

Doktori (PhD) értekezés tézisei

Emberi tevékenység felismerés EEG szenzorok adataiból gépi tanulással

Majoros Tamás

Témavezető: Dr. Oniga István



DEBRECENI EGYETEM
Informatika Tudományok Doktori Iskola

Debrecen, 2023.

Tartalomjegyzék

1.	Kutatási célkitűzés.....	1
2.	A doktori értekezés szakirodalmi háttere és előzményei	3
3.	Az értekezés új eredményei.....	14
3.1.	EEG adatgyűjtő szoftver fejlesztése és a mérési adatok feldolgozása	14
3.2.	Optimális szegmensméret meghatározása ...	15
3.3.	Teljesítménysűrűség-spektrum kinyert jellemzőként való használatának vizsgálata	17
3.4.	CNN hálózatok hatékonyságvizsgálata saját gyűjtésű adatokon.....	19
3.5.	CNN hatékonyságvizsgálata PhysioNet adatokon	20
3.6.	Neurális hálózat FPGA implementációja.....	22
	Irodalomjegyzék.....	24
	A dolgozat alapjául szolgáló publikációk	31

1. Kutatási célkitűzés

A dolgozat egyik fő kutatási kérdése, hogy az EEG felvételek alapján történő emberi tevékenység felismerés korábbi eredményei gépi tanulási módszerekkel valamilyen módon tovább javíthatók-e. Ez a kutatási terület jelenleg igen népszerű és szerteágazó, évről évre jelentős számú új tudományos közlemény jelenik meg a témában.

A lehetőségekhez mérten széleskörű szakirodalmi áttekintést végeztem és megállapítottam, hogy az automatikus kiértékelés (osztályozás) alkalmazása során számos megoldandó probléma, illetve kérdés merül fel. Az egyik ilyen, hogy a mérésből származó nyers adatok milyen formában, milyen esetleges előfeldolgozás után kerüljenek felhasználásra a gépi tanulási modellben. Egy másik kérdés, hogy szükséges-e jellemzők (*features*) kinyerése az adatokból, és ha igen, akkor milyen típusúak legyenek ezek. Ezek után választanunk kell a számtalan gépi tanulási módszer közül egy, a feladat megoldására alkalmasat. Végül az alkalmazott módszer paramétereit finomhangolni kell, kiértékelni a teljesítményét, és annak ismeretében további finomításokat végezni, ha szükséges, akár a jellemzők kinyerése, a választott módszer, vagy a módszer paramétereinek tekintetében. Az alkalmazható eljárások skálája nagyon széles, így a számos lehetséges megközelítésből a korábbi kutatások eredményei alapján legígéretesebbnek tűnő technikákban rejlő további lehetőségeket vizsgáltam, arra keresve a választ, hogy el tudok-e érni a korábbiaknál jobb pontosságot egy megfelelő gépi tanulási algoritmus és jellemzőkinyerési

módszer megválasztásával. Ehhez legtöbb esetben nyilvánosan elérhető EEG adatbázis adatait használtam fel.

A dolgozat egy másik fő kutatási kérdése az olcsó, felhasználói szegmensnek szánt eszközök alkalmazhatóságának vizsgálata az EEG-alapú tevékenység felismerésben. Amennyiben ezek az készülékek kellően jó minőségű adatokat biztosítanak, megfizethetőségük okán a későbbiekben alkalmasak lehetnek arra, hogy akár otthonukban segítsék például fogyatékkal élők vagy idősek életét. Manapság több ilyen eszköz is megtalálható a piacon, specifikációi, továbbá korábbi kutatásokban bebizonyosodott jó használhatósága okán az Ultracortex Mark IV EEG sisakra esett a választás. Szükségesnek tartottam, hogy elkészítsek egy olyan adatgyűjtő szoftvert, amelynek segítségével rögzíthetők olyan jellegű adatok, amelyek az általam használt publikus EEG adatbázisban is megtalálhatók. Ilyen módon lehetőségem nyílt arra, hogy összehasonlítsam a választott gépi tanulási módszer teljesítményét egy professzionális eszközből származó, és egy olcsóbb készülék által biztosított adatokon.

Harmadik kutatási célként pedig a neurális hálózatok hardveres implementációs lehetőségeinek vizsgálatát tűztem ki. Ehhez egy olyan szoftvert szándékoztam elkészíteni, amely teljesen automatikusan képes FPGA-alapú (field-programmable gate array) implementációt létrehozni, így az hardveres tervezési ismeretek hiányában is képes a felhasználó számára egy ilyen megoldás előnyeit biztosítani. Emellett meg szerettem volna vizsgálni egyéb hardveres gyorsítási lehetőségek alkalmazását is.

2. A doktori értekezés szakirodalmi háttere és előzményei

Az EEG jelekből történő tevékenységfelismerés alapötlete az, hogy tevékenységek végzése közben az agy generál olyan mintákat, amelyek csak az adott tevékenységre jellemzők, így a különböző tevékenységek ezen minták alapján egymástól elkülöníthetők az EEG-ben. Erre a célra számos gépi tanulási módszer alkalmazható, ideértve a sekély és mélytanulási technikákat is. Az egyik ilyen sekély gépi tanulási módszer az SVM (*support vector machine*) alkalmazása, amely lineárisan elválasztható csoportok osztályozására szolgál olyan módon, hogy meghatározza azt a szeparáló hipersíkot, amely esetén a legnagyobb a margó.

A k -legközelebbi szomszéd (*k-nearest neighbors*, kNN) módszerrel történő osztályozás esetén a tesztvektor valamilyen metrika alapján (pl. euklideszi távolság) meghatározott k legközelebbi szomszédját vesszük a tanító halmazból, ezek közül a hozzájuk kapcsolódó osztálycímkek között legtöbbször előfordulót rendeljük a tesztadathoz.

Döntési fa (*decision tree*, DT) esetén a nemterminális csúcsok tesztfeltételt tartalmaznak. A gyökércsúcsból indulva vizsgáljuk, hogy a tesztesetre igazak-e az egyes feltételek, ilyen módon bejárva a fát, amíg végül egy levélcsúcsba érünk. A levélcsúcsokban már nem feltételt, hanem egy osztálycímket találunk, így megkapjuk, hogy melyik osztályba tartozik a vizsgált minta.

A véletlen erdő (*random forest*, RF) módszer a döntési fák kiterjesztése olyan módon, hogy több különböző, egymástól független döntési fát hoz létre a tanulás során, amelyek mindegyike hoz egy döntést és ezek közül a legtöbbször előforduló osztályt rendeljük a tesztetthez. Az alapötlet ebben az esetben (és az ehhez hasonló együttes tanulási módszernél) az, hogy gyenge osztályozók csoportba szervezve, kollektív módon egy erős, hatékony tanulóalgoritmussá válhatnak.

A naiv Bayes (NB) osztályozó megbecsüli az osztályra vonatkozó feltételes valószínűségeket, azt feltételezve, hogy adott osztály mellett az attribútumok feltételesen függetlenek egymástól, majd osztályozáskor az így kapott feltételes valószínűségek felhasználásával adja meg a legvalószínűbb osztályt.

A neurális hálózatoknak (*artificial neural network*, ANN) számos típusa létezik, közülük az egyik legegyszerűbb, de gyakran alkalmazott hálózat a többrétegű perceptron (*multilayer perceptron*, MLP), amely egy előrecsatolt neurális hálózat. Ez legalább három rétegből áll (bemeneti, kimeneti és egy vagy több rejtett réteg), a rétegekben neuronok találhatóak, a bemeneti rétegben lévő neuronok kivételével aktivációs függvényekkel együtt. Az egymást követő rétegek teljesen összekapcsoltak, azaz bármely rétegben lévő összes neuron kapcsolódik az azt követő réteg összes neuronjához.

A mélytanulási módszerek megjelenését követően azok egyre elterjedtebbé váltak a legkülönfélébb gépi tanulási problémák esetében. Az említett MLP hálózat több rejtett réteg alkalmazásával már a mélytanulási

módszerekhez sorolható, azonban bizonyos kiegészítésekkel ettől komplexebb mélytanuló hálózatok is létrehozhatók. A rekurrens neurális hálózat (*recurrent neural network*, RNN) például az MLP-vel ellentétben nem csak előrecsatolást, hanem visszacsatolást is tartalmaz, amely tulajdonképpen memóriával látja el a hálózatot. Konvolúciós neurális hálózat (*convolutional neural network*, CNN) esetén pedig új típusú rétegekkel egészül ki a hagyományos, csak neuronokat tartalmazó előrecsatolt hálózat. Ezek az új rétegek képesek automatizálni a sekély módszerek esetén „kézzel” történő jellemző kinyerést, ilyen módon egy általánosabban használható megoldást biztosítanak. Az előbbi két megoldásnak, azaz a visszacsatolásnak és a konvolúciós rétegek hozzáadásának a kombinációja is lehetséges, ekkor rekurrens konvolúciós neurális hálózatról (RCNN) beszélünk.

Számos kutató vizsgálta az előbb említett (és egyéb) gépi tanulási módszerek alkalmazhatóságát EEG alapján történő tevékenységfelismerésben, azonban a kapott eredmények nem támasztják alá, hogy lenne egy olyan algoritmus, amelynek hatékonysága egyértelműen jobb a többinél. Például az [1] cikk szerzői öt sekély algoritmust használtak elképzelt motoros tevékenység felismerésére kilenc önkéntes esetén. Négy alanynál a naiv Bayes, kettőnél a DT, kettőnél a kNN, egyenél az SVM bizonyult a leghatékonyabbnak. A [2] cikk szerzői egy, az előzőhöz hasonló adatbázison SVM és CNN osztályozók közül mind a kilenc alany esetén a CNN-t találták pontosabbnak. Ezzel szemben viszont a [3] tanulmányban kilencből öt alany esetén az SVM adott jobb eredményt a CNN-nel szemben.

A [4] cikk szerzői elképzelt motoros tevékenységek felismerésére alkalmaztak MLP, CNN és RNN típusú hálózatokat. Eredményeik alapján a CNN bizonyult a három közül a legjobbnak, továbbá megmutatták, hogy egy ugyanolyan típusú, de nagyobb, több rétegű modell nem feltétlenül jobb, mint egy sekélyebb, azaz a hálózat komplexitása nem korrelál a felismerési pontosságával. Ezen túl rámutattak arra is, hogy a CNN hálózatok teljesítményét nagymértékben befolyásolja a hiperparaméterek (azaz például a kernelméret, kernelszám) megválasztása. Az [5] publikációban a szerzők szintén RNN és CNN algoritmust vizsgáltak, és megállapították, hogy a CNN jelentősen felülmúlja az RNN-t.

A [6] tanulmányban a kutatók egy öt önkéntestől származó EEG adatbázist használtak, amelyen a jobb kéz és jobb lábfej elképzelt mozgását próbálták elkülöníteni egymástól. Ehhez DT, MLP, SVM, kNN, NB és RF algoritmusokat használtak zajcsökkentést, jellemző kinyerést és dimenziócsökkentést követően. Az elért osztályozási pontosság szempontjából az NB 53%-os eredménye bizonyult a legrosszabbnak, amelytől jelentősen jobban teljesítettek a DT (64%), MLP (67%), RF (78%) és SVM (89%) módszerek, de a legjobb eredményt a kNN algoritmus nyújtotta közel 95%-os pontosságával az öt önkéntes átlagában. Megjegyzendő ugyanakkor, hogy volt olyan alany, akinek adatai esetén a DT és az RF algoritmus felülmúlta ezt az eredményt 95%, illetve 98%-os osztályozási pontosságával.

A [7] cikk szerzői szintén SVM és MLP algoritmust használtak elképzelt motoros tevékenységek felismerésére, azonban a [6] cikkel ellentétben ők

hatékonyabbnak találták az MLP-t: SVM esetén 75%, MLP esetén 80% osztályozási pontosságot sikerült elérniük.

Az előbbieken hivatkozott kutatások rámutattak arra, hogy korántsem egyértelmű, hogy milyen gépi tanulási módszer alkalmazása lehet a leghatékonyabb az EEG alapján történő tevékenységfelismerésben. Bizonyos esetekben sekély, más esetekben mélytanuló algoritmusok bizonyultak pontosabbnak az osztályozásban. Ha egyébként ezek a kutatások nem mutattak volna olykor egymásnak ellentmondó eredményeket, akkor sem lehetne elvégezni ezek alapján egy sorrend felállítását az egyes algoritmusok között, hiszen azok eltérő architektúrájúak voltak, eltérő módon előfeldolgozott adatokon, eltérő adatbázisokon lettek alkalmazva, így általános érvényű konklúzió levonása nem lenne lehetséges. Mindezek mellett ugyanakkor megfigyelhető az a tendencia, hogy ebben a kutatási témában az utóbbi években a legáltalánosabban elterjedt algoritmussá a konvolúciós neurális hálózat vált [8].

Az EEG jelek bonyolultak és nagy mennyiségű információt tartalmaznak. Az említett tanulmányok alapján látszik, hogy egy hálózat hatékonyságában nagy szerepe van a megfelelő algoritmus és architektúra kiválasztásának, azonban legalább ennyire befolyásolni tudja a végeredményt az adatok előfeldolgozása és a jellemzők kinyerése. A jellemzők kinyerésének célja az adatok alacsonyabb dimenziós térbe transzformálása úgy, hogy az megtartsa az EEG jelek által közvetített kritikus információkat [9]. A szakirodalomban számos jellemzőkinyerési módszert javasoltak a konkrét feladat alapján, ideértve az időtartományt, frekvenciatartományt,

idő-frekvencia tartományt, valamint a térbeli kapcsolatokat [10].

A [8] kutatás széleskörű áttekintést ad a különböző EEG-n történő mélytanulást vizsgáló cikkekről. Ez alapján CNN használatánál a számba vett cikkek több, mint 55%-ánál a rögzített jelek értéke közvetlen módon, szűk 30%-ánál képpé konvertálva szolgált a hálózat bemeneteként, és csupán az esetek körülbelül 15%-ában használtak fel valamilyen, adatokból kinyert jellemzőt. Érdeemes azt is megemlíteni, hogy ez utóbbi esetekben a kutatók által elért pontosság átlaga 84%, míg a jelek közvetlen használatánál 87% volt, amely cáfolja azt a feltételezést, hogy minél több erőfeszítést teszünk az adatok jobb előfeldolgozásáért, annál pontosabb lesz az osztályozás. Sőt, egyenesen arra a meglepő következtetésre mutat rá, hogy a neurális hálózatra bízva ezt a feladatot jobb végső eredményt érhetünk el. Ezek a megfigyelések összhangban vannak azzal a ténnyel, hogy a konvolúciós rétegek képesek az automatikus jellemzőkinyerésre, és megmutatták azt, hogy emellett további statikus módszer alkalmazása nem indokolt. Szintén ezen cikk alapján viszont MLP használatakor egy kivétellel (ahol közvetlenül a rögzített jelek értékét használták) minden esetben kinyert jellemzők felhasználásával történt az osztályozás.

Az időtartományból származó jellemzők közé soroljuk a különböző statisztikai mérőszámokat, mint például az átlag, a szórás, az átlagos abszolút eltérés, a négyzetes közép, a kurtózis, vagy épp a minimum-maximum közti különbség. A frekvenciatartománybeli jellemzők között megemlíthetjük például a spektrum energiát (frekvenciakomponensek abszolút értékének

négyzetösszege), a spektrum entrópiát, a spektrumközeget (a spektrum várható értéke, ha azt valószínűségi eloszlásként tekintjük), vagy az alapfrekvenciát, amely a jelben megtalálható legnagyobb amplitúdójú komponens frekvenciája.

Bár a témában egyre több cikk jelenik meg, továbbra is nyitott kérdés, hogy milyen jellemzők felhasználásával maximalizálható a gépi tanulás pontossága. A [11] tanulmányban a kutatók mintegy egy tucat különböző idő-és frekvenciatartománybeli jellemzőt nyertek ki az EEG adatokból, amelyeket lineáris diszkriminancia-analízis (*linear discriminant analysis*, LDA) módszerrel történő osztályozáshoz használtak fel. Közülük a szerzők egy frekvenciatartománybeli jellemzőt, a teljesítménysűrűség-spektrumot (*power spectral density*, PSD) találták a leghatékonyabbnak.

Az előző kutatás nem vett számba idő-frekvenciatartománybeli jellemzőket, annak ellenére, hogy a frekvenciatérbeli leírás önmagában semmit nem mond a jel időbeli változásairól, így kevesebb információt tartalmaz, mint az idő-frekvenciatérbeli leírás. Rövid idejű Fourier-transzformációval (*short-time Fourier transform*, STFT) vagy wavelet transzformációval (WT) a frekvenciaspektrumban történő változások azok előfordulási idejével együtt határozhatók meg, amelyet kinyert jellemzőként használva felveti az osztályozó algoritmus pontosságának további növelési lehetőségét. A [12] cikk szerzői öt különböző matematikai módszert alkalmaztak frekvencia- és idő-frekvenciatartománybeli jellemzőkinyerésre. Ezek a gyors Fourier-transzformáció (*fast Fourier transform*, FFT), wavelet transzformáció, sajátvektorok, idő-frekvencia eloszlás és autoregresszív

eljárások voltak. Eredményeik azt mutatták, hogy minden módszernek vannak előnyei és hátrányai a többihez képest, így az idő-frekvenciatérbeli jellemzők használata nem feltétlenül előnyösebb a frekvenciatérbeli jellemzők használatánál.

A gépi tanulási módszerek EEG jelek feldolgozásában való egyre nagyobb mértékű elterjedésével párhuzamosan egymás után jelentek meg a nyilvánosan elérhető, EEG méréseket tartalmazó adatbázisok. Ezek közül néhány, valódi vagy elképzelt motoros tevékenységek végzése során rögzített adatokat összegyűjtő adatkészlet került felsorolásra az 1. táblázatban.

1. táblázat. Motoros tevékenységek EEG felvételeit tartalmazó nyilvános adatbázisok

Referencia	Adatgyűjtésben résztvevő önkéntesek száma	Tevékenységek típusa
[13-14]	109	Kéz, lábfej mozgatása, valódi és elképzelt
[15]	12	Fogás és emelés, valódi
[16]	13	Kéz, láb, nyelv, ujjak mozgatása, elképzelt
[17]	7	Kéz, lábfej mozgatása, elképzelt

[18] 2a	9	Kéz, láb, nyelv, ujjak mozgatása, elképzelt
[18] 2b	9	Kezek mozgatása, elképzelt
[19]	14	Kéz, lábfej mozgatása

Részben egy már meglévő adatbázis használatának magától értetődő előnyei miatt, részben annak érdekében, hogy saját kutatási eredményeim összehasonlíthatóak legyenek más, korábbi publikációkban közölt eredményekkel, munkám során én is nagyrészt egy ilyen adatbázison, konkrétan a táblázat első sorában hivatkozott, 109 önkéntes részvételével készült PhysioNet adatbázison dolgoztam. Emellett bizonyos esetekben saját EEG eszközzel, saját mérőrendszerrel rögzített adatokat használtam, a mérést és kiértékelést végző programokat kifejezetten ehhez a kutatáshoz fejlesztettem.

A PhysioNet adatbázis több, mint 1500 egy- és kétperces EEG felvételt tartalmaz 109 önkéntestől. A méréseket a BCI2000 rendszerrel végezték 64 csatornán, miközben az önkéntesek különböző motoros és elképzelt motoros tevékenységeket hajtottak végre. Minden alany esetén 14 mérés készült, amelyek közül két egyperces felvétel során az önkéntesek nem végeztek tényleges tevékenységet, csupán nyitott, illetve zárt szemmel ülve rögzítették EEG jeleiket, a további 12 mérés során pedig négy különböző feladatot hajtottak végre, mindegyiket három alkalommal megismételve, két-két perc erejéig. Ez utóbbiak közül azokat használtam, ahol egy objektum megjelenik a képernyő tetején vagy alján, és ennek

megfelelően az önkéntes összecukja vagy mindkét öklét, vagy mindkét lábfejét, amíg az objektum el nem tűnik, majd ellazul. Ez történhet akár valódi, akár elképzelt mozgásként.

Az objektumok megjelenítése a képernyőn négy másodpercig történt, a megjelenítések közti szünet szintén négy másodperc időtartamú volt. Az adatok 160 Hz mintavételi frekvenciával lettek rögzítve, EDF+ formátumban, amely egy széles körben elfogadott szabvány EEG adatok tárolására. Előnye az EDF-fel szemben, hogy támogatja a szabványos elektródanevek használatát és az időbélyegzett annotációkat az események tárolására [20], amelyek jelen esetben a tevékenységváltást jelentik.

A 2. táblázat bemutat néhány, más kutatók által a PhysioNet adatbázison elért eredményt. Megjegyzendő ugyanakkor, hogy azonos adatbázis használata esetén sem minden esetben hasonlíthatók össze az elért osztályozási pontosságok, ugyanis egyrészt számít, hogy hány önkéntes adatai lettek ténylegesen felhasználva a 109-ből, másrészt, hogy hány osztályt különböztetünk meg. Bármely mérési fájl esetén – kivéve a nyitott-csukott szem esetét – alapvetően háromféle tevékenységről állnak rendelkezésre adatok (például az első esetben bal kéz mozgása, jobb kéz mozgása, pihenés), azonban egyrészt ez szűkíthető is két osztályra, ha például a pihenést nem kívánjuk figyelembe venni, csak az aktív tevékenységeket, másrészt bővíthető is több különböző típusú mérési fájl összevonásával.

2. táblázat. PhysioNet adatbázison elért korábbi eredmények

Referencia	Legjobb elért felismerési arány
[21] (2 osztály)	80,05%
[22] (2 osztály)	80,1%
[22] (3 osztály)	69,72%
[22] (4 osztály)	59,71%
[23] (2 osztály)	74,71%
[24] (5 osztály)	70,64%
[25] (2 osztály)	74,9%
[26] (2 osztály)	83,26%

3. Az értekezés új eredményei

3.1. EEG adatgyűjtő szoftver fejlesztése és a mérési adatok feldolgozása

Az EEG-alapú tevékenységfelismerés folyamatának első lépését az adatok összegyűjtése képezi. Ebből a célból az OpenBCI-től származó Ultracortex Mark IV típusú EEG sisakot használtam, amely jó teljesítményt és nagy pontosságot biztosít az árához mérten [27]. Ez a headset száraz EEG érzékelők segítségével 8 vagy 16 csatornán képes rögzíteni az agyi aktivitást, akár 35 különböző helyről. Számomra a nyolccsatornás változat állt rendelkezésre. A mintavételezési frekvencia 250 Hz mind a nyolc csatornán. Az eszköz lítium-ion akkumulátorról üzemeltethető és az adatgyűjtő számítógéppel történő kommunikáció vezeték nélküli kapcsolaton történik.

Az adatgyűjtéshez és a mérés irányításához a [C2] cikkemben leírt módon kifejlesztettem egy programot, amellyel képes vagyok hasonló jellegű mérések elvégzésére, mint a PhysioNet adatbázis készítői. Az eszközről érkező adatok LSL (*Lab Streaming Layer*) protokollon keresztül továbbítódnak az adatgyűjtő szoftverhez. Az általam készített szoftver képes az OpenBCI eszközről érkező adatfolyam fogadására, rögzítésére és felcímkezésére. Az alkalmazás véletlenszerűen megjelenít egy objektumot a képernyő felső vagy alsó részén adott időtartamig, majd az objektum eltűnik bizonyos időre és ez a folyamat ismétlődik, ugyanúgy, mint a PhysioNet mérések során. Eközben a beérkező mérési adatok mind a nyolc csatornán rögzítésre

és felcímkézésre kerülnek, a címke megadja, hogy milyen feladatot kellett végeznie az önkéntesnek az adott pillanatban.

Az alkalmazásban felhasználóbarát módon, grafikus felületen lehet a mérési paramétereket beállítani. Ezek a mérési paraméterek megadják, hogy hány másodpercig kell az objektumot megjeleníteni, hány másodpercig nem, és ez a ciklus hányszor ismétlődjön meg.

1. tézis: *Kifejlesztettem egy szoftvert, amely képes tetszőleges OpenBCI EEG eszközökről adatgyűjtést végezni. A szoftver egy objektumot jelenít meg véletlenszerűen a képernyő különböző részein, miközben LSL protokollon keresztül fogadja, rögzíti és felcímkézi az EEG eszközről érkező adatfolyamot. A működés helyességének igazolása laboratóriumi vizsgálatokkal történt.*

3.2. Optimális szegmensméret meghatározása

EEG jelek alapján történő tevékenységfelismeréskor a mért adatok tipikusan egy hosszú, digitalizált adatfolyamként állnak rendelkezésre, amelynek során az alany akár több különböző tevékenységet is végezhet. A tanítás során arra a feltételezésre építünk, hogy az adatokban megtalálható valamilyen mintázat, amely csak egy adott tevékenység esetén jelenik meg, ennek megfelelően legalább a tevékenységváltások bekövetkezésekor szükség van az adatfolyam széttördelésére. Jellemzően azonban a jobb teljesítmény érdekében ettől kisebb darabokra történő tördelés optimális. Az adatfolyam ilyen jellegű feldarabolását

szegmentálásnak, az egyes szegmenseket pedig ablakoknak nevezzük.

Az ablakok mérete jellemzően néhány másodperces intervallumot fed le [28-30]. Fontos az ablakméret megfelelő megválasztása, ugyanis létezik egy olyan optimális érték, amellyel az adott gépi tanulási feladat esetén a modell teljesítménye maximalizálható. Ezek alapján a [J2], [C1], illetve részben ide vonatkozóan a [J1] és [C5] cikkemben leírt módon a PhysioNet adatbázis felhasználásával igyekeztem megtalálni az ideális ablakméretet. Az adatok szegmentálását különböző ablakméretekkel végeztem.

Mivel a neuronoknál alkalmazott súlyok és eltolások kezdeti nagysága Gauss-eloszlásból származó véletlenszerű érték, ezért azonos adatokkal való többszöri tanítás esetén is kissé különböző osztályozási pontosságokat kapunk. Azért, hogy csökkentsem annak az esélyét, hogy emiatt téves következtetést vonjak le az ideális ablakméretre vonatkozóan, minden ablakméret mellett öt alkalommal ismételt meg a kísérletet. A 3. táblázat tartalmazza a neurális hálózat osztályozásának pontosságát a tesztadatokon mérve, illetve a kapott értékek szórását.

3. táblázat. Neurális hálózat osztályozási pontossága különböző ablakméretek esetén

Ablakméret (mintaszám és időtartam)	Pontosság a tesztadatokon
40 (0,25 mp)	78,64 ± 1,30%
60 (0,475 mp)	86,90 ± 0,61%
80 (0,5 mp)	91,52 ± 0,69%

100 (0,625 mp)	93,76 ± 1,33%
120 (0,75 mp)	95,89 ± 0,15%
140 (0,875 mp)	97,57 ± 0,47%
160 (1 mp)	98,62 ± 0,21%
180 (1,125 mp)	98,34 ± 0,41%
200 (1,25 mp)	97,99 ± 0,33%

A kapott eredmények és más szempontok figyelembevételével az egy másodperc hosszú ablak használatát találtam optimálisnak ebben az alkalmazásban.

2. tézis: *Meghatároztam azt az optimális szegmensméretet, amellyel a gépi tanulási modell teljesítménye maximalizálható EEG-alapú tevékenységfelismerés esetén. Megállapítottam, hogy a szegmensméret növelésével a felismerési pontosság is szigorúan monoton növekvő egy másodperces méretig, ez után viszont a pontosság kis mértékű csökkenése következik be.*

3.3. Teljesítménysűrűség-spektrum kinyert jellemzőként való használatának vizsgálata

Önmagában a mérési adatok használata a gépi tanulóalgoritmus bemeneteként jellemzően nem képes maximalizálni annak teljesítményét, szükséges lehet különböző jellemzők (leírók) kinyerése, illetve kiszámítása a nyers mérési adatokból. Kutatásomban arra kerestem a választ, hogy MLP hálózat esetén milyen mértékben tud hozzájárulni a felismerési pontosság növeléséhez, ha a mérési adatok mellett kinyert

jellemzőket is használok a tanulóalgoritmus bemeneteként, illetve, ha csak és kizárólag a kinyert jellemzőket használok a mérési adatok nélkül.

Az EEG-n az idegi oszcillációk a frekvenciatartományban figyelhetők meg, amelyeket általában Fourier-transzformáción alapuló spektrális módszerekkel nyernek ki. Ilyen megközelítést használtam a [C1], [J2] és [J3] cikkeimben. A Fourier-transzformáción alapszik a teljesítménysűrűség-spektrum (PSD) is, amely a spektrális teljesítménysűrűséget adja meg, azaz a jel különböző frekvenciájú összetevői által hordozott teljesítményt.

A ritmikus agyi aktivitás frekvencia szerint sávokra bontható. Ezek megkülönböztethetők alfa, béta, gamma, delta és théta hullámokként. Ezen elnevezésekkel jelölt frekvenciatartományok nem egzakt módon definiáltak, különböző szerzők kismértékben eltérő értékeket használtak [32-34]. Az általam használt frekvenciasávok a [C1] és [J2] cikkekben a következők voltak:

- alfa: 8-14 Hz
- béta: 14-30 Hz
- gamma: 30-80 Hz
- delta: 1-4 Hz
- théta: 4-8 Hz.

A jel abszolút teljesítménye az egyes hullámsávokban ezen tartományhatárok felhasználásával került kiszámításra. Az osztályozási pontosságra gyakorolt hatás vizsgálatához MLP neurális hálózat tanítását végeztem el a kapott adatokkal. A hálózat – az eredmények összehasonlíthatósága érdekében – azonos volt az ideális ablakméret meghatározásánál alkalmazottal.

3. tézis: *Megmutattam, hogy EEG adatok használata esetén jelentős pontosságnövekedés érhető el, ha a nyers adatok mellett vagy helyett a hullámsávokban mért teljesítményt, mint kinyert jellemzőt használjuk fel MLP tanulóalgoritmus bemeneteként. Az EEG jel abszolút teljesítményét kiszámítva az alfa, béta, gamma, delta és théta hullámsávokban, és ezeket használva bemenő adatként 91,5%-os, míg a nyers adatok közvetlen felhasználásával 56,2%-os felismerési pontosságot ért el ugyanaz a hálózat.*

3.4. CNN hálózatok hatékonyságvizsgálata saját gyűjtésű adatokon

A [C2] cikkemben leírtaknak megfelelően az 1. tézispontnál említett saját fejlesztésű adatgyűjtő szoftver segítségével húsz percnyi, tíz mérési körből származó adatot gyűjtöttem egy felhasználótól a nyolccsatornás OpenBCI Ultracortex Mark IV EEG headset használatával, három különböző tevékenység végzése közben. Az adatokban az alapvonal jelentős, folyamatos eltolódását tapasztaltam. Emellett az információt hordozó jel nagysága két nagyságrenddel kisebb volt, mint az alapvonalé. Ezt a két problémát úgy oldottam meg, hogy harmadfokú polinomot illesztettem az adatokra és levontam a függvényértéket a mérési pontok értékeiből. Szegmentálást és az adatkészlet kiegyensúlyozását követően egy 15 rétegű CNN hálózattal végeztem az adatok osztályozását.

4. tézis: *Megmutattam, hogy egy alacsony költségű, nem klinikai alkalmazásra szánt EEG headset által biztosított adatok minősége – megfelelő előfeldolgozást követően – jól használható tevékenységfelismerésre. Az általam alkalmazott CNN architektúrával 94,2%-os osztályozási pontosságot sikerült elérni három osztályra vonatkoztatva.*

3.5. CNN hatékonyságvizsgálata PhysioNet adatokon

A CNN hálózatok esetén, akár EEG-alapú tevékenységfelismerésről, akár más jellegű alkalmazásról van szó, felvetődik az architektúra megválasztásának kérdése. A [J1] kutatásomban több különböző hálózat hatékonyságvizsgálatát végeztem el, ideértve teljesen összekapcsolt rétegeket is tartalmazó (CNN2) és tisztán konvolúciós (CNN1, CNN3, CNN4), sekélyebb (CNN1, CNN3) és mélyebb (CNN4) hálózatokat.

Időközben sikerült beszerezni egy új 16 csatornás EEG eszközt, így a PhysioNet adatbázisból is ezeket a csatornákat használtam a későbbi összevethetőség érdekében. A neurális hálózat struktúrájának változtatásán túl kipróbáltam különböző szegmensméretek hatását is az osztályozási pontosságra, hasonlóan, mint a korábban említett MLP esetén. A különböző hálózatokkal, különböző ablakméretek alkalmazásával, 10 illetve 20 fő adataim kapott eredmények a 4. táblázatban kerültek összegzésre.

4. táblázat. PhysioNet adatokon elért pontosság 10/20 fő esetén

Hálózat	Ablakméret (mintaszám és időtartam)			
	32 (0,2 mp)	64 (0,4 mp)	128 (0,8 mp)	160 (1 mp)
CNN1	79,2% / 71,8%	91,1% / 83,3%	96,8% / 94,6%	99,1% / 97,7%
CNN2	62,5% / 58,4%	62,1% / 64%	76,4% / 74,4%	82,6% / 76,4%
CNN3	76,5% / 68,6%	87,8% / 80,2%	96,4% / 91,2%	97,7% / 93,6%
CNN4	76,2% / 70,4%	86,1% / 79,8%	96,9% / 92,9%	99% / 96,1%

A táblázat adataiból látható, hogy erős pozitív korreláció van a szegmensméret és a hálózat osztályozási hatékonysága között, azaz a szegmensméret növelésével jelentősen nőtt a gépi tanulási modell teljesítménye, bármelyik hálózatot is tekintjük. Ez szintén alátámasztja a 2. tézispontban leírtakat. Emellett megfigyelhető, hogy a *CNN4*, amely a *CNN1* mélyebb változata, valamelyest rosszabbul teljesített annál.

5. tézis: *A PhysioNet EEG adatbázis adatainak felhasználásával, méréseim során megmutattam, hogy optimális szegmensméret és architektúra megválasztással a neurális háló felismerési aránya egyértelműen növelhető. A legjobb eredmények a tesztadatokon mérve 99,1% és 97,7%-ra adódtak 10, illetve 20 fő adatainak felhasználásával három tevékenységet magában foglaló osztályozás esetén. Megállapítottam továbbá, hogy egy hálózat indokolatlan mélyítése nemcsak, hogy nem növeli tovább, hanem akár csökkentheti is az osztályozási*

pontosságot – amellet, hogy a tanítási időigénye is nagyobb.

3.6. Neurális hálózat FPGA implementációja

A [J1], [J4] és [C5] cikkekben leírtak alapján MLP és CNN neurális hálózatok hardveres gyorsítási lehetőségeit vizsgáltam meg, MLP esetén egy tisztán hardveres, míg CNN esetén egy DPU-s implementációt alkalmaztam.

Egy betanított MLP hálózat definiálásához a hálózat struktúráján túl a neuronoknál alkalmazott súlyok és eltolási értékek ismerete szükséges. A legtöbb gépi tanulási keretrendszer képes arra, hogy ezeket valamilyen formában exportálja. Az exportált adatok alapján az MLP hardveres implementációja elkészíthető. Míg szoftveres megvalósítás esetén a lebegőpontos számábrázolás használata semmilyen problémát nem okoz a processzor lebegőpontos egységének köszönhetően, addig egy FPGA-s implementáció esetén ilyen számokkal műveleteket végezni igen nehézkes, célszerűbb fixpontos számokkal dolgozni. A hivatkozott publikációkban vizsgáltam a fixpontos számábrázolás osztályozási pontosságra gyakorolt hatását is. Természetesen némi csökkenés bekövetkezett, azonban ez nem volt jelentős.

Az aktivációs függvény megvalósítása tényleges számítások elvégzése helyett történhet LUT-ként (*lookup table*), ahol a memóriacím a függvény független változójának értéke, és a cím által kijelölt cella tartalmazza a függvényértéket. A LUT méretének kordában tartása érdekében megoldható (paraméterként megadható), hogy

a neuron által számított súlyozott összeg bitjeinek csak egy részét, például a legnagyobb helyiértékű 12 bitet használjuk fel a memória címzésére. A LUT tároláshoz dual-port ROM-ot használtam, így két neuron olvashatja egyidőben ugyanazt a memóriát, felére csökkentve ezzel ezt a fajta az erőforrásigényt.

6. tézis: *Kifejlesztettem egy szoftvert, amely képes szintetizálható Verilog kódot generálni MLP hálózat FPGA-s implementációjához. A szoftver a neurális hálózat tanítását végző keretrendszerből exportált súlyok és eltolási értékek alapján – az architektúra definiálását követően – elvégzi a lebegőpontos-fixpontos konverziókat, legenerálja a szorzókat, összeadókat, aktivációs függvényeket és ezek összekapcsolódását megvalósító Verilog kódokat, melyek tetszőleges FPGA fejlesztői környezetben importálhatók és szintetizálhatók. Mindez teljesen automatizált módon történik, így kapcsolódó szakértelem nélkül is egyszerűen elkészíthető egy hardveres implementáció. A módszer helyességét szimulációs eljárással igazoltam.*

Irodalomjegyzék

- [1] D. Hari Krishna, I.A. Pasha, T. Satya Savithri (2016). Classification of EEG Motor Imagery Multi Class Signals Based on Cross Correlation. *Procedia Computer Science*, vol. 85, pp. 490-495. doi: 10.1016/j.procs.2016.05.198.
- [2] Chen Z, Wang Y, Song Z. Classification of Motor Imagery Electroencephalography Signals Based on Image Processing Method. *Sensors (Basel)*. 2021;21(14):4646. Published 2021 Jul 7. doi:10.3390/s21144646
- [3] Wu, Y.-T., Huang, T. H., Yi Lin, C., Tsai, S. J., & Wang, P.-S. (2018). Classification of EEG Motor Imagery Using Support Vector Machine and Convolutional Neural Network. 2018 International Automatic Control Conference (CACs). doi:10.1109/cacs.2018.8606765
- [4] León J, Escobar JJ, Ortiz A, et al. Deep learning for EEG-based Motor Imagery classification: Accuracy-cost trade-off. *PLoS One*. 2020;15(6):e0234178. Published 2020 Jun 11. doi:10.1371/journal.pone.0234178
- [5] Wang Z, Zhang Z, Gong X, Sun Y and Wang H (2018). Short time Fourier transformation and deep neural networks for motor imagery brain computer interface recognition. *Concurrency and Computation: Practice and Experience*, vol. 30. doi: 10.1002/cpe.4413

- [6] Behri, M., Subasi, A., & Qaisar, S. M. (2018). Comparison of machine learning methods for two class motor imagery tasks using EEG in brain-computer interface. 2018 Advances in Science and Engineering Technology International Conferences (ASET). doi:10.1109/icaset.2018.8376886
- [7] Jia, Hongru & Wang, Shuai & Zheng, Dezhi & Qu, Xiaolei & Fan, Shangchun. (2019). Comparative study of motor imagery classification based on BP-NN and SVM. *The Journal of Engineering*. 2019. 10.1049/joe.2018.9075.
- [8] Alexander Craik, Yongtian He, Jose L Contreras-Vidal (2019). Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of Neural Engineering*, vol. 16, no 3. doi: 10.1088/1741-2552/ab0ab5
- [9] Amjed S. Al-Fahoum, Ausilah A. Al-Fraihat, "Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains", *International Scholarly Research Notices*, vol. 2014, Article ID 730218, 7 pages, 2014. doi: 10.1155/2014/730218
- [10] Swati Aggarwal, Nupur Chugh (2019). Signal processing techniques for motor imagery brain computer interface: A review. *Array*, vol 1-2, 100003. doi: 10.1016/j.array.2019.100003.
- [11] Resalat SN, Saba V. A Study of Various Feature Extraction Methods on a Motor Imagery Based Brain Computer Interface System. *Basic Clin Neurosci*. 2016;7(1):13-19.

- [12] Amjed S. Al-Fahoum, Ausilah A. Al-Fraihat, "Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains", *International Scholarly Research Notices*, vol. 2014, Article ID 730218, 7 pages, 2014 doi: 10.1155/2014/730218
- [13] Schalk, G., McFarland, D.J., Hinterberger, T., Birbaumer, N., Wolpaw, J.R. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE Transactions on Biomedical Engineering* 51(6):1034-1043, 2004.
- [14] Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation* [Online]. 101 (23), pp. e215–e220.
- [15] Luciw, M., Jarocka, E. & Edin, B. Multi-channel EEG recordings during 3,936 grasp and lift trials with varying weight and friction. *Sci Data* 1, 140047 (2014). doi: 10.1038/sdata.2014.47
- [16] Kaya, Murat; Binli, Mustafa Kemal; Ozbay, Erkan; Yanar, Hilmi; Mishchenko, Yuriy (2018): A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces. figshare. Collection. <https://doi.org/10.6084/m9.figshare.c.3917698.v1>
- [17] Benjamin Blankertz, Guido Dornhege, Matthias Krauledat, Klaus-Robert Müller, and Gabriel Curio. The non-invasive Berlin Brain-Computer Interface:

Fast acquisition of effective performance in untrained subjects. *NeuroImage*, 37(2):539-550, 2007.

- [18] Tangermann, Michael & Müller, Klaus-Robert & Aertsen, Ad & Birbaumer, Niels & Braun, Christoph & Brunner, Clemens & Leeb, Robert & Mehring, Carsten & Miller, Kai & Müller-Putz, Gernot & Nolte, Guido & Pfurtscheller, Gert & Preissl, Hubert & Schalk, Gerwin & Schlögl, Alois & Vidaurre, Carmen & Waldert, Stephan & Blankertz, Benjamin. (2012). Review of the BCI competition IV. *Frontiers in neuroscience*. 6. 55. 10.3389/fnins.2012.00055.
- [19] Schirrmester, R.T., Springenberg, J.T., Fiederer, L.D.J., Glasstetter, M., Eggensperger, K., Tangermann, M., Hutter, F., Burgard, W. and Ball, T. (2017), Deep learning with convolutional neural networks for EEG decoding and visualization. *Hum. Brain Mapp.*, 38: 5391-5420. <https://doi.org/10.1002/hbm.23730>
- [20] Kemp B, Olivan J. European data format 'plus' (EDF+), an EDF alike standard format for the exchange of physiological data. *Clin Neurophysiol.* 2003 Sep;114(9):1755-61. doi: 10.1016/s1388-2457(03)00123-8. PMID: 12948806.
- [21] Youngjoo Kim, Jiwoo Ryu, Ko Keun Kim, Clive C. Took, Danilo P. Mandic, Cheolsoo Park, "Motor Imagery Classification Using Mu and Beta Rhythms of EEG with Strong Uncorrelating Transform Based Complex Common Spatial Patterns", *Computational Intelligence and Neuroscience*, vol. 2016, Article ID 1489692, 13 pages, 2016. <https://doi.org/10.1155/2016/1489692>

- [22] Dose, H., Moller, J. S., Puthusserypady, S., & Iversen, H. K. (2018). A Deep Learning MI - EEG Classification Model for BCIs. 2018 26th European Signal Processing Conference (EUSIPCO). doi: 10.23919/eusipco.2018.8553332
- [23] Zhang, D., Chen, K., Jian, D., & Yao, L. (2020). Motor Imagery Classification via Temporal Attention Cues of Graph Embedded EEG Signals. *IEEE Journal of Biomedical and Health Informatics*, 1–1. doi:10.1109/jbhi.2020.2967128
- [24] Fadel, W., Kollod, C., Wahdow, M., Ibrahim, Y., & Ulbert, I. (2020). 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). doi:10.1109/bci48061.2020.9061622
- [25] Eitan Netzer, Alex Frid, Dan Feldman (2020). Real-time EEG classification via coresets for BCI applications. *Engineering Applications of Artificial Intelligence*, vol. 89. Article ID 103455. doi: 10.1016/j.engappai.2019.103455
- [26] Tokovarov, M. (2020). Convolutional Neural Networks with Reusable Full-Dimension-Long Layers for Feature Selection and Classification of Motor Imagery in EEG Signals. *Lecture Notes in Computer Science*, 79–91. doi:10.1007/978-3-030-61609-0_7
- [27] Audrey Aldridge, Eli Barnes, Cindy L. Bethel, Daniel W. Carruth, Marianna Kocturova, Matus Pleva, Jozef Juhar, “Accessible Electroencephalograms (EEGs): A Comparative Review with OpenBCI’s Ultracortex Mark IV Headset”, 29th International Conference

Radioelektronika (RADIOELEKTRONIKA),
Pardubice, Czech Republic, 2019, pp. 1-6, DOI:
10.1109/RADIOELEK.2019.8733482

- [28] Gaur, P., Gupta, H., Chowdhury, A., McCreadie, K., Pachori, R. B., & Wang, H. (2021). A Sliding Window Common Spatial Pattern for Enhancing Motor Imagery Classification in EEG-BCI. *IEEE Transactions on Instrumentation and Measurement*, 70, 1–9. doi:10.1109/tim.2021.3051996
- [29] Wang, Xiaying & Hersche, Michael & Tomekce, Batuhan & Kaya, Burak & Magno, Michele & Benini, Luca. (2020). An Accurate EEGNet-based Motor-Imagery Brain–Computer Interface for Low-Power Edge Computing. 1-6. doi: 10.1109/MeMeA49120.2020.9137134.
- [30] Blanco-Mora, D. & Aldridge, A. & Jorge, Carolina & Vourvopoulos, Athanasios & Figueiredo, Patrícia & Bermúdez i Badia, Sergi. (2021). Finding the Optimal Time Window for Increased Classification Accuracy during Motor Imagery. 144-151. doi: 10.5220/0010316101440151.
- [31] Akbulut, Orhan. (2020). Feature Normalization Effect in Emotion Classification based on EEG Signals. 24. 60-66. 10.16984/saufenbilder.617642.
- [32] Renton, A.I., Mattingley, J.B. & Painter, D.R., “Optimising non-invasive brain-computer interface systems for free communication between naïve human participants”, *Scientific Reports* 9, 18705 (2019). DOI: 10.1038/s41598-019-55166-y

- [33] E. Gysels and P. Celka, “Phase synchronization for the recognition of mental tasks in a brain-computer interface”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 12, no. 4, pp. 406-415, Dec. 2004, DOI: 10.1109/TNSRE.2004.838443
- [34] S. V. Bozhokin and I. B. Suslova, “Wavelet-based analysis of spectral rearrangements of EEG patterns and of non-stationary correlations”, *Physica A: Statistical Mechanics and its Applications*, vol. 21, pp. 151-160, 2015. DOI: 10.1016/j.physa.2014.11.026

A dolgozat alapjául szolgáló publikációk

- [J1] Majoros, T.; Oniga, S. Overview of the EEG-Based Classification of Motor Imagery Activities Using Machine Learning Methods and Inference Acceleration with FPGA-Based Cards. *Electronics* 2022, 11, 2293. DOI: 10.3390/electronics11152293
- [J2] Tamás Majoros, Stefan Oniga, Yu Xie, Motor imagery EEG classification using feedforward neural network, *Annales Mathematicae et Informaticae* vol 53 (2021), pp. 235-244, ISSN 1787 - 6117, DOI: 10.33039/ami.2021.04.007
- [J3] Tamás Majoros, Balázs Ujvári, Stefan Oniga, EEG data processing with neural network, *Carpathian Journal of Electronic and Computer Engineering* vol 12 number 2/2019, pp. 33-36, ISSN 1844 – 9689, DOI: 10.2478/cjece-2019-0014
- [J4] Tamás Majoros, Balázs Ujvári, Stability study of the neural network at particle physics detectors, *Carpathian Journal of Electronic and Computer Engineering* vol 11 number 1/2018, pp. 48-52, ISSN 1844 – 9689, DOI: 10.2478/cjece-2018-0009
- [C1] T. Majoros and S. Oniga, "Comparison of Motor Imagery EEG Classification using Feedforward and Convolutional Neural Network," *IEEE EUROCON 2021 - 19th International Conference on Smart Technologies*, 2021, pp. 25-29, doi: 10.1109/EUROCON52738.2021.9535592.

- [C2] T. Majoros and S. Oniga, "Activity recognition using consumer-grade EEG device," 2021 13th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), 2021, pp. 1-6, doi: 10.1109/ECAI52376.2021.9515106.
- [C3] Majoros Tamás, Oniga István László, Elképzelt motoros tevékenységek EEG-alapú osztályozása neurális hálózatok használatával, XXIII. NEMZETKÖZI SZÁMÍTÁSTECHNIKA ÉS OKTATÁS KONFERENCIA, SzámOkt 2022, Marosvásárhely, október 13-16, 2022, pp. 162-167, ISSN 2734-6757
- [C4] Majoros Tamás, Ujvári Balázs, Oniga István László, EEG adatok feldolgozása neurális hálózattal, XXIX. NEMZETKÖZI SZÁMÍTÁSTECHNIKA ÉS OKTATÁS KONFERENCIA, SzámOkt 2019, Temesvár, október 10-13, 2019, pp. 208-213, ISSN 1842 - 4546
- [C5] Majoros Tamás, Ujvári Balázs, Oniga István László, Részecskefizikai detektorban alkalmazott neurális hálózat stabilitási vizsgálata, XXVIII. NEMZETKÖZI SZÁMÍTÁSTECHNIKA ÉS OKTATÁS KONFERENCIA, SzámOkt 2018, Tusnádfürdő, október 11-14, 2018, pp. 262-267, ISSN 1842 - 4546



Nyilvántartási szám: DEENK/57/2023.PL
Tárgy: PhD Publikációs Lista

Jelölt: Majoros Tamás
Doktori Iskola: Informatikai Tudományok Doktori Iskola
MTMT azonosító: 10066820

A PhD értekezés alapjául szolgáló közlemények

Idegen nyelvű tudományos közlemények hazai folyóiratban (1)

1. **Majoros, T.**, Oniga, I. L., Xie, Y.: Motor imagery EEG classification using feedforward neural network.
Ann. Math. Inform. 53, 235-244, 2021. ISSN: 1787-5021.
DOI: <http://dx.doi.org/10.33039/ami.2021.04.007>

Idegen nyelvű tudományos közlemények külföldi folyóiratban (3)

2. **Majoros, T.**, Oniga, I. L.: Overview of the EEG-Based Classification of Motor Imagery Activities Using Machine Learning Methods and Inference Acceleration with FPGA-Based Cards.
Electronics (Switzerland). 11 (15), 1-14, 2022. EISSN: 2079-9292.
DOI: <http://dx.doi.org/10.3390/electronics11152293>
IF: 2.69 (2021)
3. **Majoros, T.**, Ujvári, B., Oniga, I. L.: EEG data processing with neural network.
Carpath. J. Electron. Comput. Eng. 12 (2), 33-36, 2019. ISSN: 1844-9689.
DOI: <http://dx.doi.org/10.2478/cjece-2019-0014>
4. **Majoros, T.**, Ujvári, B.: Stability study of the neural network at particle physics detectors.
Carpath. J. Electron. Comput. Eng. 11 (1), 48-52, 2018. ISSN: 1844-9689.
DOI: <http://dx.doi.org/10.2478/cjece-2018-0009>

Magyar nyelvű konferencia közlemények (3)

5. **Majoros, T.**, Oniga, I. L.: Elképzelt motoros tevékenységek EEG-alapú osztályozása neurális hálózatok használatával.
In: XXIII. Energetika-Elektrotechnika - ENELKO és XXXII. Számítástechnika és Oktatás SzámOkt Multi-konferencia. Szerk.: Sebestyén-Pál György, Szabó Loránd, Erdélyi Magyar Műszaki Tudományos Társaság, Kolozsvár, 162-167, 2022, (ISSN 2734-6757).
6. **Majoros, T.**, Ujvári, B., Oniga, I. L.: EEG adatok feldolgozása neurális hálózatokkal.
In: ENELKO 2019, SzámOkt 2019, Erdélyi Magyar Műszaki Tudományos Társaság, Temesvár, 208-213, 2019, (ISSN 1842-4546 ; 29.)





7. **Majoros, T.**, Ujvári, B., Oniga, I. L.: Részecskefizikai detektorban alkalmazott neurális hálózat stabilitási vizsgálata.
In: ENELKO 2018 XIX. Nemzetközi Energetika-Elektrotechnika Konferencia, SzámOkt 2018 XXVIII. Nemzetközi Számítástechnika és Oktatás Konferencia. Szerk.: Bíró Károly-Ágoston, Sebestyén-Pál György, Szabó Loránd, Erdélyi Magyar Műszaki Tudományos Társaság, Tusnádfürdő, 262-267, 2018, (ISSN 1842-4546)

Idegen nyelvű konferencia közlemények (2)

8. **Majoros, T.**, Oniga, I. L.: Activity recognition using consumer-grade EEG device.
In: 13th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), IEEE, Pitesti, 1-6, 2021. ISBN: 9781665425346
9. **Majoros, T.**, Oniga, I. L.: Comparison of Motor Imagery EEG Classification using Feedforward and Convolutional Neural Network.
In: IEEE EUROCON 2021 - 19th International Conference on Smart Technologies. Ed.: Mariya Antyufeyeva, IEEE, Lviv, 25-29, 2021. ISBN: 9781665432993

További közlemények

Idegen nyelvű, külföldi könyvrészletek (1)

10. Kovács, L., Baranyai, D., Girászi, T., **Majoros, T.**, Kovács, Á., Vágner, M., Palkovics, D., Bérczes, T.: Sensor design and integration into small sized autonomous vehicle.
In: 2022 IEEE 2nd Conference on Information Technology and Data Science (CITDS). Ed.: Fazekas István, IEEE, Piscataway, 171-176, 2022. ISBN: 9781665496537

Idegen nyelvű tudományos közlemények külföldi folyóiratban (3)

11. Xie, Y., **Majoros, T.**, Oniga, I. L.: FPGA-Based Hardware Accelerator on Portable Equipment for EEG Signal Patterns Recognition.
Electronics (Switzerland). 11 (15), 1-15, 2022. EISSN: 2079-9292.
DOI: <http://dx.doi.org/10.3390/electronics11152410>
IF: 2.69 (2021)
12. Bíró, B., David, G., Fenyvesi, A., Haggerty, J. S., Kierstead, J., Mannel, E. J., **Majoros, T.**, Molnár, J., Nagy, F., Stoll, S., Ujvári, B., Woody, C. L.: A Comparison of the Effects of Neutron and Gamma Radiation in Silicon Photomultipliers.
IEEE Trans. Nucl. Sci. 66 (7), 1833-1839, 2019. ISSN: 0018-9499.
DOI: <http://dx.doi.org/10.1109/TNS.2019.2921102>
IF: 1.575





13. Aidala, C. A., Bailey, V., Beckman, S., Belmont, R., Biggs, C., Blackburn, J., Boose, S., Chiu, M., Connors, M., Desmond, E., Franz, A., Haggerty, J. S., He, X., Higdon, M. M., Huang, J., Kauder, K., Kistenev, E., LaBounty, J., Lajoie, J. G., Lenz, M., Lenz, W., Li, S., Loggins, V. R., Mannel, E. J., **Majoros, T.**, McCumber, M. P., Nagle, J. L., Phipps, M., Pinkenburg, C., Polizzo, S., Pontieri, C., Purschke, M. L., Putschke, J., Sarsour, M., Rinn, T., Ruggiero, R., Sen, A., Sickles, A. M., Skoby, M. J., Smiga, J., Sobel, P., Stankus, P. W., Stoll, S., Sukhanov, A., Thorsland, E., Toldo, F., Towell, R. S., Ujvári, B., Vazquez-Carson, S., Woody, C. L.: Design and Beam Test Results for the sPHENIX Electromagnetic and Hadronic Calorimeter Prototypes.

IEEE Trans. Nucl. Sci. 65 (12), 2901-2919, 2018. ISSN: 0018-9499.

DOI: <http://dx.doi.org/10.1109/TNS.2018.2879047>

IF: 1.428

Idegen nyelvű konferencia közlemények (2)

14. Xie, Y., Oniga, I. L., **Majoros, T.**: Comparison of EEG Data Processing Using Feedforward and Convolutional Neural Network.
In: Proceedings of 1st Conference on Information Technology and Data Science (CITDS 2020) / editors István Fazekas, András Hajdu, Tibor Tómacs, CEUR, Debrecen, 279-289, 2021, (CEUR Workshop Proceedings, ISSN 1613-0073 ; 2874.)
15. Yu, X., **Majoros, T.**, Oniga, I. L.: Hardware Implementation of CNN Based on FPGA for EEG Signal Patterns Recognition.
In: International Conference on e-Health and Bioengineering (EHB). Ed.: Grigore T. Popa, IEEE, Iasi, 1-4, 2021. ISBN: 9781665440004

A közlő folyóiratok összesített impakt faktora: 8,383

A közlő folyóiratok összesített impakt faktora (az értekezés alapjául szolgáló közleményekre): 2,69

A DEENK a Jelölt által az IDEa Tudóstérbe feltöltött adatok bibliográfiai és tudásmetriai ellenőrzését a tudományos adatbázisok és a Journal Citation Reports Impact Factor lista alapján elvégezte.

Debrecen, 2023.02.28.



**Short thesis for the degree of doctor of philosophy
(PhD)**

**Human activity recognition from
EEG sensor data using machine
learning**

Majoros Tamás

Supervisor: Dr. Oniga István



UNIVERSITY OF DEBRECEN
Doctoral School of Informatics

Debrecen, 2023.

Tartalomjegyzék

1.	Research objectives	1
2.	Background and aims of the dissertation	3
3.	New results	12
3.1.	Development of EEG data acquisition software and processing of measurement data	12
3.2.	Determination of optimal segment size	13
3.3.	Investigation of the effect of power spectral density as an extracted feature.....	15
3.4.	Efficiency investigation of CNN networks on self-collected data.....	17
3.5.	Efficiency investigation of CNN networks on PhysioNet dataset	18
3.6.	FPGA implementation of neural networks ..	19
	Bibliography	22
	Related publications	29

1. Research objectives

One of the main research questions of this thesis is whether the previous results of human activity recognition from EEG recordings can be improved in some way by using machine learning methods. This research area is currently very popular and diversified, with a significant number of new publications appearing every year.

I carried out an extensive literature review and found that there are a number of problems and issues that need to be addressed in the application of automatic evaluation (classification). One of these is the form in which the raw data from the measurement should be used in the machine learning model, after what possible preprocessing. Another question is whether it is necessary to extract features from the data and, if so, what type of features should be extracted. Then we need to choose one of the many machine learning methods that is suitable for the task. Finally, we need to fine-tune the parameters of the method used, evaluate its performance and, in the light of this, make further refinements, if necessary, either in terms of the features extracted, the method chosen or the parameters of the method. The range of techniques that can be applied is very wide, so I investigated the further possibilities of the techniques that appear most promising from the results of previous research, looking for the answer to the question of whether I can achieve better

accuracy than before by choosing an appropriate machine learning algorithm and feature extraction method. In most cases I used a publicly available EEG dataset.

Another main research question of this thesis is to investigate the applicability of a low cost, consumer grade device in EEG-based activity recognition. If these devices provide data of sufficiently high quality, their affordability may allow them to be used in the future to assist, for example, disabled or elderly people in their homes. There are several such devices on the market today, and the Ultracortex Mark IV EEG helmet has been chosen because of its specifications and its proven usability in previous research papers. I felt it necessary to create a data acquisition software that would allow me to record the kind of data that could be found in the publicly available EEG database that I used. In this way, I had the opportunity to compare the performance of a machine learning method on data from a professional device with that provided by a cheaper headset.

The third research goal was to investigate the hardware implementation possibilities of neural networks. For this purpose, I intended to develop a software that can automatically generate a field-programmable gate array (FPGA) implementation, so that the user can benefit from such a solution even without hardware design knowledge. I also wanted to explore other hardware acceleration options.

2. Background and aims of the dissertation

The basic idea of recognizing activity from EEG signals is that while performing activities, the brain generates patterns that are unique to that specific activity. The different activities can be distinguished from each other in the EEG based on those patterns. A number of machine learning methods can be used for this purpose, including shallow and deep learning techniques. One such shallow machine learning method is to use a support vector machine (SVM) to classify linearly separable groups in such a way as to determine the separating hyperplane with the largest margin.

In the case of classification with the k -nearest neighbors (kNN) method, the nearest neighbor k of the test vector determined by some metric (e.g., Euclidean distance) is taken from the training set, and the most common occurrence of the associated class labels is assigned to the test data.

For a decision tree (DT), nonterminal nodes contain a test condition. Starting from the root node, we test whether the individual conditions for the test case are true, thus traversing the tree until we finally reach a terminal node with a class label. The random forest (RF) method is an extension of decision trees in such a way that it creates several different, independent decision trees during learning, each of them makes a decision, and the most common class of these is assigned to the test case. The basic idea in this case (and in similar collaborative

learning methods) is that weak classifiers, organized into a group, can collectively become a strong, efficient learning algorithm.

The naive Bayes (NB) classifier estimates the conditional probabilities for a class, assuming that the attributes for a given class are conditionally independent of each other, and then gives the most probable class using the resulting conditional probabilities when classifying.

There are several types of artificial neural networks (ANNs); one of the simplest but most commonly used is the multilayer perceptron (MLP), which is a feedforward neural network. It consists of at least three layers (input, output, and one or more hidden layers), with layers containing neurons, along with an activation function. Successive layers are fully connected; i.e., all neurons in any layer are connected to all neurons in the next layer.

With the advent of deep learning methods, they have become increasingly common for a wide variety of machine learning problems. The mentioned MLP network can already be classified as a deep learning method by using several hidden layers, but with some additions, more complex networks can be created. The recurrent neural network (RNN), for example, unlike MLP, includes not only feedforward but also feedback, which actually supplies the network with memory. In the case of a convolutional neural network (CNN), new types of layers are added to the traditional network containing only neurons. These new layers are able to automate the typically manual feature extraction for shallow methods, thus providing a more general solution. A combination of the former two solutions, i.e., feedback and the addition of

convolutional layers, is also possible, in which case we speak of a recurrent convolutional neural network (RCNN).

Many researchers have examined the applicability of the aforementioned (and other) machine learning methods in EEG-based activity recognition, however, the results obtained do not support the existence of an algorithm that is clearly more efficient than the others. For example, the authors of [1] used five shallow algorithms to detect imagery motor activity in nine volunteers. Naive Bayes was found to be most effective in four subjects, DT in two, kNN in two, and SVM in one. The authors of [2] found CNN to be more accurate than SVM for all nine subjects in a database similar to the previous one. In contrast, for five of the nine subjects in the [3] study, SVM performed better than CNN.

The authors of [4] used MLP, CNN, and RNN networks to recognize motor imagery activities. Based on their results, CNN performed the best of the three, and showed that the same model with more layers is not necessarily better than a shallower one, i.e., network complexity does not correlate with recognition accuracy. In addition, it was pointed out that the performance of CNN networks is greatly influenced by the choice of hyperparameters (e.g., kernel size and kernel number). In [5], the authors also examined some CNN and RNN algorithms and found that their particular seven-layer CNN significantly outperforms a three-layer RNN architecture.

In the [6] study, the researchers used an EEG database from five volunteers to try to classify the imagery

movements of the right hand and right foot. For this, DT, MLP, SVM, kNN, NB, and RF algorithms were used after noise reduction, feature extraction, and dimension reduction. In terms of the classification accuracy achieved, the 53% result of NB proved to be the worst. The DT (64%), MLP (67%), RF (78%), and SVM (89%) methods performed significantly better, but the best result, almost 95% accuracy in the average of the five volunteers, was provided by the kNN algorithm. It should be noted, however, that there was a subject for whose data the DT and RF algorithms outperformed this result, with 95% and 98% classification accuracy, respectively.

The authors of [7] also used SVM and MLP algorithms to recognize motor imagery activities, but in contrast to [6], they found MLP to be more efficient: accuracy was 75% for SVM and 80% for MLP.

The studies cited above show that it is far from clear which machine learning method can be the most effective in recognizing activity based on EEG signals. In some cases shallow, and in other cases deep learning algorithms proved to be more accurate in classification. Even if these researches had not shown sometimes contradictory results, it still would not have been possible to establish an order between the individual algorithms, as they had different architectures and were applied differently to preprocessed data and different databases, so it would not be possible to make a general conclusion. In addition, however, there is a tendency for the convolutional neural network to become the most common algorithm in this research topic in recent years [8].

EEG signals are complex and contain a large amount of information. Based on the mentioned studies, it seems that the selection of the appropriate algorithm and architecture plays a big role in the efficiency of a network, however, the preprocessing of the data and the feature extraction can influence the final result at least as much. The purpose of feature extraction is to transform the data into a lower dimensional space so that it retains the critical information transmitted by the EEG signals [9]. A number of feature extraction methods have been proposed in the literature based on the specific task, including time domain, frequency domain, time-frequency domain and spatial domain [10].

The study [8] provides a comprehensive overview of different articles examining deep learning on EEG. Based on this, when CNN was used, in more than 55% of the articles, researchers used the recorded signals directly, in 30% of the cases they were converted to images, and only about 15% used extracted features as input for the network. It is also worth mentioning that in the latter cases, the average accuracy achieved by researchers was 84%, while in the direct use of signals it was 87%, which refutes the assumption that the more effort we put into better preprocessing of data, the more accurate the classification will be. Moreover, it points straight to the surprising conclusion that by entrusting this task to the neural network, a better final result can be achieved. These observations are consistent with the fact that convolutional layers are capable of automatic feature extraction and show that the use of additional static methods is not justified for CNNs. Also based on this article, when using MLP, with one exception (where the value of the recorded

signals was used directly), the classification was done using extracted features in all cases.

The features extracted from the time domain include various statistical measures such as the mean, the standard deviation, the mean absolute deviation, the root mean square, the kurtosis, or the difference between the minimum and maximum. Among the frequency domain features, we can mention, for example, the spectral energy (the sum of the squares of the absolute values of the frequency components), the spectral entropy, the spectral mean (the expected value of the spectrum when considered as a probability distribution), or the fundamental frequency, which is the frequency of the component with the largest amplitude in the signal.

Although there is a growing number of papers on the subject, it remains an open question as to what features can be extracted to maximize the accuracy of machine learning. In the study [11], the researchers extracted about a dozen different time and frequency domain features from EEG data, which were used for classification using linear discriminant analysis (LDA). Among them, the authors found a frequency domain feature, power spectral density (PSD), to be the most effective.

The previous research did not consider time-frequency domain features, despite the fact that the frequency domain description alone does not say anything about the variations of the signal over time, and thus contains less information than the time-frequency domain description. Using a short-time Fourier transform (STFT) or wavelet transform (WT), changes in the frequency spectrum can be determined together with their time of

occurrence, which, when used as an extracted feature, raises the possibility of further increasing the accuracy of the classification algorithm. The authors of [12] applied five different mathematical methods for frequency and time-frequency domain feature extraction. These were fast Fourier transform (FFT), wavelet transform, eigenvectors, time-frequency distribution, and autoregressive methods. Their results showed that each method has advantages and disadvantages over the others, so that the use of time-frequency domain features is not necessarily preferable to the use of frequency domain features.

In parallel with the increasing prevalence of machine learning methods in the processing of EEG signals, publicly available datasets containing EEG measurements have appeared one after another. Some of those that collect data recorded during real and/or imagery motor activities are listed in Table 1.

Table 1. Public databases containing EEG recordings of motor activities

Reference	Number of subjects	Type of activity
[13-14]	109	Hand and foot movement: real and imagery
[15]	12	Grasp and lift: real
[16]	13	Hand, foot, tongue, and finger movement: imagery
[17]	7	Hand and foot movement: imagery
[18] 2a	9	Hand, foot, tongue, and finger movement: imagery

[18] 2b	9	Hand movement: imagery
[19]	14	Hand and foot movement: real and imagery

Partly because of the obvious advantages of using an existing database, and partly to make my own research results comparable to those published in other papers, I worked on such a dataset, specifically the PhysioNet database of 109 volunteers cited in the first row of Table 1. In addition, in some cases, I used data recorded with our own EEG device and my own measurement system, and the programs performing the measurement and evaluation were developed specifically for this research.

The PhysioNet database contains more than 1500 one- and two-minute EEG recordings from 109 volunteers. Measurements were performed with the BCI2000 system on 64 channels while the volunteers performed various real and imagery motor activities. For each subject, 14 measurements were performed, of which the volunteers did not perform any actual activity during two one-minute measurements, their EEG signals were just recorded while sitting with their eyes open and closed. During the other 12 two-minute measurements, subjects performed four different tasks, each repeated three times. Of the latter, I used those where an object appears at the top or bottom of the screen and, accordingly, the volunteer closes either both fists or both feet until the object disappears and then relaxes. This can happen either as real or imagery movement.

The target was displayed on the screen for four seconds, and the pause (relaxation time) between displays was also four seconds. Data were recorded at a sampling

frequency of 160 Hz in EDF+ format, which is a widely accepted standard for storing EEG data. Its advantage over EDF is that it supports the use of standard electrode names and time-stamped annotations to store events [20], which in this case represent a change of activity.

Table 2 shows some of the results obtained by other researchers on the PhysioNet database. It should be noted, however, that even if the same database is used, the classification accuracies achieved are not always comparable. Firstly, it matters how many volunteers' data were actually used out of 109, and secondly, how many classes are distinguished. For any measurement file – except the open/closed eye files –, there are basically three types of activity data available (i.e., left hand movement, right hand movement, relaxation), but it can be reduced to two classes if, for example, relaxation is not considered, meaning that only the actual activities are taken into account. On the other hand, the number of classes can be increased by merging different types of measurement files.

Table 2. Previous results on the PhysioNet database

Reference	Best accuracy achieved
[21] (2 classes)	80,05%
[22] (2 classes)	80,1%
[22] (3 classes)	69,72%
[22] (4 classes)	59,71%
[23] (2 classes)	74,71%
[24] (5 classes)	70,64%
[25] (2 classes)	74,9%
[26] (2 classes)	83,26%

3. New results

3.1. Development of EEG data acquisition software and processing of measurement data

The first step in the process of EEG-based activity recognition is the acquisition of data. For this purpose, I used an Ultracortex Mark IV EEG headset from OpenBCI, which provides good performance and high accuracy for its price [27]. Using dry EEG sensors, this headset can record brain activity on 8 or 16 channels, from up to 35 different locations. For me, the eight-channel version was available. The sampling frequency is 250 Hz on all eight channels. The device is powered by a lithium-ion battery and communication with the data acquisition computer is via a wireless connection.

For data collection and measurement control, I developed a program as described in my paper [C2], with which I am able to carry out similar measurements as the creators of the PhysioNet database. The data from the device is transmitted to the data collection software via the LSL (Lab Streaming Layer) protocol. The software I created is able to receive, record and label the data stream from the OpenBCI device. The application randomly displays a target at the top or bottom of the screen for a given period of time, then the object disappears for a couple of seconds, and this is repeated several times, just like during PhysioNet measurements. Meanwhile, the incoming measurement data is recorded and labeled on all

eight channels, with the label indicating what task the volunteer was required to perform at that moment.

In the application, the measurement parameters can be set in a user-friendly, graphical interface. These measurement parameters specify how many seconds the object should be displayed, how many seconds not, and how many times this cycle should be repeated.

Thesis 1: *I have developed a software capable of collecting data from any OpenBCI EEG device. The software displays an object randomly on different parts of the screen while receiving data via LSL protocol, recording, and labeling the data stream from the EEG device. The correctness of the operation was verified by laboratory tests.*

3.2. Determination of optimal segment size

In activity recognition based on EEG signals, the measured data is typically available as a long, digitized data stream, during which the subject may perform several different activities. The training is based on the assumption that there is some pattern in the data that only appears for a given activity, and therefore at least when activity changes occur, it is necessary to split the data stream. Typically, however, for better performance, splitting the stream into smaller pieces is optimal. This kind of data stream fragmentation is called segmentation, and the individual segments are called windows.

The size of the windows typically covers an interval of a few seconds [28-30]. It is important to choose the appropriate window size because there is an optimal value

with which the performance of the model can be maximized for the given machine learning task. Based on these, I tried to find the ideal window size using the PhysioNet database as described in my papers [J2], [C1], and partially related to this in [J1] and [C5]. The data were segmented with different window sizes.

Since the initial values of the weights and offsets applied to the neurons are random values derived from a Gaussian distribution, slightly different classification accuracies can be obtained even in the case of multiple training with the same data. To reduce the chance of drawing a wrong conclusion about the optimal window size, I repeated the experiment five times with each size. Table 3 contains the classification accuracy of the neural network measured on the test data, and the standard deviation of the obtained values.

Table 3. Accuracy for different window sizes

Window size (number of samples and duration)	Accuracy on test data
40 (0,25 s)	78,64 ± 1,30%
60 (0,475 s)	86,90 ± 0,61%
80 (0,5 s)	91,52 ± 0,69%
100 (0,625 s)	93,76 ± 1,33%
120 (0,75 s)	95,89 ± 0,15%
140 (0,875 s)	97,57 ± 0,47%
160 (1 s)	98,62 ± 0,21%
180 (1,125 s)	98,34 ± 0,41%
200 (1,25 mp)	97,99 ± 0,33%

Considering the results and other aspects, I find the use of a one-second window to be optimal in this application.

Thesis 2: *I determined the optimal segment size to maximize the performance of the machine learning model for EEG-based activity recognition. I found that as the segment size increases, the classification accuracy also increases strictly monotonically up to a window size of one second, after which there is a small decrease in accuracy.*

3.3. Investigation of the effect of power spectral density as an extracted feature

Using the measurement data alone as input to the machine learning algorithm typically cannot maximize its performance, it may be necessary to extract and calculate different features from the raw measurement data. In my research, I looked for the answer to what extent it can contribute to increasing the recognition accuracy of an MLP network, if I use extracted features as input to the learning algorithm in addition to the measurement data, or if I only and exclusively use them without the measurement data.

On the EEG, neural oscillations can be observed in the frequency domain, which are usually extracted using spectral methods based on Fourier transform. I used such an approach in my papers [C1], [J2] and [J3]. The power spectral density (PSD) is also based on the Fourier transform, and gives the spectral power density, i.e. the power carried by the different frequency components of the signal.

Rhythmic brain activity can be decomposed into bands by frequency. These can be distinguished as alpha, beta, gamma, delta and theta waves. The frequency ranges denoted by these names are not defined in an exact way, different authors used slightly different values [32-34]. The frequency bands I used in articles [C1] and [J2] were as follows:

- alpha: 8-14 Hz
- beta: 14-30 Hz
- gamma: 30-80 Hz
- delta: 1-4 Hz
- theta: 4-8 Hz.

The absolute power of the signal in each waveband was calculated using these ranges. To investigate the effect on classification accuracy, I trained an MLP neural network with the obtained data. The network was identical to the one used to determine the optimal segment size, in order to make the results comparable.

Thesis 3: *I have shown that when using EEG data, a significant increase in accuracy can be achieved if, in addition to or instead of the raw data, the power measured in the wavebands is used as an extracted feature as input to the MLP learning algorithm. By calculating the absolute power of the EEG signal in the alpha, beta, gamma, delta and theta wavebands and using these as input data, the network achieved a recognition accuracy of 91.5%, while using the raw data directly, the recognition accuracy was 56.2%.*

3.4. Efficiency investigation of CNN networks on self-collected data

As described in my paper [C2], with the help of the data collection software developed by me and mentioned in thesis 1, I collected twenty minutes of data from ten measurement rounds from a user, while performing three different activities, using an eight-channel OpenBCI Ultracortex Mark IV EEG headset. I observed a significant, continuous drift of the baseline in the measurement data. In addition, the amplitude of the signal carrying the information was two orders of magnitude smaller than that of the baseline. I solved these two problems by fitting a third-degree polynomial to the data and subtracting the function value from the values of the measurement points. After segmentation, I used a CNN network with 15 layer to classify the data.

Thesis 4: *I have shown that the quality of the data provided by a low-cost, non-clinical EEG headset can - after appropriate pre-processing - be used for activity recognition. With the CNN architecture I used, I managed to achieve a classification accuracy of 94.2% for three classes.*

3.5. Efficiency investigation of CNN networks on PhysioNet dataset

In the case of CNN networks, whether it is EEG-based activity recognition or another type of application, the question of choosing the architecture arises. In my research paper [J1], I performed efficiency tests of several different networks, including networks with fully connected layers (*CNN2*) and purely convolutional (*CNN1*, *CNN3*, *CNN4*), shallower (*CNN1*, *CNN3*) and deeper (*CNN4*) networks.

In the meantime, I obtained a new 16-channel EEG device, so I used these channels from the PhysioNet database for later comparability. In addition to changing the structure of the neural network, I also examined the effect of different segment sizes on the classification accuracy, similarly as in the case of the previously mentioned MLP. The results obtained on the data of 10 and 20 volunteers using different networks with different windows sizes are summarized in Table 4.

Table 4. Accuracy on PhysioNet data for 10/20 subjects

Network	Segment size (number of samples and duration)			
	32 (0.2 s)	64 (0.4 s)	128 (0.8 s)	160 (1 s)
CNN1	79.2% / 71.8%	91.1% / 83.3%	96.8% / 94.6%	99.1% / 97.7%
CNN2	62.5% / 58.4%	62.1% / 64%	76.4% / 74.4%	82.6% / 76.4%

CNN3	76.5% / 68.6%	87.8% / 80.2%	96.4% / 91.2%	97.7% / 93.6%
CNN4	76.2% / 70.4%	86.1% / 79.8%	96.9% / 92.9%	99% / 96.1%

From the data in the table, it can be seen that there is a strong positive correlation between the segment size and the classification efficiency of the network, i.e. increasing the segment size significantly increased the performance of the machine learning model, regardless of the network I used. This also supports the findings in thesis point 2. In addition, it can be observed that CNN4, which is a deeper version of CNN1, performed somewhat worse than that.

Thesis 5: *Using data from the PhysioNet EEG database, I showed during my measurements that the recognition accuracy of the neural network can be clearly increased by choosing the optimal segment size and architecture. The best recognition accuracy measured on the test data were 99.1% and 97.7% using the data of 10 and 20 subjects, respectively, for classifications involving three activities. I also found that causeless deepening of a network not only does not further increase, but may even reduce the classification accuracy - in addition to increasing the time required for training.*

3.6. FPGA implementation of neural networks

I investigated the hardware acceleration possibilities of MLP and CNN neural networks as described in papers [J1], [J4] and [C5], using a pure hardware implementation for MLP and a DPU implementation for CNN.

In order to define a trained MLP network, in addition to the structure of the network, knowledge of the weights and bias values applied to the neurons is required. Most machine learning frameworks are able to export these in some form. Based on the exported data, the hardware implementation of the MLP can be created. While in a software implementation the use of floating-point number representation does not cause any problems due to the floating-point unit of the processor, in an FPGA implementation it is very difficult to perform operations with such numbers, it is more practical to work with fixed-point numbers. In my referenced publications, I also investigated the effect of fixed-point number representation on classification accuracy. As expected, there was some reduction, but it was not significant.

Instead of performing actual calculations, the activation function can be implemented as a LUT (lookup table), where the memory address is the value of the independent variable of the function, and the cell designated by the address contains the function value. In order to keep the size of the LUT under control, it is possible (it can be specified as a parameter) to use only a part of the bits of the weighted sum calculated by the neuron, for example the most significant 12 bits, for addressing the memory. I used a dual-port ROM for LUT implementation, so that two neurons can access the same memory at the same time, thus reducing this kind of resource demand by half.

Thesis 6: *I have developed a software that can generate synthesizable Verilog code for the FPGA implementation of MLP networks. Based on the weights and bias values exported from the neural network training framework,*

after defining the architecture, the software performs the floating-point to fixed-point conversions and generates the Verilog codes implementing the multipliers, adders, activation functions and their connections, which can be imported and synthesized in any FPGA development environment. All this is done in a completely automated way, so a hardware implementation can be easily created even without related expertise. The correctness of the method was verified with a simulation procedure.

Bibliography

- [1] D. Hari Krishna, I.A. Pasha, T. Satya Savithri (2016). Classification of EEG Motor Imagery Multi Class Signals Based on Cross Correlation. *Procedia Computer Science*, vol. 85, pp. 490-495. doi: 10.1016/j.procs.2016.05.198.
- [2] Chen Z, Wang Y, Song Z. Classification of Motor Imagery Electroencephalography Signals Based on Image Processing Method. *Sensors (Basel)*. 2021;21(14):4646. Published 2021 Jul 7. doi:10.3390/s21144646
- [3] Wu, Y.-T., Huang, T. H., Yi Lin, C., Tsai, S. J., & Wang, P.-S. (2018). Classification of EEG Motor Imagery Using Support Vector Machine and Convolutional Neural Network. 2018 International Automatic Control Conference (CACs). doi:10.1109/cacs.2018.8606765
- [4] León J, Escobar JJ, Ortiz A, et al. Deep learning for EEG-based Motor Imagery classification: Accuracy-cost trade-off. *PLoS One*. 2020;15(6):e0234178. Published 2020 Jun 11. doi:10.1371/journal.pone.0234178
- [5] Wang Z, Zhang Z, Gong X, Sun Y and Wang H (2018). Short time Fourier transformation and deep neural networks for motor imagery brain computer interface recognition. *Concurrency and Computation: Practice and Experience*, vol. 30. doi: 10.1002/cpe.4413

- [6] Behri, M., Subasi, A., & Qaisar, S. M. (2018). Comparison of machine learning methods for two class motor imagery tasks using EEG in brain-computer interface. 2018 Advances in Science and Engineering Technology International Conferences (ASET). doi:10.1109/icaset.2018.8376886
- [7] Jia, Hongru & Wang, Shuai & Zheng, Dezhi & Qu, Xiaolei & Fan, Shangchun. (2019). Comparative study of motor imagery classification based on BP-NN and SVM. *The Journal of Engineering*. 2019. 10.1049/joe.2018.9075.
- [8] Alexander Craik, Yongtian He, Jose L Contreras-Vidal (2019). Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of Neural Engineering*, vol. 16, no 3. doi: 10.1088/1741-2552/ab0ab5
- [9] Amjed S. Al-Fahoum, Ausilah A. Al-Fraihat, "Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains", *International Scholarly Research Notices*, vol. 2014, Article ID 730218, 7 pages, 2014. doi: 10.1155/2014/730218
- [10] Swati Aggarwal, Nupur Chugh (2019). Signal processing techniques for motor imagery brain computer interface: A review. *Array*, vol 1-2, 100003. doi: 10.1016/j.array.2019.100003.
- [11] Resalat SN, Saba V. A Study of Various Feature Extraction Methods on a Motor Imagery Based Brain Computer Interface System. *Basic Clin Neurosci*. 2016;7(1):13-19.

- [12] Amjed S. Al-Fahoum, Ausilah A. Al-Fraihat, "Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains", *International Scholarly Research Notices*, vol. 2014, Article ID 730218, 7 pages, 2014 doi: 10.1155/2014/730218
- [13] Schalk, G., McFarland, D.J., Hinterberger, T., Birbaumer, N., Wolpaw, J.R. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. *IEEE Transactions on Biomedical Engineering* 51(6):1034-1043, 2004.
- [14] Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation* [Online]. 101 (23), pp. e215–e220.
- [15] Luciw, M., Jarocka, E. & Edin, B. Multi-channel EEG recordings during 3,936 grasp and lift trials with varying weight and friction. *Sci Data* 1, 140047 (2014). doi: 10.1038/sdata.2014.47
- [16] Kaya, Murat; Binli, Mustafa Kemal; Ozbay, Erkan; Yanar, Hilmi; Mishchenko, Yuriy (2018): A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces. figshare. Collection. <https://doi.org/10.6084/m9.figshare.c.3917698.v1>
- [17] Benjamin Blankertz, Guido Dornhege, Matthias Krauledat, Klaus-Robert Müller, and Gabriel Curio. The non-invasive Berlin Brain-Computer Interface:

Fast acquisition of effective performance in untrained subjects. *NeuroImage*, 37(2):539-550, 2007.

- [18] Tangermann, Michael & Müller, Klaus-Robert & Aertsen, Ad & Birbaumer, Niels & Braun, Christoph & Brunner, Clemens & Leeb, Robert & Mehring, Carsten & Miller, Kai & Müller-Putz, Gernot & Nolte, Guido & Pfurtscheller, Gert & Preissl, Hubert & Schalk, Gerwin & Schlögl, Alois & Vidaurre, Carmen & Waldert, Stephan & Blankertz, Benjamin. (2012). Review of the BCI competition IV. *Frontiers in neuroscience*. 6. 55. 10.3389/fnins.2012.00055.
- [19] Schirrmester, R.T., Springenberg, J.T., Fiederer, L.D.J., Glasstetter, M., Eggensperger, K., Tangermann, M., Hutter, F., Burgard, W. and Ball, T. (2017), Deep learning with convolutional neural networks for EEG decoding and visualization. *Hum. Brain Mapp.*, 38: 5391-5420. <https://doi.org/10.1002/hbm.23730>
- [20] Kemp B, Olivan J. European data format 'plus' (EDF+), an EDF alike standard format for the exchange of physiological data. *Clin Neurophysiol.* 2003 Sep;114(9):1755-61. doi: 10.1016/s1388-2457(03)00123-8. PMID: 12948806.
- [21] Youngjoo Kim, Jiwoo Ryu, Ko Keun Kim, Clive C. Took, Danilo P. Mandic, Cheolsoo Park, "Motor Imagery Classification Using Mu and Beta Rhythms of EEG with Strong Uncorrelating Transform Based Complex Common Spatial Patterns", *Computational Intelligence and Neuroscience*, vol. 2016, Article ID 1489692, 13 pages, 2016. <https://doi.org/10.1155/2016/1489692>

- [22] Dose, H., Moller, J. S., Puthusserypady, S., & Iversen, H. K. (2018). A Deep Learning MI - EEG Classification Model for BCIs. 2018 26th European Signal Processing Conference (EUSIPCO). doi: 10.23919/eusipco.2018.8553332
- [23] Zhang, D., Chen, K., Jian, D., & Yao, L. (2020). Motor Imagery Classification via Temporal Attention Cues of Graph Embedded EEG Signals. *IEEE Journal of Biomedical and Health Informatics*, 1–1. doi:10.1109/jbhi.2020.2967128
- [24] Fadel, W., Kollod, C., Wahdow, M., Ibrahim, Y., & Ulbert, I. (2020). 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). doi:10.1109/bci48061.2020.9061622
- [25] Eitan Netzer, Alex Frid, Dan Feldman (2020). Real-time EEG classification via coresets for BCI applications. *Engineering Applications of Artificial Intelligence*, vol. 89. Article ID 103455. doi: 10.1016/j.engappai.2019.103455
- [26] Tokovarov, M. (2020). Convolutional Neural Networks with Reusable Full-Dimension-Long Layers for Feature Selection and Classification of Motor Imagery in EEG Signals. *Lecture Notes in Computer Science*, 79–91. doi:10.1007/978-3-030-61609-0_7
- [27] Audrey Aldridge, Eli Barnes, Cindy L. Bethel, Daniel W. Carruth, Marianna Kocturova, Matus Pleva, Jozef Juhar, “Accessible Electroencephalograms (EEGs): A Comparative Review with OpenBCI’s Ultracortex Mark IV Headset”, 29th International Conference

Radioelektronika (RADIOELEKTRONIKA),
Pardubice, Czech Republic, 2019, pp. 1-6, DOI:
10.1109/RADIOELEK.2019.8733482

- [28] Gaur, P., Gupta, H., Chowdhury, A., McCreadie, K., Pachori, R. B., & Wang, H. (2021). A Sliding Window Common Spatial Pattern for Enhancing Motor Imagery Classification in EEG-BCI. *IEEE Transactions on Instrumentation and Measurement*, 70, 1–9. doi:10.1109/tim.2021.3051996
- [29] Wang, Xiaying & Hersche, Michael & Tomekce, Batuhan & Kaya, Burak & Magno, Michele & Benini, Luca. (2020). An Accurate EEGNet-based Motor-Imagery Brain–Computer Interface for Low-Power Edge Computing. 1-6. doi: 10.1109/MeMeA49120.2020.9137134.
- [30] Blanco-Mora, D. & Aldridge, A. & Jorge, Carolina & Vourvopoulos, Athanasios & Figueiredo, Patrícia & Bermúdez i Badia, Sergi. (2021). Finding the Optimal Time Window for Increased Classification Accuracy during Motor Imagery. 144-151. doi: 10.5220/0010316101440151.
- [31] Akbulut, Orhan. (2020). Feature Normalization Effect in Emotion Classification based on EEG Signals. 24. 60-66. 10.16984/saufenbilder.617642.
- [32] Renton, A.I., Mattingley, J.B. & Painter, D.R., “Optimising non-invasive brain-computer interface systems for free communication between naïve human participants”, *Scientific Reports* 9, 18705 (2019). DOI: 10.1038/s41598-019-55166-y

- [33] E. Gysels and P. Celka, “Phase synchronization for the recognition of mental tasks in a brain-computer interface”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 12, no. 4, pp. 406-415, Dec. 2004, DOI: 10.1109/TNSRE.2004.838443
- [34] S. V. Bozhokin and I. B. Suslova, “Wavelet-based analysis of spectral rearrangements of EEG patterns and of non-stationary correlations”, *Physica A: Statistical Mechanics and its Applications*, vol. 21, pp. 151-160, 2015. DOI: 10.1016/j.physa.2014.11.026

Related publications

- [J1] Majoros, T.; Oniga, S. Overview of the EEG-Based Classification of Motor Imagery Activities Using Machine Learning Methods and Inference Acceleration with FPGA-Based Cards. *Electronics* 2022, 11, 2293. DOI: 10.3390/electronics11152293
- [J2] Tamás Majoros, Stefan Oniga, Yu Xie, Motor imagery EEG classification using feedforward neural network, *Annales Mathematicae et Informaticae* vol 53 (2021), pp. 235-244, ISSN 1787 - 6117, DOI: 10.33039/ami.2021.04.007
- [J3] Tamás Majoros, Balázs Ujvári, Stefan Oniga, EEG data processing with neural network, *Carpathian Journal of Electronic and Computer Engineering* vol 12 number 2/2019, pp. 33-36, ISSN 1844 – 9689, DOI: 10.2478/cjece-2019-0014
- [J4] Tamás Majoros, Balázs Ujvári, Stability study of the neural network at particle physics detectors, *Carpathian Journal of Electronic and Computer Engineering* vol 11 number 1/2018, pp. 48-52, ISSN 1844 – 9689, DOI: 10.2478/cjece-2018-0009
- [C1] T. Majoros and S. Oniga, "Comparison of Motor Imagery EEG Classification using Feedforward and Convolutional Neural Network," *IEEE EUROCON 2021 - 19th International Conference on Smart Technologies*, 2021, pp. 25-29, doi: 10.1109/EUROCON52738.2021.9535592.

- [C2] T. Majoros and S. Oniga, "Activity recognition using consumer-grade EEG device," 2021 13th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), 2021, pp. 1-6, doi: 10.1109/ECAI52376.2021.9515106.
- [C3] Majoros Tamás, Oniga István László, Elképzelt motoros tevékenységek EEG-alapú osztályozása neurális hálózatok használatával, XXIII. NEMZETKÖZI SZÁMÍTÁSTECHNIKA ÉS OKTATÁS KONFERENCIA, SzámOkt 2022, Marosvásárhely, október 13-16, 2022, pp. 162-167, ISSN 2734-6757
- [C4] Majoros Tamás, Ujvári Balázs, Oniga István László, EEG adatok feldolgozása neurális hálózattal, XXIX. NEMZETKÖZI SZÁMÍTÁSTECHNIKA ÉS OKTATÁS KONFERENCIA, SzámOkt 2019, Temesvár, október 10-13, 2019, pp. 208-213, ISSN 1842 - 4546
- [C5] Majoros Tamás, Ujvári Balázs, Oniga István László, Részecskefizikai detektorban alkalmazott neurális hálózat stabilitási vizsgálata, XXVIII. NEMZETKÖZI SZÁMÍTÁSTECHNIKA ÉS OKTATÁS KONFERENCIA, SzámOkt 2018, Tusnádfürdő, október 11-14, 2018, pp. 262-267, ISSN 1842 - 4546



Registry number: DEENK/57/2023.PL
Subject: PhD Publication List

Candidate: Tamás Majoros
Doctoral School: Doctoral School of Informatics
MTMT ID: 10066820

List of publications related to the dissertation

Foreign language scientific articles in Hungarian journals (1)

1. **Majoros, T.**, Oniga, I. L., Xie, Y.: Motor imagery EEG classification using feedforward neural network.
Ann. Math. Inform. 53, 235-244, 2021. ISSN: 1787-5021.
DOI: <http://dx.doi.org/10.33039/ami.2021.04.007>

Foreign language scientific articles in international journals (3)

2. **Majoros, T.**, Oniga, I. L.: Overview of the EEG-Based Classification of Motor Imagery Activities Using Machine Learning Methods and Inference Acceleration with FPGA-Based Cards.
Electronics (Switzerland). 11 (15), 1-14, 2022. EISSN: 2079-9292.
DOI: <http://dx.doi.org/10.3390/electronics11152293>
IF: 2.69 (2021)
3. **Majoros, T.**, Ujvári, B., Oniga, I. L.: EEG data processing with neural network.
Carpath. J. Electron. Comput. Eng. 12 (2), 33-36, 2019. ISSN: 1844-9689.
DOI: <http://dx.doi.org/10.2478/cjece-2019-0014>
4. **Majoros, T.**, Ujvári, B.: Stability study of the neural network at particle physics detectors.
Carpath. J. Electron. Comput. Eng. 11 (1), 48-52, 2018. ISSN: 1844-9689.
DOI: <http://dx.doi.org/10.2478/cjece-2018-0009>

Hungarian conference proceedings (3)

5. **Majoros, T.**, Oniga, I. L.: Elképzelt motoros tevékenységek EEG-alapú osztályozása neurális hálózatok használatával.
In: XXIII. Energetika-Elektrotechnika - ENELKO és XXXII. Számítástechnika és Oktatás SzámOkt Multi-konferencia. Szerk.: Sebestyén-Pál György, Szabó Loránd, Erdélyi Magyar Műszaki Tudományos Társaság, Kolozsvár, 162-167, 2022, (ISSN 2734-6757).
6. **Majoros, T.**, Ujvári, B., Oniga, I. L.: EEG adatok feldolgozása neurális hálózatok segítségével.
In: ENELKO 2019, SzámOkt 2019, Erdélyi Magyar Műszaki Tudományos Társaság, Temesvár, 208-213, 2019, (ISSN 1842-4546 ; 29.)





7. **Majoros, T.**, Ujvári, B., Oniga, I. L.: Részecskefizikai detektorban alkalmazott neurális hálózat stabilitási vizsgálata.

In: ENELKO 2018 XIX. Nemzetközi Energetika-Elektrotechnika Konferencia, SzámOkt 2018 XXVIII. Nemzetközi Számítástechnika és Oktatás Konferencia. Szerk.: Bíró Károly-Ágoston, Sebestyén-Pál György, Szabó Loránd, Erdélyi Magyar Műszaki Tudományos Társaság, Tusnádfürdő, 262-267, 2018, (ISSN 1842-4546)

Foreign language conference proceedings (2)

8. **Majoros, T.**, Oniga, I. L.: Activity recognition using consumer-grade EEG device.

In: 13th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), IEEE, Pitesti, 1-6, 2021. ISBN: 9781665425346

9. **Majoros, T.**, Oniga, I. L.: Comparison of Motor Imagery EEG Classification using Feedforward and Convolutional Neural Network.

In: IEEE EUROCON 2021 - 19th International Conference on Smart Technologies. Ed.: Mariya Antyufeyeva, IEEE, Lviv, 25-29, 2021. ISBN: 9781665432993

List of other publications

Foreign language international book chapters (1)

10. Kovács, L., Baranyai, D., Girászi, T., **Majoros, T.**, Kovács, Á., Vágner, M., Palkovics, D., Bérczes, T.: Sensor design and integration into small sized autonomous vehicle.

In: 2022 IEEE 2nd Conference on Information Technology and Data Science (CITDS). Ed.: Fazekas István, IEEE, Piscataway, 171-176, 2022. ISBN: 9781665496537

Foreign language scientific articles in international journals (3)

11. Xie, Y., **Majoros, T.**, Oniga, I. L.: FPGA-Based Hardware Accelerator on Portable Equipment for EEG Signal Patterns Recognition.

Electronics (Switzerland). 11 (15), 1-15, 2022. EISSN: 2079-9292.

DOI: <http://dx.doi.org/10.3390/electronics11152410>

IF: 2.69 (2021)

12. Bíró, B., David, G., Fenyvesi, A., Haggerty, J. S., Kierstead, J., Mannel, E. J., **Majoros, T.**, Molnár, J., Nagy, F., Stoll, S., Ujvári, B., Woody, C. L.: A Comparison of the Effects of Neutron and Gamma Radiation in Silicon Photomultipliers.

IEEE Trans. Nucl. Sci. 66 (7), 1833-1839, 2019. ISSN: 0018-9499.

DOI: <http://dx.doi.org/10.1109/TNS.2019.2921102>

IF: 1.575





13. Aidala, C. A., Bailey, V., Beckman, S., Belmont, R., Biggs, C., Blackburn, J., Boose, S., Chiu, M., Connors, M., Desmond, E., Franz, A., Haggerty, J. S., He, X., Higdon, M. M., Huang, J., Kauder, K., Kistenev, E., LaBounty, J., Lajoie, J. G., Lenz, M., Lenz, W., Li, S., Loggins, V. R., Mannel, E. J., **Majoros, T.**, McCumber, M. P., Nagle, J. L., Phipps, M., Pinkenburg, C., Polizzo, S., Pontieri, C., Purschke, M. L., Putschke, J., Sarsour, M., Rinn, T., Ruggiero, R., Sen, A., Sickles, A. M., Skoby, M. J., Smiga, J., Sobel, P., Stankus, P. W., Stoll, S., Sukhanov, A., Thorsland, E., Toldo, F., Towell, R. S., Ujvári, B., Vazquez-Carson, S., Woody, C. L.: Design and Beam Test Results for the sPHENIX Electromagnetic and Hadronic Calorimeter Prototypes.

IEEE Trans. Nucl. Sci. 65 (12), 2901-2919, 2018. ISSN: 0018-9499.

DOI: <http://dx.doi.org/10.1109/TNS.2018.2879047>

IF: 1.428

Foreign language conference proceedings (2)

14. Xie, Y., Oniga, I. L., **Majoros, T.**: Comparison of EEG Data Processing Using Feedforward and Convolutional Neural Network.
In: Proceedings of 1st Conference on Information Technology and Data Science (CITDS 2020) / editors István Fazekas, András Hajdu, Tibor Tómacs, CEUR, Debrecen, 279-289, 2021, (CEUR Workshop Proceedings, ISSN 1613-0073 ; 2874.)
15. Yu, X., **Majoros, T.**, Oniga, I. L.: Hardware Implementation of CNN Based on FPGA for EEG Signal Patterns Recognition.
In: International Conference on e-Health and Bioengineering (EHB). Ed.: Grigore T. Popa, IEEE, Iasi, 1-4, 2021. ISBN: 9781665440004

Total IF of journals (all publications): 8,383

Total IF of journals (publications related to the dissertation): 2,69

The Candidate's publication data submitted to the iDEa Tudóstér have been validated by DEENK on the basis of the Journal Citation Report (Impact Factor) database.

28 February, 2023

