

A jeltől a vezérlésig:
valós-idejű műtermék eltávolítás és az
előfeldolgozási stratégiák hatása az EEG
alapú agy-számítógép interfész
rendszerekben



Adolf András

A PhD Disszertáció tézisei

Témavezető: Dr. Ulbert István, DSc

Pázmány Péter Katolikus Egyetem

Roska Tamás Műszaki és Természettudományi

Doktori Iskola

Budapest, 2025

1. Bevezetés

Az agy-számítógép interfész (BCI) rendszerek egyre inkább áttörést jelentenek a támogató technológiák területén, új lehetőséget kínálva a súlyos mozgáskorlátozottsággal élő személyek számára a kommunikációra és az interakcióra [1]. A több évtizedes kutatások ellenére a BCI rendszerek teljesítménye és megbízhatósága még mindig nem kielégítő, elsősorban az EEG-jelek összetettsége és változékonysága miatt. Ezek a jelek nemcsak hogy eleve alacsony jel-zaj aránnyal rendelkeznek, hanem rendkívül érzékenyek a nem agyi eredetű műtermékekre is, például a szemmozgásokra, izomtevékenységre vagy környezeti zajokra. A műtermékek eltávolítása és az előfeldolgozási lépések kulcsszerepet játszanak abban, hogy a hasznos idegi mintázatok kinyerhetők és pontosan értelmezhetők legyenek [2].

Bár léteznek online artifakt-eltávolító módszerek, mint például a FORCe (Fully Online and Automated Artifact Removal for Brain-Computer Interfacing) [3] és az ORICA (Online Recursive Independent Component Analysis) [4], az ilyen módszerek nyílt forráskódú, könnyen módosítható implementációi nem minden esetben érhetőek el. Ez a disszertáció a FASTER (Fully Automated Statistical Thresholding for EEG artifact Rejection) [5] algoritmus egy online adaptációját mutatja be, amelynek célja az átláthatóság, az egyszerűség és az integrálhatóság előtérbe helyezése, egy praktikus alternatívát kínálva valós idejű BCI alkalmazásokhoz. Az implementált rendszer nemcsak valós környezetben lett tesztelve, hanem azt a Cybathlon nemzetközi verseny szervezőbizottsága is felülvizsgálta és elfogadta, ami kiemeli a rendszer megfelelőségét a műszaki előírásoknak. Az algoritmus használata biztosíték afelől, hogy a versenyző pilóták nem használnak műtermékeket az agy-számítógép interfész irányítására, ezáltal a módszer támogatja a tiszta idegi aktivitáson alapuló vezérlést.

Az eszközök fejlesztésén túl egyre nagyobb az igény, hogy megértjük az interakciókat az előfeldolgozási lépések, jel reprezentációk és gépi

tanulási stratégiák között. A jelenlegi gyakorlat ezeket a komponenseket gyakran egymástól elkülönítve kezeli, mégis ezek összesített hatása formálja a klasszifikációs eredményeket. Míg például a műtermék eltávolítás általánosságban növeli a jelek minőségét, annak hatása nem általánosítható minden alanyra: míg egyes esetekben növekszik az osztályozási pontosság, más alanyok pontossága éppen hogy csökken. Hasonlóképp a transzfer tanulás is ígéretes megközelítés, de a hatása jelentősen eltérhet a bemeneti adatok természetétől függően.

Az, hogy az EEG-adatokat hogyan strukturáljuk a gépi tanulás számára - legyen szó nyers idősorokról, frekvenciaszűrt szegmensekről vagy térbeli leképezésekről, jelentősen befolyásolja a neurális hálózatok azon képességét, hogy értelmezhető mintázatot tanuljanak meg. A dolgozat új neurális architektúrák és egy sűrű, háromdimenziós reprezentáció kidolgozásán keresztül vizsgálja a térbeli információk beépítésének értékét, valamint a frekvenciasávok szerepét az osztályozási feladatokban, különösen kivágott szegmenseken alapuló tanítási körülmények között.

Összefoglalva, a disszertációt két fő célkitűzés motiválja:

1. Egy gyakorlati, valós idejű műtermék-eltávolító eszköz fejlesztése BCI rendszerekhez, különösen versenykörnyezetben való alkalmazásra.
2. Részletes vizsgálat készítése arról, hogy az EEG előfeldolgozás, a térbeli/frekvencia alapú reprezentációk és a tanulási stratégiák hogyan hatnak egymásra, és miként befolyásolják a BCI osztályozási pontosságát.

A mérnöki megvalósítás és az elméleti megértés együttes vizsgálatával ez a munka hozzájárul a jövőbeli BCI rendszerek tervezésének, megbízhatóságának és személyre szabhatóságának fejlesztéséhez.

2. Módszerek és eszközök

2.1. Az Online FASTER algoritmus

Megterveztem és megvalósítottam egy kvázi-valós-idejű szűrésre képes műtermékeltávolító eljárást, melyet Online FASTER algoritmusnak neveztem el. Az eljárás alapját a széles körben alkalmazott és validált FASTER algoritmus képezi [5], amelyet online működésre adaptáltam. Az algoritmus működési folyamata egy offline előkészítő szakaszból és további online szűrési lépésekből áll.

Az előfeldolgozási szakasz előre rögzített EEG-adatokon alapul, mivel bizonyos paramétereket nem lehet megbízhatóan kiszámítani online végrehajtás közben. Az offline *betanítási* fázis során az algoritmus statisztikai jellemzők alapján azonosítja és megjelöli a globálisan hibás csatornákat, amelyek jelentősen eltérnek a normál értékektől. Ezeket a csatornákat a későbbi feldolgozásból kizárja. Emellett az algoritmus detektálja a hibás szakaszokat az előre felvett adatbázisban, és eltávolítja azokat, hogy biztosítsa a további lépések megbízhatóságát. A legnagyobb számítási igényű rész, azaz a független komponens analízis (ICA), szintén ebben a fázisban történik. Az így kapott ICA-dekompozíciós mátrixot az algoritmus elmenti, és később az online szakaszban újra felhasználja.

Az előkészítő lépések elvégzése után az algoritmus készen áll az online alkalmazásra. Az első változtatás az eredeti FASTER folyamatmenethez képest a globálisan hibás csatornák kezelése: az online változatban ezek újraszámítása helyett az algoritmus a betanítási szakaszban meghatározott csatornákat használja, így elkerülhető a fölösleges számítási terhelés. A legfontosabb módosítás azonban az ICA komponensek számításánál történik. Az offline FASTER feldolgozási láncban az ICA dekompozíció számításigényes, ezért nem alkalmas valós idejű használatra. Az online változatban ezt a lépést újraterveztem: az előzetesen kiszámított ICA transzformációs mátrixot közvetlenül alkalmaztam a beérkező EEG-adatszegmensekre, lehetővé téve a valós idejű dekompozíciót újra-

számítás nélkül. Az így kapott független komponenseket ezután több műtermékre utaló jellemző alapján értékeli az algoritmus. Ezek közé tartoznak statisztikai mutatók, mint például a komponens EOG-jelekkel való korrelációjának Z-pontszáma, a térbeli kurtózis, a meghatározott frekvenciasávon belüli meredekség, a Hurst-exponens, valamint a medián gradiens. Ha bármelyik paraméter átlépi az előre meghatározott küszöböt - jellemzően a Z-pontszám 3 fölött van -, az adott komponens műterméknek tekinti, és eltávolítja a jelből.


Az műtermékek eltávolítása után az Online FASTER algoritmus feldolgozási folyamata az offline változathoz hasonlóan folytatódik. Az adott szakaszban hibásnak minősített csatornák eltávolításra kerülnek, majd a környező jó csatornák és a betanítás során meghatározott globálisan hibás csatornák alapján interpoláció történik. Végül egy közös átlag referenciatranszformáció (Common Average Reference, CAR) kerül alkalmazásra, a térbeli jelintegritás javítása érdekében. Az eljárás eredményeként egy műtermékektől megtisztított EEG-szegmens jön létre minden beérkező szakaszra, amely alkalmas további valós idejű elemzésre vagy osztályozásra.

A javasolt algoritmus implementációja megtalálható a projekt GitLab-repozitóriumának megjelölt almappjában:

https://dev.itk.ppke.hu/adoan/dissertation-codebase/-/tree/main/bionic_apps/artifact_filtering/

2.2. A Physionet adatbázis

Kutatásomat a Schalk és munkatársai által rögzített EEG Motor Movement/Imagery adathalmazon végeztem, amely elérhető a PhysioNet adatbázison keresztül [6]. A mérések 64 csatornás, 10-10 elrendezésű EEG rendszerrel készültek, 160 Hz mintavételezési frekvenciával, a BCI2000 keretrendszer használatával, hardveres szűrés alkalmazása nélkül [7]. Ez az egyik legnagyobb nyilvánosan elérhető EEG adatbázis motoros képzeleti feladatokhoz, összesen 109 alany méréseit tartalmazza, alanyonként 14 adatfájjal. Munkám során kizártam a 88.,



1. ábra. A FASTER algoritmus offline változatának (balra) és az általam tervezett Online FASTER módszernek (jobbra) az áttekintése. Az online algoritmusban a gyenge minőségű csatornák azonosítása és kizárása egy offline előszűrési szakaszban történik, amely megelőzi az online szűrési folyamatot. Ugyanebben az előkészítő fázisban kerül kiszámításra a független komponens analízishez (ICA) szükséges mátrix is, amelyet a műtermékek korrekciójához használunk. Fontos megjegyezni, hogy az online változat – az offline módszerrel ellentétben – nem dobja el a hibás EEG szakaszokat, hiszen a versenykörülmények során minden időpillanatot ki kell értékelni. Minden további szűrési és osztályozási lépés megelőzik az offline megvalósítással.

92. és 100. alanyt, mivel az adataik mintavételezési frekvenciája és struktúrája nem felelt meg a többihez képest. Továbbá kihagytam a 89. alanyt is, mivel az esetében az elektródaelnevezések hibásnak bizonyultak. Az adatbázis az alábbi hivatkozáson keresztül is elérhető: <https://physionet.org/content/eegmmidb/1.0.0/>.


2.3. Az EEG adatok 3-dimenziós reprezentációja

Tekintettel arra, hogy az elektródák térbeli elrendezése hasznos információkat szolgáltathat az osztályozáshoz, az EEG-jeleket háromdimenziós tenzorként reprezentáltam. Ez a tenzor két térbeli dimenzióból áll, melyek az elektródaelrendezés kétdimenziós vetületének felelnek meg, valamint egy időbeli dimenzióból, amely a jel időbeli lefutását rögzíti – hasonlóan a korábbi tanulmányokban alkalmazott megközelítésekhez [8], [9]. Ehhez az átalakításhoz egy egyedi elektródaelrendezést használtam, amelyet „sűrű 3D transzformációnak” (dense 3D transformation) neveztem el. Ebben a konstrukcióban az Iz elektródát elhagytam, a fennmaradó 63 elektródát pedig egy 9×7 -es mátrixba rendeztem át. Az elrendezés a 2. ábrán látható.

2.4. Conv2D Net


Az elsőként javasolt hálózat az előző pontban leírt nyers EEG-tenzort kétdimenziós konvolúciós rétegekkel dolgozza fel, amelyek szűrői az összes időlépésre kiterjednek. Konkrétan minden kernel mérete (k_x , k_y , T), ahol T az idődimenzió mintáinak száma. Így a konvolúció az elektródák térbeli elrendezésén megy végbe, miközben az időbeli tengely mentén súlyozott összegzés történik, egyetlen szűrőválaszba integrálva minden időpont információját.

A konvolúció előtt a bemenet L2-normáláson esik át, hogy biztosítsuk a csatornák közötti skálainvarianciát. A normalizált adat ezt követően három egymást követő 2D konvolúciós rétegen halad át, amelyeket nemlineáris aktiváció és – ahol indokolt – batch-normálás követ. A kernelek



2. ábra. Az EEG adatok 3D reprezentációja: Az eredetileg (csatornák száma $\times$ idő) formátumú EEG adatok átrendezésre kerültek egy háromdimenziós struktúrába, ahol az első két dimenzió az elektródák térbeli elhelyezkedését, míg a harmadik dimenzió az időt reprezentálja. A térbeli dimenzióhoz egy sűrű elektródaelrendezést alkalmaztam: míg az eredeti elrendezésben helykitöltő, nulla értékű csatornák is szerepelnek, az átalakítás során ezeket elhagytam, így egy sűrűbb, folyamatos térbeli reprezentációt kaptam [J2].

dimenziója $3 \times 3 \times$ idődimenzió a mindhárom konvolúciós rétegben. A kimeneti jellemzőtérképeket az algoritmus lapítja, majd egy kétszintű, teljesen összekapcsolt (dense) alhálózatba táplálja, amely a tanult tér-időbeli jellemzők szintézisét végzi el. Végül egy softmax kimeneti réteg állít elő osztálytagsági valószínűségeket, lehetővé téve a többsztályos besorolást. A teljes architektúra sematikus ábráját a 3. ábra szemlélteti.




3. ábra. A tervezett 2D konvolúciós neurális hálózat felépítése: A bemenet az EEG jelek háromdimenziós reprezentációja, amelyen 2D konvolúció történik. Az első rétegben 32 darab [$3 \times 3 \times$ az időpontok száma] méretű kernel kerül alkalmazásra. A következő két konvolúciós rétegben először 64, majd 128 darab [$3 \times 3 \times$ az előző réteg kerneljeinek száma] méretű kernel végzi az adatfeldolgozást. Ezt követően a kapott jellemzőtér lapítva kerül továbbításra egy teljesen összekapcsolt (fully connected) hálózat két rétegébe, amelyek 1024, illetve 64 neuront tartalmaznak. Végül egy softmax osztályozó réteg következik, amely 4 elemű kimenetet ad, mivel ennyi osztály szerepel az osztályozási feladatban [J2].

2.5. Conv3D Net

A fő különbség e hálózat és a hagyományos kétdimenziós konvolúciós architektúrák között a harmadik dimenzió mentén végzett további konvolúciós műveletben rejlik, amely a második konvolúciós réteg után egy négydimenziós jellemzőreprezentációt eredményez. Bár ez a megközelítés megnövekedett memóriahasználattal jár, lehetővé teszi az időbeli összefüggések és az időben eloszló jellemzők hatékonyabb megragadását.

A második általam tervezett architektúra is L2-normálással kezdődik, amelyet három 3D konvolúciós réteg követ. Az első réteg szűrőmérete $[1, 1, 30]$, amely lehetővé teszi az időbeli jellemzők kinyerését térbeli kölcsönhatás nélkül, míg a következő rétegek $[2, 2, 40]$ méretű szűrőket használnak a térbeli és időbeli dimenziók együttes figyelembevételéhez. Minden konvolúciós réteg 32 szűrőt alkalmaz. A konvolúciós műveletek között batch normálást és Exponenciális Lineáris Egység (ELU) aktivációs függvényt alkalmaztam a tanítás stabilitásának növelése és a nemlinearitás biztosítása érdekében. A konvolúciós blokkok után a jellemzőtérképek két teljesen összekapcsolt rétegen haladnak át, majd egy softmax réteg végzi el az osztályozást. A hálózat architektúráját a 4. ábra szemlélteti.



4. ábra. A 3D konvolúciós hálózat felépítése. A bemenet megegyezik a 2D CNN esetében alkalmazottal, a különbség abban rejlik, hogy ebben a struktúrában háromdimenziós konvolúció történik. Valamennyi konvolúciós rétegben 32 darab kernel található. Az első rétegben a kernel mérete $(1 \times 1 \times 30)$, míg a második és harmadik rétegben $(2 \times 2 \times 40)$. A teljesen összekapcsolt (fully connected) rész két rétegből áll, mindkettő 32 neuront tartalmaz, végül pedig egy softmax osztályozó réteg zárja a hálózatot [J2].

2.6. További megvalósított neurális hálózatok

Az általam tervezett hálózatokon kívül további gépi-tanulási architektúrákat is implementáltam, melyek közül az EEGNet és a Shallow ConvNet igen széles körben alkalmazott struktúrák.

2.7. EEGNet

Az első vizsgált hálózat, az egyik legismertebb motoros képzeleti (MI) EEG-jelek osztályozására használt rendszer, az EEGNet, amelyet V. J. Lawhern és munkatársai mutattak be [10]. Az első réteg konvolúciós kerneljének hosszát a mintavételi frekvencia felére állítottuk be, további módosításokat nem alkalmaztunk. A hálózat fő rétegei a következők: egy kétdimenziós konvolúciós réteg, egy mélységi (depth-wise) kétdimenziós konvolúciós réteg, egy szeparált kétdimenziós konvolúciós réteg, végül pedig egy teljesen összekapcsolt (fully connected) osztályozó réteg.

2.8. Shallow ConvNet

Szintén megvalósítottam a Schirmesster és munkatársai által publikált Shallow ConvNet architektúrát [11], melyet több tanulmány is sikeresen alkalmazott elképzelt mozgások osztályozására. A hálózat egy időbeli konvolúciós rétegből, egy térbeli konvolúciós rétegből, egy átlagoló (mean pooling) rétegből, valamint egy lineáris osztályozó, teljesen összekapcsolt rétegből áll.

2.9. Multi Branch Conv3D Net

Egy, a saját hálómhoz hasonlóan szintén 3D konvolúciót használó hálózat megvalósítása Xinqiao Zhao és munkatársai [8] cikke alapján készült. Az architektúra három párhuzamos ágból áll, mindegyikben két, eltérő méretű konvolúciós kerneleket használó réteg található, amelyeket három teljesen összekapcsolt réteg követ. Az utolsó rétegek mérete megegyezik az osztályok számával; ezt követően a három ág kimenete

összeadódik, majd egy softmax művelet segítségével történik meg a végső osztályozás.

2.10. Transzfer tanulás és finomhangolás


Egy mélytanulós rendszer általában hatalmas mennyiségű tanító adatot igényel, hogy a jellemzőket megfelelően általánosítsa és megfelelő pontosságot érjen el. EEG adatok esetében ez a hatalmas adatbázis általában nincs jelen, hiszen az adatok felvétele roppant idő- és munkaigényes feladat. A transzfer tanulás (Transfer Learning - TL) alapgondolata, hogy a rendszert, vagy annak egy részét a cél-adathalmaztól független mintákon előtanítsuk, és az így előzetesen beállított súlyokat finomhangoljuk a tényleges adathalmazunkon. A transzfer tanulás két fajtája elterjedt. Az első megközelítésben az EEG jelünket olyan reprezentációra transzformáljuk, melyhez hasonló reprezentációból hatalmas adatbázisok, vagy azokon már előtanított hálózatok léteznek. Egy példa erre az ImageNet, aminek bemenetére az EEG adatokból 3 csatornás képeket generálunk. Bár ez a megközelítés ígéretes kutatási irányt képvisel, munkám során nem vizsgáltam a transzfer tanulásnak ezt a módját.

A második megközelítés - melyet ténylegesen alkalmaztam kutatásaim során - az előtanításhoz is EEG-adatokat használ, ám ezek az adatok a célalanytól eltérő személyektől származnak. Másképp fogalmazva, finomhangoltam az egyes alanyokra a többi alanyon előtanított hálózatot.

A kutatásomban a transzfer tanítás a következőképpen valósult meg: a Physionet adatbázis 105 alanyát iteratívan két részre osztottam, 90%-ukon előtanítottam a hálózatot (a halmaz 20%-át validációs adathalmaznak használva), míg a maradék 10%-on alanyonként finomhangoltam és teszteltem a hálózat pontosságát. A pontos művelet a 5 ábrán látható.

2.11. A frekvenciaszűrés hatásának vizsgálata

A kutatás későbbi szakaszában a frekvenciaszűrés hatását elemeztem. Megvizsgáltam, hogyan befolyásolja az osztályozási pontosságot, ha sáv-



5. ábra. Transzfer tanulás és az eredmények létrejötte. Annak érdekében, hogy statisztikailag szignifikáns eredményeket érjek el, minden alany esetén egy 5-szörös keresztvalidációt alkalmaztam. Ez azt jelentette, hogy alanyonként, hálózatonként és előfeldolgozási lépésenként összesen 15 mérési eredmény született. Transzfer tanulás alkalmazása esetén a hálózatot az alanyok 90%-ának adataival előtanítottam, majd ezt követően finomhangolást végeztem a maradék 10%-hoz tartozó alanyok tanító adathalmazain. A teljes folyamat tízszer ismétlődött úgy, hogy minden alany legalább egyszer tesztalanyként szerepelt [J2].

áteresztő szűrőt alkalmazok a 0,1–5 Hz-es frekvenciatartományra, illetve hasonló módon értékeltem az 5 és 75 Hz közötti szakaszt is. Emellett azt is megvizsgáltam, milyen eredményeket ad a frekvenciaszűrés teljes mellőzése. A szűrés lépésekhez ötödrendű Butterworth típusú szűrőt alkalmaztam.

2.12. Szeletelt tanítás (cropped training)

Az EEG-jelek eltérő kezdési időpontjaihoz való általánosíthatóság vizsgálata érdekében implementáltam a cropped training (szeletelt tanítás) módszerét, amelyet Schirrneister és munkatársai is alkalmaztak [11]. Ebben a megközelítésben az eredeti adatokat szisztematikus időbeli eltolással új mintákká alakítottam, így bővítve a tanító és tesztelő adathalmazt. Ez biztosította, hogy a neurális hálózatok szélesebb körű időbeli variációknak legyenek kitéve az EEG-jeleken belül, elősegítve a különböző kezdési időpontok szimulációját és a modellek általánosíthatóságának javítását. Munkám során 1 másodperc hosszúságú ablakokat használtam a korábbi 2 másodperc helyett, és 0,1 másodperces lépésekben végeztem eltolásokat egészen 2 másodpercig. Ez egyetlen epizódból 11 egymást átfedő szeletet eredményez. Egy adott epizódból származó összes minta kizárólag a tanító vagy kizárólag a tesztadathalmazba kerülhetett, keveredés nem történt. A korábban ismertetett, frekvenciafüggésre irányuló kísérletet ezen kibővített adathalmazon is megismételtem az összes hálózaton, a FASTER módszer alkalmazásával és anélkül is.

2.13. A kód elérhetősége

A kutatást támogató teljes kódbázis - beleértve a megtervezett és tesztelt hálózatokat, a transzfer tanulást, a cropped training eljárást, a műtermék-eltávolítást és minden további ismertetett módszert - nyilvánosan elérhető a következő címen: <https://dev.itk.ppke.hu/adoan/dissertation-codebase>.

3. Új tudományos eredmények

I. Tézis csoport

Az első téziscsoport a valós idejű műtermék-eltávolító rendszer tervezésére, megvalósítására és gyakorlati alkalmazására fókuszál, amelyet kifejezetten a BCI csapatunk támogatására fejlesztettem ki a 2020-as és 2024-es Cybathlon versenyekre történő felkészülés során. Ezek a nemzetközi események olyan különleges környezetet teremtenek, ahol az agyszámítógép interfész rendszereknek szigorú valós idejű követelmények mellett kell működniük, miközben a technikai megbízhatóságot is garantálniuk kell. A téziscsoport tézisei a másodszerzős cikkem által bemutatott eredményeken alapulnak [J1].

I.1. tézis *A FASTER (Fully Automated Statistical Thresholding for EEG artifact Rejection) algoritmuson alapulva – amelyet eredetileg offline EEG-feldolgozásra fejlesztettek – olyan online műtermék-eltávolító rendszert dolgoztam ki, amely valós idejű BCI-kísérletek során is használható, átlagosan $0,123 \pm 0,017$ másodperc késleltetéssel.*

Az EEGNet által igényelt többletfeldolgozás ideje $0,061 \pm 0,010$ másodperc, így az 1 másodperces EEG-szegmással együtt a teljes késleltetés a valós idejű BCI-működéshez ajánlott 1–2 másodperces ablakon belül marad. Ez megerősíti, hogy a kifejlesztett online műtermék-elutasító módszer megfelel a gyakorlati BCI-alkalmazások időbeli követelményeinek. Az algoritmus részletes bemutatása a *Módszerek és módszerek* első fejezetében olvasható.

I.2 Tézis *A kifejlesztett valós idejű műtermék-eltávolító rendszert integráltam csapatunk BCI keretrendszerébe a 2020-as és 2024-es Cybathlon eseményekre. A rendszer hivatalosan is elfogadásra került csapatunk számára a 2024-es versenyre a Cy-*

bathlon szervezőbizottsága által, ami igazolja, hogy a megoldás megfelel a verseny szigorú technikai előírásainak.

A Cybathlon verseny egy 4 évente megrendezésre kerülő nemzetközi esemény, melynek az agy-számítógép interfész-szekciójában a különböző országok által delegált mozgássérült pilótáknak kell egy számítógépes játékot irányítaniuk, gondolataik segítségével. Az irányításhoz tilos a nem agyi eredetű jeleket használni, emiatt különösen fontos a megfelelő, valós időben működő műtermék eltávolító algoritmus. Az online műtermék-eltávolító rendszernek a Cybathlon BCI-keretrendszerébe történő integrációja demonstrálja a megoldás alkalmazhatóságát valós idejű versenykörnyezetben. A Cybathlon szervezőbizottságának hivatalos jóváhagyása megerősíti, hogy a rendszer megfelelt az esemény műszaki specifikációinak, és megbízhatóan működött a versenykörnyezet korlátai között.

II. Tézis csoport

A második téziscsoport az EEG előfeldolgozási lépések és az ezek hatására kialakuló osztályozási teljesítmény közötti összetett és gyakran nemlineáris összefüggéseket vizsgálja agy-számítógép interfész rendszerekben. Az előfeldolgozás alapvető szerepet játszik az EEG jelminőségének javításában és a zaj csökkentésében, ugyanakkor hatása az osztályozási eredményekre nem mindig intuitív vagy egységes különböző alanyok, adatbázisok és neurális hálózati architektúrák esetén. Az itt leírt tézisek alapja az elsőszerzős folyóiratcikkem, [J2]

II.1 Tézis *Igazoltam, hogy a FASTER műtermék-eltávolító algoritmus osztályozási pontosságra gyakorolt hatása jelentősen függ a vizsgált alanytól. Az összehasonlító elemzésem során azt találtam, hogy a FASTER algoritmus alkalmazása a 105 alany közül 80 esetében javítja az osztályozási pontosságot, átlagosan 5,4%-kal. Ugyanakkor ez a kedvező hatás nem univerzális: a*


fennmaradó 25 alanynál a módszer átlagosan 4,4%-os pontosságcsökkenést eredményez.

A résztvevők egyéni vizsgálata alapján megállapítottam, hogy a műtermékek eltávolításának hatása az adott személytől függ, akinek az adatait elemezzük. Elemzésem átfogó megközelítést alkalmazott. Kezdetben mind a négy hálózatra elvégeztem háromszor az ötszörös keresztvalidációt, műtermék-eltávolítással és anélkül is. A különbségek alátámasztása érdekében megvizsgáltam egy adott alanyra és egy adott hálózatra kapott 15 eredmény eloszlását. Ha az adatok normális eloszlást követnek, t-próbát végeztem; ellenkező esetben, ha nem-normalitást észleltem, Mann–Whitney U próbát alkalmaztam a megfigyelt különbségek szignifikanciájának meghatározására.

Az alanyokat aszerint kategorizáltam, hogy a különböző hálózatok milyen mértékű változást eredményeztek a klasszifikációs teljesítményben. Érdekes módon több olyan eset is előfordult, amikor egyes hálózatok jelentős javulást eredményeztek, míg mások ugyanazon alanyok esetében szignifikáns visszaesést mutattak. A második vizsgálat során észlelt enyhe eltérés hatására kétszer megismételtem a számításokat, hogy feltérképezsem a különbségek szignifikanciájának alakulását. Így végül négy ismétlés (három pontossági eredmény minden egyes keresztvalidációs iterációra és hálózatra) alapján négy szignifikanciaszintet kaptam minden egyes klasszifikátorra.

Az értékelésem során minden alanyhoz egy numerikus értéket rendeltem az alábbiak szerint: az érték -1-et jelentett, ha szignifikáns csökkenés volt tapasztalható, 0-t, ha nem volt szignifikáns különbség, és +1-et, ha egyértelmű javulás volt megfigyelhető az adott számítási aspektusra vonatkozóan az összes hálózat esetében. Így az összpontszám alanyonként -20 és 20 között változhatott. Huszonöt alany ért el 8 pont feletti eredményt, ami jelentős teljesítményjavulást jelez az AR módszer alkalmazása esetén, közülük a 69-es alany kiemelkedő, 20 pontos javulást produkált. Ezzel szemben néhány alany, például a 15-ös, jelentős visszaesést mutatott, és mindössze öt alany ért el -8 pont alatti eredményt.

A klasszifikátorokat tekintve az EEGNet mutatta a legkisebb javulást: csak három alany ért el legalább 3 pontot, míg hatan -3 alatti értéket kaptak. Ezzel szemben a másik négy hálózatnál legalább 20 alany haladta meg a hárompontos küszöböt, és kevesebb mint öt esetben fordult elő -3 pont vagy annál rosszabb eredmény. Az AR alanyfüggőségét a 6. ábra szemlélteti.



6. ábra. A műtermékszűrés alanyfüggősége. A színek árnyalata azt jelzi, hogy hány futtatás esetében volt statisztikailag szignifikáns javulás (zöld), illetve romlás (piros). (Minél sötétebb az árnyalat, annál több futásban volt szignifikáns az eltérés.) A szignifikancia meghatározása normális eloszlás esetén T-próbán, nem normális eloszlás esetén pedig Mann-Whitney U-teszten alapul. Az alanyokat egy összesített pontszám alapján rendeztem sorba, amelyet a szignifikáns javulások számának és a szignifikáns romlások számának különbségeként számítottam ki [J2].

II.2 Tézis *Megmutattam, hogy a transzfer tanulás konzisztensen növeli az EEG-jelek osztályozási pontosságát különböző előtanítási feltételek mellett, mind nyers, mind pedig műtermékmentesített adatok esetén. Eredményeim markáns különbséget tártak fel a pontosságnövekedés mértékében: a nyers adatoknál a transzfer tanulás 40,0%-ról 57,5%-ra növelte a pontosságot, míg a FASTER műtermék-eltávolítási eljárással feldolgozott adatoknál a pontosság csak kisebb mértékben, 43,1%-ról 53,3%-ra változott. Az eredmények az öt vizsgált neurális hálózattal elért pontosságok átlagát jelzik.*


Megmutattam, hogy a transzfer tanulással elért klasszifikációs pontosság minden esetben szignifikánsan jobb. A rangsoros Wilcoxon-próba alapján a tanulási folyamat szignifikánsan jobb teljesítményt nyújtott minden egyes hálózat esetében, mind a szűretlen adatoknál (lásd 1. táblázat), mind pedig az műtermék-eltávolított adatok esetén (lásd 2. táblázat). A 7. ábrán megfigyelhető, hogy a transzfer tanulás nem hoz akkora javulást az artifaktumszűrt adatok esetében, mint a nyers adatoknál, így utóbbiaknál magasabb klasszifikációs pontosságot eredményez. (Ez a különbség minden esetben szignifikáns, kivéve a Multi-branch Conv3D hálózat esetében.) Ezek az eredmények arra utalnak, hogy a transzfer tanulás különösen akkor hatékony, amikor a bemeneti adatok a jellemzők gazdagabb készletét őrzik meg, azaz a nyers EEG esetében. A FASTER-rel feldolgozott adatokon megfigyelt, összehasonlítva kisebb javulás azt sugallja, hogy a műtermék-eltávolítás nemcsak a zajt csökkenti, hanem bizonyos mértékig a jel variabilitását és azokat az informatív struktúrákat is, amelyeket a transzfer tanulás ki tudna használni. Összességében ez a mintázat kiemeli, hogy a transzfer tanulás eredményessége az előfeldolgozási stratégiától függ, és a legnagyobb nyereség akkor érhető el, amikor a modell az előfeldolgozatlan EEG-jelek teljes komplexitásához tud alkalmazkodni.

1. táblázat. Az egyes osztályozók pontossága szűretlen adatokon, transzfer tanulással és anélkül, valamint a szignifikancia P-értéke a Wilcoxon-próba alapján.

Classifier	Simple Acc.	TL Acc.	P value
EEGNet	0.461	0.587	1.50E-18
Shallow ConvNet	0.394	0.637	5.83E-19
Conv2D Net	0.366	0.528	7.78E-19
Conv3D Net	0.378	0.56	7.14E-19
Multi Branch Conv3D Net	0.401	0.561	1.30E-18

2. táblázat. Az egyes osztályozók pontossága műtermék-mentesített adatokon, transzfer tanulással és anélkül, valamint a szignifikancia P-értéke a Wilcoxon-próba alapján.

Classifier	Simple Acc.	TL Acc.	P value
EEGNet	0.455	0.538	1.67E-17
Shallow ConvNet	0.441	0.559	1.38E-18
Conv2D Net	0.410	0.491	7.20E-17
Conv3D Net	0.405	0.521	7.14E-19
Multi Branch Conv3D Net	0.444	0.557	5.52E-18



7. ábra. A neurális hálózatok összehasonlítása a FASTER módszer alkalmazásával és anélkül, transzfer tanulás mellett. Minden pont egy alanyhoz tartozó két pontossági értéket jelöl: az egyiket a műtermék-szűrt (AR), a másikat a FASTER algoritmus nélküli feldolgozással kapott eredmény alapján. A tesztet háromszor futtattam le. A piros vonal azokat a pontokat jelöli, ahol nincs különbség a két megközelítés között; a vonal fölötti pontok esetében a nyers (szűrés nélküli) adatfeldolgozás eredményezett jobb pontosságot, míg az alatta lévők esetében a műtermék-mentesítés javította az eredményeket. Általánosságban elmondható, hogy transzfer tanulás alkalmazása esetén a műtermék-mentesítés nélkül kapott értékek általában magasabbak [J2].


II.3 Tézis *Megterveztem két neurális hálózatot, hogy vizsgáljam a térbeli dimenzió figyelembevételének hatását. Ehhez megalkottam az adatok egy új, sűrű 3D-s reprezentációját, amely pontosabban képes kihasználni az elektródák térbeli elhelyezkedéséből származó információt. Ez a reprezentáció bizonyos architektúráknál javította a pontosságot: a Conv3D esetében szignifikáns, 4,43%-os növekedést eredményezett, a Conv2D esetében nem szignifikáns 1,19%-os javulást, míg a Multi Branch Conv3D modellnél nem szignifikáns 0,15%-os csökkenést. A manuális és a tanult térbeli kódolások összehasonlítását vizsgáló eredmények azt mutatják, hogy az explicit térbeli kódolás nem teljesít jobban azoknál az architektúráknál, amelyek implicit módon tanulják meg a térbeli összefüggéseket: míg a manuális térbeli kódolást alkalmazó hálók átlagos pontossága transzfer tanulás alkalmazása mellett 53,6% volt, addig az implicit térbeli jellemzőtanulást használó modelleké 58,0%.*

Összehasonlítottam a vizsgált 5 neurális hálózatot a klasszifikációs pontosságuk alapján. Amint azt a 8. ábra is szemlélteti, transzfer tanulás alkalmazása nélkül a legmagasabb pontosságot az EEGNet klasszifikátor éri el, mind nyers, mind pedig a műtermék-eltávolított adatok esetén. Ugyanakkor az utóbbi esetben az EEGNet, a Shallow ConvNet és az MB Conv3D Net közötti különbségek nem bizonyultak szignifikánsnak. A nyers adatok esetében a második legjobb teljesítményt a Multi Branch Conv3D Net nyújtotta, ezt követte a Shallow ConvNet, míg az általam javasolt hálózatok gyengébben szerepeltek.

A transzfer tanulás (TL) bevezetésével azonban a teljesítményranglista jelentősen átrendeződik. A Shallow ConvNet válik a legjobban teljesítő hálózattá, megelőzve az EEGNetet és a többi klasszifikátort. A nyers adatok TL-esetén az EEGNet a második helyen áll, ezt követik a 3D konvolúciós hálózatok. Az artifaktumszűrt adatokkal és TL alkalmazásával az MB Conv3D Net megelőzi az EEGNetet, így holtversenyben az első helyen végzett, mivel különbsége a Shallow ConvNethez képest

nem volt szignifikáns. Ez azt mutatja, hogy a TL jelentős hatással van a különböző hálózati architektúrák teljesítménybeli sorrendjére.

A sűrű 3D reprezentáció bemeneti adatként történő használata nem eredményezett szignifikáns javulást a klasszifikációs teljesítményben. Ez arra utal, hogy a térbeli információk bevonása nem növelte a pontosságot azokhoz a hálózatokhoz képest, amelyek nem tartalmazták ezt a kiegészítő térbeli adatot. Ez a tendencia elsősorban abban a konfigurációban a legszembetűnőbb, amely a nyers EEG-adatokon végez transzfer tanítást. Mivel ez a konfiguráció érte el a legjobb teljesítményt, így ez bír a legnagyobb jelentőséggel. Ezzel szemben a FASTER algoritmussal előfeldolgozott adatok esetében kisebb eltérés figyelhető meg: a Multi Branch Conv3D hálózat kissé felülmúlta az EEGNetet, míg a Conv2D és a Conv3D architektúrák továbbra is a leggyengébben teljesítők között maradtak.



8. ábra. A neurális hálózatokkal elért pontosságértékek transzfer tanulással és anélkül, valamint műtermék-mentesítéssel és anélkül. A boxplot ábrán az x a mintaátlagot, míg a vízszintes vonal a mediánt jelöli. A doboz határai az adatok középső 50%-ának tartományát mutatják. A transzfer tanulási módszer alkalmazása előtt az EEGNet érte el a legjobb teljesítményt, míg az alkalmazása után a Shallow ConvNet bizonyult a leghatékonyabbnak. Az ábráról leolvasható, hogy azok a hálózatok, amelyek adaptív módon használják fel a csatornák egymáshoz képesti relatív elrendeződését (EEGNet és Shallow ConvNet) jobb eredményre képesek, mint az azokat explicit módon felhasználó társaik. (Conv2D, Conv3D, és MB Conv3D) [J2]

II.4 Tézis *Megmutattam, hogy a frekvenciaszűrés alkalmazása váratlan mintázatokat eredményez az osztályozási teljesítményben a Physionet motoros képzeleti adatbázison, a δ tartomány bizonyulva döntő tényezőnek. A 0,1–5 Hz-es sávban az öt hálózat átlagos pontossága 46,8% volt, míg az 5–75 Hz-es sávban 30,3%. Ezzel szemben, amikor a tanítást és tesztelést szeletelt EEG-szegmenseken végeztem, a magasabb frekvenciasávok - a μ , β és γ tartományok - váltak informatívabbá az EEGNet és a Shallow ConvNet architektúrák számára. Az EEGNet 36,4%-os pontosságot ért el a 0,1–5 Hz-es sávban és 45,1%-ot az 5–75 Hz-es sávban, míg a Shallow ConvNet 37,7%-ot és 48,8%-ot ért el a megfelelő sávokban.*

Megállapítottam, hogy a frekvenciaszűrés elemzéséből származó eredmények váratlan mintázatokat mutatnak. Az összehasonlítást a 0,1–5 Hz-es és az 5–75 Hz-es tartományok alkalmazásával végeztem el. Amint az a 3. táblázatban látható, az öt neurális hálózathalomból három esetben csak az első frekvenciatartományban (0,1–5 Hz) születtek szignifikáns eredmények. Az 5–75 Hz-es tartományban a véletlen-szintet meghaladó eredményeket kizárólag a Shallow ConvNet és az EEGNet érték el, azonban az EEGNet esetében ezek az eredmények még mindig jóval elmaradtak az alacsonyabb frekvenciatartományban elért pontosságtól.

3. táblázat. A neurális hálózatok osztályozási pontosságainak összehasonlítása különböző frekvenciatartományú szűrők alkalmazása esetén.

Frequency range	EEGNet	Shallow ConvNet	Conv2D Net	Conv3D Net	MB Conv3D Net
0.1-5 Hz – Raw	0.482	0.406	0.437	0.410	0.457
5-75 Hz – Raw	0.315	0.362	0.262	0.258	0.271
0.1-5 Hz – AR	0.452	0.405	0.421	0.436	0.462
5-75 Hz – AR	0.324	0.381	0.261	0.261	0.289

Amint a 4 táblázat is szemlélteti, a frekvenciaszenzitivitás eltolódása is különösen az EEGNet és a Shallow ConvNet esetében látható jól - ezek azok az architektúrák, amelyek képesek kihasználni a szeletelt tanítás által bevezetett további variabilitást. Míg az egyszerű tanítás a rendelkezésre álló minták korlátozott száma miatt a alacsony frekvenciasávot részesíti előnyben, a szeletelt tanítás sokkal nagyobb számú szegmenst biztosít, lehetővé téve ezeknek a modelleknek, hogy komplexebb oszcillációs mintázatokat tanuljanak meg, amelyek a μ és β sávokhoz kapcsolódnak. A fennmaradó hálózatok esetében, amelyek a sűrű 3D-s térbeli reprezentációra támaszkodnak, ez az eltolódás a szélesebb elemzésben nem figyelhető meg: teljesítményüket továbbra is az alacsony frekvenciasáv uralja, a tanítási stratégia típusától függetlenül. Ez rámutat arra, hogy a frekvenciaszűrés hatása erősen architektúrafüggő, és azt az is befolyásolja, hogy egy modell mennyire hatékonyan képes kihasználni a szeletelés által létrehozott megnövelt adatmennyiséget.

4. táblázat. Az EEGNet és a Shallow ConvNet összehasonlítása különböző frekvenciasávok és tanítási stratégiák szerint.

		0.5–5 Hz	5–75 Hz
Simple training	EEGNet	48.48%	30.07%
	Shallow ConvNet	44.22%	39.46%
Cropped training	EEGNet	36.42%	45.13%
	Shallow ConvNet	37.65%	48.78%


II.5 Tézis *Szemléltettem, hogy az EEGNet és a Shallow ConvNet hálózatok szeletelt EEG-szegmenseken végzett tanítása során a FASTER metódus általában azoknál a vizsgálati személyeknél javítja a teljesítményt, akik a frekvenciaszűrésből önmagában is profitálnak. Továbbá, a frekvenciaszűrés önmagában jellemzően jobb eredményeket ad, mint a teljes FASTER algoritmus; az átlagos pontosság a két hálózaton 46,4% a frekvenciaszűrés, illetve 43,3% a teljes FASTER algoritmus esetében. Megmutattam, hogy azoknak a személyeknek a listája,*

akiknél a műtermék-eltávolítás javította az osztályozási pontosságot a szeletelt szegmenseken végzett tanítás során, szignifikánsan különbözik azon személyek listájától, akiknél ugyanez a javulás a teljes hosszúságú szegmenseken történő tanítás esetén figyelhető meg.

Rámutattam, hogy ahogy a 9. ábra első két részábráján is látszik, az alanyok sorrendje a két kísérlet eredményeiben szinte azonos, ami arra utal, hogy a frekvenciaszűrés hasonló alanyonkénti hatást fejt ki, mint a FASTER algoritmus a nyers adatokhoz képest. Ez a sorrend azonban eltér a az első tézispontban bemutatott eredményektől, vagyis a szeletelt adatokon történő tanítás során megváltozik, mely alanyokra hat kedvezően a FASTER algoritmus.

Megfigyeltem, hogy a FASTER és a pusztá frekvenciaszűrés összehasonlításakor a sorrend ismét módosul: a legtöbb alanynál a FASTER szignifikáns teljesítményromlást okoz. Ezáltal megállapítottam, hogy cropped tanítás esetén célszerűbb csupán a megfelelő frekvenciasávok szűrését alkalmazni, és mellőzni a bonyolultabb FASTER eljárást a jobb eredmények elérése érdekében.

Az egyéni előfeldolgozási hatások konzisztenciájának vizsgálatához minden vizsgálati személyhez egy -8 és $+8$ közötti pontszámot rendeltem, amely azt tükrözi, hogy a MI-osztályozás pontossága az előfeldolgozást követően hány körben nőtt vagy csökkent szignifikánsan. Külön pontszámokat rendeltem a frekvenciaszűréshez és a teljes FASTER módszerhez. A két pontszámhalmaz rangkorrelációja erősnek bizonyult (Spearman $\rho = 0,824$, Kendall $\tau = 0,689$, $p < 0,001$), ami azt jelzi, hogy azok a vizsgálati személyek, akiknél a frekvenciaszűrés során következetes javulás volt megfigyelhető, a teljes FASTER eljárás esetében is hasonló javulási mintázatot mutattak. Ez az eredmény arra utal, hogy az előfeldolgozás hatékonysága erősen alanyfüggő, és az egyéni jellemzők befolyásolják a különböző artefakt-eltávolítási stratégiák-ból származó előnyöket. E megfigyeléssel összhangban az 5. táblázat azt mutatja, hogy átlagosan a frekvenciaszűrés önmagában magasabb



9. ábra. A FASTER műtermék-mentesítési módszer és a frekvenciaszűrés alanyonkénti hatása az EEGNet és a Shallow ConvNet osztályozási teljesítményére – a nyers adatokhoz viszonyítva – egyszerű és cropped tanítás során. A szín árnyalata azt jelzi, hogy a négy tesztből hányszor fordult elő statisztikailag szignifikáns javulás (zöld) vagy romlás (piros). Az alanyokat a műtermék-mentesítési módszerrel, a szűretlen adatokhoz képest elért pontszám alapján rendeztem sorba [J2].

osztályozási pontosságot eredményez, mint a teljes FASTER algoritmus, míg mindkét előfeldolgozási módszer jobb teljesítményt nyújtott a nyers adatokhoz képest.

5. táblázat. EEGNet és Shallow ConvNet összehasonlítása különböző előfeldolgozási stratégiák szerint.

	Raw data	Frequency- filtered	FASTER filtered
EEGNet	36.39%	42.98%	41.08%
ShallowConvNet	43.73%	49.72%	45.47%

Mesterséges intelligencia alapú eszközök használata

A disszertáció elkészítése során a ChatGPT-t (az OpenAI által fejlesztett nyelvi modellt) használtam a nyelvtani helyesség javítására és az olvashatóság növelésére. A modell használatát követően a teljes szöveget alaposan átnéztem és szerkesztettem, hogy biztosítsam a tartalom pontosságát és megfelelőségét. A dolgozatban szereplő tartalomért és következtetésekért teljes felelősséget vállalok.

Minden bemutatott eredmény, megállapítás és érdemi következtetés teljes mértékben saját munkám. A mesterséges intelligencia használata kizárólag a szöveg világosságának és koherenciájának támogatására korlátozódott.

Köszönetnyilvánítás

Mindenekelőtt szeretném legnagyobb hálámat kifejezni témavezetőm, Dr. Ulbert István irányába, a folyamatos támogatásáért és útmutatásáért a PhD-utam teljes időtartama alatt. Tapasztalata, türelme és bátorítása nélkülözhetetlen segítséget jelentettek számomra a doktori tanulmányaim legnehezebb időszakaiban.

Hatalmas köszönet illeti Köllöd Csaba Mártont, aki nélkül ez a disszertáció szintén nem jöhetett volna létre. Mint a Cybathlon-csapatunk vezetője és a rendszer mögöttes kódázisának fejlesztője, a hozzájárulása megkérdőjelezhetetlen. Az, hogy mindig készséggel segített, amikor technikai vagy elméleti nehézségekbe ütköztem, állandó motivációt és megerősítést jelentett számomra.

Hasonlóan hálás vagyok a BCI kutatócsoportunk többi tagjának, nevezetesen Dr. Márton Gergelynek és Ward Fadelnek, az együttműködésükért és építő jellegű visszajelzéseikért, különösen az elsőszerzős folyóiratcikkem elkészítése során. Szintén szeretném megköszönni Dr. File Bálintnak, hogy megosztotta velem tapasztalatait és meglátásait a műtermék-eltávolítással kapcsolatban.

Külön köszönet illeti a 240-es szobában dolgozó doktoranduszok támogató közösségét, akiknek összetartása és bátorítása az évek során nélkülözhetetlen közösségi élményt és tartozásérzetet adott.

Szeretném továbbá kifejezni hálámat Dr. Vida Tivadarnénak türelméért és felbecsülhetetlen segítségéért a PhD-tanulmányaim adminisztratív feladataiban.

Hálás vagyok az Innovációs és Technológiai Minisztérium által meghirdetett Kooperatív Doktori Program (KDP) Doktori Hallgatói Ösztöndíjprogramja által nyújtott pénzügyi és szakmai támogatásért, amelyet a Nemzeti Kutatási, Fejlesztési és Innovációs Alap finanszírozott.

Végezetül szeretném kifejezni őszinte hálámat a családomnak – szüleimnek, húgomnak, öcsémnek és nagyszüleimnek – rendíthetetlen érzelmi támogatásukért és folyamatos bátorításukért. Bár a munkám előrehaladását firtató kérdéseik néha nyomasztónak tűntek, mégis nagyban hozzájárultak ahhoz, hogy fókuszált és elszánt maradjak, és végigküzdjem ezt az utat egészen a végéig.

A szerző publikációi

Tézispontokhoz kapcsolódó publikációk

- [J1] C. M. 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] **A. Adolf**, C. M. Köllöd, G. Márton, W. Fadel és I. Ulbert, “The Effect of Processing Techniques on the Classification Accuracy of Brain-Computer Interface Systems”, *Brain Sciences*, 14. évf., 12. sz., 2024. DOI: 10.3390/brainsci14121272.

Szerző egyéb publikációi

- [Au1] C. M. 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.
- [Au2] M. Wahdow, M. Alnaanah, W. Fadel, **A. Adolf**, C. M. Köllöd 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.
- [Au3] C. M. 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>.

Hivatkozások

- [1] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller és T. M. Vaughan, “Brain–computer interfaces for communication and control”, *Clinical Neurophysiology*, 113. évf., 6. sz., 767–791. old., 2002. DOI: 10.1016/S1388-2457(02)00057-3.
- [2] X. Jiang, G.-B. Bian és Z. Tian, “Removal of Artifacts from EEG Signals: A Review”, *Sensors*, 19. évf., 5. sz., 987. old., 2019. DOI: 10.3390/s19050987.
- [3] I. Daly, R. Scherer, M. Billinger és G. Müller-Putz, “FOR-Ce: Fully Online and Automated Artifact Removal for Brain-Computer Interfacing”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 23. évf., 5. sz., 725–736. old., 2015. DOI: 10.1109/TNSRE.2014.2346621.
- [4] S.-H. Hsu, T. R. Mullen, T.-P. Jung és G. Cauwenberghs, “Real-Time Adaptive EEG Source Separation Using Online Recursive Independent Component Analysis”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 24. évf., 3. sz., 309–319. old., 2016. DOI: 10.1109/TNSRE.2015.2508759.
- [5] 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.
- [6] A. L. Goldberger és tsai, “PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals”, *Circulation*, 101. évf., 23. sz., e215–e220., 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”, *IEEE transactions on bio-medical engineering*, 51. évf., 6. sz., 1034–1043. old., 2004. DOI: 10/b7bs63.

- [8] X. Zhao, H. Zhang, G. Zhu, F. You, S. Kuang és L. Sun, “A multi-branch 3D convolutional neural network for EEG-based motor imagery classification”, *IEEE transactions on neural systems and rehabilitation engineering*, 27. évf., 10. sz., 2164–2177. old., 2019.
- [9] T. Liu és D. Yang, “A densely connected multi-branch 3D convolutional neural network for motor imagery EEG decoding”, *Brain Sciences*, 11. évf., 2. sz., 197. old., 2021.
- [10] V. J. Lawhern, A. J. Solon, N. R. Waytowich, S. M. Gordon, C. P. Hung és B. J. Lance, “EEGNet: A Compact Convolutional Network for EEG-based Brain-Computer Interfaces”, *Journal of Neural Engineering*, 15. évf., 5. sz., 56013. old., 2018. DOI: 10.1088/1741-2552/aace8c.
- [11] R. Schirrmeister és tsai., “Deep learning with convolutional neural networks for EEG decoding and visualization: Convolutional Neural Networks in EEG Analysis”, *Human Brain Mapping*, 38. évf., 2017. DOI: 10.1002/hbm.23730.