



SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Ing. Juraj Škunda

Autoreferát dizertačnej práce

Detekcia schizofrénie 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. Juraj Škunda
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. RNDr. Andrej Ferko, PhD.
Univerzity Komenského
Fakulta matematiky, fyziky a informatiky
Katedra algebry a geometrie
Oddelenie geometrie
Mlynská dolina F1, 842 48 Bratislava

RNDr. Zuzana Černeková, PhD.
Univerzity Komenského
Fakulta matematiky, fyziky a informatiky
Katedra aplikovanej informatiky
Oddelenie počítačovej grafiky a videnia
Mlynská dolina F1, 842 48 Bratislava

Autoreferát bol rozoslaný:

Obhajoba dizertačnej práce sa bude konať dňa2022 **o**h.

na

.....
prof. Dr. Ing. Miloš Oravec

Obsah

1	Úvod.....	4
2	Súčasný stav riešenia problematiky	5
2.1	Detekcia schizofrénie a eye-tracking.....	5
3	Ciele dizertačnej práce	7
4	Metódy detekcie schizofrenickej poruchy	8
4.1	Metóda klasifikácie pomocou korelačných matíc a GTC.....	8
4.2	Návrh metódy na detekciu pomocou konvolučnej neurónovej siete	11
4.2.1	Rozšírenie datasetu.....	11
4.3	Návrh metódy na detekciu pomocou vzájomnej informácie	12
5	Dosiahnuté výsledky metód a ich vyhodnotenie	13
5.1	Dataset v experimente	13
5.2	Klasifikácia pomocou korelačných matíc a GTC.....	15
5.3	Konvolučná neurónová sieť.....	15
5.4	KNN a vzájomná informácia	17
5.5	Sumarizácia zhodnotenia navrhnutých metód.....	19
6	Pôvodné vedecké prínosy	21
7	Závery pre ďalší rozvoj vedy a praxe	22
	Zoznam použitej literatúry	23
	Zoznam publikácií autora.....	25
	Publikácie týkajúce sa dizertačnej práce	25
	Ostatné publikácie	26
	Riešené výskumné projekty	27
	Resumé	28

1 Úvod

Moderné diagnostické nástroje sú schopné urýchliť a zjednodušiť detekciu rôznych porúch súvisiacich s kognitívnymi funkciami na základe sledovaných parametrov. Detekcia poruchy je možná aj v skorom štádiu, keď ešte nemusí byť pre odborníkov v klinickej praxi pozorovateľná alebo príznaky môžu byť prehliadnuté, prípadne nesprávne vyhodnotené. Implementácia automatických, prípadne semi-automatických diagnostických nástrojov v praxi umožňuje zlepšiť kvalitu života jedinca ovplyvneného danou poruchou alebo ho aj predĺžiť. Na druhej strane môže znížiť výdavky na nákladnú liečbu vďaka včasnej diagnostike. V súčasnosti existuje mnoho výskumov, ktoré využívajú poznatky zo štatistiky, spracovania digitálneho obrazu a strojového učenia do automatizovania procesov diagnostiky v medicíne. Napríklad využitie strojového učenia pri hodnotení a klasifikácii dát z elektrokardiografie, počítačovej tomografie alebo magnetickej rezonancie. Diagnostické metódy v praxi budú vyžadovať tisíce tréningových dát, na ktorých základe budú merané dáta klasifikované. Vzhľadom na to, že ide o medicínske dáta, ich dostupnosť pre výskumníkov predstavuje problém, ale v posledných rokoch sú čoraz viac prístupné databázy, s ktorými je možné pracovať.

Dizertačná práca sa zaoberá rozpoznávaním schizofrenickej poruchy na základe nameraných dát z pohybov očí. Schizofréniou podľa štatistík trpí približne 1% svetovej populácie. Sledovanie pohybov očí je účinná metóda na skúmanie vzťahu medzi správaním subjektu a nervovými mechanizmami. Výskumy sa v posledných rokoch zameriavajú na hodnotenie kognitívnych funkcií jedinca na základe analýzy pohybov očí u pacientov. Abnormality pohybov očí a neurologických porúch, bežne spojených s kognitívnymi deficitmi, sa preukázali, napríklad pri poruchách ako amyotrofická laterálna skleróza (ALS), Alzheimerova choroba, demencia, Parkinsonova choroba, roztrúsená skleróza, epilepsia alebo schizofrénia.

Úvod práce je zameraný na opis dôležitých teoretických poznatkov pri vypracovaní našej práce. V ďalších kapitolách sa zameriame na analýzu súčasného stavu problematiky detekcie kognitívnych porúch a návrhu diagnostických postupov založených na strojovom učení. Spomenieme publikácie, ktoré prinášajú štúdie pohybov očí pri iných kognitívnych poruchách a tie, ktoré využívajú algoritmy strojového učenia. Keďže naša práca je zameraná na diagnostiku schizofrenickej poruchy, spomínané sú aj metódy založené na iných vstupných dátach. Tak môžeme porovnať výsledky s inými metódami, avšak zatiaľ sa táto vedecká oblasť iba rozvíja, vzhľadom na obmedzený prístup k dátam pacientov. V posledných kapitolách opisujeme dosiahnuté výsledky navrhovanej metódy a vyhodnocujeme vedecké prínosy práce. Na konci je uvedený zoznam použitej literatúry a publikácií autora.

2 Súčasný stav riešenia problematiky


Táto časť opisuje súčasný stav výskumu v oblasti diagnostických metód schizofrénie založených na strojovom učení a následne štúdie, ktoré analyzovali súvislosti schizofrénie a nepravidielností pohybov očí. O definíciu schizofrénie sa výskumníci snažia na základe analýzy veľkého množstva rôznych dát, ako napr. podľa záznamov z EEG, snímok z MRI a PET, alebo aj zo subjektívnych opisov pacienta - jeho výrazu tváre, reči, postoja a správania. Väčšina zatiaľ navrhovaných metód na detekciu schizofrénie vychádza z rôznych typov vyšetrení MRI alebo EEG [LAA21].

2.1 Detekcia schizofrénie a eye-tracking

Eye-tracker, na rozdiel napríklad od EEG technológie, poskytuje testovanému subjektu väčšiu mieru komfortu, čo je významné pri schizofrenických pacientoch. Štúdie v oblasti psychiatrie skúmajúce špecifiká očných pohybov jedincov s diagnostikovanou poruchou majú počiatok na začiatku 20. storočia [MMK20]. Prvá štúdia, ktorá opisuje odchýlky pohybov očí diagnostikovaných jedincov, bola zameraná na charakteristiku hladkých pohybov očí u jedincov so schizofróniou (v tom období nazývaná *dementia preacox*) a bipolárnou poruchou bola publikovaná v 1908 [DiD08]. V súčasnosti sú sledované a opísané ďalšie špecifické pohyby očí, ktoré diferencujú zdravých a diagnostikovaných jedincov. Detailne ich opíšeme v samostatnej kapitole.

Väčšina publikovaných výskumov je zameraná iba na opísanie a zhodnotenie rozdielov medzi skupinami testovaných jedincov pomocou štatistických metód. Návrhy na vytvorenie metód, ktoré automaticky klasifikujú na základe nameraných dát, je zatiaľ v tejto oblasti málo.

Rozdiely medzi zdravými a jedincami s diagnostikovanou schizofrenickou poruchou sú opísané v [LZC10]. Autori v experimente analyzovali pohyby očí testovaných subjektov vzhľadom na celkový počet fixácií, ich trvanie a miesto a dĺžku sakadických pohybov a zároveň použili pri diagnostike rovnaký vizuálny podnet - karty ROR (Rorschachovho) testu, ako bol použitý pri testovaní subjektov v datasete, ktorý sme využili v našom experimente .




Obr. 1: Fixácie subjektov (vľavo zdravý, vpravo diagnostikovaný) na ROR kartu č. 5 [Smo17].

Skupina pozostávala z 10 subjektov s diagnostikovanou schizofréniou a 10 subjektov v kontrolnej skupine, vybraných podľa pohlavia, veku a vzdelania. Priemerný vek subjektov bol 29,3 roka a priemerná dĺžka školskej dochádzky 7,6 roka. Pri experimente autori použili ROR test (karty I, II, V, VIII) a TAT - tematický a percepčný test (8 kariet, rozdelených do dvoch skupín - karty 6, 7, 10 a 12 zobrazujú tváre osôb a karty 2, 8, 9 a 13 zobrazujú zachytené objekty alebo scény z prírody). Vizuálne podnety boli prezentované na monitore. Výsledkom experimentov boli rozdiely pri sledovaní (skenovaní) daných vizuálnych stimulov u jedincov so schizofréniou; napríklad robili menej fixácií, ale fixácie mali dlhšie trvanie pri ROR kartách a tvárach TAT testu alebo mali rozdielne dĺžky sakád, v porovnaní s kontrolnou skupinou.

Výsledky ukázali najvýznamnejšie rozdiely medzi skupinami pri použití kariet ROR testu. V publikácii autori štatisticky vyhodnotili získané metriky pohybov očí, čím porovnali rozdiely medzi skupinami a potvrdili, že pri kognitívnych poruchách nastávajú zmeny v mechanizmoch vnímania abstraktných vizuálnych informácií.

Publikácia, ktorá sa zaoberá problematikou klasifikácie schizofrenického pacienta, je napríklad [KPC19]. Tento prístup využíva ako vstupné parametre klasifikátora sekvencie snímaných pozícií pohybov očí, ktoré sú mapované do oblastí Rorschachovho obrazu, kde je následne obraz segmentovaný na 7 oblastí (obr.2). Proces skenovania ROR karty charakterizujú Markovove reťazce, kde ich stavy predstavujú jednotlivé oblasti, ako je naznačené. Klasifikácia je založená na Gaussovom zmesovom modeli (GMM) a model upravený podľa rôznych nastavení, modifikácií a stratégií. Dataset pozostával zo 44 subjektov (22 diagnostikovaní a 22 kontrolná skupina) Najlepší výsledok bol pri použití vektora finálnych pravdepodobností ako funkcie modelu, kde priemerná úspešnosť klasifikácie bola 63,7% (STD $\pm 7,4$).



Obr.2: Rozdelenie ROR karty 5, podľa oblastí [KPC19].

V ďalšom článku [KPC19a] autormi navrhnutá metóda extrahuje celkový časový úsek v definovanom regióne a zameriava sa aj na trasu, akou jedinec skenuje oblasť Rorschachovej karty. Proces skenovania je vyjadrený Markovovým reťazcom a vybrané črty, ktoré sú ďalej klasifikované, sú vektory finálnych pravdepodobností a matice prechodov. Na klasifikáciu autori zvolili metódu K-Nearest Neighbors (KNN). Výsledná presnosť metódy bola v intervale 62 – 75% v závislosti od zvolených vstupných parametrov a nastavení algoritmu.

Ďalšie metódy klasifikácie dát sú opísané v [KPS20]. Autori vykonali komplexnú analýzu metód klasifikácie. Ako nástroj použili napríklad skrytý Markovov model (HMM), konvolučnú neurónovú sieť alebo rekurentnú neurónovú sieť s architektúrou dlhodobá krátkodobá pamäť (LSTM). Ako vstupné parametre klasifikátorov sa použili: namerané dáta pohybov očí, ktoré boli namapované do jednotlivých segmentov obrazu; dáta vizualizované vo forme „tepelných máp“ (*heat maps*) alebo segmentácia súradníc v časovej oblasti. Testovaný dataset bol rovnaký ako v [KPC19] a teda obsahoval 44 subjektov. Ako metóda s najvyššou úspešnosťou sa ukázalo použitie konvolučnej neurónovej siete založenej na „tepelných mapách“ ako vstupných parametrov s výsledkom 78,8% (STD $\pm$ 19).

V recenznom článku [WUH21] autori zhodnotili poznatky a výsledky v oblasti využitia navrhovanej metódy na detekciu schizofrénie. Autori konštatovali vysoký potenciál takého prístupu vzhľadom na výsledky výskumov.


3 Ciele dizertačnej práce

Na základe súčasného stavu problematiky sme definovali ciele dizertačnej práce a stanovili sme kroky na overenie úspešnosti metódy pomocou experimentov.

1. Modifikácia metódy, ktorá využíva na klasifikáciu saliency máp konvolučnú neurónovú sieť. V našom návrhu využijeme ako vstupy do CNN saliency mapy jednotlivých ROR kariet, prípadne ich kombináciu, keďže je preukázané, že jednotlivé karty majú rozdielne úspešnosti. Naším cieľom bude porovnať výsledky jednotlivých vstupov, prípadne nájsť vhodnú kombináciu ROR kariet a takisto aj nastavení parametrov konvolučnej neurónovej siete.
2. Návrh metódy na klasifikovanie saliency máp použitím vzájomnej informácie a klasifikátora KNN. Vzájomná informácia nám umožní merať podobnosť obrazov a porovnávať ich vzhľadom na ich entropiu. Výsledkom bude jednoduchá metóda na klasifikáciu saliency máp.
3. Porovnanie navrhnutých metód a vyhodnotenie ich úspešnosti.

4 Metódy detekcie schizofrenickej poruchy

Navrhnuté metódy riešenia klasifikácie schizofrenických pacientov a kontrolnej skupiny sú založené na saliency mapách, ktoré vznikli z dát pohybov očí meraných subjektov. Saliency mapy predstavujú z nášho pohľadu vhodné spracovanie dát z eye-trackera pre klasifikátory a zvolené metódy. Typické rozdiely pohybov očí je možné vidieť na obrázku dole (obr.3).



Obr.3: Príklady saliency máp subjektu z kontrolnej skupina (vľavo) a diagnostikovaného (vpravo).

Na uvedených príkladoch obrazov môžeme pozorovať rozdiel medzi diagnostikovaným a kontrolným jedincom. Je pozorovaný zrejмый rozdiel, kedy subjekt z kontrolnej skupiny „skenuje“ celú oblasť atramentovej škrvny ROR karty a diagnostikovaní sa v prevažnej miere zameriavajú na určitú časť škrvny, ako je vidieť na príklade (obr.3, vpravo). Pre lepšie zobrazenie a pre lepšiu viditeľnosť saliency máp sú invertované obrazy a pridané obrysy škvŕn ROR kariet.

4.1 Metóda klasifikácie pomocou korelačných matíc a GTC

Táto metóda je založená na spracovaní a analýze saliency máp využitím spracovania digitálneho obrazu a štatistických metód. Návrh metódy je pôvodne publikovaný v [PVC17] a v [SPK20] je prezentované rozšírenie metódy o ďalšie ortogonálne funkcie. Navrhovaný prístup je založený na klasifikátore, ktorý rozdeľuje dáta pohybov očí testovaných osôb na zdravých (kontrolná skupina) a schizofrenických jedincov.

Pre dve skupiny saliency máp - kontrolná skupina a diagnostikovaní, z ktorých každá obsahuje N subjektov sa vypočítali korelačné matice (pomocou Pearsonovho korelačného koeficientu) a výsledkom sú matice zdravých (1) a diagnostikovaných (2) subjektov:

$${}^N\mathbf{C}_H = \begin{pmatrix} 1 & & \dots & & \rho_{0,N-1} \\ & \ddots & & \rho_{i,j} & \\ \vdots & \vdots & 1 & \vdots & \vdots \\ & \rho_{j,i} & \dots & \ddots & \\ \rho_{N-1,0} & & \dots & & 1 \end{pmatrix} \quad (1)$$

$${}^N\mathbf{C}_D = \begin{pmatrix} 1 & \dots & \gamma_{0,N-1} \\ \vdots & \ddots & \vdots & \gamma_{i,j} \\ \vdots & \gamma_{j,i} & \dots & \ddots \\ \gamma_{N-1,0} & \dots & \dots & 1 \end{pmatrix} \quad (2)$$

Následne sa matice upravili podľa (3) a (4), kde koeficienty $E(\rho_{N,i})$ a $E(\rho_{j,N})$ sú stredné hodnoty korelačných koeficientov pre jednotlivé stĺpce a riadky korelačnej matice - pre každý riadok a stĺpec oboch matíc sa vypočíta stredná hodnota zdravých jedincov a $E(\gamma_{N,i})$ a $E(\gamma_{j,N})$ sú vypočítané pre diagnostikovaných. Následne sú teda pôvodné matice (22) a (23) rozšírené o tieto koeficienty.

$${}^{N+1}\mathbf{C}_{HE} = \begin{pmatrix} \begin{pmatrix} {}^N\mathbf{C}_H \end{pmatrix} & \begin{pmatrix} E(\rho_{j,N}) \\ \vdots \\ 1 \end{pmatrix} \\ E(\rho_{N,i}) & \dots \end{pmatrix} \quad (3)$$

$${}^{N+1}\mathbf{C}_{DE} = \begin{pmatrix} \begin{pmatrix} {}^N\mathbf{C}_D \end{pmatrix} & \begin{pmatrix} E(\gamma_{j,N}) \\ \vdots \\ 1 \end{pmatrix} \\ E(\gamma_{N,i}) & \dots \end{pmatrix} \quad (4)$$

Následne sa vypočíta dvojrozmerná ortogonálna transformácia z každej matice a $\mathbf{U}^{T*}$ je konjugovaná transpozícia matice $\mathbf{U}$:

$$\sqrt{\frac{1}{N+1}} {}^{N+1}\mathbf{U} {}^{N+1}\mathbf{C} {}^{N+1}\mathbf{U}^{T*} = \begin{pmatrix} \sigma_0^2 & \dots & \vdots \\ \vdots & \ddots & \vdots \\ \vdots & \dots & \sigma_N^2 \end{pmatrix} \quad (5)$$

Použité 2D transformácie sú.: diskretná Hartleyho transformácia (DHYT), diskretná sínusová transformácia (DST), diskretnú kosínusová transformácia II (DCT2) a diskretná kosínusová transformácia III (DCT3). Základné funkcie pre tieto transformácie sú definované [PVC17, RaY90]:

$${}^{DHYT}U_{k,n} = \frac{1}{\sqrt{N}} \cos\left(\frac{2\pi kn}{N}\right) + \sin\left(\frac{2\pi kn}{N}\right) \quad (6)$$

$${}^{DST}U_{k,n} = \sqrt{\frac{2}{N+1}} \sin\left(\frac{\pi(k+1)(n+1)}{N+1}\right) \quad (7)$$

$${}^{DCT2}U_{k,n} = \sqrt{\frac{2}{N}} c_k \cos\left(\frac{\pi k(2n+1)}{2N}\right) \quad (8)$$

$${}^{DCT3}U_{k,n} = \sqrt{\frac{2}{N}} c_n \cos\left(\frac{\pi(2k+1)n}{2N}\right) \quad (9)$$

Následne je z matíc vypočítaný maximálny zisk transformačného kódu (GTC), ktorý získame zakódovaním saliency máp pomocou zvolenej ortogonálnej transformácie. GTC sa vypočíta z hlavnej diagonály matice ako [PVC17]:

$$GTC({}^{N+1}\mathbf{C}) = \frac{1}{N+1} \frac{\sum_{i=0}^N \sigma_i^2}{(\prod_{i=0}^N \sigma_i^2)^{1/(N+1)}} \quad (10)$$

Napríklad ak je testovaný subjekt (môže byť zdravý alebo diagnostikovaný), sú vytvorené korelačné matice, ktoré obsahujú ďalší riadok a stĺpec. Tieto nové korelačné matice vyjadrujú podobnosť medzi testovaným (jeho saliency mapou) a všetkými ostatnými subjektami danej trénovacej skupiny, do ktorej je pridaný testovaný subjekt. Takýmto spôsobom je napríklad získaná nová matica, pre testovanie zdravého subjektu v trénovacej množine zdravých subjektov [PVC17]:

$${}^{N+1}\mathbf{C}_{HH} = \begin{pmatrix} \begin{pmatrix} {}^N\mathbf{C}_H \\ \rho_{N,i} \dots \end{pmatrix} & \begin{pmatrix} \rho_{j,N} \\ \vdots \\ 1 \end{pmatrix} \end{pmatrix} \quad (11)$$

kde:

$\rho_{N,i}$ je korelačný koeficient medzi testovanou saliency mapou zdravého subjektu a i -tou saliency mapou v trénovacej množine zdravých subjektov;

Nakoniec je definovaná klasifikačná metrika na určenie množiny pre daný testovaný subjekt. Pri klasifikácii je testovaný jeden subjekt a zvyšok datasetu predstavuje trénovacie údaje, čím a táto metóda odlišuje od pôvodnej aj v procese expero mentálneho overenia účinnosti. Takýto postup v budúcnosti dovoľí, aby sa v procese reálnej diagnostiky jednoducho zväčšoval trénovací dataset. Z trénovacích dát sa vypočítajú korelačné matice pre kontrolnú skupinu a diagnostikovaných jedincov. Potom sa vypočítajú korelačné matice s testovaným subjektom s použitím ortogonálnej transformácie. Klasifikácia testovaného subjektu je založená na metrike definovanej ako pomer medzi hodnotami GTC podľa testovaného subjektu, pričom bude splnená jedna z podmienok (15) a (16). V ideálnom prípade bude splnená len jedna z podmienok [PVC17]:

$$\left| 1 - \frac{GTC({}^{N+1}\mathbf{C}_{DD})}{GTC({}^{N+1}\mathbf{C}_{DE})} \right| \leq \left| 1 - \frac{GTC({}^{N+1}\mathbf{C}_{HD})}{GTC({}^{N+1}\mathbf{C}_{HE})} \right| \quad (15)$$

$$\left| 1 - \frac{GTC({}^{N+1}\mathbf{C}_{HH})}{GTC({}^{N+1}\mathbf{C}_{HE})} \right| \leq \left| 1 - \frac{GTC({}^{N+1}\mathbf{C}_{DH})}{GTC({}^{N+1}\mathbf{C}_{DE})} \right|. \quad (16)$$


4.2 Návrh metódy na deteciu pomocou konvolučnej neurónovej siete

V tejto metóde sme zvolili riešenie pomocou konvolučnej neurónovej siete. Na základe naštudovaného stavu súčasnej problematiky je tento klasifikátor vhodný na klasifikáciu obrazov – saliency máp, ktoré predstavujú vstupné dátá. V dizertačnej práci je CNN teoreticky opísaná v kapitole 3.4 a praktickú implementáciu opíšeme dosiahnutých výsledkoch experimentu. Na základe naštudovaných poznatkov sú CNN populárne hlavne z pohľadu 3 faktorov:

- eliminujú potrebu manuálnej extrakcie príznakov - príznaky sa učí priamo sieť z tréningových dát;
- poskytujú veľmi presné výsledky klasifikácie a rozpoznávania;
- dajú sa jednoducho pretrénovať na nové úlohy a problémy, čo nám umožňuje stavať na už existujúcich sieťach.

V metóde navrhujeme použitie 3 alebo 4 vrstvovej konvolučnej neurónovej siete. Vstupom sú saliency mapy, ktoré predstavujú vhodné predspracovanie pohybov očí testovaných subjektov.

Otestujeme hypotézu, či sa po spojení dvoch saliency máp zvýši úspešnosť klasifikácie pomocou CNN. V tomto kroku, sa zameriame na spojenie dvoch saliency máp, ktoré budú v experimentoch, kde budú klasifikované samostatne, vykazovať najvyššiu úspešnosť klasifikácie. Schéma (obr. 4) opisuje navrhnutú metódu.



Obr. 4: Postup klasifikácie dát v navrhnutej metóde.

4.2.1 Rozšírenie datasetu

V konvolučných neurónových sieťach je potrebné veľké množstvo vstupných dát, aby sa zabránilo pretrénovaniu (*overfitting*) siete. Vzhľadom na to, že mnohé oblasti, v ktorých sa siete aplikujú, nemajú prístup k dostatočne veľkému množstvu dát, ako sú napríklad pohyby očí schizofrenických pacientov. Rozšírenie údajov v datasete je súbor postupov, ktoré zväčšujú veľkosť a zvyšujú kvalitu tréningových dát tak, aby sa dali vytvoriť lepšie modely strojového učenia. Sú to napríklad geometrické transformácie, rozšírenie farebného priestoru, kernelové filtre, miešanie obrazov, náhodné vymazávanie, rozšírenie priestoru príznakov, alebo GAN (*Generative Adversarial Networks* - Generatívne súperiace siete) [HGY18, ShK19].

Ďalej sú známe dve používané možnosti rozšírenia datasetu. Prvá je známa ako „*offline*“, ktorá je uprednostňovaná pri relatívne malých súboroch dát. Nakoniec by sa dataset zväčšil o faktor rovnajúci sa počtu vykonaných transformácií (napríklad prevrátením všetkých obrazov by sa zväčšila veľkosť súboru dát o faktor 2). Druhá možnosť je známa ako „*online*“ alebo rozšírenie za behu a je používaná pri väčších súboroch. Dôvodom je to, že si nemôžeme dovoliť priveľké rozšírenie datasetu. Preto sa transformácie vykonávajú na menších „dávках“, ktoré sú

vkľadané priamo do modelu. Niektoré nástroje strojového učenia majú podporu pre online metódu, efektívne urýchľujú použitím GPU.

Takzvané neriadené rozšírenie dát znamená, že metódy nie sú spojené s triedami údajov. Pri klasifikačných úlohách obrazov sa na generovanie nových vzoriek z trénovacej množiny používajú niektoré metódy transformácie obrazu. Bežne používané metódy sú napríklad [SPP17]:

- prevrátenie (*flipping*) obrazu okolo horizontálnej alebo vertikálnej osi;
- rotácia v náhodnom smere;
- orezanie časti z pôvodného obrazu;
- posunutie obrázka doľava alebo doprava;
- úprava farieb – náhodné zmeny sýtosti farieb, jas a kontrastu vo farebnom priestore;
- pridanie náhodného šumu do RGB zložiek pixelov v obraze (používa sa napríklad Gaussov šum).


V našom experimente sme zvolili rozšírenie datasetu prevrátením obrazu okolo vertikálnej osi. Vzhľadom na typ vstupných obrazov – saliency mapy pohybov očí pri sledovaní ROR kariet, by iné formy rozšírenia datasetu (napr. rotácia, deformácia, úprava spektra farieb) neboli vhodné.

4.3 Návrh metódy na detekciu pomocou vzájomnej informácie

Ako ďalší klasifikátor sme zvolili KNN s odlišnými metrikami, na základe ktorých sú dáta klasifikované – KNN a vzájomná informácia medzi saliency mapami trénovacích a testovacích subjektov.

Vzájomná informácia je detailne opísaná v dizertačnej práci v kapitole 3.5. Klasifikátor KNN je podrobne opísaný v kapitole 3.2. V experimente navrhujeme výpočet vzájomnej informácie medzi obrazmi a následnú klasifikáciu týchto obrazov. Metóda je zameraná na overenie vhodnosti použitej metriky pre klasifikáciu zvoleného typu vstupných dát.

Použitie vzájomnej informácie je vhodné na klasifikáciu obrazov s podobnou entropiou, ako sú napríklad saliency mapy. Schéma dole (obr. 5) opíše postup pri klasifikácii na základe navrhutej metódy.



Obr. 5: Postup klasifikácie dát v navrhutej metóde.

5 Dosiahnuté výsledky metód a ich vyhodnotenie


5.1 Dataset v experimente

Meranie datasetu nebolo súčasťou riešenia dizertačnej práce a použité dáta boli merané v rámci inej výskumnej úlohy. Avšak namerané dáta sú kvalitné a použiteľné pre navrhnuté metódy, preto je tento dataset vhodný na ich overenie.


Pohyby očí testovaných subjektov boli merané pomocou systému Tobii X2-60 a riešenia Tobii Pro Studio. Vzorkovacia frekvencia pri meraní pohybov očí bola nastavená na 60 Hz. Jednotlivé karty Rorschachovho testu boli zobrazované na obrazovke s rozmerom 24 palcov a rozlíšením 1920 x 1200 pixelov. Testovanie sa uskutočňovalo v laboratóriu na Fakulte informatiky a informačných technológií FIIT STU v Bratislave vo Výskumnom centre používateľského zážitku a interakcie „UXI@FIIT“ a v neposlednom rade boli tieto merania vykonané aj v spolupráci so psychológmi z Filozofickej fakulty Univerzity Komenského a pod ich odborným dohľadom [PVC17, Smo17].

Klinická vzorka pozostávala zo 48 testovaných subjektov. 24 účastníkov so schizofréniou alebo schizoafektívnou poruchou a 24 osôb bez schizofrénie vybraných podľa pohlavia, veku a vzdelania, ktorá tvorila kontrolnú skupinu. Vzorka pacientov bola získaná z denných centier pre ľudí s duševnými chorobami, konkrétne DSS (Domova sociálnych služieb) Samária, DSS Most a OZ Sofia. Všetci ambulantní pacienti boli v súčasnej remisií a užívali antipsychotické lieky. Kritériá vylúčenia pre účastníkov v kontrolnej skupine boli anamnéza duševných chorôb aj u ich priamych príbuzných. V čase experimentu nikto z nich nemal nasadené lieky, ktoré majú sedatívny účinok [PVC17, Smo17].

Z nameraných dát očných pohybov boli vytvorené saliency mapy, ktoré predstavujú vstup do klasifikátora. V prípade klasifikátorov ako konvolučná neurónová sieť a KNN bola v experimente otestovaná každá z kariet ROR testu. Zvolená veľkosť Gaussovho filtra bola 50x50. Príklady vstupov samostatných ROR kariet sú na obrázkoch nižšie (obr. 6 a 7).




a




b

Obr. 6 a,b.







c



d

Obr.6: Príklady dát ROR karty č. 5 (a zdravý, b diagnostikovaný, obrazy c,d sú invertované obrazy s obrysmi pôvodných ROR kariet).



Obr.7: Príklady dát ROR karty č. 7 (vľavo zdravý, vpravo diagnostikovaný a dole sú invertované obrazy s obrysmi pôvodných ROR kariet).

5.2 Klasifikácia pomocou korelačných matíc a GTC

Návrh tejto metódy je prezentovaný v [PVC17] a jeho rozšírenie je s výsledkami, ktoré zohľadňujú túto úpravu publikované v [SPK20]. Výpočtami v tejto v metóde bola overená úspešnosť pre rozdielne 2D ortogonálne transformácie uvedené v autoreferáte, časť 4.1. Tabuľka 1 uvádza výsledky týchto experimentov, kde sú presnosti charakterizované celkovou úspešnosťou klasifikácie všetkých subjektov. Výsledky sú uvádzané iba pre ROR kartu 5, vzhľadom na úspešnosť klasifikácie pacientov pomocou tejto metódy, ktorá bola pôvodne publikovaná v [PVC17] a bol rovnako ako v uvedenej publikácii vykonaný na upravenom datasete, kde z celkového počtu 48 boli 4 osoby vyňaté kvôli nejednotnej diagnostike konvenčnými metódami a podozreniami na poruchy, ktoré môžu viesť k nejednoznačným výsledkom (spolu 44 – 22 kontrolná skupina, 22 - diagnostikovaní). Iné diagnózy sa u pôvodne vylúčených osôb doteraz nepreukázali. V práci sa preto ďalej pracovalo aj s týmito subjektami, aby bola overená účinnosť aj v zložitejších podmienkach.

Tab.1: Výsledky klasifikácie pre ROR kartu 5.

Transformácia	DHYT	DST	DCT II.	DCT III.
Celková [%]	65,9	70,45	68,18	72,72
Kontrolná skupina [%]	81,81	86,36	81,81	81,81
Diagnostikovaní [%]	50	54,54	54,54	63,63

Najlepší výsledok celkovej miery správnej identifikácie je pri použití DCT3 72,72 %. Táto ortogonálna transformácia vykázala aj najlepšiu presnosť pre diagnostikované osoby, ktorá dosahuje 63,63 %. Zdraví jedinci boli správne identifikovaní, keď sme použili DST, s presnosťou 86,69 %.

S výsledkami publikácie [PVC17] dosiahnuté výsledky nie sú porovnávané, lebo na základe vyjadrenia školiteľa, ktorý je hlavným autorom citovanej publikácie, výsledky zo štúdie boli určené len na potvrdenie, že saliency mapy môžu byť zaujímavým podkladom pre automatickú detekciu schizofrénie. Proces tréningu a testovania nie je dostatočný na to, aby výsledky mohli byť považované za referenčné.

5.3 Konvolučná neurónová sieť

Pre riešenie konvolučnej neurónovej siete sme zvolili prostredie Matlab. Na vytvorenie a tréning CNN bolo uvažované aj prostredie TensorFlow (voľne dostupná platforma vyvinutá tímom Google Brain). Po zhodnotení skúseností a naštudovaní problematiky rozdielov medzi oboma prostrediami sme sa rozhodli pre Matlab.

Veľkosť vstupných obrazov je 956 x 669. Pôvodný počet (24 diagnostikovaní jedinci a 24 kontrolná skupina) obrazov datasete bol po rozšírení dvojnásobný (96). Pri nasadení v reálnych aplikácia bude potrebné optimalizovať veľkosť vstupných dát, aby bol výpočet rýchly a hlavne mal najvyššiu presnosť. V našom experimente sme na porovnanie rýchlosti výpočtu pri zmenšených vstupných obrazoch nezameriavali.

V našom experimente sme na klasifikáciu použili neurónové siete s počtom konvolučných vrstiev 3 alebo 4. Ak použijeme konvolučnú neurónovú sieť s dvoma konvolučnými vrstvami, prvá vrstva je nastavená na veľkosť 3x3 s množstvom 8. Filtre nasledujúcej konvolučnej vrstvy sú nastavené na veľkosť 3x3 s množstvom 16. Tieto konvolučné vrstvy sú rovnaké ako pre konvolučnú neurónovú sieť s tromi vrstvami. Tretia konvolučná neurónová vrstva je nastavená pomocou filtrov na veľkosť 3x3 s množstvom 32. Tretia konvolučná neurónová vrstva je nastavená pomocou filtrov na veľkosť 3x3 s množstvom 64. Na učenie sa konvolučnej neurónovej siete sa používa *Stochastic Gradient Descent with Momentum* (SGDM). Počiatočná rýchlosť učenia pre SGDM je 0,01. Po každej iterácii sa údaje o tréningu preskupia. Maximálny počet tréningových epoch je 25.

Výsledky presností klasifikácie saliency máp sú uvedené v tabuľkách (tab. 3 a tab. 4). Pri tréňovaní sme zvolili rozdelenie na 42 tréningových a 6 validačných obrazov pre každú skupinu. Pre obrazy, ktoré vznikli po rozšírení datasetu bolo zabezpečené, aby neboli súčasťou tréningových dát, ak boli v testovacej množine.

Najvyššiu úspešnosť dosiahli saliency mapy kariet 5 a 7. Pri 3 konvolučných vrstvách to bolo 70,55% (STD ± 12), respektíve 67,5% (STD $\pm 12,2$). Pri 4 konvolučných vrstvách táto presnosť bola vyššia 71,7% (STD $\pm 11,7$) a 67,7% (STD $\pm 12,3$). Výsledky sú súčasťou tab. 3 a tab. 4. Priemerný čas na natréňovanie siete bol 9,2 minúty. V prípade použitia menších vstupných obrazov by sa tento čas znížil, ale sú vyžadované ďalšie experimenty na overenie a nájdenie vhodnej veľkosti, s ohľadom na najvyššiu úspešnosť klasifikácie diagnostikovaných subjektov.

Overenie predpokladu, či spojenie vstupných saliency máp zvýši presnosť klasifikácie, sme overili na obrazoch 5 a 7. Výsledky sú v tabuľkách nižšie (tab. 2 a tab. 3). Na základe výsledkov je viditeľné nezanedbateľné zvýšenie presnosti klasifikácie pre 4-vrstvovú konvolučnú sieť na 73,1% a mierne sa zvýšila stabilita výsledkov (STD $\pm 11,3$). V porovnaní s jedným vstupným obrazom (napr. karta 5) zaradenie karty 7 do diagnostickej metódy 5 + 7 znamená zvýšenie presnosti reálne o jedného človeka (čo je pri 48-mich subjektoch významné) a dokonca sa aj zvýšila „stabilita“ výsledku. Pri týchto vstupných dátach sa zvýšil aj čas na tréňovanie siete, kedy bola jeho minimálna dĺžka 14,5 minúty. Pri kombinácií iných kariet sa presnosť klasifikácie nezvýšila, vzhľadom na časovú náročnosť výpočtov sme v experimente s kombináciami nepokračovali.

Tab. 2: Výsledky pre 3 konvolučné vrstvy.

	ROR karta					
	1	2	3	4	5	
úspešnosť [%]	51,5	64,1	55,9	49,5	70,55	
STD	11	12,3	11,5	11,1	12	
max [%]	66,7	83,33	66,7	66,7	100	
	ROR karta					
	6	7	8	9	10	5 + 7
úspešnosť [%]	63,1	67,5	59,5	53,3	50,6	71,9
STD	13	12,2	12,7	13,5	12,8	13,3
max [%]	83,33	83,33	83,33	83,33	83,33	83,33

Tab. 3: Výsledky pre 4 konvolučné vrstvy.

	ROR karta					
	1	2	3	4	5	
úspešnosť [%]	52,1	65,3	56,5	52,1	71,7	
STD	11,7	11,5	12	11,4	11,7	
max [%]	66,7	83,33	66,7	66,7	100	
	ROR karta					
	6	7	8	9	10	5 + 7
úspešnosť [%]	63,1	67,7	60,4	53,9	51,1	73,1
STD	13	12,3	12,9	12,2	12,6s	11,3
max [%]	83,33	100	83,33	83,33	83,33	100

Navrhnutá metóda bola publikovaná v [SPN21]. V kapitole 7.5 dizertačnej práce, porovnávame výsledky s inými metódami na detekciu schizofrénie. Na rozdiel od výsledkov vyššie boli tieto metódy overené na pôvodnom zmenšenom datasete v porovnaní s opísanými experimentami.

5.4 KNN a vzájomná informácia

V prípade algoritmu KNN, sme zvolili porovnanie korelačnej metriky a metriky vypočítanej na základe vzájomnej informácie. Korelačná metrika bola zvolená ako porovnávacia na základe skúseností z iných aplikácií v spracovaní obrazov. Využili sme funkciu v Matlabe na klasifikáciu dát, resp. obrazov. Hodnoty K sme zvolili K=5 a K=7. Výpočet korelačnej metriky (vzdialenosti) je implementovaný v danej funkcii. Na výpočet hodnoty vzájomnej informácie sme využili poznatky z kapitoly 3.5 a na základe toho hodnotu vypočítali. V tomto experimente sme rozšírený dataset nepoužili. Trénovacia vzorka pozostávala z 20 trénovacích a zvyšok boli testovacie dáta. Presnosť klasifikácie sme vypočítali pre každý obraz. Vstupy klasifikátora predstavovali saliency mapy, rovnako ako v prípade konvolučnej neurónovej siete.

Výsledky sú uvedené v tabuľkách pri výpočte vzdialenosti pomocou korelačnej metriky (tab. 4), a taktiež aj výsledky pri výpočte, ak bola metrika vzájomná informácia. Najvyššia presnosť 67,5% bola dosiahnutá pri ROR karte 2 pri výpočte vzdialenosti pomocou vzájomnej

informácie, pre $K=5$. Potvrdilo sa, že vzájomná informácia je vhodnou metrikou na porovnávanie saliency máp získaných z ROR testov. Navyše sa ukázalo, že úspešnosť klasifikácie pri karte 2 je pri použití vzájomnej informácie v jednoduchom KNN vyššia, ako bola dosiahnutá oveľa sofistikovanejšou CNN. To môže naznačiť potrebu vhodného predspracovania vstupných dát, aby sa mohol využiť potenciál aj iných kariet.

Tab. 4: Výsledky presnosti klasifikácie [%] algoritmom KNN.

ROR karta	korelačná metrika		vzájomná informácia	
	K = 5	K = 7	K = 5	K = 7
1	41,5 (STD 4,4)	40 (STD 3,2)	42,4 (STD 2,1)	39,5 (STD 2,7)
2	60,5 (STD 2,9)	62,5 (STD 3,5)	63,7 (STD 2,3)	67,5 (STD 2,6)
3	49,1 (STD 3,4)	48,5 (STD 4,5)	37,1 (STD 3,7)	40,5 (STD 3)
4	46,4 (STD 4,2)	47,1 (STD 3,2)	36,2 (STD 3,8)	38,4 (STD 2,9)
5	58,8 (STD 2,5)	59,1 (STD 2,8)	62,7 (STD 3,3)	61,6 (STD 2,1)
6	58,7 (STD 3,3)	57,9 (STD 2,9)	59,8 (STD 2,5)	60,9 (STD 3,2)
7	60 (STD 1,9)	59,4 (STD 3,1)	64,6 (STD 2)	63,4 (STD 2,1)
8	50,1 (STD 3,9)	52,1 (STD 2,4)	55,2 (STD 2,1)	59,3 (STD 2,8)
9	47,5 (STD 3,2)	46,5 (STD 3,9)	49,2 (STD 3)	44,4 (STD 3,7)
10	37,8 (STD 4,1)	38,1 (STD 4,7)	36 (STD 4,3)	39,1 (STD 3,9)

5.5 Sumarizácia zhodnotenia navrhnutých metód

V tab. 5 sú zhrnuté všetky významné výsledky nami navrhnutých metód dosiahnuté v experimentoch na kompletnom datasete 48 osôb. Najvyššiu úspešnosť ($73,1 \pm 11,3$) dosahuje metóda založená na použití konvolučnej neurónovej siete a kombinácii vstupných saliency máp na základe kariet 5 a 7.

Tab. 5: Dosiahnuté výsledky presnosti klasifikácie navrhnutých metód [%].

	KNN (vzájomná informácia)		CNN		GTC (DCT III)*
ROR karta	K = 5	K = 7	3 konvolučné vrstvy	4 konvolučné vrstvy	
1	42,4 (STD 2,1)	39,5 (STD 2,7)	51,5 (STD 11)	52,1 (STD 11,7)	
2	63,7 (STD 2,3)	67,5 (STD 2,6)	64,1 (STD 12,3)	65,3 (STD 11,5)	
3	37,1 (STD 3,7)	40,5 (STD 3)	55,9 (STD 11,5)	56,5 (STD 12)	
4	36,2 (STD 3,8)	38,4 (STD 2,9)	49,5 (STD 11,1)	52,1 (STD 11,4)	
5	62,7 (STD 3,3)	61,6 (STD 2,1)	70,55 (STD 12)	71,7 (STD 11,7)	72,72
6	59,8 (STD 2,5)	60,9 (STD 3,2)	63,1 (STD 13)	63,1 (STD 13)	
7	64,6 (STD 2)	63,4 (STD 2,1)	67,5 (STD 12,2)	67,7 (STD 12,3)	
8	55,2 (STD 2,1)	59,3 (STD 2,8)	59,5 (STD 12,7)	60,4 (STD 12,9)	
9	49,2 (STD 3)	44,4 (STD 3,7)	53,3 (STD 13,5)	53,9 (STD 12,2)	
10	36 (STD 4,3)	39,1 (STD 3,9)	50,6 (STD 12,8)	51,1 (STD 12,6)	
5 +7			71,9 (STD 13,3)	73,1 (STD 11,3)	

* experiment s GTC bol vykonaný len na zmenšenom datasete (44 – 22 kontrolná skupina, 22 - diagnostikovaní)

Aby na bolo možné zhodnotiť a porovnať výsledky navrhnutých metód s inými publikovanými metódami so zmenšeným datasetom, zmenšili sme testovaný dataset z pôvodného počtu subjektov (48) na modifikovaný, kde boli určité subjekty vyradené. Takto modifikovaný dataset obsahoval 44 subjektov (22 kontrolná skupina a 22 diagnostikovaní). Je rovnaký ako vo všetkých publikovaných metódach, s ktorými sa porovnáваме.

Tabuľka (tab. 5) obsahuje výsledky ďalších experimentov. Výsledky porovnáваме s metódami publikovanými v [KPC19] a [KPS20]. Metóda, ktorá je opísaná v [KPC19] klasifikuje dáta

pohybov očí s využitím Markovových reťazcov pomocou GMM, podrobnejšie je opísaná v kapitole 4.3 dizertačnej práce a najvyššia dosiahnutá presnosť klasifikácie bola 63,7% (STD $\pm 7,4$). Doteraz najúčinnejšia publikovaná metóda, ktorá bola publikovaná v [KPS20], je založená na klasifikácii saliency máp s veľkosťou Gaussovho filtra 20x20 a využitím CNN, kde dosiahla úspešnosť 78,75% (STD ± 19). Autori v [KPS20] porovnali ich navrhnuté diagnostické metódy s referenčnou diagnostickou metodikou publikovanou v [LZC10], ktorá je založená na počte fixácií a sakád, mediánu dĺžky fixácií a sakád, mediánu a maximálnej rýchlosti sakád a dĺžky trasy skenovania. Najvyššia presnosť bola 71,2% (STD $\pm 6,2$) pre FNN (doprednú neurónovú sieť), s 200 neurónmi a dvoma skrytými vrstvami [KPS20].

Tab. 7: Porovnanie metód a ich presnosti klasifikácie [%], v zátvorke je uvedená STD.

ROR karta	CNN (3-vr.)	CNN (4-vr.)	KNN (K=5)	KNN (K=7)	GTC	GMM [KPC19]	CNN [KPS20]	FNN [LCZ10]
5	77,3 (11,2)	78,1 (10,6)	67,6 (1,9)	64,9 (2,9)	72,72	63,7 (7,4)	78,75 (19)	71,25 (6,2)
7	72,3 (12)	73,7 (11,9)	68,5 (2,2)	65,1 (3)				
5 +7	76,6 (9,7)	79,4 (10,1)						

a

V našich metódach sme pre redukovaný dataset vykonali experimenty iba pre saliency mapy ROR kariet 5, 7 a ich kombináciu s veľkosťou Gaussovho filtra 50x50. Použili sme navrhnuté metódy s 3- a 4-vrstvovou CNN a klasifikátor KNN s využitím vzájomnej informácie. Z výsledkov vyplýva, že použitie 4-vrstvovej CNN a vstupných dát ako kombinácie saliency máp kariet 5+7 preukazuje najvyššiu úspešnosť pri porovnaní s podobnými metódami. Výsledok je lepší ako doteraz najlepší publikovaný výsledok s týmto datasetom s významne menším rozptylom. Experimenty s ostatnými kartami na redukovanom sme nevykonali, pretože by ich nebolo s čím porovnať.

6 Pôvodné vedecké prínosy

Cieľom dizertačnej práce je priniesť nové poznatky, ktoré poskytnú možnosti zlepšenia v oblasti automatických diagnostických metód schizofrénie. Naše návrhy sú založené na metódach strojového učenia a spracovania dát. Vzhľadom na aktuálnosť danej problematiky sa tieto metódy stále vyvíjajú a testujú. Nasadenie strojového učenia v lekárskej praxi pri diagnostike rôznych ochorení bude ešte vyžadovať mnoho rokov výskumu a vývoja. Počas toho sa ešte ukáže mnoho prekážok, ako sú napríklad obmedzený prístup k medicínskym dátam alebo nedostatočné investície do zdravotníctva. Rýchly technologický progres však umožňuje vo vedeckej oblasti návrhy a testovanie metód, ktoré už v blízkej budúcnosti môžu byť implementované v klinickej praxi.

Metódy navrhnuté v práci sú založené na konvolučnej neurónovej sieti a na klasifikátore KNN. Po naštudovaní problematiky sme zvolili tieto algoritmy, keďže v oblasti strojového učenia vykazujú vysokú úspešnosť a používajú sa už dlhodobo napr. v celom spektre priemyslu, kde je potrebné spracovanie dát, ako je hlavne obrazová informácia (napr. kontrola kvality súčiastok, rozpoznávanie tváre, riadenie autonómnych vozidiel, atď). V našej práci sme dáta pohybov očí testovaných subjektov, spracovaných do formy saliency máp, klasifikovali pomocou metód na základe zvolených algoritmov a výsledky sme vyhodnotili a porovnali.

Nami navrhnuté metódy je možné po otestovaní na dostatočne veľkej vzorke dát (*v našom experimente sme boli obmedzení dostupnými dátami*) implementovať vo vhodnom softvéri a nasadiť v klinickej praxi, kde budú následne musieť byť dodatočne testované pod dohľadom odborníka. Po úspešnom otestovaní by sa tieto aplikácie mohli stať súčasťou bežného vyšetrenia, kedy by mohli pomôcť odhaliť kognitívnu poruchu včas, a tým zvýšiť kvalitu ľudského života.

Výsledky môžeme zhrnúť do nasledovných bodov:

1. Návrh metódy na klasifikáciu subjektov na základe kombinácie saliency máp získaných z pohybov očí jednotlivých subjektov pri prezeraní jednotlivých ROR kariet pomocou CNN.
2. Použitie vzájomnej informácie v algoritme KNN.
3. Modifikácia metódy klasifikácie saliency máp na základe GTC.

7 Závery pre ďalší rozvoj vedy a praxe

Dizertačná práca sa zaoberala prehľadom súčasného stavu problematiky detekcie kognitívnej poruchy a použitia poznatkov z oblasti strojového učenia. V súčasnosti je najvýznamnejším problémom tejto oblasti nedostatok dát na natrénovanie algoritmu, čo by umožnilo vytvorenie softvérovej implementácie pre použitie v klinickej praxi. Avšak v práci sme pomocou experimentov, kde sme využili získané dáta pohybov očí meranej skupiny subjektov pozostávajúcich zo schizofrenických pacientov a kontrolnej skupiny, overili navrhnuté metódy vhodnej ako súčasť potencionálnej aplikácie na detekciu poruchy, ktorá môže byť nasadená v praxi.

Aj napriek malému datasetu výsledky experimentov zameraných na detekciu schizofrenickej poruchy preukázali výsledky, ktoré zvýšia kvalitu života pacientov, ktorým môže byť včas diagnostikovaná schizofrenická porucha. Bežný život každý deň dokazuje, že implementácia algoritmov strojového učenia v zdravotníctve je už v súčasnosti nevyhnutná s ohľadom na digitalizáciu dát a používanie bežne dostupných technológií (napr. nositeľná elektronika) a hlavne čoraz väčším nedostatkom odborného personálu a s tým narastajúce nároky, ktoré častokrát vedú k zlyhaniu ľudského faktora.

V práci sme sa zamerali na dáta získané z eye-trackera a následne z týchto dát, vytvorených saliency máp, kde podstata navrhnutých metód spočíva vo významných rozdieloch medzi schizofrenickými pacientmi a kontrolnou skupinou. Ďalším krokom v rozvoji metód na detekciu schizofrenickej poruchy môže byť sledovanie ďalších metrík (napr. čas skenovania podnetu, kombinácia s EEG, ...). Prípadne na rozdiel od ROR obrazov iné vizuálne podnety, ako čítanie textu alebo sledovanie iných obrazov, resp. videí (ľudské tváre, príroda...).

Na základe výsledkov vidno, že zrejme pre každú ROR kartu bude potrebné určiť vhodný klasifikátor. Zrejme ide o podobný jav ako napríklad pri hodnotení kvality videa po kódovaní. V prípade hodnotenia kvality videa už vieme, že subjektívne hodnotenie ovplyvňujú napríklad farba (farebnejšie sa zdá kvalitnejšie), obsah videa (ovplyvňuje emócie) atď. *Vyzerá, že v prípade automatickej diagnostiky schizofrénie na základe ROR kariet je tiež niekoľko vecí, čím sa jednotlivé výsledky odlišujú najmä vo vzťahu k tomu, ako sú kognitívne alebo emočne náročné, napr. karta č. 5 je najmenej kognitívne aj afektívne náročná, 7 je o niečo ťažšia na kognitívne uchopenie, ale nebýva emočne zaťažujúca, ale 2 je afektívne veľmi silná (červené asociácie vyvolávajú úzkosť, hnev a pod.), čo má dopad aj na kognitívne funkcie.* (Málišová, osobná komunikácia).

Na základe výsledkov dizertačnej práce je zrejmá účinnosť použitia konvolučnej neurónovej siete, hlavne v prípade spracovania obrazových dát. Môžeme teda konštatovať, že je potrebné ďalšie rozšírenie objemu dát na ďalšie otestovanie metód a následné otestovanie iných metrík získaných z eye-trackera. Výsledky naznačili potrebu osobitného prístupu k predspracovaniu vstupných dát a použitia rozdielnych prístupov ku klasifikácii dokonca aj obrazových vnemov jednej triedy (pozri klasifikáciu máp karty 2 pomocou KNN). Nasledujúcim krokom k implementácii diagnostického nástroja je kombinácia týchto znalostí a vytvorenie aplikácie, ktorá po vhodnom otestovaní pod dohľadom zodpovedných inštitúcií môže byť nasadená v praxi.

Zoznam použitej literatúry

[DiD08] Diefendorf, A.R., & Dodge, R. AN EXPERIMENTAL STUDY OF THE OCULAR REACTIONS OF THE INSANE FROM PHOTOGRAPHIC RECORDS. *Brain*, 31, 451-489.

[HGY18] Hussain, Z., Gimenez, F., Yi, D., Rubin, D. (2018). Differential Data Augmentation Techniques for Medical Imaging Classification Tasks. *AMIA ... Annual Symposium proceedings. AMIA Symposium*, 2017, 979–984.

[KPC19] Kacur J., Polec J., Csoka F., and Smolejova E., "GMM Based Detection of Schizophrenia Using Eye Tracking," 2019 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB), Siena, Italy, 2019, pp. 1-4, doi: 10.1109/CIBCB.2019.8791239.

[KPC19a] Kacur J., Polec J., and Csóka F. "Eye Tracking and KNN Based Detection of Schizophrenia," 2019 International Symposium ELMAR, 2019, pp. 123-126, doi: 10.1109/ELMAR.2019.8918840.

[KPS20] Kacur J, Polec J, Smolejova E, Heretik A. An Analysis of Eye-Tracking Features and Modelling Methods for Free-Viewed Standard Stimulus: Application for Schizophrenia Detection. *IEEE J Biomed Health Inform.* 2020 Nov;24(11):3055-3065. doi: 10.1109/JBHI.2020.3002097. Epub 2020 Nov 4. PMID: 32750936.

[LAA21] Lai, J. W., Ang, C., Acharya, U. R., & Cheong, K. H. (2021). Schizophrenia: A Survey of Artificial Intelligence Techniques Applied to Detection and Classification. *International journal of environmental research and public health*, 18(11), 6099. <https://doi.org/10.3390/ijerph18116099>

[LZC10] Lukasova K., Zanin L. L., Chucre M. Valois M., de Gamaliel C. & de Macedo E. C. (2010). Analysis of exploratory eye movements in patients with schizophrenia during visual scanning of projective tests' figures. *Jornal Brasileiro de Psiquiatria*, 59(2), 119-125. <https://doi.org/10.1590/S0047-20852010000200007>

[MMK20] Morita, K, Miura, K, Kasai, K, Hashimoto, R. Eye movement characteristics in schizophrenia: A recent update with clinical implications. *Neuropsychopharmacol Rep.* 2020; 40: 2– 9. <https://doi.org/10.1002/npr2.12087>

[PVC17] Polec, J., Vargic, R., Csóka, F., Bieliková, M., Svrček, M., Móro, M., Smolejová, E., Heretik, A. Detection of Schizophrenia Spectrum Disorders Using Saliency Maps. *AICT 2017: 11th IEEE International conference on application of information and communication technologies*. Moscow, Russia. September 20-22, 2017. Piscataway: IEEE, pp. 398-402. 2017.

[RaY90] Rao K.R., Yip. P. (1990). Discrete cosine transform: algorithms, advantages, applications. Academic Press Professional, Inc., USA.

[ShK19] Shorten, C., Khoshgoftaar, T.M. A survey on Image Data Augmentation for Deep Learning. *J Big Data* 6, 60 (2019). <https://doi.org/10.1186/s40537-019-0197-0>

[Smo17] Smolejová, E. Špecifiká očných pohybov u pacientov so schizofréniou počas vizuálneho spracovania Rorschachovho testu. Univerzita Komenského v Bratislave FiF FiF.KPs, 2017. 68 s. Diplomová práca.

[SPK20] Skunda, J., Polec, J., Kacur, J., Nerusil, B., Almasi, M., Málišová, E. "Orthogonal Transform Coding Theory for Schizophrenia Disorder Detection," 2020 ELEKTRO, 2020, pp. 1-4, doi: 10.1109/ELEKTRO49696.2020.9130648.

[SPK20] Skunda, J., Polec, J., Kacur, J., Nerusil, B., Almasi, M., Málišová, E. "Orthogonal Transform Coding Theory for Schizophrenia Disorder Detection," 2020 ELEKTRO, 2020, pp. 1-4, doi: 10.1109/ELEKTRO49696.2020.9130648.

[SPP17] Shijie, J., Ping, W., Peiyi, J., Siping, H. (2017). Research on data augmentation for image classification based on convolution neural networks. 4165-4170. 10.1109/CAC.2017.8243510.

[WUH21] Wolf, A., Ueda, K. and Hirano, Y. (2021), Recent updates of eye movement abnormalities in patients with schizophrenia: A scoping review. Psychiatry Clin. Neurosci., 75: 82-100. <https://doi.org/10.1111/pcn.13188>

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 *SPSymposium 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/SPSymposium51155.2020.9593313. **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 schizophrenia 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**

Ostatné publikácie

ADC Vedecké práce v zahraničných karentovaných časopisoch

ADC02 ŠKUNDA, Juraj [34 %] - BAROŇÁK, Ivan [33 %] - CHROMÝ, Erik [33 %]. Theoretical approach to optimization of home subscriber server in IP multimedia subsystem. In *Wireless personal communications*. Vol. 110, Iss. 4 (2020), s. 1825-1837. ISSN 0929-6212 (2020: 1.671 - IF, Q4 - JCR Best Q, 0.302 - SJR, Q3 - SJR Best Q). V databáze: SCOPUS: 2-s2.0-85074340976 ; CC: 000528671000001 ; DOI: 10.1007/s11277-019-06813-0. **Kat. A-**

ADM Vedecké práce v zahraničných časopisoch registrovaných v databázach Web of Science alebo SCOPUS

ADM01 ŠKUNDA, Juraj [50 %] - BAROŇÁK, Ivan [50 %]. Dimensioning of home subscriber server in IP multimedia subsystem. In *Advances in Electrical and Electronic Engineering*. Vol. 15, No. 4, Special Issue (2017), s. 577-584. ISSN 1336-1376 (2017: 0.274 - SJR, Q2 - SJR Best Q). V databáze: SCOPUS: 2-s2.0-85037660047 ; WOS: 000424328700001. **Kat. A+**

AFD Publikované príspevky na domácich vedeckých konferenciách

AFD03 ŠKUNDA, Juraj [50 %] - PILKO, Matej [50 %]. The model based on the 2D principal component analysis. In Redžúr 2018 : 12th International workshop on multimedia information and communication technologies. Bratislava, Slovakia. May 15, 2018. 1. vyd. Bratislava : Vydavateľstvo Spektrum STU, 2018, S. 45-47. ISBN 978-80-227-4793-6. **Kat. B**

Riešené výskumné projekty

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)
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 - 30.06.2022, riešiteľ)

Resumé

Title: Detection of schizophrenia by machine learning methods

Keywords: machine learning, neural networks, schizophrenia, diagnostic method

This dissertation reviews the current state of the art in cognitive impairment detection and the application of machine learning knowledge. Currently, the most significant problem in this area is the lack of data to train an algorithm that would allow the creation of a software implementation for use in clinical practice. However, in this work, we have validated the proposed method suitable as part of a potential disorder detection application that can be deployed in practice by means of experiments using the acquired eye movement data of a measured group of subjects consisting of schizophrenic patients and a control group.

The methods proposed in this paper are based on convolutional neural network and KNN classifier. After studying the problem, we have chosen these algorithms since they show a high success rate in the field of machine learning and have been used for a long time, e.g., in a wide range of industries where data processing is needed, such as mainly image information (e.g., quality control of parts, face recognition, driving autonomous vehicles, etc.). In our work, we have classified the eye movement data of test subjects, processed into saliency maps, using methods based on the chosen algorithms, and evaluated and compared the results.

Despite the small dataset, the results of experiments aimed at detecting schizophrenic disorder have shown results that will enhance the quality of life of patients who may be diagnosed early with schizophrenic disorder. Everyday life proves that the implementation of machine learning algorithms in healthcare is already essential in view of the digitalization of data and the use of commonly available technologies (e.g. wearable electronics) and, most importantly, the increasing scarcity of professional staff and the associated increasing demands that often lead to human factors failure.

Based on the results of this dissertation, the effectiveness of using convolutional neural network is evident, especially in the case of image data processing. Thus, we can conclude that further expansion of the data volume is needed to further test the methods and subsequently test other eye-tracker derived metrics. The results indicated the need for a specific approach to preprocess the input data and to use different approaches to classify even single-class image sensations (see the classification of Card 2 maps using KNNs). The next step towards the implementation of a diagnostic tool is to combine this knowledge and create an application that can be deployed in practice after appropriate testing under the supervision of the responsible institutions.