



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV TELEKOMUNIKACÍ

DEPARTMENT OF TELECOMMUNICATIONS

ANALÝZA GRAFOMOTORICKÝCH OBTÍŽÍ POMOCÍ METOD STROJOVÉHO UČENÍ

ANALYSIS OF GRAPHOMOTOR DIFFICULTIES USING MACHINE LEARNING METHODS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Tomáš Maňásek

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Ján Mucha, Ph.D.

BRNO 2025



Diplomová práce

magisterský navazující studijní program **Telekomunikační a informační technika**

Ústav telekomunikací

Student: Bc. Tomáš Maňásek

ID: 221283

Ročník: 2

Akademický rok: 2024/25

NÁZEV TÉMATU:

Analýza grafomotorických obtíží pomocí metod strojového učení

POKYNY PRO VYPRACOVÁNÍ:

Cílem práce je výzkum nových pokročilých kinematických parametrů sloužících k analýze grafomotorických obtíží. Analyzován bude ručně psaný projev reprezentovaný časovými řadami (online písmo) získaný pomocí digitalizačního tabletu u pacientů s Parkinsonovou nemocí a dětí s vývojovou dysgrafií. Výzkum nových metod bude zaměřen na použití derivací neceločíselného řádu k extrakci kinematických parametrů. Parametry budou evaluovány pomocí metod strojového učení (klasifikace/regrese) a statistické analýzy.

DOPORUČENÁ LITERATURA:

- [1] MUCHA, J., et al. Identification and monitoring of Parkinson's disease dysgraphia based on fractional-order derivatives of online handwriting. Applied Sciences, 2018, 8.12: 2566.
- [2] MEKYSKA, J. et al. 'Graphomotor and Handwriting Disabilities Rating Scale (GHDRS): towards complex and objective assessment, Australian Journal of Learning Difficulties, 29(1), pp. 1–34. doi: 10.1080/19404158.2024.2326686.

Termín zadání: 10.2.2025

Termín odevzdání: 27.5.2025

Vedoucí práce: Ing. Ján Mucha, Ph.D.

prof. Ing. Jiří Mišurec, CSc.
předseda rady studijního programu

UPOZORNĚNÍ:

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

ABSTRAKT

Cílem práce byl výzkum nových pokročilých kinematických parametrů určených k analýze grafomotorických obtíží. Analyzován byl ručně psaný projev reprezentovaný časovými řadami (online písmo), získaný pomocí digitalizačního tabletu u pacientů s Parkinsonovou nemocí. Výzkum se zaměřil na využití derivací neceločíselného řádu pro extrakci kinematických parametrů. Tyto parametry byly evaluovány pomocí metod strojového učení a statistické analýzy.

V teoretické části práce byla nastudována problematika grafomotorických obtíží u pacientů s Parkinsonovou nemocí a dětí s vývojovou dysgrafií. Dále bylo seznámeno s online písmem, neceločíselným kalkulem, metodami strojového učení a jejich využití za účelem diagnostiky grafomotorických potíží. Poslední krok teoretické části byl návrh nových kinematických parametrů založených na neceločíselných derivacích.

V praktické části byly tyto parametry extrahovány ze vzorků online písma obsažených v databázi rukopisů pacientů s Parkinsonovou nemocí (PaHaW) a použity k trénování klasifikačního modelu strojového učení metodou XGBoost. Následně byly parametry evaluovány na základě výsledků Pearsonovy korelační analýzy, podle výkonu modelů, které jimi byly natrénovány a jejich užitečnosti v těchto modelech. Nakonec byly podle těchto metrik porovnány se stávajícími kinematickými parametry.

Korelační analýza odhalila silnou souvislost mezi nově navrženými parametry založenými na časové paměti (Temporal Memory Index, TMI) a statusem onemocnění. Nejsilnější parametr vykazoval pozitivní Pearsonovu korelaci 0,45 a p-hodnoty po úpravě metodou FDR (False Discovery Rate) v řádu tisícín. Nejlepší klasifikační model dosáhl vyvážené přesnosti 0,79, citlivosti 0,77 a specifity 0,78.

KLÍČOVÁ SLOVA

grafomotorické obtíže, Parkinsonova nemoc, vývojová dysgrafie, online písmo, neceločíselný kalkulus, derivace neceločíselného řádu, strojové učení, XGBoost

ABSTRACT

The aim of this thesis was to explore new advanced kinematic features for the analysis of graphomotor difficulties. The analysis focused on handwritten output represented by time series (online handwriting) acquired using a digitizing tablet from patients with Parkinson's disease. The research concentrated on the use of fractional-order derivatives for the extraction of kinematic parameters. These parameters were evaluated using machine learning methods and statistical analysis.

The theoretical part of the thesis introduces the issue of graphomotor difficulties in patients with Parkinson's disease and in children with developmental dysgraphia. It also presents the concept of online handwriting, fractional calculus, machine learning methods, and their application in the diagnosis of graphomotor impairments. The final section of the theoretical part proposes novel kinematic parameters based on fractional derivatives.

In the practical part, these parameters were extracted from samples of online handwriting contained in the PaHaW dataset of Parkinson's disease patients and used to train a machine learning classification model using the XGBoost algorithm. The parameters were then evaluated based on the results of Pearson correlation analysis, the performance of the models trained on them, and their usefulness within these models. Finally, they were compared to existing kinematic parameters according to these metrics.

Correlation analysis revealed a strong relationship between the newly proposed parameters based on temporal memory (Temporal Memory Index, TMI) and disease status. The strongest parameter exhibited a positive Pearson correlation of 0.45 and p-values adjusted using the FDR (False Discovery Rate) method in the order of thousandths. The best classification model achieved a balanced accuracy of 0.79, sensitivity of 0.77, and specificity of 0.78.

KEYWORDS

graphomotor difficulties, Parkinson's disease, developmental dysgraphia, online handwriting, fractional calculus, fractional order derivatives, machine learning, XGBoost

MAŇÁSEK, Tomáš. *Analýza grafomotorických obtíží pomocí metod strojového učení*. Diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací, 2025. Vedoucí práce: Ing. Ján Mucha, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora:	Bc. Tomáš Maňásek
VUT ID autora:	221283
Typ práce:	Diplomová práce
Akademický rok:	2024/25
Téma závěrečné práce:	Analýza grafomotorických obtíží pomocí metod strojového učení

Prohlašuji, že svou závěrečnou práci jsem vypracoval samostatně pod vedením vedoucí/ho závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora*

*Autor podepisuje pouze v tištěné verzi.

Prohlášení o využití generativní umělé inteligence

Čestně prohlašuji, že jsem při zpracování této diplomové práce využil nástroje generativní umělé inteligence (AI). Toto využití, jeho rozsah a účel byly konzultovány s vedoucím mé práce. Nástroje AI sloužily jako podpora v rámci řešení, konkrétně pro vyhledávání informací a orientaci ve zdrojích, a dále při formálních a stylistických úpravách mnou koncipovaného textu.

Veškeré informace a podněty získané s pomocí AI byly mnou kriticky posouzeny, ověřeny z dalších zdrojů a samostatně zpracovány. Finální text je mým původním dílem a neobsahuje pasáže přímo převzaté z výstupů AI.

Prohlašuji, že jsem postupoval v souladu s doporučeními VUT pro využívání generativní AI, zejména co se týče její přípustné asistenční role a zákazu přímého kopírování výstupů. Nesou plnou odpovědnost za obsah, původnost a kvalitu odevzané práce.

Brno

.....

podpis autora*

*Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu diplomové práce panu Ing. Ján Mucha, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	13
1 Grafomotorické potíže (GP)	14
1.1 GP u pacientů s Parkinsonovou nemocí (PD)	14
1.2 GP u dětí s vývojovou dysgrafií VD	15
1.3 Diagnostika grafomotorických potíží u PD/VD	15
2 Online písmo a jeho akvizice	17
2.1 Digitalizační tablet	18
2.1.1 Wacom	18
3 Základní parametry	20
3.1 Kinematické parametry	20
3.2 Statistické charakteristiky	21
4 Derivace neceločíselného řádu	23
4.1 Grünwald–Letnikov	23
4.2 Riemann–Liouville	24
4.3 Caputo	24
5 Metody strojového učení pro analýzu GP	26
5.1 Random Forest (RF)	26
5.2 XGBoost	26
5.3 AdaBoost	27
5.4 Support Vector Machine (SVM)	28
5.5 Konvoluční neuronové sítě (CNN)	29
6 Návrh nových kinematických parametrů založených na FD	30
6.1 FD kinematických parametrů o neceločíselných řádech vyššího rozlišení	30
6.2 Temporal Memory Index (TMI)	30
6.3 Korelace řádu FD s danou funkcí	31
6.4 Entropie s pomocí FD	32
7 Dataset	34
7.1 PaHaW	34
7.2 Výběr parametrů	35
7.3 Získání parametrů	37
7.3.1 Základní kinematické	39
7.3.2 Caputo neceločíselné derivace	39

7.3.3	Temporal Memory Index (TMI)	39
7.3.4	Počet parametrů	39
7.4	Předzpracování dat	40
7.4.1	Výběr a rozdělení dat	40
7.4.2	Zahození nevhodných parametrů	40
7.4.3	Odstranění efektu kovariátů	40
8	Trénování modelu	42
8.1	Křížová validace	42
8.2	Bayesovská optimalizace hyperparametrů	42
8.3	Redukce datasetu	43
8.4	Hodnocení modelu	44
9	Výsledky	46
9.1	Přehled	46
9.2	Diskuze	52
	Závěr	54
	Literatura	55

Seznam obrázků

2.1	Vizualizace parametrů online písma.	17
2.2	Wacom Intuos 4M schéma.	19
6.1	Vliv různých řádů α na vzory vertikální rychlosti.	32
7.1	Příklad předvyplněné šablony	34
7.2	Příklady úkolů. Tahy na povrchu.	36
7.3	Příklad rozdělení vzorku na tahy.	37
7.4	Příklad rozdělení spirály na horizontální a vertikální složky.	38
9.1	Porovnání HC a PD hodnot parametru s nejlepší korelací.	53

Seznam tabulek

2.1	Příklad datového záznamu online písma.	17
8.1	Rozsahy hodnot pro ladění parametrů	43
9.1	Pět nejlepších modelů a jejich metriky.	47
9.2	Pět nejlepších modelů a jejich hyperparametry.	47
9.3	Pět nejlepších parametrů, pěti nejlepších modelů.	48
9.4	Korelace parametrů s daty. Úkol 1.	49
9.5	Korelace parametrů s daty. Úkol 3.	50
9.6	Korelace parametrů s daty. Úkol 9.	51

Úvod

Parkinsonova nemoc (PN) a vývojová dysgrafie (VD) jsou dvě poruchy, které výrazně ovlivňují schopnost jedince vykonávat běžné motorické úkoly, včetně psaní. U pacientů s Parkinsonovou nemocí dochází k postupnému zhoršování motorických funkcí, což se projevuje v grafomotorických potížích (GP). Naopak u dětí s vývojovou dysgrafií jsou GP způsobeny poruchami vývoje motorických dovedností, které mají vliv na jejich schopnost psát plynule a čitelně. Tato grafomotorická omezení mohou být klíčovým indikátorem pro diagnostiku obou poruch.

V poslední době se ve výzkumu diagnostiky pomocí GP stále více využívají metody strojového učení, které umožňují efektivní a objektivní analýzu online písma a tím pádem i detekci GP. Tato metoda přináší nové možnosti pro včasnou diagnózu a monitorování progresu nemocí, jako je PN. Jedním z odvětví tohoto výzkumu je odvětví zabývající se využitím neceločíselného kalkulu (FC), zejména derivací neceločíselného řádu (FD) k extrakci kinematických parametrů za účelem strojové analýzy. Motivace pro použití FD spočívá v jejich schopnosti modelovat složité dynamické procesy, kde tradiční metody derivace nejsou schopny zachytit všechny aspekty pohybu. FD poskytují detailnější pohled na změny v dynamice písma a umožňují efektivnější analýzu motorických funkcí, což je klíčové pro diagnostiku a hodnocení progresu PD a VD.

Cíl této práce je navázat a rozšířit výše zmíněné odvětví. První část práce má za účel nastudování problematiky PN, VD a jejich diagnostiky na základě jimi způsobenými GP. Dále seznámení s online písmem, kinematickými parametry, statistickými charakteristikami, neceločíselnými derivacemi (FD) a metodami strojového učení. To vše za účelem návrhu nových kinematických parametrů založených na FD pro jejich použití k analýze GP ze vzorků online písma získaných pomocí digitalizačního tabletu u pacientů s PN a VD. Druhá část se zabývá implementací a ověřením nových parametrů statistickými metodami a metodami strojového učení.

1 Grafomotorické potíže (GP)

Grafomotorické dovednosti jsou referovány jako kombinace plánování a provádění pohybů, vizuálně-percepčních schopností, ortografického kódování, kinestetické zpětné vazby a vizuálně-motorické koordinace [1].

GP mají negativní vliv na tyto dovednosti a mohou se projevovat různými způsoby. GP se často vyskytují u poruch, jako jsou dysgrafie, vývojová koordinační porucha nebo neurologická onemocnění, jako Parkinsonova nemoc.

1.1 GP u pacientů s Parkinsonovou nemocí (PD)

Parkinsonova nemoc (PD) je heterogenní onemocnění s rychle a pomalu postupujícími formami [4]. PD se nejčastěji vyskytuje u osob ve věku 60 let a starších. Až 10% pacientů je však diagnostikováno před 50. rokem života, přičemž muži bývají postiženi častěji než ženy [36]. V roce 2016 nemocí trpělo přibližně 6,1 milionu lidí celosvětově. Globální průzkum neurologických onemocnění ukázal, že incidence a prevalence se rychle zvyšují po celém světě. Podle Bloem et al.[8] lze zvýšenou incidenci částečně vysvětlit stárnoucí populací a zlepšující se přesností diagnostiky, mohou však existovat další externí faktory jako znečištění životního prostředí pesticidy nebo chemikáliemi, o nichž je známo, že poškozují neurony a mozkové okruhy související s PD [6].

Jde o pomalu postupující onemocnění mozku, které vede k oslabování, degeneraci a odumírání dopaminergních neuronů (druh neuronů v centrální nervové soustavě, které produkují dopamin) z důvodu patologického procesu akumulace α -synukleinu, který vede k tvorbě Lewyho tělísek a Lewyho neuritů v části mozku nazývané substantia nigra pars compacta (SNpc), jež je zodpovědná za řízení pohybů. To má za následek problémy s motorickými dovednostmi, jako je třes, ztuhlost v pažích nebo nohou či obtíže s udržením rovnováhy a dysgrafií.[26][16]

Parkinsonská dysgrafie (PDYS) označuje soubor neuromuskulárních obtíží, zahrnujících problémy s motorickou pamětí (neschopnost efektivně propojit paměťové podněty s motorickými reakcemi), grafomotorické deficity (nedostatečná koordinace svalů) a potíže se zpětnou vazbou při pohybu (například nadměrné zapojení určitých svalů a kloubů během psaní, nebo obtíže při sledování pozice hrotu pera). Tyto problémy vedou k různým obtížím s rukopisem, které se projevují jako neplynulé, roztřesené, pomalé a méně čitelné písmo, často doprovázené mikrografií (postupné zmenšování velikosti nebo šířky písmen).[30]

Bylo prokázáno, že PDYS může být použit jako významný biomarker pro diagnostiku PD [15][47]. Mikrografie je nejčastěji pozorovanou abnormálností rukopisu u pacientů s PD a může být v přibližně 5% případech pozorována dokonce ještě

před nástupem klíčových motorických symptomů, jako je bradykineze, rigidita nebo tremor [51][34].

1.2 GP u dětí s vývojovou dysgrafií VD

Během prvních tří školních let dítě typicky získává své grafomotorické dovednosti, jako je kreslení a psaní. Během tohoto období by si dítě mělo tyto dovednosti osvojit, což by mělo vést k písmu, které je čitelné, automatizované, dobře koordinované a rychlé [45]. To odráží jeho zralost a integraci jazykových, psychomotorických a mentálních schopností, stejně jako připravenost na vzdělávání[33]. I přes rozvoj moderních technologií psaní rukou stále zabírá 30–60% školního času dítěte [19].

Osvojení rukopisu hraje zásadní roli pro školní úspěch a sebevědomí dítěte. Přesto 10–30% dětí čelí grafomotorickým problémům, jako jsou špatná svalová koordinace, nepřesné pohyby, neobvyklý úchop pera, poruchy motorické paměti či zpětné vazby [19]. Tyto obtíže úzce souvisejí s VD, která je klasifikována jako vývojová porucha školních dovedností podle ICD-10[57] a specifická porucha učení podle DSM-5[3] [45]. Ve Spojených státech zákon o vzdělávání osob se zdravotním postižením (IDEA)[18] definuje „specifickou poruchu učení“ jako stav, kdy dítě buď:

- Nedosahuje odpovídajících výsledků pro svůj věk nebo požadované státní standardy v oblastech jako ústní projev, porozumění slyšenému, písemný projev, čtenářské dovednosti či matematika, i při poskytnutí vhodné podpory.
- Nedělá dostatečný pokrok v těchto oblastech při vědecky podložených intervencích nebo vykazuje vzorec silných a slabých stránek relevantní pro diagnózu poruchy. Příčinou obtíží nesmí být primárně jiné zdravotní, kulturní či ekonomické faktory nebo neznalost jazyka.

VD může vést k demotivaci, emočním problémům a obtížím v komunikaci a sociálních vztazích, což negativně ovlivňuje vzdělávací a psychologický vývoj dítěte [32].

1.3 Diagnostika grafomotorických potíží u PD/VD

Současné diagnostické metody PDYS se převážně opírají o klinické vyšetření, které zahrnuje pozorování motorických příznaků, jako je bradykineze, rigidita a třes.[54]

Diagnóza a hodnocení GP a VD jsou v současnosti převážně subjektivní, a to na základě nástrojů, jako je dotazník pro hodnocení grafomotorických dovedností (HPSQ)[44], zkrácená verze metody hodnocení dětského rukopisu (SOS: BHK)[53]


nebo měřítko čitelnosti rukopisu (HLS)[7]. Tyto nástroje slouží k hodnocení schopností psaní, ale samotný proces zůstává subjektivní a závisí na úsudku klinika, který je používá.[23]

V posledních letech se objevila řada studií zaměřených na objektivní hodnocení rukopisu s podporou strojového učení, za cílem zakomponování těchto technik do diagnostického řetězu u PD a také dětí s VD. Tento přístup byl poprvé představen v roce 2016, kdy Mekyska et al. pomocí random forest (RF) klasifikátoru dokázali rozdělit zdravé děti a děti s GP navštěvující třetí třídu s přesností přes 90% [35]. Podobně v následujícím roce Rosenblum et al. rozdělili pomocí klasifikátoru SVM (Support Vector Machine) třetíáky s přesností 90% [46].

Od té doby se popularita diagnostiky s počítačovou podporou výrazně rozvinula. Byly prozkoumány další techniky strojového učení, např. XGBoost, AdaBoost, CNN a jiné [27]. Při analýze byly zkoumány nejen základní rysy, jako je rychlost psaní, amplituda pohybu, tlak na psací nástroj, nebo doba pera ve vzduchu. V roce 2020 Galaz et al. ve své studii navrhli využít pokročilé techniky parametrizace rukopisu založené na modulačních spektrech, derivacích neceločíselného řádu a vlnkové transformaci s laditelným Q-faktorem a spojením těchto funkcí s běžně používanými dosáhli přesnosti 84% [21]. Z množství literatury vyplývá, že z těchto pokročilých způsobů parametrizace se nejvíce osvědčily parametry založené na neceločíselné derivaci.

2 Online písmo a jeho akvizice

Online písmo označuje technologii zachycování a analýzy ručně psaného textu v digitální podobě v reálném čase. Umožňuje zaznamenat nejen prostorové parametry písma, ale i kinematické, dynamické, časové a další. Tato technologie je běžně využívána na dotykových obrazovkách, tabletech a zařízeních s elektronickými pery, což umožňuje široké spektrum aplikací. Online písmo zaznamenává pohyby pera nebo stylusu na dotykové obrazovce v reálném čase. Informace o těchto pohybech jsou obvykle ukládána jako časová sekvence bodů, kde každý bod obsahuje informace o poloze v podobě x a y souřadnic, časové razítko, které označuje okamžik záznamu bodu. Některá zařízení umožňují zaznamenávat další informace jako tlak pera na povrch, náklon pera, azimut pera, vzdálenost od povrchu a jiné. V porovnání s offline písmem nabízí obecně vyšší množství informací, protože nezaznamenává pouze tvar psaného textu, ale samotný proces tvorby písma.



Obr. 2.1: Vizualizace parametrů online písma. Viz Obr. 1 v [59].

t	x	y	Tlak	Sklon	Azimut	Vzdálenost	Na povrchu
0	0	0	0	25°	110°	3	0
1	1	5	4	33°	109°	0	1
2	2	5	2	34°	109°	0	1
3	3	5	1	32°	110°	0	1
4	2	7	0	25°	111°	2	0

Tab. 2.1: Příklad datového záznamu online písma.

„t“ je časové razítko, „x“ a „y“ jsou souřadnice, „Tlak“ značí tlak pera, „Sklon“ jeho náklon vůči psací ploše, „Azimut“ , „Vzdálenost“ vzdálenost od povrchu a „Na povrchu“ jestli se pero dotýká povrchu. Jednotky jsou libovolné.

Online písmo lze získávat pomocí různých typů zařízení, jako jsou grafické a digitalizační tablety, dotykové tablety, telefony a notebooky, digitální pera a jiné.

2.1 Digitalizační tablet

Digitalizační tablet je vstupní zařízení, které převádí ručně psanou trajektorii do digitální podoby online písma. Tato trajektorie může představovat kreslenou grafiku, podpis nebo ručně psaný text.

Digitalizační tablet se obvykle skládá z elektronické podložky a pera. Tablety můžeme rozdělit na „aktivní“ a „pasivní“. U aktivních tabletů komunikuje digitální podložka s elektronickým (aktivním) perem, které obsahuje vlastní elektroniku a je nutné jej napájet. V některých případech se digitalizér skládá pouze z elektronického pera, které se používá na běžném nebo speciálním papíře. Naopak pera pasivních tabletů neobsahují žádnou elektroniku a snímání provádí pouze elektronická podložka.

Pera aktivních tabletů mohou mít buď svůj vlastní zdroj, nebo jsou napájena bezdrátově z elektronické podložky.

2.1.1 Wacom

Jedním z výrobců těchto tabletů je společnost Wacom. V této práci je zmiňována zejména proto, že záznamy online písma použité pro analýzu byly pořízeny pomocí jejího zařízení.


Wacom vyvíjí a používá dvě hlavní technologie digitálního snímání: EMR (Electro-Magnetic Resonance) a Active ES (Electrostatic) [55].

EMR (Electro-Magnetic Resonance) je charakteristická tím, že pero neobsahuje žádnou elektroniku ani baterii – napájení probíhá bezdrátově díky elektromagnetickému poli generovanému mřížkou pod povrchem tabletu. Tablet vysílá signál, který indukuje proud v cívce uvnitř pera. Ten se následně využívá ke komunikaci s tabletem. Výsledkem je vysoká přesnost, rychlá odezva a odolnost zařízení bez nutnosti pravidelného dobíjení. Technologie EMR umožňuje snímat nejen polohu pera, ale i jeho přítlak, sklon a rotaci. Vzorkovací frekvence se běžně pohybuje kolem 133 Hz a rozlišení dosahuje až 2540 lpi.

Active ES (Electrostatic) na rozdíl od EMR používá Active ES pero, které obsahuje vlastní elektroniku a vyžaduje napájení. Komunikace probíhá prostřednictvím kapacitního senzoru v tabletu, který detekuje změny v elektrickém poli při dotyku hrotu pera. Active ES umožňuje kombinovat snímání stylusu a dotykového vstupu v jedné sensorové vrstvě, což usnadňuje konstrukci zařízení, jako jsou tablety

a konvertibilní notebooky. Technologie podporuje detekci přítlaku, polohy i základních gest, přičemž zachovává nízkou spotřebu energie.

Wacom Intuos 4M je model, který byl využit k záznamu online písma analyzovaného v této práci. Jde o profesionální digitalizační tablet určený pro přesné snímání perového vstupu. Disponuje aktivní plochou o rozměrech přibližně 223,5 × 139,7 mm. Používá technologii EMR a je schopen zaznamenat až 2048 úrovní tlaku. Podporuje také snímání náklonu pera (v rozsahu $\pm 60^\circ$). Tablet je vybaven programovatelnými tlačítky (ExpressKeys) a dotykovým kolečkem (Touch Ring) pro rychlý přístup k často používaným funkcím [56].



Obr. 2.2: Wacom Intuos 4M schéma. [56]

1. Aktivní plocha
2. Stavové LED
3. Touch Ring
4. ExpressKeys
5. ExpressKeys displej

Tento model byl často využíván v oblasti digitální grafiky, ale pro své přesné snímání se osvědčil také v oblasti biometrického rozpoznávání rukopisu a výzkumu v oblasti dysgrafie [17], což je i případ této práce.

3 Základní parametry

3.1 Kinematické parametry

Kinematické parametry písma popisují pohyb psacího nástroje po papíře nebo snímací ploše bez ohledu na síly, které tento pohyb způsobují. Mezi základní kinematické parametry patří:

- **Pozice:**
 - $x[t]$ a $y[t]$: Souřadnice pozice pera v čase t ve 2D prostoru. Popisují, kde se pero nachází na psací ploše v daném čase.
- **Rychlost:**
 - Rychlost definuje změnu pozice v čase:

$$v = \frac{\Delta x}{\Delta t}, \quad v = \frac{\Delta y}{\Delta t} \quad (3.1)$$

kde Δx je změna polohy ve vodorovném směru [m], Δy je změna polohy ve svislém směru [m] a Δt je změna času [s].

- Mimo jiné poskytuje informace o plynulosti a rytmu rukopisu.
- Písmo u jedinců s grafomotorickými problémy bývá často pomalejší než písmo u zdravých. Nízká rychlost psaní tedy může naznačovat výskyt problémů s grafomotorikou. Tyto potíže často nutí jedince věnovat psaní zvýšenou pozornost.
- **Zrychlení:**
 - Míra změny rychlosti v čase:

$$a = \frac{\Delta v}{\Delta t} \quad (3.2)$$

kde Δv je změna rychlosti [$m \cdot s^{-1}$] a Δt je změna času [s].

- Zrychlení určuje změnu rychlosti v čase. Odhaluje přerušování pohybů, změny dynamiky psaní a jiné. Neplynulé zpomalení a zrychlení se častěji vyskytuje u jedinců s grafomotorickými obtížemi.
- **Trh:**
 - Míra změny zrychlení (Δa) v čase (Δt):

$$j = \frac{\Delta a}{\Delta t} \quad (3.3)$$

kde Δa je změna zrychlení [$m \cdot s^{-2}$] a Δt je změna času [s].

- Trh poskytuje informace, zda je písmo hladké, plynulé, nebo zda obsahuje náhlé ostré změny. Trhané, neplynulé písmo má zvýšený výskyt u jedinců s grafomotorickými problémy.

3.2 Statistické charakteristiky

Statistické charakteristiky těchto parametrů mohou být použity k identifikaci odchylek, které naznačují grafomotorické poruchy.

Statistické charakteristiky obecně slouží k popisu a analýze dat, zejména pro identifikaci centrální tendence, variability a dalších vlastností. Poskytují komplexní pohled na datové soubory a umožňují odhalit klíčové vlastnosti a trendy v analyzovaných hodnotách. V této práci slouží k popisu různých vypočítaných parametrů písma, za účelem další analýzy. Mezi základní statistické charakteristiky patří:

- **Průměr (Mean):**
 - *Definice:* Součet všech hodnot dělený jejich celkovým počtem.
 - Citlivý na extrémní hodnoty, ale poskytuje důležitý pohled na centrální tendenci dat.
- **Medián (Median):**
 - *Definice:* Prostřední hodnota vzestupně seřazených dat.
 - Pokud je počet hodnot lichý, medián je prostřední hodnota. Pokud je sudý, medián je průměr dvou prostředních hodnot.
- **Směrodatná odchylka (Standard Deviation):**
 - *Definice:* Míra rozptýlení hodnot v datové sadě okolo jejího průměru.
 - Vypočítává se jako odmocnina z rozptylu:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}} \quad (3.4)$$

kde x_i jsou jednotlivé hodnoty, \bar{x} je průměr a n je počet hodnot.

- Směrodatná odchylka udává, jak blízko nebo daleko jsou hodnoty od průměru – čím vyšší hodnota, tím větší rozptyl.
- **Percentil (Percentile):**
 - *Definice:* Hodnota, pod kterou leží určitá procentuální část dat.
 - Například 25. percentil označuje hodnotu, pod kterou leží 25 % dat.
- **Kvartil (Quartile):**
 - *Definice:* Kvartily dělí uspořádanou datovou sadu na čtyři stejné části, přičemž každá obsahuje 25 % dat
 - První kvartil Q_1 se rovná 25. percentilu, druhý Q_2 je roven 50. percentilu a třetí Q_3 je stejný jako 75. percentil.
- **Interkvartilové rozpětí (IQR):**
 - *Definice:* Rozdíl mezi prvním a třetím kvartilem.
 - Hodnota IQR měří šíři „středních“ 50 % dat.
 - *Vzorec:*

$$IQR = Q_3 - Q_1$$

- **Neparametrická variace (Non-Parametric Variation):**

- Zahrnuje metody, které nevyžadují žádné předpoklady o konkrétním rozdělení dat, například normálním rozdělením.
 - Typicky používá medián a IQR místo průměru a směrodatné odchylky.
 - Vhodný zejména tehdy, když data nejsou symetrická, obsahují extrémní hodnoty nebo mají neobvyklé rozdělení.
- **Počet změn (Number of Changes):**
 - *Definice:* Počet změn směru nebo chování v datové sadě.
 - Například v analýze rukopisu může znamenat počet změn směru psaní nebo počet zvednutí a položení pera.
 - Slouží k hodnocení dynamiky a variability dat, zejména v časových řadách.

4 Derivace neceločíslného řádu

Obecně spadají neceločíslné derivace (FD) do oblasti neceločíslného počtu (fractional calculus, FC), což je teorie integrálů a derivací libovolného řádu [43]. Koncept neceločíslných operátorů vznikl téměř současně s vývojem klasického diferenciálního a integrálního počtu [28] a přitáhl pozornost mnoha významných matematiků, jako byli Euler, Liouville, Laplace, Riemann, Grünwald a Letnikov. Principy neceločíslného počtu našly uplatnění při modelování řady fyzikálních a chemických procesů a našly široké využití také v současném technickém výzkumu a vědě obecně [31][48][52]. Významné využití FC se projevilo například při modelování nemocí, jako jsou virus lidské imunodeficience (HIV) [5] nebo malárie [42]. V poslední době byl potenciál FC zkoumán v oblasti počítačového vidění (computer vision), například při obnově obrazu, super-rozlišení, segmentaci obrazu a odhadu pohybu [49][41]. Další možnosti uplatnění FC ve strojovém učení byly zkoumány v práci [25], kde autoři představili koncept neceločíslné generativní adversariální sítě (fractional generative adversarial network, FGAN). Rovněž práce [2] se zabývala využitím Caputova operátoru v procesu zpětného šíření chyby v neuronových sítích.

Existuje mnoho definic FD [40], mezi nejčastěji používané patří Grünwald–Letnikov, Riemann–Liouville a Caputo definice.

4.1 Grünwald–Letnikov

Definice neceločíslné derivace podle Grünwalda-Letnikova je jedním z prvních a základních přístupů [28]. Přímá definice derivace funkce $y(t)$ řádu α , označená jako $D^\alpha y(t)$ [43], je založena na konečných diferencích na ekvidistantní mřížce v intervalu $[0, \tau]$, za předpokladu, že funkce $y(t)$ splňuje určité podmínky hladkosti na každém konečném intervalu $(0, t)$, kde $t \leq T$, a T označuje periodu.

Mřížka je definována jako:

$$0 = \tau_0 < \tau_1 < \dots < \tau_{n+1} = t = (n + 1)h, \quad (4.1)$$

kde platí:

$$\tau_{k+1} - \tau_k = h. \quad (4.2)$$

S použitím notace konečných diferencí:

$$\frac{1}{h^\alpha} \Delta_h^\alpha y(t) = \frac{1}{h^\alpha} \left(y(\tau_{n+1}) - \sum_{v=0}^n c_v^\alpha y(\tau_{n+1-v}) \right), \quad (4.3)$$

kde:

$$c_v^\alpha = (-1)^{v-1} \binom{\alpha}{v}, \quad (4.4)$$

Definice Grünwalda-Letnikova z roku 1867 je vyjádřena jako:

$${}^{GL}D^\alpha y(t) = \lim_{h \rightarrow 0} \Delta_h^\alpha y(t), \quad (4.5)$$

kde ${}^{GL}D^\alpha y(t)$ označuje Grünwald-Letnikovovu derivaci řádu α funkce $y(t)$, a h představuje velikost kroku mřížky.

4.2 Riemann–Liouville

Další klasická forma FD byla uvedena Riemannem-Liouvillem. Levostranná inverzní interpretace ${}^{RL}D^\alpha y(t)$ podle Riemanna-Liouvilleho z roku 1869 vychází z Riemanna-Liouvilleho definice neceločíselného integrálu [43][31]:

$${}^{RL}J_\alpha y(t) = \frac{1}{\Gamma(\alpha)} \int_0^t (t-x)^{\alpha-1} y(x) dx, \quad (4.6)$$

${}^{RL}J_\alpha$ je operátor integrace řádu α , kde $\alpha \in \mathbb{R}^+$ a $t > 0$, Γ je gama funkce.

$${}^{RL}D^\alpha y(t) = \left(\frac{d}{dt} \right)^n ({}^{RL}J_{(n-\alpha)} y(t)) \quad (4.7)$$

kde ${}^{RL}D^\alpha y(t)$ označuje Riemann-Liouville derivaci funkce $y(t)$ řádu α ($\alpha \in \mathbb{R}$) a $n-1 < \alpha \leq n$, $n \in \mathbb{N}$, $t > 0$.

Tato forma funguje na základě toho, že integrace a derivace jsou inverzní operace. k získání derivace neceločíselného řádu α nejprve integrujeme vstupní funkci neceločíselným řádem $n-\alpha$ kde n je nejbližší vyšší celé číslo k α a výsledný integrál následně derivujeme řádem n . Takže pokud chceme derivovat funkci $f(x)$ např. řádem $\alpha = 0.3$: Najdeme nejbližší vyšší celé číslo k α , což v našem případě bude $n = 1$, provedeme integraci $f(x)$ řádu $k = n - \alpha = 0.7$ a výsledný integrál zderivujeme řádem $n = 1$. Tak získáme derivaci řádu $n - k = n - (n - \alpha) = \alpha$.

4.3 Caputo

Mezi významné příspěvky k rozvoji neceločíselného počtu patří práce M. Caputa [10]. Caputova derivace je velmi podobná Riemann–Liouvilleově. Hlavní rozdíl mezi těmito dvěma definicemi spočívá v tom, že RL funkci nejprve integruje a následně derivuje, zatímco Caputo vstupní funkci nejprve derivuje a následně integruje.

Caputova derivace:

$${}^C D^\alpha y(t) = {}^{RL}J_{(n-\alpha)} y^{(n)}(t) \quad (4.8)$$

kde ${}^C D^\alpha y(t)$ označuje Caputovu derivaci funkce $y(t)$ řádu α , ${}^{RL}J_{(n-\alpha)}$ je RL neceločíselný integrál viz rovnice 4.6 a $n-1 < \alpha \leq n$, $n \in \mathbb{N}$, $t > 0$.

Tato změna má zásadní důsledky pro interpretaci počátečních podmínek [43, 31], což ji činí vhodnější pro praktické aplikace, zejména v případech, kdy je třeba modelovat skutečné systémy s počátečními podmínkami. Zatímco derivace ve smyslu Riemanna–Liouvillea vyžaduje, aby počáteční podmínky byly zadány pomocí neceločíselných integrálů a jejich celočíselných derivací, což často postrádá jasnou fyzikální interpretaci, Caputova definice umožňuje formulaci počátečních podmínek prostřednictvím běžných celočíselných derivací (např. $y(0), y'(0), \dots$). To je v souladu s běžnou praxí v inženýrských a fyzikálních aplikacích, kde jsou počáteční hodnoty měřitelné a mají přímý význam. V tomto smyslu je neceločíselná derivace podle Caputa levým inverzním operátorem k odpovídajícímu neceločíselnému integrálu, což představuje přirozené zobecnění Cauchyho formule pro n -násobnou primitivní funkci $f(t)$ [43].

5 Metody strojového učení pro analýzu GP

Strojové učení (ML) je oblast umělé inteligence, která umožňuje naučit počítače provádět predikce na základě dostupných datových sad a algoritmů. I když bylo poprvé formulováno v roce 1943, jeho rozvoj nastal až v 90. letech 20. století a dnes se stalo klíčovým nástrojem v aplikacích, jako je rozpoznávání obrazů, autonomní řízení vozidel nebo zdravotní diagnostika.

Diagnostika GP s podporou strojového učení zažila v posledních letech značný pokrok. Od roku 2016, kdy byla představena [35], značně vzrostla v popularitě. Mezi nejčastěji užívané metody patří Random Forest (RF), XGBoost, AdaBoost, Support Vector Machine (SVM) a konvoluční neuronové sítě (CNN).[23][27]

5.1 Random Forest (RF)

Random Forest je metoda strojového učení, která kombinuje více rozhodovacích stromů (*Decision Trees*) do jednoho predikčního modelu za účelem zvýšení přesnosti a robustnosti výsledků, tedy patří mezi *ensemble metody*. Využívá techniku *baggingu* (Bootstrap Aggregating), která zlepšuje modely kombinováním výsledků z různých tréninkových podmnožin. Každý strom v Random Forest je natrénován na jiné náhodné podmnožině dat, která je vytvořena pomocí náhodného výběru s opakováním (*bootstrap*). Navíc při každém rozhodování v uzlu stromu RF vybírá pouze náhodnou podmnožinu rysů, což zvyšuje rozmanitost stromů a snižuje riziko přetrénování. Výstupy jednotlivých stromů se následně agregují.[24]

RF je znám svou robustností vůči šumu a nelineárním vztahům v datech, což ho činí velmi efektivním pro širokou škálu problémů, od klasifikace po regresi. Kombinace stromů zlepšuje výkon oproti jednotlivým stromům, což vede k vyšší přesnosti. Díky baggingu a náhodnému výběru vlastností je model odolný vůči přetrénování. Na druhou stranu, trénování a predikce jsou časově i paměťově náročné, což zvyšuje výpočetní náročnost. Další nevýhodou je nízká interpretovatelnost modelu, protože kombinace mnoha rozhodovacích stromů je obtížnější pochopit než jednotlivý rozhodovací strom.[50]

5.2 XGBoost

XGBoost (Extreme Gradient Boosting) je efektivní a výkonný algoritmus strojového učení určený pro klasifikaci a regresi. Stejně jako RF patří mezi *ensemble metody* a je vylepšenou verzí *gradient boosting*. Tento algoritmus vytváří sekvenci rozhodovacích stromů, přičemž každý nový strom se zaměřuje na chyby předchozího, čímž postupně zlepšuje výkon modelu. XGBoost využívá techniku *boosting*,

kde jsou modely (stromy) trénovány postupně, a každý nový model se snaží opravit chyby předchozích stromů. Na rozdíl od metod, jako je Random Forest, kde stromy fungují nezávisle, v XGBoost se stromy navzájem doplňují. Algoritmus obsahuje regularizační termíny ($L1$ a $L2$), které pomáhají předejít přetrénování a udržují model jednodušší a lépe generalizující. XGBoost je také navržen pro vysokou efektivitu a rychlost, přičemž optimalizuje využití více procesorových jader a obsahuje techniky paralelizace pro urychlení trénování. Pokročilé ořezávání stromů (pruning) dále zjednodušuje model a zvyšuje jeho schopnost generalizace tím, že odstraní nepotřebné větve stromu. Implementuje váhování vzorků, což znamená, že chybně klasifikované vzorky dostávají vyšší váhu, což zajišťuje, že model se soustředí na těžší případy a tím zlepšuje svou celkovou přesnost.[14][12]

XGBoost je známý svou vysokou přesností, rychlostí a odolností. Díky efektivnímu trénování a optimalizaci často zvládá i složitější úlohy. Algoritmus je velmi rychlý, i při zpracování rozsáhlých datových souborů, díky paralelizaci a optimalizovaným metodám. Je robustní vůči šumu a dobře se vypořádává s neúplnými nebo nevyváženými daty. Na druhou stranu může být výpočetně náročný a náchylný k přetrénování. Podobně jako RF má nízkou interpretovatelnost.[50]

5.3 AdaBoost

AdaBoost (Adaptive Boosting) byl navržen v roce 1995. Také jde o ensemble metodu, která kombinuje více slabých klasifikátorů, aby vytvořila silnější a přesnější model. Je to metoda, která se zaměřuje na zlepšení výkonu jednoduchých modelů (slabých klasifikátorů) tím, že je iterativně upravuje, aby lépe zvládly těžší případy v trénovacích datech.[50]

AdaBoost funguje tak, že trénuje sekvenci slabých klasifikátorů, obvykle rozhodovacích stromů s malou hloubkou, které jsou známé jako „stumpy“ klasifikátory. Proces trénování probíhá v několika krocích [20]:

1. **Inicializace váh:** Každý trénovací příklad dostane počáteční váhu, která je obvykle nastavena rovnoměrně. Tato váha určuje, jak moc bude daný příklad ovlivňovat trénink modelu.
2. **Trénování slabého klasifikátoru:** V každé iteraci algoritmus trénuje nový slabý klasifikátor, který se zaměřuje na příklady, které byly v předchozích iteracích špatně klasifikovány. Čím více chyb je u daného příkladu, tím větší váhu dostane v dalším kole.
3. **Úprava váh:** Pokud klasifikátor v dané iteraci udělá chybu na nějakém příkladu, jeho váha se zvýší, čímž se zvyšuje důraz na tento příklad v dalších iteracích. Naopak, správně klasifikované příklady mají sníženou váhu.

4. **Výběr modelu a kombinace:** Po dokončení všech iterací jsou výsledné slabé klasifikátory kombinovány. Každý klasifikátor je přiřazen váhu podle jeho úspěšnosti. Výsledek finálního modelu je založen na váženém hlasování jednotlivých klasifikátorů.

AdaBoost vykazuje silnou schopnost generalizace na nová data a je odolný vůči overfittingu i při použití jednoduchých klasifikátorů. Kromě toho je flexibilní, neboť může být použit s různými slabými klasifikátory, jako jsou rozhodovací stromy, SVM nebo jiné modely. Nicméně, AdaBoost je citlivý na šum a odlehlé hodnoty, protože nesprávně klasifikované příklady dostávají stále větší váhu, což může způsobit nadměrné přizpůsobení modelu šumu. Další nevýhodou je výpočetní náročnost při vysokém počtu iterací nebo u velmi rozsáhlých datasetů. [50]

5.4 Support Vector Machine (SVM)

SVM je jeden z nejrozšířenějších algoritmů v oblasti strojového učení, který se používá především pro úlohy klasifikace, ale i pro regrese. SVM je založen na myšlence najít optimální hyperrovinu, která co nejlépe rozdělí data do dvou tříd. Tento princip je vhodný především pro úlohy, kde je potřeba oddělit data, která jsou lineárně separovatelná, ale může být také použit pro nelineární úlohy s pomocí jaderných funkcí.

SVM se používá k rozdělení dat do dvou tříd pomocí hyperroviny. Cílem SVM je najít takovou hyperrovinu, která maximálně odděluje data obou tříd. V případě, že jsou data nelineárně separovatelná, využívá SVM jádrové funkce, které transformují data do vyšší dimenze, kde jsou třídy lépe oddělitelné.

Hlavním prvkem SVM jsou *support vectors*, což jsou body, které leží na okraji jednotlivých tříd a mají klíčový vliv na pozici hyperroviny. SVM se snaží maximalizovat *margin*, což je vzdálenost mezi hyperrovinou a support vectors. Čím větší margin, tím lepší generalizace modelu na nová data.[50]

SVM je známý svou vysokou přesností, zejména u složitějších problémů, kde jsou data nelineárně separovatelná. Díky své robustnosti vůči šumu a flexibilitě v použití různých jader se hodí pro širokou škálu úloh. Nicméně, SVM může být výpočetně náročný, zejména při práci s velkými datovými soubory, a výběr vhodné jádrové funkce může být časově náročný. SVM také není ideální pro velmi rozsáhlé datasety, kde může být pomalejší než jiné metody, jako je například Random Forest nebo XGBoost. [50]

5.5 Konvoluční neuronové sítě (CNN)

Metoda konvolučních neuronových sítí (CNN) byla poprvé představena v 80. letech 20. století francouzským vědcem Yannem LeCunem, který vytvořil jednu z prvních verzí CNN pro rozpoznávání ručně psaných číslic, známou jako *LeNet* [29].

CNN jsou specializovaným typem umělých neuronových sítí (ANN), které jsou navrženy především pro zpracování obrazových dat. Jejich struktura je inspirována biologickými procesy v lidském mozku, přičemž jsou tvořeny umělými neurony, které jsou navzájem propojené ve třech hlavních vrstvách: vstupní vrstva, skrytá vrstva a výstupní vrstva. Na rozdíl od tradičních ANN, které mohou mít několik skrytých vrstev, CNN využívá specifické vrstvy, které se zaměřují na extrakci a analýzu rysů z dat.[50]

Struktura CNN zahrnuje dva základní bloky [50]:

- **Blok pro učení rysů (feature learning block)** – Tento blok se skládá z několika střídajících se vrstev konvoluce a poolingových vrstev. Konvoluční vrstva slouží k extrakci rysů z vstupních obrazových dat. Po každé konvoluční vrstvě následuje poolingová vrstva, která slouží k redukci rozměrů dat a vytažení podstatných informací.
- **Blok pro klasifikaci (classification block)** – Tento blok je odpovědný za klasifikaci extrahovaných rysů a rozhodování o výsledném výstupu sítě.

Konvoluce je operace, při které se filtr (nebo jádro) aplikuje na vstupní data, čímž se získávají různé rysy jako jsou hrany, textury, tvary apod. Tyto rysy jsou následně posílány do dalších vrstev, kde se vytvářejí složitější reprezentace, což umožňuje síti "pochopit" a analyzovat data na vyšší úrovni.

CNN jsou vynikající pro úkoly, které zahrnují obrazová data, například klasifikaci obrázků, rozpoznávání objektů nebo analýzu videa. Tyto sítě umožňují efektivně a přesně zpracovávat vizuální informace díky své schopnosti automaticky extrahovat relevantní rysy z dat bez potřeby ručního předzpracování.[50]

6 Návrh nových kinematických parametrů založených na FD

Studie ukázaly, že použití FD pro klasifikaci grafomotorických obtíží je v současnosti slibným přístupem, který rozšiřuje tradiční metody analýzy založené na klasických kinematických parametrech [58][39][38]. V této kapitole je představen návrh nových kinematických parametrů založených na FD, které mohou nabídnout hlubší vhled do charakteristik grafomotorických obtíží. Tyto parametry by mohly rozšířit stávající metody analýzy.

6.1 FD kinematických parametrů o neceločíselných řádech vyššího rozlišení

Ve stávajících studiích byly základní kinematické parametry derivovány s hodnotou α v rozsahu $(k, 1)$ kde α značí řád derivace a k značí krok (senzitivitu). Hodnota $k = 0, 1$ byla nejčastěji používanou senzitivitou.[58][39][37]

Navrhují prozkoumat derivace o $k = 0, 05$ senzitivitě. Snížením kroku lze získat detailnější informace o jemných změnách ve funkci a více než dvojnásobné množství rysů oproti $k = 0, 1$ (19 rysů pro $k = 0, 05$ zatímco jen 9 rysů pro $k = 0, 1$ mezi dvěma celočíselnými derivacemi). Různé hodnoty α mohou zvýraznit specifické aspekty pohybu. Zejména pro nízké desetinné hodnoty řádu α jsou variace funkcí sousedících řádů výrazné viz Obr. 6.1. Analýza těchto rysů s větší senzitivitou má potenciál odhalit dosud neprozkoumané řády derivace s lepší diskriminační schopností.

6.2 Temporal Memory Index (TMI)

Jedním z hlavních rozdílů mezi neceločíselnými derivacemi a klasickými celočíselnými derivacemi je jejich nelokální povaha. Zatímco hodnoty celočíselných derivací závisí pouze na lokálním chování funkce v okolí daného bodu, neceločíselné derivace závisí také na všech předešlých hodnotách funkce. Jinými slovy, nesou v sobě paměť o vývoji funkce v čase.

Dosavadní analýza neceločíselných derivací ukázala, že parametry nižších řádů α často lépe korelují se stavem vzorků než parametry vyšších řádů [58][37]. Vzhledem k tomu, že derivace nižších řádů obvykle vykazují výraznější paměťový efekt než derivace vyšších řádů, mohlo by to naznačovat potenciální význam paměťového efektu jako klasifikačního parametru.

Za účelem ověření této myšlenky byl definován Temporal Memory Index (TMI) založený na rozdílu FD různých řádů α .

Pro jeho výpočet nejprve definujeme alpha-rozdílový vektor (ADV) jako:

$$ADV(t) = D^{\alpha_2} f(t) - D^{\alpha_1} f(t), \quad (6.1)$$

kde D^α značí FD řádu α a platí $\alpha_2 > \alpha_1$. ADV vyjadřuje rozdíl v míře minulého vlivu na signál, reprezentovaný dvěma neceločíselnými derivacemi. Čím větší je tento rozdíl, tím výraznější je paměťový efekt.

TMI je pak definováno jako aritmetický průměr absolutních hodnot ADV:

$$TMI = \frac{1}{T} \int_0^T |ADV(t)| dt = \frac{1}{N} \sum_{i=1}^N |ADV(N)|, \quad (6.2)$$

kde T je časový interval a N je počet vzorků.

6.3 Korelace řádu FD s danou funkcí

Průběh funkcí na Obr. 6.1 naznačuje, že existuje zřetelný vztah mezi řádem α a tvarem výsledné funkce. Navrhuji prozkoumat, jak se průběh funkcí mění v závislosti na hodnotách α . Tento vztah by mohl být popsán pomocí korelační analýzy, jako například Pearsonův a Spearmanův korelační koeficient.

Pearsonův korelační koeficient r :

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (6.3)$$

kde x_i a y_i jsou jednotlivé hodnoty dvou hodnocených proměnných a \bar{x} a \bar{y} jsou aritmetický průměr těchto proměnných.

Spearmanův korelační koeficient ρ :


$$\rho = 1 - \frac{6 \sum[\text{rank}(x_i) - \text{rank}(y_i)]^2}{n(n^2 - 1)} \quad (6.4)$$

kde x_i a y_i jsou jednotlivé hodnoty dvou hodnocených proměnných, n značí celkový počet těchto dvojic a $\text{rank}(x_i)$ respektive $\text{rank}(y_i)$ vyjadřuje vzestupné pořadí hodnoty x_i respektive y_i (nejnižší hodnota bude mít pořadí 1, nejvyšší bude mít pořadí n).

Korelační analýza umožňuje kvantifikovat míru závislosti mezi dvěma proměnnými. Abychom mohli vypočítat korelaci α s funkcí, je nutné tuto funkci zastoupit nějakou hodnotou (kvantifikovat). K tomu můžou být vhodné, mimo jiné, v této práci již zmíněné statistické charakteristiky jako aritmetický průměr, medián nebo směrodatná odchylka. Tímto způsobem však ztratíme informace o tvaru funkce.

Pokud nechceme ztrácet tolik informací, dalším možným řešením by mohlo být postupně provést korelaci pro všechny hodnoty funkcí v čase, čímž bychom získali korelační koeficienty pro každý časový úsek. Toto řešení by mohlo poskytnout velmi detailní informace o korelaci funkce, ale není jasné, zda by tato metoda nebyla příliš výpočetně náročná.

Kompromisem mezi těmito extrémami by mohlo být rozdělení funkce na menší časové úseky a postupné výpočty korelačních koeficientů pro každý z těchto úseků pomocí první metody. Tento přístup by nám umožnil nalézt rovnováhu mezi přesností výsledků a výpočetní náročností. Kratší časové úseky by poskytovaly detailnější analýzu, zatímco delší úseky by zvýšily efektivitu výpočtů, avšak na úkor jemnosti výsledků. Výsledkem by byla dynamická analýza, která umožňuje sledovat změny korelace v čase, čímž by bylo možné lépe identifikovat vzory, trendy a případné anomálie.



Obr. 6.1: Vliv různých řádů α na vzory vertikální rychlosti (**Figure 4** v [38])

6.4 Entropie s pomocí FD

Signál vykazuje určité známky chaosu, což znamená, že jeho průběh je nepravidelný, složitý nebo obsahuje znatelné odchylky a nepravidelnosti. Tyto rysy lze kvantifikovat pomocí entropie. Dá se předpokládat, že písmo u osob s GP bude vykazovat nepravidelnosti v rukopisu, variace v tlaku pera, nebo náhlé změny rychlosti

a směru pohybu a tím pádem i zvýšené hodnoty entropie. Studie ukázaly, že entropie může být užitečná k detekci GP. Například Brabenec et al. našli korelace mezi mediánem Shannonovy entropie pro vodorovné pohyby ve vzduchu a skórem pozornosti ($R = -0,55; p = 0,006$) [9].

Shannonova entropie $H(X)$ náhodné proměnné X :

$$H(X) = - \sum_{i=1}^n p(x_i) \log_2 p(x_i) \quad (6.5)$$

kde $p(x_i)$ je pravděpodobnost výskytu i -té hodnoty x_i v rozdělení pravděpodobností náhodné proměnné X a n je počet možných hodnot náhodné proměnné X .


Vzhledem k tomu, že kinematická analýza vykazuje větší citlivost u FD, předpokládám, že i entropie bude vykazovat větší citlivost při použití FD. To by mohlo vést k lepší schopnosti zachytit jemnější změny ve struktuře písma, které by mohly být přehlédnuty při použití standardních metod analýzy. Tato vyšší citlivost by mohla přispět k přesnějšímu zhodnocení komplexity a chaosu v písmu, což by mohlo vést ke zvýšené klasifikační schopnosti.

7 Dataset

7.1 PaHaW

Pro náš dataset byla použita databáze rukopisu pacientů s Parkinsonovou nemocí (PaHaW) [17]. Databáze obsahuje záznamy od 75 účastníků z toho 38 zdravých kontrol (HC) a 37 s diagnózou PN. Každý z účastníků poskytl záznamy svého online písma, psaného podle předvyplněné šablony.

Při akvizici rukopisu byly subjekty odpočínuté a usazené před stolem v pohodlné pozici. Každý subjekt byl požádán, aby pohodlným tempem provedl úkol psaní podle připravené předvyplněné šablony viz Obr. 7.1. Subjekty měly možnost úkol opakovat v případě chyby nebo nesprávnosti při psaní. Nebyla stanovena žádná omezení ohledně počtu opakování slabik/slov v úkolech nebo jejich výšky.



Obr. 7.1: Příklad předvyplněné šablony

K zaznamenávání signálů byl použit digitální tablet Wacom Intuos 4M. Na tablet byla umístěna prázdná papírová šablona obsahující pouze tištěné čáry a čtvercové rámečky vymezující oblast pro Archimédovu spirálu. Subjekt k zápisu použil speciální inkoustové pero, což zajistilo co nejpřirozenější psací podmínky s okamžitou vizuální zpětnou vazbou během záznamu rukopisu. Záznamy začaly, když pero přišlo

do kontaktu s povrchem tabletu, a skončily, když byl úkol dokončen. Tablet zachytil následující dynamické charakteristiky v podobě časové sekvence se vzorkovací frekvencí 100 Hz: x souřadnice, $x[t]$; y souřadnice, $y[t]$; časová značka, $s[t]$; stav tlačítka, $b[t]$; tlak, $p[t]$; a diskrétní čas t . Stav tlačítka je binární proměnná, kdy 0 znamená pohyb ve vzduchu a 1 pohyb na povrchu.

K analýze byly vybrány 3 úkoly z šablony a to jejich úplný záznam viz Obr. 7.2. Úkol číslo 1: Archimédova spirála, úkol číslo 3: pět přerušovaných psacích malých „L“ a úkol číslo 9: věta „Tramvaj dnes už nepojede.“ psaná psacím písmem. Z těchto úkolů byly vytvořeny 3 datasety.

7.2 Výběr parametrů

V teoretické části práce byly navrženy čtyři nové skupiny parametrů založené na využití FD (Viz kapitola 6):

- FD kinematické parametry o neceločíselných řádech vyššího rozlišení,
- Index časové paměti TMI,
- Korelace řádu FD s danou funkcí,
- Entropie s využitím FD.


Cílem praktické části je ověřit přínos navržených parametrů pro analýzu GP u pacientů s Parkinsonovou nemocí. Vzhledem k omezenému rozsahu práce nebylo možné experimentálně implementovat všechny čtyři přístupy. Výběr byl proto omezen na dvě skupiny parametrů, a to:

1. FD kinematické parametry o vyšším rozlišení,
2. Index časové paměti TMI.


FD kinematické parametry o vyšším rozlišení byly zvoleny pro jejich přímou rozšiřitelnost existujících metod. Přístup přímo navazuje na již existující výzkum využívající FD parametrů, avšak zavádí jemnější krok $k = 0,05$, čímž výrazně zvyšuje rozlišení a umožňuje hlouběji prozkoumat nízké řády α které mívají mezi sebou vysokou variaci viz Obr. 6.1. Tato metoda je snadno implementovatelná a přirozeně rozšiřuje dosavadní přístup.

TMI jsme zvolili pro jeho schopnost kvantifikovat paměťový efekt signálu pomocí rozdílů neceločíselných derivací různých řádů. Tento parametr tak může odhalit jemné změny v dynamice signálu, které nejsou zachytitelné klasickými metodami a může být zvláště přínosný při rozlišení stavů s odlišnou historií vývoje pohybového vzoru.

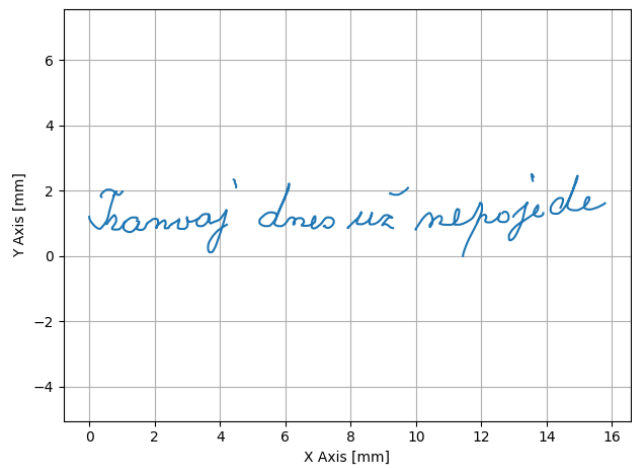
Obě zvolené metody také obnáší nižší výpočetní náročnost oproti metodám založeným na korelační analýze nebo entropii. Korelační analýza přes celé časové řady či segmenty by vyžadovala komplexnější přípravu dat a větší počet experimentů pro



(a) Úkol 1 - Spirála



(b) Úkol 3 - Psací „l“



(c) Úkol 9: Psací věta


Obr. 7.2: Příklady úkolů. Tahy na povrchu.

ověření. Entropie s využitím FD by si naopak vyžádala pečlivé ladění metod výpočtu hustoty pravděpodobnosti pro různé α , což přesahuje časové možnosti této práce.

Očekává se, že oba zvolené typy parametrů povedou k rozšíření současného popisu kinematiky a zvýšení diskriminační schopnosti při klasifikaci pacientů. Zároveň představují nový, dosud nepublikovaný přístup.

7.3 Získání parametrů


Data byla rozdělena na tahy viz Obr. 7.3. Tahy byly získány rozdělením datového záznamu na bloky, ohraničené změnou binárního stavu tlačítka které určovalo zda byl záznam proveden na povrchu nebo ve vzduchu (0 = ve vzduchu, 1 = na povrchu). Kinematické parametry byly počítány na jednotlivých tazích z x-souřadnic,




Obr. 7.3: Příklad rozdělení vzorku na tahy. Modré tahy jsou na povrchu, červené ve vzduchu.

y-souřadnic a z trajektorie, a to jak pro tahy na povrchu, tak i pro tahy ve vzduchu. Takto zpracované tahy byly rozděleny na záznamy ve vzduchu a na povrchu, zpětně spojeny do celých záznamů a výsledné parametry byly získány výpočtem průměru, mediánu a směrodatné odchylky těchto záznamů. Tímto způsobem bylo z každého datasetu získáno 18 parametrů (polovina u datasetů neobsahujících tahy ve vzduchu, v našem případě spirála) pro každou metodu extrakce.


Získané parametry byly uloženy do 4 tabulek. První 3 odpovídaly jednotlivým úkolům a poslední byla spojením všech parametrů.



(a) Složená spirála [mm]



(b) Složka x [mm] v čase t [s]



(c) Složka y [mm] v čase t [s]

Obr. 7.4: Příklad rozdělení spirály na horizontální a vertikální složky.

7.3.1 Základní kinematické

Základní kinematické parametry byly počítány pro rychlost, zrychlení a trh, tedy první druhá a třetí derivace trajektorie. Byly přidány k souboru parametrů za účelem porovnání s novými kinematickými parametry.

7.3.2 Caputo neceločíselné derivace

První skupinou nových kinematických parametrů byly parametry založené na Caputově FD derivaci. Caputova metoda byla zvolena pro její dobré výsledky v dosavadní literatuře v rámci našeho oboru [58][39].

FD byly spočítány pro celkem 19 různých řádů α a to v rozmezí $\alpha = 0,05$ až $\alpha = 0,95$ o délce kroku $k = 0,05$. Původní návrh délky kroku byl $k = 0,025$. Nakonec byla zvolena délka $k = 0,05$ pro snížení množství parametrů a tím i výpočetní náročnosti celé práce. Cíl otestovat málo probádané derivace nízkých řádů byl však stále splněn, protože valná většina dosavadní literatury nepřesahuje dolní limit kroku $k = 0,1$.

Vzhledem k vlastnosti tzv. dočasné paměti (temporal memory) dochází při tomto výpočtu k výskytu výrazných špiček v bodech nespojitosti, typicky například na začátku úlohy se spirálou. Z tohoto důvodu bylo z každého vektoru příznaků odstraněno prvních 50 vzorků jako odlehlé hodnoty, aby se předešlo zkreslení při následném výpočtu vyšších parametrů.

7.3.3 Temporal Memory Index (TMI)

Parametry TMI byly spočítány pro všechny kombinace hodnot řádů α_1 a α_2 , kde $\alpha_1 \in \{0.05, 0.1, \dots, 0.45\}$ a $\alpha_2 \in \{0.5, 0.55, \dots, 0.95\}$, což vyšlo na 90 kombinací celkem. Hodnoty byly navrženy pro otestování různých velikostí rozdílů α .

7.3.4 Počet parametrů

Pro výpočet parametrů jsme měli 3 datasety. Ze dvou datasetů bylo extrahováno 18 parametrů na metodu extrakce, ze třetího (spirála) jen polovina tedy 9. Metody extrakce základních kinematických parametrů byly 3: rychlost, zrychlení a trh. U Caputo FD měla 19, jedna pro každý řád. Metod na základě TMI bylo 90 a to jedna pro každou kombinaci α_1 a α_2 . To celkem tvoří $3 + 19 + 90 = 112$ metod extrakce.

Z těchto informací pak můžeme vypočítat celkový počet parametrů N :

$$N = (2 \cdot 18 + 9) \cdot 112 = 5040 \quad (7.1)$$

Získané parametry byly rozděleny do tří tabulek, každá pro parametry jednoho úkolu. Tabulka parametrů z úkolu 1 obsahovala 1008 parametrů, zbylé dvě pak každá 2016. Poté byla vytvořena čtvrtá tabulka obsahující všech 5040 parametrů.

7.4 Předzpracování dat

Tabulky získané v předchozí sekci obsahovaly surové datasey parametrů. Než bylo možné tyto datasey použít, bylo je třeba ořezat a kompenzovat o jisté nedostatky. Také bylo potřeba data upravit, tak aby s nimi algoritmus strojového učení dokázal pracovat. Za tímto účelem bylo provedeno několik kroků.

7.4.1 Výběr a rozdělení dat

Obecně ne všechna data v tabulce patří do stejné kategorie, což platilo i pro naše tabulky. Před učením tedy bylo nutné je rozdělit a to na sloupce příznaků, cílový sloupec a sloupce kovariátů. Příznaky jsou data která charakterizují vzorky. Cílový sloupec představuje kategorie, která dělí naše vzorky. V našem případě šlo o sloupec se jménem „Disease“ který dělil vzorky na zdravé jedince (HC) a pacienty s PN (PD). Byla to tedy výstupní hodnota, kterou se model učil predikovat. Sloupce kovariátů pak představují proměnné, které mají rušivý vliv na hodnoty příznaků. V našem případě se jednalo o věk a pohlaví.

Sloupce, které neobsahují číselné hodnoty, ale textové kategorie, je nutné před použitím ve strojovém učení převést na číselné. V našem případě šlo o sloupce „Disease“ a „Sex“. Oba tyto sloupce obsahovaly pouze dvě možné kategorie, takže jejich převod do číselné podoby byl jednoduchý:

- Disease: PD \rightarrow 1, HC \rightarrow 0
- Sex: M \rightarrow 1, F \rightarrow 0

7.4.2 Zahození nevhodných parametrů

Po extrakci všech parametrů bylo nutné odstranit ty, které nebyly vhodné pro použití při trénování modelu. Mezi tyto parametry patřily zejména ty, které obsahovaly velké množství nulových nebo NaN hodnot. Jako velké množství bylo považován počet přesahující 10% všech hodnot.

7.4.3 Odstranění efektu kovariátů

Jak již bylo zmíněno, kovariáty jsou proměnné, které ovlivňují hodnoty parametrů, aniž by souvisely s cílovou proměnnou. Je proto vhodné jejich vliv potlačit nebo

zcela odstranit. Pohlaví a věk byly identifikovány jako proměnné které této charakteristice odpovídají, jelikož mohou mít systematický vliv na extrahované parametry bez přímé souvislosti s klasifikačním cílem.

Vliv kovariátů byl odstraněn pomocí lineární regrese. Tento postup se běžně označuje jako regresní reziduální korekce. Postup odhaduje část variability parametru, kterou lze vysvětlit kovariátem, a tu z výsledných dat odstraní. Následně se dále pracuje pouze s rezidui – tedy s „očistěnými“ hodnotami.

8 Trénování modelu

Na základě dostupné literatury a konzultace s vedoucím práce bylo rozhodnuto pro použití algoritmu XGBoost. Účinnost této metody byla v oblasti klasifikace GP na základě online písma osvědčena v několika publikacích [39] [22].

K tréninku modelu byla použita Python knihovna XGBoost [11].

8.1 Křížová validace

K hodnocení výkonu modelu byla použita metoda opakované stratifikované křížové validace (k-fold stratified cross-validation). Data byla náhodně rozdělena do 5 stejně velkých skupin (foldů) tak, aby byl v každé skupině zachován původní poměr tříd (stratifikace). Model byl následně pětikrát natrénován vždy na čtyřech skupinách a testován na zbývající skupině. Tento proces se opakoval pro každou možnou kombinaci trénovacích a testovacích skupin. Výkon modelu byl vyhodnocen pomocí zvolené hodnotící metriky na každém testovacím foldě. Celý postup byl následně opakován pětikrát, pokaždé s novým náhodným rozdělením. Hodnocení bylo získáno aritmetickým průměrem výsledků všech iterací (25 výsledků).

8.2 Bayesovská optimalizace hyperparametrů

Pro natrénování co nejpřesnějšího modelu je nutné zvolit co nejvhodnější hyperparametry. Těchto parametrů je velké množství a není vždy jasné, jaký vliv bude konkrétní hodnota daného parametru na výslednou výkonnost modelu. Z tohoto důvodu byla v této práci využita **Bayesovská optimalizace** pro nalezení co nejlepších kombinací parametrů vzhledem ke zvolené metrice skórování. Optimalizační proces byl prováděn s použitím `BayesSearchCV`, který v každé iteraci provede trénování a hodnocení modelu pomocí **stratifikované křížové validace** (5 foldů a 5 opakování). Výkonnost modelu se tedy hodnotí nikoliv na jednom rozdělení trénovacích a testovacích dat, ale na průměru přes dvacet pět rozdělení, což zvyšuje spolehlivost výsledků a snižuje riziko přeučení na konkrétní dělení dat.

Celý proces optimalizace byl opakován celkem 32krát (32 iterací), přičemž při každé iteraci byla vybrána nová kombinace hyperparametrů ke zhodnocení na základě předchozích výsledků. Optimalizace byla řízena tak, aby maximalizovala metriku `balanced_accuracy`.

Bylo laděno sedm parametrů zatímco ostatní parametry byly ponechány na jejich základních hodnotách, které lze najít v dokumentaci XGBoost knihovny [13]. Laděné parametry:

- `learning_rate` – rychlost učení (velikost kroků při aktualizaci vah stromu),

- `max_depth` – maximální hloubka jednotlivých stromů,
- `subsample` – poměr vzorků použitých pro trénování každého stromu,
- `colsample_bytree` – poměr vstupních proměnných (sloupců) použitých pro každý strom,
- `colsample_bylevel` – poměr vstupních proměnných použitých pro každou úroveň stromu,
- `min_child_weight` – minimální suma váhy vzorků potřebná pro rozdělení uzlu,
- `scale_pos_weight` – váha negativní vs. pozitivní třídy (užitečné při nevyvážených datech),
- `n_estimators` – počet stromů v modelu.

parametr	rozsah
<code>learning_rate</code>	[0.001, 0.3]
<code>max_depth</code>	[3, 20]
<code>subsample</code>	[0.5, 1.0]
<code>colsample_bytree</code>	[0.5, 1.0]
<code>min_child_weight</code>	[1, 10]
<code>scale_pos_weight</code>	[1, 10]
<code>n_estimators</code>	[50, 300]

Tab. 8.1: Rozsahy hodnot pro ladění parametrů

Výsledkem tohoto postupu byla nejlepší nalezená kombinace parametrů a model, který byl natrénován s těmito parametry na celém datasetu.

8.3 Redukce datasetu

Trénování modelů na vysokém množství parametrů může vést k tomu, že se model příliš přesně naučí vlastnosti trénovacích dat – včetně náhodného šumu nebo odchylek, které nejsou obecně platné (přeučení). Takový model sice dosahuje velmi dobrého výkonu na datech, na kterých byl natrénován, ale nedokáže dobře zobecňovat – tedy má horší výsledky na nových testovacích datech. Tomuto můžeme předejít snížením celkového množství trénovacích parametrů. Abychom mohli rozhodnout které parametry použít a které zahodit, je důležité mít nějakou metriku, na základě které můžeme posoudit užitečnost parametrů.

V této práci byly parametry voleny podle jejich užitečnosti v modelu natrénovaném na všech parametrech a to podle metriky „gain“. Tato metrika vyjadřuje

relativní zlepšení výkonu modelu při zařazení daného parametru a slouží k hodnocení jeho přínosu pro predikční schopnost. Vyšší hodnota „gain“ znamená, že daný parametr významně přispívá ke zlepšení přesnosti modelu. Následně byl trénovací proces zopakován pro [10, 20, 30, 40, 50] nejlépe hodnocených parametrů, čímž bylo vytvořeno dalších pět modelů.

8.4 Hodnocení modelu

K vyhodnocení výkonu modelu bylo využito totožné rozdělení dat ze stratifikované křížové validace jako při trénovací fázi, čímž byla zajištěna konzistence mezi učním a testováním. Na každém foldu byla vygenerována predikce modelu, která byla následně porovnána se skutečnými třídami v testovací množině. Na základě tohoto porovnání byly získány následující hodnoty:

- **TP** (True Positive) – počet případů, kdy model správně identifikoval pozitivní třídu,
- **TN** (True Negative) – počet případů, kdy model správně identifikoval negativní třídu,
- **FP** (False Positive) – počet případů, kdy model nesprávně označil negativní třídu jako pozitivní,
- **FN** (False Negative) – počet případů, kdy model nesprávně označil pozitivní třídu jako negativní.

Na základě těchto údajů byly vypočteny metriky pro hodnocení vlastností natrénovaného modelu:

- „Balanced Accuracy“ (BACC) – vyrovnaná přesnost, která zohledňuje jak citlivost, tak specificitu:

$$\text{BACC} = \frac{1}{2} \left(\frac{\text{TP}}{\text{TP} + \text{FN}} + \frac{\text{TN}}{\text{TN} + \text{FP}} \right) \quad (8.1)$$

- „Accuracy“ (ACC) – celková přesnost modelu:

$$\text{ACC} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (8.2)$$

- „Sensitivity“ (citlivost, také *Recall*) – schopnost modelu správně identifikovat pozitivní případy:

$$\text{Sensitivity} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (8.3)$$

- „Specificity“ – schopnost modelu správně identifikovat negativní případy:

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (8.4)$$

- F1 skóre – harmonický průměr přesnosti a citlivosti:

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}, \quad \text{kde Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (8.5)$$

Pro každou z metrik *BACC*, *ACC*, *Sensitivity*, *Specificity* a *F1* byl na základě výsledků ve všech foldových děleních určen průměr a směrodatná odchylka, které sloužily jako souhrnné ukazatele výkonnosti modelu.

9 Výsledky

9.1 Přehled

V rámci práce bylo získáno celkem 5040 parametrů. Z toho 1008 parametrů bylo vypočteno ze vzorků úkolu 1 (kresba Archimédovy spirály), 2016 parametrů z úkolu 3 (opakováný zápis písmene „l“) a 2016 parametrů z úkolu 9 (zápis věty „Tramvaj dnes už nepojede.“).

Parametry byly počítány zvlášť z horizontálních tahů (souřadnice x), vertikálních tahů (souřadnice y) a složené trajektorie tahu (vektorový součin výpočtů x a y). U všech tří směrů byly rozlišovány tahy provedené na povrchu a tahy vedené ve vzduchu.

Extrahované parametry vycházely ze tří metod:

1. Klasické kinematické parametry (rychlost, zrychlení, trh – neboli *jerk*),
2. FD parametry (neceločíselné derivace řádu α v rozsahu 0,05 až 0,95 se skokem 0,05, tj. celkem 19 řádů),
3. TMI parametry (Temporal Memory Index), založené na 90 kombinacích řádů: α_2 v intervalu 0,05–0,45 a α_1 v intervalu 0,5–0,95.

Pro každý tah byl výpočet proveden zvlášť a výsledky tahů byly následně agregovány do jednoho vektoru. Pro každý parametr byly z agregovaného vektoru vypočteny tři hodnoty: průměr, medián a směrodatná odchylka.

Byly vytvořeny čtyři sady parametrů: jedna obsahovala všechny dostupné parametry, zatímco zbývající tři zahrnovaly pouze parametry odpovídající jednotlivým úkolům. Pro jednotlivé sady byly vypočteny Pearsonovy korelační koeficienty a odpovídající p -hodnoty, které byly následně kompenzovány metodou FDR (False Discovery Rate). Za statisticky významné byly považovány korelace s p -hodnotou menšími než $p = 0,05$.

Na těchto sadách bylo natrénováno a otestováno celkem 24 modelů. Pro každý z těchto datasetů byl natrénován základní model, ze kterého bylo následně na základě metriky „gain“ vybráno 50 nejvýznamnějších parametrů. Na základě těchto výsledků bylo pro každý základní model natrénováno pět dalších modelů s využitím 10 až 50 nejvýznamnějších parametrů (násobky deseti, top 10, top 20, atd.).

Tabulky Tab. 9.1 a Tab. 9.2 obsahují 5 modelů s nejlepšími výsledky a jejich hyperparametry. Nejlepších hodnot dosahují modely založené na úplné sadě parametrů a na sadě parametrů pouze úkolu 9 (psací věta „Tramvaj dnes už nepojede“ Viz Obr. 7.2c). V tabulce Tab. 9.3 pak můžeme vyčíst, že parametry úkolu 9 obsazují všechna první tři místa nejlepších modelů.

Tab. 9.1: Pět nejlepších modelů a jejich metriky.

Modely	BACC		SEN		SPEC		F1	
	AVG	STD	AVG	STD	AVG	STD	AVG	STD
U(1 3 9) top 30	0.79	0.10	0.77	0.15	0.81	0.15	0.78	0.11
U(1 3 9) top 20	0.78	0.12	0.75	0.19	0.80	0.16	0.76	0.15
U9 top 30	0.75	0.11	0.72	0.16	0.79	0.16	0.74	0.12
U(1 3 9) top 10	0.75	0.10	0.76	0.16	0.75	0.13	0.74	0.12
U9 top 50	0.74	0.10	0.75	0.13	0.74	0.18	0.74	0.09

BACC - vyvážená přesnost; SEN - senzitivita; SPEC - specificita; F1 - F1 skóre. Řazeno podle BACC. Vysvětlení pojmenování modelu: „M(K) top n“: M(K) označuje model trénovaný na úkolech K, top n znamená použití n nejlepších parametrů.

Tab. 9.2: Pět nejlepších modelů a jejich hyperparametry.

Modely	Hyperparametry						
	CSB	LR	MD	MCW	NE	SPW	SS
U(1 3 9) top 30	0.50	0.10	20	1	300	1	0.50
U(1 3 9) top 20	0.50	0.04	6	1	300	1	0.50
U9 top 30	0.50	0.20	20	1	50	1	0.50
U(1 3 9) top 10	0.98	0.30	20	1	253	1	0.51
U9 top 50	0.50	0.10	20	5	249	1	1.00

Hyperparametry: CSB - „colsample_bytree“, LR - „learning_rate“, MD - „max_depth“, MCW - „min_child_weight“, NE - „n_estimators“, SPW - „scale_pos_weight“, SS - „subsample“. Vysvětlení pojmenování modelu: „M(K) top n“: M(K) označuje model trénovaný na úkolech K, top n znamená použití n nejlepších parametrů.

Tab. 9.3: Pět nejlepších parametrů, pěti nejlepších modelů.

modely	Parametry	gain
U(1,3,9) top 30	U9 povrch FD alpha 0.05(median)	0.0796
	U9 povrch FD alpha 0.2(mean)	0.0655
	U9 povrch TMI F0.5-0.3(median)	0.0601
	U9 vzduch TMI F0.5-0.3(median)	0.0582
	U9 vzduch rychlost horizontální(std)	0.0535
U(1,3,9) top 20	U9 povrch TMI F0.55-0.45(mean)	0.0887
	U9 povrch FD alpha 0.2(mean)	0.0846
	U9 povrch TMI F0.5-0.3(median)	0.0812
	U9 povrch FD alpha 0.05(median)	0.0643
	U9 vzduch TMI F0.5-0.3(median)	0.0595
U9 top 30	U9 povrch TMI F0.5-0.35(median)	0.1316
	U9 povrch TMI F0.8-0.1(std)	0.0776
	U9 povrch TMI F0.6-0.3(median)	0.0614
	U9 povrch TMI F0.7-0.3(median)	0.0604
	U9 vzduch vertikální FD alpha 0.85(median)	0.0550
U(1,3,9) top 10	U9 povrch TMI F0.55-0.45(mean)	0.1676
	U9 povrch FD alpha 0.05(median)	0.1459
	U9 vzduch TMI F0.5-0.3(median)	0.1015
	U1 povrch horizontální TMI F0.55-0.05(median)	0.0959
	U9 povrch FD alpha 0.2(mean)	0.0959
U9 top 50	U9 povrch TMI F0.55-0.35(median)	0.1112
	U9 povrch TMI F0.5-0.1(median)	0.0850
	U9 povrch TMI F0.6-0.3(median)	0.0836
	U9 povrch trh horizontální(std)	0.0777
	U9 povrch FD alpha 0.2(mean)	0.0740

Modely řazeny podle BACC, parametry řazeny podle metriky „gain“ pro každý model sestupně. U_n značí úkol číslo n . Vysvětlení pojmenování parametrů: U_n značí Úkol číslo n , vzduch/povrch značí kde byl tah proveden, vertikální/horizontální/- značí která složka tahu byla počítána (x/y/aritmetický průměr obou), FD alpha α značí FD řádu α , TMI $F_{\alpha_2-\alpha_1}$ značí TMI vypočítané z FD řádů α_2 a α_1 viz sekce 6.2.

Korelační analýza parametrů spirály nenalezla žádné silné korelace, a to ani pro neupravené hodnoty p_s viz Tab. 9.4. Parametry vykazují buď nízkou citlivost, nebo jen slabý vztah ke klinickým datům. Nejlepší parametry jsou TMI parametry s $\alpha_1 = 0,05$.

Tab. 9.4: Výsledky korelační analýzy mezi klinickými daty pacientů a vypočítanými parametry rukopisu seřazené podle p-hodnot. Úkol 1. (Spirála)

Parametry	ρ	p_s	p_{adj}
U1 povrch vertikální TMI F0.9-0.05(median)	-0.2127	0.0793	0.9681
U1 povrch vertikální TMI F0.95-0.05(median)	-0.2112	0.0815	0.9681
U1 povrch vertikální TMI F0.85-0.05(median)	-0.2112	0.0815	0.9681
U1 povrch vertikální TMI F0.8-0.05(median)	-0.2083	0.0859	0.9681
U1 povrch vertikální TMI F0.75-0.05(median)	-0.2025	0.0952	0.9681
U1 povrch vertikální TMI F0.95-0.05(mean)	-0.1996	0.1002	0.9681
U1 povrch vertikální TMI F0.9-0.05(mean)	-0.1967	0.1053	0.9681
U1 povrch vertikální TMI F0.85-0.05(mean)	-0.1937	0.1107	0.9681
U1 povrch vertikální TMI F0.7-0.05(median)	-0.1923	0.1134	0.9681
U1 povrch vertikální TMI F0.8-0.05(mean)	-0.1908	0.1163	0.9681
U1 povrch vertikální TMI F0.75-0.05(mean)	-0.1908	0.1163	0.9681
U1 povrch vertikální TMI F0.6-0.05(median)	-0.1894	0.1191	0.9681
U1 povrch vertikální TMI F0.65-0.05(median)	-0.1879	0.1220	0.9681
U1 povrch vertikální TMI F0.7-0.05(mean)	-0.1821	0.1343	0.9681
U1 povrch vertikální TMI F0.65-0.05(mean)	-0.1792	0.1407	0.9681
U1 trh vertikální povrch(std)	-0.1777	0.1440	0.9681
U1 povrch vertikální TMI F0.6-0.05(mean)	-0.1777	0.1440	0.9681
U1 povrch vertikální TMI F0.55-0.05(median)	-0.1777	0.1440	0.9681
U1 trh horizontální povrch(std)	-0.1763	0.1474	0.9681
U1 zrychlení povrch(std)	-0.1734	0.1543	0.9681

Tabulka uvádí korelační koeficienty (ρ), p-hodnoty (p) a upravené p-hodnoty (p_{adj}). Vysvětlení pojmenování parametrů: Un značí Úkol číslo n , vzduch/povrch značí kde byl tah proveden, vertikální/horizontální/- značí která složka tahu byla počítána (x/y/aritmetický průměr obou), FD alpha α značí FD řádu α , TMI $F\alpha_2-\alpha_1$ značí TMI vypočítané z FD řádů α_2 a α_1 viz sekce 6.2.

Korelační analýza parametrů psacích „l“ je o něco silnější než parametry spirály viz Tab. 9.5. Bylo nalezeno 8 parametrů se silnou korelací $p_s < 0.05$. Zajímavý trend těchto parametrů je, že se většinou jedná o směrodatnou odchylku základních kinematických parametrů tahů ve vzduchu s negativní korelací. Po úpravě ale žádný z těchto parametrů nesplňoval kritérium statistické významnosti.

Tab. 9.5: Výsledky korelační analýzy mezi klinickými daty pacientů a vypočítanými parametry rukopisu seřazené podle p-hodnot. Úkol 3. (psací „l“)

Parametry	ρ	p_s	p_{adj}
U3 vzduch zrychlení(std)	-0.3634	0.0014	0.6011
U3 vzduch zrychlení horizontální(std)	-0.3425	0.0026	0.6011
U3 vzduch trh horizontální(std)	-0.3301	0.0038	0.6011
U3 vzduch trh(std)	-0.3240	0.0046	0.6011
U3 vzduch rychlost(std)	-0.3215	0.0049	0.6011
U3 vzduch horizontální FD alpha 0.05(median)	0.2920	0.0110	0.6011
U3 vzduch rychlost horizontální(std)	-0.2525	0.0288	0.6011
U3 vzduch horizontální FD alpha 0.1(median)	0.2427	0.0359	0.6011
U3 povrch vertikální TMI F0.55-0.05(std)	0.2180	0.0602	0.6011
U3 vzduch horizontální TMI F0.75-0.05(median)	0.2168	0.0617	0.6011
U3 vzduch horizontální TMI F0.85-0.05(median)	0.2156	0.0632	0.6011
U3 vzduch horizontální TMI F0.8-0.05(median)	0.2144	0.0648	0.6011
U3 vzduch horizontální TMI F0.95-0.05(median)	0.2144	0.0648	0.6011
U3 vzduch horizontální TMI F0.9-0.05(median)	0.2131	0.0664	0.6011
U3 vzduch horizontální TMI F0.7-0.05(median)	0.2082	0.0731	0.6011
U3 vzduch horizontální TMI F0.6-0.05(median)	0.2057	0.0766	0.6011
U3 vzduch horizontální TMI F0.65-0.05(median)	0.2045	0.0784	0.6011
U3 vzduch horizontální TMI F0.55-0.05(median)	0.2020	0.0822	0.6011
U3 povrch vertikální TMI F0.5-0.05(std)	0.2008	0.0841	0.6011
U3 vzduch horizontální TMI F0.5-0.05(median)	0.1946	0.0943	0.6011

Tabulka uvádí korelační koeficienty (ρ), p-hodnoty (p) a upravené p-hodnoty (p_{adj}). Vysvětlení pojmenování parametrů: Un značí Úkol číslo n , vzduch/povrch značí kde byl tah proveden, vertikální/horizontální/- značí která složka tahu byla počítána (x/y/aritmetický průměr obou), FD alpha α značí FD řádu α , TMI $F\alpha_2-\alpha_1$ značí TMI vypočítané z FD řádů α_2 a α_1 viz sekce 6.2.

Korelační analýza parametrů psací věty „Tramvaj dnes už nepojede“ ukázala velmi silnou souvislost viz Tab. 9.5. Kritérium statistické významnosti $p_s < 0,05$ splnila více než dvě třetiny všech parametrů, a to i po úpravě na FDR. Za dominantní trend lze považovat celkově dobrý výkon mediánových parametrů TMI odvozených z trajektorie tahů.

Tab. 9.6: Výsledky korelační analýzy mezi klinickými daty pacientů a vypočítanými parametry rukopisu seřazené podle p-hodnot. Úkol 9. (Psací věta: „Tramvaj dnes už nepojede“)

Parametr	ρ	p	p_{adj}
U9 povrch TMI F0.6-0.3(median)	0.4546	4.1878E-05	0.0033
U9 povrch TMI F0.95-0.25(median)	0.4496	5.18792E-05	0.0033
U9 povrch TMI F0.55-0.3(median)	0.4496	5.18792E-05	0.0033
U9 povrch TMI F0.85-0.25(median)	0.4496	5.18792E-05	0.0033
U9 povrch TMI F0.9-0.25(median)	0.4496	5.18792E-05	0.0033
U9 povrch TMI F0.8-0.25(median)	0.4472	5.76719E-05	0.0033
U9 povrch TMI F0.75-0.25(median)	0.4459	6.0788E-05	0.0033
U9 povrch TMI F0.5-0.35(median)	0.4459	6.0788E-05	0.0033
U9 povrch TMI F0.55-0.35(median)	0.4459	6.0788E-05	0.0033
U9 povrch TMI F0.65-0.3(median)	0.4447	6.40596E-05	0.0033
U9 povrch TMI F0.7-0.3(median)	0.4447	6.40596E-05	0.0033
U9 povrch TMI F0.7-0.25(median)	0.4447	6.40596E-05	0.0033
U9 povrch TMI F0.8-0.3(median)	0.4435	6.74938E-05	0.0033
U9 povrch TMI F0.75-0.3(median)	0.4435	6.74938E-05	0.0033
U9 povrch TMI F0.5-0.3(median)	0.4435	6.74938E-05	0.0033
U9 povrch TMI F0.85-0.3(median)	0.4423	7.10978E-05	0.0033
U9 povrch TMI F0.6-0.35(median)	0.4398	7.88464E-05	0.0033
U9 povrch TMI F0.95-0.3(median)	0.4398	7.88464E-05	0.0033
U9 povrch TMI F0.9-0.3(median)	0.4398	7.88464E-05	0.0033
U9 povrch TMI F0.65-0.25(median)	0.4386	8.30072E-05	0.0033

Tabulka uvádí korelační koeficienty (ρ), p-hodnoty (p) a upravené p-hodnoty (p_{adj}). Vysvětlení pojmenování parametrů: Un značí Úkol číslo n , vzduch/povrch značí kde byl tah proveden, vertikální/horizontální/- značí která složka tahu byla počítána (x/y/aritmetický průměr obou), FD alpha α značí FD řádu α , TMI $F_{\alpha_2-\alpha_1}$ značí TMI vypočítané z FD řádů α_2 a α_1 viz sekce 6.2.

9.2 Diskuze

Na základě provedené korelační analýzy lze pozorovat výrazné rozdíly v diagnostickém potenciálu jednotlivých úkolů. Parametry odvozené z kresby spirály (úkol 1 viz Obr. 7.2a) vykazovaly velmi slabé korelace, přičemž žádný z parametrů nesplnil po úpravě na FDR kritérium statistické významnosti (Tab. 9.4).

Mírně lepší výsledky přinesl úkol opakovaného psaní písmene „l“ (úkol 3 viz Obr. 7.2b), kde se sice objevilo několik parametrů s p -hodnotou nižší než 0,05, nicméně po úpravě FDR žádný z nich rovněž nevyhověl (Tab. 9.5). Zajímavým trendem Úkolu 3 bylo to, že se ukázaly jako nejvýznamnější parametry založené na směrodatné odchylce základních kinematických parametrů ve vzduchu, které vykazovaly negativní souvislost. To by naznačovalo, že pohyb ve vzduchu pacientů s PD vykazuje menší rychlostní výkyvy než pohyb zdravých osob. Jedním z možných vložení tohoto trendu je, že pacienti provádí pohyby ve vzduchu s větší opatrností než HC.

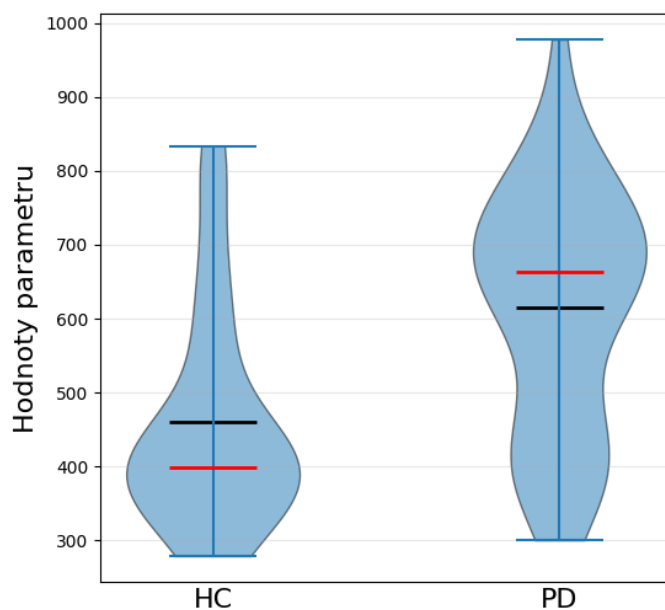
Zcela odlišnou situaci však poskytl úkol psaní celé věty (úkol 9 viz Obr. 7.2c), kde byla nalezena rozsáhlá skupina parametrů s velmi silnou korelací s klinickými daty (Tab. 9.6). Tyto výsledky zůstaly statisticky významné i po kompenzaci p -hodnot metodou FDR. Dominantní roli zde sehrály TMI parametry, zejména mediánové hodnoty odvozené z povrchových tahů, které dosahovaly vysokých hodnot korelačních koeficientů ($\rho > 0,44$) a velmi nízkých p -hodnot ($p < 0,004$). Nejvyšší korelace dosáhl parametr „U9 povrch TMI F0.6-0.3(median)“ s hodnotami $\rho = 0.455$ a p -hodnotou upravenou na FDR $p_{adj} = 0.003$ (Obr. 9.1).

Tyto rozdíly naznačují, že komplexnější úkoly, které lépe odrážejí přirozený styl rukopisu, mohou být citlivějším nástrojem pro detekci klinických změn.

Strojová analýza podporuje tuto myšlenku. Pět nejlepších modelů vzešlo buď čistě z parametrů Úkolu 9, nebo z kombinace všech úkolů. Porovnání užitečnosti parametrů v modelu podle metriky „gain“ ukázalo, že Úkol 9 hrál nejvýznamnější roli i v kombinovaných modelech viz Tab. 9.3.

Co se týče výkonu klasifikačních modelů, nejlepší výsledky dosáhl model založený na 30 nejvýznamnějších parametrech z kombinované sady, přičemž vykazoval vyváženou přesnost (balanced accuracy) 0,79, sensitivitu 0,77, specificitu 0,81 a F1 skóre 0,78 a směrodatná odchylka těchto metrik se pohybovala kolem hodnoty 0,12 viz Tab. 9.1. Tyto výsledky naznačují, že zapojení více než jednoho psacího úkolu do diagnostického procesu může významně zlepšit klasifikační výkon a tím i přesnost detekce klinických změn.

Na základě těchto výsledků lze usoudit, že metoda extrakce parametrů TMI by mohla být velmi slibným přídavkem do diagnostických nástrojů založených na analýze psaní. Její schopnost zachytit míru časové paměti se ukazuje jako silný



Obr. 9.1: Porovnání HC a PD parametru s nejlepší korelací: **U9 povrch TMI F0.6-0.3(median)** viz Tab. 9.6. Červená značka je medián, černá průměr.

diskriminační parametr, což může být dobrým podnětem pro její další zkoumání v oblasti diagnostiky Parkinsonovy nemoci.

Zvýšení rozlišení řádů neceločíselných derivací mělo rovněž pozitivní dopad. V nejlepším modelu patřily parametry odvozené z nízkých řádů FD mezi 5 nejdůležitějších, jak ukazuje Tab. 9.3. Tento výsledek podporuje hypotézu, že prozkoumání jemně odstupňovaných řádů může nalézt přínosná data pro diagnostiku.

Práce není bez nedostatků. Statistickou analýzu by bylo vhodné rozšířit o t-testy. Dále by analýza křížové korelace mezi nejlepšími parametry mohla pomoci eliminovat ty, které jsou si vzájemně příliš podobné, čímž by se snížil počet parametrů bez výrazného oslabení diskriminační schopnosti modelu. Toto je výhodné, protože příliš velké množství parametrů má negativní vliv na výkon modelu, jelikož mimo jiné zvyšuje náchylnost modelu k přetrénování. Dále by přispělo otestování více kombinací různých setů parametrů. Modely naučené na pečlivěji vybíraných parametrech (např. s pomocí statistických metod jako korelace nebo výše zmíněných t-testů).

Závěr

Cílem práce byl výzkum nových pokročilých kinematických parametrů určených k analýze grafomotorických potíží (GP). Analyzován byl ručně psaný projev reprezentovaný časovými řadami, získaný pomocí digitalizačního tabletu u pacientů s Parkinsonovou nemocí. Výzkum se zaměřil na využití derivací neceločíselného řádu (FD) pro extrakci kinematických parametrů. Tyto parametry byly evaluovány pomocí metod strojového učení a statistické analýzy.

Byly navrženy čtyři nové metody extrakce parametrů založené na FD. Na základě konzultace s vedoucím práce byly k dalšímu testování vybrány dvě z nich: FD s vyšším rozlišením řádu a indexy časové paměti (TMI). Metoda využívající více hodnot řádu FD byla zvolena s ohledem na její přímou návaznost na dosavadní výzkum a teoretickou interpretovatelnost. TMI byly vybrány pro svou schopnost zachytit paměťový efekt signálu, což představuje potenciálně cenný nástroj pro analýzu rukopisu, kde může být míra časové konzistence pohybových vzorců klíčovým diskriminačním znakem.

Tyto parametry byly implementovány na databázi PaHaW konkrétně na záznamech rukopisů tří úkolů. Dále byla na parametrech provedena Pearsonova korelační analýza. Následně byly parametry využity k natrénování klasifikačních modelů, jejichž výkon byl hodnocen pomocí metrik: vyvážená přesnost (BACC), senzitivita (SEN), specifická (SPE) a F1 skóre.

Nejzajímavější výsledky korelační analýzy ukázaly vysoké pozitivní hodnoty korelace TMI parametrů Úkolu 9. (psací věta „Tramvaj dnes už nepojede.“). Nejvyšší korelace dosáhla hodnoty $\rho = 0.455$ a upravenou p-hodnotu na FDR $p_{adj} = 0.003$ (Tab. 9.6).

Nejlepší klasifikační výkon dosáhl model s 30 nejvýznamnějšími parametry z kombinované sady, s vyváženou přesností 0,79, senzitivitou 0,77, specifíciou 0,81 a F1 skóre 0,78. Výsledky naznačují, že kombinace více psacích úkolů může výrazně zlepšit přesnost detekce klinických změn.

Z výsledků je patrné, že metoda extrakce parametrů TMI představuje nadějně rozšíření nástrojů pro strojovou analýzu GP. Její schopnost kvantifikovat míru časové paměti v trajektoriích rukopisu se ukázala jako silný diskriminační prvek (zejména pro komplexnější záznamy), a proto by měla být dále zkoumána v kontextu diagnostiky Parkinsonovy nemoci.

Dále můžeme říci, že zvýšení rozlišení řádů FD mělo pozitivní dopad. Zejména parametry odvozené z nízkých řádů se zařadily mezi nejdůležitější v rámci klasifikačního modelu, což podporuje hypotézu, že jemnější rozlišení mezi hodnotami řádu může odhalit nové, diagnosticky relevantní rysy. Další navýšení rozlišení by tedy mohlo stát za otestování, zejména pro nízké řády.

Literatura

- [1] ALHUSAINI, A. A.; MELAM, G. R. a BURAGADDA, S. Short-term sensorimotor-based intervention for handwriting performance in elementary school children. *Pediatrics International*. Wiley Online Library. 2016, sv. 58, č. 11, s. 1118–1123.
- [2] ALTAN, G.; ALKAN, S. a BALEANU, D. A novel fractional operator application for neural networks using proportional Caputo derivative. *Neural Computing and Applications*. Springer. 2023, sv. 35, č. 4, s. 3101–3114.
- [3] AMERICAN PSYCHIATRIC ASSOCIATION. *Diagnostic and Statistical Manual of Mental Disorders, 5th Edition (DSM-5)*. Washington, DC: American Psychiatric Publishing, 2013. ISBN 978-0-89042-555-8. Dostupné z: <https://www.psychiatry.org/psychiatrists/practice/dsm>.
- [4] ARMSTRONG, M. J. a OKUN, M. S. Diagnosis and Treatment of Parkinson Disease: A Review. *JAMA*. Únor 2020, sv. 323, č. 6, s. 548–560. DOI: 10.1001/jama.2019.22360. ISSN 0098-7484. Dostupné z: <https://doi.org/10.1001/jama.2019.22360>.
- [5] ARSHAD, S.; BALEANU, D.; BU, W. a TANG, Y. Effects of HIV infection on CD4+ T-cell population based on a fractional-order model. *Advances in Difference Equations*. Březen 2017, sv. 2017, s. 92. DOI: 10.1186/s13662-017-1143-0.
- [6] ASCHERIO, A. a SCHWARZSCHILD, M. A. The epidemiology of Parkinson's disease: risk factors and prevention. *The Lancet Neurology*. Elsevier. 2016, sv. 15, č. 12, s. 1257–1272.
- [7] BARNETT, A. L.; PRUNTY, M. a ROSENBLUM, S. Development of the Handwriting Legibility Scale (HLS): A preliminary examination of Reliability and Validity. *Research in developmental disabilities*. Elsevier. 2018, sv. 72, s. 240–247.
- [8] BLOEM, B. R.; OKUN, M. S. a KLEIN, C. Parkinson's disease. *The Lancet*. 2021, sv. 397, č. 10291, s. 2284–2303. DOI: [https://doi.org/10.1016/S0140-6736\(21\)00218-X](https://doi.org/10.1016/S0140-6736(21)00218-X). ISSN 0140-6736. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S014067362100218X>.
- [9] BRABENEC, L.; KLOBUSIAKOVA, P.; MEKYSKA, J. a REKTOROVA, I. Shannon entropy: A novel parameter for quantifying pentagon copying performance in non-demented Parkinson's disease patients. *Parkinsonism & Related Disorders*. 2022, sv. 94, s. 45–48. DOI: <https://doi.org/10.1016/j.parkreldis.2021.11.037>.

ISSN 1353-8020. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1353802021004442>.

- [10] CAPUTO, M. Linear models of dissipation whose Q is almost frequency independent—II. *Geophysical journal international*. Blackwell Publishing Ltd Oxford, UK. 1967, sv. 13, č. 5, s. 529–539.
- [11] CHEN, T. et al. *XGBoost: Scalable and Flexible Gradient Boosting Library*. 2016. Accessed: 2025-05-22. Dostupné z: <https://github.com/dmlc/xgboost>.
- [12] CHEN, T. a GUESTRIN, C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. 2016, s. 785–794. DOI: <https://doi.org/10.1145/2939672.2939785>.
- [13] CHEN, T. a XGBOOST DEVELOPERS the. *XGBoost Documentation: Parameters*. 2024. Accessed: 2025-05-22. Dostupné z: <https://xgboost.readthedocs.io/en/stable/parameter.html>.
- [14] CONTRIBUTORS, X. *XGBoost Model Tutorial*. 2024. Accessed: 2024-12-11. Dostupné z: <https://xgboost.readthedocs.io/en/stable/tutorials/model.html>.
- [15] DE STEFANO, C.; FONTANELLA, F.; IMPEDOVO, D.; PIRLO, G. a SCOTTO DI FRECA, A. Handwriting analysis to support neurodegenerative diseases diagnosis: A review. *Pattern Recognition Letters*. 2019, sv. 121, s. 37–45. DOI: <https://doi.org/10.1016/j.patrec.2018.05.013>. ISSN 0167-8655. Graphonomics for e-citizens: e-health, e-society, e-education. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0167865518301880>.
- [16] DICKSON, D. W. Parkinson's disease and parkinsonism: neuropathology. *Cold Spring Harbor perspectives in medicine*. Cold Spring Harbor Laboratory Press. 2012, sv. 2, č. 8, s. a009258.
- [17] DROTÁR, P.; MEKYSKA, J.; REKTOROVÁ, I.; MASAROVÁ, L.; SMÉKAL, Z. et al. Evaluation of handwriting kinematics and pressure for differential diagnosis of Parkinson's disease. *Artificial Intelligence in Medicine*. 2016, sv. 67, s. 39–46. DOI: <https://doi.org/10.1016/j.artmed.2016.01.004>. ISSN 0933-3657. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0933365716000063>.
- [18] EDUCATION, U. D. of. *Identification of Specific Learning Disabilities. Office of Special Education Programs*. 2019. Dostupné z: https://sites.ed.gov/idea/files/Identification_of_SLD_10-4-06.pdf.

- [19] FEDER, K. P. a MAJNEMER, A. Handwriting development, competency, and intervention. *Developmental Medicine & Child Neurology*. Wiley Online Library. 2007, sv. 49, č. 4, s. 312–317.
- [20] FREUND, Y.; SCHAPIRE, R. E. et al. Experiments with a new boosting algorithm. In: Citeseer. *Icml*. 1996, sv. 96, s. 148–156.
- [21] GALAZ, Z.; MUCHA, J.; ZVONCAK, V.; MEKYSKA, J.; SMEKAL, Z. et al. Advanced Parametrization of Graphomotor Difficulties in School-Aged Children. *IEEE Access*. 2020, sv. 8, s. 112883–112897. DOI: 10.1109/ACCESS.2020.3003214.
- [22] GAVENCIÁK, M.; MUCHA, J.; MEKYSKA, J.; GALAZ, Z.; ZVONCAKOVÁ, K. et al. Computer-Aided Diagnosis of Graphomotor Difficulties Utilizing Direction-Based Fractional Order Derivatives. *Cognitive Computation*. 2024, sv. 17, č. 1, s. 13. DOI: 10.1007/s12559-024-10360-7. ISSN 1866-9964. Dostupné z: <https://doi.org/10.1007/s12559-024-10360-7>.
- [23] GAVENČIAK, M.; MUCHA, J.; MEKYSKA, J.; GALÁŽ, Z.; ZVONČÁKOVÁ, K. et al. Computer-Aided Diagnosis of Graphomotor Difficulties Utilizing Direction-Based Fractional Order Derivatives. *Available at SSRN 4654220*. 2023. DOI: <https://dx.doi.org/10.2139/ssrn.4654220>. Dostupné z: <https://ssrn.com/abstract=4654220>.
- [24] GOOGLE. *Random forests*. N.d. Accessed: 2024-12-11. Dostupné z: <https://developers.google.com/machine-learning/decision-forests/random-forests>.
- [25] HERRERA ALCÁNTARA, O. a CASTELÁN AGUILAR, J. R. Fractional Gradient Optimizers for PyTorch: Enhancing GAN and BERT. *Fractal and Fractional*. 2023, sv. 7, č. 7. DOI: 10.3390/fractalfrac7070500. ISSN 2504-3110. Dostupné z: <https://www.mdpi.com/2504-3110/7/7/500>.
- [26] KIM, S.-Y.; JEITNER, T. M. a STEINERT, P. M. Transglutaminases in disease. *Neurochemistry International*. 2002, sv. 40, č. 1, s. 85–103. DOI: [https://doi.org/10.1016/S0197-0186\(01\)00064-X](https://doi.org/10.1016/S0197-0186(01)00064-X). ISSN 0197-0186. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S019701860100064X>.
- [27] KUNHOTH, J.; AL MAADEED, S.; KUNHOTH, S.; AKBARI, Y. a SALEH, M. Automated systems for diagnosis of dysgraphia in children: A survey and novel framework. *International Journal on Document Analysis and Recognition (IJDAR)*. Springer. 2024, s. 1–29. DOI: <https://doi.org/10.1007/s10032-024-00464-z>.

- [28] LAZAREVIĆ, M. Further results on fractional order control of a mechatronic system. *Scientific Technical Review, ISSN*. 1820, sv. 206, s. 2013.
- [29] LECUN, Y. LeNet-5, Convolutional Neural Networks. *Proceedings of the IEEE*. 1989, sv. 86, č. 11, s. 2299–2318. Dostupné z: <https://ieeexplore.ieee.org/document/1100004>.
- [30] LETANNEUX, A.; DANNA, J.; VELAY, J.-L.; VIALLET, F. a PINTO, S. From micrographia to Parkinson's disease dysgraphia. *Movement Disorders*. 2014, sv. 29, č. 12, s. 1467–1475. DOI: <https://doi.org/10.1002/mds.25990>. Dostupné z: <https://movementdisorders.onlinelibrary.wiley.com/doi/abs/10.1002/mds.25990>.
- [31] LUCHKO, Y. a GORENFLO, R. An operational method for solving fractional differential equations with the Caputo derivatives. *Acta Math. Vietnam*. 1999, sv. 24, č. 2, s. 207–233.
- [32] MCCLOSKEY, M. a RAPP, B. Developmental dysgraphia: An overview and framework for research. *Cognitive Neuropsychology*. Routledge. 2017, sv. 34, 3-4, s. 65–82. DOI: 10.1080/02643294.2017.1369016. PMID: 28906176. Dostupné z: <https://doi.org/10.1080/02643294.2017.1369016>.
- [33] MCHALE, K. a CERMAK, S. A. Fine motor activities in elementary school: Preliminary findings and provisional implications for children with fine motor problems. *The American journal of occupational therapy*. The American Occupational Therapy Association, Inc. 1992, sv. 46, č. 10, s. 898–903.
- [34] MCLENNAN, J.; NAKANO, K.; TYLER, H. a SCHWAB, R. Micrographia in Parkinson's disease. *Journal of the Neurological Sciences*. 1972, sv. 15, č. 2, s. 141–152. DOI: [https://doi.org/10.1016/0022-510X\(72\)90002-0](https://doi.org/10.1016/0022-510X(72)90002-0). ISSN 0022-510X. Dostupné z: <https://www.sciencedirect.com/science/article/pii/0022510X72900020>.
- [35] MEKYSKA, J.; FAUNDEZ ZANUY, M.; MZOUREK, Z.; GALAZ, Z.; SMEKAL, Z. et al. Identification and Rating of Developmental Dysgraphia by Handwriting Analysis. *IEEE Transactions on Human-Machine Systems*. 2017, sv. 47, č. 2, s. 235–248. DOI: 10.1109/THMS.2016.2586605.
- [36] MOINI, J.; LOGALBO, A. a SCHNELLMANN, J. G. Chapter 15 - Pharmacology of Parkinson's disease. In: MOINI, J.; LOGALBO, A. a SCHNELLMANN, J. G., ed. *Neuropsychopharmacology*. Academic Press, 2023, s. 257–274. DOI: <https://doi.org/10.1016/B978-0-323-95974-2.00021-9>. ISBN 978-0-

323-95974-2. Dostupné z: <https://www.sciencedirect.com/science/article/pii/B9780323959742000219>.

- [37] MUCHA, J.; GALAZ, Z.; MEKYSKA, J.; FAUNDEZ ZANUY, M.; ZVONCAK, V. et al. Exploration of Various Fractional Order Derivatives in Parkinson's Disease Dysgraphia Analysis. In: CARMONA DUARTE, C.; DIAZ, M.; FERRER, M. A. a MORALES, A., ed. *Intertwining Graphonomics with Human Movements*. Cham: Springer International Publishing, 2022, s. 308–321. ISBN 978-3-031-19745-1.
- [38] MUCHA, J.; MEKYSKA, J.; GALAZ, Z.; FAUNDEZ ZANUY, M.; IPINA, K. Lopez-de et al. Identification and Monitoring of Parkinson's Disease Dysgraphia Based on Fractional-Order Derivatives of Online Handwriting. *Applied Sciences*. 2018, sv. 8, č. 12. DOI: 10.3390/app8122566. ISSN 2076-3417. Dostupné z: <https://www.mdpi.com/2076-3417/8/12/2566>.
- [39] MUCHA, J.; MEKYSKA, J.; GALAZ, Z.; FAUNDEZ ZANUY, M.; ZVONCAK, V. et al. Analysis of Various Fractional Order Derivatives Approaches in Assessment of Graphomotor Difficulties. *IEEE Access*. 2020, sv. 8, s. 218234–218244. DOI: 10.1109/ACCESS.2020.3042591.
- [40] OLIVEIRA, E. C. d. a MACHADO, J. A review of definitions for fractional derivatives and integral. *Mathematical Problems in Engineering*. Hindawi. 2014, sv. 2014, s. 1–7. DOI: <https://doi.org/10.1155/2014/238459>.
- [41] PERSECHINO, A. An introduction to fractional calculus. *Advanced Electromagnetics*. Advanced Electromagnetics. únor 2020, sv. 9, č. 1, s. 19–30. DOI: 10.7716/aem.v9i1.1192. ISSN 2119-0275. Dostupné z: <http://dx.doi.org/10.7716/aem.v9i1.1192>.
- [42] PINTO, C. M. a TENREIRO MACHADO, J. Fractional model for malaria transmission under control strategies. *Computers & Mathematics with Applications*. 2013, sv. 66, č. 5, s. 908–916. DOI: <https://doi.org/10.1016/j.camwa.2012.11.017>. ISSN 0898-1221. Fractional Differentiation and its Applications. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0898122112006785>.
- [43] PODLUBNY, I. Fractional differential equations : an introduction to fractional derivatives, fractional differential equations, to methods of their solution and some of their applications. In.: 1999. Dostupné z: <https://api.semanticscholar.org/CorpusID:124040597>.

- [44] ROSENBLUM, S. Development, reliability, and validity of the Handwriting Proficiency Screening Questionnaire (HPSQ). *The American Journal of Occupational Therapy*. The American Occupational Therapy Association, Inc. 2008, sv. 62, č. 3, s. 298–307.
- [45] ROSENBLUM, S. Inter-relationships between objective handwriting features and executive control among children with developmental dysgraphia. *PloS one*. Public Library of Science San Francisco, CA USA. 2018, sv. 13, č. 4, s. e0196098. DOI: 10.1371/journal.pone.0196098.
- [46] ROSENBLUM, S. a DROR, G. Identifying Developmental Dysgraphia Characteristics Utilizing Handwriting Classification Methods. *IEEE Transactions on Human-Machine Systems*. 2017, sv. 47, č. 2, s. 293–298. DOI: 10.1109/THMS.2016.2628799.
- [47] ROSENBLUM, S.; SAMUEL, M.; ZLOTNIK, S.; ERIKH, I. a SCHLESINGER, I. Handwriting as an objective tool for Parkinson’s disease diagnosis. *Journal of neurology*. Springer. 2013, sv. 260, s. 2357–2361. DOI: 10.1007/s00415-013-6996-x.
- [48] SAMKO, S. G.; KILBAS, A. A. a MARICHEV, O. I. Fractional Integrals and Derivatives: Theory and Applications. In: 1993. Dostupné z: <https://api.semanticscholar.org/CorpusID:118631078>.
- [49] SUN, H.; ZHANG, Y.; BALEANU, D.; CHEN, W. a CHEN, Y. A new collection of real world applications of fractional calculus in science and engineering. *Communications in Nonlinear Science and Numerical Simulation*. 2018, sv. 64, s. 213–231. DOI: <https://doi.org/10.1016/j.cnsns.2018.04.019>. ISSN 1007-5704. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1007570418301308>.
- [50] THAI, H.-T. Machine learning for structural engineering: A state-of-the-art review. *Structures*. 2022, sv. 38, s. 448–491. DOI: <https://doi.org/10.1016/j.istruc.2022.02.003>. ISSN 2352-0124. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S2352012422000947>.
- [51] THOMAS, M.; LENKA, A. a KUMAR PAL, P. Handwriting analysis in Parkinson’s disease: current status and future directions. *Movement disorders clinical practice*. Wiley Online Library. 2017, sv. 4, č. 6, s. 806–818. DOI: <https://doi.org/10.1002/mdc3.12552>.
- [52] UCHAIKIN, V. *Fractional Derivatives for Physicists and Engineers: Volume I Background and Theory Volume II Applications*. Springer Berlin Heidelberg,

2013. Nonlinear Physical Science. ISBN 9783642339103. Dostupné z: https://books.google.cz/books?id=R_lzxxgEACAAJ.
- [53] VAN WAELVELDE, H.; HELLINCKX, T.; PEERSMAN, W. a SMITS ENGELSMAN, B. C. SOS: A screening instrument to identify children with handwriting impairments. *Physical & occupational therapy in pediatrics*. Taylor & Francis. 2012, sv. 32, č. 3, s. 306–319.
- [54] VÁRADI, C. Clinical Features of Parkinson’s Disease: The Evolution of Critical Symptoms. *Biology*. 2020, sv. 9, č. 5. DOI: 10.3390/biology9050103. ISSN 2079-7737. Dostupné z: <https://www.mdpi.com/2079-7737/9/5/103>.
- [55] WACOM. *Technologies*. 2025. Přístup: 23. května 2025. Dostupné z: <https://www.wacom.com/en-us/about-wacom/technologies>.
- [56] WACOM CO., LTD.. *Intuos4 User’s Manual* [<https://cdn.wacom.com/u/productsupport/manuals/Intuos4/User%27s%20Manual.pdf>]. Kazo, Japan: Wacom, 2009. User manual for Wacom Intuos4 pen tablet. Dostupné z: <https://cdn.wacom.com/u/productsupport/manuals/Intuos4/User%27s%20Manual.pdf>.
- [57] WORLD HEALTH ORGANIZATION. *International Statistical Classification of Diseases and Related Health Problems, 10th Revision (ICD-10)*. Geneva: World Health Organization, 1992. ISBN 978-92-4-154420-6. Dostupné z: <https://www.who.int/classifications/icd/en/>.
- [58] ZVONCAK, V.; MUCHA, J.; GALAZ, Z.; MEKYSKA, J.; SAFAROVA, K. et al. Fractional Order Derivatives Evaluation in Computerized Assessment of Handwriting Difficulties in School-aged Children. In: *2019 11th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT)*. 2019, s. 1–6. DOI: 10.1109/ICUMT48472.2019.8970811.
- [59] ZVONČÁK, V.; MEKYSKA, J.; ŠAFÁROVÁ, K.; MUCHA, J.; KISKA, T. et al. Vliv intra-writer normalizace na diagnózu vývojové dysgrafie založené na kvantitativní analýze online písma. *Elektrorevue*. 2018, sv. 20, č. 6, s. 177–181. ISSN 1213-1539. [Online; cit. 2025-05-23]. Dostupné z: <http://hdl.handle.net/11012/214224>.