná data od podskupin signifikantně liší. Výsledky testů h včetně hladiny hodnot p , t hodnoty testu a parametrů odhadovaných rozdělení jsou uvedeny v Tab. 3.

Poměr parametrů	Oblast vrásek	μ_{HC}	σ_{HC}	μ_{PN}	σ_{PN}	h	p	$t(170)$
ssd_{norm}	čelní	0,21	0,13	0,15	0,11	1	<0,01	-3,15
	nasolabiální	0,13	0,06	0,09	0,03	1	<0,001	-5,87

Tab. 3: Výsledky parametrického t-testu rozdělení setů zdravých kontrol a pacientů. ssd_{norm} odpovídá změně vrásek mezi snímky. PN značí pacienty, HC zdravé kontroly, μ = průměr vzorku, σ = směrodatná odchylka vzorku, h = výsledek testování nulové hypotézy, p = hodnota testu p , t = statistická hodnota testu, 170 = zaokrouhlená hodnota počtu stupňů volnosti.

Graf odhadovaných normálních rozdělení za pomoci maximální věrohodnosti lépe ukazuje odlišnost rozdělení pro nasolabiální rýhy, vykreslen je na Obr. 18.



Obr. 18: Odhad distribučních funkcí ssd_{norm} pro pacienty a zdravé kontroly. ssd_{norm} = normalizovaný součet druhých mocnin rozdílů vráskových snímků, pdf = hustota pravděpodobnosti.

U ostatních skupin jsem využil nepárový Wilcoxonův rank sum test. Nulová hypotéza předpokládá, že naše dvě skupiny jsou vzorky ze spojitých rozdělení se stejným mediánem proti alternativní hypotéze, že nejsou. Výsledek zamítnutí hypotézy má stejný důsledek jako v předešlém případě. Výsledky Wilcoxonova testu h jsou uvedeny včetně hladin hodnoty p a statistické hodnoty testu z v Tab. 4.

Poměr parametrů	Oblast vrásek	h	p	z
ssd_{norm}	glabelární	1	<0,001	-3,61
std_{norm}	čelní	1	<0,001	-5,46
	nasolabiální	1	<0,01	-2,74
	glabelární	1	<0,05	-2,30

Tab. 4: Výsledky Wilcoxonova testu pro neparametrické veličiny. h = výsledek testu, p = p hodnota testu, z statistická hodnota testu. ssd_{norm} = normalizovaný součet druhých mocnin vráskových snímků, std_{norm} = normalizovaná směrodatná odchylka množství vrásek.

3.2.4. Korelace parametrů s percepčním hodnocením a klinickými daty

Mezi percepčním hodnocením pacientů a samotnými parametry nebyly nalezeny žádné výrazné korelace, stejně tak jako mezi percepčním hodnocením a poměry parametrů ssd_{norm} pro jakékoliv vráskové oblasti. Významné korelace ale byly nalezeny mezi percepčním hodnocením pacientů a poměry parametrů std_{norm} a sice pro všechny oblasti vrásek. U glabelárních vrásek jsme využili vzhledem k testům normality Pearsonovu korelaci, u čelních vrásek a nasolabiálních rýh Spearmanovu korelaci. Hodnoty korelací r a hladiny hodnot p s percepčním hodnocením pacientů jsou zaneseny v Tab. 5.

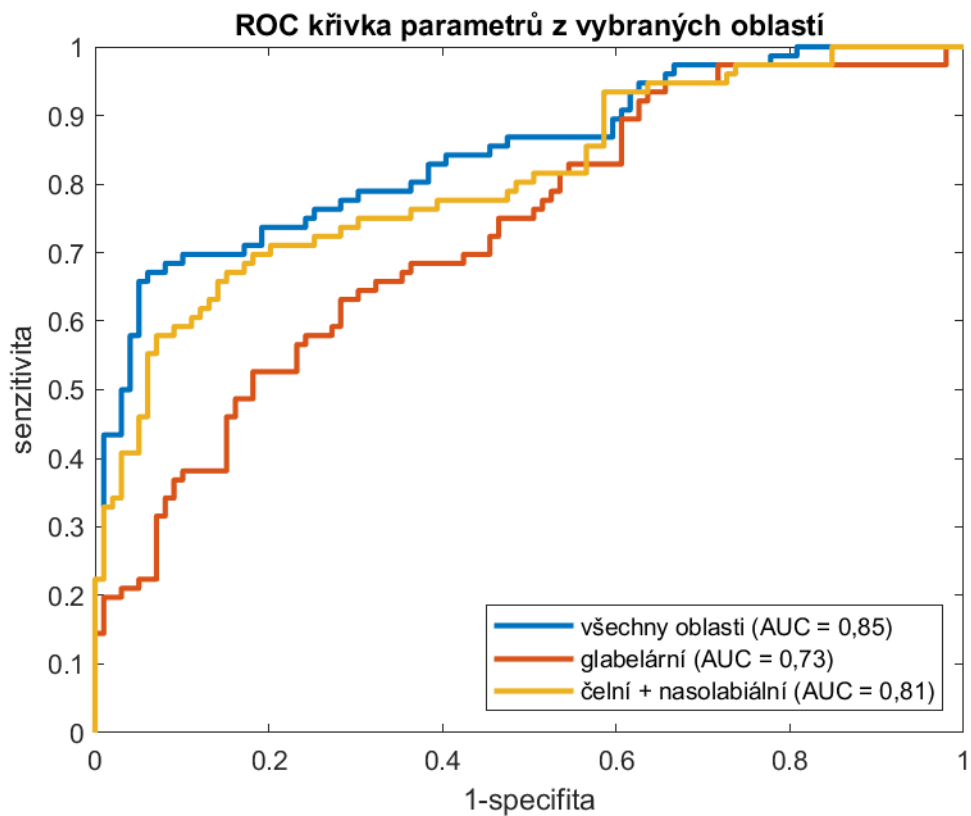
Poměr parametrů	Oblast vrásek	r	p
std_{norm}	čelní	-0,25	<0,05
	nasolabiální	-0,25	<0,05
	glabelární	-0,42	<0,001

Tab. 5: Výsledky Pearsonovy korelace pro std_{norm} s percepčním hodnocením pro glabelární vrásky a Spearmanovy korelace pro čelní vrásky a nasolabiální rýhy. r = síla korelace, p = p hodnota korelace

Mezi klinickými daty a parametry ani jejich poměry nebyly nalezeny žádné významné korelace.

3.2.5. Klasifikace zdravých kontrol a pacientů

ROC křivka modelu logistické regrese parametrů ssd_{avg} , sum_{std} a sum_{avg} pro vybrané oblasti vrásek je zanesena na Obr. 19. Tab. 6 poskytuje seznam vypočítaných AUC pro všechny možné kombinace oblastí. Tab. 6 rovněž uvádí výsledky analýzy přesnosti, senzitivity a specifity klasifikátoru hodnocené pomocí LOSO.



Obr. 19: ROC křivka logistické regrese parametrů z vybraných oblastí. AUC = plocha pod ROC křivkou

Oblast	AUC	ACC	SENZ	SPEC
čelní	0,75	0,66	0,65	0,68
nasolabiální	0,74	0,70	0,68	0,76
glabelární	0,73	0,64	0,63	0,67
čelní + nasolabiální	0,81	0,73	0,72	0,75
nasolabiální + glabelární	0,78	0,73	0,71	0,77
glabelární + čelní	0,81	0,72	0,70	0,76
všechny	0,85	0,77	0,78	0,77

Tab. 6: Porovnání klasifikace de-novo pacient/zdravá kontrola pomocí logistické regrese parametrů z možných kombinací oblastí vrásek. AUC = plocha pod ROC křivkou, ACC = přesnost, SENZ = senzitivita, SPEC = specifita.

4. Diskuse

4.1. Předzpracování

Pro předzpracování jsem zvolil otáčení obličejů tak, aby spojnice očí byla vodorovná a zároveň osa obličeje byla svislá. Toto vcelku jednoduché řešení fungovalo velmi dobře pro kompenzaci naklání hlavy, nicméně její otáčení nahoru, dolů nebo do stran kompenzováno nebylo.

4.2. Segmentace

Lokalizace nasolabiálních a glabelárních oblastí pomocí významných bodů tváře spolehlivě lokalizovala vrásky. Vzhledem k tomu, že významné body na čele končily u obočí, byl zde problém zvolit výšku okna. Tu jsme nakonec zvolili jako třetinu jeho šířky, avšak občas okno zasahovalo do vlasů, naopak někdy jsme ztratili data nezachycením celé oblasti čela. V této části segmentace je jistě prostor pro vylepšení.

Velkou nevýhodou zde prezentované segmentace je značný pohyb významných bodů na obličejí v průběhu videa, což může způsobit falešný pohyb detekovaných vrásek. To však nejspíše lze kompenzovat klouzavým průměrováním významných bodů, či dokonce průměrováním otáčených obličejů na sebe.

4.3. Výběr filtru a pofiltrační úpravy

Jednoznačně nejvhodnější se pro detekci vrásek z dostupných algoritmů ukázal Frangiho filtr. Vzhledem k možnosti volby směru detekce vrásek a přesnosti detekovaných vrásek oproti ostatním algoritmům nebylo těžké ho vybrat. Občas detekoval vrásky dokonce přesněji než člověk, který má tendenci si segmenty spojovat do linií, které tam ale ve skutečnosti jsou. Vyfiltrované hodnoty reagovaly i na hloubku vrásek. Pro vylepšení je možnost zkusit implementovat složitější algoritmy, které nebyly dostupné.

Jednoduché úpravy významně pomohly k výraznému snížení falešné detekce vrásek ve všech třech oblastech. Změna velikosti oken detekovaných vrásek sice mohla přinést informační zkreslení, ale sjednotila jednotlivé účastníky studie mezi sebou a umožnila dělat mezisnímkové rozdíly.

4.4. Výběr parametrů

Výběr tří parametrů (ssd_{avg} , sum_{std} a sum_{avg}) pro každou vráskovou oblast proběhl intuitivně. Myšlenkou pro výběr těchto parametrů byla ta, že sum_{std} bude odpovídat vzniku a zániku vrásek při mimice, ssd_{avg} bude odpovídat pohybování vrásek po tváři. sum_{avg} pak mělo kompenzovat

základní množství vrásek u každého člověka. Ukázalo se, že všechny parametry byly v různých částech informačně významné.

4.5. Výsledky analýzy parametrů

Parametry samy o sobě nebyly rozdílné pro pacienty ani zdravé kontroly, zajímavě se jevily poměry ssd_{norm} a std_{norm} . Ty se lišily na hladině významnosti alespoň 5 % pro všechny oblasti. Nejvíce se lišil poměr ssd_{norm} pro nasolabiální rýhy a std_{norm} pro čelní vrásky u zdravých kontrol a pacientů, a to na hladině významnosti menší jak 0,1 %.

Korelace s klinickými daty nebyla statisticky významná a získané parametry ani jejich poměry nesouvisí s daty získanými z klinických testů. Lépe vyšlo percepční hodnocení, které významně korelovalo s poměrem std_{norm} u všech tří oblastí. Největší korelace překvapivě byla získána u glabelárních vrásek, které tak dobře neodlišovaly zdravé kontroly od pacientů. Hodnota korelací vyšla u glabelárních vrásek $r = -0,42$ a zbývajících $r = -0,25$. Záporné znaménko je způsobeno tím, že menší pohyb vrásek odpovídá většímu skóre postižení.

Pro klasifikaci pacientů jsem nejdříve využil logistickou regresi parametrů ze všech kombinací oblastí. Nejlépe klasifikovalo použití všech devíti parametrů (AUC = 0,85; ACC = 0,77). Z jednotlivých oblastí ke klasifikaci nejvýznamněji přispívala oblast nasolabiálních rýh (AUC = 0,74; ACC = 0,70).

4.6. Limitace a další kroky

Největší problém detekce zde prezentovaného postupu je nedokonalá návaznost segmentů jednotlivých snímků na sebe, což může vyvolávat falešný domnělý pohyb vrásek. Další nevýhodou automatizovaného přístupu k detekci je informační šum způsobený označení pramínek vlasů, které měly vodorovný a šikmý směr, směřujících přes čelo jako vrásky; a také četný sestřih s ofinou, který sice jako vrásky detekován nebyl, ale vrásky zakryl. Mezi větší limitace patří ještě špatná kompenzace otáčení hlavy. Drobným nedostatkem je nutnost kompenzace snímkovací frekvence a velikosti rozlišení pro případné opakování experimentu. Pokud by se v budoucnu podařilo tyto nedostatky vylepšit, mohly by být výsledky automatické detekce výrazně lepší.

5. Splnění zadaných cílů

- **Seznamte se s problematikou hypomimie u Parkinsonovy nemoci a metodami automatické analýzy obličejové mimiky**

K obou tématům jsem provedl rešerši. Hypomimie u Parkinsonovy nemoci je velmi dobře popsáný fenomén. Pro účely této práce není vhodná analýza obličejové mimiky dostupná, protože aktuální vědecké práce se spíše zabývají simulací mimiky.

- **Na základě dostupné literatury nastudujte vhodné metody pro parametrizaci hypomimie pomocí obličejových vrásek u pacientů trpících Parkinsonovou nemocí**

V dostupné literatuře jsem nenašel články hodnotící hypomimii na základě vrásek, dosavadní práce využívaly hlavně polohu významných bodů obličeje. Proto jsem parametry hodnotící hypomimii na základě vrásek navrhl sám.

- **Porovnejte dostupné automatické hodnocení obličejových vrásek z videozáznamů na volné téma.**

Vyhodnocovat vrásky je dle dostupné literatury možno více způsoby. Pro detekci vrásek jsem zvolil tři oblasti a hodnoty zvrásnění kůže v dané oblasti jsem získával dostupným Frangiho filtrem [36], který se pro tento účel ukázal nejvhodnější. Bylo navíc nutné vymyslet podetekční úpravy k potlačení falešně detekovaných vrásek. Ze všech oblastí jsem pro každou osobu účastníci se studie vypočítal celkem devět parametrů.

- **S pomocí navržených metod proveďte vhodné statistické analýzy a vyhodnoťte nejvhodnější parametry pro popis hypomimie způsobené Parkinsonovou nemocí.**

Nejprve jsem ověřil Kolmogorovým-Smirnovým testem, které významné parametry a jejich poměry vykazují normální rozdělení. Dále jsem hledal odlišnosti parametrů a jejich poměrů u normálních rozdělení parametrickými testy a u nenormálních rozdělení neparametrickými testy. Na hladině významnosti menší jak 0,1 % se lišily dva poměry parametrů, jeden z nasolabiálních rýh a jeden z čelních vrásek.

Dále jsem u parametrických veličin prováděl Pearsonovu korelaci a neparametrických Spearmanovu s percepčním hodnocením a klinickými daty. S klinickými daty nekorelovaly parametry z žádné oblasti vrásek, s percepčním hodnocením naopak jeden poměr parametrů ze všech oblastí, s tím, že nejvýznamnější byla korelace u glabelárních vrásek.

Nakonec jsem zkoušel klasifikovat za pomoci získaných parametrů, kde u kombinace všech byla získána přesnost 0,77 a nejdůležitější se ukázaly informace z nasolabiálních rýh.

6. Závěr

Cílem bakalářské práce bylo především vytvořit automatizované hodnocení hypomimie z videí monologů pacientů a zdravých kontrol na volné téma pomocí detekce vrásek. Jako nejrobustnější dostupný detektor vrásek se ukázal Frangiho filtr.

Vrásky detekované ze tří oblastí se prokazatelně chovaly u de-novo diagnostikovaných pacientů a zdravých kontrol odlišně, konkrétně vykazovaly menší pohyb oproti jejich celkovému množství, což odpovídá literatuře. Souvislost s klinickými daty nalezena nebyla, ale byla zde signifikantní korelace s percepčním hodnocením. Díky tomu se dal sestrojít klasifikátor pouze na základě pohybu vrásek s přesností 0,77.

Největší problémy zde prezentovaného přístupu jsou především nedokonalá segmentace a vliv šumu z vlasů a obočí, což mohou být oblasti pro další vylepšení.

Automatizovaná detekce vrásek by tedy mohla přispět k dřívějšímu odhalení pacientů s Parkinsonovou nemocí, což může být zásadní pro hlubší pochopení nemoci a případné vyvinutí léčby.

7. Zdroje

- [1] W. Poewe *et al.*, “Parkinson disease,” *Nat. Rev. Dis. Prim.*, vol. 3, no. 1, pp. 1–21, Mar. 2017, doi: 10.1038/nrdp.2017.13.
- [2] D. Snead and D. Eliezer, “Alpha-Synuclein Function and Dysfunction on Cellular Membranes,” *Exp. Neurobiol.*, vol. 23, no. 4, pp. 292–313, Dec. 2014, doi: 10.5607/en.2014.23.4.292.
- [3] A. J. Granger, N. Mulder, A. Saunders, and B. L. Sabatini, “Cotransmission of acetylcholine and GABA,” *Neuropharmacology*, vol. 100. Elsevier Ltd, pp. 40–46, Jan. 01, 2016. doi: 10.1016/j.neuropharm.2015.07.031.
- [4] A. M. Graybiel, “The Basal ganglia,” *Current Biology*, vol. 10, no. 14. Current Biology Ltd, Jul. 13, 2000. doi: 10.1016/S0960-9822(00)00593-5.
- [5] “Wiring diagram basal ganglia hyperdirect, direct and indirect pathways.... | Download Scientific Diagram.” https://www.researchgate.net/figure/Wiring-diagram-basal-ganglia-hyperdirect-direct-and-indirect-pathways-Hyperdirect_fig1_323209219 (accessed May 07, 2022).
- [6] J. Jankovic, “Parkinson’s disease: Clinical features and diagnosis,” *Journal of Neurology, Neurosurgery and Psychiatry*, vol. 79, no. 4. BMJ Publishing Group, pp. 368–376, Apr. 01, 2008. doi: 10.1136/jnnp.2007.131045.
- [7] B. S. Freeze, A. V Kravitz, N. Hammack, J. D. Berke, and A. C. Kreitzer, “Control of Basal Ganglia Output by Direct and Indirect Pathway Projection Neurons,” *Soc Neurosci.*, 2013, doi: 10.1523/JNEUROSCI.1278-13.2013.
- [8] M. M. McGregor and A. B. Nelson, “Circuit Mechanisms of Parkinson’s Disease,” *Neuron*, vol. 101, no. 6. Cell Press, pp. 1042–1056, Mar. 20, 2019. doi: 10.1016/j.neuron.2019.03.004.
- [9] R. B. Postuma *et al.*, “MDS clinical diagnostic criteria for Parkinson’s disease,” *Movement Disorders*, vol. 30, no. 12. John Wiley and Sons Inc, pp. 1591–1601, Oct. 01, 2015. doi: 10.1002/mds.26424.
- [10] A. B. dos Santos, G. E. Barreto, and K. A. Kohlmeier, “Treatment of sleeping disorders should be considered in clinical management of Parkinson’s disease,” *Front. Aging Neurosci.*, vol. 6, no. OCT, p. 273, Oct. 2014, doi: 10.3389/fnagi.2014.00273.
- [11] A. C. Lajoie, A. L. Lafontaine, and M. Kaminska, “The Spectrum of Sleep Disorders in Parkinson Disease: A Review,” *Chest*, vol. 159, no. 2. Elsevier Inc., pp. 818–827, Feb.

- 01, 2021. doi: 10.1016/j.chest.2020.09.099.
- [12] M. Bologna, G. Fabbrini, L. Marsili, G. Defazio, P. D. Thompson, and A. Berardelli, “Facial bradykinesia,” *Journal of Neurology, Neurosurgery and Psychiatry*, vol. 84, no. 6. BMJ Publishing Group, pp. 681–685, 2013. doi: 10.1136/jnnp-2012-303993.
- [13] J. R. Orozco-Arroyave *et al.*, “Automatic detection of Parkinson’s disease in running speech spoken in three different languages,” *J. Acoust. Soc. Am.*, vol. 139, no. 1, pp. 481–500, Jan. 2016, doi: 10.1121/1.4939739.
- [14] M. Novotný, J. Rusz, ... R. Č.-I. T., and undefined 2014, “Automatic evaluation of articulatory disorders in Parkinson’s disease,” *ieeexplore.ieee.org*, Accessed: May 10, 2022. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/6827910/>
- [15] J. Vásquez-Correa, ... J. O.-A.-J. of, and undefined 2018, “Towards an automatic evaluation of the dysarthria level of patients with Parkinson’s disease,” *Elsevier*, Accessed: May 10, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S002199241730076X>
- [16] A. Grammatikopoulou, N. Grammalidis, S. Bostantjopoulou, and Z. Katsarou, “Detecting Hypomimia Symptoms By Selfie Photo Analysis,” *dl.acm.org*, pp. 517–522, Jun. 2019, doi: 10.1145/3316782.3322756.
- [17] S. Argaud, M. Vérin, P. Sauleau, and D. Grandjean, “Facial emotion recognition in Parkinson’s disease: A review and new hypotheses,” *Movement Disorders*, vol. 33, no. 4. John Wiley and Sons Inc., pp. 554–567, Apr. 01, 2018. doi: 10.1002/mds.27305.
- [18] M. Rajnoha, J. Mekyska, ... R. B.-... C. on U., and undefined 2018, “Towards identification of hypomimia in Parkinson’s disease based on face recognition methods,” *ieeexplore.ieee.org*, Accessed: May 10, 2022. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/8631249/>
- [19] G. Lemperle, R. E. Holmes, S. R. Cohen, and S. M. Lemperle, “Cosmetic A Classification of Facial Wrinkles,” 2015. Accessed: May 08, 2022. [Online]. Available: <https://escholarship.org/content/qt5367f9z0/qt5367f9z0.pdf>
- [20] A. Mawale and A. Chaugule, “Facial Wrinkles Detection Techniques and its Application,” 2016. Accessed: May 08, 2022. [Online]. Available: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.735.7016&rep=rep1&type=pdf>
- [21] K. Luu, T. D. Bui, C. Y. Suen, and K. Ricanek, “Combined local and holistic facial

- features for age-determination,” in *11th International Conference on Control, Automation, Robotics and Vision, ICARCV 2010*, 2010, pp. 900–904. doi: 10.1109/ICARCV.2010.5707910.
- [22] R. C. Gonzalez and R. E. Woods, “Digital Image Processing Second Edition Education 2012 MSU LIBRARY,” 2009.
- [23] S. Choi, Y. Lee, S. Lee, K. Park, J. K.-P. recognition, and undefined 2011, “Age estimation using a hierarchical classifier based on global and local facial features,” *Elsevier*, Accessed: May 08, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0031320310005704>
- [24] V. Prasad, J. D.-J. A. Sci, and undefined 2005, “Gabor filter visualization,” *academia.edu*, Accessed: May 08, 2022. [Online]. Available: <https://www.academia.edu/download/47726591/report.pdf>
- [25] C. Ng, M. Yap, N. Costen, ... B. L.-I. C. on, and undefined 2014, “An investigation on local wrinkle-based extractor of age estimation,” *ieeexplore.ieee.org*, Accessed: May 08, 2022. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/7294873/>
- [26] J. Hayashi, M. Yasumoto, ... H. I.-... supported by user, and undefined 2002, “Age and gender estimation based on wrinkle texture and color of facial images,” *ieeexplore.ieee.org*, Accessed: May 08, 2022. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/1044736/>
- [27] N. Batool and R. Chellappa, “Modeling and detection of wrinkles in aging human faces using marked point processes,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2012, vol. 7584 LNCS, no. PART 2, pp. 178–188. doi: 10.1007/978-3-642-33868-7_18.
- [28] S. G. Jeong, Y. Tarabalka, and J. Zerubia, “Marked point process model for facial wrinkle detection,” in *2014 IEEE International Conference on Image Processing, ICIP 2014*, Jan. 2014, pp. 1391–1394. doi: 10.1109/ICIP.2014.7025278.
- [29] N. Batool, R. C.-2012 19th I. International, and undefined 2012, “A Markov point process model for wrinkles in human faces,” *ieeexplore.ieee.org*, Accessed: May 09, 2022. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/6467233/>
- [30] A. F. Frangi, W. J. Niessen, K. L. Vincken, and M. A. Viergever, “Multiscale vessel enhancement filtering,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1998, vol. 1496, pp. 130–137. doi: 10.1007/bfb0056195.

- [31] C. C. Ng, M. H. Yap, N. Costen, and B. Li, “Automatic wrinkle detection using hybrid Hessian filter,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2015, vol. 9005, pp. 609–622. doi: 10.1007/978-3-319-16811-1_40.
- [32] C. Ng, M. Yap, N. Costen, B. L.-I. Access, and undefined 2015, “Wrinkle detection using hessian line tracking,” *ieeexplore.ieee.org*, Accessed: May 10, 2022. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/7155483/>
- [33] A. Bulat and G. Tzimiropoulos, “How far are we from solving the 2D & 3D Face Alignment problem? (and a dataset of 230,000 3D facial landmarks).” Accessed: May 10, 2022. [Online]. Available: www.adrianbulat.com/face-alignment/
- [34] “68 facial landmarks. | Download Scientific Diagram.” https://www.researchgate.net/figure/68-facial-landmarks_fig1_338048224 (accessed May 17, 2022).
- [35] C. G. Goetz *et al.*, “Movement Disorder Society-sponsored revision of the Unified Parkinson’s Disease Rating Scale (MDS-UPDRS): Scale presentation and clinimetric testing results,” *Mov. Disord.*, vol. 23, no. 15, pp. 2129–2170, Nov. 2008, doi: 10.1002/mds.22340.
- [36] D.-J. Kroon, “Hessian based Frangi Vesselness filter (<https://www.mathworks.com/matlabcentral/fileexchange/24409-hessian-based-frangi-vesselness-filter>), MATLAB Central File Exchange. Retrieved May 10, 2022.”
- [37] G. I. Webb *et al.*, “Leave-One-Out Cross-Validation,” in *Encyclopedia of Machine Learning*, Springer US, 2011, pp. 600–601. doi: 10.1007/978-0-387-30164-8_469.