



SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Ing. Boris Nerušil

Autoreferát dizertačnej práce

Detekcia dyslexie metódami strojového učenia

na získanie akademického titulu: „doktor“ („philosophiae doctor“, v skratke „PhD.“)

v doktorandskom študijnom programe: telekomunikácie

v študijnom odbore: informatika

Forma štúdia: denná

Miesto a dátum: Bratislava, jún 2022



Dizertačná práca bola vypracovaná na

Ústav multimediálnych informačných a komunikačných technológií
Fakulta elektrotechniky a informatiky
Slovenská technická univerzita v Bratislave

Predkladateľ:

Ing. Boris Nerušil
Slovenská technická univerzita v Bratislave
Fakulta elektrotechniky a informatiky
Ústav multimediálnych informačných a komunikačných technológií
Ilkovičova 3, 812 19 Bratislava 1

Školiteľ:

prof. Ing. Jaroslav Polec, PhD.
Slovenská technická univerzita v Bratislave
Fakulta elektrotechniky a informatiky
Ústav multimediálnych informačných a komunikačných technológií
Ilkovičova 3, 812 19 Bratislava 1

Oponenti:

doc. Ing. Libor Hargaš, PhD.
Žilinská univerzita
Fakulta elektrotechniky a informačných technológií
Katedra mechatroniky a elektroniky
Oddelenie špeciálnej elektroniky
Univerzitná 8215/1, 010 26 Žilina

doc. Ing. Miroslav Hagara, PhD.
Slovenská technická univerzita v Bratislave
Fakulta elektrotechniky a informatiky
Katedra rádioelektroniky
Oddelenie rádiokomunikačnej a multimediálnej techniky
Ilkovičova 2961/3841 04 Karlova Ves

Autoreferát bol rozoslaný:

.....

Obhajoba dizertačnej práce sa bude konať dňa2022 oh.

na

.....
prof. Dr. Ing. Miloš Oravec

Obsah

1 Úvod	4
2 Stručný prehľad problematiky	5
2.1 Výskumy venujúce sa detekcii dyslexie na základe textu	5
2.2 Výskumy venujúce sa detekcii dyslexie na základe očných pohybov	5
2.3 Výskumy venujúce sa detekcii dyslexie na základe MRI skenov	6
2.4 Výskumy venujúce sa detekcii dyslexie na základe EEG skenov	6
2.5 Publikácia: Advance Machine Learning Methods for Dyslexia Biomarker Detection: A Review of Implementation Details and Challenges [UMO21]	6
2.6 Publikácia: Dysgraphia detection through machine learning [DrD20]	7
3 Ciele dizertačnej práce	8
4 Zvolené metódy riešenia	9
4.1 Detekcia na základe fixácií	9
4.2 Detekcia na základe časového priebehu a magnitudového spektra	10
5 Experiment	11
5.1 Dataset	11
5.2 Prvotné upravenie dát	12
5.3 Triedenie použitím histogramu na základe trvania čítania textu	13
5.4 Triedenie dát pomocou kmeans na základe fixácií	13
5.5 Klasifikácia dát metódou KNN na základe fixácií	13
5.6 Triedenie dát pomocou kmeans a klasifikácia pomocou KNN na základe magnitudo-vého spektra interpolovaného signálu	14
5.7 Klasifikácia dát konvolučnou neurónovou sieťou	15
5.7.1 Klasifikácia dát s využitím informácie len o x-ových súradniciach	16
5.7.2 Klasifikácia dát s využitím informácie o x-ových a y-ových súradniciach	20
5.8 Klasifikácia dát váženého spektra – logaritmickou funkciou	22
5.9 Aplikácia navrhutej metódy na subjekty s dysgrafiou	22
Dosiahnuté výsledky metód a ich vyhodnotenie	24
Záver	25
Resumé	26
Zoznam publikácií autora	27
Publikácie týkajúce sa dizertačnej práce	27
Riešené výskumné úlohy	28
Zoznam použitej literatúry	29

1 Úvod


Zrak je jeden z našich najdôležitejších piatich zmyslov. Zmyslovým orgánom sú oči, ktorými je možné získať veľké množstvo informácií okolo nás. Očné pohyby jedinca sú veľkým zdrojom informácií, ktorými sa môžu zisťovať kognitívne procesy. Zaznamenávanie a spracovanie očných pohybov má široké využitie, či už napríklad pre reklamné účely na webstránkach, ale takisto pomohli aj zodpovedať viacero výskumných otázok.

Od roku 1998 bolo vydaných veľa významných vedeckých publikácií so zameraním na modelovanie a sledovanie vizuálnej pozornosti na zisťovanie kognitívnych porúch u jedincov. Metóda zaznamenávania očných pohybov je jednou z najuniverzálnejších metód na študovanie a spracovanie ľudského správania. Zachytávanie očných pohybov sa vykonáva prostredníctvom zariadenia eye tracker, pomocou ktorého sme schopní vytvárať cesty vizuálnej pozornosti, či už pri pohybe oka počas čítania alebo sledovania obrazov. Následne vieme kognitívne poruchy u subjektov vyhodnocovať vďaka rozdielom pohybov očí, ktoré predstavujú základné ukazovatele kognitívnych procesov.

Pri detekcii osôb so schizofréniou boli používané roscharchové obrazce [KPC19], pri detekcii stareckej demencie a dyslexie bol subjektom predložený text na čítanie. [YHE18][MKA15][KIE19] Dyslexia patrí medzi poruchy, ktoré ovplyvňujú kognitívne funkcie. Bol zistený rozdiel pohybu očí počas čítania textu u subjektov s dyslexiou a u nedyslektických subjektov. Dyslexia je špecifická porucha neurobiologického pôvodu, ktorá ovplyvňuje čítanie a učenie subjektov. Odhaduje sa, že postihuje 10% celkovej populácie sveta. Medzi najcharakteristickejšie rozdiely medzi subjektami s dyslexiou a bez dyslexie zaraďujeme rozdiely v čítaní. Na dekodovanie určitých zložitejších slov vyžadujú jedinci s dyslexiou dlhší čas, čo predstavuje, že pri očných pohyboch evidujeme dlhšie trvajúce a častejšie sa vyskytujúce sa fixácie na niektoré slová, čo vedie ku kratším očným pohybom nazývajúcich sa sakády.

2 Stručný prehľad problematiky

V posledných rokoch prebiehalo viacero výskumov venujúcich sa klasifikáciám kognitívnych porúch – demencia, Alzheimerova choroba, schizofrénia, autizmus. [MiF20, FFK17, YHE18, MKA15] V práci sa zameriame na detekciu jedincov s dyslexiou, ktorá sa prejavuje ako porucha čítania. Táto kapitola zachytáva súhrn najvýznamnejších publikácií zameriavajúcich sa na detekciu dyslexie. V tejto časti opíšeme metódy klasifikácie dyslexie inými metódami s využitím techniky strojového učenia. [BSY16, Kai20, LCF15, ReB15, PGA17, KCB18, RRR18, FrM18, PSW18, HAM18, AMP19, RZŽ19, SCS19, CXS16] Publikácie sa zaoberajú rozličnými metódami na detekciu dyslexie detegovanú viacerými spôsobmi, napr. – testy založené na čítaní, webové slovné hry, sledovanie pohybov očí počas čítania, MRI alebo EEG. Strojové učenie zohráva dôležitú úlohu pri klasifikácii. Pomocou neho je možné dosiahnuť vyššiu úspešnosť klasifikácie. Je časovo aj finančne menej náročné ako iné používané metódy. Nakoľko sa u jedincov s dyslexiou často vyskytuje pridružená kognitívna porucha – dysgrafia prejavujúca sa ako porucha písania, tak na overenie navrhnutej metódy opísanej v kapitole 4, sme porovnali dosiahnuté ACC výsledky s publikáciou Dysgraphia detection through machine learning. [DrD20] Detekcia pomocou strojového učenia pozostáva zo 4 hlavných krokov, vid' Obr .1.



Obr. 1 Postup pri strojovom učení na detekciu kognitívnych porúch [Kai20]

2.1 Výskumy venujúce sa detekcii dyslexie na základe textu

Pri tejto metóde je klasifikácia vykonaná na základe textových údajov poväčšine chybných dvojíc slov. Výskumy venujúce sa tejto problematike sú Lakretz et al [LCF15], Rello et al [RRR18], Khan et al [KCB18].

2.2 Výskumy venujúce sa detekcii dyslexie na základe očných pohybov

Očnými pohybmi je možné sledovať a vytvoriť vizuálnu cestu subjektu. Väčšina súčasných výskumov sa venuje detekcii dyslexie na základe očných pohybov, ktoré sú vstupom do klasifikátora – najčastejšie počas čítania, nakoľko jedinec s dyslexiou má rozdielny pohyb oka ako bežný čitateľ – viac regresných sakád, fixácií a dopredných sakád. Publikácie venujúce sa klasifikácii na základe očných pohybov sú: Asvestopoulou et al. [AMP19], Benfatto et al. [BSY16], Rello and Ballesteros. [ReB15]

2.3 Výskumy venujúce sa detekcii dyslexie na základe MRI skenov

V tejto metóde sa autori publikácií Plonski et al [PGA17]. a Cui et al [CXS16] zamerali na detekciu dyslexie na základe MRI snímok mozgu počas aktivity – čítania. Následne získané dáta spracovali, a tie slúžili ako vstup do klasifikátora.

2.4 Výskumy venujúce sa detekcii dyslexie na základe EEG skenov

V tejto metóde sa autori publikácií Frid and Manevitz [FrM18], Perera et.al [PSW18], Rezvani et al. [RZŽ19] zamerali na detekciu dyslexie na základe ERP signálov mozgu počas aktivity – čítania alebo písania. Následne získané dáta spracovali, a tie slúžili ako vstup do klasifikátora.


2.5 Publikácia: Advance Machine Learning Methods for Dyslexia Biomarker Detection: A Review of Implementation Details and Challenges [UMO21]

Autori v danom článku analyzujú a porovnávajú 22 vybraných výskumných prác zameriavajúcich sa na detekciu dyslexie prostredníctvom najnovších metód strojového učenia. Porovnávané výskumné práce boli publikované v rozmedzí rokov 2010 až 2020. Články boli najprv zvolené pomocou elektronického vyhľadávania literatúry, následne sa vylúčili duplikáty a 84 prác bolo poskytnutých trom recenzentom. [UMO21] Na Obr. 2 je zobrazené ročné rozdelenie 84 článkov posudzovaných recenzentmi. Najviac článkov bolo uverejnených práve v rozmedzí rokov 2014 až 2019 (64 článkov). Ďalších 18 článkov bolo publikovaných medzi rokmi 2010 a 2013 a napokon 2 články pochádzajú z roku 2020.



Obr. 2 Počet publikácií v priebehu rokov venujúcich sa klasifikácii dyslexie [UMO21]

Na detekciu pohybov očí a následnú klasifikáciu dyslektických a nedyslektických subjektov použili eye trackery a štatistické metódy založené na disperzii a rýchlosti. Autori poukazujú na vzostup používania algoritmov hlbokého učenia a tradičných metód strojového učenia v poslednom čase. Jedná sa najmä o SVM, DT, RF, lineárnu regresiu, logistickú regresiu, KNN, Naïve Bayes, LDA, ANN a CNN. Hlavnou úlohou článku je vyhodnotiť prínos, význam a obmedzenia nedávnych výskumných prác, ktoré využívajú práve tieto metódy na detekciu dyslexie. Daná štúdia sa zameriava na zber dát, ich prípravu a predspracovanie, extrakciu a výber príznakov, tréning, klasifikáciu a vyhodnotenie. Na nasledujúcom Obr. 3 môžeme vidieť rozdelenie využitia metód strojového učenia z vybraných 22 výskumných prác.



Obr. 3 Rozdelenie klasifikátorov, ktoré boli použité v 22 článkoch venujúcich sa klasifikácii dyslexie [UMO21]


Autori jednotlivých publikácií použili na klasifikovanie subjektov rozdielne algoritmy klasifikácie – klasifikátory. [UMO21] Najčastejšie použitý klasifikátor je model strojového učenia SVM – 13 publikácií, ANN 5 štúdií, KNN - 4, CNN - 4, LR, RF – po 3 publikáciách, Naivný Bayes a kmeans po 2 publikáciách. [UMO21] Hlavným kritériom celkovej úspešnosti bola ACC, nasledovalo: TPR, TNR, PPV, NPV, F1-skóre, AUC krivka, ROC krivka, MSE [UMO21]. Taktiež autori na validáciu výsledkov použili rozdielne krížové validácie, napr. k-priečinkovú krížovú validáciu, kde $k=4, \dots, 10$ [SSC19, PGA17, ZGS20, UsM20, RRR18], najčastejšie použitá 10-fold CV, čo znamená, že dáta boli rovnomerne rozdelené do 10 priecinkov a 9 priecinkov slúžilo na tréning a zvyšný 1 slúžil na validáciu a testovanie, alebo LOOCV (leave-one-out-cross-validation). [PGA17, CXS16, RZZ19]

Pre porovnanie jednotlivých metód zberu dát je ACC nasledovná [UMO21]

- Zber dát prostredníctvom testov – 73,9% - 99%
- Zber dát prostredníctvom rukopisu – 55,7% - 77,6%
- Zber dát prostredníctvom EEG – 78% - 95,9%
- Zber dát prostredníctvom MRI – 64% - 94,8%
- Zber dát prostredníctvom videa – 77,6% - 97,8%
- Zber dát prostredníctvom eye trackingu – 80,2% - 95,6%

2.6 Publikácia: Dysgraphia detection through machine learning [DrD20]

Autormi vybraný dataset sa skladá zo vzoriek 120 subjektov vo veku 8 až 15 rokov, pričom z týchto účastníkov bolo 40 dievčat a 80 chlapcov. 16 subjektov malo ľavú dominantnú ruku a zvyšok subjektov pravú. Vekové rozpätie subjektov je pomerne veľké a klasifikáciu robí náročnejší aj fakt, že v týchto rokoch sa subjekty ešte stále vyvíjajú. U 57 subjektov sa potvrdila dysgrafia a zvyšných 63 sa vyvíjali normálne. Počas testu mali subjekty rôzne úlohy, najprv to bolo napísať písmeno „l“, slabiku „le“ a slovo „leto“ pri bežnom a rýchlom písaní, ďalej vymyslené slovo „lamoken“ a náročné slovo „hračkárstvo“. Poslednou úlohou bolo napísať celú vetu, a to „V lete bude teplo a sucho“.



Obr. 4 Vzor rukopisu dysgrafia a zachytené signály tabletom. Červená bodkovaná čiara znázorňuje pohyb vo vzduchu. [DrD20]

Navrhnutý klasifikačný model má slúžiť na triedenie vzoriek na subjekty s dysgrafiou a na normálne vyvíjajúce sa subjekty bez dysgrafie. Počas výskumu vyskúšali mnoho klasifikačných algoritmov, avšak najviac upriamili svoju pozornosť na nelineárne klasifikátory. Uskutočnili 10-násobný krížový validačný proces, ktorý zopakovali 10-krát. Najväčšiu úspešnosť dosiahli autori pri použití nelineárnych klasifikátorov Adaboost, a to 79,5%, SVM a RF dosiahli v porovnaní s Adaboost nižšiu úspešnosť. Celková úspešnosť klasifikátora SVM predstavuje 78,8% a RF 77,6%. Autori použili aj klasifikátory ako sú rozhodovacie stromy, KNN, naivný Bayes a logistickú regresiu, avšak výsledky boli oveľa horšie, a preto ich neuvádzajú.

3 Ciele dizertačnej práce

Na základe preštudovanej odbornej literatúry je hlavným cieľom porovnať pohyby očí subjektov s dyslexiou a subjektov s normálnymi čitateľským výkonom pri čítaní určitého textu s využitím zariadenia eye tracker na zachytenie očných pohybov. Pri existujúcich dosiahnutých výsledkoch z rôznych štúdií môžeme formulovať tieto hypotézy:

H1: Subjekty s dyslexiou potrebujú dlhší čas na prečítanie textu ako subjekty s normálnymi čitateľským výkonom

H2: Subjekty s dyslexiou potrebujú viac fixácií na prečítanie textu ako subjekty s normálnym čitateľským výkonom

H3: Subjekty s dyslexiou potrebujú viac regresívnych sakád na prečítanie textu ako subjekty s normálnymi čitateľským výkonom

Otázkou je: Je možné pomocou konvenčnej teórie signálov upraviť signály tak, že sa zvýši úspešnosť klasifikácie subjektov, ktorými ich opisujeme?

Z týchto hypotéz a výskumnej otázky stanovujeme nasledujúce ciele dizertačnej práce:

1. Navrhnuť vhodnú metódu na spracovanie signálov získaných pozorovaním subjektov s dyslexiou a subjektov s normálnymi čitateľským výkonom prispievajúcej k úspešnej diagnostike tejto kognitívnej poruchy.
2. Navrhnuť vhodnú metódu alebo modifikovať existujúcu metódu na klasifikáciu subjektov s dyslexiou a subjektov s normálnymi čitateľským výkonom s využitím predspracovania signálov získaných pozorovaním subjektov.

V dizertačnej práci naviažeme na výskum [BSY16] – Screening for dyslexia using eye tracking during reading venujúci sa zisťovaniu dyslexie prostredníctvom očných pohybov u subjektov počas čítania. Celkovo získali 168 príznakov zachytávajúcich rozličné kvantitatívne parametre očí počas čítania textu, napr.: trvanie, amplitúda, smer, stabilita a symetria. Prostredníctvom metódy rekurzívna eliminácia funkcií – RFE sa celá sada zmenšila na 48 znakov. Následne boli dáta klasifikované prostredníctvom metódy Support vector machine (SVM), ktorá spolu s RFE vytvára metódu SVM-RFE. V našej metóde sme sa rozhodli nebrať do úvahy rozličné typy pohybov očí, ale zdrojové signály X-Y súradníc vyjadrené v časovej oblasti alebo vyjadrené vo frekvenčnej oblasti, predspracované a klasifikované príslušným klasifikátorom. Naším cieľom je zistiť, či je možné na tento problém použiť konvenčnú teóriu signálov v spolupráci s modernými nástrojmi klasifikácie.

Naša práca bude vychádzať z nasledujúcich predpokladov:

1. Celkový čas potrebný na prečítanie celého textu je u detí s poruchou čítania (HR) výrazne väčší ako u detí bez poruchy čítania (LR).
2. Predpoklad 1 neplatí pre všetky deti. To znamená, že rozhodovacie kritérium celkový čas čítania určite prinesie chybu klasifikácie. Pozri Obr. 33.
3. Časový priebeh hodnôt x-ových súradníc zaznamenaných očných pohybov u LR detí má pílovitý priebeh, ktorý v ideálnom prípade má toľko maxim (zubov), koľko je riadkov prečítaného textu a každý zub má lineárny priebeh.
4. Časový priebeh hodnôt x-ových súradníc zaznamenaných očných pohybov u HR detí má pílovitý priebeh, ktorý vyjadruje aj návraty počas čítania jednotlivých riadkov. To deformuje ideálnu pílu tak, že pôvodný jeden zub pozostáva z viacerých podzubov.
5. Ak by všetky LR aj HR deti prečítali text za rovnaký čas, spektrum pílovitého signálu podľa predpokladu 3 bude výrazne kratšie ako spektrum signálu podľa predpokladu 4.

4 Zvolené metódy riešenia

V kapitole opíšeme zvolené metódy návrhu riešenia klasifikácie dyslexie. V prípade navrhnutých metód na klasifikáciu dyslexie predpokladáme ako vstupné dáta časovú postupnosť súradníc (x, y), získanú zo zariadenia eye tracker pri čítaní ľubovoľného textu.

4.1 Detekcia na základe fixácií

V návrhu tejto metódy vhodnej na klasifikovanie dyslexie sme sa rozhodli zamerať na očné pohyby jedincov, konkrétne len na fixácie, aby sme zistili, nakoľko sú dôležité, keďže autori [BSY16] nesledovali dôležitosť jednotlivých príznakov, ktoré vo svojom experimente použili. Výber robili vždy so skupinou rôznych príznakov. Vychádzali sme z hypotézy číslo 2, že pri subjektoch s dyslexiou pri čítaní textu bude dochádzať k častejším fixáciám ako v skupine subjektov s normálnym čitateľským výkonom. V návrhu Obr. 5 si zadefinujeme citlivosť na základe fixácií a aplikovaním Euklidovej vzdialenosti na dataset určíme hodnotu, podľa ktorej rozhodneme, či v danom momente ide o fixáciu.

Snažíme sa o čo najdôveryhodnejšie určenie, čo je a čo nie je fixácia. Následne vypočítame hodnoty vektora príznakov, pozostávajúceho z:

- Počet fixácií
- Priemerná dĺžka v počte riadkov



Obr. 5 Bloková schéma klasifikácie na základe fixácii

Ako klasifikátor navrhujeme použiť niektorý z jednoduchších klasifikátorov napr. KNN z dôvodu predpokladanej nižšej úspešnosti detekcie v prospech rýchlosti.

4.2 Detekcia na základe časového priebehu a magnitudového spektra

Podľa načrtnutých predpokladov sme sa v súlade s nimi rozhodli navrhnúť nasledujúce varianty metódy klasifikácie so vstupmi s rovnakou dĺžkou:

1. Doplnenie signálu nulami a klasifikovanie časového priebehu
2. Doplnenie signálu nulami a klasifikovanie magnitudového spektra
3. Interpolácia a klasifikovanie časového priebehu
4. Interpolácia a klasifikovanie magnitudového spektra

V prvom Obr. 6a a druhom Obr. 6b variante metódy budú signály doplnené nulami, aby sa signály dorovnali na rovnakú dĺžku ako u najpomalšieho čítajúceho (predpoklad 1) a vo variante 2 sa použije aj DFT na výpočet spektra. Pri 3. Obr. 6c a 4. Obr. 6d variante metódy budeme postupovať s ohľadom na predpoklady 1 až 5 opísané v kapitole 3 a zameriame sa na predpoklad číslo 5. V ňom je potreba rovnakej dĺžky času čítania celého textu u všetkých subjektov – zo skupiny dyslektikov aj skupiny subjektov s normálnym čitateľským výkonom, čím by sme mali aj zároveň eliminovať chyby podľa predpokladu 1. Tento predpoklad docielime interpolovaním harmonickými funkciami preferovanými pri spracovaní obrazu. Ako vhodnú sme zvolili metódu interpolácie pomocou diskkrétnej kosínusovej transformácie 3. [RPK97]


$$DCT3_{U_{k,n}} = \sqrt{\frac{2}{N}} c_n \cos\left(\frac{\pi((2k+1)n)}{2N}\right) \quad (7)$$

$$k = 0, 1, \dots, N-1, n = 0, 1, \dots, N-1,$$

kde k predstavuje poradie spektrálnej zložky a n časové indexy.

Pre výpočet spektra sa použije štandardná DFT a z neho len magnitudové spektrum. Magnitudové spektrum by malo dostatočne opísať výkonovo pílovitý charakter signálu a zároveň aj disproporciu v šírke zubov u nedyslektických detí a u dyslektických subjektov. Magnitudové spektrum je nezávislé od toho, v ktorom riadku čítaného textu má dyslektický subjekt problém s čítaním a musí sa vracieť (to je v spektre vyjadrené fázou). Toto by možno spĺňala aj niektorá z nekomplexných ortogonálnych báz, ale pri DFT stačí na reprezentáciu magnitudového spektra len polovica spektrálnych zložiek. Rozdiel medzi variantmi je, že pri treťom sa budeme zaoberať interpoláciou a klasifikáciou časového priebehu a pri štvrtom

klasifikáciou spektra. Ďalšou možnosťou rozšírenia je použitie váženého spektra vhodnou funkciou, napríklad logaritmom.




Obr. 6 Bloková schéma klasifikácie na základe časového priebehu a magnitudového spektra

V tejto metóde predpokladáme vyššiu úspešnosť preto navrhujeme ako nosný klasifikátor použiť CNN a ako jednoduchý, výpočtovo a časovo menej náročný variant klasifikátor KNN.

5 Experiment

5.1 Dataset

Dataset nadobudnutý zo švédskej výskumnej úlohy obsahoval pohyby pravého oka v súradniciach x a y a ľavého oka takisto v súradniciach x a y počas čítania textu pre celkovo 185 subjektov. [BSY16] Subjekty navštevovali 3. ročník na základnej škole a boli vo veku od 9 do 10 rokov. Subjekty boli roztriedené do dvoch skupín. Prvá skupina obsahovala 97 jedincov, u ktorých bola zistená dyslexia, tzv. skupina HR, pričom chlapcov bolo 76 a dievčat 21. V druhej skupine sa nachádzalo 88 subjektov bez klasifikovanej dyslexie, z toho 69 chlapcov a 19 dievčat. Text, ktorý subjekty čítali, sa skladal z 10 viet členených do 8 riadkov, kde priemerná dĺžka slova bola 4,6 písmena. Text bol vo švédskom jazyku. Očné pohyby boli zachytené prostredníctvom Goggle-based Obe-2 TM vo vertikálnom a aj horizontálnom smere pre obidve oči so vzorkovacou frekvenciou 100 Hz. Na Obr. 8 sú zobrazené typické očné pohyby pre subjekt z LR skupiny a takisto pre subjekt z HR skupiny. Pre účely nášho výskumu a s prihliadnutím na načrtnuté predpoklady boli na ďalšie spracovanie použité horizontálne a vertikálne pohyby očí priemerované cez obe oči.



Obr. 7 Pohyby očí náhodne vybraných subjektov zo skupiny HR (vľavo) a LR (vpravo) počas čítania textu (subjekty sú vybrané z tohto výskumu - presahy mimo papier sa nezobrazujú z priestorových dôvodov)


5.2 Prvotné upravenie dát

V prvom kroku bolo potrebné spriemerovať hodnoty pre obe oči R_x , L_x a R_y a L_y , nakoľko nie je brané do úvahy, že jedinci s dyslexiou by mali odlišné pozorovacie vzory pre pravé a ľavé oko. Touto úpravou docielime aj produkciu menej nadbytočných a robustnejších vzoriek určených na tréning a testovanie. Nové súradnice X a Y sme vypočítali:


$$X = \frac{R_x + L_x}{2} \quad (8)$$

$$Y = \frac{R_y + L_y}{2} \quad (9)$$

Následne bolo treba orezať dáta od nadbytočnej informácie, ktorá tvorila takmer polovicu celkovej informácie. Táto nadbytočná informácia mohla vzniknúť z dôvodu, že subjekty nečítali text nahlas, takže nedošlo k zastaveniu zaznamenávania očných pohybov, aj keď subjekty dočítali, namiesto toho prebiehalo nahrávanie očí, aj keď subjekty venovali pozornosť inde. Dáta boli v x-ovej osi orezané na hodnotu po 7. píle, čo zodpovedá prečítaniu prvých 7 riadkov textu a presunu očí na začiatok 8. riadku. Posledný 8. riadok bol odstránený z dôvodu presnejšieho určenia konca textu. Na Obr. 8 a Obr. 9 je znázornené, kde boli dáta orezané pre jeden subjekt z LR a HR skupiny.




Obr. 8 Orezanie dát subjekt LR-3



Obr. 9 Orezanie dát subjekt HR-93

5.3 Triedenie použitím histogramu na základe trvania čítania textu

Po úprave dát sme sa rozhodli zistiť, či je možné dáta triediť do dvoch skupín na základe H1. Subjekty sme rozdelili z datasetu do dvoch skupín výlučne na časoch čítania subjektov (rýchlosti prečítania 7 riadkov text). Použitím iba takéhoto jednoduchého parameteru je možné zostrojiť jednu prahovú hodnotu, ktorá poskytuje presnosť 95,67%. Je to zrejmé z časového rozdelenia v obidvoch triedach znázornených na Obr. 9, kde je nesprávne klasifikovaných iba 8 vzoriek – 4 subjekty z LR skupiny boli priradené do HR skupiny a 4 subjekty z HR sú priradené do LR skupiny. Tým síce potvrdzujeme predpoklad 1, ale aj predpoklad 2. Je preto opodstatnené informáciu o dĺžke čítania textu eliminovať v prospech iných črt.



Obr. 9 Rozdelenie na základe časov čítania

5.4 Triedenie dát pomocou kmeans na základe fixácii

Z prvotne predspracovaných dát sme zisťovali, či sa jedná o fixáciu. Z metódy navrhutej na klasifikáciu dyslexie na základe fixácií a aplikovaním Euklidovej vzdialenosti na dataset sme zistili hodnoty, podľa ktorých vieme rozhodnúť, či v danom momente ide o fixáciu. Každý výsledok Euklidovej vzdialenosti sme porovnávali so stanovenými citlivosťami, ktoré sme stanovili 0,1 a 0,4. Ide o čo najpresnejšie zistenie, čo je a čo nie je fixácia. Následne sme dostali 2 výsledné matice príznakov o veľkosti 185x2 pre citlivosti 0,1 a 0,4 z navrhutej metódy. Touto metódou triedenia dát sme dosiahli presnosť pri použití metriky štandardizovaná Euklidova vzdialenosť zobrazené v Tab.1:

Tab. 1 Dosiahnutá presnosť triedenia

Kmeans	Presnosť triedenia	
Citlivosť	0,1	0,4
	62,7 %	75,14 %

Metóda bola publikovaná v [AFD03].

5.5 Klasifikácia dát metódou KNN na základe fixácii

Spracované dáta, ktoré sme triedili (dĺžka fixácii, smerodajná odchýlka), sme následne klasifikovali metódou KNN. Dáta boli roztriedené do dvoch skupín - trénovacia – obsahovala 184 subjektov a testovacia obsahovala 1 subjekt. V prvom kroku sme vybrali jeden subjekt, ktorý slúžil ako testovací. Tento cyklus sme opakovali 185-krát, aby sme každý subjekt testovali. Najlepšie výsledky sme dosiahli pri štandardizovanej Euklidovej vzdialenosti. Klasifikáciu sme vykonali pre obidve metódy. Niekoľko sérií výpočtov s rôznou hodnotou k -susedov sa uskutočňovali v klasifikácii KNN. Výsledky v Tab. 2 sú výsledky KNN pre euklidovú vzdialenosť pre definovanie fixácii citlivosť 0,1 a 0,4.


Tab. 2 Dosiahnuté výsledky klasifikátorom KNN pre zistené fixácie (zvýraznené sú najlepšie výsledky)

	Citlivosť 0,1			Citlivosť 0,4		
	TPR	TNR	ACC	TPR	TNR	ACC
K=5	52,58	81,82	66,49	76,29	81,82	78,92
K=21	60,82	79,55	69,73	74,22	87,5	80,54
K=25	60,82	81,82	70,81	72,16	86,36	78,92
K=31	61,86	79,55	70,27	75,26	86,36	80,54
K=45	59,79	81,82	70,27	73,2	86,36	79,46


Metóda bola publikovaná v [AFD03].

5.6 Triedenie dát pomocou kmeans a klasifikácia pomocou KNN na základe magnitudového spektra interpolovaného signálu

Triedenie dát kmeansom bolo použité aj pre overenie opodstatnenia variantu 4 navrhutej metódy. Podľa návrhu sme sekvencie, ktoré boli rozličnej dĺžky, z dôvodu rozdielnej rýchlosti čítania subjektov, interpolovali pomocou DCT3, aby mali rovnakú dĺžku. Všetky signály boli interpolované - predĺžené na dĺžku podľa subjektu s najpomalším čítaním. Následne sa pre všetky subjekty vypočítali pomery medzi pôvodnou a zarovnanou (novou) dĺžkou. Súradnice v osi x sa vynásobili pomermi, aby sa korigovala celková energia. Okrem času čítania sa horizontálne signály (súradnice x) líšia aj medzi subjektmi LR a HR, Obr. 10 a Obr. 11. Zatiaľ čo x súradnice v prípade subjektov LR veľmi pripomínajú tvar píľky, napríklad dosť deterministická štruktúra je narušená nepredvídateľnými prudkými pohybmi dozadu a rovnako náhlými návratmi do pôvodnej polohy. Táto vlastnosť bola dominantná (nesie významné informácie), takže vertikálna súradnica (y) nebola zahrnutá do nasledujúceho spracovania a klasifikácie. Týmto sme znížili spracované údaje o faktor 2.




Obr. 10 Interpolácia očných pohybov v horizontálnej osi pre Subjekt 3 LR




Obr. 11 Interpolácia očných pohybov v horizontálnej osi pre Subjekt 93 HR

Dodatočnou aplikáciou DFT a extrahovaním iba spektier, ktoré by mali odrážať tieto náhle „body nespojitosti“ bez ohľadu na ich polohy (fázové informácie), sme znížili spracované (klasifikačné) údaje o ďalší faktor 2; celkom 4, Obr. 12 a Obr. 13. Pretože jednosmerná zložka nenesie žiadne zjavné informácie (iba stred textu v horizontálnom smere), bola vylúčená z konečného vektora vstupujúceho do triedenia.



Obr. 12 Magnitudové spektrum interpolovaného signálu v čase Subjekt 3 LR



Obr. 13 Magnitudové spektrum interpolovaného signálu v čase Subjekt 93 HR

Pri triedení dát kmeansom sme dosiahli najlepšiu úspešnosť 94,05%. Z toho vyplýva, že predpoklad navrhnutého heuristického prístupu k riešeniu problému by mal byť potvrdený. Navyše spracovanie v DFT spektre by malo viesť k úspešnosti nad 94 percent. Pri klasifikácii dát pomocou klasifikátora KNN sme dosiahli nasledovné výsledky Tab. 3. Trénovanie a testovanie bolo urobené rovnako ako v kapitole 5.5.

Tab. 3 Dosiahnuté výsledky klasifikátorom KNN pre klasifikovanie magnitudového spektra interpolovaného signálu - horizontálna os

Klasifikovanie podľa Magnitudového spektra interpolovaného signálu			
	TPR	TNR	ACC
K=5	89.69	79.55	84.86
K=19	89.69	82.95	86.49
K=25	89.69	84.09	87.03
K=33	90.72	82.95	87.03
K=55	87.63	82.95	85.41


Metóda bola publikovaná v [AFD01].

5.7 Klasifikácia dát konvolučnou neurónovou sieťou


Ako ďalší klasifikátor predspracovaných dát použijeme konvolučnú neurónovú sieť. Nakoľko CNN sú robustnejšie systémy, rozhodli sme sa ich použiť na klasifikáciu predspracovaných dát pre všetky varianty metódy (1,2,3,4).

5.7.1 Klasifikácia dát s využitím informácie len o x-ových súradniciach

Pri prvom a druhom variante metódy sa signály doplnili nulami na rovnakú dĺžku najpomalšieho čítajúceho, pre všetky subjekty Obr. 14 a Obr. 15.




Obr. 14 Doplnenie nulami časového priebehu očných pohybov vo vodorovnom smere subjektu LR-S3




Obr. 15 Doplnenie nulami časového priebehu očných pohybov vo vodorovnom smere subjektu HR-S93

Vo variante 2 sa použila DFT a vypočítalo sa spektrum, ako je to znázornené na Obr. 16 a Obr. 17 opäť pre subjekty LR a HR.



Obr. 16 Magnitudové spektrum signálu doplneného nulami v čase - subjekt LR (S3)




Obr. 17 Magnitudové spektrum signálu doplneného nulami v čase - subjekt HR (S93)

Pri 3. a 4. variante sme postupovali podľa opisu schémy Obr. 6 (c) a (d) s tým, že v 3. variante metódy sme sa zaoberali interpoláciou a klasifikáciou časového priebehu a pri štvrtom klasifikáciou spektra. CNN sú v súčasnosti najvýkonnejšie štruktúry NN v oblasti rozpoznávania obrazu a videa, klasifikácie obrazov, analýzy medicínskych obrazov a jazykového spracovania. [Sch15][KPC19][BAW19] Je to vďaka ich štruktúram, ktoré umožňujú extrahovať príslušné prvky umiestnené na rôznych pozíciách (invariantný posun), viac filtrov (jadier) umiestnených v paralelných rovinách poskytuje často invariantnosť rozlíšenia a správne zreťazenie viacerých konvolučných vrstiev umožňuje hierarchickú nelineárnu extrakciu príznakov. CNN zvyčajne vyžaduje relatívne malé predspracovanie signálu v porovnaní s inými algoritmami klasifikácie obrazu, pretože sa učí z extrakcie príznakov pomocou strojového učenia minimalizujúceho chybu klasifikácie. To je na rozdiel od tradičných algoritmov, ktoré využívajú teoretické (zvyčajne obmedzené) vedomosti, veľkou výhodou. Táto nezávislosť od predchádzajúcich poznatkov a ľudských chýb v dizajne je hlavnou výhodou. [KPC19][BAW19] V našich experimentoch sme použili konvolučnú neurónovú sieť z prostredia Matlab. Aby sme znížili efekt nesprávne nastavených klasifikačných modelov, t. j. zložitosť CNN, testovali sme CNN s rôznym počtom konvolučných vrstiev (2, 3 a 4); presné štruktúry testovaných CNN sú uvedené v Tab. 4.

Tab. 4 Parametre siete


Meno siete	Štruktúra
	[kernel veľkosť; počet kernelov]
CNN2	[3x3, 3x3; 8, 16]
CNN3	[3x3, 3x3, 3x3; 8, 16, 32],
CNN4	[3x3, 3x3, 3x3, 3x3; 8, 16, 32, 64]

Po každej konvolučnej vrstve nasledovala vrstva max pooling [2x2]. Pre všetky typy CNN bol použitý na prispôsobenie váh algoritmus SGDM (Stochastic Gradient Descent Momentum). Počiatočná rýchlosť učenia pre SGDM bola 0,01 a maximálny počet tréningových epoch bol nastavený na 20. Zo 185 subjektov sme vygenerovali 100 rôznych testovacích skupín, z ktorých každá obsahovala 16 subjektov (8 HR, 8 LR). Takýto scenár napodobňoval tréningové podmienky ako v [BSY16] a poskytuje presnejšie a robustnejšie výsledky. Bolo zaistené, že v najhoršom prípade došlo k najviac 50% zhode medzi akýmikoľvek skupinami. Zvyšné údaje boli rozdelené na 90% pre tréningovanie a 10% pre validáciu. Proces tréningovania, klasifikácie a validácie je znázornený na Obr. 18.




Obr. 18 Schéma tréningovania a testovania


V ďalšej sérii experimentov boli testované navrhnuté varianty: interpolácia vs. doplnenie nulami signálu. Najskôr vizualizujeme typické vstupy (normalizované) do CNN pre 5 subjektov z LR a 5 HR skupiny, tj. signály – doplnené nulami vyjadrené v čase a vo frekvenčnej doméne Obr. 19 a Obr. 20, a časovo interpolované signály vyjadrené v čase a frekvencii na Obr. 21 a Obr. 22.




Obr. 19 Normalizované signály doplnené nulami v časovej doméne pre 5 subjektov LR a 5 HR



Obr. 20 Normalizované signály doplnené nulami vo frekvenčnej doméne pre 5 subjektov LR a 5 HR



Obr. 21 Normalizované interpolované signály v časovej doméne pre 5 subjektov LR a 5 HR



Obr. 22 Normalizované interpolované signály vo frekvenčnej doméne pre 5 subjektov LR a 5 HR

Je zrejmé, že existujú viditeľné rozdiely medzi LR a HR skupinami v prípade signálov doplneného nulami v časovej doméne a časovo interpolovaných signálov vyjadrených ako magnitúdové spektrá. V prvom prípade to vyplýva z rozdielov v časoch čítania (dĺžkach) záznamov, v druhom to vyplýva z rozdielnych počtov návratov, pretože informácia o dĺžke

čítania bola odstránená. V Tab. 5 sú uvedené dosiahnuté výsledky klasifikácie pre rôzne spôsoby spracovania signálov 3-vrstvovou CNN.

Tab. 5 Porovnanie metód 3 vrstvovou CNN

Metóda	ACC [%]
Doplnenie signálu nulami a klasifikovanie časového	95,2 % $\pm$ 3,8 %
Doplnenie signálu nulami a klasifikovanie	95,9 % $\pm$ 3,4 %
Interpolácia a klasifikovanie časového priebehu	73,5 % $\pm$ 10,8 %
Interpolácia a klasifikovanie magnitudového	96,6 % $\pm$ 2,9 %

Najvyššia úspešnosť klasifikácie bola dosiahnutá v prípade interpolácie a klasifikovania magnitudového spektra - zvýraznená v Tab. 21. Magnitudové spektrum bolo úspešné v oboch prípadoch, tj. pri doplnení nulami a interpolácii. Tab. 6 ukazuje dosiahnuté výsledky pre ACC, TPR a TNR pre rôzne nastavenia CNN pri spracovávaní magnitudových spektier interpolovaných signálov a v porovnaní s dostupnými výsledkami pôvodného švédskeho výskumu. [BSY16]

Tab. 6 Dosiahnuté výsledky klasifikácie CNN, variant 4

	2 Vrstvová CNN	3 Vrstvová CNN	4 Vrstvová CNN	SVM-RFE
TPR [%]	96 % $\pm$ 3,7 %	97,8 % $\pm$ 2,1 %	97 % $\pm$ 2,6 %	95,5 % $\pm$ 4,6 %
TNR [%]	95,3 % $\pm$ 4,3 %	95,4 % $\pm$ 4,1 %	95,5 % $\pm$ 3,9 %	95,7 % $\pm$ 4,5 %
ACC [%]	95,6 % $\pm$ 3,8 %	96,6 % $\pm$ 2,9 %	96,3 % $\pm$ 3,1 %	95,6 % $\pm$ 4,5 %


Najlepšie výsledky sa pozorovali pri trojvrstvovej štruktúre CNN, aj keď štvorvrstvová poskytovala veľmi podobné výsledky. Ako vidno, náš prístup dokáže zavedením holistického prístupu zlepšiť pôvodné výsledky, cca o 1% - 96,6% oproti 95,6%, pritom je odstránená akákoľvek informácia o dĺžke čítania. [BSY16] Je zaujímavé, že ak je signál interpolovaný v časovej oblasti, čím je odstránená akákoľvek informácia o dĺžke čítania, ale ďalej sa netransformuje do frekvenčnej oblasti, presnosť detekcie významne poklesla na 73,5%.

V porovnaní s referenčnou metódou [BSY16] využívajúcou vybranú kombináciu globálnych funkcií pomocou SVM-RFE sme boli schopní dosiahnuť lepší proces detekcie použitím holistického prístupu, pomerne jednoduchého predspracovania signálu, reprezentovaného (spektrum) a vhodným klasifikačným modelom (CNN). Navyše nebolo nutné hľadať spomedzi ponúkaných príznakov kombinácie, ktoré by práve pre naše experimentálne dáta boli tie „najvhodnejšie“. Náš prístup tiež dosiahol lepšie skóre v klasifikácii subjektov zo skupiny HR v porovnaní s referenčnou metódou o 2,4%. To môže hrať úlohu, keď je TPR dôležitejšie ako celková úspešnosť klasifikácie. Spravidla je to tak v lekárskej diagnostike, kde by nesprávna klasifikácia zdravých pacientov bola menej závažná, ako neposkytnutie liečby subjektom, ktoré potrebujú pomoc. [ŠČB13] Falošná negativita v tomto prípade môže dieťaťu sťažiť ďalšie vzdelávanie, pretože nebude adekvátne prispôsobené jeho poruche čítania. Ďalšou výhodou nášho systému je, že vstupom je iba vektor súradníc (horizontálne), a teda nie sú potrebné ďalšie klasifikácie / detekcie udalostí vyjadrujúcich typy pohybu očí (počet fixácií, dĺžka fixácií alebo dĺžka sakád) a ich následný výber a kombinácia napr. rekurzívnou elimináciou funkcií. Pri sledovaní výkonnosti nášho prístupu vo vzťahu k zložitosti štruktúry CNN je zrejmé, že relatívne jednoduchá štruktúra (3 - 4 vrstvy) môže extrahovať relevantné informácie na


klasifikáciu subjektov s dyslexiou v scenári čítania textu - sledovania očí. Metóda bola publikovaná v [ADC01].

5.7.2 Klasifikácia dát s využitím informácie o x-ových a y-ových súradniciach

V nasledujúcom postupe by sme sa chceli zamerať na klasifikáciu dát so súradnicami x , y , či pridanie vertikálnej súradnice zlepši už dosiahnuté výsledky klasifikácie CNN dosiahnutej v kapitole 5.7.1. pre metódu č.4. Rovnako sme postupovali v prípade predspracovania dát. Prvým krokom bolo orezanie dát na požadovanú dĺžku Obr. 23 a Obr. 24.




Obr. 23 Orezanie dát na požadovanú dĺžku LR subjekt - modrá farba – $x(n)$, oranžová – $y(n)$




Obr. 24 Orezanie dát na požadovanú dĺžku HR subjekt - modrá farba – $x(n)$ oranžová – $y(n)$

Výsledná interpolácia signálov DCT3 pre subjekty LR a HR je zobrazená na Obr. 25 a Obr. 26




Obr. 25 Interpolácia očných pohybov pre horizontálnu a vertikálnu os pre subjekt z LR skupiny - modrá farba – $x(n)$ oranžová – $y(n)$




Obr. 26 Interpolácia očných pohybov pre horizontálnu a vertikálnu os pre subjekt z HR skupiny - modrá farba – $x(n)$ oranžová – $y(n)$

Po DFT sme získali magnitúdové spektra Obr. 27 a Obr. 28, z ktorých sme brali len polovicu, a jednosmernú zložku sme vynechali.



Obr. 27 Magnitúdové spektrum interpolovaného signálu v čase subjekt LR skupiny - modrá farba – $|X(k)|$ oranžová – $|Y(k)|$



Obr. 28 Magnitúdové spektrum interpolovaného signálu v čase subjekt HR skupiny - modrá farba – $|X(k)|$ oranžová – $|Y(k)|$


Predspracované dáta sme následne klasifikovali konvolučnou neurónovou sieťou, ktorou boli dosiahnuté najlepšie výsledky v kapitole. 5.7.1 . Výsledky dosiahnuté pridaním vertikálnej osi nedosiahli vyššiu presnosť klasifikácie subjektov s dyslexiou , dosiahnuté výsledky sú v Tab. 7. Metóda bola publikovaná v [AFC01].

Tab. 7 Dosiahnuté výsledky klasifikácie subjektov pre vertikálnu a horizontálnu os


	3 vrstvová CNN	3 vrstvová CNN
TPR [%]	96.6 % $\pm$ 3%	97,8 % $\pm$ 2,1 %
TNR [%]	95.8% $\pm$ 3.7%	95,4 % $\pm$ 4,1 %
ACC [%]	96.2% $\pm$ 3.2%	96,6 % $\pm$ 2,9 %

5.8 Klasifikácia dát váženého spektra – logaritmickou funkciou

V následnej navrhutej metóde sme rozšírili pôvodný variant 4 navrhutej metódy (najvyššia celková klasifikačná presnosť) a zamerali sme sa na klasifikáciu dát váženého spektra vhodnou funkciou - logaritmom, aj v tomto prípade, ako je zobrazené v nasledovných Obr. 29 a Obr. 30, môžeme vidieť významné rozdiely medzi jedincami z HR a LR skupiny.



Obr. 29 Logaritmované spektrum subjektu S3



Obr. 30 Logaritmované spektrum subjektu S93


Následne sme predspracované dáta previedli do obrazov, ktoré slúžili ako vstup do nami navrhutej CNN v prostredí Matlab. Pri navrhutej metóde sme nezaznamenali nárast úspešnosti celkovej klasifikácie subjektov prípadne presnejšie klasifikovanie subjektov z HR skupiny v porovnaní s metódou interpolovaného signálu a klasifikovaní magnitudového spektra. Výsledky dosiahnuté touto metódou boli pre celkovú úspešnosť ACC: $95,8\% \pm 3,7\%$. Z vyššie uvedených dôvodov práca nebola publikovaná. Neznamená to však, že by voľbou vhodnejšej funkcie váženia nemohlo dôjsť k zvýšeniu úspešnosti. Už tu dosiahnutá úspešnosť detekcie je vyššia ako v referenčnej metóde.

5.9 Aplikácia navrhutej metódy na subjekty s dysgrafiou

Dátový set bol získaný v rámci úlohy APVV-16-0211 publikovaný v [DrD20]. Výskumnej úlohy sa zúčastnilo 120 školopovinných detí vo vekovom rozložení 8-15 rokov, z toho 80 chlapcov a 40 dievčat. Pri 57 subjektoch bola potvrdená dysgrafia a 63 subjektov malo normálne písateľské zručnosti. Subjekty mali za úlohu napísať písmeno *l*, slov *le*, *leto*, vymyslené slovo *lamoken*, a zložitejšie slovo *hračkárstvo* a vetu *V lete bude teplo a sucho*.

Pri dyslektických subjektoch sa stretávame s tým, že subjekty čítajú text podstatne pomalšie ako nedyslektici a táto vlastnosť je jednou z najdôležitejších príznakov na klasifikáciu, v prípade dysgrafie sa s týmto prístupom často nestretávame. Variant 4 vyššie navrhutej metódy eliminuje časový faktor, preto rovnako ako pri dyslexii, tak aj pri dysgrafií sa odstráni faktor pomalého písania, ktorý je prítomný pri dysgrafikoch. Pri dysgrafií sme vychádzali z dát

zozbieraných z tabletu, na ktorom sa zaznamenávali súradnice pohybu pera po tablete. Na Obr. 31 sú zobrazené pohyby pera jedinca s dysgrafiou a zdravého subjektu.



Obr. 31 Znárodné pohyby pera po tablete pre subjekt s dysgrafiou vľavo a zdravého subjektu vpravo

Pre porovnanie zosnímaných pohybov ruky s očnými pohybmi na Obr. 8 je vidieť významné spoločné rysy. Rozdiely pri písucích subjektoch je v začiatkových súradniciach, ktoré nie sú rovnaké, čo je spôsobené rozdielnymi veľkosťami písma subjektov. Tento faktor nemá vplyv na klasifikáciu subjektov s dysgrafiou. Pomocou vlastností DFT sú tieto problémy eliminované. Aby sme dosiahli, že všetky postupnosti súradníc budú mať rovnaké veľkosti, sme na dáta aplikovali interpoláciu. Na klasifikáciu subjektov s dysgrafiou sme použili rovnaký spôsob predspracovania dát ako v prípade dyslexie, ktorý bol aplikovaný na nepredspracované súradnice získané snímaním polohy pera pri písaní subjektov na tablete vybraných slovných spojení. Signály boli najprv interpolované na najväčšiu dĺžku podľa najpomalšie písuceho subjektu. Toto sa využilo na odstránenie nepodstatných časových informácií zo signálov. Signál bol interpolovaný pomocou DCT3. Takto získané postupnosti boli použité na výpočet magnitúdového spektra DFT. Magnitúdové spektrum eliminuje priestorový posun začiatku písania, veľmi dobre dekoreluje nadbytočné informácie a sústreďuje najdôležitejšie tvarové vlastnosti písaného textu do menšieho počtu energeticky významných spektrálnych zložiek podobne, ako je to napríklad pri klasifikácii textúr. [PBV16] Takéto predspracovanie bolo urobené jednorozmerne v smere x a jednorozmerne v smere y. Takto predspracované signály potom vstupujú do klasifikátora. Ako klasifikátor bola v experimente použitá konvolučná neurónová sieť. Vstupom do nej boli dvojice predspracovaných vektorov x a y. Ako klasifikátor bola použitá 3-vrstvová konvolučná neurónová sieť, s ktorou boli dosiahnuté najlepšie výsledky klasifikácie pri dyslexii opísané v kapitole 5.7.1. Dáta boli rozdelené v pomere 80-10-10 na tréning, validačné a testovacie. Dosiahnuté výsledky sú zobrazené v Tab. 8. Dosiahnuté výsledné klasifikačné skóre mohlo byť ovplyvnené malým počtom subjektov (malý dataset). Pre možné zlepšenie výslednej ACC by bolo vhodné dataset rozšíriť.

Tab. 8 Dosiahnuté výsledky klasifikácie dysgrafie

	3 vrstvá CNN	AdaBoost	SVM [DrD20]	RF [DrD20]
ACC	79,7% ±2.9%	79.5 % ± 3%	78.8 % ± 2 %	77.6 % ± 1%
TPR	76% ±4.9%	79.7 % ± 5 %	74.5 % ± 4 %	71.4 % ± 3%
TNR	80.6% ±3%	76.7 % ± 2%	82.4 % ± 4 %	83.3 % ± 2%

Metóda bola publikovaná v [AFC04].

Dosiahnuté výsledky metód a ich vyhodnotenie

Najdôležitejším prínosom tejto práce je metóda detekcie dyslexie, ktorá aj so svojimi modifikáciami bola publikovaná. Je tu prezentovaná nová metóda detekcie kognitívnych porúch využívajúca signály sledovania očí v teste čítania textu. Tento výskum zlepšuje publikované články, ktoré extrahujú kombináciu množstva rôznych príznakov. Robí to spracovaním celých záznamov sledovania očí buď v čase alebo frekvencii, pričom sa aplikuje iba základné predspracovanie signálu. Takéto signály boli ďalej klasifikované ako celok konvolučnými neurónovými sieťami (CNN), ktoré hierarchicky extrahujú podstatné prvky rozptylu buď v čase alebo vo frekvencii a nelineárne ich spájajú pomocou strojového učenia, aby sa minimalizovala chyba detekcie. V experimentoch sme použili 100-násobnú krížovú validáciu a súbor údajov obsahujúci signály 185 subjektov (88 subjektov s nízkym rizikom a 97 subjektov s vysokým rizikom dyslexie). V sérii experimentov sa zistilo, že navrhnutá reprezentácia časovo interpolovaných signálov sledovania očí na základe magnitúdového spektra zaznamenala najlepšie výsledky, t. j. dosiahla sa priemerná presnosť 96,6 % v porovnaní s 95,6 % pôvodnej publikácie [BSY16], čo je najlepší dovtedy publikovaný výsledok, prípadne publikácie [JoB20] pracujúcej s tou istou databázou. Tieto zistenia naznačujú, že holistický prístup zahŕňajúci malé, ale dostatočne zložité CNN aplikované na správne predspracované a vyjadrené signály poskytuje ešte lepšie výsledky ako kombinácia starostlivo vybraných známych príznakov. Pre porovnanie v Tab. 26 uvádzame dosiahnuté výsledky s ostatnými publikáciami, ktoré použili rovnaký dataset. Metóda bola navrhnutá aj v menej účinnej rýchlej verzii bez použitia neurónových sietí, použitý bol klasifikátor KNN, ktorá dosahuje relatívne slušnú úspešnosť vzhľadom na jej rýchlosť a jednoduchú implementáciu. Predchádzajúce metódy zo sledovaných pozícií využívajú len vodorovnú časť súradníc. Navrhnutá a otestovaná bola aj metóda s využitím obidvoch súradníc a vychádza z najúspešnejšej navrhnutej metódy. Ukázala sa vysoká účinnosť metódy dosahujúca najlepšie v súčasnosti dosahované výsledky. Navrhnutá metóda bola použitá aj na dataset obsahujúci rukopis dysgrafických subjektov a zdravých subjektov a taktiež vhodnou kombináciou predspracovania dát a CNN bola dosiahnutá lepšia ACC 79,7 % oproti pôvodnej 79,5%. Pre porovnanie v Tab. 27 uvádzame dosiahnuté výsledky s referenčnou metódou.

Na záver si dovoľujem zosumarizovať najdôležitejšie prínosy dizertačnej práce Detekcia dyslexie metódami strojového učenia nasledovne:

- Návrh nových metód určených na detekciu dyslexie systémami využívajúcimi signály sledovania očí v teste čítania textu
- Zvýšenie presnosti detekcie navrhnutej metódy s CNN využívajúcej ako príznaky zložky magnitúdového spektra oproti prácam, ktoré na klasifikáciu s CNN využívajú kombináciu množstva rôznych príznakov.
- Modifikácia navrhnutej metódy využívajúcej ako príznaky zložky magnitúdového spektra použitím rýchlej verzie klasifikátora KNN
- Aplikácia navrhnutej metódy využívajúcej ako príznaky zložky magnitúdového spektra a zlepšenie presnosti detekcie aj pri identifikácii dysgrafie

Záver

Najdôležitejším výsledkom dizertačnej práce je nová metóda na detekciu dyslexie, ktorá je využiteľná ako podporná metóda pri diagnostike aj v klinickej praxi. Najúčinnšie metódy ako vstup používajú dáta získané sledovaním pohybu očí pri čítaní textu, ktoré po vhodnom predspracovaní vstupujú do klasifikátorov KNN a konvolučnej neurónovej siete. U dyslexie dáta predstavujú časovú postupnosť sledovaných dát spracovaných do formy spektra. Pri klasifikácii dyslexie v dizertačnej práci dosiahla jedna z navrhnutých metód na rovnakom voľne dostupnom datasete najvyššiu doteraz vo vedeckej literatúre publikovanú účinnosť klasifikácie. Kombinácia sledovania očí a čítania textu sa ukazuje zas ako veľmi účinná pri detekcii dyslexie. Bolo by teda zaujímavé otestovať, či by navrhnutý alebo podobný prístup bol taký úspešný aj pri iných diagnózach. Ďalším zaujímavým bodom práce by mohlo byť aplikovanie našej metódy na ďalšie poruchy ovplyvňujúce kognitívne funkcie, napríklad detegovanie osôb so zvýšením rizikom vzniku demencie sledovaním pohybu očí počas testu čitateľskej aktivity. Takýto test by mohol doplniť niektoré komplexné hodnotenie miernej kognitívnej poruchy, ako je Montreal Cognitive Assessment (MoCA). [Haj19]

V závere môžeme konštatovať, že aj keď navrhnuté diagnostické metódy neodhalili u všetkých sledovaných subjektov dyslexiu so 100% úspešnosťou, stále môžu byť použité ako podporný mechanizmus v prvotných testoch poprípade na skoré odhalenie dyslexie a dysgrafie u subjektov na 1.stupni základných škôl, nakoľko pri subjektoch s dyslexiou a dysgrafiou je potrebný špecifický prístup vzdelávania, ktorý ak je v prvotnej fáze nedostatočný, môže viesť k zhoršenému prospechu jedincov s kognitívnou poruchou.

Resumé

The most important result of the thesis is a new method for the detection of dyslexia, which can be used as a supportive method in diagnosis and clinical practice. The most efficient methods as input use data obtained by tracking eye movement when reading text, which after appropriate pre-processing, enter the KNN classifiers and the convolutional neural network. In dyslexia, the data represent the time sequence of the observed data processed into the form of a spectrum. When classifying dyslexia in the thesis, once of the proposed methods on the same available dataset achieved the highest classification accuracy published in the scientific literature. The combination of eye tracking and text reading proves to be very effective in detecting dyslexia. It would therefore be interesting to test whether the proposed or similar approach would be so successful for other diagnoses. Another interesting point of work could be the application of our method to other disorders affecting cognitive functions, such as detecting people at increased risk of dementia by monitoring eye movement during a test of reading activity. Such a test could complement some comprehensive assessment of mild cognitive impairment such as the Montreal Cognitive Assessment (MoCA). [Haj19]

In conclusion, although the proposed diagnostic methods did not detect dyslexia in all subject with 100% accuracy, they can still be used as a support mechanism in initial tests or early detection of dyslexia and dysgraphia in subjects attending the first grade of primary schools, as in subjects with dyslexia and dysgraphia a specific learning approach is required, which, if inadequate in the early stages, can lead to impaired benefit for individuals with cognitive impairment.

Zoznam publikácií autora

POZNÁMKA: Kategorizácia výstupov uvedená na konci každého výstupu je podľa: Minimálne kritériá na získanie titulu docent a titulu profesor na Slovenskej technickej univerzite v Bratislave, Obory habilitačného a inauguračného konania: Aplikovaná informatika, Telekomunikácie, schválené vo VR STU 22. 02. 2021

Publikácie týkajúce sa dizertačnej práce

ADC Vedecké práce v zahraničných karentovaných časopisoch

- ADC01 NERUŠIL, Boris [35 %] - POLEC, Jaroslav [35 %] - ŠKUNDA, Juraj [15 %] - KAČUR, Juraj [15 %]. Eye tracking based dyslexia detection using a holistic approach. In *Scientific Reports*. Vol. 11, Iss. 1 (2021), Art. no. 15687 [10] s. ISSN 2045-2322 (2020: 4.380 - IF, Q1 - JCR Best Q, 1.240 - SJR, Q1 - SJR Best Q). V databáze: DOI: 10.1038/s41598-021-95275-1 ; WOS: 000684191400012 ; CC: 000684191400012 ; SCOPUS: 2-s2.0-85111960688. **Kat. A+**

AFC Publikované príspevky na zahraničných vedeckých konferenciách

- AFC01 NERUŠIL, Boris [55 %] - POLEC, Jaroslav [25 %] - ŠKUNDA, Juraj [20 %]. Detection of dyslexia using eye tracking. In *SPSympo 2021 : Signal processing symposium. Łódź, Poland. September 20-23, 2021*. Piscataway : IEEE, 2021, S. 202-205. ISBN 978-0-7381-1340-1. V databáze: IEEE: 9593313 ; DOI: 10.1109/SPSympo51155.2020.9593313. **Kat. A-**
- AFC02 ŠKUNDA, Juraj [40 %] - POLEC, Jaroslav [20 %] - KAČUR, Juraj [10 %] - NERUŠIL, Boris [10 %] - ALMÁŠI, Marek [5 %] - SMOLEJOVÁ, Eva [15 %]. Orthogonal transform coding theory for schizophrenia disorder detection. In *ELEKTRO 2020 : 13th International conference. Taormina, Italy. May 25-28, 2020*. Piscataway : IEEE, 2020, [4] s. ISBN 978-1-7281-7542-3. V databáze: IEEE ; WOS: 000621581100132 ; DOI: 10.1109/ELEKTRO49696.2020.9130648. **Kat. A-**
- AFC03 ŠKUNDA, Juraj [55 %] - POLEC, Jaroslav [15 %] - NERUŠIL, Boris [15 %] - MÁLIŠOVÁ, Eva [15 %]. Schizophrenia detection using convolutional neural network. In *Proceedings of ELMAR-2021 : 63rd International symposium. Zadar, Croatia. September 13-15, 2021*. 1. ed. Zadar : Croatian Society Electronics in Marine, 2021, S. 151-154. ISSN 1334-2630. ISBN 978-1-6654-4436-1. V databáze: IEEE: 9550955; SCOPUS: 2-s2.0-85117128682; DOI: 10.1109/ELMAR52657.2021.9550955. **Kat. A-**

AFC04 ŠKUNDA, Juraj [30 %] - NERUŠIL, Boris [50 %] - POLEC, Jaroslav [20 %]. Method for Dysgraphia Disorder Detection using Convolutional Neural Network. In WSCG 2022 Proceedings. : 30th International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision 2022. May 17-20, 2022. Pilsen, Czech Republic., v tlači; 2018 CORE B, **Kat. A**

AFD Publikované príspevky na domácich vedeckých konferenciách

AFD01 NERUŠIL, Boris [50 %] - POLEC, Jaroslav [20 %] - ŠKUNDA, Juraj [30 %]. Fast algorithm for dyslexia detection. In Systems, Signals and Image Processing [ed. Gregor Rozinaj, Radoslav Vargic; rec. Raphae Abreu, Cristhian A. Aguilera] : 28th International Conference, IWSSIP 2021, Bratislava, Slovakia, June 2-4, 2021. Cham : Springer, 2022, S. 152-160. ISBN 978-3-030-96877-9. V databáze: SCOPUS: 2-s2.0-85126177801 ; DOI: 10.1007/978-3-030-96878-6_14. **Kat. A-**

AFD02 POLEC, Jaroslav [30 %] - KAČUR, Juraj [20 %] - KRBAŤA, Jakub [10 %] - ŠKUNDA, Juraj [10 %] - NERUŠIL, Boris [10 %] - SMOLEJOVÁ, Eva [20 %]. Detection of schizphrenia disorder using deep learning. In Redžúr 2020 : 14th International workshop on multimedia information and communication technologies. Bratislava, Slovakia. June 5, 2020. 1. vyd. Bratislava : Vydavateľstvo Spektrum STU, 2020, S. 11-14. ISBN 978-80-227-5007-3. **Kat. B**

AFD03 STRAŠIFTÁK, Martin [35 %] - VANYA, Adam [5 %] - HORVÁT, Roman [5 %] - BACKA, Šimon [5 %] - NERUŠIL, Boris [50 %]. Detection of visual attention disorder. Redžúr 2020 14th International workshop on multimedia information and communication technologies. Bratislava, Slovakia. June 5, 2020. 1. vyd. Bratislava : Bratislava: Vydavateľstvo Spektrum STU, 2020, , 15-18. ISBN 978-80-227-5007-3. **Kat. B**

Riešené výskumné úlohy

1. VEGA 1/0440/19 - Detekcia kognitívnych porúch na základe sledovania pohybu očí, zodpovedný riešiteľ: prof. Ing. Jaroslav Polec, PhD. (01.01.2019 - 31.12.2021, riešiteľ)

2. READ2020 Grant v Rámci programu na podporu mladých výskumníkov na STU - Metóda pre rýchlu diagnostiku porúch čítania pomocou sledovania pohybov očí, zodpovedný riešiteľ: Ing. Juraj Škunda (01.03.2020 - 28.02.2021, riešiteľ)

3. WRITE2021 Grant v Rámci programu na podporu mladých výskumníkov na STU - Mobilné pracovisko pre detekciu dysgrafie, zodpovedný riešiteľ: Ing. Boris Nerušil. (01.04.2021 - 31.06.2022)

Zoznam použitej literatúry

- [MiF20] Miciak J, Fletcher M.J, The Critical Role of Instructional Response for Identifying Dyslexia and Other Learning Disabilities SAGE journals 105:343-353. 2020
<https://doi.org/10.1177/0022219420906801>
- [FFK17] Fraser K. C., Fors K. L., Kokkinakis D., A. Nordlund, An analysis of eye-movements during reading for detection of mild cognitive impairment“ Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, pp. 1016–1026. DOI: 10.18653/v1/D17-1107
- [YHE18] Yaneva V., Ha L. A., Eraslan S., Yesilada Y., Mitkova R., “Detecting Autism Based on Eye-Tracking Data from Web Seaching Tasks“ W4A '18: Proceedings of the Internet of Accessible Things, The Internet of Accessible Things Lyon France, April 2018 Article No.: 16 , pp. 1–10.
- [MKA15] Molitor R.J, Ko P.C, Ally B.A. “Eye movements in Alzheimer's disease.” Journal of Alzheimer's disease : JAD vol. 44,1 (2015): 1-12. doi:10.3233/JAD-141173
- [KIE19] Klein Ch, Ettinger U., Eye movement research, Springer International Publishing, 2019 ISBN:978-3-030-20085-5
- [BSY16] Benfatto M. N., Seimyr G. Ö., Ygge J., Pansell T., Rydberg A. and Jacobson C., “Screening for Dyslexia Using Eye Tracking during Reading”. PLoS ONE vol. 11(12), 2016.
<https://doi.org/10.1371/journal.pone.0165508>
- [Kai20] Kaisar S., Developmental dyslexia detection using machine learning techniques: A survey, Volume 6, Issue 3, September 2020, Pages 181-184, <https://doi.org/10.1016/j.ict.2020.05.006>
- [LCF15] Lakretz Y., Chechik G., Friedmann N., Rosen-Zvi M., Probabilistic graphical models of dyslexia, in: Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2015, pp. 1919–1928.
- [ReB15] Rello L., Ballesteros M., Detecting readers with dyslexia using machine learning with eye tracking measures, in: Proceedings of the 12th Web for All Conference, 2015,1–8.
- [PGA17] Płonski P., Gradkowski W., Altarelli I., Monzalvo K., van Ermingen-Marbach M., Grande M., Heim S., Marchewka A., Bogorodzki P., Ramus F., et al., Multi-parameter machine learning approach to the neuroanatomical basis of developmental dyslexia, Hum. Brain Mapp. 38 (2) (2017) 900–908. doi: 10.1002/hbm.23426.
- [KCB18] Khan R.U., Cheng J.L.A., Bee O.Y., Machine learning and dyslexia: Diagnostic and classification system (dcs) for kids with learning disabilities, Int. J. Eng. Technol. 7 (3.18) (2018) 97–100.
- [RRR18] Rello L., Romero E., Rauschenberger M., Ali A., Williams K., Bigham J.P., White N.C., Screening dyslexia for English using hci measures and machine learning, in: Proceedings of the 2018 International Conference on Digital Health, 2018, pp. 80–84.
- [FrM18] Frid A., Manevitz L.M., Features and machine learning for correlating and classifying between brain areas and dyslexia, 2018, arXiv preprint arXiv:1812.10622.
- [PSW18] Perera H., Shiratuddin M.F., Wong K.W., Fullarton K., Eeg signal analysis of writing and typing between adults with dyslexia and normal controls, Int. J. Interact. Multimedia Artif. Intell. 5 (1) (2018) 62. doi: 10.9781/ijimai.2018.04.005.
- [HAM18] Hamid S.S.A, Admodisastro N., Manshor N., Kamaruddin A., Ghani A.A.A., Dyslexia adaptive learning model: student engagement prediction using machine learning approach, in: ICSCDM, Springer, 2018, pp. 372–384.
- [AMP19] Asvestopoulou T., Manousaki V., Psistakis A., Smyrnakis I., Andreadakis V., Aslanides I.M., Papadopoulou M., Dyslexml: Screening tool for dyslexia using machine learning, 2019, arXiv preprint arXiv: 1903.06274.
- [RZŽ19] Rezvani Z., Zare M., Žarić G., Bonte M., Tijms J., Van der Molen M., González G.F., Machine learning classification of dyslexic children based on eeg local network features, 2019, pp. 1–23, bioRxiv. doi:10.1101/569996.
- [SCS19] Spoon K., Crandall D., Siek K., Towards detecting dyslexia in children's handwriting using neural networks, in: Proceedings of the 36th International Conference on Machine Learning, 2019, pp. 1–5.
- [CXS16] Cui Z., Xia Z., Su M., Shu H., Gong G., Disrupted white matter connectivity underlying developmental dyslexia: a machine learning approach, Hum. Brain Mapp. 37 (4) (2016) 1443–1458.

- [Convo] Convolutional Neural Network Architecture: Forging Pathways to the Future. Dostupné na internete <https://missinglink.ai/guides/convolutional-neural-networks/convolutional-neural-network-architecture-forging-pathways-future/>
- [Sch15] Schmidhuber J., "Deep learning in neural networks: An overview", *Neural Networks*, 61, pp. 85–117, 2015.
- [KPC19] Kacur J., Polec J., Csoka F. and Smolejova E., "GMM Based Detection of Schizophrenia Using Eye Track-ing," 2019 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB), Siena, Italy, 2019, pp. 1-4, doi: 10.1109/CIBCB.2019.8791239.
- [BAW19] Basaia S., Agosta F., Wagner L., Canu E., Magnani G., Santangelo R., Filippi M., Automated classification of Alzheimer's disease and mild cognitive impairment using single MRI and deep neural networks, *ScienceDirect*, 2019, Volume: 21: <https://doi.org/10.1016/j.nicl.2018.101645>
- [ŠCB13] Šikudová E., Černeková Z., Benešová W., Haladová Z., Kučerová J., *Computer Vision Object Detection and Recognition*. Wikina, Praha, 2013.
- [Workin] Working with Heat Maps and Gaze Plots, [online] Dostupné na internete <https://www.tobiipro.com/learn-and-support/learn/steps-in-an-eye-tracking-study/interpret/working-with-heat-maps-and-gaze-plots/>
- [Classi] Classification Using Nearest Neighbors, [online], Dostupné na internete <https://www.mathworks.com/help/stats/classification-using-nearest-neighbors.html#bsfjytu-1>
- [Convo] Convolutional Neural Network: 3 things you need to know, [online], Dostupné na internete <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html>
- [RPK97] Rozinaj, G., Polec, J., Kotuliaková, J., Podhradský, P., Marček, A., Marchevský, S.: Číslicové spracovanie signálov II FABER Bratislava, 1997. 150 s. ISBN 80-967503-5-6
- [UMO21] Usman, L.O, Muniyandi CH.R, Omar K, Mohamad M, Advance Machine Learning Methods for Dyslexia Biomarker Detection: A Review of Implementation Details and Challenges, 2021 Dostupné na internete: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9364974>, DOI: 10.1109/ACCESS.2021.3062709
- [SSC19] Spoon K., Siek K., Crandall D., Fillmore M., "Can we (and should we) use AI to detect Dyslexia in children's handwriting?" in *Proc. Artif. Intell. Social Good* 2019, pp1–6.
- [Speci] Specificke poruchy učenia Dostupné online: http://www.pppknn.sk/data/pdf/materialy/specificke_poruchy/specificke_poruchy_ucenia.pdf
- [Haj19] Hajduk, M. et al. Clinical Utility of Slovak Version of Montreal Cognitive Assessment in Detection of MCI in Well-Educated Older People 714–715 (Taylor & Francis Inc, 2019). <https://doi.org/10.1080/13854046.2019.1595155>.
- [ZGS20] Zahia S., Garcia-Zapirain B., Saralegui I., Fernandez-Ruanova B., "Dyslexia detection using 3D convolutional neural networks and functional magnetic resonance imaging," *Comput. Methods Programs Biomed.*, vol. 197, Dec. 2020, Art. no. 105726, doi: 10.1016/j.cmpb.2020.105726.
- [UsM20] Usman O. L, Muniyandi R. C., "CryptoDL: Predicting dyslexia biomarkers from encrypted neuroimaging dataset using energy-efficient residue number system and deep convolutional neural network," *Symmetry*, vol. 12, no. 5, p. 836, 2020, doi: 10.3390/sym12050836.
- [DrD20] Drotár, P., Dobeš, M. Dysgraphia detection through machine learning. *Sci Rep* 10, 21541 (2020). <https://doi.org/10.1038/s41598-020-78611-9>
- [JoB20] Jothi P. A, Bhargavi R. Predictive Model for Dyslexia from Fixations and Saccadic Eye Movement Events. *Comput Methods Programs Biomed.* 2020 Oct;195:105538. doi: 10.1016/j.cmpb.2020.105538. Epub 2020 May 30. PMID: 32526535
- [PBV16] Polec, J., Benesova, W., Vargic, R., Ilčíková, I., & Csóka, T. (2016). Texture feature extraction using an orthogonal transform of arbitrarily shaped image regions. *Journal of Electronic Imaging*. 25. 061413. 10.1117/1.JEI.25.6.061413