

*Pázmány Péter Katolikus Egyetem
Információs Technológiai és Bionikai Kar
Roska Tamás Műszaki és Természettudományi Doktori Iskola*



Köllőd Csaba Márton

Agy-Számítógép Kapcsolatok Fejlesztése
Mélytanulási Technológiák Felhasználásával

PhD Disszertáció tézisei

Témavezető: Ulbert István, DSc

Budapest, 2023

1. Bevezetés

Az agy-számítógép kapcsolatok (angolul: Brain-Computer Interface, továbbiakban: BCI) korunk egyik folyamatosan innováló és fejlődő interdiszciplináris területe, amely jelentős potenciállal rendelkezik olyan rendszerek kifejlesztésében, melyek lehetővé teszik alanyok számára, hogy kizárólag agyi tevékenységük módosításával kommunikáljanak, irányítsanak és interakcióba lépjenek számítógépes eszközökkel, motoros irányítás vagy más fizikai kontroller használata nélkül. Ez a technológia jelentősen javíthatja a látás-, hallás-, mozgás-, vagy kommunikációs zavarokkal élő emberek életminőségét, továbbá előnyös lehet azok számára, akik betegség vagy sérülés következtében Locked In szindrómában szenvednek. Ezen betegség megakadályozza az embereket abban, hogy neuromuszkuláris csatornáikat használva mozgassák testüket, noha kognitív állapotukban ezek az emberek teljesen egészségesek.

A BCI-k nagy potenciállal rendelkeznek, ugyanakkor a kutatási területen még mindig jelentős kihívásokkal kell szembenézni. Az egyik fő kihívás a BCI rendszerek pontosságának és megbízhatóságának javítása, mely kiemelten nehéz feladatnak számít valós idejű felhasználás esetén a folyamatosan változó környeze-

ti és felhasználói állapotok miatt. Ezenkívül a kommunikációs rendszereken alapuló BCI-k jelentősen lassabbak lehetnek a hagyományos kommunikációs csatornáknál. Ugyanakkor a kommunikáció képességének visszaállítása rendkívüli hatással lehet az alany életminőségének javulásában, függetlenül a kommunikáció sebességétől.

Ezen disszertáció egy BCI rendszert mutat be, amelyet tetraplégias betegek használhatnak videójáték vezérlésére. Továbbá különböző osztályozási módszereket vizsgál és hasonlít össze annak érdekében, hogy továbbfejlessze az BCI technológia területét. A tanulmány magában foglalja a jelfeldolgozó algoritmusok és gépi tanulási modellek fejlesztését.

2. Módszerek

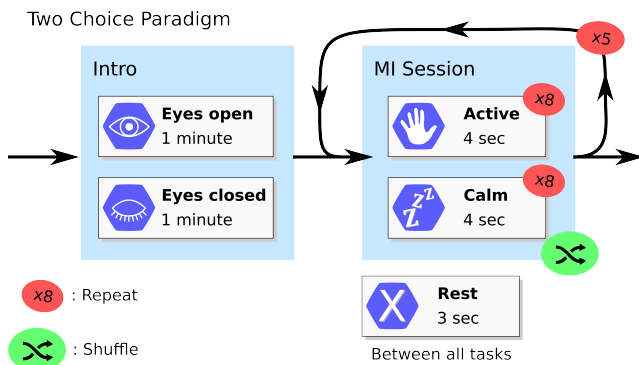
A Cybathlon [1] 2020 versenyre terveztem egy BCI rendszert, melynek első lépéseként Nolan és munkatársai által publikált FASTER [2] algoritmust használtam fel artefaktok elutasítására. Az algoritmus Python implementációjának alapja Vliettől [3] származik. Artefaktok lehetnek pislogások, szemmozgások és arckifejezések által generált jelek, melyek eltávolítása után a jellemzőkinyerése következett frekvenciatartományban. A jelfeldolgozás során a komplex Gyors Fourier Transzformáció abszolút értékét [4] (FFTabs) számítottam ki 1 másodperces elektroencefalográfias (EEG) ablakokon. Egy FFTabs adatból több, 2 Hz széles, nem átfedő frekvenciatartományi átlagot számítottam ki, range40 módszerként hivatkozva. Az osztályozás során több Support Vector Machine-t (SVM) [5] tanítottam, melyek közül mindegyik csak egy frekvenciatartománybeli adatot használt. A végső osztályozási döntést az összes SVM egység maximális szavazatának alkalmazásával határoztam meg. Erre az összetett osztályozó rendszerre Voting SVM-ként hivatkozok. Legjobb tudomásom szerint a Voting SVM-et a range40 jellemző kinyerési módszerrel kombinálva, amely az FFTabs-on alapul, még nem vizsgálták és hasonlították össze statisztikailag elképzelt motoros mozgató

(MI) adatbázison, vagy használták számítógépes játék vezérlésére BCI alkalmazás részeként.

A statisztikai összehasonlító elemzések elvégzéséhez felhasználtam az EEG Motor Movement/Imagery Dataset-et, amely megtalálható a PhysioNet-en (Physionet) [6]. Ez az adatbázis az MI feladatokon alapuló adatok egyik legnagyobb tárházát képviseli, melyet a BCI2000 rendszer [7] felhasználásával rögzítettek. A Physionet adatbázis 109 alany EEG felvételeit tartalmazza, melyeket egy 64-csatornás 10-20 EEG rendszerrel rögzítettek.

A fentiekkel párhuzamban terveztem egy úgynevezett Két Választási Paradigmát (Two Choice Paradigm), hogy egyszerűsítsem a Physionet feladat végrehajtását, mivel a két tetraplegiás alanynak (pilóta), akiknek C5 vagy magasabb gerincvelői sérülése van, nehézséget jelentett a négy végtag képzeletbeli mozgatása a teszt kísérletek során.

Minden kísérlet előtt a pilóták utasítást kaptak arra, hogy kerüljék a pislogást, nyelést, fogak összeszorítását vagy bármilyen olyan mozgást vagy arckifejezést, amely nem kapcsolódik a feladathoz a feladatperiódusok alatt. Az MI feladatokat addig kellett folyamatosan ismételve végrehajtani, amíg a kísérleti fókusz keresztül a képernyőn látható volt. A pihenőperiódusok alatt a paradigmavezérlő program a következő feladatot írásban jeleltette meg a képernyőn. Ezen időszakok alatt a pilóták pisloghattak, nyelhettek és bármilyen szükséges mozgást végezhettek a következő feladatra való felkészülés érdekében. Az MI feladatok végrehajtására 4 másodperc, míg a feladatok közötti pihenésre összesen 3 másodpercnyi idő volt szánva.



2.1. ábra. **Two Choice Paradigm** – A feladat egy perces nyitott szemmel való üléssel kezdődik, melyet egy egyperces csukott szemű ülés feladat követ annak érdekében, hogy a pilóta teljes figyelmét a további feladatokra felkészítse, melynek során 8 aktív elképzelt motoros mozgatóást és 8 nyugodt metnális állapotot kellett fenntartani. A feladatok sorrendje véletlenszerű volt. Egy MI szakasz 5-ször lett ismételve.

A Two Choice Paradigm, amelyet a 2.1 ábra szemléltet, egy egyperces periódussal kezdődött, melynek során a pilótáknak nyitott szemmel a képernyőn megjelenő keresztre kellett fókuszálniuk. Ezt követte egy másik egyperces periódus, amit csukott szemmel kellett végig ülni. A pilótáknak mindkét esetben annyira nyugodtan kellett ülniük, amennyire csak lehetséges, mind fizikailag, mind mentálisan. Ezen bevezető szakasz célja az volt, hogy megragadja a pilóták teljes figyelmét az MI szakaszok előkészítése érdekében.

A bevezető részt követően a kísérlet 5 MI szakasszal folytatódott. Minden MI feladat 8-szor volt ismételve egy szakasz alatt

véletlenszerű sorrendben. Minden befejezett szakasz után a pilótáknak lehetőségük volt önmaguk által meghatározott szünetet tartani anélkül, hogy elhagyták volna a kísérleti berendezést.

Az aktív MI feladatokhoz a pilóták választhattak és kombinálhattak bármilyen kéz- és lábmozgást. Azonban ezeket a mozgásokat a kísérlet kezdete előtt el kellett döntenie és rögzíteni. A B pilóta a bal kéz elképzelt mozgását választotta az aktív feladathoz, míg a C pilóta mindkét láb elképzelt mozgását. A nyugodt feladat azt követelte meg a résztvevőktől, hogy nyitott szemmel üljenek és tartózkodjanak minden mozgástól vagy gondolattól vagy más zajt kiváltó lehetséges tevékenységtől.

A range40 jellemző kinyerési módszeremet az általam fejlesztett Voting SVM osztályozómmal kombinálva összehasonlítottam az EEGNet [8] algoritmussal, hogy eredményeimhez viszonyítási pontot tudjak adni a BCI közösség számára. Megbízható osztályozási pontossági eredmények eléréséhez 5-szörös keresztvalidálást végeztem minden résztvevőnél, minden adatbázison, melynek eredményeit átlagoltam. A Wilcoxon statisztikai teszt kimutatta, hogy módszerem szignifikánsan felülmúlta az EEGNet-et a Physionet adatbázison. A tesztek megismétlése a Two Choice Paradigm adatbázison kevésbé szignifikáns eredményt mutatott. (3.1 ábra)

Ezen összehasonlítások elvégzése után kifejlesztettem egy valós idejű BCI rendszert, amely egy egyedi vezérlési protokollt tartalmaz, melyet Váltó Kapcsolónak (Toggle Switch) neveztem el. Ez az algoritmus lehetővé tette a pilóták számára, hogy csak két mentális parancs segítségével irányítsák a BrainDriver számítógépes játékot négy helyett. A mechanizmust Perdikis és munkatár-

sai [9] inspirálták, akik olyan algoritmust fejlesztettek, amely két-féle MI jelet osztályozott egy küszöbérték technika segítségével. Amikor egy harmadik aktív játékvezérlési parancsra volt szükségük, pilótájuk két különböző aktív MI feladatot indított el egy adott időablakban. Ezzel szemben módszerem egymás után ciklikusan halad végig az aktív vezérlési parancsokon, mindaddig amíg a pilóták aktív MI feladatot végeznek. Az így kapott protokoll egyszerűen bővíthető további parancsokkal.

Az általam fejlesztett BCI rendszer felhasználásával valós idejű BCI kísérleteket végeztem a pilóták közreműködésével, melynek során a Cybathlon 2020 verseny BCI diszciplínájához fejlesztett BrainDriver játékot kellett irányítani. A játékmenet során a pilóták azonnali visszajelzést kaptak a számítógéptől mentális parancsaik helyességéről.

A különböző osztályozók, az adatbázisok és a transzfer tanulás hatásának vizsgálatához összehasonlításokat végeztem, amelyek további adatbázisokat igényeltek, nevezetesen a BCI Competition IV 2a [25], a Giga [26] és a TTK adatbázist [Au6]. A 2.1 táblázatban bemutatott EEGNet családból tetszőlegesen kiválasztottam a Shallow és Deep ConvNet-et [10] az EEGNet elődjeként, magát az EEGNet-et [8], az EEGNet Fusion-t [12] és az MI-EEGNet-et [16]. Legjobb tudomásom szerint ezeknek a kiválasztott neurális hálózatoknak a transzfer tanulási hatását még nem vizsgálták a szakirodalomban.

Az egyénenkénti osztályozásnál 5-szörös keresztvalidálást végeztem résztvevőnként, melynek során az adatbázist az epoch szintjén osztottam fel annak érdekében, hogy azonos epochból származó ablakok kizárólag a tanítási vagy tesztelési halmazba

2.1. táblázat. EEGNet család és felhasznált MI EEG adatbázis

Nerális Hálózat	MI EEG adatbázis
Shallow ConvNet [10]	BCI Competition IV dataset 2a, BCI Competition IV dataset 2b
Deep ConvNet [10]	BCI Competition IV dataset 2a, BCI Competition IV dataset 2b
EEGNet [8]	BCI Competition IV dataset 2a
S-EEGNet [11]	BCI Competition IV dataset 2a
EEGNet Fusion [12]	PhysioNet
TCNet Fusion [13]	BCI Competition IV dataset 2a, High Gamma Dataset
Sinc-EEGNet [14]	BCI Competition IV dataset 2a
TSGL-EEGNet [15]	BCI Competition IV dataset 2a, BCI Competition III dataset IIIa
MI-EEGNet [16]	BCI Competition IV dataset 2a, High Gamma Dataset
Channel-Mixing-ConvNet [17]	BCI Competition IV dataset 2a, High Gamma Dataset
AMSI-EEGNet [18]	BCI Competition IV dataset 2a
ATCNet [19]	BCI Competition IV dataset 2a
FFCL [20]	BCI Competition IV dataset 2a
MTFB-CNN [21]	BCI Competition IV dataset 2a, BCI Competition IV dataset 2b, High Gamma Dataset
TCACNet [22]	BCI Competition IV dataset 2a, High Gamma Dataset
FB-EEGNet [23]	No MI databases are utilized
CRGNet [24]	BCI Competition IV dataset 2a

kerüljenek. A tanítási adatok körülbelül 10%-át használtam validációs halmazként, melyeket szintén az epoch szintjén különítettem el.

A transzfer tanulás esetén a tesztalanyokat 10 fős csoportokba rendeztem, a többi résztvevőt pedig előtanítási alanyokként jelöltem ki és használtam fel a neurális hálózatok kezdeti optimális súlyainak meghatározása érdekében. Az előtanítási adatokból validációs halmazt különítettem el az általam módosított korai leállítási és modellmentési stratégiám használatához. Az előtanítási fázis konvergenciája után, vagy a maximális tanítási periódus elérésevel, vagy korai leállítással, a legjobb hálózati súlyok lettek eltárolva. Minden tesztalany esetében 5-szörös keresztvalidálást végeztem, ahogy azt az egyénekenkénti osztályozás esetén ismertettem. Mindegyik keresztvalidálási lépés előtt betöltöttem a mentett modellsúlyát és a tesztalany számára kiválasztott tanítási halmazt használtam finomhangolási adatként. A finomhangolás során ismételten validációs halmazokat használtam a korai leállítási és modell súlymentési stratégiák alkalmazásával.

3. Új tudományos eredmények


3.1. Tézis Pontok

I. Tézis csoport – Valós időben működő Agy-Számítógép Kapcsolat rendszer fejlesztése és tesztelése

Kapcsolódó publikáció: [J1]

I. Tézis *Kifejlesztettem egy új jellemzőkinyerési és osztályozási folyamatrendszert, mely gyors Fourier-transzformáció és Support Vector Machine algoritmusok felhasználásával valós időben feldolgozza és osztályozza az elképzelt motoros mozgásokhoz tartozó Elektroencefalogramokat Agy-Számítógép Kapcsolat vezérlésének céljából.*

Ia. Tézis *Összehasonlítottam az általam fejlesztett range40 jellemző kinyerési módszerrel kombinált Voting SVM osztályozó rendszert a korszerű EEGNet algoritmussal a Physionet-es adatbázis felhasználásával, melynek során a Wilcoxon statisztikai teszt alkalmazásával a saját rendszerem szignifikánsan jobb eredményt mutatott.*

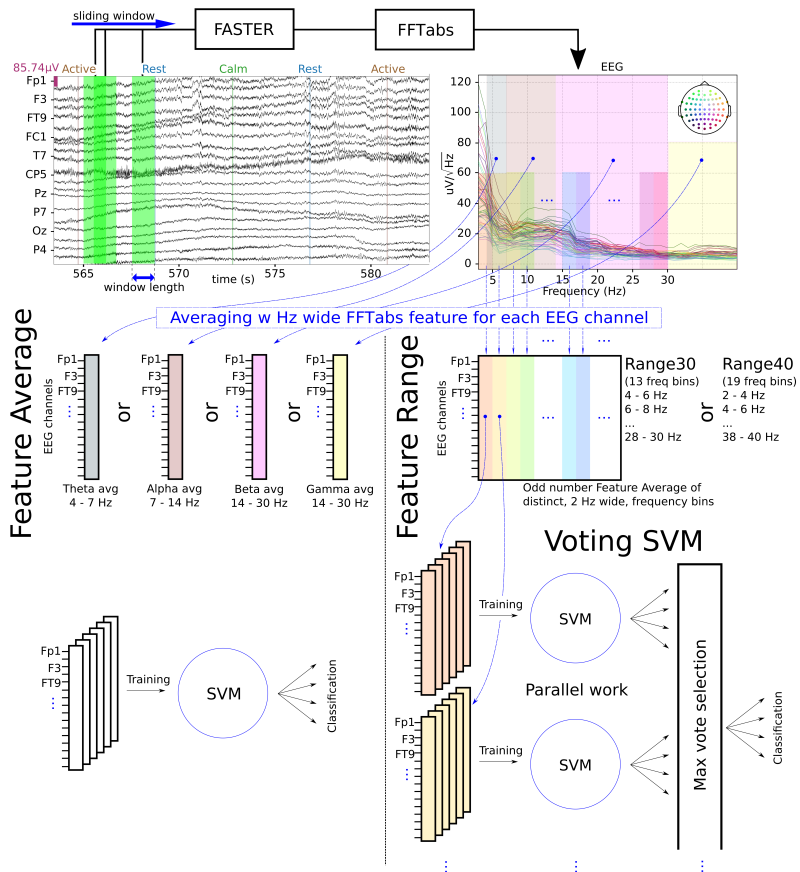


3.1. ábra. A range40 + Voting SVM és az EEGNet 5-szörösen keresztvalidált osztályozás pontossági eredményeinek összehasonlítása. A p -érték annotációja a következő: nem szignifikáns (ns): $5 \times 10^{-2} < p$; ****: $p \leq 10^{-4}$. Az adatsor átlaga a '+' szimbólummal van jelölve. A vízszintes vonal a dobozokban az adat mediánját jelöli. A dobozok alsó és felső szélei a quartiliseknek felelnek meg, míg a bajuszok az adatok eloszlását szemléltetik, kivéve a az egyedi pontokat, amik kiugró értékek.

A range40 jellemző kinyerési módszer az adott EEG ablak gyors Fourier-transzformációjának abszolút értékét számítja ki, és átlagolja az értékeket 2 Hz széles frekvenciatartományokban (2-4 Hz, 4-6 Hz, ..., 38-40 Hz) minden EEG csatornán. A $19 \times$ csatornaszám generált jellemzőt 19 RBF kerneles SVM tanítására használtam. Minden SVM különböző agyi jelek jellemzőit tanulta meg a 2 Hz széles frekvenciatartományokra való tekintettel. Az SVMek saját döntést hoztak, melyből a végső döntést az SVM egységek maximális szavazataként lett meghatározva. Ezt az együttes SVM osztályozót Voting SVM-nek neveztem el. A teljes jelfeldolgási folyamatot a 3.2. ábra szemlélteti.

Ib. Tézis *Kifejlesztettem egy egyedi vezérlési protokollt, amely az Agy-Számítógép Kapcsolati rendszer 2 osztályú kimenetét 4 osztállyá alakítja, hogy irányítani lehessen egy 4 bemenet váró számítógépes játékot. A rendszer aktív elképzelt mozgás esetén a vezérlő parancsokat egymás után cirkuláltatja mindaddig, amíg a felhasználó a nyugalmi állapot aktivizálásával ki nem választ egyet. Ez a módszer könnyen kiterjeszthető négynél több vezérlési parancs kiadására is.*

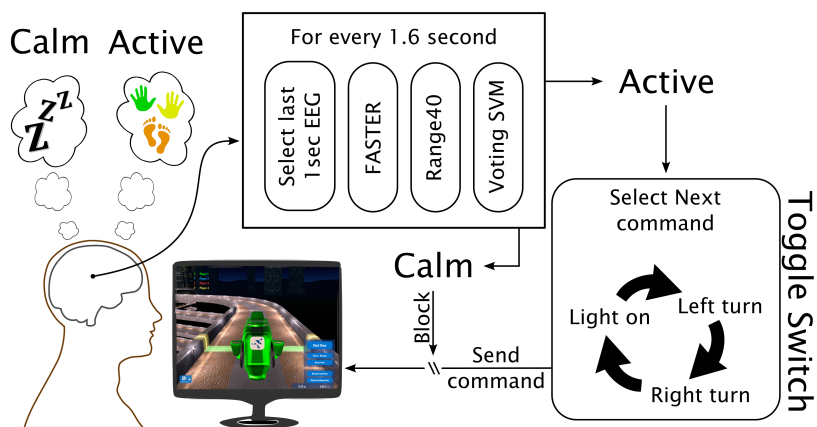
A BrainDriver program négy bemeneti parancsot igényelt a felhasználótól (három aktív parancs plusz a parancsok hiánya), de a Two Choice Paradigm csak kettő kiadására lett tervezve. Ennek áthidalására egy egyedi mechanizmust, a Toggle Switch-et vezettem be, amelyet a Brain Tweaker csapat ihletett [9]. Amikor a felhasználó az aktív MI feladatot végezte, a program a játékvezérlő parancsokat előre meghatározott időközönként sorban ismételte. Amikor a kívánt vezérlőparancs lett kiadva, a felhasználónak nyu-



3.2. ábra. BCI jelfeldolgási folyamat

godt mentális feladatot kellett kezdeményeznie annak érdekében, hogy a parancsot fenntartsa elkerülve ezzel további rossz vezérlési parancsok küldését a játékba. Ezt a mechanizmust a 3.3. ábra szemlélteti.


Real-time working BCI System



3.3. ábra. Valós időben működő BCI rendszer részei és a Váltó Kapcsoló (Toggle Switch) irányítási mechanizmus.

Ic. Tézis *Az elkészült Agy-Számítógép kapcsolati rendszer felhasználásával 59 videójáték vezérlési kísérletet végeztem két C5 vagy magasabb nyaki csigolya sérüléssel diagnosztizált kísérleti alany bevonásával. A játék irányítási eredményei összehasonlíthatóak a 2020-ban megrendezett Cybathlon versenyen résztvevő csapatok publikált eredményeivel.*

A pilóták változó eredménnyel fejezték be a játékot 200 és 280 másodperc között, ahogy ezt a 3.4. ábra is szemlélteti. B pilóta tanulási görbéje szignifikánsnak bizonyult, ugyanakkor a pandémia miatti korlátozások következtében összesen 9 kísérleti alkalmat tudtam szervezni, amely során a két pilóta együttesen 59 játék irányítási kísérletet tudott végrehajtani.



3.4. ábra. Pilóták játékeredményei. A verseny 240 másodperces limitideje piros vonallal van jelölve. A szürke vonalak a pilóták tanulási görbéjét szemléltetik.

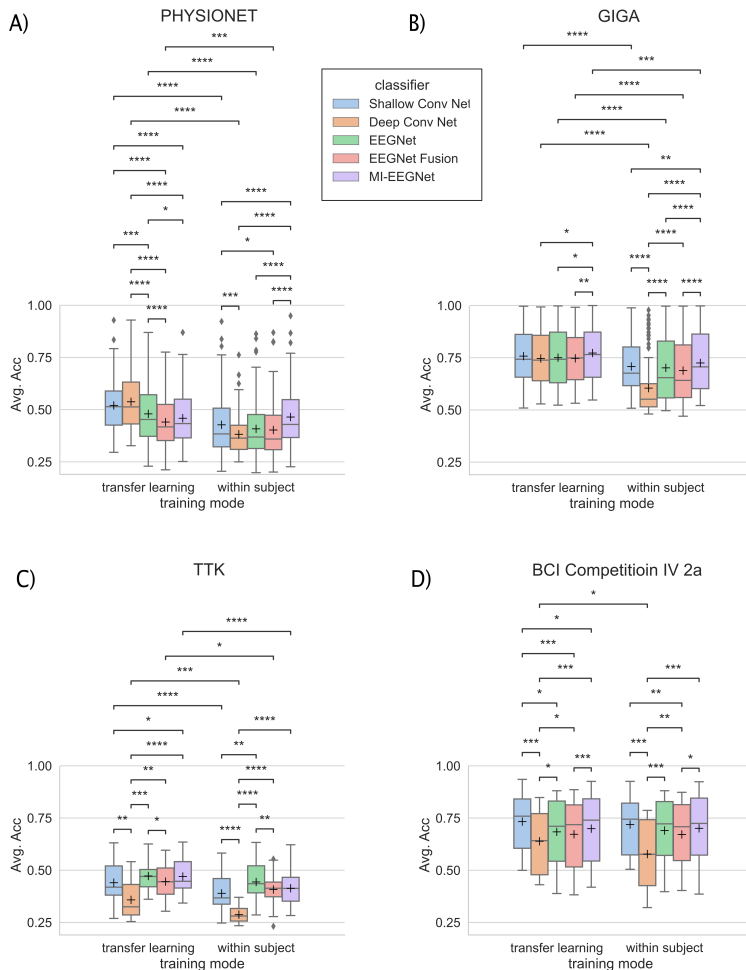
II. Tézis csoport – Az EEGNet család neurális hálózatainak kritikai összehasonlítása

Kapcsolódó publikáció: [J2]

II. Tézis *Kiválasztottam a Shallow ConvNet, Deep ConvNet, EEGNet, EEGNet Fusion és MI-EEGNet neurális hálózatokat és összehasonlítottam az osztályozó és transzfer tanulás képességeiket artefakt-szűrt EEG adatokon, melyek 4 különböző alanyszámú adatbázisokból származnak.*

IIa. Tézis *Megmutattam, hogy artefakt eltávolítást követve a transzfer tanulás alkalmazásával a kiválasztott neurális hálózaton szignifikánsan jobb osztályozási eredmény érhető el, mintha csak alanyonkénti osztályozást végeznénk.*

A négy adatbázison mind az öt neurális hálózat kétfajta tanítási metódusának (alanyonkénti és transzfer tanulás) ötszörös keresztvalidációjának kombinációjából gyűjtött osztályozási pontossági adatok begyűjtését követően az adatokon végzett normalitásvizsgálat nem normális adateloszlást mutatott. Ennek megfelelően a Wilcoxon statisztikai tesztet alkalmaztam Bonferroni korrekcióval a szignifikanciavizsgálathoz. Az eredményeket a 3.5. ábrán szemléltetem. A transzfer tanulás jelentősen javította a teljesítményt az összes adatbázison, kivéve a BCI Competition IV 2a-t.



3.5. ábra. EEGNet család összehasonlítása 4 adatbázison független napok konfigurációjának alkalmazása mellett.

A p -érték annotációja a következő: *: $10^{-2} < p \leq 5 \times 10^{-2}$; **: $10^{-3} < p \leq 10^{-2}$; ***: $10^{-4} < p \leq 10^{-3}$; ****: $p \leq 10^{-4}$. Az adatsor átlaga a '+' szimbólummal van jelölve. A vízszintes vonal a dobozokban az adat mediánját jelöli. A dobozok alsó és felső szélei a quartiliseknek felelnek meg, míg a bajuszok az adatok eloszlását szemléltetik, kivéve a az egyedi pontokat, amik kiugró értékek.

IIIb. Tézis *Az összehasonlítás során szintén demonstráltam, hogy 10-nél kevesebb alanyt tartalmazó adatbázison nem lehet szignifikáns összehasonlítást végezni.*

Az adatbázisokat a közöttük megfigyelt szignifikáns különbségek szintjei alapján rangsoroltam. A 3.1. táblázatban szemléltetem a szignifikáns tartományok összegét (amely megfelel az ábrákon lévő csillagok számának) és a szignifikáns különbségek számát, valamint az egyes adatbázisokban lévő alanyok számát. A szignifikáns tartományok összege erősen korrelál az egyes adatbázisokban lévő alanyok számával ($r(3) = 0,7709$), bár ez a korreláció nem volt statisztikailag szignifikáns (p -érték = $0,127014 > 0,05$).

3.1. táblázat. Statisztikai vizsgálat

Adatbázis	Szignifikancia szint		
	Szum	Darab	Alanyszám
Physionet	63	18	105
Giga	49	15	108
TTK	45	16	25
BCI Comp IV 2a	31	15	18
BCI Comp IV 2a- alanyonként összefűzve	0	0	9

III. Tézis *A neurális hálózatok összehasonlításához két metrikát használtam, a „Véletlen szinttől történő javulás” és a „Transzfer tanulás általi javulás”. Ezek a metrikák azt mutatták, hogy a Shallow ConvNet és a Deep ConvNet hálózatok jobban teljesítettek, mint az EEGNet család újabban publikált tagjai. Az eredmények rámutatnak arra, hogy a neurális hálózatok teljesítményének rangsorolásakor több tényezőt is figyelembe kell venni az általánosan használt osztályozási pontosság összehasonlításán kívül.*

3.2. táblázat. Neurális hálózatok teljesítményének rangsorolása független kísérleti napok elrendezésben.

	Neurális hálózat	Átl. Pont. Javulás	Sorrend a véletlentől
Alanyon- ként	Shallow ConvNet	0.2071	2
	Deep ConvNet	0.1249	5
	EEGNet	0.1997	3
	EEGNet Fusion	0.1871	4
	MI-EEGNet	0.2306	1
Transzfer tanulás	Shallow ConvNet	0.2721	1
	Deep ConvNet	0.2598	2
	EEGNet	0.2521	4
	EEGNet Fusion	0.2312	5
	MI-EEGNet	0.2537	3

3.3. táblázat. Osztályozási pontosság javulás transzfer tanulás segítségével független napok konfigurációban használt adatbázisokon.

Sorrend	Neurális Hálózatok	Physionet	Giga	TTK	BCI Comp IV 2a	Átl. Pont. Javulás
1	Deep ConvNet	0.1557	0.1418	0.0708	0.0614	0.1075
2	Shallow ConvNet	0.0928	0.0497	0.0509	0.0141	0.0519
3	EEGNet	0.0716	0.0487	0.0288	-0.0065	0.0357
4	EEGNet Fusion	0.0381	0.0586	0.0379	0.0007	0.0338
5	MI-EEGNet	-0.0058	0.0475	0.0564	-0.0015	0.0241

3.2. Lehetséges alkalmazások és előnyök

A BCI rendszert egy konkrét alkalmazásra, a Cybathlon 2020 verseny BCI szakágára terveztem, ahol a quadroplégiás pilóták egy autóverseny jellegű számítógépes játékban versenyeznek, melynek során az avatarjukat jól időzített képzelt mentális parancsokkal irányítják, melyeket az EEG erősítő rögzít.

Ezenkívül ez a munka az Innovációs és Technológiai Minisztérium Kooperatív Doktori Program (KDP) doktori hallgatói ösztöndíj programjának a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott szakmai támogatásával készült. A KDP ösztöndíj célja a tudományos kutatás ipari célokra történő megvalósítása. A kutatásom során szerzett tudást az elektromiográfiai jelprocesszálo területre is átvittem, ahol kis, hordozható, megfizethető EMG karpántot használtam fel. A teljes tanulmány megtekinthető az alábbi cikkekben: [Au4] és [Au5].

Az EEGNet család tagjainak összehasonlításával bemutattam annak fontosságát, hogy az EEG jelfeldolgozás új osztályozási módszereinek bemutatásakor létfontosságú olyan adatbázisok használata, amelyek nagyszámú alannyal rendelkeznek, mint például a Physionet vagy a Giga. Ezenkívül kiemeltem, hogy a neurális hálózatok teljesítményének rangsorolásakor több tényezőt is érdemes figyelembe venni: Ha csak a hálózatok közötti pontosságkülönbségekre támaszkodunk és zajszűretlen adatkészleteket használunk kis számú alannyal, akkor ez nem megalapozott eredményekhez vezethet.

Ideális esetben ezek az eredmények egy új összehasonlító eljárásokhoz vezethetnek a jövőben, amikor új neurális hálózatot mutatnak be az EEG jelek feldolgozására és osztályozására.

Tézisekkel kapcsolatos publikációk

- [J1] **Cs. Köllöd**, A. Adolf, G. Márton, M. Wahdow, W. Fadel és I. Ulbert, „Closed loop BCI system for Cybathlon 2020“, *Brain-Computer Interfaces*, 10. évf., 2. sz., 114–128. old., 2023. DOI: 10.1080/2326263X.2023.2254463.
- [J2] **Cs. Köllöd**, A. Adolf, K. Iván, G. Márton és I. Ulbert, „Deep Comparisons of Neural Networks from the EEGNet Family“, *Electronics*, 12. évf., 12. sz., 2743. old., 2023. DOI: 10.3390/electronics12122743.

Szerző egyéb publikációi

- [Au1] M. Wahdow, M. Alnaanah, W. Fadel, A. Adolf, **Cs. Kollod** és I. Ulbert, „Multi frequency band fusion method for EEG signal classification“, *Signal, Image and Video Processing*, 2022. DOI: 10.1007/s11760-022-02399-6.
- [Au2] W. Fadel, **Cs. Kollod**, M. Wahdow, Y. Ibrahim és I. Ulbert, „Multi-Class Classification of Motor Imagery EEG Signals Using Image-Based Deep Recurrent Convolutional Neural Network“, *2020 8th International Winter Conference on Brain-Computer Interface (BCI)*, 2020, 1–4. old. DOI: 10.1109/BCI48061.2020.9061622.
- [Au3] W. Fadel, M. Wahdow, **Cs. Kollod**, G. Marton és I. Ulbert, „Chessboard EEG Images Classification for BCI Systems Using Deep Neural Network“, *Bio-inspired Information and Communication Technologies*, Y. Chen, T. Nakano, L. Lin, M. U. Mahfuz és W. Guo, szerk., *Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering* sor., 329. köt., Cham: Springer International Publishing, 2020, 97–104. old. DOI: 10.1007/978-3-030-57115-3_8.

- [Au4] N. J. Eftimiu, **Cs. Köllöd**, I. Ulbert és G. Márton, „A Surface Electromyography Dataset for Hand Gesture Recognition“, *2022 IEEE 20th Jubilee International Symposium on Intelligent Systems and Informatics (SISY)*, 2022, 115–120. old. DOI: 10.1109/SISY56759.2022.10036305.
- [Au5] **Cs. Köllöd**, N. J. Eftimiu, G. Márton és I. Ulbert, „Classification of Semi-Automated Labeled MindRove Armband Recorded EMG Data“, *2022 IEEE 22nd International Symposium on Computational Intelligence and Informatics and 8th IEEE International Conference on Recent Achievements in Mechatronics, Automation, Computer Science and Robotics (CINTI-MACRo)*, 2022, 381–386. old. DOI: 10.1109/CINTI-MACRo57952.2022.10029540.
- [Au6] **Cs. Köllöd**, A. Adolf, G. Márton, M. Wahdow, W. Fadel és I. Ulbert, *TTK dataset - 4 class Motor-Imagery EEG*, 2022, <https://hdl.handle.net/21.15109/CONCORDA/UOQQVK>.

Irodalomjegyzék

- [1] R. Riener és L. J. Seward, „Cybathlon 2016“, *2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 2014, 2792–2794. old. DOI: 10.1109/SMC.2014.6974351.
- [2] H. Nolan, R. Whelan és R. B. Reilly, „FASTER: Fully Automated Statistical Thresholding for EEG artifact Rejection“, *Journal of Neuroscience Methods*, 192. évf., 1. sz., 152–162. old., 2010. DOI: 10.1016/j.jneumeth.2010.07.015.
- [3] M. v. Vliet, *wmvanvliet/mne-faster: First official release*, 2021. DOI: 10.5281/zenodo.5112399.
- [4] J. W. Cooley és J. W. Tukey, „An Algorithm for the Machine Calculation of Complex Fourier Series“, *Mathematics of Computation*, 19. évf., 90. sz., 297–301. old., 1965. DOI: 10.2307/2003354.
- [5] B. E. Boser, I. M. Guyon és V. N. Vapnik, „A training algorithm for optimal margin classifiers“, *Proceedings of the fifth annual workshop on Computational learning theory*, COLT '92 sor., New York, NY, USA: Association for

- Computing Machinery, 1992, 144–152. old. DOI: 10.1145/130385.130401.
- [6] Goldberger Ary L., Amaral Luis A. N., Glass Leon és tsai., „PhysioBank, PhysioToolkit, and PhysioNet“, *Circulation*, 101. évf., 23. sz., 215–220. old., 2000. DOI: 10.1161/01.CIR.101.23.e215.
- [7] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer és J. R. Wolpaw, „BCI2000: a general-purpose brain-computer interface (BCI) system“, eng, *IEEE transactions on bio-medical engineering*, 51. évf., 6. sz., 1034–1043. old., 2004. DOI: 10.1109/TBME.2004.827072.
- [8] V. J. Lawhern, A. J. Solon, N. R. Waytowich, S. M. Gordon, C. P. Hung és B. J. Lance, „EEGNet: a compact convolutional neural network for EEG-based brain–computer interfaces“, *Journal of Neural Engineering*, 15. évf., 5. sz., 17. old., 2018. DOI: 10.1088/1741-2552/aace8c.
- [9] S. Perdikis, L. Tonin, S. Saeedi, C. Schneider és J. d. R. Millán, „The Cybathlon BCI race: Successful longitudinal mutual learning with two tetraplegic users“, *PLOS Biology*, 16. évf., 5. sz., 28. old., 2018. DOI: 10.1371/journal.pbio.2003787.
- [10] R. T. Schirrmeister, J. T. Springenberg, L. D. J. Fiederer és tsai., „Deep learning with convolutional neural networks for EEG decoding and visualization“, *Human Brain Mapping*, 38. évf., 11. sz., 5391–5420. old., 2017. DOI: 10.1002/hbm.23730.

- [11] W. Huang, Y. Xue, L. Hu és H. Liuli, „S-EEGNet: Electroencephalogram Signal Classification Based on a Separable Convolution Neural Network With Bilinear Interpolation“, *IEEE Access*, 8. évf., 131636–131646. old., 2020. DOI: 10.1109/ACCESS.2020.3009665.
- [12] K. Roots, Y. Muhammad és N. Muhammad, „Fusion Convolutional Neural Network for Cross-Subject EEG Motor Imagery Classification“, *Computers*, 9. évf., 72. sz., 2020. DOI: 10.3390/computers9030072.
- [13] Y. K. Musallam, N. I. AlFassam, G. Muhammad és tsai., „Electroencephalography-based motor imagery classification using temporal convolutional network fusion“, *Biomedical Signal Processing and Control*, 69. évf., 102826. sz., 2021. DOI: 10.1016/j.bspc.2021.102826.
- [14] A. Bria, C. Marrocco és F. Tortorella, „Sinc-based convolutional neural networks for EEG-BCI-based motor imagery classification“, *arXiv:2101.10846 [eess]*, 2021.
- [15] X. Deng, B. Zhang, N. Yu, K. Liu és K. Sun, „Advanced TSGL-EEGNet for Motor Imagery EEG-Based Brain-Computer Interfaces“, *IEEE Access*, 9. évf., 25118–25130. old., 2021. DOI: 10.1109/ACCESS.2021.3056088.
- [16] M. Riyad, M. Khalil és A. Adib, „MI-EEGNET: A novel convolutional neural network for motor imagery classification“, *Journal of Neuroscience Methods*, 353. évf., 109037. sz., 2021. DOI: 10.1016/j.jneumeth.2021.109037.

- [17] W. Ma, Y. Gong, G. Zhou, Y. Liu, L. Zhang és B. He, „A channel-mixing convolutional neural network for motor imagery EEG decoding and feature visualization“, *Biomedical Signal Processing and Control*, 70. évf., 103021. sz., 2021. DOI: 10.1016/j.bspc.2021.103021.
- [18] M. Riyad, M. Khalil és A. Adib, „A novel multi-scale convolutional neural network for motor imagery classification“, *Biomedical Signal Processing and Control*, 68. évf., 102747. sz., 2021. DOI: 10.1016/j.bspc.2021.102747.
- [19] H. Altaheri, G. Muhammad és M. Alsulaiman, „Physics-inform attention temporal convolutional network for EEG-based motor imagery classification“, *IEEE Transactions on Industrial Informatics*, 19. évf., 2. sz., 2049–2058. old., 2022. DOI: 10.1109/TII.2022.3197419.
- [20] H. Li, M. Ding, R. Zhang és C. Xiu, „Motor imagery EEG classification algorithm based on CNN-LSTM feature fusion network“, *Biomedical Signal Processing and Control*, 72. évf., 103342. sz., 2022. DOI: 10.1016/j.bspc.2021.103342.
- [21] H. Li, H. Chen, Z. Jia, R. Zhang és F. Yin, „A parallel multi-scale time-frequency block convolutional neural network based on channel attention module for motor imagery classification“, *Biomedical Signal Processing and Control*, 79. évf., 104066. sz., 2022. DOI: 10.1016/j.bspc.2022.104066.
- [22] X. Liu, R. Shi, Q. Hui és tsai., „TCACNet: Temporal and channel attention convolutional network for motor ima-

- gery classification of EEG-based BCI“, *Information Processing & Management*, 59. évf., 103001. sz., 2022. DOI: 10.1016/j.ipm.2022.103001.
- [23] H. Yao, K. Liu, X. Deng, X. Tang és H. Yu, „FB-EEGNet: A fusion neural network across multi-stimulus for SS-VEP target detection“, *Journal of Neuroscience Methods*, 379. évf., 109674. sz., 2022. DOI: 10.1016/j.jneumeth.2022.109674.
- [24] C. Gao, W. Liu és X. Yang, „Convolutional neural network and riemannian geometry hybrid approach for motor imagery classification“, *Neurocomputing*, 507. évf., 180–190. old., 2022. DOI: 10.1016/j.neucom.2022.08.024.
- [25] M. Tangermann, K.-R. Müller, A. Aertsen és tsai., „Review of the BCI Competition IV“, *Frontiers in Neuroscience*, 6. évf., 55. sz., 31. old., 2012. DOI: 10.3389/fnins.2012.00055.
- [26] M.-H. Lee, O.-Y. Kwon, Y.-J. Kim és tsai., „EEG dataset and OpenBMI toolbox for three BCI paradigms: an investigation into BCI illiteracy“, *GigaScience*, 8. évf., 5. sz., 16. old., 2019. DOI: 10.1093/gigascience/giz002.