

# Elképzel motoros tevékenységek EEG-alapú osztályozása neurális hálózatok használatával

## EEG-based classification of motor imagery activities using neural networks

MAJOROS Tamás PhD hallgató<sup>1</sup>, Dr. ONIGA István László egyetemi docens<sup>2</sup>

<sup>1</sup> Debreceni Egyetem, Informatikai Kar, Informatikai Rendszerek és Hálózatok Tanszék,  
Debrecen, Magyarország, majoros.tamas@inf.unideb.hu

<sup>2</sup> Debreceni Egyetem, Informatikai Kar, Informatikai Rendszerek és Hálózatok Tanszék,  
Debrecen, Magyarország, oniga.istvan@inf.unideb.hu

### Abstract

*EEG-based classification of motor imagery activities is often performed using neural networks. In this article, we examined the effect of data segmentation and different neural network structures. By applying proper window size and using a purely convolutional neural network, we achieved 97.7% recognition accuracy on data from twenty subjects in three classes, which outperforms several networks used in previous research.*

**Keywords:** EEG, neural network, classification, activity recognition, data segmentation

### Kivonat

*Az elképzelt motoros tevékenységek EEG-alapú osztályozását gyakran neurális hálózatok segítségével végzik. Ebben a cikkben az adatszegmentáció és különböző neurális hálózati struktúrák hatását vizsgáltuk. Megfelelő ablakméret alkalmazásával és egy tisztán konvolúciós neurális háló használatával 97,7%-os felismerési pontosságot értünk el húsz alany adatain három osztályban, ami több, a korábbi kutatásokban használt hálózatot felülmúl.*

**Kulcsszavak:** EEG, neurális hálózat, osztályozás, tevékenységfelismerés, adatszegmentálás

## 1. BEVEZETÉS

Az agy működését kísérő elektromos jelenségek elemzésének egyik módszere elektroencefalográfia (EEG), amelynek segítségével tanulmányozható a pszichés működés élettani háttere az idegsejtek elektromos aktivitásának regisztrálása útján. Agyi tevékenység során az agykéregben lévő neuronok aktivitásából származó ionáramok elektromos feszültség ingadozásokat eredményeznek a kéreg felszínén [1]. Egy-egy agyi neuron működése által okozott feszültség-ingadozás rendkívül csekély mértékű, azonban sok neuron egy időben történő aktivitása már mérhető, néhány tíz  $\mu\text{V}$  nagyságrendű feszültség-ingadozást okoz. A mérés során kapott jelek regisztrálhatók és így egy komplex, időben változó, az agyi tevékenységet leíró görbéhez jutunk.

A kapott jel összetett, helyes értelmezése több évnyi tanulást és tapasztalatot igényel a szakértők részéről. Manapság azonban a gépi tanulás tudományának fejlődésével a tanulóalgoritmusok fokozatosan felváltják a bonyolult, időt és szakértelmet igénylő vizuális kiértékelést és lehetővé teszik az agyi aktivitás EEG felvételeiből információ kinyerését, így központi szerepet töltenek be számos EEG-alapú kutatásban és alkalmazásban. Például a gépi tanulási technikák sok klinikai alkalmazásra szánt EEG-alapú agy-számítógép interfész (*brain-computer interface*, BCI) központi elemét képezik mind a kommunikációban, mind a rehabilitációban [2]. A BCI célja kommunikációs kapcsolat létrehozása az emberi agy és egy számítógép között, amelynek segítségével az agyhullámok tényleges fizikai mozgássá alakíthatók izmok használata nélkül. Az EEG jelek robosztus automatikus kiértékelése fontos lépés afelé, hogy ez a módszer egyre több és több alkalmazásban legyen használható és kevésbé támaszkodjon képzett szakemberekre.

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 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, amely lehet akár sekély, akár mélytanuló algoritmus. Végül az alkalmazott módszer paramétereit finomhangolni kell, kiértékelni a teljesítményét, és annak ismeretében további finomításokat végezni, ha szükséges.

## 2. IRODALMI ÁTTEKINTÉS

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 tevékenyégeken ezen minták alapján egymástól elkülöníthetők.

Számos kutató vizsgálta a különböző 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 a [3] cikk szerzői öt sekély algoritmust használtak elképzelt motoros tevékenység felismerésére kilenc önkéntes esetén. Négy alanynál a naiv Bayes, kettőnél a döntési fa (*decision tree*, DT), kettőnél a  $k$ -legközelebbi szomszéd (*k-nearest neighbors*, kNN), egynél a támogató vektor gép (*support vector machine*, SVM) bizonyult a leghatékonyabbnak. A [4] cikk szerzői egy, az előzőhöz hasonló adatbázison SVM és CNN osztályozók közül mind a kilenc alany esetén a konvolúciós neurális hálózatot (*convolutional neural network*, CNN) találták pontosabbnak. Ezzel szemben viszont a [5] tanulmányban kilencből öt alany esetén az SVM adott jobb eredményt a CNN-hez képest.

A [6] cikk szerzői elképzelt motoros tevékenységek felismerésére alkalmaztak MLP, CNN és RNN (*recurrent neural network*) 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 (például a kernelméret, kernelszám) megválasztása. A [7] publikációban a szerzők szintén RNN és CNN algoritmust vizsgáltak, és megállapították, hogy a CNN jelentősen felülmúlja az RNN-t.

A [8] 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 (*random forest*) algoritmusokat használtak. 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 [9] cikk szerzői szintén SVM és MLP algoritmust használtak elképzelt motoros tevékenységek felismerésére, azonban a [8] 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 koránt sem 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 [10].

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 [10] 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. Érdemes 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.

A kutatásban általunk használt PhysioNet adatbázis [11] több, mint 1500 egy- és kétperces EEG felvételt tartalmaz 109 önkéntestől, akik különböző motoros és elképzelt motoros tevékenységeket hajtottak végre. Munkánk során azokat az adatfájlokat dolgoztuk fel, amelyekben az önkéntesek mindkét kézfej vagy mindkét lábfej összeszorítását képzelik el annak megfelelően, hogy egy objektum a képernyő tetején vagy alján jelenik meg. Amikor a szimbólum eltűnik, elképzelik a szorítás elengedését. Az elérhető 64-ből 16 csatorna adatait használtuk (Fp1, Fp2, F7, Fz, F8, T7, C3, Cz, C4, T8, P7, P3, P4, P8, O1 és O2), mert a jövőben a saját 16 csatornás eszközünkkel mért adatok felismerését is el szeretnénk végezni a nagy adatbázison tanított hálózattal.

### 3. GÉPI TANULÁS ALKALMAZÁSA

Az adatok rendelkezésre állását követően megtörténhet azok előfeldolgozása. Ez az előfeldolgozási folyamat jellemzően további részfolyamatokra bontható, amelyek magukba foglalhatják az adatfolyam szegmentálását, jellemzők kinyerését, az adatok szűrését, feljavítását, vagy valamilyen jellegű átalakítását.

#### 3.1 Szegmentálás

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.

A szegmentálás történhet az adatfolyam egyszerű széttördelésével, de megvalósulhat csúszó ablak alkalmazásával is, ebben az esetben van valamekkora átfedés az egymást követő ablakok adatai között. Természetesen ez utóbbi esetben – az ablakok közötti átfedés mértékének függvényében – nagyobb számú tanítási (és tesztelési) mintához jutunk. Minél nagyobb az átfedés, annál több mintát tudunk a tanításnál felhasználni, azonban túlzottan nagy mértékű átfedés esetén az egymást követő ablakok csak minimális plusz információt adnak egymáshoz képest, aminek következtében nem igazán járulnak hozzá a gépi tanulóalgoritmus pontosságának javításához, viszont a tanítási idő növekedését okozzák.

Az ablakok mérete jellemzően néhány másodperces intervallumot fed le [12-13]. Fontos az ablakméret megfelelő megválasztása, ugyanis létezik egy olyan optimális érték, amellyel az adott gépi tanulási feladat esetén a modell teljesítménye maximalizálható. Ettől kisebb, azaz túl rövid időintervallumot magában foglaló ablakméret mellett előfordulhat, hogy az ablak nem tartalmaz elég információt a végzett tevékenységről, amely így az osztályozás pontosságát csökkenti. Nagy ablakméret esetén pedig több különböző tevékenységből származó adatot is tartalmazhat, különösen, ha a tevékenységváltások viszonylag gyakoriak. Bár ez utóbbi probléma egyszerűbben orvosolható, hiszen eldobhatjuk azokat az ablakokat, amelyek közben tevékenységváltás történt, de ha túl sok ilyen van, az a rendelkezésre álló tanítási minták számának szignifikáns csökkenését okozhatja. Egy másik probléma pedig már nem a tanítás során, hanem a betanított modell használatakor jelentkezik nagyméretű ablak esetén: valós idejű tevékenységfelismeréskor a végzett tevékenység megváltozását követően nagyobb késleltetéssel jelenik meg a kimeneten az osztályozás eredménye.

Kutatásunkban a PhysioNet adatbázis felhasználásával igyekeztünk megtalálni az ideális ablakméretet. Az adatokat szegmentálását különböző ablakméretekkel végeztük. Az ablakok majdnem teljesen átfedőek voltak, egy  $N$  méretű ablak az aktuális és az előző  $N-1$  mérési pontot tartalmazta az említett 16 darab EEG csatorna adataiból.

#### 3.2 Neurális hálózat

Amint arról korábban szó volt, az EEG adatokból történő aktivitás felismeréskor az optimális tanulási algoritmus kiválasztása és megfelelő paraméterezése korántsem egyértelmű, a különböző hivatkozott tanulmányok sok esetben egymásnak ellentmondó következtetésekre jutottak. Ugyanakkor megfigyelhető az a tendencia, hogy az ilyen típusú tevékenységfelismerési feladatokban alkalmazott módszerek között egyre nagyobb teret hódítanak a konvolúciós neurális hálózatok. Ezen megfigyelések alapján gépi tanulási módszerként mi is konvolúciós neurális hálózatot használtunk. A jellemzőkinyerést – szintén a hivatkozott cikkek következtetései alapján – a hálózatra bíztuk. A tanítást és a tesztelést kiegyensúlyozott adatkészleten

végeztük, 10 és 20 alany adatait felhasználva. Az alkalmazott algoritmus Adam optimalizáló volt. A rendelkezésre álló adatok 70%-át tanításra, 30%-át pedig tesztelésre használtuk fel.

A CNN esetében a pontosságot nagymértékben meghatározza a hálózat felépítése és különféle paraméterei (kernelszám, kernelméret stb.), ezért különböző felépítésű hálózatok teljesítményét hasonlítottuk össze, hogy megtaláljuk az erre a feladatra optimálisat. Mivel egy (konvolúciós) neurális hálózat rétegeinek és paramétereinek meghatározására nincs analitikus módszer, a struktúra kialakításánál tapasztalatokra és kísérletezésre támaszkodtunk. A használt neurális hálózatok közül az első (a továbbiakban: *CNN1*) tisztán konvolúciós hálózat, azaz nem tartalmaz teljesen összekapcsolt rétegeket. Azonos kísérleteket végeztünk egy más felépítésű, összevonó és teljesen összekapcsolt rétegeket is tartalmazó hálózat (a továbbiakban *CNN2*) használatával is. Felépítésüket az 1. táblázat foglalja össze.

CNN1 és CNN2 hálózat struktúrája

1. táblázat

Réteg sorszáma	CNN1	CNN2
1	Bemeneti réteg (szegmensméret-függően)	Bemeneti réteg (szegmensméret-függően)
2	Konvolúció (16 darab 5x5-ös kernel, 2-es lépésköz, párnázással)	Konvolúciós réteg (8 darab 3x3-as kernel, 1-es lépésköz, párnázással)
3	Batch normalizációs réteg (16 csatorna)	Aktivációs réteg (ReLU)
4	Aktivációs réteg (ReLU)	Maximum pooling réteg (2x2-es szűrő, 2-es lépésköz)
5	Konvolúciós réteg (32 darab 5x5-ös kernel, 2-es lépésköz, párnázással)	Konvolúciós réteg (16 darab 5x5-ös kernel, 1-es lépésköz, párnázás nélkül)
6	Batch normalizációs réteg (32 csatorna)	Aktivációs réteg (ReLU)
7	Aktivációs réteg (ReLU)	Maximum pooling réteg (2x2-es szűrő, 2-es lépésköz)
8	Konvolúciós réteg (64 darab 3x3-as kernel, 2-es lépésköz, párnázással)	Sorosító réteg
9	Batch normalizációs réteg (64 csatorna)	Teljesen összekapcsolt réteg (64 neuron)
10	Aktivációs réteg (ReLU)	Aktivációs réteg (ReLU)
11	Konvolúciós réteg (64 darab 2x8-as kernel, 2x8-es lépésköz, párnázás nélkül)	Teljesen összekapcsolt réteg (32 neuron)
12	Batch normalizációs réteg (64 csatorna)	Aktivációs réteg (ReLU)
13	Sorosító réteg	Teljesen összekapcsolt réteg (3 neuron)
14		Aktivációs réteg (Softmax)

Kísérleteink során azt tapasztaltuk, hogy a *CNN2* lényegesen rosszabbul teljesített, mint a *CNN1*, ezért alapvetően ahhoz a struktúrához visszatérve egy másik megközelítést alkalmazva végeztük el az újabb kísérleteket. Ebben a hálózatban (a továbbiakban *CNN3*) az összes konvolúciós rétegben a szűrők méretét 5x5-ösről 3x3-as mérsékeljük, minden más tekintetben a modell azonos a *CNN1*-gyel. A tapasztalatok alapján a következő alkalmazott modellel (a továbbiakban *CNN4*) ismét a *CNN1*-ben használt kernelméretre tértünk vissza, ezúttal azonban a hálózat mélyítésének hatását vizsgáltuk meg. A *CNN1* hálózatot alapvetően egy konvolúciós – batch normalizációs – ReLU rétegeket tartalmazó blokkal egészítettük ki ebben az esetben. Ez utóbbi hálózat felépítését a 2. táblázat foglalja össze.

Réteg sorszáma	Réteg típusa
1	Bemeneti réteg (szegmensméret-függően)
2	Konvolúciós réteg (8 darab 5x5-ös kernel, 2-es lépésköz, párnázással)
3	Batch normalizációs réteg (8 csatorna)
4	Aktivációs réteg (ReLU)
5	Konvolúciós réteg (16 darab 5x5-ös kernel, 2-es lépésköz, párnázással)
6	Batch normalizációs réteg (16 csatorna)
7	Aktivációs réteg (ReLU)
8	Konvolúciós réteg (32 darab 5x5-ös kernel, 2-es lépésköz, párnázással)
9	Batch normalizációs réteg (32 csatorna)
10	Aktivációs réteg (ReLU)
11	Konvolúciós réteg (64 darab 3x3-as kernel, 2-es lépésköz, párnázással)
12	Batch normalizációs réteg (64 csatorna)
13	Aktivációs réteg (ReLU)
14	Konvolúciós réteg (64 darab 2x8-as kernel, 2x8-es lépésköz, párnázás nélkül)
15	Batch normalizációs réteg (64 csatorna)
16	Sorosító réteg

#### 4. EREDMÉNYEK

Első alkalommal 32 mintás (0,2 mp) ablakméretet használtunk, amellyel 79,2%-os felismerési pontosságot értünk el a 10 alanyú adathalmazon a *CNN1* hálózattal. Ugyanezt a kísérletet 20 alanyból álló adatsoron is elvégeztük, és a kapott eredmények megerősítették korábbi hipotézisünket és a [14] következtetését, vagyis azt, hogy az ilyen típusú tevékenységek által generált EEG jelek egyénenként változnak. A pontosság 71,8%-ra adódott, ami lényegesen alacsonyabb, mint a 10 fő esetén elért teljesítmény. A hálózat pontosságát nem találtuk kielégítőnek ilyen kis ablakméret mellett, de a méret növelésével ez jelentősen javult. A legnagyobb alkalmazott ablakméret 160 volt, ami 1 mp-et fed le, és ekkora késést okoz a valós idejű adatfeldolgozásnál is, ezért ezt már nem kívántuk tovább növelni. Az eredményeket úgy értelmeztük, hogy egy 0,8-1 mp-es szegmens már elegendő egyénfüggetlen információt tartalmazott ahhoz, hogy a gépi tanulási modell általános mintát tudjon felismerni az adatokban. Az elért eredményeket a 3. táblázat mutatja be.

PhysioNet adatokon elért pontosság 10/20 fő esetén

3. táblázat

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 szegmens mérete és a hálózat osztályozási pontossága között, azaz a szegmens méretének növelésével jelentősen megnő a gépi tanulási

modell teljesítménye, függetlenül attól, hogy melyik hálózatot használjuk. Megállapítható az is, hogy a batch normalizálást nem, viszont összevonó és teljesen összekapcsolt rétegeket tartalmazó *CNN2* teljesítménye mindig lényegesen alacsonyabb volt a tisztán konvolúciós hálózatok teljesítményénél. A kernelméret hatását tekintve az  $5 \times 5$ -ös méretet használó *CNN1* minden esetben valamivel jobban teljesített, mint a  $3 \times 3$ -ast alkalmazó *CNN3*. Bár a [15]-ben leírtak szerint az ideális kernelméret személyenként változik, sőt azonos személynél is időről időre eltérő lehet, azonban ezekkel az adatokkal, ezzel a *CNN1/CNN3* hálózati réteggel, az  $5 \times 5$ -ös kernelméret összességében kedvezőbb, mint a  $3 \times 3$ -as, azaz ha több emberre általánosítható megoldást keresünk, ennél a neurális hálózati struktúránál a nagyobb szűrő a jobb választás.

A hálózat mélységét tekintve megállapítható, hogy a mélyebb hálózat alkalmazása nem feltétlenül előnyösebb, mint egy sekélyebb. Egy több konvolúciót tartalmazó hálózat elméletileg relevánsabb jellemzőket nyerhet ki, így jobb osztályozást teljesítményt nyújthat. Ezzel szemben a több paraméter miatt több időt vesz igénybe a tanítás, és hajlamosabb a túltanulásra is, ami kevésbé általánosítható modellt eredményez. A táblázat adatai azt mutatják, hogy a sekélyebb *CNN1* jobban teljesített ebben a feladatban, mint a mélyebb *CNN4*.

Ugyanezen az adatbázison, szintén 20 fő adatait felhasználva, jobb eredményt (97,7%) értünk el, mint a [16] cikkben közölt 93,86%. A [17]-es cikk szerzői 10 fős adathalmazt használtak, és az általuk közölt 96,36%-os pontosság elmarad az általunk elért 99,1%-tól.

## IRODALMI HIVATKOZÁSOK

- [1] Sanei, S.; Chambers, J.A. *EEG Signal Processing*; Wiley: Oxford, UK, 2007; ISBN-13: 9780470025819.
- [2] Schirmer, R.T.; Springenberg, J.T.; Fiederer, L.; Glasstetter, M.; Eggensperger, K.; Tangermann, M.; Hutter, F.; Burgard, W.; Ball, T. *Deep learning with convolutional neural networks for EEG decoding and visualization*. arXiv 2018, arXiv:1703.05051v5.
- [3] Krishna, D.H.; Pasha, I.A.; Savithri, T.S. *Classification of EEG Motor Imagery Multi Class Signals Based on Cross Correlation*. *Procedia Comput. Sci.* 2016, 85, 490–495.
- [4] Chen, Z.; Wang, Y.; Song, Z. *Classification of Motor Imagery Electroencephalography Signals Based on Image Processing Method*. *Sensors* 2021, 21, 4646.
- [5] Wu, Y.-T.; Huang, T.H.; Lin, C.Y.; Tsai, S.J.; Wang, P.-S. *Classification of EEG Motor Imagery Using Support Vector Machine and Convolutional Neural Network*. In Proceedings of the 2018 International Automatic Control Conference (CAC), Taoyuan, Taiwan, 10 January 2019.
- [6] León, J.; Escobar, J.J.; Ortiz, A.; Ortega, J.; González, J.; Martín-Smith, P.; Gan, J.Q.; Damas, M. *Deep learning for EEG-based Motor Imagery classification: Accuracy-cost trade-off*. *PLoS ONE* 2020, 15, e0234178.
- [7] Wang, Z.; Cao, L.; Zhang, Z.; Gong, X.; Sun, Y.; Wang, H. *Short time Fourier transformation and deep neural networks for motor imagery brain computer interface recognition*. *Concurr. Comput. Pract. Exp.* 2018, 30, e4413.
- [8] Behri, M.; Subasi, A.; Qaisar, S.M. *Comparison of machine learning methods for two class motor imagery tasks using EEG in brain-computer interface*. In Proceedings of the 2018 Advances in Science and Engineering Technology International Conferences (ASET), Dubai, United Arab Emirates, 11 June 2018.
- [9] Jia, H.; Wang, S.; Zheng, D.; Qu, X.; Fan, S. *Comparative study of motor imagery classification based on BP-NN and SVM*. *J. Eng.* 2019, 2019, 8646–8649.
- [10] Craik, A.; He, Y.; Contreras-Vidal, J.L. *Deep learning for electroencephalogram (EEG) classification tasks: A review*. *J. Neural Eng.* 2019, 16, 031001.
- [11] Schalk, G.; McFarland, D.J.; Hinterberger, T.; Birbaumer, N.; Wolpaw, J.R. *EEG Motor Movement/Imagery Dataset*. Available online: <https://physionet.org/content/egmmidb/1.0.0/> (Utolsó letöltés: 2021.06.12.)
- [12] Gaur, P.; Gupta, H.; Chowdhury, A.; McCreddie, K.; Pachori, R.B.; Wang, H. *A Sliding Window Common Spatial Pattern for Enhancing Motor Imagery Classification in EEG-BCI*. *IEEE Trans. Instrum. Meas.* 2021, 70, 1–9.
- [13] Blanco-Mora, D.; Aldridge, A.; Jorge, C.; Vourvopoulos, A.; Figueiredo, P.; Bermúdez i Badia, S. *Finding the Optimal Time Window for Increased Classification Accuracy during Motor Imagery*. In Proceedings of the 14th International Joint Conference on Biomedical Engineering Systems and Technologies, Vienna, Austria, 11–13 February 2021; pp. 144–151.
- [14] Saha, S.; Baumert, M. *Intra- and Inter-subject Variability in EEG-Based Sensorimotor Brain Computer Interface: A Review*. *Front. Comput. Neurosci.* 2020, 13, 87.
- [15] Altuwaijri, G.A.; Muhammad, G. *A Multibranch of Convolutional Neural Network Models for Electroencephalogram-Based Motor Imagery Classification*. *Biosensors* 2022, 12, 22.
- [16] Huang, W.; Chang, W.; Yan, G.; Yang, Z.; Luo, H.; Pei, H. *EEG-based motor imagery classification using convolutional neural networks with local reparameterization trick*. *Expert Syst. Appl.* 2022, 187, 115968.
- [17] Lun, X.; Liu, J.; Zhang, Y.; Hao, Z.; Hou, Y. *A Motor Imagery Signals Classification Method via the Difference of EEG Signals between Left and Right Hemispheric Electrodes*. *Front. Neurosci.* 2022, 16, 865594.